



Ақпараттық технологиялар факультеті
Факультет информационных технологий
Faculty of Information technologies

Студенттер мен жас ғалымдардың
«ФАРАБИ ӘЛЕМІ» атты
халықаралық ғылыми конференциясының
МАТЕРИАЛДАРЫ

МАТЕРИАЛЫ
международной научной конференции
студентов и молодых ученых
«ФАРАБИ ӘЛЕМІ»

MATERIALS
Of International Scientific Conference
of Students and Young Scientists
«FARABI ALEMI»



Алматы, 2025 жыл

ӘЛ-ФАРАБИ АТЫНДАҒЫ ҚАЗАҚ ҰЛТТЫҚ УНИВЕРСИТЕТІ
КАЗАХСКИЙ НАЦИОНАЛЬНЫЙ УНИВЕРСИТЕТ ИМЕНИ АЛЬ-ФАРАБИ
AL-FARABI KAZAKH NATIONAL UNIVERSITY

Ақпараттық технологиялар факультеті
Факультет информационных технологий
Faculty of Information technologies

«ФАРАБИ ӘЛЕМІ»

атты студенттер мен жас ғалымдардың халықаралық ғылыми конференция
МАТЕРИАЛДАРЫ
Алматы, Қазақстан, 2025 жылдың 3-5 сәуірі

МАТЕРИАЛЫ
международной конференции студентов и молодых учёных
«ФАРАБИ ӘЛЕМІ»
Алматы, Казахстан, 3-5 апреля 2025 года

MATERIALS
International Scientific Conference of Students and Young
Scientists
«FARABI ALEMI»
Almaty, Kazakhstan, April 3-5, 2025

Алматы
«Қазақ университеті»
2025

Ответственные секретари:

Сарсембаева Т.С.

Болтабоева А.К.

Байспай Г.Б.

Мұханбет А.

Шормакова А.Н.

Материалы международной научной конференции студентов и молодых учёных «Фараби әлемі». Алматы, Казахстан, 3-5 апреля 2025 года. – Алматы: Қазак университеті, 2025. – 567 стр.

ISBN 978-601-04-7105-4

На факультете информационных технологий Казахского национального университета имени аль-Фараби ежегодно проводится **Международная научная конференция студентов и молодых ученых «Фараби Әлемі»**. В конференции традиционно принимают участие студенты, магистранты, докторанты и молодые ученые из различных вузов и научных организаций.

В рамках конференции представлены научные работы **теоретического, экспериментального и прикладного характера** по следующим секциям:

- Современные подходы и технологии науки о данных и искусственного интеллекта
- Интеллектуальные системы управления и автоматизация: решения для умных технологий
- Кибербезопасность и криптология
- Современные тенденции в компьютерных науках и инженерии
- Математические методы и машинное обучение в интеллектуальных информационных системах

Сборник включает в себя **тезисы докладов**, отражающие современные исследования в различных областях информационных технологий. В представленных работах затрагиваются актуальные проблемы фундаментальной и прикладной науки, предлагаются инновационные решения и методики, направленные на развитие технических и естественных наук. Материалы сборника полезны для студентов, исследователей и преподавателей, интересующихся последними достижениями в области информационных технологий.

КазНУ имени аль-Фараби, 2025.

ISBN 978-601-04-7105-4

МАЗМУНЫ/СОДЕРЖАНИЕ/CONTENT

«ЖАСАНДЫ ИНТЕЛЛЕКТ ЖӘНЕ ДЕРЕКТЕР ТУРАЛЫ ҒЫЛЫМ: ЗАМАНАУИ ТӘСІЛДЕР МЕН ТЕХНОЛОГИЯЛАР» СЕКЦИЯСЫ СЕКЦИЯ «СОВРЕМЕННЫЕ ПОДХОДЫ И ТЕХНОЛОГИИ НАУКИ О ДАННЫХ И ИСКУССТВЕННОГО ИНТЕЛЛЕКТА» «MODERN APPROACHES AND TECHNOLOGIES OF DATA SCIENCE AND ARTIFICIAL INTELLIGENCE» SECTION

1. <i>Abish M.B., Pyrkova A.Y.</i> APPLICATION OF MACHINE LEARNING METHODS FOR GENOMIC DATA ANALYSIS IN BIOINFORMATICS.....	18
2. <i>Аблаи Ғ.А., Сарсембаева Т.С.</i> ЖАСАНДЫ ИНТЕЛЛЕКТ ЖӘНЕ ИОТ ТЕХНОЛОГИЯСЫ НЕГІЗІНДЕ БИОМЕТРИЯЛЫҚ ДЕРЕКТЕРДІ ТАЛУҒА АРНАЛҒАН ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕНІ ӘЗІРЛЕУ.....	20
3. <i>Аблаи Ғ.А., Сарсембаева Т.С.</i> СИСТЕМА БИОМЕТРИЧЕСКОГО РАСПОЗНАВАНИЯ НА ОСНОВЕ АНАЛИЗА ВЕН ЛАДОНИ С ИСПОЛЬЗОВАНИЕМ ИНФРАКРАСНОЙ ТЕХНОЛОГИИ.....	22
4. <i>Абсадықов Д.Б., Нұрахов Е.</i> COMPARATIVE ANALYSIS OF MEDIAPIPE AND YOLO MODELS FOR POSE ESTIMATION: PERFORMANCE EVALUATION ACROSS VARIOUS CONDITIONS.....	24
5. <i>Ази О.Ж., Шаяхметова А.С.</i> СУДЫ ТҮШЫЛАНДЫРУ ПРОЦЕСІНДЕ ҚОЛДАНЫЛАТЫН ӘДІСТЕР МЕН ТЕХНОЛОГИЯЛАРҒА ШОЛУ.....	27
6. <i>Аманжолов Е.Н., Сарсембаева Т.С.</i> БЛОКЧЕЙН ТЕХНОЛОГИЯЛАРЫН ОҚЫТУҒА АРНАЛҒАН ОҚУ ОЙЫНЫН ӘЗІРЛЕУ ЖӘНЕ МАШИНАЛЫҚ ОҚЫТУ ЭЛЕМЕНТТЕРІН БІРІКТІРУ АРҚЫЛЫ ТИІМДІЛІКТІ БАҒАЛАУ.....	29
7. <i>Аманжолов Е.Н., Сарсембаева Т.С.</i> МАШИНАЛЫҚ ОҚЫТУ (ML) ЖӘНЕ КҮШЕЙТІЛГЕН ОҚЫТУ (REINFORCEMENT LEARNING) ӘДІСТЕРІ.....	30
8. <i>Арманқызы З.</i> ЖАСАНДЫ ИНТЕЛЛЕКТ АЛГОРИТМДЕРІН ПАЙДАЛАНА ОТЫРЫП, КӨЛІК АҒЫНДАРЫН АВТОМАТТАНДЫРЫЛҒАН БАСҚАРУ.....	32
9. <i>Ахметжан Б., Джомартова Ш.А.</i> АДАМДЫ САУСАҚ ІЗДЕРІ АРҚЫЛЫ ЖЕКЕ БАСЫН ТАЛУ ПРОЦЕСІН ОҒТАЙЛАНДЫРУ.....	34
10. <i>Ахметжанов Ф.Р., Нуртаева Г.К.</i> ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ, БУДУЩЕЕ И ЭТИКА: ВЛИЯНИЕ ИИ НА ВОСПРИЯТИЕ РЕАЛЬНОСТИ.....	35
11. <i>Әбдіхан Ж.Б., Шаяхметова А.С.</i> ИИ АВТОМАТИЗАЦИЯ ОБРАБОТКИ ЗАПРОСОВ ПОЛЬЗОВАТЕЛЕЙ СЛУЖБОЙ ТЕХНИЧЕСКОЙ ПОДДЕРЖКИ КОМПАНИИ: ПОВЫШЕНИЕ ЭФФЕКТИВНОСТИ И КАЧЕСТВА ОБСЛУЖИВАНИЯ.....	36
12. <i>Багатикова А.С., Егизбаева А.Ж., Шакирова Г.А.</i> ҮЛКЕН ТІЛДІК ҮЛГІЛЕРДІ ҮЙРЕТУ ҮШІН ҚАЗАҚША МӘТІНДЕРДІ БЕЛГІЛЕУ.....	39
13. <i>Бақытұлы А., Исабаева Д.Н.</i> ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ОБРАЗОВАТЕЛЬНЫХ ПЛАТФОРМАХ ДЛЯ УЛУЧШЕНИЯ ПРОЦЕССА ОБУЧЕНИЯ.....	41
14. <i>Егизбаева А.Ж., Багатикова А.С., Шакирова Г.А.</i> ҮЛКЕН ТІЛДІК МОДЕЛЬДЕРДІ ОҚЫТУ ЖӘНЕ ТЕСТІЛЕУ ҮШІН ҚАЗАҚША МӘТІНДЕР КОРПУСЫН ҚҰРУ.....	43
15. <i>Джұраев Д.Б., Уалиева И.М.</i> СРАВНЕНИЕ ЭФФЕКТИВНОСТИ VIT И МАХVIT НА НАБОРЕ ДАННЫХ О БОЛЕЗНЯХ ЛИСТЬЕВ РИСА.....	45
16. <i>Жанабил А.Ғ., Зиятбекова Г.З.</i> КӘСПОРЫННЫҢ ВИРТУАЛДЫ ӨКІЛІ ҮШІН ҮЛКЕН ДЕРЕКТЕРДІ САҚТАУ ИНФРАҚҰРЫЛЫМЫН ЖОБАЛАУ.....	47
17. <i>Жанболат Г.Ж., Сарсембаева Т.С.</i> ПОСТКОВИД СИНДРОМЫН ТАЛДАУДЫҢ ЗАМАНАУИ ӘДІСІ: МАШИНАЛЫҚ ОҚЫТУ ЖҮЙЕСІН ҚОЛДАНУ.....	49
18. <i>Жанболат Г.Ж., Сарсембаева Т.С.</i> VR/AR ТЕХНОЛОГИЯЛАРЫМЕН ҚАШЫҚТАН БІЛІМ БЕРУ ПЛАТФОРМАСЫ.....	51

19. Жәділ Е.Н., Сарсембаева Т.С. СТУДЕНТТЕРДІ ҚОЛДАУ ҚЫЗМЕТТЕРІН ЖАҚСARTY YШІН ЖАСАНДЫ ИНТЕЛЛЕКТПЕН БАСҚАРЫЛАТЫН АҚЫЛДЫ САНДЫҚ КӨМЕКШІ ЧАТ- БОТ.....	53
20. Жетпісбай Ж.Е., Жасұзақ М.С. РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНОГО МОДУЛЯ НА ОСНОВЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОБРАБОТКИ И АНАЛИЗА ЭПИГЕНЕТИЧЕСКОГО ВОЗРАСТА.....	55
21. Жыйлысова Д.С., Сарсембаева Т.С. ЖАСАНДЫ ИНТЕЛЛЕКТ ЖӘНЕ ЗАТТАР ИНТЕРНЕТІ ТЕХНОЛОГИЯЛАРЫ НЕГІЗІНДЕ ҚАЛДЫҚТАРДЫ ЖИНАУ ЖӘНЕ СҰРЫПТАУДЫ БАСҚАРУДЫҢ ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕСІН ҚҰРУ.....	56
22. Kengeszhan D. APPLICATIONS OF ARTIFICIAL INTELLIGENCE IN MONITORING EMERGING SOIL CONTAMINANTS.....	57
23. Керімбекова Э.М., Сарсембаева Т.С. ҚАЛАЛЫҚ КӨЛІК ЖҮЙЕЛЕРІН ОҢТАЙЛАНДЫРУ YШІН НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ ПАЙДАЛАНЫП ТРАФИКТІ МОДЕЛЬДЕУ.....	59
24. Кәрім М.М., Сарсембаева Т.С. МАШИНАЛЫҚ ОҚЫТУ ЖӘНЕ КҮШЕЙТІЛГЕН ОҚЫТУДЫҢ ЖАСАНДЫ ИНТЕЛЛЕКТТЕГІ РӨЛІ.....	61
25. Кәрім М.М., Сарсембаева Т.С. БЛОКЧЕЙН ТЕХНОЛОГИЯЛАРЫН ОҚЫТУҒА АРНАЛҒАН ОҚУ ОЙЫНЫҢ ӘЗІРЛЕУ ЖӘНЕ БАҚЫЛАУ.....	63
26. Кошанова А.К., Мансурова М.Е. САД/САМ ТЕХНОЛОГИЯЛАРЫН ҚОЛДАНА ОТЫРЫП, ЦИФРЛЫҚ ОРТАДАҒЫ МОДЕЛЬДЕРДІ ВИЗУАЛИЗАЦИЯЛАУ ЖӘНЕ ТАЛДАУ.....	65
27. Қайырбекова А.Ж., Зиятбекова Г.З. ЦИФРЛЫҚ ЕГІЗ YШІН ДЕРЕКТЕРДІ ЖИНАУ ЖӘНЕ САҚТАУ ЖҮЙЕСІНДЕ ҚҰПИЯЛЫЛЫҚТЫ ҚАМТАМАСЫЗ ЕТУ.....	66
28. Құмарханов А.Д. ПРОГНОЗИРОВАНИЯ ПСИХИЧЕСКОГО БЛАГОПОЛУЧИЯ ПАЦИЕНТОВ С КОГНИТИВНЫМИ НАРУШЕНИЯМИ.....	68
29. Құмарханов А.Д. РАЗРАБОТКА ИИ-КОМПАЊОНА ДЛЯ ПОДДЕРЖКИ ПСИХИЧЕСКОГО ЗДОРОВЬЯ В КАЗАХСТАНЕ С УЧЕТОМ КУЛЬТУРНЫХ ОСОБЕННОСТЕЙ.....	70
30. Мухамбеткалиева М., Шаяхметова А.С., Ахметова А.М. ҚҰРЫЛЫС КОМПАНИЯСЫНДА ЖЫЛЖЫМАЙТЫН МҮЛІК ОБЪЕКТІЛЕРІН ЖОСПАРЛАУ МЕН АҒЫМДАҒЫ ЕСЕБІНІҢ АВТОМАТТАНДЫРЫЛҒАН ЖҮЙЕСІН ҚҰРУДЫ ҰЙЫМДАСТЫРУ.....	71
31. Мұхаммеджанова Д.М. АҚПАРАТТЫҚ ЖҮЙЕЛЕРДЕ МЕДИЦИНАЛЫҚ ДЕРЕКТЕРДІ ҚАУІПСІЗДІГІН БОЛЖАУ ЖӘНЕ ҚАМТАМАСЫЗ ЕТУ YШІН ЖАСАНДЫ ИНТЕЛЛЕКТ ӘДІСТЕРІН ӘЗІРЛЕУ ЖӘНЕ ЗЕРТТЕУ.....	73
32. Мұхтарқызы М., Шаяхметова А.С., Ахметова А.М. АТ-МЕНЕДЖМЕНТІ КЕҢСЕ ТЕХНИКАСЫНА ҚЫЗМЕТ КӨРСЕТУГЕ СҰРАНЫСТАРДЫ БЕРУ, ЕСЕПКЕ АЛУ ЖӘНЕ ОРЫНДАУ ЖҮЙЕСІН АВТОМАТТАНДЫРУДЫ ҰЙЫМДАСТЫРУ.....	75
33. Нағашыбек А.Б., Сарсембаева Т.С. РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ РЕАБИЛИТАЦИИ ПАЦИЕНТОВ С НАРУШЕНИЯМИ МОТОРНЫХ ФУНКЦИЙ НА ОСНОВЕ ИГРОВЫХ ТЕХНОЛОГИЙ.....	77
34. Нурумбаев Д.Н. МАШИНАЛЫҚ ОҚЫТУ ЖӘНЕ КОМПЬЮТЕРЛІК КӨРУ ТЕХНОЛОГИЯЛАРЫН ҚОЛДАНА ОТЫРЫП, РОБОТТАНДЫРЫЛҒАН ӨНІМ ЖИНАУ ЖҮЙЕСІН ЖОБАЛАУ.....	79
35. Нұрғазы Т.Н., Амирханова Г.А. ТАМАҚ ӨНЕРКӘСІБІНІҢ ВИРТУАЛДЫ МОДЕЛІН КӨРСЕТУ YШІН ТОЛЫҚТЫРЫЛҒАН ШЫНДЫҚТЫ ПАЙДАЛАУ.....	80
36. Оразай Ә.Н., Сарсембаева Т.С. БІЛІМ БЕРУДЕГІ ЖАСАНДЫ ИНТЕЛЛЕКТ.....	82
37. Орынбек Б.Б., Зиятбекова Г.З. ВИРТУАЛДЫ МОДЕЛЬДІ ҚОЛДАНА ОТЫРЫП, КӘСПОРЫН ЖҰМЫСЫНЫҢ СИМУЛЯЦИЯЛЫҚ МОДЕЛЬДЕРІН ҚҰРУ ЖӘНЕ ТАЛДАУ.....	84

38. <i>Өскенбаев С.Т., Асет А.</i> ҚҰРЫЛЫС НЫСАНДАРЫНА АРНАЛҒАН ӨЛШЕМДЕРДІ ҚАШЫҚТЫҚТАН ТАНИТЫН КАМЕРА ҚОЛДАНАТЫН ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕ ҚҰРУ.....	85
39. <i>Өскенбаева А.А., Сарсембаева Т.С.</i> НАУҚАСТАРДЫҢ ЖАҒДАЙЫН НАҚТЫ УАҚЫТ РЕЖИМІНДЕ БАҚЫЛАУ ҮШІН ІОТ ТЕХНОЛОГИЯЛАРЫН ҚОЛДАНАТЫН СМАРТ ПАЛАТАНЫ ӨЗІРЛЕУ.....	86
40. <i>Пазилханов А.И., Бисембаев А.С.</i> ПРИМЕНЕНИЕ КЛАСТЕРНОГО АНАЛИЗА ДЛЯ ИНТЕЛЛЕКТУАЛЬНОГО УПРАВЛЕНИЯ ВЕТРОЭНЕРГЕТИЧЕСКИМИ СИСТЕМАМИ..	88
41. <i>Полатбек Е.А., Оспан Ә.Ғ.</i> ҚАЗАҚ ТІЛІНДЕГІ МӘТІНДЕРДІ ӨНДЕУ ҮШІН RETRIEVAL-AUGMENTED GENERATION (RAG) ӘДІСТЕРІН ҚОЛДАНУДЫҢ ТИІМДІЛІГІН БАҒАЛАУ.....	90
42. <i>Райымбергенов Б.Т., Бедельбаев А.А.</i> DEEPFAKE ЖӘНЕ ЭТИКАЛЫҚ МӘСЕЛЕЛЕР.....	92
43. <i>Сабурова Н.Б.</i> МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН ҚОЛДАНУ АРҚЫЛЫ КЕСКІНДЕРДІ СЫҒУ ТЕХНОЛОГИЯЛАРЫН ЖЕТІЛДІРУ.....	94
44. <i>Сайлау А.Ж., Оспан Ә.Ғ.</i> ҮЛКЕН ТІЛДІК ҮЛГІЛЕР ҮШІН ҚАЗАҚША МӘТІНДЕРДІ АЛДЫН АЛА ӨНДЕУ ӘДІСТЕРІН ӨЗІРЛЕУ.....	96
45. <i>Самигуллаев Д.С., Бельгибаев Б.А.</i> ИНТЕЛЛЕКТУАЛЬНОЕ РЕЧЕВОЕ РАСПОЗНАВАНИЕ КОМАНД ДЛЯ УДАЛЕННОГО УПРАВЛЕНИЯ РАСПАШНЫМИ ВОРОТАМИ.....	98
46. <i>Смамқожаев М.Т., Омаров Б.</i> НАВИГАЦИЯ В ПОМЕЩЕНИИ И НАХОЖДЕНИЕ НАИБОЛЕЕ ОПТИМАЛЬНОГО МАРШРУТА ПРИ ПОМОЩИ СОЧЕТАНИЯ АЛГОРИТМОВ.....	100
47. <i>Сугирбаев А.А., Зиятбекова Г.З.</i> РАЗРАБОТКА МАШИННОГО ОБУЧЕНИЯ ДЛЯ АНАЛИЗА ДАННЫХ УСТРОЙСТВА МОНИТОРИНГА СТРЕССА.....	102
48. <i>Султанова А., Макашев Е.</i> DEVELOPING A SMART CAMERA PROGRAM USING ARTIFICIAL INTELLIGENCE.....	105
49. <i>Tang Daoyun, Amir Khanova G.</i> MULTIMODAL DATA MINING ALGORITHM FOR ABNORMAL CASES OF AUTONOMOUS DRIVING.....	107
50. <i>Талғатұлы Ә., Абдилдаева А.А.</i> ДЕРЕКТЕРДІ ТАЛДАУ ӘДІСТЕРІ НЕГІЗІНДЕ АҚАУЛАРДЫ БАСҚАРУДЫҢ ИНТЕЛЛЕКТУАЛДЫ АВТОМАТТАНДЫРУ ЖҮЙЕСІН ҚҰРУ.....	109
51. <i>Темірханова А.Б., Оспан Ә.Ғ.</i> МӘТІНДІ АВТОМАТТЫ ТҮРДЕ БЕЛГІЛЕУ ӘДІСТЕРІНІҢ ҮЛКЕН ТІЛДІК ҮЛГІЛЕРДІҢ ДӘЛДІГІ МЕН ТИІМДІЛІГІНЕ ӨСЕРІН БАҒАЛАУ.....	111
52. <i>Тусупов А.К., Тулеев А.А., Зиятбекова Г.З.</i> СБОР ДАННЫХ С ДАТЧИКОВ ДЛЯ ЦИФРОВОГО ДВОЙНИКА ПРЕДПРИЯТИЯ.....	113
53. <i>Хамитова К.Ә., Тойғанбаева Н.А.</i> LLM МОДЕЛЬДЕРІНЕ ШОЛУ ЖАСАУ.....	116
54. <i>Шаймов Б.А., Ахметова А.М.</i> ЖАСАНДЫ ИНТЕЛЛЕКТТІ ПАЙДАЛАНА ОТЫРЫП, ҚАРЖЫЛЫҚ НЕГІЗГІ ТИІМДІЛІК КӨРСЕТКІШТЕРІН БАСҚАРУ, ТӘУЕКЕЛДЕРДІ БАСҚАРУ ЖӘНЕ НОРМАТИВТІК ТАЛАПТАРДЫ САҚТАУ.....	118
55. <i>Шаймов Б.А., Ахметова А.М.</i> ОБЗОР МЕТОДОВ ПРЕДВАРИТЕЛЬНОЙ ОБРАБОТКИ ДАННЫХ ДЛЯ АВТОМАТИЗИРОВАННЫХ СИСТЕМ МОНИТОРИНГА.....	120
56. <i>Шайхиева Ж.М., Амирханова Г.А.</i> ГЕНЕРАЦИЯ ТЕКСТА С ПОМОЩЬЮ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ: ТЕХНИКИ PROMPT- ИНЖИНИРИНГА.....	123
57. <i>Жұмахан А., Сарсембаева Т.С.</i> ИНСУЛЬТТАН КЕЙІНГІ РЕАБИЛИТАЦИЯ ҮШІН КІНЕСТ-ТЕГІ КОГНИТИВТІ-ҚОЗҒАЛЫСТЫҚ ҚОСАРЛАНҒАН ТАПСЫРМАЛАРҒА НЕГІЗДЕЛГЕН МОДУЛЬДІК ЖҮЙЕ.....	125
58. <i>Темір Н.К., Шаяхметова А.С.</i> БИЗНЕС-ПРОЦЕСТЕРДІ ТАЛДАУ ӘДІСТЕРІН ЖЕТІЛДІРУ АРҚЫЛЫ ОҢТАЙЛАНДЫРУ.....	127

**«ИНТЕЛЛЕКТУАЛДЫ БАСҚАРУ ЖҮЙЕЛЕРІ ЖӘНЕ АВТОМАТТАНДЫРУ:
СМАРТ ТЕХНОЛОГИЯЛАРҒА АРНАЛҒАН ШЕШІМДЕР» СЕКЦИЯСЫ
СЕКЦИЯ «ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ УПРАВЛЕНИЯ И
АВТОМАТИЗАЦИЯ: РЕШЕНИЯ ДЛЯ УМНЫХ ТЕХНОЛОГИЙ»
«INTELLIGENT CONTROL SYSTEMS AND AUTOMATION:
SOLUTIONS FOR SMART TECHNOLOGIES» SECTION**

1. *Абсатарова А.А., Абжанова Л.Қ.* ӨНЕРКӘСПТІК АҒЫНДЫ СУЛАРДЫ ТАЗАРТУ ПРОЦЕСІН БАСҚАРУДЫҢ ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕСІ.....130
2. *Аркатов.Е.А., Бейсембаева А.К., Жұмахан Н.Б.* ҚҰБЫРДЫ ТАЗАЛАУ ҮШІН ҚАДАМДЫ РОБОТТЫҢ БАСҚАРУ ЖҮЙЕСІН ЗЕРТТЕУ.....132
3. *Аскарлов Е.Е., Бейсембаев А.А.* АЛГОРИТМЫ ДВИЖЕНИЯ 4-СТЕПЕННОГО МАНИПУЛЯЦИОННОГО РОБОТА ПО ЗАДАНЫМ ТРАЕКТОРИЯМ.....134
4. *Асланов А.А., Асет А.* ДИЗАЙН ЖӘНЕ ӨНДІРІСТІК ИНЖЕНЕРИЯ ҮШІН ЦИФРЛЫҚ ЕГІЗДІ ҚАЛЫПТАСТЫРУ.....136
5. *Асланов А.А., Асет А.* КӘСПОРЫННЫҢ ЦИФРЛЫҚ ЕГІЗІН ВИРТУАЛДЫ ОРТАДА ВИЗУАЛИЗАЦИЯЛАУ ЖӘНЕ ТАЛДАУ.....137
6. *Асылхан Б.С.* ТАУ-КЕН ӨНЕРКӘСІБІНДЕГІ ҰНТАҚТАУ ПРОЦЕСІН АВТОМАТТАНДЫРУ ЖӘНЕ ТИІМДІЛІГІН АРТТЫРУ.....138
7. *Ахметов К.Т., Толегенова М.С.* ЦИФРОВОЙ ПИД-РЕГУЛЯТОР И ПРИМЕНЕНИЕ ЕГО В ПРАКТИКЕ УПРАВЛЕНИЯ БЕСКОЛЛЕКТОРНЫХ ДВИГАТЕЛЕЙ.....140
8. *Байғараева Ж.Е., Болтабоева А.К., Иманбек Б.Т., Ибрашева З.С., Jetal A.G., Амирханова Г.А.* НАҚТЫ НАУҚАСТЫҢ ДЕНСАУЛЫҒЫН ЖӘНЕ ҚОРШАҒАН ОРТАНЫҢ ФАКТОРЛАРЫН МОНИТОРИНГ ЖҮРГІЗУГЕ АРНАЛҒАН ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕНІ ӨЗІРЛЕУ ҮШІН ЗАТТАР ИНТЕРНЕТІ МЕН МАШИНАЛЫҚ ОҚЫТУДЫ ИНТЕГРАЦИЯЛАУ.....142
9. *Бақтыбай А.А.* МОДЕЛИ И АЛГОРИТМЫ ОПИСАНИЯ РАБОЧИХ ПРОСТРАНСТВ 3-Х СТЕПЕННЫХ ШАРНИРНЫХ МАНИПУЛЯЦИОННЫХ РОБОТОВ В ВИДЕ ЛОГИЧЕСКИХ ФУНКЦИЙ.....144
10. *Бахтова Д.И.* ВЛИЯНИЕ НАСЛЕДИЯ ФАРАБИ НА СОВРЕМЕННЫЕ ОБРАЗОВАТЕЛЬНЫЕ ТЕХНОЛОГИИ.....146
11. *Болатов Б.Б.* ӨЛ-ФАРАБИ ИДЕЯЛАРЫ ЖӘНЕ БОЛАШАҚ ҒЫЛЫМЫ.....147
12. *Берікқазы О.Б.* РАЗРАБОТКА И ИССЛЕДОВАНИЕ ИНТЕЛЛЕКТУАЛЬНЫХ АЛГОРИТМОВ УПРАВЛЕНИЯ ПРОЦЕССОМ АДСОРБЦИИ СЕРОВОДОРОДА.....149
13. *Есенаманов Ж.Ө., Елдесов Т.А., Қосбақ А.* "АҚЫЛДЫ ҮЙ" ЖОБАСЫНЫҢ НЕГІЗДЕРІ ЖӘНЕ ҚҰРЫЛЫМДЫҚ ЕРЕКШЕЛІКТЕРІ.....152
14. *Жандин С.В.* РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ УСОВЕРШЕНСТВОВАННОГО УПРАВЛЕНИЯ ПРОЦЕССАМИ НА ВЫСОКОТЕХНОЛОГИЧНОМ ПРЕДПРИЯТИИ.....154
15. *Жиганбеков Қ.* КОНСТРУКЦИЯ И ПРИМЕНЕНИЕ ОБОИМ В ПОДШИПНИКОВЫХ УЗЛАХ.....156
16. *Кайрат А.А.* АНАЛИЗ СОСТОЯНИЯ И ПЕРСПЕКТИВЫ ВНЕДРЕНИЯ ЦИФРОВЫХ ДВОЙНИКОВ ДЛЯ ИНТЕЛЛЕКУТАЛЬНЫХ СЛОЖНЫХ СИСТЕМ УПРАВЛЕНИЯ.....157
17. *Исмұханбетов Б.Т., Бектас М.Н.* ӨНЕРКӘСПТІК ЦЕХТАР МЕН ЗАУЫТТАРДА ҚАРА ЖОЛДЫ ІЗДЕУ АЛГОРИТМІНЕ НЕГІЗДЕЛГЕН РОБОТТАРДЫ ПАЙДАЛАНУДЫ ЗЕРТТЕУ.....159
18. *Каратаева Ж.Е., Джумабекова З.А., Чакеева К.С.* УСТРОЙСТВО ПОМОЛА ЗЕРНА И ПРОМЕЖУТОЧНЫХ ПРОДУКТОВ В ВАЛЬЦОВЫХ СТАНКАХ ПОВЫШЕННОЙ ПРОИЗВОДИТЕЛЬНОСТИ.....161
19. *Койбағаров М., Алдияров Н., Рахметова П., Сыдыканов С.* ПРЕДИКТИВНЫЙ ПРОМЫШЛЕННЫЙ СЕРВИС С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ.....163

20. Кубашев Б. ИНТЕЛЛЕКТУАЛДЫ БАСҚАРУ ЖҮЙЕЛЕРІ ЖӘНЕ АВТОМАТТАНДЫРУ: АҚЫЛДЫ ҚҰРЫЛҒЫЛАРҒА АРНАЛҒАН ШЕШІМДЕР.....	166
21. Кутняков Д.И. РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНОЙ СЛОЖНОЙ СИСТЕМЫ УПРАВЛЕНИЯ КОТЛОАГРЕГАТАМИ НА ОСНОВЕ МОДЕЛЬНО ПРЕДИКТИВНОГО УПРАВЛЕНИЯ.....	168
22. Қуаныш А.Н., Сулейменов Б.А. ФИЛЬТРАТТАН КҮКІРТСУТЕКТІ ДЕСОРБЦИЯЛАУ ПРОЦЕСІН БАСҚАРУДЫҢ ИНТЕЛЛЕКТУАЛДЫ АЛГОРИТМДЕРІ: ҚАЗІРГІ ТӘСІДЕР МЕН БОЛАШАҒЫ.....	170
23. Намазбек А.Д. МҰНАЙ АЙДАУДЫҢ ТЕХНОЛОГИЯЛЫҚ ПРОЦЕСІН АВТОМАТТАНДЫРУ.....	173
24. Нұрхан А.М. ИНТЕЛЛЕКТУАЛДЫ БАСҚАРУ ЖҮЙЕЛЕРІНЕ КІРІСПЕ.....	175
25. Нығыманов Б.А. РАЗРАБОТКА СИСТЕМЫ ВИЗУАЛИЗАЦИИ ДАННЫХ ДЛЯ МОНИТОРИНГА ПРОИЗВОДСТВЕННЫХ ПРОЦЕССОВ С ИСПОЛЬЗОВАНИЕМ GRAFANA И PROMETHEUS.....	177
26. Оразай Ә.Н. АҚЫЛДЫ ДӘРІ-ДӨРМЕК ШКАФЫ: САҚТАУ ЖӘНЕ ҚОЛЖЕТІМДІЛІКТІ БАСҚАРУДЫҢ ИННОВАЦИЯЛАРЫ.....	179
27. Орманбекова А.А., Ильясов Е.С., Исмуханбетов Б.Т. ARDUINO НЕГІЗІНДЕГІ ИНТЕЛЛЕКТУАЛДЫ СҰРЫПТАУ ЖҮЙЕСІН ӨЗІРЛЕУ.....	181
28. Оспан А.Ж. АВТОМАТИЗАЦИЯ ТЕХНОЛОГИЧЕСКИХ ПРОЦЕССОВ НАСОСНОЙ СТАНЦИИ.....	184
29. Раева А.А., Амирханова Г.А. ЖОБАЛАРДЫ БАСҚАРУ ЖӘНЕ КОМАНДАЛЫҚ ЖҰМЫСҚА АРНАЛҒАН КЕШЕНДІ ШЕШІМ.....	186
30. Сақтаған А.А. ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА УПРАВЛЕНИЯ УСТАНОВКОЙ КАТАЛИТИЧЕСКОГО РИФОРМИНГА.....	188
31. Самигуллаев Д.С. ИНТЕЛЛЕКТУАЛЬНОЕ РЕЧЕВОЕ РАСПОЗНАВАНИЕ КОМАНД ДЛЯ УДАЛЕННОГО УПРАВЛЕНИЯ РАСПАШНЫМИ ВОРОТАМИ.....	190
32. Сарсембаева Т.С., Өскенбаева А.А. СМАРТ ТЕХНОЛОГИЯЛАРДЫҢ ДЕНСАУЛЫҚ САҚТАУ ЖҮЙЕСІНДЕГІ РӨЛІ ЖӘНЕ ОЛАРДЫҢ ТИІМДІЛІГІ.....	192
33. Сарсембаева Т.С., Жыйлысова Д.С. ЖАСАНДЫ ИНТЕЛЛЕКТ ЖӘНЕ ЗАТТАР ИНТЕРНЕТІ ТЕХНОЛОГИЯЛАРЫ НЕГІЗІНДЕ ҚАЛДЫҚТАРДЫ ЖИНАУ ЖӘНЕ СҰРЫПТАУДЫ БАСҚАРУДЫҢ ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕСІН ҚҰРУ.....	194
34. Серікханова А.М. РАЗРАБОТКА СИСТЕМЫ ЦИФРОВОГО УПРАВЛЕНИЯ ВЕТРОГЕНЕРАТОРНЫМИ УСТАНОВКАМИ.....	196
35. Смайлова П.Н. СҰЗУ ПРОЦЕСІН АВТОМАТТЫ РЕТТЕУ ЖҮЙЕСІН ӨЗІРЛЕУ.....	198
36. Солтангельдинова М.К. ГЛУБОКОЕ ОБУЧЕНИЕ CNN YOLO ДЛЯ ОНЛАЙН МОНИТОРИНГА И РАСПОЗНАВАНИЕ БОЛЕЗНЕЙ ПШЕНИЦЫ С ПОМОЩЬЮ КОМПЬЮТЕРНОГО ЗРЕНИЯ.....	199
37. Солтангельдинова М.К. ПРИМЕНЕНИЕ ИИ В МОДЕРНИЗАЦИИ ТЕХНОЛОГИЧЕСКОГО УКЛАДА СЕЛЬСКОГО ХОЗЯЙСТВА РК.....	201
38. Сұлтанбай А.Ж., Орманбекова А.А. ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АДАПТИВНОГО УПРАВЛЕНИЯ ВОЗДУХООБМЕНОМ В ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМАХ НА ОСНОВЕ IOT.....	202
39. Тулегенова Н.А. ОПИСАНИЕ РАБОЧЕГО ПРОСТРАНСТВА УПРАВЛЯЕМОГО РОБОТА В ВИДЕ ЛОГИЧЕСКИХ ФУНКЦИЙ.....	205
40. Фаизов Г.А., Утегенова А.У. ПРОЕКТИРОВАНИЕ ИНФОРМАЦИОННОЙ СИСТЕМЫ ОЦЕНКИ КАЧЕСТВА ВОДЫ В РЕКАХ ПУТЕМ ПОСТРОЕНИЯ ГИДРОПОСТА.....	207
41. Хамитова К. КОНСТРУКЦИЯ И ПРИМЕНЕНИЕ ОБОЙМ В ПОДШИПНИКОВЫХ УЗЛАХ.....	210
42. Харесова А.А. РАЗРАБОТКА СИСТЕМЫ ЦИФРОВОГО УПРАВЛЕНИЯ ВЕТРОГЕНЕРАТОРНЫМИ УСТАНОВКАМИ.....	211

43. Харесова А.А. МОДЕЛИ И АЛГОРИТМЫ ПРОГРАММНОГО УПРАВЛЕНИЯ РОБОТАМИ-МАНИПУЛЯТОРАМИ ТРЕХ ПОКОЛЕНИЙ С ИСПОЛЬЗОВАНИЕМ ПАКЕТА SIMMECHANICS.....	213
44. Шарасулов Ш.Ш. ИССЛЕДОВАНИЯ И РАЗРАБОТКА ЭФФЕКТИВНОЙ СИСТЕМЫ УПРАВЛЕНИЯ ЭЛЕКТРОФИЛЬТРАМИ НА ПРЕДПРИЯТИЯХ ГОРНОДОБЫВАЮЩЕЙ ПРОМЫШЛЕННОСТИ КАЗАХСТАНА.....	215
45. Шарипжан Б.Б., Балгабек А.Б., Шаймуранулы Н. IOT НЕГІЗІНДЕ АҚЫЛДЫ ЖЫЛЫЖАЙ ЖОБАЛАУ.....	217
46. Шугаева А.А. МОДЕЛИРОВАНИЕ ДВИЖЕНИЯ ЧЕТЫРЕХЗВЕННОГО РОБОТА В SIMMECHANICS.....	219
47. Шукенов Ж.Е. ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ УПРАВЛЕНИЯ В УМНЫХ ГОРОДАХ: АВТОМАТИЗАЦИЯ ДЛЯ РАЗВИТИЯ IOT-ИНФРАСТРУКТУРЫ.....	221
48. Ghulam Abbas Wafa NETSETSHOP: A SECURE, SCALABLE, AND INTELLIGENT E-COMMERCE PLATFORM USING DJANGO.....	223
49. Maulenkul A., Kerimberdy U., Nauryzbayeva A. INTELLIGENT QUALITY CONTROL SYSTEMS BASED ON COMPUTER VISION.....	224
50. Maulenkul A., Oleksandr G. Gurko, Karatayeva Zh. DIGITAL TWINS IN INTELLIGENT CONTROL SYSTEMS: PRINCIPLES AND DEVELOPMENT PROSPECTS.....	227
51. Mazhit M.T., Ormanbekova A. AUTONOMOUS MOBILE ROBOTS: NAVIGATION AND CONTROL ALGORITHMS.....	229
52. Sapargaliyeva A., Samsaliev A., Jumabekova Z. MACHINE LEARNING ALGORITHMS IN INTELLIGENT CONTROL SYSTEMS FOR INDUSTRIAL AND AGRICULTURAL ENTERPRISES.....	231
53. Zhaskairatov K., Alieva M. AUTOMATION OF PRODUCTION PROCESSES USING ARTIFICIAL INTELLIGENCE.....	232

«КИБЕРҚАУПСІЗДІК И КРИПТОЛОГИЯ» СЕКЦИЯСЫ
СЕКЦИЯ «КИБЕРБЕЗОПАСНОСТЬ И КРИПТОЛОГИЯ»
«CYBERSECURITY AND CRYPTOLOGY» SECTION

1. Абдуллаев Н.А., Ерболат Н., Мурзабеков З.Н. КӨЛІК МӘСЕЛЕЛЕРІН ШЕШУ ҮШІН ӨНІМДІ ТАСЫМАЛДАУДЫ ЖОСПАРЛАУ КЕЗІНДЕ КӘСПОРЫННЫҢ АҚПАРАТТЫҚ ҚАУІПСІЗДІГІН ҚАМТАМАСЫЗ ЕТУ..	235
2. Ақшолақ Г.И. КИБЕРҚАУІПСІЗДІКТІ КҮШЕЙТУ: МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІНІҢ ЗИЯНДЫ ЖЕЛІЛІК ТРАФИКТІ ТАЛДАУДАҒЫ РӨЛІ	236
3. Амангелді Н.Б., Болатбек М.А. ӘЛЕУМЕТТІК ЖЕЛІЛЕРДЕГІ ПАЙДАЛАНУШЫЛАРДЫҢ АГРЕССИВТІ МІНЕЗ-ҚҰЛҚЫН АНЫҚТАУ ЖӘНЕ ТАЛДАУ ӘДІСТЕРІН ЗЕРТТЕУ	237
4. Ануарбек А.М., Адилжанова С.А. СОВРЕМЕННЫЕ ПОДХОДЫ К КИБЕРБЕЗОПАСНОСТИ: ОБЛАЧНЫЕ ТЕХНОЛОГИИ, МАШИНОЕ ОБУЧЕНИЕ И АНАЛИЗ ДАННЫХ ДЛЯ ЗАЩИТЫ ИНФОРМАЦИИ.....	238
5. Ахметұлы Ә., Нарбаева С.М. СОЗДАНИЕ ПРИЛОЖЕНИЯ ДЛЯ ОБЕСПЕЧЕНИЯ СЕТЕВОЙ БЕЗОПАСНОСТИ «SECURENET».....	239
6. Базаркулова И.Е., Болатбек М.А. ҮЛКЕН ТІЛ МОДЕЛЬДЕРІНІҢ КИБЕРАГРЕССИЯНЫ АНЫҚТАУДАҒЫ РӨЛІ: МҮМКІНДІКТЕР, ШЕКТЕУЛЕР ЖӘНЕ БОЛАШАҚ ДАМУЫ	241
7. Ерген М.О., Нарбаева С.М. КОРПОРАТИВТІК ЖЕЛІНІ ЖОБАЛАУ ЖӘНЕ ҚОРҒАУ	242
8. Әбдыев М.О., Болатбек М.А. ЖАСТАР АРАСЫНДА ДЕСТРУКТИВТІ МАЗМҰНДЫ АНЫҚТАУ ЖӘНЕ ТАРАТУМЕН КҮРЕСУ ҚҰРАЛЫН ЗЕРТТЕУ.....	243
9. Әсетова Д.Ә., Темирбекова Ж.Е. МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН ҚОЛДАНА ОТЫРЫП, RSA АЛГОРИТМІНІҢ КРИПТОТӨЗІМДІЛІГІН ТАЛДАУ.....	244
10. Жапаров Д.Ж. ANALYSIS OF MODERN METHODS FOR DETECTING CYBER THREATS IN CORPORATE NETWORKS.....	245

11. Жолдыбаева Д.Ж., Болатбек М.А. ЖАСТАР ҮШІН ҚАУІПТІ ВЕБ-РЕСУРСТАРДЫ АНЫҚТАУ ӘДІСІН ЗЕРТТЕУ	247
12. Жубанышева Г.Т., Адилжанова С.А. АҚПАРАТТЫҚ ҚАУІПСІЗДІК САЛАСЫНДАҒЫ ТӘУЕКЕЛДЕРДІ ТАЛДАУ ЖӘНЕ БАСҚАРУ ҮШІН ПЛАТФОРМА ҚҰРУ	249
13. Жуманбаев Е.А., Байспай Г.Б. OSINT ТАЛДАУЫ ҮШІН АШЫҚ КӨЗДЕРДЕН ДЕРЕКТЕРДІ ЖИНАУДЫ АВТОМАТТАНДЫРУДЫҢ ТИІМДІЛІГІ.....	250
14. Кабыкенова С.Ф. ЖАЛҒАН АККАУНТТАРҒА ҚАРСЫ ГЕНЕРАТИВТІ БӘСЕКЕЛЕСУ ЖЕЛІЛЕРІ: ӘЛЕУМЕТТІК ЖЕЛІЛЕРДЕГІ АНОМАЛИЯЛАРДЫ АНЫҚТАУ.....	252
15. Нәдия Қ., Турарбек Ә.Т. МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІНІҢ КИБЕРҚАУІПСІЗДІК АУДИТІНДЕ ҚОЛДАНЫЛУЫ.....	253
16. Қалаубекова Ж.Қ. БИОМЕТРИЯЛЫҚ СӘЙКЕСТЕНДІРУДІҢ ДӘЛДІГІ МЕН ҚАУІПСІЗДІГІН АРТТЫРУҒА АРНАЛҒАН АНСАМБЛЬДІК МОДЕЛЬ.....	255
17. Мауленова А.М., Адилжанова С.А. СИММЕТРИЯЛЫҚ ЖӘНЕ АСИММЕТРИЯЛЫҚ КРИПТОГРАФИЯЛЫҚ АЛГОРИТМДЕРДІҢ ӨНІМДІЛІГІН САЛЫСТЫРМАЛЫ ТАЛДАУ.....	257
18. Миркасимова Т.Ш., Адилжанова С.А. МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН АҚПАРАТТЫҚ ҚАУІПСІЗДІК ТӘУЕКЕЛДЕРІН БАҒАЛАУДА ҚОЛДАНУ ТИІМДІЛІГІ..	258
19. Мырзақұл Ж.Н., Мусиралиева Ш.Ж. ЮТ ҚАУІПСІЗДІГІН АРТТЫРУҒА АРНАЛҒАН МОДИФИКАЦИЯЛАНҒАН ГОМОМОРФТЫ ШИФРЛАУ АЛГОРИТМІ.....	259
20. Омар А.Б., Мусиралиева Ш.Ж. ФЕДЕРАТИВТІ ОҚЫТУ: ТАРАТЫЛҒАН ҚҰРЫЛҒЫЛАРДА ҚҰПИЯ ДЕРЕКТЕРДІ ҚОРҒАУДЫҢ ЖАҢА ДӘУІРІ	260
21. Рахимов А.Ж. .NET ПЛАТФОРМАСЫНДАҒЫ АУТЕНТИФИКАЦИЯ ҚАУІПСІЗДІГІ..	262
22. Сағынай М., Болатбек М.А. ҚАЗАҚ ТІЛІНДЕГІ ҚАУІПТІ ВЕБ-КОНТЕНТТІ АНЫҚТАУ ЖӘНЕ ЖІКТЕУ ҮШІН МАШИНАЛЫҚ ОҚЫТУ МОДЕЛЬДЕРІН ҚҰРУ.....	264
23. Сериккажина М.С., Мурзабеков З.Н. ШАҒЫН БИЗНЕС ҰЙЫМДАРЫНДАҒЫ АҚПАРАТТЫҚ ҚАУІПСІЗДІК ЖҮЙЕСІН ҚАМТАМАСЫЗ ЕТУ ЖӘНЕ ӘДІСТЕРІН ҚҰРАСТЫРУ	265
24. Сериккалиева А.К., Болатбек М.А. МАШИНАЛЫҚ ОҚЫТУ АРҚЫЛЫ БЕЙНЕЛЕРДЕГІ ЖЕККӨРІНШТІ МАЗМҰНДЫ ТАБУ.....	267
25. Мамажанов Д.С., Жумахан Р.Ж., Мырзаханов М.Ж., Байспай Г.Б. МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІН ҚОЛДАНА ОТЫРЫП, ИНТЕРНЕТ ҚАУІПТЕРІН ЗЕРТТЕУ ЖӘНЕ ТАЛДАУ.....	268
26. Сыбанова Д. ESP32 НЕГІЗІНДЕГІ МЕДИЦИНАЛЫҚ ЖҮЙЕЛЕРДЕГІ КРИПТОГРАФИЯЛЫҚ АЛГОРИТМДЕРДІҢ ӨНІМДІЛІГІНЕ СЫРТҚЫ ФАКТОРЛАРДЫҢ ӘСЕРІН ТАЛДАУ.....	270
27. Тортай А.Б. ӨНЕРКӘСІПТІК ИНТЕРНЕТ ЗАТТАРЫ ҮШІН ҚАУІПСІЗ МОНИТОРИНГ ЖҮЙЕСІ.....	272
28. Амиртаева А.К., Қозытай А.К., Турарбек А.Т. ОРГАНИЗАЦИЯ ЗАЩИТЫ ПЕРСОНАЛЬНЫХ ДАННЫХ: ОСВЕДОМЛЁННОСТЬ И РЕАЛИЗАЦИЯ МЕР БЕЗОПАСНОСТИ.....	273
29. Басшықызы Д., Ахметов Б.С. ИНФОРМАЦИОННАЯ БЕЗОПАСНОСТЬ LMS-СИСТЕМ.....	274
30. Қылышбаев Б., Кенжебаева М.О. ҚАЗІРГІ ЗАМАНҒЫ ҚАУІП-ҚАТЕРЛЕРГЕ НЕГІЗДЕЛГЕН ПАРОЛЬДЕР МЕН АУТЕНТИФИКАЦИЯ ӘДІСТЕРІНІҢ ҚАУІПСІЗДІГІН БАҒАЛАУ.....	275
31. Бұрханбек Т.М., Кенжебаева М.О. НЕЙРОНДЫҚ ЖЕЛІНІ ПАЙДАЛАНА ОТЫРЫП, ФОТОСУРЕТТЕРДЕГІ БЕТТЕРДІ ТАҢУ.....	277
32. Ерболат Н., Абдуллаев Н.А., Мурзабеков З.Н. КОНДИТЕР ФАБРИКАСЫНЫҢ ӨНІМДЕРІН ӨНДІРУ БОЙЫНША КӘСІПОРЫННЫҢ АҚПАРАТТЫҚ ҚАУІПСІЗДІГІН ҚАМТАМАСЫЗ ЕТУ	279

33. Ермекова Г.Е., Темирбекова Ж.Е. ЭЛЬ-ГАМАЛЬ КРИПТОЖҮЙЕСІ МЕН ЖАСАНДЫ ИНТЕЛЛЕКТ НЕГІЗІНДЕ ҚҰПИЯЛЫЛЫҚТЫ САҚТАЙ ОТЫРЫП, БИОМЕТРИЯЛЫҚ КЕСКІНДЕРДІ ШИФРЛАУ.....	280
34. Жүнісәлі Ә.Қ. ADILET.ZAN.KZ ЗАҢНАМАЛЫҚ ЖҮЙЕСІНІҢ ЗАҢДАР ДЕРЕКТЕРІН ҚОЛДАНЫП, GOLANG ПРОГРАММАЛАУ ТІЛІНДЕ ЗАҢНАМАЛЫҚ СҰРАҚ-ЖАУАП ЖҮЙЕСІН ҚҰРУ.....	281
35. Қуандықова Н.Т., Байспай Г.Б. НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ ҚОЛДАНА ОТЫРЫП, ФИШИНГТІК ХАБАРЛАМАЛАРДЫ АНЫҚТАУ ЖҮЙЕСІН ҚҰРУ.....	283
36. Қурбаниязов Н., Ахметов Б.С. УНИВЕРСИТЕТТЕРДІҢ АҚПАРАТТЫҚ-БІЛІМ БЕРУ ЖҮЙЕЛЕРІНДЕГІ ЦИФРЛЫҚ ЕГІЗДЕРДІҢ ҚАУІПСІЗДІГІ.....	285
37. Матанбай М.А. АҚПАРАТТАНДЫРУ ОБЪЕКТІЛЕРІ АРАСЫНДА ҚОРҒАУ РЕСУРСТАРЫН ҰТЫМДЫ БӨЛҮДІ ЗЕРТТЕУ.....	286
39. Нурсалимов Н.К., Нарбаева С.М. КОРПОРАТИВТІК ЖЕЛІНІ ЖОБАЛАУ ЖӘНЕ ҚОРҒАУ.....	288
40. Құлбарақ А.А., Өсербеков Ұ.М., Турарбек А.Т. ИСПОЛЬЗОВАНИЕ ТЕХНОЛОГИИ VPN ДЛЯ РАЗРАБОТКИ ЗАЩИЩЕННОЙ КОРПОРАТИВНОЙ СЕТИ.....	289
41. Рахыш А.Е., Адильжанова С.А. АСА МАҢЫЗДЫ МЕМЛЕКЕТТІК ИНФРАҚҰРЫЛЫМДЫ ҚОРҒАУ: КИБЕРҚАУІПСІЗДІКТІ БАҒАЛАУ ӘДІСТЕРІ.....	290
42. Сайлау Ә.Ж., Абдулинова А.М., Турарбек Ә.Т. КИБЕРБУЛЛИНГТІҢ АЛДЫН АЛУ ӘДІСТЕРІН ЗЕРТТЕУ ЖӘНЕ ТАЛДАУ.....	291
43. Тасболат Е.Е., Сақыпбекова М.Ж. БЕЛГІСІЗДІК ЖАҒДАЙЫНДА АҚПАРАТТЫҚ ҚАУІПСІЗДІКТІ БАСҚАРУ ЖҮЙЕСІНІҢ МОДЕЛІН ЗЕРТТЕУ.....	292
44. Сатпай А. ВЫЯВЛЕНИЕ АНОМАЛИЙ В ПЛАТЕЖНЫХ ТРАНЗАКЦИЯХ: ЭФФЕКТИВНОСТЬ ПРАВИЛ И СТАТИСТИЧЕСКИХ МЕТОДОВ.....	293
45. Тұрсынова Ә.Ғ., Сақан Қ.С. ҚАЗІРГІ ШИФРЛАУ АЛГОРИТМДЕРІНІҢ СЫЗЫҚТЫ ЕМЕС ТҮЙІНДЕРІН ЗЕРТТЕУ.....	295
46. Уралова Ф.С., Мусиралиева Ш.Ж. ӘЛЕУМЕТТІК ЖЕЛІЛЕРДЕ АЛАЯҚТАРДЫ АНЫҚТАУ ҮШІН МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН ҚОЛДАНУ.....	296
47. Усманова А.М., Болатбек М.А. ЖЕЛІЛІК ТРАФИКТІ ТАЛДАУ ӘДІСІН ҚҰРУ ЖӘНЕ ОНЫҢ АРХИТЕКТУРАСЫ.....	298
48. Темирғазиева Ш., Болатбек М.А. ГРАФИКАЛЫҚ ДЕСТРУКТИВТІ МАЗМҰНДЫ АНЫҚТАУ ӘДІСТЕРІ.....	300
49. Фёдорова В.В. КИБЕРБЕЗОПАСНОСТЬ И КРИПТОЛОГИЯ: ЦИФРОВАЯ ВОЙНА ЗА ПРИВАТНОСТЬ.....	302
50. Шулинбаева А.М., Байспай Г.Б. КИБЕРҚАУІПСІЗДІКТЕГІ OSINT (OPEN SOURCE INTELLIGENCE) ҚҰРАЛДАРЫН ЗЕРТТЕУ ЖӘНЕ ТАЛДАУ.....	303
51. Абдраманов Д.Б., Болатбек М.А. ПРОГНОЗЫ ПО ПРОДВИНУТЫМ УГРОЗАМ (АРТ) НА 2025 ГОД.....	306
52. Құрасбек А.Н., Кенжебаева М.О. ПРИМЕНЕНИЕ LLM В КИБЕРБЕЗОПАСНОСТИ: ОБЗОР УЯЗВИМОСТЕЙ LLM.....	308
53. Нұрғали А.А., Исмаилов Д.М., Омаров Б.С., Турарбек А.Т. ОБНАРУЖЕНИЕ КРИМИНАЛЬНЫХ ДЕЙСТВИЙ В ВИДЕ АТАК И ОПРЕДЕЛЕНИЕ АНОМАЛИЙ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ.....	310
54. Жұмақын А.Е., Темирбекова Ж.Е. ЖАСАНДЫ ИНТЕЛЛЕКТ НЕГІЗІНДЕГІ ІОТ ҚҰРЫЛҒЫЛАРЫН БАСҚАРУ: ТИІМДІЛІК, ҚАУІПСІЗДІК ЖӘНЕ МАСШТАБАЛУДЫ ҮЙЛЕСТІРУ.....	312
55. Бимолдина Ж.А., Багитова К.Б. КИБЕРШАБУЫЛДАРДЫ АНЫҚТАУ ЖӘНЕ КИБЕРҚАУІПСІЗДІК ДЕҢГЕЙІН АРТТЫРУ ҮШІН МАШИНАЛЫҚ ОҚЫТУДЫ ПАЙДАЛАНУ.....	314

56. <i>Абыл А.С., Мурзахметов А.Н.</i> ИОТ ҚҰРЫЛҒЫЛАРЫН КИБЕРШАБУЫЛДАН ҚОРҒАУ ӘДІСТЕРІН ТАЛДАУ: DDOS ШАБУЫЛДАРЫНАН ҚОРҒАУ ЖӘНЕ ПЕРСПЕКТИВАЛЫҚ ШЕШІМДЕР.....	316
57. <i>Мурзалиев Д.Н., Нарбаева С.М.</i> СОВРЕМЕННЫЕ МЕТОДЫ ЗАЩИТЫ СМАРТФОНА ОТ КРАЖИ ДАННЫХ.....	317

**«КОМПЬЮТЕРЛІК ҒЫЛЫМДАР МЕН ИНЖЕНЕРИЯДАҒЫ ЗАМАНАУИ
ТЕНДЕНЦИЯЛАР» СЕКЦИЯСЫ
СЕКЦИЯ «СОВРЕМЕННЫЕ ТЕНДЕНЦИИ В КОМПЬЮТЕРНЫХ НАУКАХ И
ИНЖЕНЕРИИ»
«MODERN TRENDS IN COMPUTER SCIENCE AND ENGINEERING» SECTION**

1. <i>Abutayev Zh.</i> DEVELOPMENT OF AN APPLICATION FOR PREDICTING THE PROBABILITY OF A STROKE IN A PATIENT USING MACHINE LEARNING MODELS.....	320
2. <i>Almbekuly A.</i> DEVELOPMENT OF A HUMAN RECOGNITION SYSTEM CAMERALEARNING TO WARNING THE OWNER OF THE HOUSE.....	322
3. <i>Aman.Sh., Kabdrakhova S.</i> PREDICTING FOOTBALL PLAYER’S PRICE USING ML ALGORITHMS.....	
4. <i>Baiguziyev I., Rakhimzhanova L.B.</i> DEVELOPMENT OF THE INFORMATION SUPPORT SYSTEM FOR LIBRARY USERS.....	323
5. <i>Darzhanov N., Rakhimzhanova L.B.</i> DEVELOPMENT OF A SMART INTERFACE WITH HAND GESTURE RECOGNITION ELEMENTS.....	326
6. <i>Sabyrzhan Y., Imankulov T.</i> PARALLELIZATION OF A MONTE CARLO METHOD FOR SOLVING HEAT CONDUCTION PROBLEMS USING GPU.....	328
7. <i>Saurambayeva A., Cherikbayeva L., Bapiyeva Y.</i> OPTIMIZATION OF DEEP NEURAL NETWORK MODELS FOR ACCURATE BRAIN TUMOR SEGMENTATION.....	329
8. <i>Turganbayeva D.</i> RESEARCH AND ANALYSIS OF MACHINE LEARNING METHODS FOR AUTOMATIC TARGET SHOOTING SCORING.....	331
9. <i>Xu Yuying, Balakayeva G.</i> DEVELOPMENT OF A SOFTWARE PACKAGE PROCESSING OF OIL SLUDGE IN ORDER TO MINIMIZE THE HARMFUL EFFECTS OF OIL WASTE ON ENVIRONMENT.....	333
10. <i>Абдрахман А.М., Кабдрахова С.С.</i> НЕЙРОНДЫҚ ЖЕЛІ КӨМЕГІМЕН ЭЭГ СИГНАЛДАР АРҚЫЛЫ МИ БЕЛСЕНДІЛІГІН КЛАССТАРҒА ЖІКТЕУ.....	335
11. <i>Akjan Yerkin, Kabdrakhova S.S.</i> CLASSIFICATION OF SPINAL DISEASE SEVERITY USING MRI IMAGES BASED ON NEURAL NETWORKS.....	336
12. <i>Abiirbek K., Matkerim B.</i> AI-DRIVEN OPTIMIZATION OF SATELLITE RESCUE SYSTEMS FOR EFFICIENT EMERGENCY SIGNAL TRANSMISSION IN REMOTE MOUNTAIN AREAS.....	338
13. <i>Esengeldiev D., Turganbaeva A.</i> STUDY OF METHODS OF MINIMIZING DELAYS AND DEVELOPING A DATABASE MONITORING SYSTEM IN MICROSERVICE APPLICATIONS.....	341
14. <i>Issadil N., Kenzhebek Y.</i> DEVELOPING DEEP NEURAL NETWORKS TO SOLVE THE THERMAL CONDUCTIVITY PROBLEM.....	343
15. <i>Raxim A.</i> OPTIMIZING BIG DATA PROCESSING IN JAVA USING THREADS AND PARALLEL COMPUTING.....	344
16. <i>Нұрланова Қ.</i> ТЕРЕҢ ОҚЫТУ ТӘСІЛДЕРІН ПАЙДАЛАНА ОТЫРЫП, АУАНЫҢ ЛАСТАНУЫН БОЛЖАУ.....	345
17. <i>Сүйеубек Е.</i> ЖЫЛУӨТКІЗГІШТІК ТЕНДЕУІН ШЕКТЕУЛІ АЙЫРЫМ ӘДІСТЕРІМЕН GPU АРХИТЕКТУРАЛАРЫНДА ПАРАЛЛЕЛЬДІ ТИІМДІ ЖҮЗЕГЕ АСЫРУ.....	347
18. <i>Uzenbek Y., Rakhimzhanova L.B.</i> DEVELOPMENT OF A WEB APPLICATION FOR	

GAMING VIDEO CONFERENCES WITH AUGMENTED REALITY.....	350
19. Ұзақбаева А. ВЕБ-ҚОСЫМШАЛАР АРҚЫЛЫ ИНТЕРАКТИВТІ ОҚЫТУ МӘСЕЛЕЛЕРІ: АНАЛИТИКАЛЫҚ ШОЛУ.....	352
20. Orazbek A., Imankulov T. PREDICTING STUDENTS ACADEMIC ACHIEVEMENTS..	354
21. Yerzhan M., Matkerim B. COORDINATION AND ROUTING OF AUTONOMOUS DRONES FOR RAPID RESPONSE IN HIGH-RISK MOUNTAINOUS AREAS.....	356
22. Тлеужанулы Д. COMPARATIVE ANALYSIS OF RETRIEVAL-AUGMENTED GENERATION AND DOMAIN-SPECIFIC FINE-TUNING FOR ENHANCING E-COMMERCE CONVERSATIONAL CHATBOTS.....	357
23. Omirzakhova N., Imankulov T. COMPREHENSIVE STUDY ON INTELLIGENT INFORMATION SYSTEMS FOR CLASSIFICATION OF STUDENT ACADEMIC ACHIEVEMENTS.....	359
24. Kaiyrbekov Y., Rakhimzhanova L.B. OPTIMIZATION OF 3D ANIMATION AND VISUALIZATION IN AUGMENTED REALITY.....	361
25. Курмангалиева А.М., Турганбаева А.Р. ЖОҒАРЫ СЫНЫП ОҚУШЫЛАРЫН РҮТНОН ТІЛІНДЕ ОЙЫН ҚҰРУҒА ҮЙРЕТУ ӘДІСТЕРІ.....	362
26. Балтабай Е., Тұрар О.Н. OPENGL ЖӘНЕ ШЕЙДЕРЛЕРДІ ПАЙДАЛАНА ОТЫРЫП, НАҚТЫ УАҚЫТТАҒЫ СӘУЛЕЛЕРДІ БАҚЫЛАУ.....	364
27. Сейлхан Ә. НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ ҚОЛДАНА ОТЫРЫП, ЖАҢАРТЫЛАТЫН ЭНЕРГИЯНЫ ЭНЕРГЕТИКАЛЫҚ ЖҮЙЕЛЕРГЕ ИНТЕГРАЦИЯЛАУДЫ ОҢТАЙЛАНДЫРУҒА АРНАЛҒАН ЗАМАНАУИ ЗЕРТТЕУЛЕРГЕ ШОЛУ.....	366
28. Дәуіт Ж.Б., Кенжебек Е. ПУАССОН ТЕНДЕУІН ШЕШУГЕ АРНАЛҒАН ГИБРИДТІ ПАРАЛЛЕЛЬДІ АЛГОРИТМ ҚҰРУ.....	368
29. Сейдалиев Н.Н., Муханбет А.А. БЕТТІ ТАҢУ САПАСЫН ЖАҚСARTУ ҮШІН СИНТЕТИКАЛЫҚ ДЕРЕКТЕРДІ ГЕНЕРАЦИЯЛАУ.....	369
30. Valgaliyev A., Matkerim B. DEVELOPMENT AND OPTIMIZATION OF A DEEP LEARNING MODEL FOR EARLY BREAST CANCER DETECTION BASED ON MRI SCANS.....	371
31. Хаджимурат Н.М., Кенжебек Е. КЛАССИФИКАЦИЯ ТАПСЫРМАСЫ ҮШІН КОНВОЛЮЦИЯЛЫҚ НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ ПАРАЛЛЕЛЬ ОҚЫТУ.....	373
32. Каздаев Т. РАЗРАБОТКА ПРИЛОЖЕНИЯ ДЛЯ КОРРЕКТИРОВКИ КЛАССИФИКАЦИИ ЛОКАЛЬНЫХ КЛИМАТИЧЕСКИХ ЗОН С УЧЕТОМ ВЫСОТЫ СТРОЕНИЙ.....	375
33. Баймурзин Р. РАЗРАБОТКА ПРИЛОЖЕНИЯ ДЛЯ АНАЛИЗА И ВИЗУАЛИЗАЦИИ ДАННЫХ МОДЕЛИРОВАНИЯ.....	376
34. Мәжит Ә.Е., Қабдрахова С.С. ЖҮРЕК-ҚАН ТАМЫР ЖҮЙЕСІ АУРУЛАРЫН АНЫҚТАУҒА АРНАЛҒАН CNN МОДЕЛЬДЕРІНІҢ САЛЫСТЫРМАЛЫ ТАЛДАУЫ.....	378
35. Ultarakov N., Turganbayeva A.R. MODERN CYBER ATTACKS METHODS, CONSEQUENCES, AND DEFENSE STRATEGIES.....	381
36. Жасмай С.Х., Matkerim B. ЖОҒАРЫ ӨНІМДІ КЛАСТЕРЛЕРДЕ ЕСЕПТЕУ АЙМАҒЫН ДЕКОМПОЗИЦИЯЛАУ АРҚЫЛЫ ЖЫЛУӨТКІЗГІШТІК ТЕНДЕУІН ШЕШУДІҢ МАСШТАБАЛАТЫН ПАРАЛЛЕЛЬДІ АЛГОРИТМДЕРІ.....	383
37. Buianbaev Zh., Imankulov T. IMPLEMENTATION OF THE MONTE CARLO METHOD ON GPU.....	385
38. Turarov B.M., Kabdrakhova S.S. OPTIMIZING CONVOLUTIONAL NEURAL NETWORKS FOR REAL-TIME SQL INJECTION DETECTION IN POSTGRESQL DATABASES WITH A FOCUS ON REDUCING FALSE POSITIVES.....	386
39. Асан Ж.Ж. ӘРТҮРЛІ ЕСЕПТЕУ ҚУАТЫ БАР ТАРАТЫЛҒАН ЖҮЙЕЛЕР ҮШІН ФЕДЕРАТИВТІ ОҚЫТУ ӘДІСТЕРІН ОҢТАЙЛАНДЫРУҒА ШОЛУ.....	389
40. Қалиева С.А., Макашев Е.П. ҚҰС ФАБРИКАСЫНЫҢ ДЕРЕКТЕРІН ТАЛДАУ	

БАҒДАРЛАМАСЫН ӨЗІРЛЕУ.....	391
41. <i>Өмірсеріков Н.</i> ПАРАЛЛЕЛЬДІ СҰРЫПТАУ ЖӘНЕ ІЗДЕУ АЛГОРИТМДЕРІН CUDA ЖӘНЕ MPI КӨМЕГІМЕН ТАЛДАУ ЖӘНЕ ОҒТАЙЛАНДЫРУ.....	392
42. <i>Egisinov Zh., Makhmut E.</i> HIGH-PERFORMANCE COMPUTING FOR CARBONATED WATER INJECTION IN OIL RECOVERY.....	394
43. <i>Dauletkaliyeva A.</i> APPLICATION FOR PARTICIPATION IN THE CONFERENCE.....	396
44. <i>Кенгесов Е.Д., Кашаганова Г.Б.</i> МОБИЛЬДІ ОҚЫТУДЫҢ ТИІМДІЛІГІ: КОРПОРАТИВТІК ОҚЫТУ ҚОСЫМШАСЫН ӨЗІРЛЕУ ЖӘНЕ ЕНГІЗУ.....	398
45. <i>Жумабаева С.Е., Черикбаева Л.Ш.</i> МЕКЕМЕНІҢ ІШКІ ҚҰЖАТТАРЫН ЦИФРЛАНДЫРУ ҮШІН МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІН ҚОЛДАНУ.....	402
46. <i>Мареев Д., Иманкулов Т.С.</i> ГЕНЕРАТИВНО-СОСЯЗАТЕЛЬНАЯ СЕТЬ ДЛЯ МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ (MI-GAN).....	404
47. <i>Orynbasar R., Rakhimzhanova L.B.</i> DEVELOPING OPTIMIZATION ALGORITHMS TO IMPROVE ENERGY EFFICIENCY IN SMART BUILDINGS USING AI.....	405
48. <i>Mukhamedali S., Satymbekov M.</i> DEVELOPMENT OF AN INTELLIGENT SYSTEM FOR EVACUATION FROM A BUILDING IN CASE OF FIRE BASED ON ARTIFICIAL INTELLIGENCE TECHNOLOGY.....	407
49. <i>Байтұрсын Ә.Е., Макашев Е.П.</i> АГРОӨНЕРКӘСПТІК СЕКТОР САЛАСЫНДА МАМАНДАРДЫ ДАЯРЛАУҒА АРНАЛҒАН WEB-ҚОСЫМШАНЫ ӨЗІРЛЕУ.....	409
50. <i>Абдымажит И., Қабдрахова С.С.</i> ИНТЕРАКТИВТІ ЦИФРЛЫ-ВЕКТОРЛЫҚ “KAZMAPS” КАРТОГРАФИЯЛЫҚ ҚОСЫМШАСЫ.....	411
51. <i>Сиванқұл Д., Қасымбек Н.</i> ПАРАЛЛЕЛЬДЕУ ӘДІСТЕРІН ҚОЛДАНА ОТЫРЫП, ҚОСАРЛАНҒАН ГРАДИЕНТ ӘДІСІН ӨЗІРЛЕУ ЖӘНЕ ІСКЕ АСЫРУ.....	413
52. <i>Есенғалиева Г.Т., Черикбаева Л.Ш.</i> МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІН ҚОЛДАНА ОТЫРЫП, ИНСУЛЬТТИ ЕРТЕ ДИАГНОСТИКАЛАУ.....	414
53. <i>Тұрарбек Қ.</i> RESEARCH OF APPROACHES TO SOFTWARE DEVELOPMENT WITH DEVOPS IN MIND.....	416
54. <i>Spatayev A.</i> DEEP LEARNING-BASED FIRE DETECTION USING CONVOLUTIONAL NEURAL NETWORKS.....	419
55. <i>Marat A., Pyrkova A.Y.</i> DEVELOPMENT OF AN INTELLIGENT CHATBOT FOR COLLECTING AND PROTECTING MEDICAL DATA USING AES ALGORITHM FOR ENCRYPTION AND ANALYSIS.....	420
56. <i>Ашим Т.Т., Пыркова А.Ю.</i> МЕНТОРЛЫҚ, ЖОБАЛЫҚ ОҚЫТУ ЖӘНЕ КЕЙІПКЕРДІ ДАМУ ЭЛЕМЕНТТЕРІ БАР БІЛІМ БЕРУ ПЛАТФОРМАСЫН ӨЗІРЛЕУ.....	422
57. <i>Смағұл А.Қ.</i> ТУРИЗМ САЛАСЫНДАҒЫ ЖАСАНДЫ ИНТЕЛЛЕКТ ӘДІСТЕРІН ЗЕРТТЕУ ЖӘНЕ ТАЛДАУ.....	423
58. <i>Жетписбай Р.С.</i> АДАМ-КОМПЬЮТЕРЛІК ӨЗАРА ӨРЕКЕТТЕСУДЕГІ ҚИМЫЛДАРДЫ ТАНУ АЛГОРИТМДЕРІН ЗЕРТТЕУ.....	425
59. <i>Қойшиев А.</i> ҚИМЫЛДАРДЫ ТАНУ ҮШІН ТЕРЕҢ НЕЙРОНДЫҚ ЖЕЛІ АРХИТЕКТУРАЛАРЫН ТАЛДАУ.....	427
60. <i>Наркешова Ф.М., Жасұзақ М.С.</i> ӘЛСІЗ ЖАРЫҚ ЖАҒДАЙЛАРЫНДА ОБЪЕКТІНІ АНЫҚТАУ ДӘЛДІГІН ЖАҚСARTU МАҚСАТЫНДА КОНВОЛЮЦИЯЛЫҚ НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ ОҒТАЙЛАНДЫРУҒА АРНАЛҒАН ГЕНЕТИКАЛЫҚ АЛГОРИТІМІН ӨЗІРЛЕУ.....	428
61. <i>Құдіретулла Ж.Н., Жасұзақ М.С.</i> ҚАЗАҚ БІМ ТІЛІН КОМПЬЮТЕРЛІК КӨРУ ЖӘНЕ ОҚЫТУ ӘДІСТЕРІН ҚОЛДАНУ АРҚЫЛЫ ТАНУ ЖҮЙЕСІН ӨЗІРЛЕУ.....	429
62. <i>Әбдіразақ З.Б., Бурибаев Ж.А.</i> РАЗРАБОТКА МЕТОДА РАСПОЗНАВАНИЯ ДЕЙСТВИЙ И АНАЛИЗА ПОВЕДЕНИЯ ЛЮДЕЙ В ТООПЕ С ПРИМЕНЕНИЕМ АЛГОРИТМОВ КОМПЬЮТЕРНОГО ЗРЕНИЯ.....	430
63. <i>Сейтбек А.Б., Жасұзақ М.С.</i> НЫСАНАҒА ТИГЕН ОҚТАРДЫ АВТОМАТТЫ ТҮРДЕ АНЫҚТАУҒА АРНАЛҒАН ИНТЕЛЛЕКТУАЛДЫ МОДУЛЬДІ ӨЗІРЛЕУ.....	432

64. <i>Есенова Н.Б., Урмашев Б.А.</i> AGRO КЕШЕНДІ БАҒДАРЛАМАСЫНЫҢ МӘЛІМЕТТЕР БАЗАСЫ ҚҰРАМДАС БӨЛІГІН ҚҰРУ.....	433
65. <i>Жакып А., Мустафин М.Б.</i> МРІ ЖӘНЕ БІРНЕШЕ GPU ҚОЛДАНУ АРҚЫЛЫ ҮЛКЕН ДЕРЕКТЕРДІ ТАЛДАУҒА АРНАЛҒАН МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІН ІСКЕ АСЫРУ ЖӘНЕ ОҢТАЙЛАНДЫРУ.....	434
66. <i>Mustayev A., Satymbekov M.</i> DEVELOPMENT OF A DYNAMIC INDOOR EVACUATION INDICATOR BASED ON BLE BEACONS AND A* PATHFINDING ALGORITHM.....	436
67. <i>Bekele S.D., Kenzhebek Y., Imankulov T.</i> INTERPRETABLE NEURAL MODELING FOR POLYMER FLOODING THROUGH SYMBOLIC EXPRESSIONS IN KOLMOGOROV-ARNOLD NETWORKS.....	437

**«ИНТЕЛЛЕКТУАЛДЫ АҚПАРАТТЫҚ ЖҮЙЕЛЕРДЕГІ МАТЕМАТИКАЛЫҚ
ӘДІСТЕР МЕН МАШИНАЛЫҚ ОҚЫТУ» СЕКЦИЯСЫ
СЕКЦИЯ «МАТЕМАТИЧЕСКИЕ МЕТОДЫ И МАШИНОЕ ОБУЧЕНИЕ В
ИНТЕЛЛЕКТУАЛЬНЫХ ИНФОРМАЦИОННЫХ СИСТЕМАХ»
«MATHEMATICAL METHODS AND MACHINE LEARNING IN INTELLIGENT
INFORMATION SYSTEMS» SECTION**

1. <i>Ауезхан М.Қ, Бейбітхан Е.</i> ТАБИҒИ ТІЛДІ ӨНДЕУ НЕГІЗІНДЕ АҚПАРАТТЫҚ ЖҮЙЕНІҢ ИНТЕЛЛЕКТУАЛДЫ МҮМКІНДІКТЕРІН АРТТЫРУ.....	441
2. <i>Арапова Ж.Е., Алиев Р., Каримов М., Черикбаева Л.Ш., Турарбек Ә.Т.</i> ЖЕР СІЛКІНІСТЕРІНІҢ ЫҚТИМАЛ САЛДАРЫН МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН ҚОЛДАНУ АРҚЫЛЫ АНЫҚТАУ.....	443
3. <i>Абдилдаева Ж.Қ., Глесова Б.</i> ДЕРЕКТЕРДІ ТАЛДАУ ЖӘНЕ ЕСЕП БЕРУ ҚҰРАЛДАРЫН ПАЙДАЛАНА ОТЫРЫП, ЖОБАНЫ БАСҚАРУДЫҢ АҚПАРАТТЫҚ ЖҮЙЕСІН ӨЗІРЛЕУ.....	444
4. <i>Абдыкарим А., Байшоланова К.С.</i> МАШИНАЛЫҚ ОҚЫТУ НЕГІЗІНДЕ БИОМЕТРИЯЛЫҚ ДЕРЕКТЕР АРҚЫЛЫ ПАЙДАЛАНУШЫЛАРДЫҢ АУТЕНТИФИКАЦИЯСЫНЫҢ АҚПАРАТТЫҚ ЖҮЙЕСІ.....	447
5. <i>Абай М.А., Глесова Б.</i> МАШИНАЛЫҚ ОҚЫТУ МОДЕЛЬДЕРІ МЕН НЕЙРОНДЫҚ ЖЕЛЛЕРДІ ҚОЛДАНУ АРҚЫЛЫ ДЕРЕКТЕРДІ ТАЛДАУ ӘДІСТЕРІН ӨЗІРЛЕУ ЖӘНЕ АҚПАРАТТЫҚ ТЕХНОЛОГИЯЛАР АУДИТІН ЖҮРГІЗУ.....	449
6. <i>Амантай А.М.</i> КЕУЕКТІ ОРТАНЫ ЕСКЕРЕ ОТЫРЫП, АУАДАҒЫ ҰСАҚ ДИСПЕРСТІ БӨЛШЕКТЕРДІҢ КОНЦЕНТРАЦИЯСЫН САНДЫҚ МОДЕЛЬДЕУ.....	451
7. <i>Асқапова М.К., Кәрібаева А.С.</i> ПАРАЛЛЕЛЬДІ ҚАЗАҚ-ТҮРІК СӨЙЛЕУ КОРПУСЫН ҚАЛЫПТАСТЫРУДЫҢ ӘДІСІ МЕН МОДЕЛІН ҚҰРУ.....	453
8. <i>Әскер Б.Н., Бөкенов З.Қ., Борибаева У.Б.</i> АҚЫЛДЫ ҮЙДІ ТАЛДАУ ЖӘНЕ АВТОМАТТАНДЫРЫЛҒАН ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕЛЕРДІ ҚҰРУ.....	456
9. <i>Әбдішүкір Қ.К., Бейбітхан Е.</i> БИЗНЕС-АНАЛИТИКА ЖӘНЕ ЖАСАНДЫ ИНТЕЛЛЕКТ ЭЛЕМЕНТТЕРІ БАР ЕСЕПТІЛІКТІ ҚҰРУ ЖӘНЕ БАСҚАРУДЫҢ АҚПАРАТТЫҚ ЖҮЙЕСІН ӨЗІРЛЕУДІҢ МАҢЫЗЫ.....	458
10. <i>Байбосын Н.Н., Кожанова А.М.</i> ИНФОРМАЦИОННАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ И АНАЛИЗА ЭФФЕКТИВНОСТИ ЦЕННЫХ БУМАГ.....	460
11. <i>Болат Ж.Ф. Қаулыбек Б.Е., Бекмурат Б.Б., Бейбітхан Е.</i> АВТОМАТТАНДЫРЫЛҒАН ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕЛЕРДІ ЗЕРТТЕУ НӘТИЖЕЛЕРІ ЖӘНЕ ОЛАРДЫҢ АҚЫЛДЫ ТЕХНОЛОГИЯЛАР ҚҰРУДАҒЫ РӨЛІ.....	462
12. <i>Батырбек А.Қ.</i> АЛМАТЫНЫҢ ЭКОЛОГИЯЛЫҚ ЖАҒДАЙЫН ЖАҚСАРТАТЫН ИНТЕЛЛЕКТУАЛДЫ АҚПАРАТТЫҚ ЖҮЙЕ ҚҰРУ.....	464
13. <i>Бахытбай Б., Бурибаев Б.</i> КӘСІБИ БАҒДАР БЕРУ ҚЫЗМЕТІНДЕ ЖАСАНДЫ ИНТЕЛЛЕКТІНІ ҚОЛДАНУ МҮМКІНДІГІ.....	466

14. <i>Бейсембай Н.М., Орынбасарова Э.Ж., Рахимова Д.Р.</i> МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН ПАЙДАЛАНА ОТЫРЫП, БАЛАЛАРДЫҢ СӨЙЛЕУ БҰЗЫЛЫСТАРЫН ДИАГНОСТИКАЛАУҒА АРНАЛҒАН ҚОСЫМШАНЫ ӨЗІРЛЕУ.....	468
15. <i>Бимбетов Б.М.</i> СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОВ CRM И PERT ДЛЯ УПРАВЛЕНИЯ ПРОЕКТАМИ.....	471
16. <i>Даулет Е. А., Рахимова Д.Р.</i> ИССЛЕДОВАНИЕ И РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНОЙ ВОПРОСНО-ОТВЕТНОЙ СИСТЕМЫ НА ОСНОВЕ СЕМАНТИЧЕСКИХ ПОДХОДОВ ДЛЯ ГОСУДАРСТВЕННОГО ЯЗЫКА В СФЕРЕ ЗАКОНОДАТЕЛЬСТВА РЕСПУБЛИКИ КАЗАХСТАН.....	474
17. <i>Дилда И.Ж., Байкувекоев М.Б.</i> ЖҮРЕК АУРУЛАРЫН БОЛЖАУ МАҚСАТЫНДА ВЕБ-ҚОСЫМШАНЫ ӨЗІРЛЕУ: МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІН ҚОЛДАНУ.....	476
18. <i>Еркінбаева Б.Е., Байшоланова К.С.</i> ІТ ӨНІМДЕРДІ ЖАСАУШЫ ЖОБАЛЫҚ ТОПТЫ БАСҚАРУДЫҢ АҚПАРАТТЫҚ ЖҮЙЕСІН ЖАСАУ.....	477
19. <i>Жұмағалиқызы Н., Омарова П.Т.</i> КЕУЕКТІ ОРТАЛАРДЫ ЕСКЕРЕ ОТЫРЫП, АУАНЫҢ ЛАСТАНУЫН БОЛЖАУ.....	479
20. <i>Жақсымбет А.Т., Асқапова М.К., Кәрібаева А.С.</i> ӨЛЕУМЕТТІК ЖЕЛІЛЕРДЕГІ СУИЦИДТІК МІНЕЗ-ҚҰЛЫҚ БЕЛГІЛЕРІ БАР МӘТІНДЕРДІ ТАЛДАУ ЖӘНЕ ЖІКТЕУДІҢ ҚОСЫМШАСЫН ҚҰРУ.....	481
21. <i>Жаппарова Е.Ф., Бурибаев Б.Б.</i> “JAVA ПРОГРАММАЛАУ ТІЛІ” ПӘНІНЕ АРНАЛҒАН ЖАППАЙ АШЫҚ ОНЛАЙН КУРСЫН ЖАСАУ.....	482
22. <i>Жубанышева Г.Т., Адилжанова С.А.</i> АҚПАРАТТЫҚ ҚАУІПСІЗДІК САЛАСЫНДАҒЫ ТӘУЕКЕЛДЕРДІ ТАЛДАУ ЖӘНЕ БАСҚАРУ ҮШІН ПЛАТФОРМА ҚҰРУ.....	485
23. <i>Зетбек А.Б., Рахимова Д.Р.</i> ДЕРЕКТЕР БАЗАСЫНЫҢ НЕГІЗДЕРІ” ПӘНІ БОЙЫНША ЭЛЕКТРОНДЫҚ ОҚУ КЕШЕНІН ӨЗІРЛЕУ.....	487
24. <i>Исахан М.А., Қалидоллина Г.Т.</i> ИНТЕЛЛЕКТУАЛДЫ ОҚЫТУ ЖҮЙЕСІНІҢ КӨМЕГІМЕН ПРОГРАММАЛАУ ТІЛДЕРІН ҮЙРЕНЕТІН ЖӘНЕ БІЛІМ ДЕҢГЕЙІН АНЫҚТАУҒА МҮМКІНДІК БЕРЕТІН АҚПАРАТТЫҚ ӨНІМГЕ САРАЛАУ.....	489
25. <i>Кабдолдаева Ә.Б., Қалидоллина Г.Т.</i> «METASTUDY» БІЛІМ БЕРУ ОРТАЛЫҒЫ ҮШІН «ОҚУШЫ КҮНДЕЛІГІ» АҚПАРАТТЫҚ ЖҮЙЕСІН ӨЗІРЛЕУ.....	492
26. <i>Князбай А.Ә.</i> ІРІ СУПЕРМАРКЕТТЕ ТҰТЫНУ ТАУАРЛАРЫН СӨРЕЛЕРГЕ ОҢТАЙЛЫ ОРНАЛАСТЫРУДЫҢ ИНТЕЛЛЕКТУАЛДЫ АҚПАРАТТЫҚ ЖҮЙЕСІН ӨЗІРЛЕУ.....	495
27. <i>Күмісбек М.Н., Шормакова А.Н.</i> LLM НЕГІЗІНДЕ СПАМ ХАБАРЛАМАЛАРДЫ АНЫҚТАУ: SUPERVISED ЖӘНЕ UNSUPERVISED ОҚЫТУДЫ ҚОЛДАНУ.....	496
28. <i>Қойшыбай Б.Е.</i> НЕЙРОНДЫҚ ЖЕЛІЛЕРДІҢ МАТЕМАТИКАЛЫҚ НЕГІЗДЕРІ: СЫЗЫҚТЫҚ ЕМЕС ФУНКЦИЯЛАР ЖӘНЕ КЕРІ ТАРАТУ АЛГОРИТМІ.....	498
29. <i>Құдайбергенов Ж.А.</i> ҚАЗПОШТА БӨЛІМШЕЛЕРІ БОЙЫНША ПОШТА ЖӨНЕЛТІЛІМДЕРІНІҢ ОҢТАЙЛЫ ЛОГИСТИКАСЫ ҮШІН ЗИЯТКЕРЛІК АҚПАРАТТЫҚ ЖҮЙЕНІ ӨЗІРЛЕУ.....	502
30. <i>Құрметқан Т., Мамырбаев Ө.Ж.</i> КӨПМОДАЛЬДЫ ҚАЗАҚ СӨЙЛЕУЛЕРІН ТАНУДА МОДАЛЬДАРДЫ БІРІКТІРУ ӘДІСТЕРІН ЗЕРТТЕУ.....	504
31. <i>Қуанышпаева Ж.Б., Мурзабеков З.Н.</i> РАЗРАБОТКА АЛГОРИТМА И МОДЕЛИРОВАНИЕ УПРАВЛЕНИЯ ПРЕДПРИЯТИЕМ ПРИ ИЗМЕНЕНИИ ОГРАНИЧЕННЫХ РЕСУРСОВ.....	507
32. <i>Накенов Б.Е.</i> ИНТЕГРАЦИЯ МОДЕЛЕЙ ТЕОРИИ МАССОВОГО ОБСЛУЖИВАНИЯ И МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОПТИМИЗАЦИИ ПРОЦЕССОВ БАНКОВ.....	509
33. <i>Нәдия Қ., Турарбек Ә.Т.</i> МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІНІҢ КИБЕРҚАУІПСІЗДІК АУДИТІНДЕ ҚОЛДАНЫЛУЫ.....	511
34. <i>Максұтова Ш.У.</i> БИЗНЕСТЕГІ АҚПАРАТТЫҚ ТЕХНОЛОГИЯЛАР.....	513
35. <i>Махашева Н.А., Бурибаев Б.</i> ШАҒЫН МЕКЕМЕНІҢ АВТОМАТТАНДЫРЫЛҒАН АҚПАРАТТЫҚ ЖҮЙЕСІН ЖАСАУ (С.НҰРМАҒАМБЕТОВ АТ. ЖАЛПЫ ОРТА МЕКТЕБІ МЫСАЛЫНДА).....	516

36. <i>Мейрхан Ш., Бакибаев А.В.</i> СИСТЕМА УПРАВЛЕНИЯ ОТПУСКАМИ В КОРПОРАТИВНОЙ СРЕДЕ.....	518
37. <i>Мырзақұл Ж.Н., Мусиралиева Ш.Ж.</i> ДЕСТРУКТИВТІ МӘТІНДЕРДІ АНЫҚТАУ ЖӘНЕ ЗЕРТТЕУ.....	520
38. <i>Нұрланова Қ.</i> ТЕРЕҢ ОҚЫТУ ТӘСІЛДЕРІН ПАЙДАЛАНА ОТЫРЫП, АУАНЫҢ ЛАСТАНУЫН БОЛЖАУ.....	521
39. <i>Нұрпейіс Р.Ж., Ілесова Б.Е.</i> РАЗРАБОТКА МЕТОДОВ АНАЛИЗА И ВИЗУАЛИЗАЦИИ ДАННЫХ АУДИТА ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ НА ЯЗЫКЕ ПРОГРАММИРОВАНИЯ RUTNOM.....	523
40. <i>Орынбасар А. Ж., Орманбекова А.А.</i> БЕЙНЕЛЕРДІ ТАҢУ ЖҮЙЕЛЕРІН ДАМЫТУ: БІРТАҚТАЛЫ КОМПЬЮТЕРЛЕР МЕН НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ БІРІКТІРУ.....	525
41. <i>Омархалиева Н.Г., Байшоланова К.С.</i> ТЕЛЕМЕДИЦИНА АҚПАРАТТЫҚ ЖҮЙЕСІН ДАМЫТУ.....	528
42. <i>Орақбаев Ж.А.</i> ҚОЙМА БАСҚАРУ ЖҮЙЕСІН ӨЗІРЛЕУ ЖӘНЕ ІСКЕ АСЫРУ.....	530
43. <i>Орынбек Ш. Ж., Байшоланова К.С.</i> БАНКТИҢ ЖЕКЕ ТҮЛҒАЛАРҒА ҚЫЗМЕТ КӨРСЕТУІНЕ АРНАЛҒАН АҚПАРАТТЫҚ ЖҮЙЕНІ ЖАСАУ.....	532
44. <i>Рахманберді Н.А., Тукеев У., Шормасқова А.Н.</i> ӨЗЕРБАЙЖАН ТІЛІНІҢ CSE МОДЕЛІ ЖӘНЕ ОНЫҢ МОРФОЛОГИЯЛЫҚ ЕРЕКШЕЛІКТЕРІ.....	534
45. <i>Рысбек Б.С., Тукеев У.А.</i> ҚАЗАҚ ТІЛІНДЕГІ БАҒДАРЛАМАЛАУ ТІЛДЕРІНЕ АРНАЛҒАН ИНТЕЛЛЕКТУАЛДЫ СҰРАҚ-ЖАУАП ЖҮЙЕСІ.....	536
46. <i>Самбетбаева А.К.</i> ЖОЛ ЖАБЫНДАРЫНЫҢ САПАСЫН БАҒАЛАУДА ЖАСАНДЫ ИНТЕЛЛЕКТ ПЕН ТЕРЕҢ ОҚЫТУ ТЕХНОЛОГИЯЛАРЫН ҚОЛДАНУ.....	538
47. <i>Сұлтанәлі Т., Бурибаев Б.Б.</i> «RUTNOM ПРОГРАММАЛАУ ТІЛІ» ПӘНІН ҮЙРЕНУГЕ АРНАЛҒАН ЭЛЕКТРОНДЫҚ КЕШЕН ЖАСАУ.....	540
48. <i>Сағындықов Т.М., Байкувекоев М.Б.</i> МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІН ҚОЛДАНА ОТЫРЫП, ЖҮРЕК ЖАҒДАЙЫН БАҚЫЛАУҒА АРНАЛҒАН МОБИЛЬДІ ҚОСЫМШАНЫ ӨЗІРЛЕУ.....	543
49. <i>Сейтказин Б.Ә., Бейбітхан Е.</i> ҰЙЫМНЫҢ БИЗНЕС АНАЛИТИКАСЫ ЖҮЙЕСІН ҚҰРУ ЖӘНЕ ЖОБАЛАУ.....	544
50. <i>Сембай А.М., Қалидоллина Г.Т.</i> БАНКЕТ ЗАЛДАРЫН БРОНЬДАУ ЖҮЙЕСІН АВТОМАТТАНДЫРУДЫ ЗЕРТТЕУ.....	547
51. <i>Серікболова А.Қ., Көпбосын Л.С.</i> ТУРИСТТІК АГЕНТТІКТИҢ ЖҰМЫС ЖҮЙЕСІН АВТОМАТТАНДЫРУДЫ ЗЕРТТЕУ.....	549
52. <i>Токтар Г., Байшоланова Қ., Максұтова Ш.</i> МАРКЕТИНГТЕГІ ШЕШІМ ҚАБЫЛДАУҒА АРНАЛҒАН АҚПАРАТТЫҚ ЖҮЙЕНІ ӨЗІРЛЕУ.....	552
53. <i>Түгелбай Н.А.</i> КӘСПОРЫНДАР АРАСЫНДАҒЫ ӨЗАРА ҚАРЫМ-ҚАТЫНАСТЫ АВТОМАТТАНДЫРУҒА АРНАЛҒАН ЗИЯТКЕРЛІК В2В САУДА ПЛАТФОРМАСЫН ӨЗІРЛЕУ.....	555
54. <i>Шопчекбаев Қ.Ж., Бейбітхан Е.</i> АВТОКӨЛІК НӨМЕРЛЕРІН ТАНИТЫН АҚПАРАТТЫҚ ЖҮЙЕ ҚҰРУ.....	557
55. <i>Ысқақ С.Е., Ибраимқұлов А.Е.</i> БІЛІМ БЕРУДЕГІ ПЛАТФОРМАЛАРДЫ ДАМЫТУ: МАҢЫЗЫ, ҚОЛДАНЫЛАТЫН ӘДІСТЕР МЕН ТЕХНОЛОГИЯЛАР.....	559
56. <i>Kezler H.</i> USING MACHINE LEARNING ALGORITHMS TO EVALUATE AND PREDICT EMPLOYEE PERFORMANCE.....	560
57. <i>Li Xin</i> DEVELOPMENT OF PINN ALGORITHM FOR THE INVERSE PROBLEM OF THREE-CHAMBER PHARMACOKINETICS MODEL.....	561
58. <i>Sagyntayev M.A.</i> APPLICATION OF MACHINE LEARNING AND CYBER ANALYSIS IN AN INTELLIGENT INFORMATION SYSTEM FOR CRYPTOCURRENCY PRICE ANALYSIS.....	563
59. <i>Бержанова У.Г., Mohamed Othman, Мухитова А.А.</i> YOLO NAS S НЕГІЗІНДЕ ҚАЗАҚ ЫМ ТІЛІН ТАҢУ МОДЕЛІН ҚҰРУ ЖӘНЕ ЗЕРТТЕУ.....	565

**«ЖАСАНДЫ ИНТЕЛЛЕКТ ЖӘНЕ ДЕРЕКТЕР ТУРАЛЫ
ҒЫЛЫМ: ЗАМАНАУИ ТӘСІЛДЕР МЕН ТЕХНОЛОГИЯЛАР»
СЕКЦИЯСЫ**

**СЕКЦИЯ «СОВРЕМЕННЫЕ ПОДХОДЫ И ТЕХНОЛОГИИ
НАУКИ О ДАННЫХ И ИСКУССТВЕННОГО ИНТЕЛЛЕКТА»**

**«MODERN APPROACHES AND TECHNOLOGIES OF DATA
SCIENCE AND ARTIFICIAL INTELLIGENCE» SECTION**

Application of machine learning methods for Genomic data analysis in bioinformatics

Abish M.B

*Faculty of information technology
email: magnet.magmat@gmail.com*

Pyrkova A.Y.

*Professor,
Candidate of Physical and Mathematical sciences
Al-Farabi Kazakh National University*

The rapid advancement of DNA and RNA sequencing technologies has led to an exponential increase in genomic data, necessitating more sophisticated methods for analysis and interpretation. Traditional bioinformatics approaches often struggle with handling the complexity, high dimensionality, and heterogeneous nature of genomic datasets [1]. In this context, machine learning (ML) has emerged as a transformative tool, enabling the automatic extraction of patterns, prediction of disease risk, and detection of mutation-associated anomalies.

Machine learning techniques have been widely applied in genomic research, particularly in cancer detection and classification. One of the fundamental ML tasks in genomics is feature selection, where algorithms identify relevant genetic markers associated with cancer progression. Methods such as decision trees, support vector machines (SVM), and random forests effectively filter out non-informative features, reducing the computational burden and improving classification accuracy. Deep learning approaches, particularly convolutional neural networks (CNNs), have demonstrated remarkable success in processing DNA sequences, recognizing motifs, and predicting genetic predispositions to diseases.

A particularly promising area of ML in bioinformatics is multimodal learning, where different types of biomedical data are integrated for improved predictions. Soenksen et al. (2022) discuss how multimodal artificial intelligence frameworks combine genomic sequences, mutation data, metabolomic profiles, and clinical records to enhance diagnostic accuracy. By leveraging diverse data sources, these models outperform unimodal approaches, achieving improvements of 6-33% in predictive tasks. The ability to integrate various biomedical data streams allows for a more holistic understanding of disease mechanisms, particularly in cancer research.

In practical genomic data analysis, ML pipelines typically begin with data preprocessing. This involves removing duplicates, normalizing values, and encoding DNA sequences using methods such as one-hot encoding or k-mer partitioning [3]. Clustering algorithms like k-means and hierarchical clustering help in uncovering hidden patterns in genetic data. Classification models, including random forests and transformer-based architectures, are used to distinguish between cancerous and non-cancerous sequences with high accuracy. Additionally, anomaly detection techniques, such as autoencoders and generative adversarial networks (GANs), help identify rare mutations that may contribute to tumorigenesis.

One of the key challenges in applying ML to genomic data is interpretability. While deep learning models achieve high accuracy, their decision-making processes often function as black boxes. Techniques like SHAP (Shapley Additive Explanations) and Grad-CAM (Gradient-weighted Class Activation Mapping) have been introduced to provide insight into how specific genetic features contribute to predictions. The implementation of explainable AI (XAI) methodologies is crucial in medical applications, ensuring that ML-driven diagnoses align with biological knowledge and clinical reasoning.

Experimental studies utilizing real-world datasets, such as The Cancer Genome Atlas (TCGA), have demonstrated the efficacy of ML models in genomic analysis. Ensemble methods, including XGBoost and random forests, have achieved mutation classification accuracies of up to 92%. Deep learning architectures, such as CNNs and transformers, have further improved prediction accuracy, reaching up to 95% in classifying cancer-related mutations. Moreover, multimodal approaches that

integrate genomic data with clinical and imaging records have shown a 10-20% increase in diagnostic performance compared to single-modality models.

The future of ML in genomic research lies in further enhancing multimodal frameworks and integrating explainable AI techniques. Advanced deep learning architectures, such as hybrid transformer models, are expected to provide even more precise predictions by capturing complex interactions between genetic mutations and clinical manifestations. Additionally, the development of federated learning approaches will enable secure, privacy-preserving ML training on distributed genomic datasets, fostering collaboration across research institutions.

Machine learning is revolutionizing genomic data analysis, offering unprecedented opportunities for early cancer detection and precision medicine. By integrating multimodal data sources and advancing interpretability techniques, ML-driven bioinformatics is paving the way for more accurate diagnostics, personalized treatment plans, and a deeper understanding of genetic diseases.

References:

1. Libbrecht M.W., Noble W.S. Machine learning applications in genetics and genomics. *Nature Reviews Genetics*, 2015.
2. Soenksen L.R., et al. Integrated multimodal artificial intelligence framework for healthcare applications. *npj Digital Medicine*, 2022.
3. Alipanahi B., et al. Predicting the sequence specificities of DNA- and RNA-binding proteins by deep learning. *Nature Biotechnology*, 2015.
4. Zhang X., et al. Interpretable deep learning for single-cell transcriptomics. *Nature Methods*, 2021.

Жасанды интеллект және IoT технологиясы негізінде биометриялық деректерді тануға арналған интеллектуалды жүйені әзірлеу

Аблай Ғ. А.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: g4n1bet@gmail.com, +7 776 699 1806

Сарсембаева Т.С.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Қазіргі қауіпсіздік жүйелері жеке тұлғаны тез әрі дәл анықтайтын технологияларды қажет етеді. Бұл жұмыста бет-әлпетті тануға бағытталған, жасанды интеллект (AI) және Заттар интернеті (IoT) технологиялары негізіндегі биометриялық деректерді тануға арналған интеллектуалды жүйенің әзірленуі сипатталады. Жүйе терең нейрондық желілер арқылы кескіндерді талдауды және IoT құрылғыларымен нақты уақытта деректерді жинауды біріктіреді, ал деректер локальді түрде өңделеді. Бұл шешім жеке басты тексерудің сенімділігін арттырып, әртүрлі қолдану салаларына бейімделеді.

Жеке басын автоматты түрде анықтауға деген сұраныстың артуы биометриялық технологияларды дамытуды тездетуде. Кілттер немесе құпиясөздер сияқты әдеттегі әдістер бірегей сипаттамаларға, мысалы, бет-әлпетке негізделген биометриялық жүйелерге қарағанда тиімділігі төмен. Жасанды интеллект және IoT технологиялары нақты уақытта бет кескіндерін талдап, жеке тұлғаны анықтайтын жүйелерді құруға мүмкіндік береді. Бұл қоғамдық орындарда, кәсіпорындарда және қала инфрақұрылымында қауіпсіздікті қамтамасыз ету үшін маңызды. Бұл жұмыста Python тілінде және DeepFace кітапханасы арқылы локальді деректерді өңдеуге негізделген жүйе ұсынылады.

Әдістер мен технологиялар:

1. DeepFace кітапханасы: Python-да қолданылатын DeepFace құралы бет-әлпеттің негізгі белгілерін (көз, мұрын, ауыз) анықтау үшін терең нейрондық желілерді пайдаланады. Бұл дайын модель тану процесін жеңілдетеді және қолжетімді деректерде оңтайлы нәтиже береді.

2. IoT құрылғылары: Камералар мен сенсорлар нақты уақытта биометриялық деректерді жинап, оларды локальді өңдеу блогына жібереді. Бұл жүйенің үздіксіз жұмысын қамтамасыз етеді.

3. Локальді деректерді талдау: Деректер сыртқы желілерге тәуелді болмай, жүйенің ішкі модулінде өңделеді, бұл автономдылықты және жеделдікті арттырады.

4. Кескінді өңдеу әдістері: Жарықты реттеу және бетті туралау сияқты алдын ала өңдеу DeepFace-ке сапалы деректер беру үшін қолданылады.

DeepFace кітапханасымен әзірленген жүйе бет-әлпетті тануда жоғары дәлдік көрсетеді, әсіресе жақсы жарықтандырылған кескіндерде. IoT құрылғыларымен біріктіру деректерді өңдеуді тездетеді, бұл жүйені нақты уақытта қолдануға мүмкіндік береді. Жарық өзгерістері мен бұрыш ауытқуларына төзімділік алдын ала өңдеу арқылы жақсарды, бірақ кейбір жағдайларда (мысалы, нашар жарық) нәтижелер әлі де зерттеуді қажет етеді. Болашақта жүйені беттің жартылай көрінетін жағдайларына (маска, көзілдірік) бейімдеу және басқа биометриялық белгілерді (алақан тамырлары арқылы тану) қосу жоспарланып отыр.

Жасанды интеллект және IoT негізіндегі биометриялық деректерді тану жүйесі қауіпсіздікті күшейту мен жеке басын тексеруді автоматтандырудың жана жолдарын ұсынады. Терең нейрондық желілер мен IoT құрылғыларының үйлесімі жоғары дәлдік пен жылдамдықты қамтамасыз етеді, бұл жүйені кең қолдануға қолайлы етеді. Технологияны одан әрі дамыту оның күрделі жағдайларға бейімділігін және әмбебаптығын арттыруға бағытталады.

Пайдаланылган әдебиеттер тізімі:

1. Serengil, S. I., & Ozpinar, A. (2021). DeepFace: A Lightweight Face Recognition Framework for Python. *Journal of Open Source Software*, 6(65), 3421.
2. Zhang, X., & Zhou, Y. (2023). IoT-Based Biometric Systems: Design and Applications. *IEEE Internet of Things Journal*, 10(5), 1234–1245.
3. Zhao, W., Chellappa, R., & Phillips, P. J. (2020). Face Recognition: A Literature Survey. *ACM Computing Surveys*, 35(4), 399–458.
4. Kumbhar, S., & Patil, S. (2022). Real-Time Facial Recognition Using Deep Learning and IoT Integration. *International Journal of Computer Applications*, 184(12), 25–32.
5. Taigman, Y., Yang, M., Ranzato, M., & Wolf, L. (2014). DeepFace: Closing the Gap to Human-Level Performance in Face Verification. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1701–1708.

Система биометрического распознавания на основе анализа вен ладони с использованием инфракрасной технологии

Аблай Ғ.А.

*КазНУ им. аль-Фараби, 4 курс бакалавриат
E-mail: g4n1bet@gmail.com, +7 776 699 1806*

Сарсембаева Т.С.

КазНУ им. аль-Фараби, старший преподаватель

Современные системы безопасности требуют технологий, способных быстро и точно идентифицировать личность. В этой статье описывается разработка интеллектуальной системы для распознавания биометрических данных, основанной на анализе вен ладони. Система использует искусственный интеллект (ИИ) и инфракрасные технологии для анализа изображений вен в реальном времени. Для обработки данных применяются глубокие нейронные сети, а сбор информации осуществляется с помощью инфракрасных камер. Все вычисления выполняются локально, что повышает надежность и автономность системы. Это решение подходит для различных областей применения, включая повышение безопасности.

С ростом потребности в автоматической идентификации личности биометрические технологии становятся всё более востребованными. Традиционные методы, такие как ключи, пароли или карты доступа, уступают по удобству и безопасности системам, использующим уникальные физические характеристики человека. Одной из таких характеристик являются вены ладони, которые сложно подделать и которые можно анализировать с помощью современных технологий. В этой работе представлена система распознавания вен ладони, основанная на искусственном интеллекте и инфракрасных камерах. Она обеспечивает быструю и точную проверку личности в реальном времени, что делает её полезной для применения в общественных местах, на предприятиях и в других сферах, где важна безопасность. Для реализации проекта использовался язык программирования Python и нейронная сеть ResNet50.

В разработке системы применялись следующие подходы и инструменты:

1. Нейронная сеть ResNet50: Для классификации изображений вен ладони использовалась готовая модель глубокого обучения ResNet50, реализованная на Python. Эта сеть обеспечивает высокую точность распознавания благодаря своей архитектуре, которая эффективно обрабатывает сложные данные.

2. Инфракрасные камеры: Сбор биометрических данных осуществляется с помощью инфракрасных камер, которые фиксируют изображения вен ладони в реальном времени. Инфракрасный спектр позволяет выявить уникальный рисунок вен даже через кожу.

3. Локальная обработка данных: Все вычисления выполняются внутри системы без подключения к внешним серверам. Это повышает скорость работы и делает систему независимой от интернет-соединения.

4. Предобработка изображений: Перед подачей данных в нейронную сеть изображения проходят предварительную обработку: корректируется освещение, убираются шумы и выравнивается положение ладони. Это улучшает качество входных данных и повышает точность распознавания.

Разработанная система показала высокую точность распознавания вен ладони, особенно при хорошем освещении и правильном положении руки. Интеграция инфракрасных камер с нейронной сетью ResNet50 позволила достичь быстрой обработки данных, что делает систему пригодной для использования в реальном времени. Предобработка изображений улучшила устойчивость системы к изменениям условий, таким как угол наклона ладони или слабое освещение. Однако в сложных случаях, например при плохом освещении или частично закрытой ладони, точность пока требует доработки.

В будущем планируется:

1. Адаптировать систему к ситуациям, когда ладонь частично видна (например, в перчатках или с повязкой).
2. Улучшить алгоритмы обработки изображений для работы в условиях низкой освещенности.
3. Добавить поддержку других биометрических данных, таких как отпечатки пальцев, для повышения универсальности.

Разработанная система распознавания вен ладони на основе искусственного интеллекта и инфракрасных технологий открывает новые возможности для повышения безопасности и автоматизации идентификации личности. Благодаря высокой точности, скорости и локальной обработке данных она может быть применена в самых разных сферах — от контроля доступа до городской инфраструктуры. Дальнейшее развитие системы сделает её ещё более универсальной и устойчивой к сложным условиям.

Список использованной литературы:

1. He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep Residual Learning for Image Recognition*. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770–778.
2. Zhou, Y., & Kumar, A. (2011). *Human identification using palm-vein images*. IEEE Transactions on Information Forensics and Security, 6(4), 1259–1274.
3. Kang, W., & Wu, Q. (2014). *Contactless palm vein recognition using a mutual foreground-based local binary pattern*. IEEE Transactions on Information Forensics and Security, 9(11), 1974–1985.

Comparative Analysis of MediaPipe and YOLO Models for Pose Estimation: Performance Evaluation Across Various Conditions

Absadykov Daniyar

Department of Computational and Data Sciences, Astana IT University, Kazakhstan

d.absadykov2002@gmail.com

Scientific Supervisor: Yedil Nurakhov

Abstract: This study compares MediaPipe and YOLOv8 pose estimation models across various configurations and video conditions. I evaluate performance metrics including FPS, CPU usage, and memory consumption on scenarios featuring walking, break dance, martial techniques, and crowded scenes. Results show MediaPipe's lite configuration delivers superior FPS and low latency for real-time applications, while YOLOv8 excels in complex scenes with superior handling of occlusions and dense object detection. This analysis provides insights for selecting appropriate pose estimation models based on specific application requirements.

Keywords: Pose Estimation, MediaPipe, YOLOv8, Performance Evaluation, Computer Vision

Human pose estimation identifies positions and orientations of body parts in images or videos, enabling applications from human-computer interaction to health monitoring [1]. This challenge increases with multiple individuals in dynamic environments [2]. Recent advancements include Part Affinity Fields by Cao et al. [1] and YOLO models adapted for pose estimation [3]. This paper compares pre-trained MediaPipe and YOLO models, focusing on performance metrics including processing time, FPS, CPU usage, and memory consumption across various conditions and video resolutions.

The evaluation used publicly available videos in various conditions (walking, break dance, martial techniques, two people walking, overcrowded scenes) at three resolutions (1080p, 720p, 480p). Performance metrics included:

- Average FPS: Calculated as $\text{avg_fps} = (\text{sum of fps_counter}) / (\text{length of fps_counter})$ where $\text{current_fps} = 1 / (\text{time_after} - \text{time_before})$
- Average CPU Usage: Calculated using `psutil.cpu_percent(interval=0.1)`
- Memory Usage: Tracked as $\text{memory_usage} = (\text{process.memory_info().rss}) / (1024^2)$ (in MB)
- Total Elapsed Time: Measured as $\text{total_elapsed_time} = \text{time.time}() - \text{start_time}$

Experimental Setup

Experiments were conducted on Google Colab with:

- CPU: Intel(R) Xeon(R) CPU @ 2.00GHz, 2 cores
- GPU: NVIDIA Tesla T4, 15,360 MB
- CUDA Version: 12.2

Pre-trained MediaPipe and YOLOv8 models were evaluated by processing each video frame, recording processing times, and tracking resource usage.

Results:

MediaPipe Model Performance




Figure 1 MediaPipe Model Performance Metrics

Key findings:

- Lite Configuration: Highest average FPS with moderate CPU usage and lower memory consumption
 - Full Configuration: Balanced FPS and resource usage
 - Heavy Configuration: Lowest FPS and highest memory usage
 - Higher resolutions (1080p) generally reduced performance compared to lower resolutions
- The MediaPipe model is based on BlazePose, which was designed specifically for on-device real-time body pose tracking [4].

YOLOv8 GPU Model Performance

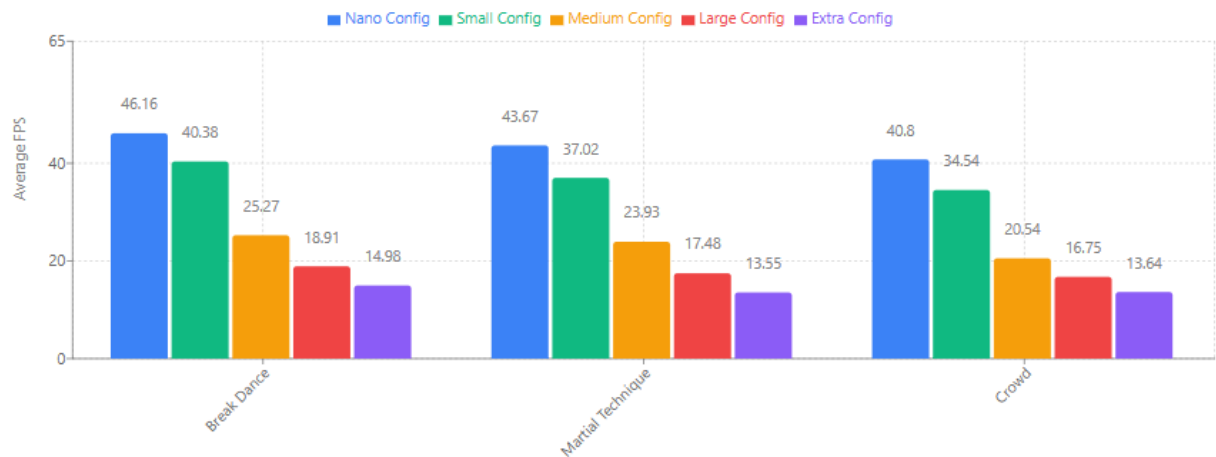


Figure 2: YOLOv8 GPU Model Performance Metrics

Key findings:

- Nano Configuration: Highest average FPS with relatively low CPU usage
- Small/Medium Configurations: Balanced performance metrics
- Large/Extra Configurations: Lower FPS with increased resource consumption
- Complex scenes significantly impacted performance across all configurations

Discussion

Performance Comparison

MediaPipe's lite configuration significantly outperformed YOLOv8's extra-large configuration in scenarios with fast movement, maintaining higher FPS and lower latency. This aligns with findings from Zhang [5], who demonstrated MediaPipe's effectiveness in at-home fitness applications requiring real-time analysis.



Pic 1: Performance Comparison: MediaPipe (Lite) vs. YOLOv8 (Extra Large) in Break Dance Scenario

Key Observations

- FPS and Latency: MediaPipe achieved significantly higher FPS in high-movement scenarios
- Resource Utilization: MediaPipe maintained performance with lower resource consumption
- Simple Tasks: Both models performed well in basic detection scenarios



Pic 2: Performance Comparison: MediaPipe (Lite) vs. YOLOv8 (Nano) in Walking Detection Scenario

- Challenging Tasks: YOLOv8's extra-large model outperformed MediaPipe's heavy model in complex movements
- Model Selection Trade-offs: Our findings support Ceriola et al.'s [6] research on the trade-offs between model complexity, accuracy, and processing speed when selecting pose estimation models for specific applications.



Pic 3: Performance Comparison: MediaPipe vs. YOLOv8 in Crowded Scenes

- Crowded Scenes: YOLOv8 significantly outperformed MediaPipe with multiple people, handling occlusions better

Conclusion

MediaPipe models demonstrate superior efficiency for real-time pose estimation tasks, especially with fast movements and limited computational resources. YOLOv8, while requiring more resources, excels in complex scenes with multiple people. Future work could explore hybrid models combining strengths of both approaches and further optimization of YOLOv8 for real-time applications.

References:

1. Cao, Z., Simon, T., Wei, S.-E., & Sheikh, Y. (2017). Realtime multi-person 2D pose estimation using part affinity fields. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 7291--7299. <https://doi.org/10.1109/CVPR.2017.143>
2. Andriluka, M., Pishchulin, L., Gehler, P., & Schiele, B. (2014). 2D human pose estimation: New benchmark and state of the art analysis. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 3686--3693. <https://doi.org/10.1109/CVPR.2014.471>
3. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 779--788. <https://doi.org/10.1109/CVPR.2016.91>
4. Bazarevsky, V., Grishchenko, I., Raveendran, K., Zhu, T., Zhang, F., & Grundmann, M. (2020). BlazePose: On-device real-time body pose tracking. *arXiv*. <https://arxiv.org/abs/2006.10204>
5. Zhang, Y. (2022). *Applications of Google MediaPipe pose estimation using a single camera* [Unpublished master's project]. California State Polytechnic University, Pomona, CA.
6. Ceriola, A., Li, M., & Zhang, P. (2023). Evaluation of human pose estimation methods. *Journal of Physics: Conference Series*, 2425(1), Article 012034. <https://doi.org/10.1088/1742-6596/2425/1/012034>

Суды тұщыландыру процесінде қолданылатын әдістер мен технологияларға шолу

Ази О.Ж.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: oralbai.azi@mail.ru

Шаяхметова А.С.

Әл-Фараби атындағы ҚазҰУ, PhD, профессор м.а.

Бұл жұмыста суды тұщыландырудың әртүрлі әдістері қарастырылып, олардың тиімділігі мен қолдану салалары талданды. Атап айтқанда, кері осмос және нанофльтрация әдістеріне салыстырмалы талдау жүргізілді. Зерттеу нәтижесінде екі әдісті қатар қолдану судың сапасын жақсартып, энергия шығынын азайтуға және мембраналардың қызмет ету мерзімін ұзартуға мүмкіндік беретіні анықталды. Бұл кешенді тәсіл экологиялық таза әрі экономикалық тұрғыдан тиімді шешім болып табылады.

Суды тұщыландыру – тұщы су тапшылығын шешудің маңызды тәсілі. Әсіресе құрғақ климатты аймақтарда немесе теңіз жағалауларында бұл процесс ауыз суға деген қажеттілікті қамтамасыз ету үшін қолданылады. Тұщыландыру арқылы теңіз, тұзды жер асты суларынан зиянды тұздар мен минералдар алынып, ішуге жарамды таза су алынады [1]. Бұл процесс қазіргі таңда көптеген мемлекеттерде экологиялық және экономикалық тұрғыдан маңызды шешім ретінде қарастырылады [2].

Суды тұщыландырудың бірнеше әдістері бар, олардың ішінде ең көп қолданылатындары:

1. Дистилляция (Буландыру) – суды қыздыру арқылы буландырып, содан кейін конденсациялау арқылы тұщы су алу процесі. Бұл әдіс қарапайым, бірақ энергия шығыны жоғары. Оның негізгі артықшылығы – кез келген типтегі суды тазалай алады. Дегенмен, бұл әдіс жоғары энергия тұтынуына байланысты қымбат болып саналады [3].

2. Электродиализ – иондық мембраналар арқылы тұзды суды электр өрісімен тазарту әдісі. Бұл процесс аз тұзды суларды тазалауда тиімді болып табылады. Электродиализдің басты артықшылығы – энергияны салыстырмалы түрде аз тұтынуы және ұзақ мерзімді пайдалану мүмкіндігі [3, 4].

3. Кері осмос (Reverse Osmosis) – жартылай өткізгіш мембрана арқылы қысыммен суды өткізу процесі. Тиімділігі жоғары әрі қазіргі таңда кең таралған әдіс. Кері осмос теңіз суын тұщыландыруда жиі қолданылады, себебі ол 99%-ға дейін тұздар мен ластағыштарды кетіруге қабілетті. Бұл әдістің негізгі кемшілігі – мембраналардың жиі ауыстыру қажеттілігі мен жоғары қысымды жабдықтардың қымбаттығы [3, 4].

4. Нанофльтрация – кері осмосқа ұқсас әдіс, бірақ мембраналар ірі молекулаларды ғана ұстап, минералдардың бір бөлігін өткізуге мүмкіндік береді. Бұл әдіс жұмсақ суды алу үшін қолданылады. Нанофльтрацияның артықшылығы – кальций мен магний сияқты екі валентті иондарды жою мүмкіндігі, сонымен қатар органикалық заттар мен микробиологиялық ластағыштарды тиімді түрде кетіреді [4, 5].

5. Ион алмасу – арнайы шайырлар көмегімен судың құрамындағы иондарды алмастыру арқылы тұщыландыру әдісі. Бұл әдіс әдетте қатты суды жұмсарту және белгілі бір иондарды жою үшін қолданылады. Ион алмасу әдісі төмен тұзданған сулар үшін тиімді және кең таралған [3, 4].

Кері осмос және нанофльтрация – екеуі де мембраналық технологияларға негізделген, бірақ олардың жұмыс принциптері мен қолдану салалары әртүрлі.

Кері осмос – жоғары қысыммен суды жартылай өткізгіш мембрана арқылы өткізіп, барлық дерлік еріген тұздар мен органикалық заттарды жояды. Бұл әдіс жоғары деңгейде тұзсыздандыру қажет болған жағдайда қолданылады [4, 6].

Нанофльтрация – төменгі қысымда жұмыс істейді және мембранасының кеуектілігі үлкенірек, бұл екі валентті иондарды (мысалы, кальций, магний) тиімді жояды, бірақ бір

валентті иондарды (мысалы, натрий, хлорид) өткізуі мүмкін. Бұл әдіс суды жұмсарту және органикалық заттарды жою үшін тиімді [5, 6].

Біз қарастырған материалдар бойынша суды тұщыландыру үшін кешенді тәсіл, яғни нанофльтрация мен кері осмос әдістерін қатар қолдану ең тиімді шешім деп таптық. Нанофльтрация суды жұмсартып, екі валентті иондарды, органикалық заттар мен бактерияларды жоюға мүмкіндік береді, ал кері осмос жоғары сапалы таза су алуға көмектеседі. Бұл комбинация судың сапасын жақсартып, оның пайдалы минералдарын сақтап қалуға мүмкіндік береді [4, 6].

Сондай-ақ, екі әдісті бірге қолдану жүйенің қызмет ету мерзімін ұзартады және мембраналардың ластануын азайтады. Энергия шығынын төмендету және ұзақ мерзімді пайдалану тұрғысынан бұл әдіс экологиялық және экономикалық тұрғыдан тиімді шешім болып табылады [6].

Біздің таңдаған әдісіміз – кешенді тәсіл, яғни нанофльтрация мен кері осмос технологияларын қатар қолдану. Бұл комбинация судың сапасын жақсартуға, пайдалы минералдарды сақтап, жоғары деңгейде тұщы су алуға мүмкіндік береді. Энергияны тиімді пайдалану мен мембраналардың ұзақ қызмет етуі тұрғысынан бұл әдіс қазіргі замандағы ең перспективті шешімдердің бірі болып табылады. Суды тұщыландыру саласындағы технологиялардың дамуы экологиялық таза әрі экономикалық тұрғыдан тиімді шешімдерді енгізуге мүмкіндік береді.

Пайдаланылған әдебиеттер тізімі:

1. https://kk.wikipedia.org/wiki/Суды_тұщыландыру
2. Жүнісхан А. Ақылды технология су тапшылығының алдын алады // Технология, 2024 <https://egemen.kz/article/378351-aqyldy-tekhnologiya-su-tapshylyghynynh-aldyn-alady>
3. Суды тұщыландыру: әдістері мен параметрлері, 2025. <https://kk.techconfronts.com/17250147-water-desalination-methods-and-installations>
4. Суды тазарту. Суды тазарту әдістері, 2019. Thestrip <https://thestrip.ru/kk/prazdnichnyjj/vodopodgotovka-metody-vodopodgotovki>
5. Нанофльтрация воды // Мембранные элементы, 2019. 5-12.
6. Фарносова Е. Н., Каграманов Г. Г. Нанофльтрация и обратный осмос: сравнение и области оптимального применения // Журнал «Вода Magazine», №6 (118), 2019.

Блокчейн технологияларын оқытуға арналған оқу ойынын әзірлеу және машиналық оқыту элементтерін біріктіру арқылы тиімділікті бағалау

Аманжолов Е.Н.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: yernarnugmanovich2004@gmail.com

Сарсембаева Т.С.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Қазіргі таңда блокчейн технологиялары қаржы, логистика, денсаулық сақтау, білім беру сияқты көптеген салаларда кеңінен қолданылуда. Алайда, бұл технологияны меңгеру көптеген студенттер үшін күрделі мәселе болып табылады. Осы орайда, білім беру үдерісін жеңілдету үшін геймификация тәсілін қолдану тиімді әдістердің бірі бола алады. Бұл баяндамада блокчейн технологияларын оқытуға арналған оқу ойынын әзірлеу және оның тиімділігін машиналық оқыту әдістері арқылы бағалау мәселелері қарастырылады.

Оқу ойындары білім алушылардың қызығушылығын арттырып, күрделі тақырыптарды интерактивті түрде меңгеруге көмектеседі. Блокчейн технологияларын үйрету үшін арнайы әзірленген ойын студенттерге мынадай артықшылықтар береді:

Теориялық материалдарды практикалық қолдану арқылы жақсырақ түсіну;

Блокчейннің негізгі принциптерімен танысу (мысалы, транзакциялар, смарт-келісімшарттар, шифрлау);

Қателіктерден сабақ алу және білімдерін бекіту мүмкіндігі.

Геймификация әдістері білім беру саласында кеңінен қолданылып келеді. Зерттеулер көрсеткендей, интерактивті ойындар арқылы оқыту студенттердің мотивациясын арттырады және материалды тиімді меңгеруге ықпал етеді.

Студенттердің оқу процесіндегі жетістіктерін объективті түрде бағалау үшін машиналық оқыту әдістерін қолдануға болады. Бұл әдіс келесі көрсеткіштерді талдауға мүмкіндік береді:

Ойын барысында жіберілген қателер саны мен түрлері;

Ойын тапсырмаларын орындау жылдамдығы;

Оқу материалының қаншалықты меңгерілгенін анықтау.

Машиналық оқыту алгоритмдері студенттердің әрекеттерін талдап, олардың қай бөлімдерде қиындықтарға тап болғанын анықтай алады. Бұл оқытушыларға оқу бағдарламасын жетілдіруге және жеке оқыту траекторияларын құруға көмектеседі (Baker & Inventado, 2014).

Блокчейн технологияларын оқытуға арналған ойын құру және оның тиімділігін машиналық оқыту әдістері арқылы бағалау – білім беру үдерісін жетілдірудің перспективалық бағыттарының бірі. Мұндай тәсіл студенттердің білім алуын қызықты әрі тиімді етеді, сондай-ақ олардың оқу нәтижелерін терең талдауға мүмкіндік береді. Болашақта бұл әдісті басқа да күрделі технологияларды оқытуда қолдануға болады

Пайдаланылған әдебиеттер тізімі:

1. Namari, J., Koivisto, J., & Sarsa, H. (2014). Does gamification work? – A literature review of empirical studies on gamification. *Computers in Human Behavior*, 40, 151–160. <https://doi.org/10.1016/j.compedu.2013.08.012>

2. Baker, R. S., & Inventado, P. S. (2014). Educational data mining and learning analytics. In *Learning analytics* (pp. 61-75). Springer. https://doi.org/10.1007/978-1-4899-7635-3_5

3. Nakamoto, S. (2008). Bitcoin: A Peer-to-Peer Electronic Cash System. <https://bitcoin.org/bitcoin.pdf>

Машиналық оқыту (ML) және күшейтілген оқыту (Reinforcement Learning) әдістері

Аманжолов Е.Н.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: yernarnugmanovich2004@gmail.com

Сарсембаева Т.С.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Қазіргі заманда жасанды интеллект пен деректер туралы ғылым саласының қарқынды дамуы машиналық оқыту (ML) мен күшейтілген оқыту (Reinforcement Learning, RL) әдістерін кеңінен қолдануға жол ашты. Бұл технологиялар адам әрекеттерін автоматтандыру, күрделі шешімдерді оңтайландыру және интеллектуалды жүйелерді дамытуда маңызды рөл атқарады. Бұл баяндамада машиналық оқыту және күшейтілген оқыту әдістерінің негізгі принциптері мен олардың қолдану салалары қарастырылады.

Машиналық оқыту (ML)

1. Машиналық оқытудың анықтамасы мен принциптері

Машиналық оқыту – компьютерлердің адам көмегінсіз деректерден заңдылықтарды анықтап, өздігінен үйренуін қамтамасыз ететін жасанды интеллекттің бір саласы. Бұл әдіс үлкен көлемдегі деректерді талдау арқылы болжам жасауға, классификациялауға және оңтайландыруға мүмкіндік береді.

2. Машиналық оқытудың негізгі түрлері

Машиналық оқыту әдістері үш негізгі топқа бөлінеді:

Қадағалаумен оқыту (Supervised Learning) – кіріс деректері мен олардың сәйкес шығыс мәндері бар үлгілерді пайдаланып, модельдер үйренеді. Мысалдар: сызықтық регрессия, логистикалық регрессия, нейрондық желілер, шешім ағаштары.

Қадағалаусыз оқыту (Unsupervised Learning) – тек кіріс деректермен жұмыс істейді, яғни қандай да бір белгіленген нәтижелерсіз деректерді топтастырады. Мысалдар: кластерлеу (K-Means, DBSCAN), бас компоненттер әдісі (PCA).

Жартылай қадағаланатын оқыту (Semi-Supervised Learning) – қадағаланатын және қадағаланбайтын оқыту әдістерінің араласқан түрі. Бұл әдіс деректердің көпшілігі белгісіз болған жағдайда қолданылады.

3. Машиналық оқытудың қолдану салалары

Медицина – ауруларды болжау, дәрі-дәрмек әзірлеу.

Қаржы саласы – алаяқтықты анықтау, несиелік рейтингтерді есептеу.

Өнеркәсіп және өндіріс – сапаны бақылау, болжамдық техникалық қызмет көрсету.

Маркетинг – тұтынушылардың мінез-құлқын талдау, жарнама бағыттау.

Күшейтілген оқыту (Reinforcement Learning)

1. Күшейтілген оқытудың анықтамасы мен принциптері

Күшейтілген оқыту (RL) – агенттің қоршаған ортамен әрекеттесіп, өз әрекеттерінің нәтижесі бойынша марапат (reward) немесе жазалау (penalty) алып, сол арқылы ең тиімді стратегияны үйренуін қамтамасыз ететін әдіс. Бұл әдісте агент күтілетін марапатты оңтайландыру үшін сынау және қатемен (trial-and-error) оқиды.

2. Күшейтілген оқытудың негізгі элементтері

Агент (Agent) – оқытылатын модель.

Қоршаған орта (Environment) – агент әрекет ететін кеңістік.

Күй (State) – агенттің ағымдағы жағдайы.

Әрекет (Action) – агенттің орындауы мүмкін іс-әрекеттер жиынтығы.

Марапат (Reward) – агенттің әрекетін бағалайтын көрсеткіш.

Саясат (Policy) – агенттің келесі әрекетін таңдау стратегиясы.

3. Күшейтілген оқытудың танымал алгоритмдері

Q-Learning – мәндік негіздегі күшейтілген оқыту алгоритмі.

Deep Q-Networks (DQN) – терең нейрондық желілерді пайдалана отырып Q-learning әдісін жақсартады.

Proximal Policy Optimization (PPO) – саясат негізінде оқыту әдісі, тұрақты және сенімді жұмысымен танымал.

Actor-Critic әдісі – агенттің шешімдерін оңтайландыруға бағытталған модель.

4. Күшейтілген оқытудың қолдану салалары

Робототехника – автономды роботтарды үйрету.

Ойындар – AlphaGo, Dota 2, StarCraft II сияқты ойындарда жоғары деңгейлі ойыншыларды жеңе алатын жүйелерді жасау.

Қаржы – акциялар нарығын болжау.

Автономды көліктер – өзін-өзі басқаратын автомобильдер үшін қозғалысты оңтайландыру.

Қорытынды

Машиналық оқыту мен күшейтілген оқыту – қазіргі заманғы жасанды интеллекттің негізін қалаушы технологиялар. ML әдістері деректерді талдау, болжау және шешім қабылдау үшін кеңінен қолданылса, RL күрделі басқару және оңтайландыру міндеттерінде тиімділік көрсетуде. Бұл технологиялардың болашағы өте зор, әсіресе, озық жүйелерді дамытуда және автоматтандыруды жетілдіруде маңызды рөл атқарады.

Пайдаланылған әдебиеттер тізімі:

1. Goodfellow I., Bengio Y., Courville A. "Deep Learning." MIT Press, 2016.
2. Sutton R. S., Barto A. G. "Reinforcement Learning: An Introduction." MIT Press, 2018.
3. Bishop C. M. "Pattern Recognition and Machine Learning." Springer, 2006.
4. Géron A. "Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow." O'Reilly Media, 2019.
5. Silver D., Schrittwieser J., Simonyan K., et al. "Mastering the game of Go with deep neural networks and tree search." Nature, 2016.

Жасанды интеллект алгоритмдерін пайдалана отырып, көлік ағындарын автоматтандырылған басқару

Арманқызы Зере

әл-Фараби атындағы Қазақ Ұлттық Университеті, 3 курс студенті

E-mail: zerearmankyzy05@gmail.com

Қазіргі таңда урбанизацияның қарқынды дамуы көлік қозғалысын тиімді басқарудың маңыздылығын арттырып отыр. Кептелістердің көбеюі, экологиялық проблемалардың ушығуы және уақыт шығыны сияқты мәселелер көптеген мегаполистер үшін өзекті болып отыр. Бұл проблемаларды шешудің тиімді жолдарының бірі – жасанды интеллект (ЖИ) алгоритмдерін қолдану арқылы көлік ағындарын автоматтандырылған басқару жүйесін енгізу.

Жасанды интеллект негізіндегі басқару жүйелері үлкен деректерді өңдеу және нақты уақыт режимінде шешім қабылдау қабілетіне ие. ЖИ-ді көлік жүйесіне интеграциялау жолдардың жүктемесін азайтуға, қозғалысты оңтайландыруға және қауіпсіздікті арттыруға мүмкіндік береді.

ЖИ көмегімен көлік ағындарын басқарудың негізгі тәсілдерінің бірі – машиналық оқыту және терең оқыту алгоритмдерін қолдану. Бұл әдістер арқылы жол қозғалысының динамикасын болжауға, көлік жүктемесін алдын ала анықтауға және кептелістерді болдырмауға болады. Сонымен қатар, нейрондық желілер жол қозғалысының үлгілерін талдап, белгілі бір уақыт аралығында көлік ағынын басқаруға мүмкіндік береді.

ЖИ негізінде көлік ағындарын болжау және басқару үшін үлкен деректерді өңдеу маңызды рөл атқарады. GPS трекерлерден, жол қозғалысын бақылау камераларынан, датчиктерден жиналған ақпаратты талдау арқылы нақты уақыт режимінде жолдағы жағдайды бақылауға болады. Жасанды интеллект осы деректерді өңдеп, жүргізушілерге ең қолайлы бағыттарды ұсыну, бағдаршамдардың жұмысын динамикалық реттеу, қоғамдық көліктердің қозғалыс кестесін оңтайландыру сияқты маңызды шешімдер қабылдай алады.

Автоматтандырылған көлік басқару жүйесін енгізудің бірнеше артықшылықтары бар:

Кептелісті азайту – жолдардың жүктемесін алдын ала болжау арқылы көлік қозғалысын тиімді реттеуге болады.

Экономикалық тиімділік – жанармай шығынын азайтып, тасымалдау тиімділігін арттырады.

Экологиялық таза орта қалыптастыру – көлік тұрып қалатын уақытты азайту арқылы ауаға бөлінетін зиянды заттардың мөлшерін төмендетеді.

Қауіпсіздікті арттыру – көлік ағынын тиімді бақылау арқылы жол-көлік оқиғаларының санын азайтуға болады.

Қорыта айтқанда, жасанды интеллект алгоритмдерін көлік ағындарын басқаруға енгізу – урбанизацияланған қалалар үшін ең тиімді шешімдердің бірі. Бұл технология қозғалысты реттеудің дәстүрлі әдістерімен салыстырғанда әлдеқайда тиімді, әрі болашақта ақылды қалаларды дамыту үшін маңызды рөл атқарады. Жасанды интеллект негізінде автоматтандырылған басқару жүйелерін енгізу – көлік инфрақұрылымын жетілдіруге бағытталған маңызды қадам.

Пайдаланылған әдебиеттер тізімі:

1. Бекмұхамедов Е.Ш., Әлімқұлов Е. Жасанды интеллект негіздері. – Алматы: Қазақ университеті, 2021.

2. Қуандықов Н.С. Көлік жүйесін автоматтандырудағы зияткерлік технологиялар. – Нұр-Сұлтан: Назарбаев Университеті баспасы, 2019.

3. Дүниежүзілік экономикалық форум (World Economic Forum). Көлік жүйесіндегі жасанды интеллект: мүмкіндіктер мен сын-тегеуріндер. – Женева, 2021.

4. Қазақстан Республикасы Цифрлық даму, инновациялар және аэроғарыш өнеркәсібі министрлігі. Қазақстандағы «Ақылды қала» тұжырымдамасы. – Астана, 2022.

Адамды саусақ іздері арқылы жеке басын тану процесін оңтайландыру

Ахметжан Б.

Әл-Фараби атындағы Қазақ ұлттық университеті, 4 курс бакалавриат

E-mail: nesibelisaburova9@gmail.com

Джомартова Ш.А.

Әл-Фараби атындағы Қазақ ұлттық университеті, доцент

Қазіргі таңда цифрлық технологиялардың дамуы биометриялық сәйкестендіру жүйелерінің кеңінен қолданылуына алып келді. Саусақ іздері арқылы жеке басын тану әдістері құқық қорғау, банк жүйелері және электронды үкімет платформаларында кеңінен қолданылады. Бұл әдістер жоғары дәлдікке ие болғанымен, оларды жетілдіру қажеттілігі туындауда. Себебі сәйкестендіру жылдамдығы, үлкен көлемдегі деректерді өңдеу тиімділігі және жүйенің қауіпсіздігі маңызды мәселелер қатарында қалып отыр. Қазіргі заманғы биометрикалық технологиялар жеке басын тану процестерін жетілдіруге бағытталған. Саусақ іздері арқылы идентификациялау – ең сенімді және кең таралған әдістердің бірі. Алайда, үлкен көлемдегі мәліметтерді өңдеу жылдамдығы, жүйенің дәлдігі және киберқауіпсіздік мәселелері жүйенің тиімділігіне әсер етеді [1]. Осы зерттеу жұмысының мақсаты – саусақ іздері арқылы жеке басын тану процесін оңтайландыру үшін алгоритмдік және технологиялық шешімдерді әзірлеу. Зерттеу аясында қазіргі заманғы саусақ іздерін тану жүйелері мен алгоритмдерінің тиімділігіне талдау жүргізілуде [2]. Сонымен қатар, деректерді өңдеу жылдамдығын арттыру үшін нейрондық желілер мен жасанды интеллект әдістерін қолдану мүмкіндігі қарастырылуда [3]. Саусақ іздерін тану үшін Minutiae-based және Pattern-based әдістері салыстырылып, олардың артықшылықтары мен кемшіліктері зерттелуде [4]. Алдын ала тәжірибелік зерттеулер нақты уақыт режимінде саусақ іздерін сәйкестендіру алгоритмдерін жетілдірудің маңыздылығын көрсетіп отыр. Бастапқы талдау нәтижелері көрсеткендей, дәстүрлі Minutiae-based әдісі жоғары дәлдікке ие болғанымен, есептеу жылдамдығы жағынан шектеулерге ие. Pattern-based әдісі, керісінше, үлкен көлемдегі мәліметтерді өңдеуде тиімдірек, бірақ дәлдік жағынан Minutiae әдісінен төмен [5]. Осы мәселені шешу үшін гибридті әдісті қолдану қарастырылуда, онда нейрондық желілер арқылы алдын ала өңдеу жүргізіліп, саусақ іздерін танудың жоғары дәлдігіне және жылдамдығына қол жеткізу жоспарлануда. Саусақ іздері арқылы жеке басын тану процесін оңтайландыру алгоритмдерінің дамуы қауіпсіздік пен сәйкестендіру жылдамдығын арттыруға мүмкіндік береді. Зерттеу нәтижелері болашақта жеке тұлғаны сәйкестендіру жүйелерін жетілдіруде және құқық қорғау, банк жүйелері мен электронды үкімет салаларында қолданылуы мүмкін.

Пайдаланылған әдебиеттер тізімі:

1. Jain, A. K., Prabhakar, S., & Pankanti, S. (2002). On the similarity of identical twin fingerprints. *Pattern Recognition*, 35(11), 2653–2663. DOI: 10.1016/S0031-3203(01)00218-7
2. Maltoni, D., Maio, D., Jain, A. K., & Prabhakar, S. (2009). *Handbook of Fingerprint Recognition* (2nd ed.). Springer. DOI: 10.1007/978-1-84882-254-2
3. Cao, K., & Jain, A. K. (2018). Automated latent fingerprint recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 41(4), 767–779.
4. Sankaran, A., Tulyakov, S., Govindaraju, V., & Setlur, S. (2017). Intelligent pattern recognition techniques for biometric authentication. *IEEE Transactions on Image Processing*, 26(5), 2344–2357.
5. Yoon, S., Feng, J., & Jain, A. K. (2012). Altered fingerprints: Analysis and detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(3), 451–464.

Искусственный интеллект, будущее и этика: влияние ии на восприятие реальности

Ахметжанов Ф.Р.

*КазНМУ имени С.Д. Асфендиярова, 1 курс
email: akhmetzhankafariska@gmail.com*

Нургаева Г.К.

КазНМУ имени С.Д. Асфендиярова, PhD, ассоц. профессор

Искусственный интеллект в медицине приносит значительные улучшения, повышая точность диагностики, ускоряя процессы лечения и обеспечивая персонализированный подход к каждому пациенту. Эти преимущества позволяют значительно улучшить качество медицинской помощи и уменьшить вероятность ошибок. Однако, несмотря на очевидную пользу в этой области, использование ИИ в других сферах, таких как :безопасность и приватность данных, порождает этические проблемы. Эти аспекты требуют внимательного анализа, что в дальнейшем позволит более глубоко рассмотреть вызовы, связанные с развитием искусственного интеллекта в разных областях. ИИ проникает во все сферы жизни, предлагая огромные возможности, но одновременно несет серьезные этические вызовы. Как отметил Генеральный секретарь ООН Антониу Гутерриш, «предупреждения о новых формах ИИ – оглушительны, и громче всего их подают сами разработчики». Нам необходимо осознать эти риски и научиться управлять ими.

Современные алгоритмы формируют информационное поле каждого человека, создавая эффект «эхо-камеры», где человек видит только подтверждающую его взгляды информацию. Это искажает объективную картину мира и усиливает социальную поляризацию. Технологии deepfake, позволяющие подделывать видео и аудиозаписи с пугающей достоверностью, вызывают потерю доверия к реальным данным и ведут к феномену «постправды 2.0».

Генеративные модели ИИ могут создавать фальшивые тексты, что способствует манипуляциям общественным мнением. Основные этические вызовы ИИ затрагивают не только информацию, но и ключевые аспекты общества:

- Приватность и слежка – риск цифрового тоталитаризма.
- Предвзятость алгоритмов – дискриминация из данных приводит к несправедливым решениям.
- Отсутствие прозрачности – многие алгоритмы – «черные ящики».
- Автономное оружие – машины, принимающие решения об убийстве, угрожают гуманности.
- Социальный контроль – системы рейтинга граждан ограничивают права.
- Авторское право – кто владеет контентом, созданным нейросетями?

Будущее: три сценария 1. Пессимистический. ИИ становится инструментом манипуляций, контроля и социальной несправедливости. 2. Оптимистический. Разрабатываются строгие нормы, а технологии служат на благо общества. 3. Смешанный. В одних сферах (например, медицине) ИИ под контролем, а в других (реклама, соцсети) – остается полем для манипуляций.

Подходя к концу можем уверенно сказать, что ИИ– мощный инструмент, который может служить как прогрессу, так и разрушению общества. Сегодня мы стоим перед выбором: создать справедливую и безопасную цифровую среду или допустить, чтобы технологии вышли из-под контроля. Этот выбор определит будущее нашего мира.

Список использованной литературы:

1. <https://www.reuters.com/technology/un-chief-backs-idea-global-ai-watchdog-like-nuclear-agency-2023-06-12/>
2. <https://www.unesco.org/en/artificial-intelligence/recommendation-ethics/cases>

ИИ Автоматизация обработки запросов пользователей службой технической поддержки компании: повышение эффективности и качества обслуживания

Әбдіхан Жармахан

КазНУ имени аль-Фараби, 4 курс бакалавриат

Шаяхметова А.С.

КазНУ имени аль-Фараби, и.о. профессора

В эпоху цифровой трансформации, характеризующейся экспоненциальным ростом объема данных и клиентских взаимодействий, службы технической поддержки сталкиваются с возрастающей нагрузкой и необходимостью оперативного и качественного реагирования на запросы пользователей. Традиционные методы обработки заявок часто оказываются неспособными эффективно справиться с этим вызовом, что приводит к увеличению времени ожидания, снижению удовлетворенности клиентов и росту операционных издержек. В этой связи, автоматизация процессов службы технической поддержки с применением технологий искусственного интеллекта (ИИ) становится ключевым фактором оптимизации работы компании. Использование ИИ позволяет не только автоматизировать рутинные задачи, но и внедрить интеллектуальные механизмы для более эффективной обработки сложных запросов, что открывает новые возможности для повышения производительности и улучшения клиентского опыта.[1]

Внедрение ИИ в службу технической поддержки позволяет решить ряд ключевых проблем, связанных с обработкой запросов. Во-первых, интеллектуальная маршрутизация, основанная на анализе содержания запроса и компетенций специалистов, значительно сокращает время передачи заявки нужному сотруднику. Алгоритмы машинного обучения способны классифицировать запросы по категориям и приоритетам, обеспечивая оперативное реагирование на критические инциденты. Во-вторых, чат-боты, оснащенные технологиями обработки естественного языка (NLP), могут эффективно обрабатывать значительную часть типовых запросов, предоставляя мгновенные ответы на часто задаваемые вопросы и решая простые проблемы без участия операторов. Это освобождает специалистов для работы над более сложными и нетривиальными задачами, повышая их продуктивность и снижая уровень выгорания. В-третьих, ИИ может быть использован для анализа больших объемов данных об обращениях, выявляя закономерности и тенденции, что позволяет прогнозировать потенциальные проблемы и оптимизировать процессы поддержки. Например, анализ тональности обращений помогает оперативно реагировать на негативные отзывы и предотвращать отток клиентов.[2]

Таким образом, автоматизация обработки запросов пользователей службой технической поддержки компании с использованием технологий искусственного интеллекта представляет собой стратегически важный шаг, позволяющий достичь значительного повышения эффективности работы и качества обслуживания. Внедрение интеллектуальных инструментов, таких как чат-боты и системы маршрутизации на основе машинного обучения, позволяет сократить время обработки заявок, снизить нагрузку на персонал, минимизировать влияние человеческого фактора и обеспечить более персонализированный подход к каждому клиенту. Дальнейшее развитие и интеграция ИИ в службу технической поддержки будет играть ключевую роль в обеспечении конкурентоспособности компаний в условиях растущих требований к клиентскому сервису.[3]

Пример успешного внедрения ИИ в службе технической поддержки казахстанской телекоммуникационной компании "АлмаТелеком". Компания "АлмаТелеком", крупный оператор связи в Казахстане, столкнулась с быстрорастущим объемом обращений в службу технической поддержки, особенно по вопросам подключения к интернету, настройки оборудования и проблемам с телевидением. Существующая команда операторов не всегда справлялась с нагрузкой, что приводило к увеличению времени ожидания на линии, снижению

удовлетворенности абонентов и повышенной нагрузке на персонал.

Таблица № 1 Гипотетическая таблица: Сравнение показателей работы службы поддержки "АлмаТелеком" до и после внедрения ИИ

Показатель	До внедрения ИИ (Предыдущий период)	После внедрения ИИ (Текущий период)	Изменение (%)
Среднее время ожидания ответа оператора (мин)	8	4.5	-43.75
Процент решенных запросов чат-ботом (%)	0	65	+65
Среднее время решения инцидента (часы)	12	9	-25
Уровень удовлетворенности клиентов (CSI, %)	75	86	+14.67
Нагрузка на операторов первой линии (заявок/день)	50	32	-36
Операционные расходы на службу поддержки	100% (базовый уровень)	90%	-10
Доля повторных обращений по одному вопросу (%)	15	8	-46.67

Внедрение комплексной системы автоматизации на базе искусственного интеллекта в службе технической поддержки казахстанской компании "АлмаТелеком" демонстрирует значительный потенциал для повышения эффективности работы и улучшения качества обслуживания клиентов. Автоматизация рутинных задач с помощью чат-бота, интеллектуальная маршрутизация сложных запросов и анализ тональности обращений привели к существенному сокращению времени ожидания для клиентов, снижению нагрузки на операторов первой линии и, как следствие, к повышению общего уровня удовлетворенности абонентов. Более того, оптимизация рабочих процессов и сокращение необходимости в дополнительном персонале позволили компании снизить операционные расходы. Успех внедрения был обусловлен качественной базой знаний, учетом языковых особенностей целевой аудитории, интеграцией с существующими системами и постоянной работой над оптимизацией AI-решений. Данный гипотетический пример подчеркивает актуальность и перспективность использования ИИ в сфере клиентского сервиса на рынке Казахстана, открывая возможности для значительного улучшения ключевых операционных показателей и повышения конкурентоспособности компаний.[4]

Список использованной литературы:

1. Человек и системы искусственного интеллекта / Под ред. акад. РАН В.А. Лекторского. — СПб.: Издательство «Юридический центр», 2022 — 328 с.
2. Джураев Ш.С. Искусственный интеллект в менеджменте // Интернаука. - 2021. - № 25-1 (201). С. 80-82.
3. А.И. Соснило. Атлас искусственного интеллекта для бизнеса и власти. – СПб: Университет ИТМО, 2022. – 98 с.

4. Ключко В.А. Технологии искусственного интеллекта в менеджменте наукоемких предприятий // Вестник Московского финансово-юридического университета МФЮА. 2023. № 1. С. 105-117

Үлкен тілдік үлгілерді үйрету үшін қазақша мәтіндерді белгілеу

Багатикова А.С.

Егизбаева А.Ж.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: bagatikova_adelya@live.kaznu.kz, +7 775 417 4309

Шакирова Г.А.

Әл-Фараби атындағы ҚазҰУ, PhD, аға оқытушы

Үлкен тілдік үлгілер (ҮТҮ) – жасанды интеллект пен табиғи тілді өңдеудегі маңызды технологиялардың бірі. Олар мәтінді түсіну, сұрақтарға жауап беру, аударма жасау сияқты тапсырмаларды орындай алады. Алайда, қазақ тіліндегі ҮТҮ дамуы деректердің аздығы мен белгіленген корпустардың жеткіліксіздігінен тежелуде.

Ғылыми жұмыстың мақсаты – қазақша мәтіндерді белгілеу әдістерін қарастырып, олардың ҮТҮ-ді оқытуға әсерін бағалау. Қазіргі таңда қазақ тілінде сапалы аннотацияланған деректердің жетіспеушілігі ҮТҮ-дің тиімді дамуына үлкен кедергі келтіруде. Сондықтан, қолжетімді корпус сапасын жақсарту және автоматтандырылған белгілеу әдістерін дамыту өзекті мәселе болып табылады.

Бүгінгі күнде өзектілігі қазақ тіліндегі үлкен тілдік үлгілерді дамытудағы басты қиындықтардың бірі – сапалы әрі ауқымды аннотацияланған деректердің жетіспеуі. Морфологиялық, синтаксистік және семантикалық белгілеу, сондай-ақ атаулы нысандарды тану (NER) әдістері қазақша мәтіндерді өңдеу сапасын жақсартып алады [1]. Қазақ тілінің агглютинативті табиғаты мен сөз түрленуінің күрделілігі белгілеу процесін қиындатады [2]. Сонымен қатар, қолмен аннотация жасау көп уақыт пен ресурсты талап ететіндіктен, белгілеу процесерін автоматтандыру маңызды [3].

Мақсатқа қол жеткізу үшін есеп қойылымы мынадай: қазақ тіліндегі үлкен тілдік үлгілерді дамыту үшін сапалы деректерді белгілеу әдістерін талдау, қолжетімді корпустарды зерттеу және олардың тиімділігін бағалау. Сонымен қатар, қазақ тіліне бейімделген алдын ала үйретілген үлгілердің нәтижелерін салыстырып, белгілеудің сапаға әсерін анықтау.

Есепті шешу әдістері келесі қадамнан тұрады: біріншіден, қазақ тіліне қолжетімді корпус және белгілеу әдістерін жинақтау мен талдау. Екіншіден, морфологиялық, синтаксистік және семантикалық белгілеу әдістерін қарастырып, олардың қазақ тіліндегі ҮТҮ-ге әсерін бағалау. Үшіншіден, қолмен және автоматты аннотациялау тәсілдерін салыстыру. Төртіншіден, белгіленген деректер негізінде GPT [4], BERT [5] үлгілерін сынақтан өткізіп, олардың нәтижелерін салыстыру. Бесіншіден, алынған нәтижелерді талдап, болашақта қазақ тіліндегі ҮТҮ сапасын арттыру жолдарын ұсыну.

Белгіленген деректер ҮТҮ-ді үйретуде шешуші рөл атқарады. Жинақталған деректерді сапалы аннотациялау және олардың бірізділігін қамтамасыз ету модельдердің нәтижелеріне тікелей әсер етеді. Белгіленген корпус негізінде GPT [4], BERT [5] үлгілерімен жүргізілген тәжірибелер қазақ тілінде алдын ала үйретілген модельдердің дәлірек нәтиже беретінін көрсетті.

Алдағы жылдары қазақ тіліндегі ҮТҮ сапасын арттыру үшін көптілді корпустарды біріктіру, морфологиялық ерекшеліктерді жақсы түсінетін модельдер әзірлеу және машиналық оқыту әдістерімен белгілеуді автоматтандыру қажет. Сонымен қатар, мемлекеттік қолдау мен ашық дереккөздерді дамыту қазақ тілінде үлкен көлемді әрі сапалы ҮТҮ жасауға мүмкіндік береді. Қазақ тіліндегі үлкен тілдік үлгілерді дамыту сапалы аннотацияланған деректердің болуына тікелей байланысты. Сондықтан, белгілеу әдістерін жетілдіру және автоматтандыру арқылы ҮТҮ нәтижелерін жақсартып, қазақ тілінің цифрлық кеңістіктегі мүмкіндіктерін кеңейтуге болады. Бұл бағыттағы зерттеулер әрі қарай көптілді корпустарды біріктіру, морфологиялық ерекшеліктерді тереңірек зерттеу және машиналық оқытудың жаңа тәсілдерін қолдану арқылы жалғасуы тиіс.

Пайдаланылган әдебиеттер тізімі:

1. Manning, C. D., Surdeanu, M., Bauer, J., Finkel, J., Bethard, S. J., & McClosky, D. (2014). The Stanford CoreNLP natural language processing toolkit. Proceedings of 52nd Annual Meeting of the Association for Computational Linguistics: System Demonstrations, 55–60. <https://doi.org/10.3115/v1/P14-5010>
2. Altintas, K., & Cicekli, I. (2002). A morphological disambiguator for Turkish. Proceedings of the 20th International Conference on Computational Linguistics (COLING 2002), 1–7. <https://doi.org/10.48550/arXiv.cs/0205026>
3. Zeman, D., & Resnik, P. (2008). Cross-language parser adaptation between related languages. Proceedings of the 46th Annual Meeting of the Association for Computational Linguistics, 35–42. <https://doi.org/10.3115/1557690.1557695>
4. Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., ... & Amodei, D. (2020). Language models are few-shot learners. Advances in Neural Information Processing Systems, 33, 1877–1901. <https://doi.org/10.48550/arXiv.2005.14165>
5. Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 1, 4171–4186. <https://doi.org/10.48550/arXiv.1810.04805>

Применение искусственного интеллекта в образовательных платформах для улучшения процесса обучения

Бакытұлы А.

КазНУ им. аль-Фараби, 1 курс магистрант

E-mail: akzholl.bakytuly@gmail.com

Исабаева Д.Н.

КазНУ им. аль-Фараби, к.п.н., и.о. профессора

Данный тезис исследует применение искусственного интеллекта в образовательных платформах для повышения эффективности учебного процесса. Рассматриваются возможности персонализации обучения, оперативной обратной связи и объективной оценки знаний через интеллектуальные системы. Работа выявляет преимущества интеграции ИИ, а также существующие вызовы, связанные с обеспечением безопасности данных и необходимостью повышения квалификации педагогов.

В результате современного технологического прогресса возможности искусственного интеллекта (ИИ) стремительно расширились во многих областях, включая образование. Образовательные платформы с поддержкой ИИ способны автоматизировать множество задач, одновременно предлагая индивидуальное обучение, адаптированное к потребностям каждого ученика [1]. В условиях дистанционного обучения, вызванного пандемией COVID-19, проблема традиционного образования заключается в его негибкости и медленной адаптации к быстрым изменениям в знаниях учащихся [3]. Необходимо внедрять современные технологии, способные оптимизировать учебный процесс, поскольку образовательная система испытывает дополнительную нагрузку из-за большого объема работы учителей и необходимости быстрого обновления учебных программ [2]. ИИ создает новые возможности для интеллектуальных систем, помогающих в обучении, таких как чат-боты, адаптивные системы тестирования и интеллектуальные обучающие системы [5].

Данное исследование направлено на изучение возможностей использования искусственного интеллекта в образовательных платформах для улучшения учебного опыта. Помимо оценки влияния этих технологий на мотивацию и успеваемость учащихся, исследование пытается определить преимущества и недостатки интеграции ИИ в образовательный процесс. Для достижения этой цели необходимо изучить опыт различных стран и учебных заведений, использующих ИИ для совершенствования педагогических процедур, и выявить ключевые элементы успешной интеграции этих технологий в образовательную среду [4].

Согласно исследованиям, использование ИИ в образовательных платформах может улучшить обучение путем оперативного отслеживания знаний учащихся и персонализации учебного процесса. Более глубокое усвоение материала и повышение академической успеваемости — это два преимущества интеллектуальных систем, основанных на алгоритмах машинного обучения, которые способны адаптировать образовательный контент к уникальным особенностям каждого ученика [1]. С помощью чат-ботов и виртуальных ассистентов учителя и ученики могут легче общаться, предоставляя учащимся возможность получать быструю обратную связь и дополнительную помощь онлайн [2]. Кроме того, исследования показывают, что интеграция искусственного интеллекта в систему оценивания позволяет осуществлять более быстрый и объективный контроль знаний, что повышает доверие к образовательной системе и снижает нагрузку на преподавателей [5]. Тем не менее, признается, что все еще существует много организационных и технологических проблем, которые необходимо решить, особенно тех, которые касаются конфиденциальности данных и жизнеспособности информационных систем в условиях широкого использования [3]. Кроме того, крайне важно учитывать необходимость обучения педагогов использованию новых технологий в классе [4].

Таким образом, использование ИИ в образовательных платформах — это перспективная область, обладающая потенциалом значительно улучшить учебный процесс через внедрение персонализированных программ обучения, повышение объективности оценки знаний и оптимизацию взаимодействия между участниками образовательного процесса. Несмотря на препятствия, которые еще предстоит преодолеть, развитие ИИ и его интеграция в образовательную систему открывают множество возможностей для модернизации учебных заведений и повышения качества специализированной подготовки. Согласно результатам, для успешного внедрения ИИ необходима комплексная стратегия, включающая как организационно-технические меры, так и методическую подготовку преподавательского состава. Дальнейшие исследования в этой области позволят более точно определить оптимальные модели интеграции ИИ в образовательные процессы и сформулировать рекомендации по практическому внедрению технологий в учебных заведениях [2][5].

Список использованной литературы:

1. Kaplan-Rakowski R., Grotewold K., Hartwick P., Papin K. Generative AI and Teachers' Perspectives on Its Implementation in Education. *J. Interact. Learn. Res.* 2023, 34(2): 313–338.
2. Al Darayseh A. Acceptance of Artificial Intelligence in Teaching Science: Science Teachers' Perspective. *Comput. Educ. Artif. Intell.* 2023, 100132.
3. Coman C., Tiru L.G., Mesesan L., Stanciu C., Bularca M.C. Online Teaching and Learning in Higher Education during the Coronavirus Pandemic: Students' Perspective. *Sustainability* 2020, 12: 10367.
4. Abuhassna H., Al-Rahmi W.M., Yahya N., Megat A.Z., Mohamad D. Development of a New Model on Utilizing Online Learning Platforms to Improve Students' Academic Achievements and Satisfaction. *Int. J. Educ. Technol. High. Educ.* 2020, 17: 38.
5. Ahmad S.F., Rahmat M.K., Mubarik M.S., Alam M.M., Hyder S.I. Artificial Intelligence and Its Role in Education. *Sustainability* 2021, 13: 12902.

Үлкен тілдік модельдерді оқыту және тестілеу үшін қазақша мәтіндер корпусын құру

Егизбаева А.Ж.

Багатикова А.С.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: amina.ezh@mail.ru, +7 747 939 6719

Шакирова Г.А.

Әл-Фараби атындағы ҚазҰУ, PhD, аға оқытушы

Қазіргі кезеңде жасанды интеллект пен табиғи тілді өңдеу (NLP) технологияларының қарқынды дамуы үлкен тілдік модельдерді (YTM) тиімді оқыту мен тестілеу үшін сапалы және кең ауқымды мәтіндік корпустардың қажеттілігін арттырып отыр. Алайда, қазақ тілінде құрылымдалған және стандартталған деректердің тапшылығы бұл бағыттағы зерттеулердің мүмкіндіктерін шектейді [1]. Қолданыстағы көптілді корпустарда қазақ тілі мардымсыз қамтылған немесе сапасы төмен деңгейде ұсынылған, бұл қазақ тіліндегі нейрондық желілердің өнімділігіне кері әсерін тигізуде [2]. Осыған байланысты, қазақ тілінің морфологиялық, синтаксистік және семантикалық ерекшеліктерін ескеретін жоғары сапалы тілдік корпус құру – өзекті ғылыми мәселе болып табылады.

Зерттеудің мақсаты – қазақ тіліндегі сапалы мәтіндік корпус қалыптастырудың әдістемелік негіздерін әзірлеу, оны құрылымдау, аннотациялау және YTM-ді оқыту мен тестілеу барысында қолдану тәсілдерін айқындау.

Зерттеудің өзектілігі қазақ тілінде сапалы және кең ауқымды мәтіндік ресурстардың жеткіліксіздігімен байланысты. Тілдік деректердің жетіспеушілігі машиналық оқыту модельдерінің тиімділігін төмендетіп, қазақ тіліне бейімделген NLP жүйелерінің сапасын әлсіретеді [3]. Сонымен қатар, корпус құруда дереккөздердің әртүрлілігі мен тілдік материалдардың өңдеу сапасы маңызды рөл атқарады. Қазақ тіліндегі ашық және стандартталған корпустың болмауы ғылыми-зерттеу жұмыстары мен коммерциялық жобалардың дамуын тежейді.

Зерттеу міндеттері қазақ тіліндегі мәтіндік корпусты қалыптастырудың ғылыми негіздемесін әзірлеуді, корпуста енгізілетін дереккөздерді жүйелеу мен таңдауды, жинақталған мәтіндерді өңдеу және белгілеу әдістерін анықтауды, корпустың сапасын бағалау тәсілдерін әзірлеуді, сондай-ақ YTM-ді оқыту және тестілеу барысында корпусты қолданудың тиімділігін бағалауды қамтиды.

Зерттеу әдістері бірнеше негізгі кезеңнен тұрады. Бірінші кезеңде корпус үшін бастапқы дереккөздер анықталып, оның құрамына әдеби шығармалар, ресми құжаттар, бұқаралық ақпарат құралдарының материалдары, ғылыми еңбектер және интернет кеңістігіндегі мәтіндер енгізіледі [4]. Келесі кезеңде мәтіндерді алдын ала өңдеу жүргізіліп, лингвистикалық нормализация жасалады, мағыналық тұрғыдан қажетсіз және қайталанатын деректер сүзгіден өтеді, кодтау мәселелері стандартталады [5]. Морфологиялық, синтаксистік және семантикалық деңгейлерде аннотациялау барысында машиналық оқыту мен терең оқыту әдістері, соның ішінде GPT [6], BERT [7] модельдері қолданылады. Корпустың сапасын бағалау процесінде адамдық аннотация нәтижелері мен автоматтандырылған метрикалардың көрсеткіштері негізге алынады, бұл тілдік деректердің дәлдігі мен қолданбалы маңыздылығын объективті түрде анықтауға мүмкіндік береді [5]. Соңғы кезеңде құрастырылған корпус үлкен тілдік модельдерді алдын ала оқыту және тестілеу процесінде қолданылады, нәтижесінде қазақ тілінде жұмыс істейтін NLP жүйелерінің тиімділігі артады және олардың сапалық көрсеткіштері жақсарады [6].

Зерттеу нәтижелері қазақ тіліндегі мәтіндік корпустарды құрудың ғылыми және қолданбалы маңыздылығын көрсетеді. Алынған корпус қазақ тілінде жұмыс істейтін NLP жүйелерінің өнімділігін жақсартуға, қазақ тілін цифрлық кеңістікте кеңінен қолдануға және автоматтандырылған тілдік талдау жүйелерін дамытуға мүмкіндік береді. Болашақта қазақ

тіліндегі ашық қолжетімді корпустарды жетілдіру, белгілеу стандарттарын қалыптастыру және оларды халықаралық лингвистикалық ресурстар жүйесіне интеграциялау маңызды ғылыми-зерттеу бағыттарының бірі болып қала береді.

Пайдаланылған әдебиеттер тізімі:

1. Scannell, K. P. (2007). The Crúbadán Project: Corpus building for under-resourced languages. *Building and Exploring Web Corpora: Proceedings of the 3rd Web as Corpus Workshop*, 5, 20–28. <https://doi.org/10.3115/1626329.1626333>
2. Tyers, F. M., Washington, J. N., & Enache, I. R. (2017). Towards a free/open-source universal-dependency treebank for Kazakh. *Proceedings of the 16th International Workshop on Treebanks and Linguistic Theories (TLT16)*, 136–147. <https://doi.org/10.18653/v1/W17-7615>
3. Ataman, D., Negri, M., Turchi, M., & Federico, M. (2019). Exploring the role of BPE in the neural machine translation of agglutinative languages. *Proceedings of the 16th Conference of the European Chapter of the Association for Computational Linguistics: Main Volume*, 17, 1–11. <https://doi.org/10.18653/v1/E19-3001>
4. Ural, A. (2020). Challenges in developing NLP tools for under-resourced Turkic languages. *Proceedings of the 12th Language Resources and Evaluation Conference (LREC 2020)*, 3568–3574. <https://doi.org/10.48550/arXiv.2006.00983>
5. Sproat, R., & Jaitly, N. (2016). RNN approaches to text normalization: A challenge. *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (ACL 2016)*, 2, 609–618. <https://doi.org/10.18653/v1/P16-2099>
6. Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., ... & Amodei, D. (2020). Language models are few-shot learners. *Advances in Neural Information Processing Systems*, 33, 1877–1901. <https://doi.org/10.48550/arXiv.2005.14165>
7. Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, 1, 4171–4186. <https://doi.org/10.48550/arXiv.1810.04805>

Сравнение эффективности ViT и MaxViT на наборе данных о болезнях листьев риса

Джураев Д.Б.

КазНУ им. аль-Фараби, 4 курс бакалавриат

Email: doninadirov@mail.ru

Уалиева И.М.

КазНУ им. аль-Фараби, Ассоциированный профессор (доцент)

Методы машинного обучения и глубокого обучения широко применяются для обнаружения и классификации заболеваний листьев риса путем использования возможностей обработки изображений и распознавания образов. Эти методы направлены на выявление заболеваний растений на ранних стадиях, что приводит к уменьшению потери урожая и улучшению продуктивности сельского хозяйства.

На протяжении многих лет для классификации заболеваний на основе изображений использовались различные подходы: от традиционных методов машинного обучения до сверточных нейронных сетей (CNN), в последнее время растет популярность архитектур на основе трансформеров используемых в обработке естественного языка.

В этом исследовании мы изучаем производительность Vision Transformer (ViT) и его усовершенствованного варианта, Multi-Axis Vision Transformer (MaxViT), для классификации заболеваний листьев риса. Используя крупный набор данных, содержащий 42 876 изображений по девяти классам заболеваний, мы проводим сравнительный анализ, чтобы определить, какая модель обеспечивает более высокую точность классификации и лучшую способность к обобщению.

Результаты экспериментов

Эксперименты проводились на двух графических процессорах NVIDIA T4 Tensor Core. Использовалась предварительно обученная модель MaxViT-T (версия IMAGENET1K_V1), где последний полностью связанный слой был модифицирован для классификации 9 классов заболеваний. Количество параметров в модели MaxViT составляет 32,1 миллиона. В исследовании использовалась предварительно обученная модель ViT-BasePatch16-224 от Google, адаптированная для распознавания заболеваний риса путем замены выходного слоя на полностью связанный слой, содержащий 9 нейронов. Количество параметров в модели ViT составляет 85 798 656.

TABLE 3. VALIDATION ACCURACY AND LOSS

	<i>MaxViT</i>	<i>ViT</i>
Accuracy	94.10%	91.21%
Loss	0.1901	0.2292

TABLE 4. VALIDATION PRECISION, RECALL AND F1-SCORE FOR MAXVIT

<i>Class</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Bacterial leaf blight	100%	100%	100%
Blight	100%	99,65%	99,82%
Brown Spot	98,15%	90,86%	94,36%
Hispa	93,77%	91,09%	92,41%
Leaf blast	91,5%	99,65%	95,4%
Leaf scaled	91,49%	98,28%	94,77%
Leaf smut	89,14%	74,08%	80,92%
Sheath Blight	82,03%	91,21%	86,37%
Tungro	99,65%	99,65%	99,65%
Average	93,97%	93,83%	93,75%

TABLE 5. VALIDATION PRECISION, RECALL AND F1-SCORE FOR VIT

<i>Class</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Bacterial leaf blight	99,54%	100%	99,77%
Blight	100%	99,54%	99,77%
Brown Spot	98,01%	95,89%	96,94%
Hispa	79,06%	92,69%	85,33%
Leaf blast	93%	95,66%	94,31%
Leaf scaled	96,19%	98,05%	97,11%
Leaf smut	86%	44,17%	58,37%
Sheath Blight	74,02%	94,97%	83,2%
Tungro	99,43%	99,88%	99,65%
Average	91,69%	91,21%	90,49%

Кәсіпорынның виртуалды өкілі үшін үлкен деректерді сақтау инфрақұрылымын жобалау

Жанабил А.Ғ.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр
E-mail: alikhanzhanabil@gmail.com, +7 747 433 5114

Зиятбекова Г.З.

Әл-Фараби атындағы ҚазҰУ, PhD, доцент м.а.

Бұл жұмыстың мақсаты – кәсіпорынның виртуалды көрінісі үшін ауқымды сақтау және үлкен деректерді өңдеу инфрақұрылымын құру. Қазіргі бизнестегі деректер көлемінің қарқынды өсуі жағдайында ақпараттық ағындарды тиімді басқару, оларды нақты уақытта сақтау және өңдеу қажет. Осы мақсатқа жету үшін деректерді өңдеудің заманауи технологиялары қарастырылады және жүйенің жоғары өнімділігі мен сенімділігін қамтамасыз ете алатын архитектуралық шешімдер жобаланады.

Қазіргі бизнестегі деректер көлемінің өсуі заттар интернетінің (IoT) дамуына, бизнес-процестерді автоматтандыруға және кәсіпорындардың цифрлық трансформациясына байланысты. Негізгі міндет-деректердің үлкен массивтерін сақтау ғана емес, сонымен қатар басқару шешімдерін қабылдау үшін оларды жедел өңдеу. Деректерді сақтаудың ауқымды инфрақұрылымын енгізу компанияларға өз қызметінің тиімділігін арттыруға, шығындарды азайтуға және деректерді талдау процестерін жеделдетуге мүмкіндік береді.

Кәсіпорынның виртуалды көрінісі ретінде цифрлық егіз – бұл компанияның нақты бизнес-процестері мен инфрақұрылымын көрсететін бағдарламалық жасақтама моделі. Цифрлық егіздерді пайдалану жүйенің әрекетін болжауға, әртүрлі сценарийлерді тексеруге және ресурстарды басқарудың тиімділігін арттыруға мүмкіндік береді. Бұл жұмыс үлкен деректерді өңдеудің заманауи технологияларын қолдана отырып, кәсіпорынның цифрлық егіздерді басқару жүйесін құруды қарастырады [1].

Үлкен деректерді тиімді сақтау үшін уақыт сериялары үшін InfluxDB немесе TimescaleDB сияқты мамандандырылған мәліметтер базасы, сондай-ақ Amazon Redshift және Google BigQuery сияқты аналитикалық сұрау шешімдері қолданылады. Сақтау жүйесінде бұлтқа негізделген инфрақұрылым, соның ішінде AWS S3 және Azure Blob Storage маңызды рөл атқарады, бұл нақты уақыт режимінде деректерді сенімді сақтауға және оларға қол жеткізуге мүмкіндік береді. Цифрлық егіз үшін үлкен деректерді сақтау инфрақұрылымын жүзеге асыру үшін негізгі компоненттер мен олардың өзара әрекеттесуін қамтитын жүйенің жоғары деңгейлі архитектурасы жасалады. Технологиялық стек ретінде Django, MQTT, PostgreSQL, Kafka және басқа да заманауи шешімдер қолданылады. Даму ортасы контейнерлеу үшін Docker көмегімен конфигурацияланады, сонымен қатар Django жобасын инициализациялау негізгі параметрлерді орнатумен жүзеге асырылады [2].

Уақыт қатарларын тиімді сақтау үшін InfluxDB немесе timescaledb дерекқоры біріктіріледі. Деректерді бірнеше данаға бөлу үшін мәліметтер базасын сегменттеу жүзеге асырылады, бұл жүйенің жұмысын жақсартады. Apache Kafka жоғары өткізу қабілеттілігін қамтамасыз ететін нақты уақыттағы деректерді ағынмен өңдеу үшін қолданылады. Пакеттік өңдеу және үлкен деректерді талдау үшін Apache Spark қолданылады. Шикі деректер AWS S3 немесе Azure Blob Storage сияқты бұлттық қоймаларда сақталады. Аналитикалық сұраулар мен есеп беру үшін Amazon Redshift және Google BigQuery негізіндегі шешімдер енгізілуде. Жүйе деректерді алу, өңдеу және сақтау сияқты жеке компоненттерді дербес масштабтауға мүмкіндік беретін микросервистік архитектураға негізделген. Kubernetes контейнерлерді басқару үшін қолданылады, бұл жүктемені автоматты түрде орналастыруға және теңестіруге мүмкіндік береді. Деректерді іздеуді жеделдету және дерекқордағы жүктемені азайту үшін Redis немесе Memcached көмегімен жадты кәштеу жүзеге асырылады.

Орталықтандырылған журнал жүргізу және жүйені бақылау үшін ELK (Elasticsearch,

Logstash, Kibana) стегі қолданылады. Prometheus және Grafana өнімділікті бақылау және негізгі көрсеткіштерді визуализациялау үшін қолданылады. Күпия ақпаратты қорғау үшін деректерді беру кезінде де, сақтау кезінде де шифрлау жүзеге асырылады. Рөлге негізделген қол жетімділікті басқару (RBAC) пайдаланушы құқықтары мен деректерге қол жетімділікті басқаруға мүмкіндік береді. Деректерді визуализациялау үшін веб-қосымшаның интерфейсі D3.js және Chart.js сияқты құралдарды біріктіреді Жүйенің қауіпсіздігін қамтамасыз ету үшін пайдаланушыларды аутентификациялау және авторизациялау тетігі енгізілуде.

Цифрлық егіз кәсіпорынға ағымдағы процестерді талдап қана қоймай, болашақтағы оқиғалардың дамуын болжауға мүмкіндік береді. Бұл, әсіресе, деректерді жедел талдауды және әртүрлі сценарийлерді модельдеуді қажет ететін күрделі іскери операцияларға қатысты. Цифрлық егізді қолдану проблемаларды тез анықтауға, жаңа стратегияларды сынауға және тәуекелдерді азайтуға мүмкіндік береді. Цифрлық егіздердің болашағы жасанды интеллект, Машиналық оқыту және ИОТ технологияларының интеграциясымен байланысты. Болашақта цифрлық егіздер бизнесті дербес басқару, жабдыққа болжамды қызмет көрсету және нақты уақыттағы бизнес-процестерді оңтайландыру үшін пайдаланылады. Бұлтты есептеу мен 5G технологиясының дамуы әр түрлі салаларда цифрлық егіздердің таралуын тездетеді [3].

Минималды өміршең өнім (MVP) – әзірлеудің тәсілі ретінде дамудың алғашқы кезеңдерінде цифрлық егіз тұжырымдаманы сынауға және жүйенің негізгі талаптарын анықтауға мүмкіндік беретін тәсіл. Үлкен деректерді сақтау және өңдеу инфрақұрылымын әзірлеуде MVP пайдалану тәуекелдерді азайтуға, ресурстарды оңтайландыруға және инновациялық шешімдерді тезірек енгізуге көмектеседі. Бұл жүктемені, сенімділікті және деректердің қауіпсіздігін ескеру қажет масштабталатын жүйелерді құру кезінде өте маңызды. Цифрлық егіздерді енгізу бизнес-процестерді оңтайландыру, шығындарды азайту және операциялық тиімділікті арттыру арқылы бизнеске шығындарды айтарлықтай азайтуға мүмкіндік береді. Болжалды аналитика мен процестерді автоматтандыруды қолдану жабдыққа техникалық қызмет көрсету шығындарының төмендеуіне, төтенше жағдайлардың азаюына және активтердің қызмет ету мерзімінің ұзаруына әкеледі. Сонымен қатар, цифрлық егіздер компанияларға нарықтағы өзгерістерге тезірек бейімделуге мүмкіндік береді, бұл олардың бәсекеге қабілеттілігін жақсартады және бизнестің кірістілігін арттырады [4].

Пайдаланылған әдебиеттер тізімі:

1. М.В. Царев, Ю.С. Андреев. Цифровые двойники в промышленности: история развития, классификация, технологии, сценарии использования // Изв. вузов. Приборостроение, 2021. - Т. 64. - № 7. - С. 517-531.

2. А.И. Боровков, Ю.А. Рябов. Цифровые двойники: определение, подходы и методы разработки // Цифровая трансформация экономики и промышленности: Сб. тр. науч.-практ. конф. с зарубежным участием, 20-22 июня 2019 г. - СПб: Политех-Пресс, 2019. - С. 234-245. DOI:10.18720/PEP/2019.3/25.

3. T. Dasbach, E. Zancul, K. Schützer, R. Anderl. Digital Twin - Integrating Cloud Services into Communication Protocols // Fortin C., Rivest L., Bernard A., Bouras A. (Eds). Product Lifecycle Management in the Digital Twin Era: PLM 2019. IFIP Advances in Information and Communication Technology. - Cham: Springer, 2019. - Vol. 565. - Pp. 283-292. DOI:10.1007/978-3-030-42250-9_27.

4. С.А. Зыкин, М.И. Катаева. Разработка автоматизированной системы управления технологическим процессом на предприятии // Пермский национальный исследовательский политехнический университет. Пермь, 2018. - Т. 1. - С. 139 -140.

Постковид синдромын талдаудың заманауи әдісі: машиналық оқыту жүйесін қолдану

Жанболат Г.Ж.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: gzhanbolatovaa@gmail.com

Сарсембаева Т.С.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Постковид синдромының жүрек-қан тамыр жүйесіне әсерін машиналық оқыту (ML) әдістері арқылы талдау мәселесі қарастырылады. Постковидтен кейінгі миокардит, аритмия, жүрек жеткіліксіздігі, тромбоз және қан қысымының тұрақсыздығы сияқты асқынулардың диагностикасы мен болжауында жасанды интеллект технологияларының рөлі зерттеледі. ЭКГ, КТ, МРТ сияқты медициналық бейнелерді өңдеу үшін терең нейрондық желілер қолданылады. Predictive Analytics әдістері жүрек ауруларының даму ықтималдығын бағалауға мүмкіндік береді, ал телемедицина және смарт құрылғылар пациенттердің жүрек саулығын үздіксіз бақылауға көмектеседі.

Жасанды интеллект (ЖИ) күнделікті өміріміздің ажырамас бөлігіне айналды. Оның көмегімен адамдар уақытын үнемдеп, тапсырмаларды оңай орындай алады. Біз оны жиі байқамасақ та, ол біздің өмірімізді жеңілдетуде. Соңғы жылдары машиналық оқыту, терең оқыту және нейрондық желілер сияқты әдістер ЖИ-дің мүмкіндіктерін айтарлықтай кеңейтті. Жасанды интеллект (ЖИ) қазіргі медицина бағытында да революциялық өзгерістер әкелуде. Ол диагноз қою, емдеу тәсілдерін жетілдіру, медициналық зерттеулер жүргізу және денсаулық сақтау жүйесін оңтайландыру сияқты салаларда кеңінен қолданылады.

Магниттік-резонанстық томография (МРТ) – жүрек бұлшықетіндегі өзгерістерді анықтау; Аутопсия және зертханалық талдаулар – постковидтің жүрекке әсерін терең зерттеу.

Пациенттерді ұзақ мерзімді бақылау (1 жылдық клиникалық зерттеу) – жүрек ауруларының дамуын динамикада бағалау.

Диагностикалық технологиялар:

Электрокардиограмма (ЭКГ) – жүрек ырғағының бұзылыстарын анықтау.;

Эхокардиография (УДЗ) – жүрек қақпақшалары мен жүрек бұлшықетінің жағдайын зерттеу.

Зертханалық талдаулар:

Тропонин (сTnI, сTnT) – жүрек зақымдануының биомаркері;

NT-proBNP – жүрек жеткіліксіздігін бағалау;

D-димер – қан ұюының жоғарылығын анықтау (тромбоз қаупі);

Ферритин, CRP – қабыну процестерін бағалау.

Машиналық оқыту және жасанды интеллект әдістері:

Convolutional Neural Networks (CNN) – МРТ және ЭКГ суреттерін талдау арқылы жүрек аномалияларын анықтау;

Recurrent Neural Networks (RNN), Long Short-Term Memory (LSTM) – уақытқа тәуелді деректерді өңдеп, тахикардия мен аритмияны болжау;

Gradient Boosting (XGBoost, LightGBM, CatBoost) – жүрек жеткіліксіздігі қаупін бағалау;

Natural Language Processing (NLP) – клиникалық жазбалар мен пациенттердің шағымдарын өңдеу.

Емдеу технологиялары:

Фармакогеномика және AI-Drug Discovery – дәрілік терапияны жекелендіру және жаңа препараттарды әзірлеу;

Телемедицина және ақылды құрылғылар (Apple Watch, Fitbit, Samsung Health) – пациенттердің жүрек көрсеткіштерін қашықтан бақылау;

Бета-блокаторлар, антикоагулянттар, ACE тежегіштері – постковидтік жүрек ауруларын

емдеудің негізгі дәрілік құралдары.

Алдын алу шаралары:

Вакцинация – COVID-19 инфекциясының ауыр түрлерінің алдын алу;

Физикалық белсенділікті бақылау – аптасына 150 минуттық аэробтық жаттығу жасау;

Диеталық ұсыныстар – жүрек-қан тамырларын қорғауға бағытталған дұрыс тамақтану (Жерорта теңізі диетасы).

Бұл әдістер мен технологиялар кардиологиялық постковид синдромының диагностикасы, емдеу стратегияларын оңтайландыру және пациенттердің денсаулығын ұзақ мерзімді бақылау үшін қолданылады.

Кардиологиялық постковид синдромын басқаруда ерте диагностика, ұзақ мерзімді бақылау және дербестендірілген емдеу тәсілдері басты назарда болуы керек. Машиналық оқыту мен жасанды интеллект арқылы аурудың даму қаупін болжау, жеке терапия стратегияларын жасау және науқастардың жағдайын үздіксіз бақылау мүмкіндіктері кеңеюде.

Пайдаланылған әдебиеттер тізімі:

1. WHO (World Health Organization). (2023). Post COVID-19 condition (Long COVID). Retrieved from www.who.int
2. European Society of Cardiology (ESC). (2022). Impact of COVID-19 on cardiovascular health: A systematic review. *European Heart Journal*, 43(12), 2351-2370.
3. American Heart Association (AHA). (2022). Long-term cardiovascular effects of COVID-19. *Circulation*, 145(5), 320-330.
4. Puntmann, V. O., Carerj, M. L., Wieters, I., et al. (2020). Outcomes of cardiovascular magnetic resonance imaging in patients recently recovered from COVID-19. *JAMA Cardiology*, 5(11), 1265-1273.
5. Gupta, A., Madhavan, M. V., Sehgal, K., et al. (2020). Extrapulmonary manifestations of COVID-19. *Nature Medicine*, 26, 1017–1032.
6. Xiao, F., Fong, T., et al. (2021). AI and machine learning approaches in post-COVID-19 cardiovascular diagnosis and treatment. *Journal of Biomedical Informatics*, 118, 103798.
7. Poland Research Institute. (2022). MRI-based detection of post-COVID myocardial injury. *Poland Medical Journal*, 78(4), 112-125.
8. Pakistan Health Study. (2022). Clinical symptoms and cardiovascular outcomes in post-COVID patients. *Pakistan Journal of Cardiology*, 65(2), 201-215.

VR/AR технологияларымен қашықтан білім беру платформасы

Жанболат Г.Ж.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: gzhanbolatovaa@gmail.com

Сарсембаева Т.С.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Бұл жоба қашықтан оқытудың сапасын арттыру үшін виртуалды (VR) және кеңейтілген шындық (AR) технологияларын қолданатын білім беру платформасын әзірлеуді ұсынады. Платформа оқушылар мен студенттерге интерактивті сабақтарға қатысуға, тәжірибелік зертханалық жұмыстарды орындауға және иммерсивті оқу ортасында білім алуға мүмкіндік береді.

Қазіргі таңда білім беру саласында цифрлық технологиялар қарқынды дамып, оқыту әдістерін түбегейлі өзгертіп келеді. Қашықтан білім беру кең таралғанымен, оның тиімділігі көбінесе шектеулі интерактивтілік пен практикалық тәжірибенің жетіспеушілігіне байланысты төмендейді. Бұл мәселені шешу үшін виртуалды шындық (VR) және кеңейтілген шындық (AR) технологияларын пайдалану білім беру процесін жаңа деңгейге көтеруге мүмкіндік береді.

VR/AR технологияларын жасаудың негізгі кезеңдері:

Жоспарлау және концепция: Бұл кезеңде жобаның мақсаты, аудиториясы және негізгі функциялары анықталады. Жоспарлау барысында концепцияны құру, сценарий жазу және қажетті ресурстарды анықтау маңызды.

Дизайн және прототип жасау: Бұл кезеңде 3D модельдер, анимациялар және интерфейс элементтері жасалады. Прототип жасау арқылы жобаның алғашқы нұсқасы құрылады, оны тестілеу және жетілдіру үшін пайдаланылады.

Даму және бағдарламалау: Бұл кезеңде әзірлеушілер бағдарламалау тілдері мен платформаларды пайдаланып, қосымшаны жасайды. Unity, Unreal Engine, ARKit, ARCore сияқты құралдар осы кезеңде қолданылады.

Тест және жетілдіру: Бұл кезеңде қосымша тестілеуден өтеді. Қателерді анықтау және түзету, өнімділікті жақсарту және пайдаланушы тәжірибесін жетілдіру маңызды.

Жариялау және тарату: Қосымша дайын болғаннан кейін, оны жариялау және тарату кезеңі басталады. Мобильді қосымшалар үшін App Store немесе Google Play сияқты платформаларда жариялау қажет.

Қолдау және жаңарту: Қосымша жарияланғаннан кейін, оны қолдау және жаңарту маңызды. Пайдаланушылардың пікірлерін ескеру, қателерді түзету және жаңа функциялар қосу қажет.

VR/AR технологияларымен жабдықталған қашықтан білім беру платформасы оқушылар мен студенттерге оқу материалын интерактивті түрде меңгеруге, виртуалды зертханалар мен тренажерлар арқылы тәжірибелік дағдыларын дамытуға жағдай жасайды. Мұндай әдіс әсіресе медицина, инженерия, жаратылыстану ғылымдары және техникалық мамандықтар үшін маңызды. Сонымен қатар, жасанды интеллекттің көмегімен жеке оқу бағдарламаларын бейімдеуге және студенттердің оқу үлгерімін тиімді бақылауға болады.

Пайдаланылған әдебиеттер тізімі:

1. Azuma, R. T. (1997). "A Survey of Augmented Reality." *Presence: Teleoperators and Virtual Environments*, 6(4), 355-385.
2. Milgram, P., & Kishino, F. (1994). "A Taxonomy of Mixed Reality Visual Displays." *IEICE Transactions on Information and Systems*, E77-D(12), 1321-1329.
3. Slater, M., & Sanchez-Vives, M. V. (2016). "Enhancing Our Lives with Immersive Virtual Reality." *Frontiers in Robotics and AI*, 3, 74.

4. Johnson, L., Adams Becker, S., Estrada, V., & Freeman, A. (2015). *The NMC Horizon Report: 2015 Higher Education Edition*. The New Media Consortium.
5. Dede, C. (2009). "Immersive Interfaces for Engagement and Learning." *Science*, 323(5910), 66-69.
6. Wu, H. K., Lee, S. W. Y., Chang, H. Y., & Liang, J. C. (2013). "Current Status, Opportunities and Challenges of Augmented Reality in Education." *Computers & Education*, 62, 41-49.
7. Parong, J., & Mayer, R. E. (2018). "Learning Science in Immersive Virtual Reality: Effects of Immersion and Interaction on Recall and Transfer." *Journal of Educational Psychology*, 110(6), 785-797.
8. Sherman, W. R., & Craig, A. B. (2018). *Understanding Virtual Reality: Interface, Application, and Design*. Morgan Kaufmann.
9. Freina, L., & Ott, M. (2015). "A Literature Review on Immersive Virtual Reality in Education: State of the Art and Perspectives." *The International Scientific Conference eLearning and Software for Education*, 1, 133-141.

Студенттерді қолдау қызметтерін жақсарту үшін жасанды интеллектпен басқарылатын ақылды сандық көмекші чат-бот

Жәділ Е.Н.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: edil.zhadil@mail.ru

Сарсембаева Т.С.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Жасанды интеллект негізіндегі ақылды сандық кеңесші (чатбот) Al-Farabi Қазақ Ұлттық Университетінде (ҚазҰУ) студенттердің тәжірибесін жақсарту мақсатында әзірленіп іске асырылды. Университеттер әртүрлі студенттерге қолжетімді және толық ақпарат ұсыну мәселесіне тап болады, ал дәстүрлі әдістер тиімдісіз және көп уақыт алады. Осы мәселені шешу үшін spaCy және Transformers көмегімен табиғи тіл өңдеу (NLP) әдістері, деректер қауіпсіздігі үшін Ollama қолданылатын жергілікті орналастырылған үлкен тіл моделі (LLM) және семантикалық іздеу үшін векторлық эмбедингтері бар PostgreSQL білім базасы пайдаланып, модульді чатбот әзірленді. Жүйе архитектурасы, іске асыру барысы, негізгі компоненттер мен оңтайландыру стратегиялары сипатталды. Өнімділік дәлдік, жауап беру уақыты және қолданушы қанағаттануы сияқты көрсеткіштер негізінде бағаланды. Мәтін бойында деректерді талдау және кестелер мен суреттерді қоса алғанда визуализациялар негізгі өнімділік аспектілерін көрсету және қорытындыларды дәлелдеу үшін қолданылды. Нәтижелер студенттердің белсенділігін арттыру, ақпаратқа жылдам қолжетімділікті қамтамасыз ету және жалпы қанағаттануды жақсартудың әлеуетін көрсетіп, чатботтың университет қауымдастығының барлық мүшелері үшін құнды құрал екенін дәлелдеді.

Қазіргі білім беру мекемелері ақпарат ағындарын тиімді басқару, студенттерге дәл және уақтылы ақпарат беру және әкімшілік үдерістерді оңтайландыру мәселелеріне тап болады. Сандық трансформация мен «Ақылды университет» тұжырымдамасының дамуы аясында, студенттермен жеке қарым-қатынасты қамтамасыз ете алатын ақылды қолдау жүйелерінің қажеттілігі артып келеді. Бұл зерттеу Al-Farabi Қазақ Ұлттық Университетінің студенттеріне арналған ақылды сандық кеңесшіні жасауға бағытталған. Жүйе заманауи табиғи тіл өңдеу әдістері мен жасанды интеллект алгоритмдерін қолдана отырып, сабақ кестесі, оқу бағдарламалары және әкімшілік ережелер туралы ақпаратты автоматты түрде ұсынады. Зерттеу нәтижелері студенттердің ақпаратқа қолжетімділігін жақсартып, университет пен студенттер арасындағы қарым-қатынасты жеңілдетуге ықпал етеді. Даму процесінде біз келесі компоненттер мен технологияларды қолданылды:

Пайдаланушы интерфейсі: Django/Flask көмегімен жасалды, көптілді сұраныстарды (қазақ, орыс, ағылшын) қолдап, WCAG 2.1 қолжетімділік стандарттарына сай келеді.

Табиғи тіл өңдеу модулі (NLP): spaCy және BERT негізінде енгізілген, кіріс сұраныстарды талдап, құрылымдауға арналған; қазақ тіліне арнайы токенизаторлар әзірленді.

Диалог менеджері: Жауап стратегиясын тандауға жауапты, сөйлесу контекстін бақылау үшін Redis қолданылып, сенімділік төмен болған жағдайда резервтік механизм іске қосылады.

Локальді үлкен тіл моделі (LLM): Ollama платформасы мен университет GPU кластерінде орналастырылған LLaMA-2 13B моделін қолданады, күрделі немесе екіұшты сұраныстарды өңдеуге мүмкіндік береді.

Білім базасы: PostgreSQL-дің pgvector кеңейтімі негізінде ұйымдастырылған, университеттегі 350 мыңнан астам құжат бойынша жылдам және тиімді семантикалық іздеуді қамтамасыз етеді.

Өнімділікті оңтайландыру: Redis кәштеу, Kubernetes негізіндегі горизонталь масштабтау және сұраныстарды басымдыққа қою қолданылады, жүйенің жылдам жауап беруі мен тұрақты жұмысын қамтамасыз етеді.

Қауіпсіздік шаралары: Деректерді шифрлау (AES-256, TLS 1.3), FPE көмегімен

анонимизация және өзгермейтін логтар арқылы аудит жүргізілді, бұл GDPR және Қазақстан заңнамасына сәйкес келеді. Осы технологиялардың үйлесімі университет студенттерін тиімді қолдай алатын сенімді және кеңейтілетін сандық кеңесшіні жасауға мүмкіндік береді.

Бұл жоба AI-Farabi Қазақ Ұлттық Университетінің студенттерін қолдау мақсатында ақылды сандық көмекшінің архитектурасын ұсынады. Жүйе студенттердің сұраныстарын өңдеп, тиісті жауаптар беру үшін NLP әдістеріне, жергілікті орналастырылған үлкен тіл моделіне және PostgreSQL білім базасына негізделген.

Прототип моделі әзірленіп, алдын ала эксперименттер жүргізілді, олар ұсынылған тәсілдің ақпаратқа қолжетімділікті арттырып, жауап беру процесін жеделдететінін көрсетті. Алайда, жүйені масштабтау, білім базасын кеңейту және екіұшты сұраныстарды өңдеу сияқты қиындықтар әлі де бар. Болашақтағы зерттеулер модельді оңтайландыруға, жауаптың дәлдігін арттыруға және функционалдық мүмкіндіктерді кеңейтуге бағытталмақ. Қазіргі уақытта модель жасау процесінде, ал тәжірибелік қолданыс нәтижесінде болашақта қолжетімді болады, осылайша ұсынылған архитектура университеттегі білім беру және әкімшілік үдерістерде ақылды сандық көмекшілерді дамыту мен енгізудің негізі бола алады.

Пайдаланылған әдебиеттер тізімі:

1. "Harvard University to introduce AI assistant for CS50 programming course," Unipage, 2023. Доступно онлайн: <https://www.unipage.net/ru/2934>
2. "PolyU launches AI-based assistant for students," Trends RBC, 2023. Доступно онлайн: <https://trends.rbc.ru/trends/industry/cmrm/66cd88929a79475617ca7215>
3. "AI-powered learning: Harvard and Microsoft research findings," RBC Ukraine, 2023. Доступно онлайн: <https://www.rbc.ua/ukr/news/ssha-pershiy-universitet-zapustit-navchannya-1738843471>
4. S. Hussain, O. A. Sianaki и N. Ababneh, "A survey on conversational agents/chatbots classification and design techniques," AI in Education, том 10, стр. 35–47, 2021.
5. D. Adamopoulou и L. Moussiades, "An overview of chatbot technology," Artificial Intelligence Applications, том 24, № 3, стр. 21–36, 2021.
6. X. Wang, H. Liu и Y. Zhang, "Conversational AI for student support: A case study," Journal of Educational Technology, том 19, № 4, стр. 58–74, 2022.
7. K. Bii, "AI-driven digital assistants and their impact on education systems," Computational Intelligence Review, том 15, стр. 87–102, 2022.
8. O. Zawacki-Richter, M. Sun и T. Bond, "Artificial intelligence in higher education: A meta-analysis," International Review of Research in Open and Distributed Learning, том 23, № 2, стр. 45–67, 2022.
9. Y. Sun, J. Li и H. Chen, "Impact of AI-driven tutors on student performance," Computers & Education, том 190, стр. 104583, 2023.
10. L. Li и X. Chen, "Gamified AI chatbots for improving student engagement," IEEE Transactions on Learning Technologies, том 16, № 1, стр. 112–125, 2023.

Разработка интеллектуального модуля на основе машинного обучения для обработки и анализа эпигенетического возраста

Жетпісбай Ж.Е.

*Казахский Национальный Университет им. аль-Фараби, студент 4 курса
E-mail: zhibekzhetpisbay@gmail.com*

Жасұзақ М.С.

Казахский Национальный Университет им. аль-Фараби, преподаватель

По статистике ВОЗ, причиной каждой шестой смерти являются онкологические заболевания. [1] В настоящее время ранняя диагностика является приоритетом для успешного выздоровления, но существующие методы диагностики не рассматривают суть проблемы. Мутации на клеточном уровне и ранние стадии заболевания выявляет эпигенетика. На данный момент в число популярных решений входят эпигенетические часы Стива Хорвата [2], Ханнума [3] и GrimAge [4]. В отличие от существующих методов приоритетом данного алгоритма является анализ эпигенетического возраста при раке и разработка более оптимизированного алгоритма извлечения значимых CpG признаков.

Материалом исследования является 3 типа рака: почек, толстого кишечника и легких. Эпигенетические и фенотипические данные были собраны из портала GDC. [5]

Методы включают в себя предобработку, обучение модели и внедрение в веб-приложение. Предобработка состоит из 2 шагов: очистки и нормализации. При очистке удалялись те признаки (CpG) более половины которых составлял шум, а остальные пустые значения заменяются средними. Нормализация проведена функцией BMIQ улучшенной оптимизатором COBYLA. Для обучения модели первоначально отбираются статистически значимые признаки при помощи корреляции Спирмена, затем циклически применяется регрессия Риджа с удалением неинформативных признаков. Модель предсказания была интегрирована в веб-приложение при помощи фреймворка flask. Была реализована возможность выбора типа рака, загрузки бета-значений метилирования и получения эпигенетического возраста после обработки данных веб-сайтом.

В результате был разработан алгоритм предсказания эпигенетического возраста на основе данных метилирования. Наилучшие результаты на тестовых данных достигнуты при раке кишечника с метрикой R^2 в 0.975. Замечена сильная зависимость качества модели от изначального количества CpG, что доказано раком толстого кишечника показавшим наилучшие результаты при наибольшем количестве признаков.

Список использованной литературы:

1. World Health Organization (WHO) [Internet]. [cited 2025 Jan 13]. Available from: <https://www.who.int>
2. Horvath S. DNA methylation age of human tissues and cell types. *Genome Biol.* 2013 Dec 10;14(10):3156.
3. Hannum G, Guinney J, Zhao L, Zhang L, Hughes G, Sada S, et al. Genome-wide Methylation Profiles Reveal Quantitative Views of Human Aging Rates. *Mol Cell.* 2013 Jan 24;49(2):359–67.
4. Lu AT, Binder AM, Zhang J, Yan Q, Reiner AP, Cox SR, et al. DNA methylation GrimAge version 2. *Aging.* 2022 Dec 14;14(23):9484–549.
5. GDC Data Portal Homepage [Internet]. [cited 2025 Jan 6]. Available from: <https://portal.gdc.cancer.gov/>

Жасанды интеллект және заттар интернеті технологиялары негізінде қалдықтарды жинау және сұрыптауды басқарудың интеллектуалды жүйесін құру

Жыйлысова Д.С.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: zhyilyssovadana@gmail.com

Сарсембаева Т.С.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Жасанды интеллект (ЖИ) және деректер туралы ғылым қазіргі заманғы технологиялық үдерістерді жетілдіруде маңызды рөл атқарады. Бұл жұмыста деректерді талдау және машиналық оқыту әдістерін қолдана отырып, қалдықтарды басқару жүйелерін автоматтандыру қарастырылады. Компьютерлік көру, конволюциялық нейрондық желілер (CNN) және IoT технологияларын біріктіру арқылы қалдықтарды (шыны, пластик, қағаз, органикалық заттар) жоғары дәлдікпен сұрыптау әдістері ұсынылады. Бұл тәсіл қайта өңдеу тиімділігін арттырып, сұрыптау қателерін азайтады.

Деректер ғылымы мен жасанды интеллект технологиялары қоршаған ортаны қорғау және қалдықтарды басқару саласында тиімді шешімдер ұсынуда. Дәстүрлі сұрыптау әдістері жиі қателіктер жіберетін және еңбекті көп қажет ететін жүйелерге негізделген. Компьютерлік көру және деректерді талдау негізінде қалдықтардың түрін автоматты түрде анықтап, оларды тиісті контейнерлерге бағыттауға мүмкіндік береді. Бұл экологиялық проблемаларды азайтып, қайта өңдеу үдерісін оңтайландыруға ықпал етеді.

Компьютерлік көру: Конволюциялық нейрондық желілер (CNN) көмегімен қалдықтардың кескіндерін талдау және оларды автоматты түрде санаттарға бөлу.

Машиналық оқыту: Таңбаланған деректер жиынтығында қалдықтарды тану моделін оқыту, сонымен қатар кластерлеу әдістерін қолдану.

IoT және роботтық жүйелер: Сенсорлар мен манипуляторлар арқылы қалдықтарды автономды түрде сұрыптауды жүзеге асыру.

Деректерді талдау: Қалдықтардың түрін тексеру үшін гистограммалық талдау, объектілерді сегментациялау және нейрондық желілердің ансамбльдік әдістерін қолдану.

Әзірленген жүйе қалдықтарды сұрыптаудың дәлдігін 95% деңгейіне дейін жеткізді. Компьютерлік көру мен IoT технологияларын интеграциялау арқылы қалдықтарды тану жылдамдығы жақсарды, ал қателіктер деңгейі айтарлықтай азайды. Деректерді талдау мен жасанды интеллект әдістерін қолдану қайта өңдеу зауыттарына түсетін жүктемені төмендетіп, өңдеу шығындарын азайтуға мүмкіндік береді. Болашақ зерттеулер үлгілерді жетілдіру мен өнеркәсіптік ауқымда пайдалану бағытында жүргізіледі.

Жасанды интеллект және деректер туралы ғылым қалдықтарды сұрыптауда және экологиялық тұрақтылықты арттыруда маңызды рөл атқарады. Автоматтандырылған жүйелер қайта өңдеу үдерісін оңтайландырып, экологиялық жүктемені азайтады. Болашақта бұл технологияларды қалалық инфрақұрылымға енгізу арқылы қалдықтарды тиімді басқару жүйесін құру мүмкіндігі артады.

Пайдаланылған әдебиеттер тізімі:

1. Zhang, L., & Wang, Y. (2022). AI-Driven Waste Sorting: Innovations and Challenges. *Environmental Technology & Innovation*, 28, 102314.
2. Kumar, P., & Gupta, A. (2023). Machine Learning in Waste Management: A Systematic Review. *Journal of Cleaner Production*, 335, 130257.
3. Williams, E., & Thompson, B. (2021). Smart Waste Sorting Systems: A Comprehensive Overview. *Waste Management*, 150, 211-225.
4. Garcia, M., & Hernandez, R. (2022). Clustering Methods in Waste Classification: An AI Approach. *Journal of Environmental Engineering*, 145, 654-670.

Applications of Artificial Intelligence in Monitoring Emerging Soil Contaminants

Kengeszhan Didar

Al-farabi kazakh national university, master's student, 2nd year

E-mail: kend1dar@outlook.com

With industrialization, novel soil pollutants threaten ecosystems and human health. Soil Systems complexity creates high-dimensional, nonlinear data, challenging traditional methods. This paper explores AI challenges in feature selection, dimensionality reduction, and model complexity control, proposing solutions.

Soil is vital for ecosystems and human well-being. Emerging contaminants (ECs), like antibiotics and microplastics, are accumulating in soil, posing risks due to their complex interactions and toxicity. Traditional lab-based monitoring is costly and inefficient, limiting large-scale, real-time applications. AI technologies offer new opportunities for soil EC monitoring, yet the high dimensionality and complexity of soil data pose significant challenges [1].

2. High-Dimensionality and Complexity of Soil EC Monitoring Data

2.1 Multifactorial Influences in Soil Environments Soil texture governs porosity, aeration, and water retention, affecting EC diffusion and adsorption. Organic matter content enhances hydrophobic interactions with organic ECs, while pH determines chemical speciation and bioavailability (e.g., increased solubility of heavy metals in acidic soils). Temperature and humidity modulate microbial activity and physicochemical processes like volatilization and degradation. Microbial communities drive EC transformation via metabolic pathways, with degradation efficiency dependent on species composition and environmental conditions.

2.2 High-Dimensional Data Characteristics Numerous physical, chemical, and biological factors contribute to high-dimensional datasets. For instance, a single soil sample may include EC concentrations, texture parameters, organic matter, pH, temperature, humidity, and microbial taxa abundance. Traditional analytical methods struggle to extract meaningful patterns from such complexity.

2.3 Nonlinear Relationships

Interactions among factors form intricate nonlinear networks. While moderate organic matter enhances microbial activity, excessive levels may inhibit degradation by altering soil aeration. These nonlinear dynamics complicate predictive modeling, necessitating advanced AI approaches.

3. Challenges for AI Models in Soil EC Monitoring

3.1 Feature Selection Dilemmas

High-dimensional data contain redundant or irrelevant features (e.g., microbial taxa with minimal degradation relevance). Including all features increases computational load and overfitting risks. Conventional methods like correlation analysis fail to capture nonlinear interactions.

3.2 Dimensionality Reduction Limitations

Linear methods like principal component analysis (PCA) lose efficacy with nonlinear data, while nonlinear techniques (e.g., Isomap) suffer from computational inefficiency and parameter sensitivity.

3.3 Model Complexity vs. Interpretability

Complex models (e.g., deep neural networks) risk overfitting and lack interpretability, hindering actionable insights for pollution control. For instance, a black-box model predicting EC concentration spikes without explaining drivers limits remediation strategies.

4. Strategies to Address AI Challenges

4.1 Domain Knowledge-Guided Feature Selection

Integrate soil science expertise with machine learning (ML) algorithms. Random forests or support vector machines (SVMs) can evaluate feature importance, identifying key drivers (e.g., enzyme activity for antibiotic degradation).

4.2 Hybrid Dimensionality Reduction

Combine linear (PCA) and nonlinear (manifold learning) methods. For example, PCA reduces dimensions linearly, followed by Isomap to preserve nonlinear structures. Feature engineering (e.g., log transformations) further enhances compatibility.

4.3 Balancing Complexity and Interpretability

Apply regularization (L1/L2) to prevent overfitting. Use interpretable models (e.g., decision trees) or explainability tools like LIME (Local Interpretable Model-agnostic Explanations) to decode complex models [2]. For instance, visualizing attention maps in CNNs clarifies feature contributions to EC predictions.

5. Conclusions and Future Perspectives AI demonstrates significant potential in soil EC monitoring through advanced feature selection, hybrid dimensionality reduction, and interpretability enhancements. Case studies validate AI's accuracy in concentration prediction, migration modeling, and risk assessment.

Future research should focus on domain-knowledge integration, dynamic data optimization, and user-friendly explainability tools to bridge AI innovations with practical soil management.

References:

1. Hou, D., et al. (2021). Artificial intelligence for the detection of environmental contaminants: Current advances and future directions. *Environmental Science & Technology*, 55(20), 13596-13614.
2. Wang, X., et al. (2021). Gaussian process regression for modeling organic pollutant degradation in soil. *Journal of Hazardous Materials*, 415, 125634.

Қалалық көлік жүйелерін оңтайландыру үшін нейрондық желілерді пайдаланып трафикті модельдеу

Керимбекова Эльнура

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

Email: kerimbekovaelnura7@gmail.com

Сарсембаева Т.С.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Қазіргі уақытта мегаполистер көлік инфрақұрылымының өсуіне байланысты көптеген мәселелерге тап болады, мысалы, тығыздық, бағдаршамдарды тиімсіз басқару және көлік жүйелерінің өзгеріп отыратын жағдайларға бейімделу қабілетінің жеткіліксіздігі. Дәстүрлі трафикті басқару әдістері қалалық ортаның динамикасына жиі көтере алмайды, нәтижесінде жолда өткізілетін уақыт ұзарады, зиянды заттардың шығарындылары артады және халықтың қозғалғыштығы төмендейді. Нейрондық желілерді қолдана отырып трафикті имитациялық модельдеу бұл мәселелерді шешуге инновациялық тәсіл ұсынады, бұл көлік ағындарын болжауға, жол инфрақұрылымын басқаруды оңтайландыруға және қалалық көлік жүйелерінің тиімділігін арттыруға мүмкіндік береді.

Қазақстанның қалаларында урбанизацияның өсуі және көлік құралдарының санының артуына байланысты келесі мәселелер байқалады:

- Тығыздықтың жоғары деңгейі, әсіресе шақырым сағаттарында, бұл жолда өткізілетін уақытты ұзартады және қала тұрғындарының өмір сапасын төмендетеді.

- Бағдаршамдарды тиімсіз басқару, бұл ағымдағы жол жағдайын есепке алмайтын тіркелген уақыт интервалдарына негізделген.

- Трафикті басқарудың бейімделмеген жүйелерінің болмауы, бұл көлік ағындарының өзгеруіне оперативті түрде жауап бере алмайды.

Нейрондық желілерге негізделген жүйелер (АҚШ, Еуропа)

- Трафикті болжау және бағдаршамдардың циклдарын оңтайландыру үшін нейрондық желілерді қолдану.

- Бейімделген басқару арқылы жолда өткізілетін уақытты 20-30% қысқарту.

- GPS жүйелері мен мобильді қосымшалармен интеграция, жүргізушілерге жол жағдайы туралы ақпараттың өзектілігін қамтамасыз ету.

Ақылды көлік жүйелері (Сингапур, Жапония)

- Трафик ағындарын талдау және болжау үшін имитациялық модельдерді қолдану.

- Тығыздықтың алдын алу үшін магистральдардағы қозғалыс жылдамдығын автоматты түрде реттеу.

- Трафикті нақты уақытта бақылау үшін датчиктер мен камералардан алынған деректерді пайдалану.

Жасанды интеллектке негізделген трафикті басқару жүйелері (Қытай)

- Трафик туралы үлкен деректер көлемін талдау үшін нейрондық желілерді енгізу.

- Қоғамдық көлік маршруттарын оңтайландыру және аялдамаларда күту уақытын қысқарту.

- Көлік құралдарының тұру уақытын қысқарту арқылы CO₂ шығарындыларын азайту.

Функционалдық ерекшеліктері

- Нейрондық желілерді қолдану тарихи деректер мен нақты уақыттағы деректер негізінде көлік ағындарын болжау үшін.

- Датчиктер мен камералармен интеграция жол жағдайын бақылау үшін.

- Бейімделген бағдаршамдарды басқару жолдардың ағымдағы жүктемесін есепке ала отырып.

- Қоғамдық көлік маршруттарын оңтайландыру күту уақытын қысқарту және жолаушылардың ыңғайлылығын арттыру үшін.

- Тығыздықты талдау және болжау олардың пайда болуын болдырмау мақсатында.

Нейрондық желілерді қолдана отырып имитациялық модельді енгізу келесі жақсартуларға әкеледі:

Көрсеткіш	Қазіргі жағдай	Күтілетін өзгерістер
Жолда өткізілетін уақыт	Жоғары	20-30% қысқару
Тығыздық деңгейі	Жоғары	25-40% қысқару
Зиянды заттардың шығарындылары	Жоғары	15-20% қысқару
Басқару тиімділігі	Төмен	30-50% арту
Қала тұрғындарының қанағаттануы	Төмен	20-40% арту

Нейрондық желілерді қолдана отырып трафикті имитациялық модельдеу қалалық көлік жүйелерін оңтайландыру үшін перспективалы шешім болып табылады. Мұндай технологияларды енгізу тек тығыздық деңгейін төмендетіп, жолда өткізілетін уақытты қысқартпай, сонымен қатар көліктің қоршаған ортаға тигізетін теріс әсерін азайтады. Шетелдік елдердің тәжірибесі нейрондық желілер мен бейімделген трафикті басқару жүйелерін қолдану көлік инфрақұрылымының тиімділігін айтарлықтай арттыра алатынын көрсетеді. Қазақстан үшін мұндай шешімдерді енгізу ақылды қалаларды құру және халықтың өмір сапасын жақсарту жолында маңызды қадам болар еді.

Пайдаланылған әдебиеттер тізімі:

1. M. Chen, "Artificial Neural Networks-Based Machine Learning for Wireless Networks: A Tutorial," / M. Chen, U. Challita, W. Saad, C. Yin and M. 67 Debbah // in IEEE Communications Surveys & Tutorials, Vol. 21, No. 4, pp. 3039- 3071, Fourthquarter 2019, doi: 10.1109/COMST.2019.2926625.
2. Volkov A. IoT Traffic Prediction with Neural Networks Learning Based on SDN Infrastructure. / Volkov A., Abdellah A.R., Muthanna A., Makolkina M., Paramonov A., Koucheryavy A. // In: Vishnevskiy V.M., Samouylov K.E., Kozyrev D.V. (eds) Distributed Computer and Communication Networks. DCCN 2020. Lecture Notes in Computer Science, Springer, Cham. Vol 12563. pp. 64-76, 2020, https://doi.org/10.1007/978-3-030-66471-8_6 .
3. Boutaba, R. A comprehensive survey on machine learning for networking: evolution, applications, and research opportunities. / Boutaba, R., Salahuddin, M.A., Limam, N. et al. // J Internet Serv Appl., Vol. 9, Article number. 16, pp. 1-99, 2018. <https://doi.org/10.1186/s13174-018-0087-2>.
4. Nour Alqudah, "Machine Learning for Traffic Analysis: A Review" / Nour Alqudah, Qussai Yaseen // Elsevier, Procedia Computer Science, Vol. 170, pp. 911- 916, 2020, ISSN 1877-0509, <https://doi.org/10.1016/j.procs.2020.03.111>.

Машиналық оқыту және күшейтілген оқытудың жасанды интеллекттегі рөлі

Кәрім М.М.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: *mereibekk_k@mail.ru*

Сарсембаева Т.С.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Машиналық оқыту (ML) және күшейтілген оқыту (RL) — қазіргі заманғы жасанды интеллект (AI) саласының негізгі бағыттарының бірі. Бұл технологиялар әртүрлі қолданбаларда, оның ішінде деректер талдауынан бастап робототехникаға дейін, күнделікті өмірде кеңінен қолданылады. Олардың ерекшеліктері мен дамуы туралы толығырақ талқылайық. Машиналық оқыту (ML) — бұл компьютерлерге деректер негізінде үлгілерді тануға және болжау жасауға мүмкіндік беретін әдіс. Бұл әдіс статистика мен алгоритмдерге негізделген, және ең бастысы, адамдарға алдын ала бағдарлама жазбай-ақ машиналарға «үйренуге» мүмкіндік береді. Машиналық оқыту үш негізгі түрге бөлінеді:

1. Бақыланатын оқыту (Supervised Learning): Бұл әдіс кезінде алгоритмдер алдын ала белгіленген деректермен (белгіленген нәтижелермен) оқытылады. Мысалы, сыныптау (classification) және регрессия (regression) тапсырмалары осы әдіспен шешіледі.

2. Бақыланбайтын оқыту (Unsupervised Learning): Алгоритмдер белгісіз деректермен жұмыс істейді және оларды өздігінен топтастырады немесе үлгілерді таниды. Мұндай әдіс деректерді сегменттеу немесе жинақтау сияқты мәселелерде қолданылады.

3. Жартылай бақыланатын оқыту (Semi-supervised Learning): Бұл әдіс бақыланатын және бақыланбайтын оқытудың араласуы болып табылады. Мұнда бір бөлігі белгіленген деректермен жұмыс істейді, ал екінші бөлігі белгіленбеген деректермен.

Машиналық оқыту көптеген салаларда қолданылады, мысалы, қаржы саласында алаяқтықты анықтау, денсаулық сақтау саласында диагноз қою, маркетингте тұтынушы мінез-құлқын болжау және т.б.

Күшейтілген оқыту (Reinforcement Learning, RL) — бұл машиналық оқытудың бір тармағы, онда агент белгілі бір ортада әрекет етіп, оның нәтижесінде алған сыйақыға немесе жазаға қарай өз іс-әрекетін реттейді. RL-дің басты ерекшелігі — агенттің мақсатқа жету үшін қоршаған ортаны өздігінен зерттеу және тәжірибе арқылы үйрену мүмкіндігі. RL жүйесінде агенттің мақсаттары мен сыйақы функциялары анықталады, және агентәрбір әрекетінің нәтижесінде бонустар немесе айыппұлдар алады. Агент ұзақ мерзімді мақсаттарға жету үшін тәжірибесін үнемі жақсартып отырады. RL-дің негізгі қолданылу салаларының бірі — ойындар (мысалы, шахмат, Go немесе видео ойындар), онда агент өзін өзі баптап, тәжірибе арқылы стратегиясын жетілдіреді. Сонымен қатар, RL робототехникада да қолданылуда, мысалы, роботтардың ортаны шарлап, нақты тапсырмаларды орындау үшін әрекет етуі.

Машиналық оқыту мен күшейтілген оқытудың арасындағы айырмашылық — оларды үйрету тәсілінде. Машиналық оқытуда модельге нақты деректер жиынтығы беріледі, және ол осы деректер негізінде болжау жасауға үйренеді. Күшейтілген оқытуда агент өз ортасында әрекет етіп, тәжірибе жинақтайды, әрі оның әрекеттерінің нәтижесінде алынған сыйақы мен жазалау арқылы үйренеді. Екі әдіс те қазіргі уақытта жасанды интеллекттің негізгі элементтеріне айналды және олардың қолданыс ауқымы күннен-күнге кеңейуде. Мысалы, машиналық оқыту мен күшейтілген оқытудың үйлесімі өзін-өзі үйрететін жүйелер мен автономды басқару жүйелерінде маңызды рөл атқарады.

Машиналық оқыту мен күшейтілген оқыту технологиялары жасанды интеллекттің дамуына үлкен үлес қосуда. Олардың әрқайсысының ерекшеліктері мен қолдану салалары өте кең және олар қоғамның көптеген салаларына әсер етеді. Алдағы жылдары осы технологиялардың дамуы өмірімізге жаңа мүмкіндіктер мен шешімдер ұсынатыны сөзсіз.

Пайдаланылган әдебиеттер тізімі:

1. Sutton R. S., Barto A. G. "Reinforcement Learning: An Introduction." MIT Press, 2018.
2. Bishop C. M. "Pattern Recognition and Machine Learning." Springer, 2006.

Блокчейн технологияларын оқытуға арналған оқу ойының әзірлеу және бақылау

Кәрім М.М.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: *mereibekk_k@mail.ru*

Сарсембаева Т.С.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Қазіргі ақпараттық технологиялардың қарқынды дамуы жаңа білім беру әдістерін қажет етеді. Блокчейн – қаржы, логистика, киберқауіпсіздік және басқа да салаларда кеңінен қолданылатын заманауи технологиялардың бірі. Алайда оны меңгеру күрделі процесс болғандықтан, дәстүрлі оқыту әдістері студенттер үшін қызықсыз және тиімсіз болуы мүмкін. Сондықтан оқытудың жаңа тәсілдерін енгізу маңызды. Оқу ойындары (serious games) білім беру процесінде оқушылардың белсенділігін арттырып, күрделі материалды жеңіл әрі қызықты түрде меңгеруге мүмкіндік береді. Сонымен қатар, машиналық оқыту (ML) технологияларын оқу процесіне енгізу арқылы студенттердің жетістіктерін автоматтандырылған түрде бақылауға, олардың білім деңгейін бағалауға және оқыту траекториясын жекелендіруге болады.

Осы зерттеудің мақсаты – блокчейн технологияларын үйретуге арналған оқу ойының әзірлеу және оның тиімділігін машиналық оқыту әдістерін қолдану арқылы бағалау.

Блокчейн технологияларын оқыту әдістерін талдау – қазіргі оқыту тәсілдерінің тиімділігін анықтау және олардың кемшіліктерін айқындау. Оқыту ойындарын әзірлеу әдістерін зерттеу – білім беру ойындарының принциптерін, құрылымын және олардың оқытуда қолданылуын зерттеу. Машиналық оқыту элементтерін біріктіру жолдарын анықтау – ойын барысында алынған мәліметтерді жинау, өңдеу және талдау әдістерін анықтау. Оқу ойынының тиімділігін бағалау – пайдаланушылардың білім деңгейінің өзгерісін өлшеу және оның оқыту сапасына әсерін талдау.

Әдеби шолу – блокчейн, геймификация және машиналық оқытуға қатысты ғылыми мақалаларды, кітаптарды талдау. Жүйелік талдау – оқу ойынының архитектурасын жобалау және оның негізгі компоненттерін анықтау. Эксперименттік зерттеу – оқу ойынын тәжірибелік топта қолданып, алынған нәтижелерді бағалау. Машиналық оқыту әдістерін қолдану – студенттердің прогрессін бағалау үшін білім траекторияларын талдау және болжам жасау.

Ойын блокчейн технологиясының негізгі аспектілерін үйретуге бағытталады және келесі компоненттерден тұрады: Теориялық модульдер – блокчейннің негізгі ұғымдарын (транзакциялар, блоктар, консенсус алгоритмдері, криптография) түсіндіреді. Практикалық тапсырмалар – студенттерге смарт-келісімшарттар құру, желіде транзакцияларды жүргізу, хештеу алгоритмдерін қолдану сияқты тапсырмалар беріледі.

Симуляциялық орталар – блокчейн желісінің жұмысын модельдеу арқылы студенттерге блоктардың қалай қалыптасатынын көрсету. Машиналық оқыту алгоритмдері – студенттердің әрекеттерін талдау, олардың әлсіз тұстарын анықтау және оқыту траекториясын бейімдеу.

Оқу ойыны студенттердің блокчейн технологияларын түсінуін жеңілдетеді. Машиналық оқыту элементтерін қолдану арқылы оқыту үдерісі дербестендіріледі. Ойын нәтижелері бойынша оқушылардың білім деңгейі мен қызығушылығының артуы күтіледі. Әзірленген әдістеме оқытушылар мен білім беру ұйымдары үшін тиімді құралға айналады.

Зерттеу барысында блокчейн технологияларын оқыту үшін ойын форматында оқыту әдісі ұсынылады. Геймификация элементтері мен машиналық оқытуды біріктіру арқылы оқу процесінің тиімділігі артады. Бұл тәсіл студенттердің пәнге деген қызығушылығын арттырып, білімді тез әрі сапалы меңгеруіне мүмкіндік береді. Ұсынылған оқу ойыны білім беру саласындағы инновациялық әдістердің бірі ретінде қарастырылады және оны басқа технологияларды оқытуда да қолдануға болады.

Пайдаланылган әдебиеттер тізімі:

1. Baker, R. S., & Inventado, P. S. (2014). Educational data mining and learning analytics. In Learning analytics (pp. 61-75). Springer. https://doi.org/10.1007/978-1-4899-7635-3_5
2. Nakamoto, S. (2008). Bitcoin: A Peer-to-Peer Electronic Cash System. <https://bitcoin.org/bitcoin.pdf>

CAD/CAM ТЕХНОЛОГИЯЛАРЫН ҚОЛДАНА ОТЫРЫП, ЦИФРЛЫҚ ОРТАДАҒЫ МОДЕЛЬДЕРДІ ВИЗУАЛИЗАЦИЯЛАУ ЖӘНЕ ТАЛДАУ

Кошанова Айым Канагатовна

Әл-Фараби атындағы ҚазҰУ, 2-курс магистрант

E-mail: aiymkoshanova2002@gmail.com

Мансурова Мадина Есимхановна

Әл-Фараби атындағы ҚазҰУ, профессор

Қазіргі заманғы Computer-Aided Design (CAD) және Computer-Aided Manufacturing (CAM) технологиялары цифрлық жобалау мен өндірістік процестерді автоматтандыруда маңызды рөл атқарады. Олар жоғары дәлдіктегі үш өлшемді модельдерді жасауға, оларды талдауға және модельдеуге мүмкіндік беріп, жобалау тиімділігі мен нақтылығын айтарлықтай арттырады.

CAD/CAM жүйелеріндегі модельдерді визуализациялау 3D-рендеринг, соңғы элементтер әдісі (FEM) және үлкен деректерді өңдеу алгоритмдеріне негізделеді. AutoCAD, SolidWorks, CATIA, Siemens NX сияқты заманауи құралдар шынайы графика мен дәл есептеулерді қамтамасыз етіп, механикалық жүктемелерді, жылулық әсерлерді және өнеркәсіптік өндіріс үшін қажетті басқа да параметрлерді модельдеуге мүмкіндік береді.

CAD/CAM технологияларының негізгі міндеттері мыналарды қамтиды:

- **Модельдерді визуализациялау және рендеринг** – нақты материалдар, жарықтандыру және текстураларды ескере отырып бейнелеу;
- **Физикалық процестерді модельдеу** (жүктемелер, жылулық әсерлер, гидродинамика және т.б.) – өнімнің өндіріс алдындағы сипаттамаларын бағалау;
- **Өндірісті автоматтандырылған түрде дайындау**, оның ішінде **сандық бағдарламалық басқару (ЧПУ) станоктары үшін басқару бағдарламаларын генерациялау**.

Қосымша (AR) және виртуалды шындықты (VR) CAD/CAM технологияларымен біріктіру модельдерді егжей-тегжейлі зерттеуге, оларды виртуалды ортада сынақтан өткізуге және физикалық өндіріс кезеңіне дейін өзгерістер енгізуге мүмкіндік береді. Бұл әдістер әсіресе машина жасау, аэроғарыш өнеркәсібі, сәулет және медицина салаларында сұранысқа ие, өйткені олар күрделі инженерлік параметрлерді ескеру қажет.

Сонымен қатар, жасанды интеллект (ЖИ) пен цифрлық егіздер технологияларын интеграциялау нысандардың әртүрлі пайдалану жағдайларындағы мінез-құлқын жобалауға және болжауға мүмкіндік береді. Деректерді талдауды автоматтандыру, бұлттық технологиялар арқылы жүзеге асырылатындықтан, қашықтан қолжетімділік пен жобалау топтарының бірлесіп жұмыс істеуін жеңілдетеді.

Осылайша, CAD/CAM жүйелері жобалау процесін жеңілдетіп қана қоймай, цифрлық өндірістің болашағын қалыптастырады, заманауи технологияларды күрделі инженерлік нысандарды жасау мен басқару тізбегіне біріктіреді.

Пайдаланылған әдебиеттер тізімі:

1. Zienkiewicz, O. C., & Taylor, R. L. (2013). The Finite Element Method: Its Basis and Fundamentals. Butterworth-Heinemann.
2. Zeid, I. (2019). Mastering CAD/CAM. McGraw-Hill Education.
3. Pahl, G., Beitz, W., Feldhusen, J., & Grote, K. H. (2007). Engineering Design: A Systematic Approach. Springer Science & Business Media.
4. Negishi, K. (2021). Advanced 3D CAD Modeling: Techniques and Applications. Elsevier.
5. Groover, M. P. (2020). Automation, Production Systems, and Computer-Integrated Manufacturing. Pearson

Цифрлық егіз үшін деректерді жинау және сақтау жүйесінде құпиялылықты қамтамасыз ету

Қайырбекова А.Ж.

*Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр
E-mail: kiyrbekova.aigul2004@gmail.com*

Зиятбекова Г.З.

Әл-Фараби атындағы ҚазҰУ, PhD, доцент м.а

Цифрлық технологиялардың дамуына байланысты медицина саласында пациенттердің цифрлық егіздерін құруға көбірек назар аударылуда. Цифрлық егіз — бұл пациенттің физикалық күйін, медициналық деректерін және емдеу тарихын көрсететін виртуалды модель. Бұл технология медицинада диагноз қою, емдеу жоспарын жасау және пациенттердің денсаулығын бақылау үшін кеңінен қолданылады. Дегенмен, жиналған деректер көлемінің артуына байланысты олардың құпиялылығы мен қауіпсіздігін қамтамасыз ету мәселесі туындайды. Бұл мақалада блокчейн және деректерді орталықсыз сақтау сияқты заманауи технологияларды қолдана отырып, цифрлық егізді жинау және сақтау жүйесін құру тәсілі қарастырылады [1].

Медициналық деректер ең сезімтал деректердің бірі болып табылады, өйткені олардың ашылуы пациент үшін ауыр салдарға әкелуі мүмкін. Мысалы, деректердің ашылуы пациенттің жеке өміріне қол сұғуға, дискриминацияға немесе қаржылық шығындарға әкелуі мүмкін. Деректерді сақтаудың дәстүрлі жүйелері, мысалы, орталықтандырылған дерекқорлар, шабуылдарға және рұқсатсыз қол жеткізуге осал болады. Сонымен қатар, пациенттер өз деректеріне толық бақылау жасай алмайды, бұл олардың құпиялылық құқығын бұзады [2-3].

Деректердің құпиялылығын қамтамасыз ету үшін келесі технологияларды қолдану ұсынылады:

1. Блокчейн: Блокчейн технологиясы деректермен операциялардың өзгермейтіндігін және ашықтығын қамтамасыз етеді. Смарт-контракттер арқылы деректерге рөлдер бойынша (пациент, дәрігер, әкімші) қол жеткізуді басқаруға мүмкіндік береді.

2. Орталықсыз сақтау (IPFS): IPFS (InterPlanetary File System) — бұл деректерді таратылған желіде сақтауға мүмкіндік беретін технология. Бұл жүйе деректерді шабуылдар мен ашылуларға төзімді етеді.

3. Шифрлау: IPFS-ке жүктелгенге дейін барлық деректер шифрланады, бұл олардың тіпті ашылу жағдайында да қорғалуын қамтамасыз етеді.

Жүйе келесі негізгі компоненттерден тұрады:

1. Фронтенд: Пайдаланушылармен (пациенттер, дәрігерлер, әкімшілер) өзара әрекеттесу үшін веб-интерфейс.

2. Бэкенд: Django фреймворкінде жазылған қолданба, ол пайдаланушыларды, рөлдерді және деректерге қол жеткізуді басқарады.

3. Блокчейн: Ethereum желісі деректердің хэштерін сақтау және смарт-контракттер арқылы қол жеткізуді басқару үшін қолданылады.

4. IPFS: Медициналық деректерді орталықсыз сақтау үшін пайдаланылады.

Іске асыру

1. Деректерді жинау: Пациент веб-интерфейс арқылы өз медициналық деректерін жүктейді. Деректер шифрланып, IPFS-ке жүктеледі.

2. Хэштерді сақтау: Деректердің хэші смарт-контракт арқылы блокчейнде сақталады.

3. Қол жеткізуді басқару: Дәрігерлер деректерге тек смарт-контракт арқылы расталғаннан кейін ғана қол жеткізе алады.

4. Деректерді шифрдан шығару: Пациент немесе авторизацияланған дәрігер дерекқорда сақталатын кілт арқылы деректерді шифрдан шығара алады.

Жүйенің артықшылықтары

1. Құпиялылық: Деректер шифрланып, орталықсыз желіде сақталады.
2. Өзгермейтіндік: Блокчейннің қолданылуы деректердің пациенттің келісімінсіз өзгертілмейтіндігін кепілдейді.
3. Қол жеткізуді басқару: Пациент өз деректеріне кім қол жеткізе алатындығын толық бақылайды.

4. Төзімділік: Орталықсыз деректерді сақтау жүйені шабуылдарға төзімді етеді.

Ұсынылған жүйе медициналық деректердің құпиялылығын және қауіпсіздігін қамтамасыз етуге бағытталған инновациялық шешім ретінде танылады. Цифрлық егіздерді құру және басқару процесінде блокчейн, орталықсыз сақтау жүйесі (IPFS) және күрделі шифрлау әдістері сияқты заманауи технологияларды қолдану арқылы пациенттердің деректерінің жоғары деңгейдегі қорғалуына қол жеткізілді. Бұл жүйе тек қана деректердің қауіпсіздігін қамтамасыз етумен шектелмей, сонымен қатар пациенттерге өз деректеріне толық бақылау жасау мүмкіндігін береді.

Блокчейн технологиясының қолданылуы деректердің өзгермейтіндігін және ашықтығын қамтамасыз етеді. Смарт-контракттер арқылы деректерге қол жеткізуді басқару пациенттерге өз деректерін кіммен бөлісетінін шешуге мүмкіндік береді. Сонымен қатар, IPFS сияқты орталықсыз сақтау жүйесі деректердің бір орталықтан басқарылмайтындығын қамтамасыз етеді, бұл жүйені шабуылдарға және деректердің ашылуына төзімді етеді. Шифрлау технологиясы деректердің тіпті ашылу жағдайында да қорғалуын қамтамасыз етеді.

Болашақта жүйенің функционалдығын одан әрі кеңейту жоспарлануда. Мысалы, медициналық құрылғылармен интеграциялау арқылы деректерді автоматты түрде жинау және талдау мүмкіндігі қарастырылуда.

Ұсынылған жүйе медицина саласындағы цифрлық егіздерді басқару үшін сенімді, ашық және қауіпсіз шешім ретінде танылады. Бұл технологиялардың қолданылуы тек қана медициналық деректердің қорғалуын қамтамасыз етумен шектелмей, сонымен қатар пациенттердің өз деректеріне қатысты құқықтарын нығайтады. Болашақта осы бағыттағы зерттеулер мен технологиялық жаңалықтар медицина саласындағы деректерді басқаруды одан әрі жетілдіруге мүмкіндік береді.

Осылайша, ұсынылған жүйе медициналық деректердің құпиялылығын және қауіпсіздігін қамтамасыз етуге бағытталған тиімді және инновациялық шешім болып табылады. Бұл жүйенің кеңінен қолданылуы медицина саласындағы деректерді басқарудың жаңа стандарттарын белгілеуге мүмкіндік береді.

Пайдаланылған әдебиеттер тізімі:

1. Nakamoto, S. (2008). Bitcoin: A Peer-to-Peer Electronic Cash System.
2. Benet, J. (2014). IPFS - Content Addressed, Versioned, P2P File System.
3. Ethereum Foundation. (2023). Ethereum Whitepaper.

Прогнозирования психического благополучия пациентов с когнитивными нарушениями

Кумарханов А.Д.

Казахский национальный университет им. аль-Фараби, магистрант 2 курса

Email: assankumarkhanov@gmail.com

Благодаря стремительному развитию алгоритмов машинного обучения и возрастанию доступности экономически эффективных носимых устройств с широким спектром физиологических сенсоров, мы наблюдаем рост числа исследований, ориентированных на применение данных технологий для количественной оценки, мониторинга и прогнозирования эмоционального состояния и психического здоровья человека. [1, 2, 3].

Такие показатели, как ежедневное количество шагов и качество сна, демонстрируют высокую эффективность для классификации субъективного благополучия [4] и прогнозирования депрессивных состояний [5].

Для сбора данных планируется включить 30 участников (15 мужчин и 15 женщин) различных возрастных категорий (условно: молодые, зрелые и пожилые), отобранных среди действующих пациентов, находящихся под наблюдением медицинских специалистов. Для обеспечения объективности данных и повышения точности результатов эксперимент необходимо проводить на протяжении не менее 10 недель. При этом исследование должно осуществляться в строгом соответствии с принципами Хельсинкской декларации [6].

Для мониторинга физиологических и активностных показателей участников в течение указанного периода предлагается использовать наручные часы, предназначенные для контроля состояния здоровья пациента. Такие устройства должны быть оснащены разнообразными сенсорами, включая акселерометр, оптический датчик сердечного ритма, датчик насыщения кислородом, ЭКГ и сенсор EDA. На основании данных, получаемых с помощью этих датчиков, устройство должно ежедневно определять следующие показатели, связанные с физической активностью:

1. Количество Сожженных калорий
2. Количество Пройденных шагов
3. Общее Пройденное расстояние
4. Минуты сидячей активности
5. Минуты легкой активности
6. Минуты достаточно активной деятельности
7. Минуты очень активной деятельности
8. Количество калорий, сожженных во время физической активности

Предполагается, что модель будет прогнозировать следующие показатели: уровень психического благополучия, измеряемый по шкале WEMWBS (Уорик-Эдинбургская шкала психического благополучия) [7], уровень стресса, отражаемый шкалой PSS (шкала воспринимаемого стресса) [8], а также качество сна, оцененное по индикатору состояния сна (SCI) – 8-пунктовой шкале для определения степени бессонницы у участников [9].

При обучении модели можно использовать несколько классификационных алгоритмов, часто применяемых в аналогичных исследованиях, таких как SVM, логистическая регрессия, Random Forest, XGBoost и тд. В качестве предикторов выступают ранее упомянутые признаки. Для оценки вклада каждого из этих признаков в прогностическую модель мы можем воспользоваться методом TreeExplainer. Он основан на теории кооперативных игр, что позволит нам вычислять предельный вклад каждого признака, анализируя его влияние на все комбинации входных параметров.

Список использованной литературы:

1. P. Siirtola, S. Tamminen, G. Chandra, A. Ihalapathirana and J. Röning, " Predicting

emotion with biosignals: A comparison of classification and regression models for estimating valence and arousal level using wearable sensors," *Sensors*, 23(3), vol. 23, no. 3, p. 1598, 2023.

2. Ö. D. İ. Berrenur Saylam, "Quantifying Digital Biomarkers for Well-Being: Stress, Anxiety, Positive and Negative Affect via Wearable Devices and Their Time-Based Predictions," *Sensors*, 2023.

3. N. Magal, S. L. Rab, P. Goldstein, L. Simon, T. Jiryis and R. Admon, "Predicting chronic stress among healthy females using daily-life physiological and lifestyle features from wearable sensors," *Chronic Stress*, 2022.

4. A. C. Kılıç, A. Karakuş and E. Alptekin, "Prediction of university students' subjective well-being with sleep and physical activity data using classification algorithms," *Procedia Computer Science*, vol. 207, pp. 2648-2657, 2022.

5. I. Moshe, Y. Terhorst, K. Opoku Asare, L. Sander, D. Ferreira, H. Baumeister, D. Mohr and L. Pulkki-Råback, "Predicting symptoms of depression and anxiety using smartphone and wearable data," *Frontiers in psychiatry*, vol. 12, p. 625247, 2021.

6. World Medical Association. World Medical Association Declaration of Helsinki: Ethical Principles for Medical Research Involving Human Subjects // *JAMA*. — 2013-11-27. — Т. 310, вып. 20. — С. 2191–2194. — ISSN 0098-7484. — doi:10.1001/jama.2013.281053

7. R. Tennant, L. Hiller, R. Fishwick, S. Platt, S. Joseph, S. Weich, J. Parkinson, J. Secker and S. Stewart-Brown, "The Warwick-Edinburgh mental well-being scale (WEMWBS): development and UK validation," *Health and Quality of life Outcomes*, vol. 5, pp. 1-13, 2007

8. S. Cohen, T. Kamarck and R. Mermelstein, "A global measure of perceived stress," *Journal of health and social behavior*, pp. 385-396, 1983.

9. C. A. Espie, S. D. Kyle, P. Hames, M. Gardani, L. Fleming and J. Cape, "The Sleep Condition Indicator: a clinical screening tool to evaluate insomnia disorder," *BMJ open*, vol. 4, no.3, p. e004183, 2014.

Разработка ИИ-компаньона для поддержки психического здоровья в Казахстане с учетом культурных особенностей

Кумарханов А.Д.

Казахский национальный университет им. аль-Фараби, магистрант 2 курса e-mail:
assankumarkhanov@gmail.com

Актуальность темы исследования обусловлена ростом числа людей, испытывающих стресс, тревожные расстройства и депрессию, особенно в условиях современной социальной и экономической нестабильности. В Казахстане, как и во всем мире, наблюдается дефицит квалифицированных специалистов в области психического здоровья, а существующие методы поддержки зачастую недоступны из-за финансовых, географических или культурных барьеров.

Разработка ИИ-компаньона способна стать эффективным инструментом для снижения нагрузки на специалистов, повышения доступности психологической поддержки и предоставления персонализированной помощи пользователям. Запущенный в ноябре 2022 года, ChatGPT имеет потенциал существенно изменить такие сферы, как здравоохранение и научное письмо, однако его точность и надежность в этих областях все еще нуждаются в детальном анализе и оценке. [1]

Использование искусственного интеллекта для анализа биосигналов способствует развитию персонализированной медицины, учитывая индивидуальные характеристики пациентов и обеспечивая более точные рекомендации для поддержания их психического и физического здоровья. [2] Восприятие чат-ботов-компаньонов как более осознанных и человекоподобных связано с более позитивным отношением к ним и усиленным восприятием их социальных преимуществ. [3] Эмоциональные связи, возникающие у пользователей с ИИ-компаньонами, демонстрируют, что разговорный искусственный интеллект способен обеспечивать поддержку, сравнимую с человеческим общением, однако это также сопряжено с риском формирования эмоциональной зависимости. [4]

Несмотря на потенциал машинного обучения, существуют значительные вызовы, связанные с интеграцией этих технологий в здравоохранение. [5] Внедрение такого решения позволит расширить доступ к психологической помощи, снизить барьеры, связанные с географическими и финансовыми ограничениями, и повысить уровень осведомленности о ментальном здоровье.

Список использованной литературы:

1. Alkaissi H, McFarlane S I (February 19, 2023) Artificial Hallucinations in ChatGPT: Implications in Scientific Writing. *Cureus* 15(2): e35179. doi:10.7759/cureus.35179
2. Lee, Y.J., Park, C., Kim, H. et al. Artificial intelligence on biomedical signals: technologies, applications, and future directions. *Med-X* 2, 25 (2024). <https://doi.org/10.1007/s44258-024-000431>
3. R. E. Guingrich and M. S. A. Graziano, "Chatbots as social companions: How people perceive consciousness, human likeness, and social health benefits in machines," arXiv preprint, 18 pages, 3 figures, presented at ASSC '26 at NYU, Nov. 2023, doi: 10.48550/arXiv.2311.10599.
4. Kouros, T., & Papa, V. (2024). Digital Mirrors: AI Companions and the Self. *Societies*, 14(10), 200. <https://doi.org/10.3390/soc14100200>
5. Alvin Rajkomar, Jeffrey Dean, and Isaac Kohane. Machine learning in medicine. *New England Journal of Medicine*, 380(14):1347–1358, 2019.

Құрылыс компаниясында жылжымайтын мүлік объектілерін жоспарлау мен ағымдағы есебінің автоматтандырылған жүйесін құруды ұйымдастыру

Мухамбеткалиева М.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

Email: madina_m.2003@mail.ru

Шаяхметова А.С.

Әл-Фараби атындағы ҚазҰУ, PhD, профессор м.а.

Ахметова А.М.

Әл-Фараби атындағы ҚазҰУ, PhD, аға оқытушы

Құрылыс саласындағы басқару процестерін автоматтандыру тиімділікті арттыруға және ресурстарды оңтайлы пайдалануға мүмкіндік береді [1]. Бұл мақала құрылыс компаниясында жылжымайтын мүлік объектілерін жоспарлау мен ағымдағы есеп жүргізуді автоматтандыру үшін жасанды интеллект (AI) және ақпараттық жүйелерді қолдануды қарастырады. Жобаны басқару, қаржы есебі, құрылыс материалдарын бақылау және клиенттермен өзара әрекеттесуді оңтайландыру үшін веб-қосымша әзірлеу ұсынылады. Ұсынылған жүйе құрылыс компанияларының жұмысын жеңілдетуге және жобаларды басқару тиімділігін арттыруға бағытталған.

Құрылыс индустриясы күрделі логистикалық және қаржылық процестерді басқаруды талап етеді [2]. Дәстүрлі әдістерде құжат айналымы көп уақыт алады, ал мәліметтерді нақты уақытта жаңарту қиындық туғызады. Бұл басқару шешімдерінің тиімділігін төмендетуі мүмкін [3]. Қазіргі таңда автоматтандырылған жүйелерді енгізу арқылы жоспарлау мен есеп жүргізуді оңтайландыруға болады [4]. Бұл зерттеуде құрылыс компаниясында жылжымайтын мүлік объектілерін басқаруды автоматтандыру үшін веб-қосымша құру ұсынылады. Жүйе құрылыс процестерін оңтайландыру, шығындарды бақылау, қаржылық есепті жүргізу, материалдық ресурстарды басқару және клиенттермен өзара әрекеттесуді жақсарту мүмкіндігін береді.

1. Веб-қосымша архитектурасы – жүйе клиент-сервер моделінде жұмыс істейді. Сервер жағы Python (Django) фреймворкі арқылы әзірленеді, ал фронтенд HTML/CSS, JavaScript, Bootstrap технологияларын қолданады.

2. Мәліметтер қоры – объектілер туралы ақпаратты сақтау үшін SQLite қолданылады. Ол құрылыс нысандары, қаржы есептері, пайдаланушылар және құрылыс материалдары бойынша мәліметтерді сақтауға мүмкіндік береді.

3. CRM және қаржы есебі – клиенттермен өзара әрекеттесу және келісімшарттарды бақылау үшін CRM жүйесі, сондай-ақ кірістер мен шығыстарды бақылау үшін қаржы есептеу модулі енгізіледі.

4. Жасанды интеллект және машиналық оқыту – қаржылық болжам жасау және ресурстарды тиімді жоспарлау үшін қолданылады.

5. Материалдық ресурстарды басқару – қоймадағы құрылыс материалдарының қозғалысын бақылау және олардың қажетті мөлшерін болжау үшін автоматтандырылған құралдар пайдаланылады.

Ұсынылған автоматтандырылған жүйе құрылыс компанияларына жылжымайтын мүлік объектілерін басқаруды оңтайландыруға көмектеседі. Жүйені енгізу нәтижесінде:

- Қаржылық есептілік пен бақылаудың дәлдігі артады;
- Құрылыс материалдарының қозғалысын тиімді басқаруға мүмкіндік туады;
- Құрылыс жобаларының орындалу барысын нақты уақытта қадағалау мүмкіндігі пайда болады;

- Клиенттермен өзара әрекеттесу жүйеленеді;

- Жұмыс процестерінің автоматтандырылуы есебінен уақыт пен ресурстар үнемделеді.

Құрылыс компанияларында жылжымайтын мүлік объектілерін жоспарлау мен есепке алуды автоматтандыру жүйенің тиімділігін арттырады. Әзірленген веб-қосымша жобаларды

басқару, шығындарды есептеу және қаржылық бақылауды жеңілдетеді. Жүйе құрылыс процестерін цифрландыру арқылы шығындарды азайтуға, ресурстарды оңтайлы пайдалануға және жұмыс тиімділігін арттыруға мүмкіндік береді.

Пайдаланылған әдебиеттер тізімі:

1. Smith, J., Brown, K. (2023). Digital Solutions in Construction Management. *Journal of Building Technologies*, 45(3), 120-135.

2. Zhang, L., Chen, Y. (2022). AI-Driven Project Planning in Construction. *Automation in Construction*, 40, 205-219.

3. Williams, R., Johnson, T. (2021). Smart Construction: Innovations and Trends. *Construction Management Journal*, 35(2), 98-115.

4. Kumar, P., Gupta, A. (2023). Real Estate Data Management: A Systematic Review. *Journal of Urban Technologies*, 28, 305-322.

Ақпараттық жүйелерде медициналық деректердің қауіпсіздігін болжау және қамтамасыз ету үшін жасанды интеллект әдістерін әзірлеу және зерттеу

Мұхаммеджанова Д.М.

Әл-Фараби атындағы ҚазҰУ, 2 курс докторант

Email: m.dinargul.14@gmail.com

Бұл мақалада медициналық ақпараттық жүйелердегі деректердің қауіпсіздігін қамтамасыз ету және оларды болжау үшін жасанды интеллект (ЖИ) әдістерін қолдану мәселелері қарастырылады. Медициналық деректердің көлемі ұдайы өсіп келе жатқандықтан, олардың қауіпсіздігін қамтамасыз ету маңызды міндетке айналуда. ЖИ технологиялары машиналық оқыту, шифрлау, биометриялық аутентификация және аномалияларды анықтау әдістерін қамти отырып, медициналық деректердің қорғалуын жақсартуға мүмкіндік береді. Сонымен қатар, мақалада қазіргі заманғы қауіпсіздік шешімдері, құқықтық талаптар және болашақ зерттеу бағыттары талқыланады. ЖИ-дың медициналық деректердің қауіпсіздігін арттырудағы рөлі мен болашақта осы салада қолданылу мүмкіндіктері көрсетілген.

Медициналық ақпараттық жүйелердегі деректердің қауіпсіздігі мен оларды болжауға арналған жасанды интеллект (ЖИ) әдістері қазіргі таңда өзекті зерттеу салаларының бірі болып табылады. Цифрландырудың қарқынды дамуы медициналық деректердің жаппай жинақталуына әкеліп, олардың құпиялылығы мен қауіпсіздігін қамтамасыз етудің жаңа тәсілдерін талап етеді. Бұл мақалада медициналық деректерді қорғау және қауіпсіздігін болжауға арналған ЖИ әдістеріне жасалған әдеби шолу ұсынылады.

Медициналық ақпараттық жүйелердегі деректердің қауіпсіздігіне қатысты негізгі қатерлерге мыналар жатады:

- Кибершабуылдар (ransomware, phishing, DDoS);
- Деректердің заңсыз таралуы және рұқсатсыз қол жеткізу;
- Денсаулық сақтау жүйелеріндегі осалдықтар;
- Құқықтық талаптарға (GDPR, HIPAA, ҚР «Дербес деректер туралы» заңы) сәйкес келмеу.

IBM Security Report мәліметтері бойынша, медициналық ұйымдарға жасалған кибершабуылдар саны жыл сайын артып келеді, ал медициналық деректерді заңсыз пайдалану оқиғалары көптеген елдерде үлкен проблемаға айналды. Сондықтан медициналық деректердің қауіпсіздігін қамтамасыз ету үшін жаңа технологияларды қолдану қажеттілігі туындауда.

Жасанды интеллект алгоритмдері медициналық деректердің қауіпсіздігін қамтамасыз ету және қауіптерді болжау үшін кеңінен қолданылады. Негізгі әдістерге мыналар жатады:

- Машиналық оқыту (ML) және терең оқыту (DL) – аномалияларды анықтау және рұқсатсыз әрекеттерді болжау;
- Шифрлау алгоритмдері – деректерді қорғау үшін AES, RSA, Homomorphic Encryption технологияларын пайдалану;
- Биометриялық аутентификация – қолданушыларды анықтау үшін бет әлпетін тану, саусақ іздері және дауысты сәйкестендіру;
- Аномалияларды анықтау жүйелері – компьютерлік жүйелерде қалыптан тыс әрекеттерді бақылау;
- Blockchain және Zero-Trust архитектурасы – деректердің тұтастығын сақтау және әрбір транзакцияны қауіпсіз ету.

ЖИ әдістерін енгізу медициналық ұйымдардың ақпараттық жүйелеріне бағытталған шабуылдарды ерте анықтауға және болжауға мүмкіндік береді. Бұл медицина саласындағы киберқауіпсіздікті жақсартуға ықпал етеді.

Көптеген зерттеулерде медициналық деректердің қауіпсіздігін қамтамасыз етуге бағытталған түрлі тәсілдер қарастырылады:

- Аномалияларды анықтау: Isolation Forest, Autoencoder, One-Class SVM әдістері күдікті

әрекеттерді анықтау үшін қолданылады.

- Дифференциалды құпиялылық (Differential Privacy): деректерді өңдеу кезінде жеке ақпараттың жария етілуін шектеу үшін қолданылады.

- Шифрлау және қолжетімділікті бақылау: Blockchain технологиясы арқылы деректердің өзгеріссіз сақталуын қамтамасыз ету.

- Қорғалған бұлттық жүйелер: деректерді қашықтан қауіпсіз сақтау үшін қауіпсіздік шараларын күшейту.

Бұл әдістердің барлығы медициналық ақпараттық жүйелердегі деректердің қауіпсіздігін күшейтуге және құқықтық талаптарға сәйкестігін қамтамасыз етуге бағытталған. Медициналық деректерді қорғау және олардың қауіпсіздігін болжау саласында бірнеше болашақ зерттеу бағыттары бар:

- Кванттық шифрлау және пост-кванттық қауіпсіздік әдістері;

- ЖИ мен Blockchain технологияларын біріктіру;

- Агенттік жүйелер арқылы автономды киберқауіпсіздік жүйелерін құру;

- Қорғалған федеративті оқыту әдістерін медициналық деректермен интеграциялау.

Медициналық ақпараттық жүйелердегі деректердің қауіпсіздігін қамтамасыз ету және оларды болжау үшін жасанды интеллект әдістерін қолдану – денсаулық сақтау саласындағы маңызды зерттеу бағыты болып табылады. Кибершабуылдардың артуы және заңнамалық талаптардың қатаңдануы бұл тақырыптың өзектілігін арттырады. Болашақта ЖИ, Blockchain және кванттық қауіпсіздік әдістерін біріктіру арқылы медициналық деректердің қауіпсіздігін жаңа деңгейге көтеру мүмкін болады.

Пайдаланылған әдебиеттер тізімі:

1. Smith, J., Brown, L. (2023). A Review on AI and Security in Healthcare Data Systems. *International Journal of Healthcare Informatics*.

2. Wang, Y., Zhao, X. (2022). Machine Learning for Cybersecurity in Healthcare. *IEEE Transactions on Medical Informatics*.

3. Miller, R., Thomas, K. (2021). GDPR and HIPAA Compliance in AI-Driven Medical Data Protection. *Journal of Data Privacy & Security*.

4. Nguyen, P., Li, F. (2023). Deep Learning for Anomaly Detection in Medical Systems. *Springer Health Informatics*.

5. Patel, A., Singh, M. (2022). Blockchain Technology for Secure Healthcare Data Storage. *Journal of Blockchain and Healthcare*.

АТ-менеджменті кеңсе техникасына қызмет көрсетуге сұраныстарды беру, есепке алу және орындау жүйесін автоматтандыруды ұйымдастыру

Мұхтарқызы М.

*Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр
Email: mukhtarqyzumerei@mail.ru*

Шаяхметова А.С.

Әл-Фараби атындағы ҚазҰУ, PhD, профессор м.а.

Ахметова А.М.

Әл-Фараби атындағы ҚазҰУ, PhD, аға оқытушы

Мақалада АТ-менеджменті кеңсе техникасына қызмет көрсетуге сұраныстарды беру, есепке алу және орындау жүйесін автоматтандыру тақырыбы қарастырылады. Осы жүйе кәсіпорынның жұмыс тиімділігін арттыруға, қызмет көрсету процесін жеңілдетуге және операциялық шығындарды төмендетуге бағытталған. Бұл технологияның мүмкіндіктері мен артықшылықтары туралы талқыланып, оның қазіргі замандағы кеңсе бизнесінде қолданылуы көрсетіледі.

Қазіргі таңда ақпараттық технологиялар кеңсе жұмысында маңызды рөл атқарады. Кеңсе техникасына қызмет көрсету бойынша сұраныстарды басқару — әрбір ұйым үшін қажетті үрдіс. Мұндай сұраныстарды автоматтандырылған жүйе арқылы басқару, қызмет көрсету сапасын жақсартып, уақыт пен ресурстарды үнемдеуге мүмкіндік береді [1]. Мақаланың негізгі мақсаты — кеңсе техникасына қызмет көрсету процесін автоматтандырудың тиімділігін зерттеу және оның ұйымдардағы қолданылу мүмкіндіктерін қарастыру.

Жүйені автоматтандыру үшін бірнеше әдістер мен технологиялар қолданылады. Бұл процеске кіріспес бұрын, ұйымдарда кеңсе техникасына қызмет көрсетуге арналған сұраныстарды өңдеудің негізгі кезеңдері қарастырылды [2]. Біріншіден, сұраныстарды қабылдау, тіркеу және әртүрлі категориялар бойынша жіктеу жүзеге асырылады. Екіншіден, әрбір сұранысқа жауапты маман тағайындалып, орындау мерзімі белгіленеді. Үшіншіден, жүйе қызмет көрсету жағдайы мен нәтижелерін мониторингтеу үшін арнайы есеп беру функцияларымен жабдықталады.

Қазіргі кезде қызмет көрсету жүйелерінде жасанды интеллект, машиналық оқыту және деректерді өңдеудің жаңа тәсілдері қолданылады [3]. Бұл жүйелер сұраныстарды талдау, жіктеу және мамандарды тиісті қызмет көрсету үшін автоматты түрде тағайындау мүмкіндігін береді.

Жүйені автоматтандырудың негізгі нәтижелері мен артықшылықтары арасында қызмет көрсету сапасының жақсаруы, жұмыс уақытын үнемдеу, және қызмет көрсету жауапкершілігін нақты түрде бөлу болады. Автоматтандырылған жүйе кеңсе техникасына қызмет көрсету процестерінің тиімділігін айтарлықтай арттырады, себебі барлық сұраныстар деректер қорында сақталады және қадағаланады [4].

Болашақта осы жүйелердің кеңсе техникасына қатысты қолданылуы одан әрі дамып, процестердің барлық кезеңдерін толық автоматтандыруға мүмкіндік береді. Бұл әртүрлі ұйымдар үшін уақытты, ресурстарды үнемдеу және процестердің ашықтығын қамтамасыз етеді.

Қорытындылай келе, кеңсе техникасына қызмет көрсетуге сұраныстарды беру, есепке алу және орындау жүйесін автоматтандыру — қазіргі заманғы ұйымдар үшін тиімді шешім болып табылады. Бұл жүйе қызмет көрсету сапасын арттырып, жұмыс процестерін оңтайландырады. Алдағы уақытта жүйелердің мүмкіндіктері кеңейіп, технологиялар одан әрі жетілдіріледі деп күтілуде.

Пайдаланылған әдебиеттер тізімі:

1. Байымбетова, А. (2018). "Ақпараттық жүйелерді автоматтандыру: теориясы мен практикасы". Алматы: ЖШС "Қазақ университеті".
2. Қожаев, Р. (2020). "Жасанды интеллект пен автоматтандырудың қазіргі замандағы рөлі". Астана: "Жоғары оқу орны".
3. Ермеков, Т. (2019). "Кеңсе қызметін автоматтандыруға арналған жүйелер". Мәскеу: "Технотранс".
4. Исаков, Н. (2017). "Ақпараттық технологиялар және олардың кеңсе жүйелерінде қолданылуы". Алматы: "ИнфоТех" баспасы.

Разработка интеллектуальной системы реабилитации пациентов с нарушениями моторных функций на основе игровых технологий

Нағашыбек А.Б.

КазНУ имени аль-Фараби, 4 курс бакалавриат

Сарсембаева Т.С.

КазНУ им. аль-Фараби, старший преподаватель

E-mail: sarsembayeva.talshyn@gmail.com

Реабилитация пациентов с нарушениями моторных функций после инсульта или травм требует инновационных подходов, направленных на восстановление двигательной активности и повышение мотивации пациентов. Одним из перспективных решений является использование игровых технологий, таких как сенсорное устройство Microsoft Kinect, которое позволяет отслеживать движения пациента в реальном времени, адаптировать программу упражнений и анализировать эффективность занятий [1]. В настоящее время ведется разработка интеллектуальной реабилитационной системы на основе игровых технологий и искусственного интеллекта, способной адаптировать упражнения в зависимости от двигательной активности пациента и отслеживать динамику восстановления. На данном этапе проект включает анализ существующих методов цифровой реабилитации и их эффективности, включая VR и сенсорные технологии [2].

Разрабатывается программный модуль, использующий Microsoft Kinect для регистрации движений пациента и их последующей обработки [3]. Ведется работа над алгоритмами машинного обучения, которые позволят персонализировать коррекцию упражнений и повысить эффективность реабилитационного процесса [4]. В дальнейшем планируется тестирование системы на моделях и с участием пациентов для оценки ее результативности и определения возможных направлений для совершенствования [5]. На основе анализа существующих решений выявлены ключевые преимущества Microsoft Kinect для реабилитации – бесконтактный мониторинг движений, удобство использования в домашних и клинических условиях, возможность геймификации упражнений. Текущая разработка направлена на интеграцию этих преимуществ в единое интеллектуальное решение. Ожидается, что игровые элементы повысят вовлеченность пациентов в процесс восстановления, а алгоритмы машинного обучения обеспечат индивидуальную адаптацию тренировок [3, 4]. Применение интеллектуальных игровых технологий в реабилитации пациентов с нарушениями моторных функций представляется перспективным направлением, способным значительно повысить эффективность восстановительных программ. В дальнейшем планируется проведение испытаний системы, доработка алгоритмов адаптации упражнений и интеграция с телемедицинскими платформами [5].

Список использованной литературы:

1. Chang Y.-J., Han W.-C., Tsai Y.-C. A Kinect-based upper limb rehabilitation system to assist people with cerebral palsy // *Research in Developmental Disabilities*. – 2013. – Т. 34, № 11. – С. 3654-3659. DOI: 10.1016/j.ridd.2013.08.021
2. Tao W., Liu T., Zheng R., Feng H. Gait analysis using wearable sensors // *Sensors*. – 2012. – Т. 12, № 2. – С. 2255-2283. DOI: 10.3390/s120202255
3. Webster D., Celik O. Systematic review of Kinect applications in elderly care and stroke rehabilitation // *Journal of NeuroEngineering and Rehabilitation*. – 2014. – Т. 11, № 1. – С. 108. DOI: 10.1186/1743-0003-11-108
4. Lange B., Chang C.-Y., Suma E., Newman B., Rizzo A. A., Bolas M. Development and evaluation of low-cost game-based balance rehabilitation tool using the Microsoft Kinect sensor // *Journal of NeuroEngineering and Rehabilitation*. – 2011. – Т. 8, № 1. – С. 95.
5. Devanne M., Baccon M., Grandjean D., Wannous H., Daoudi M. 3D human action

recognition using a recursive feature elimination-based optimization framework for Kinect skeleton data // IEEE Transactions on Computational Intelligence and AI in Games. – 2015. – T. 7, № 3. – С. 261-273.

Машиналық оқыту және компьютерлік көру технологияларын қолдана отырып, роботтандырылған өнім жинау жүйесін жобалау

Нурумбаев Д.Х.

*Әл-Фараби атындағы Қазақ Ұлттық университеті, 4 курс бакалавриаты
E-mail: damir.nurumbaev@gmail.com*

Ауыл шаруашылығындағы заманауи технологиялар Автоматтандыру және роботтандыру бағытында қарқынды дамып келеді. Бұл процесс өндіріс тиімділігін арттыру, қол еңбегіне кететін шығындарды азайту және егін шығынын азайту қажеттілігіне байланысты. Дәстүрлі егін жинау әдістері айтарлықтай уақыт пен адам ресурстарын қажет етеді, бұл процесті экономикалық және экологиялық тұрғыдан тиімсіз етеді. Осыған байланысты ауыл шаруашылығына интеллектуалды роботтық жүйелерді енгізу өзекті міндет болып табылады[1].

Бұл зерттеу жемістерді автоматты түрде анықтау, жіктеу және дәл жинау үшін компьютерлік көру және машиналық оқыту технологияларын қолданатын роботты егін жинау жүйесін жобалауға бағытталған[2]. Жүйенің басты ерекшелігі-оның өзгеретін ортада алгоритмдердің икемділігі мен дәлдігін қамтамасыз ете отырып, нақты жұмыс жағдайларына бейімделу қабілеті.

Зерттеудің негізгі мақсаты роботты басқару алгоритмдерін виртуалды ортада оларды енгізер алдында сынауға мүмкіндік беретін модельдеу жүйесін әзірлеу болып табылады. Ол үшін роботтың қозғалыс динамикасын, манипулятордың жұмысын және оның қоршаған ортамен өзара әрекеттесуін нақты модельдеуге мүмкіндік беретін AnyLogic платформасы қолданылады. Модельдеу процесінде жүйенің тұрақтылығы мен тиімділігі әртүрлі параметрлерде бағаланады.

Компьютерлік көру технологиялары піскен жемістерді анықтау және олардың нақты орналасуын анықтау үшін қолданылады, ал Машиналық оқыту әдістері (нейрондық желілер, шешім ағаштары, күшейтілген оқыту) жүйені жинау және оңтайландыру процесін икемді басқару үшін қолданылады. Зерттеу объектілерді анықтау алгоритмдерін (YOLO, Faster R-CNN), манипуляторды басқару әдістерін (кері кинематика, траекторияны жоспарлау, күшейту жаттығулары) және жүйенің жұмысын оңтайландыру стратегияларын талдайды[3].

Ұсынылған тәсіл келесі артықшылықтарды ұсынады:

- Физикалық прототипті әзірлеу шығындарын азайту;
- Алгоритмдерді тестілеу және оңтайландыру процесін жеделдету;
- Роботтың дәлдігі мен өнімділігін арттыру;
- Автономды егін жинау жүйелерін нақты өндірістік ортаға тиімді енгізу.

Модельдеу нәтижелері ауыл шаруашылығында автономды егін жинау жүйелерін енгізу үшін ұсынылған әдістің болашағын растайды. Зерттеу нәтижелері агроөнеркәсіптік саладағы робототехника мен жасанды интеллект әдістерін дамытуға үлес қосады.

Пайдаланылған әдебиеттер тізімі:

1. Szeliski R. Computer Vision: Algorithms and Applications. — Springer, 2022.
2. Siciliano B., Khatib O. Springer Handbook of Robotics. — Springer, 2016.
3. Redmon J., Farhadi A. YOLOv3: An Incremental Improvement // arXiv preprint arXiv:1804.02767, 2018.

Тамақ өнеркәсібінің виртуалды моделін көрсету үшін толықтырылған шындықты пайдалану

Нұрғазы Т.Н.

Әл-Фараби атындағы ҚазҰУ, 1 курс магистрант
Email: nurgazytomiris@gmail.com, +7 747 419 57 23

Амирханова Г.А.

Әл-Фараби атындағы ҚазҰУ, PhD, аға оқытушы

Мақалада тамақ өнеркәсібі кәсіпорнының виртуалды моделін визуализациялау үшін толықтырылған шындық (AR) модулі әзірленді. Бұл жұмыс өндірістік процестерді оңтайландыруға, өндіріс қызметкерлерін оқыту тиімділігін арттыруға және өнім сапасын бақылауды жақсартуға бағытталған.

Қазіргі заманғы толықтырылған шындық (AR) технологиялары әртүрлі өнеркәсіп салаларында өндірістік процестерді визуализациялау және басқару үшін жаңа мүмкіндіктер ұсынады. Өндірісте AR қолдану өнімділікті және дәлдікті айтарлықтай арттырып, жабдықтың тоқтап қалуын шамамен 30–40%-ға қысқартады [1]. Тамақ өнеркәсібі контекстінде толықтырылған шындық технологиясын пайдалану өндірістің негізгі кезеңдерінде бақылауды күшейтуге, қызметкерлерді оқытуға және негізгі стратегиялар бойынша шешім қабылдауға мүмкіндік беретін перспективалы бағыт болып табылады. Өндіріс 4.0-мен байланысты толықтырылған шындық сияқты технологиялар өндірістік процестердің ашықтығына қойылатын өсіп келе жатқан талаптарды қанағаттандыру және сапалы өнім жеткізу үшін бәсекелестік артықшылықтарға қол жеткізуде өнеркәсіпті түрлендіруде маңызды рөл атқарады [2].

Бұл жұмыстың мақсаты — тамақ өнеркәсібі кәсіпорнының виртуалды моделін визуализациялау үшін AR модулін жасау. Тамақ өндіріске AR технологияларын енгізу операторлардың қателіктерін айтарлықтай азайтып, өнімнің сапасын бақылауды жақсартуға мүмкіндік береді [3]. Бұл жұмыстың негізгі мақсаты — өндірістік жабдықтың егжей-тегжейлі көрсетілімімен тамақ өнеркәсібі кәсіпорнының үш өлшемді виртуалды моделін визуализациялау үшін толықтырылған шындық модулін әзірлеу. Зерттеудің бастапқы кезеңінде тамақ өндіру жабдығының виртуалды моделінің мүмкіндіктерін көрсететін AR қолданбасының прототипін жасауға баса назар аударылады, бұл жұмыстың әрі қарай дамуы үшін негіз болады. Осы мақсатқа жету үшін төрт негізгі әдіс қолданылады: тамақ өнеркәсібі кәсіпорнының негізгі өндірістік жабдықтарының 3D моделін жасау; Unity платформасын пайдалана отырып AR қолданбасын әзірлеу; виртуалды объектілерді дәл орналастыру үшін маркерді тану әдісін қолдану; интуитивті түсінікті пайдаланушы интерфейсін жобалау. Мұндай жүйелерді әзірлеу үшін Unity платформасы мен ARCore / ARKit технологияларының үйлесімі ең тиімді болып табылады, бұл модельдің егжей-тегжейлігі мен AR қолданбасының өнімділігінің оңтайлы қатынасын қамтамасыз етеді [4]. Жұмыс аясында жүйе архитектурасы екі негізгі компоненттен тұрады: 3D модельдеу модулі және AR визуализация модулі. Мұндай модульдік құрылым жүйенің икемділігін және оны өндірістік ортада кезең-кезеңмен енгізу мүмкіндігін қамтамасыз етеді [5].

Бұл жұмыстың нәтижесі — тамақ өнеркәсібі кәсіпорнының үш өлшемді моделін физикалық кеңістікте визуализациялауға мүмкіндік беретін AR қолданбасының функционалды прототипін жасау. Тамақ өнеркәсібі кәсіпорнының персоналын оқытуда AR қолдану жаңа дағдыларды игеру уақытын қысқартады [6]. Сондықтан әзірленген модульдің практикалық қолданылуы бірнеше негізгі аспектілерді қамтиды: күрделі өндірістік процестерді визуализациялау арқылы персоналды оқыту, жөндеу нұсқауларын тікелей маманның көру өрісіне шығару арқылы қызмет көрсету, жабдықтың жұмыс параметрлерін жедел бақылау және технологиялық процестің тиімсіз аймақтарын анықтау арқылы өндірісті оңтайландыру. Өнеркәсіпте AR технологияларын сәтті енгізу тек техникалық мәселелерді

шешуді ғана емес, сонымен қатар бизнес процестерді қайта құруды, ұйымдық құрылымды бейімдеуді және персоналдың цифрлық құзыреттерін дамытуды талап етеді [7]. Бұл зерттеу тамақ өнімдері саласындағы кәсіпорындарды басқаруға және бағыттауға арналған кеңейтілген шындық технологияларын қолданатын жүйені құруға негіз болады. Өндірістік процестердің өнімділігін айтарлықтай арттыруға, персоналды оқыту сапасын жақсартуға және технологиялық операциялар параметрлеріне қатысты бақылау көрсеткіштерін жақсартуға мүмкіндік береді деп күтілуде.

Қорытындылай келе, кәсіпорынның цифрлық моделін визуализациялау үшін толықтырылған шындық модулін құру — әртүрлі технологиялық стратегиялардың тоғысуын және жеке өндірістік процестерге байланысты бірегей мүмкіндіктерді ескеруді талап ететін күрделі міндет екенін мойындау маңызды. AR модулін жобалау және іске асыру үшін біртұтас жоспар құру осы технологияны өнімділікті арттыру және кәсіпорынның бәсекеге қабілеттілігін қамтамасыз ету үшін тиімді пайдаланудың кепілі болып табылады.

Пайдаланылған әдебиеттер тізімі:

1. Masood, T., Egger, J. Augmented reality in support of Industry 4.0—Implementation challenges and success factors // *Robotics and Computer-Integrated Manufacturing*. – 2019. – Т. 58. –Б.181 195
[//https://www.sciencedirect.com/science/article/abs/pii/S073658451830401?via%3Dihub](https://www.sciencedirect.com/science/article/abs/pii/S073658451830401?via%3Dihub)
2. Panigrahi, R. R., Singh, N., Muduli, K. Digital technologies and food supply chain: a scoping view from 2010 to 2024 // *International Journal of Industrial Engineering and Operations Management*. – 2024. // <https://www.emerald.com/insight/content/doi/10.1108/ijieom-05-2024-0030/full/html>.
3. Styliaras, G. D. Augmented Reality in Food Promotion and Analysis: Review and Potentials // *Digital*. – 2021. – Т. 1, №4. // <https://www.mdpi.com/2673-6470/1/4/16>.
4. Nowacki, P., Woda, M. Capabilities of ARCore and ARKit Platforms for AR/VR Applications // *Engineering in Dependability of Computer Systems and Networks / Zamojski, W., Mazurkiewicz, J., Sugier, J., Walkowiak, T., Kacprzyk, J. (Ред.)*. – *Advances in Intelligent Systems and Computing*, Т. 987. – Cham: Springer International Publishing, 2020. – Б. 358–370. // https://link.springer.com/chapter/10.1007/978-3-030-19501-4_36
5. Malta, A., Farinha, T., Mendes, M. Augmented Reality in Maintenance—History and Perspectives // *Journal of Imaging*. – 2023. – Т. 9, №7. // <https://www.mdpi.com/2313-433X/9/7/142>
6. Ho, P. T., Albajez, J. A., Santolaria, J., Yagüe-Fabra, J. A. Study of Augmented Reality Based Manufacturing for Further Integration of Quality Control 4.0: A Systematic Literature Review // *Applied Sciences*. – 2022. – Т. 12, №4. // <https://www.mdpi.com/2076-3417/12/4/1961>
7. Brito, E. D. M. Және т. Б. Innovations in virtual and augmented reality: Transforming organizational culture management for the 21st century // *Interconnections of Knowledge: Multidisciplinary Approaches*. – 1-е басылым. – Seven Editora, 2024. // <https://sevenpublicacoes.com.br/index.php/editora/article/view/4652>

Білім берудегі жасанды интеллект

Оразай Ә. Н.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

Email: aliorazai04@gmail.com

Сарсембаева Т.С.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Қазіргі уақытта жасанды интеллект (ЖИ) технологиялары білім беру саласында кеңінен қолданылуда. Бұл технологиялар оқыту процесін жекелендіруге, білім алушылардың қажеттіліктеріне сәйкес икемдеуге және білім сапасын жақсартуға мүмкіндік береді. ЖИ-дің мүмкіндіктерін тиімді пайдалану білім беру жүйесінің дамуына серпін береді. Сонымен қатар, жасанды интеллект білім беру саласында оқу үдерісін автоматтандыруға және оқытушылардың жүктемесін азайтуға мүмкіндік береді. Жасанды интеллект көмегімен оқу материалдарын бейімдеу, оқушылардың үлгерімін бақылау және оқу үлгісін оңтайландыру жүзеге асырылады.

Цифрлық трансформацияның қарқынды дамуы білім беру жүйесіне де ықпал етуде. Жасанды интеллекттің білім беру саласындағы рөлі күн санап артып келеді. Қазіргі таңда адаптивті оқыту жүйелері, интеллектуалды оқыту ассистенттері және білім беру аналитикасы кеңінен қолданылуда. Жасанды интеллекттің бұл технологиялары білім беруді барынша тиімді және икемді етіп, әрбір білім алушыға жеке оқу траекториясын ұсынуға көмектеседі. Сонымен қатар, білім алушылардың білім деңгейін автоматтандырылған түрде анықтауға және қажетті қосымша ресурстарды ұсынуға мүмкіндік береді.

Жасанды интеллект негізіндегі адаптивті оқыту жүйелері білім алушылардың оқу үлгерімін талдап, олардың қабілеттеріне сәйкес білім беру бағдарламаларын бейімдейді. Мұндай жүйелер білім алушылардың әлсіз және күшті жақтарын анықтап, жеке ұсыныстар береді. Сонымен қатар, чат-боттар мен виртуалды оқыту көмекшілері студенттерге сұрақтарына жедел жауап беруге, күрделі тақырыптарды түсіндіруге көмектеседі. Мұндай жүйелер студенттерге оқу материалын жақсы меңгеруге және өз бетінше білім алуға мүмкіндік береді.

Білім беру аналитикасы деректерді талдау арқылы студенттердің үлгерімін болжауға және оқу үдерісін оңтайландыруға көмектеседі. Университеттер мен мектептер осы аналитиканы пайдалана отырып, оқу бағдарламаларын жетілдіре алады. Сонымен қатар, жасанды интеллект арқылы автоматтандырылған бағалау жүйелері оқу үлгерімін объективті бағалауға мүмкіндік береді, бұл оқытушылардың жүктемесін азайтады. Сонымен қатар, жасанды интеллект көмегімен виртуалды зертханалар мен модельдеу құралдары жасалып, студенттерге практикалық дағдыларды меңгеруге жағдай жасайды. Бұл әсіресе техникалық және медициналық мамандықтарда оқитын студенттер үшін өте маңызды.

Жасанды интеллект білім беру жүйесін жетілдірудің қуатты құралы болып табылады. Оның көмегімен оқу үдерісін жекелендіру, студенттердің білім алу сапасын жақсарту және оқытушылардың жұмысын жеңілдету мүмкін болады. Жасанды интеллектті тиімді пайдалану білім беру сапасын жақсартуға, білім алушылардың қызығушылығын арттыруға және оқу процесінің нәтижелілігін жоғарылатуға ықпал етеді. Алдағы уақытта ЖИ технологияларын білім беру жүйесіне кеңінен енгізу оқу сапасын арттырудың негізгі бағыттарының бірі болмақ. Сонымен қатар, ЖИ көмегімен қашықтықтан білім беру жүйесі жетілдіріліп, студенттерге оқу процесіне икемділік пен ыңғайлылық беріледі. Бұл білімге қолжетімділікті арттырып, инклюзивті білім беруді дамытуға ықпал етеді.

Пайдаланылған әдебиеттер тізімі:

1. Luckin, R. (2017). "Artificial Intelligence and Education: Promises and Implications for Teaching and Learning."

2. Holmes, W., Bialik, M., & Fadel, C. (2019). "Artificial Intelligence in Education: Promises and Implications for Teaching and Learning."
3. Сарсенбаев, А. (2021). "Цифрлық білім беру және жасанды интеллект."
4. Huang, R., Spector, J. M., & Yang, J. (2019). "Educational Technology: A Guide to Artificial Intelligence Applications."
5. Шарипов, Б. (2022). "Жасанды интеллект және оның білім беру жүйесіндегі рөлі."

Виртуалды модельді қолдана отырып, кәсіпорын жұмысының симуляциялық модельдерін құру және талдау

Орынбек Б.Б.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

Email: baimoshorynbek@gmail.com

Зиятбекова Г.З.

Әл-Фараби атындағы ҚазҰУ, PhD, доцент м.а

Қазіргі заманғы өндірістік кәсіпорындар өздерінің тиімділігін арттыру мен шығындарды қысқарту мақсатында цифрлық технологияларды белсенді енгізуде. Өндірістік процестердің күрделілігі мен нарықтық жағдайлардың тұрақсыздығы нақты сынақтарды жүргізуді қиындатады, сондықтан виртуалды модельдерді қолдану – өндірістік жүйелерді сандық ортада симуляциялаудың озық әдісі болып табылады [1]. Бұл тәсіл кәсіпорындарға әртүрлі сценарийлерді алдын ала тексеріп, нақты деректер негізінде басқарушылық шешімдер қалыптастыруға мүмкіндік береді.

Симуляциялық модельдеу әдісі өндірістік желілердің, материалдық ағындардың және логистикалық процестердің жұмысын кешенді түрде зерттеуге жағдай жасайды. Виртуалды модельдер өндірістік объектілердің сандық көшірмесін жасап, олардың жұмысын егжей-тегжейлі бейнелейді. Осы арқылы өндірістік ақауларды алдын ала болжау, жабдықтардың техникалық күйін үздіксіз бақылау және ресурстарды тиімді бөлу мүмкіндігі артады. Сонымен бірге, өндірістік процестердің оңтайландыру мақсатында нақты уақыттағы деректерді жинау мен автоматтандырылған басқару жүйелерімен интеграция ұсынылатын әдіс болып табылады [2]. Физикалық жүйелермен үйлестіруді қамтамасыз ету үшін «The Executable Digital Twin» тұжырымдамасы [3] ұсынылады, ол цифрлық және физикалық әлемдерді біріктіру арқылы өндірістік процестердің нақты жұмысын дәл модельдеуге мүмкіндік береді. Мұндай тәсіл жабдықтардың техникалық күйін үздіксіз бақылауға, материалдық ресурстарды тиімді бөлуге және логистикалық операцияларды жетілдіруге ықпал етеді. Өндірістік желілердің икемділігі артып, кәсіпорындар өзгермелі нарықтық талаптарға тез жауап бере алады.

Цифрлық егіздер мен интеграцияланған басқару жүйелерінің қолданылуы кәсіпорындардың өндірістік тиімділігін арттырумен қатар, стратегиялық жоспарлау мен ресурстарды үнемді пайдалануда жаңа мүмкіндіктер ашады. Өндірістік шешімдерді нақты уақыттағы деректер негізінде қабылдау арқылы бизнес-процестердің икемділігі артып, өндірістік шығындар азаяды. Болашақта осы технологияларды одан әрі жетілдіру кәсіпорындардың бәсекеге қабілеттілігін күшейтіп, инновациялық өндірістік экожүйенің дамуына ықпал етпек.

Пайдаланылған әдебиеттер тізімі:

1. Ahsan, M. M., Liu, Y., Raman, S., & Siddique, Z. (2024). Digital Twins in Additive Manufacturing: A Systematic Review. arXiv preprint arXiv:2409.00877. <https://arxiv.org/abs/2409.00877>
2. Fu, Y., Downey, A. R. J., Yuan, L., & Huang, H. T. (2025). Simulation-in-the-loop additive manufacturing for real-time structural validation and digital twin development. Additive Manufacturing, 98(2), 104631. https://www.researchgate.net/publication/387804990_Simulation-in-the-loop_additive_manufacturing_for_real-time_structural_validation_and_digital_twin_development
3. Van der Auweraer, H., & Hartmann, D. (2022). The Executable Digital Twin: Merging the Digital and the Physics Worlds. arXiv preprint arXiv:2210.17402. <https://arxiv.org/abs/2210.17402>

Құрылыс нысандарына арналған өлшемдерді қашықтықтан танытын камера қолданатын интеллектуалды жүйе құру

Өскенбаев С.Т.

*Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр
E-mail: oskenbaevsultan7@gmail.com*

Асет А.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Объектілерді, олардың өлшемдерін және қашықтықтарын анықтайтын камера» компьютерлік көру саласындағы заманауи технологияларды қамтиды, олар камераларға тек объектілерді суретте анықтап қана қоймай, олардың өлшемдерін және оларға дейінгі қашықтықты дәл өлшеуге мүмкіндік береді. Мұндай камераларға негізделген жүйелер әртүрлі салаларда кеңінен қолданылады, соның ішінде автономды көлік құралдары, робототехника, қауіпсіздік жүйелері және медициналық диагностика.

Компьютерлік көру және жасанды интеллект технологияларының дамуы суреттер мен бейнелерді өңдеу мүмкіндіктерін айтарлықтай жақсартты, бұл камералардың әртүрлі өмір салаларында қолданылуына жаңа мүмкіндіктер ашты. Объектілерді тану, олардың өлшемдері мен қашықтықтарын анықтау мүмкіндігі бар камералардың ерекше маңызға ие болатын негізгі салалардың бірі — автономды көлік құралдары, робототехника, қауіпсіздік және медицина салаларында интеллектуалды жүйелерді құру болып табылады.

1. Компьютерлік көру алгоритмдері: Камералар объектілерді суреттерде тану және классификациялау үшін, мысалы, терең нейрондық желілер (CNN) сияқты алгоритмдерді қолданады.

2. Машиналық оқыту және нейрондық желілер: Камераларды объектілерді және олардың өлшемдерін тануға үйрету үшін үлкен деректер көлемі негізінде қолданылады.

3. Тереңдік камералары: Инфрақызыл датчиктері бар камералар, олар тереңдік картасын құрып, объектілерге дейінгі қашықтықты өлшеуге мүмкіндік береді.

Қазіргі заманғы объектілерді, олардың өлшемдерін және қашықтықтарын анықтайтын камералар әртүрлі салаларда елеулі жетістіктерге жетті. Автономды көлік құралдарында бұл камералар объектілерге дейінгі қашықтықты дәл өлшеп, апаттардың алдын алуға көмектеседі. Робототехникада олар объектілермен манипуляцияларды дәл орындауды қамтамасыз етеді, ал медицинада — дәрігерлерге ауруларды диагностикалау үшін бейнелерді талдауға көмектеседі.

Объектілерді, олардың өлшемдерін және қашықтықтарын анықтайтын камералар қазіргі заманда әртүрлі салаларда маңызды рөл атқарады, дәлдік пен қауіпсіздікті қамтамасыз етеді. Олар автономды көлік құралдарында, робототехникада, медицинада және басқа да көптеген салаларда қолданылады, мұнда объектілердің өлшемдерін және олардың кеңістіктегі орнын жылдам және дәл анықтау қажет. Компьютерлік көру технологияларының дамуы мен басқа сенсорлармен интеграция жасау осындай жүйелердің функционалдығын жақсартуға жаңа мүмкіндіктер ашады. Болашақта деректерді өңдеу дәлдігі мен жылдамдығының әрі қарай жақсаруы және осындай камералардың қолдану аясын кеңейту күтілуде.

Пайдаланылған әдебиеттер тізімі:

1. Захаров, В. С. (2020). Компьютерное зрение и обработка изображений. Москва: Научное издательство.

2. Шмидт, Т. (2019). Основы компьютерного зрения: алгоритмы и приложения. Санкт-Петербург: Питер.

3. Фредриксон, К. В. (2021). Технологии и методы глубинного зрения для автономных транспортных средств. Журнал "Автономные системы", 12(4), 34-45.

4. Иванов, А. И., Кузнецова, И. А. (2018). Стереозрение и его применение в робототехнике. Журнал "Робототехника и искусственный интеллект", 15(2), 78-84.

Науқастардың жағдайын нақты уақыт режимінде бақылау үшін IoT технологияларын қолданатын смарт палатаны әзірлеу

Өскенбаева А.А.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: oskenbaeva2003@gmail.com

Сарсембаева Т.С.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Бұл зерттеу IoT (Интернет заттар) технологияларын қолдана отырып, науқастардың жағдайын нақты уақыт режимінде бақылауға мүмкіндік беретін смарт палата жүйесін әзірлеуге бағытталған. Жүйе түрлі сенсорлар мен медициналық құрылғылар арқылы пациенттің жүрек соғысы, қан қысымы, дене температурасы және басқа да маңызды көрсеткіштерін үздіксіз бақылайды. Алынған деректер медициналық персонал мен емдеуші дәрігерлерге мобильді қосымша немесе веб-платформа арқылы қолжетімді болады, бұл жедел шешім қабылдауға және шұғыл медициналық көмек көрсетуге мүмкіндік береді. Жүйе медициналық мекемелердегі жұмыс тиімділігін арттырып, науқастардың жағдайын бақылауды автоматтандыруға ықпал етеді.

Қазіргі заманғы медицинада пациенттердің жағдайын нақты уақыт режимінде бақылау – емдеу тиімділігін арттырудың маңызды факторы. Бұл мәселені шешу үшін IoT (Internet of Things) технологияларын қолдану арқылы смарт-палаталар әзірленуде. Смарт-палата пациенттердің өмірлік көрсеткіштерін (жүрек соғысы, қан қысымы, дене температурасы, оттегі деңгейі және қозғалыс белсенділігі) үздіксіз бақылауға мүмкіндік беретін датчиктермен жабдықталады. Жиналған деректер автоматтандырылған жүйе арқылы өңделіп, медициналық персоналға нақты уақыт режимінде жеткізіледі. Бұл жүйе дәрігерлерге пациенттің жағдайындағы кез келген өзгерістерді ерте анықтауға, жедел әрекет етуге және медициналық көмектің сапасын жақсартуға мүмкіндік береді. Осы зерттеу жұмысы IoT негізіндегі смарт-палатаның құрылымы, жұмыс істеу принциптері және оның денсаулық сақтау саласындағы маңыздылығын талдауға бағытталған.

Температура және ылғалдылық сенсорлары – палата ішіндегі климаттық жағдайларды бақылап, науқастың жайлылығын қамтамасыз ету.

Жүрек соғысы және қан қысымы сенсорлары – науқастың негізгі өмірлік көрсеткіштерін үздіксіз бақылап, денсаулығы туралы мәлімет береді.

Қимыл және орналасу сенсорлары – науқастың қозғалысын бақылап, оның төсекке жату ұзақтығын анықтап, аурухана қызметкерлеріне қажетті ақпарат береді.

Оттегі деңгейін анықтайтын сенсорлар – тыныс алу жүйесінің жағдайын бағалап, ауадағы оттегі мөлшерін бақылап, тыныс алу функцияларын жақсартады.

Смарт палата жүйесі науқастардың денсаулығын бақылау үшін заманауи IoT технологияларын тиімді қолдануға мүмкіндік береді. Әр түрлі сенсорлар арқылы температура, ылғалдылық, жүрек соғысы, қан қысымы және оттегі деңгейі сияқты маңызды көрсеткіштер нақты уақыт режимінде бақылауға алынады. Бұл жүйе дәрігерлер мен медициналық қызметкерлерге науқастардың жағдайын уақытылы бағалап, қажетті медициналық шараларды қабылдауға мүмкіндік береді. Сонымен қатар, жүйенің дәлдігі мен сенімділігі жоғары деңгейде, бұл медициналық мекемелерде денсаулық сақтау қызметінің сапасын арттыруға септігін тигізеді. Жобаның болашақта басқа ауруханалар мен медициналық орталықтарға енгізілуі, сондай-ақ одан әрі жетілдірілуі күтілуде.

Науқастардың жағдайын нақты уақыт режимінде бақылау үшін IoT технологияларын қолданатын смарт палата жүйесі дәрігерлерге шұғыл шешімдер қабылдауға, емдеуді тиімді жүргізуге және пациенттердің қауіпсіздігі мен жайлылығын қамтамасыз етуге мүмкіндік береді. Бұл жүйе денсаулық сақтау мекемелерінің жұмысын оңтайландырып, ресурстарды тиімді пайдалануға көмектеседі. Болашақта оның мүмкіндіктері кеңейіп, медициналық

қызметтерді жақсартуға ықпал етеді.

Пайдаланылған әдебиеттер тізімі:

1. Zhang, X., & Lee, H. (2017). "The Internet of Things in Healthcare: Opportunities and Challenges". *Journal of Medical Systems*, 41(6), 1-10.
2. Patel, V., & Kumar, R. (2020). "IoT-Based Smart Healthcare Systems: A Review". *International Journal of Health Information Systems and Informatics*, 15(4), 33-45.
3. Sharma, N., & Gupta, R. (2019). "The Role of IoT in Smart Hospitals". *International Journal of Advanced Research in Computer Science*, 10(5), 78-84.
4. Chen, M., & Zhang, Y. (2020). "Smart Health Monitoring Systems Using IoT". *Proceedings of the International Conference on Smart Systems and Technologies*, 12(2), 122-130.
5. Hossain, M. S., & Muhammad, G. (2018). "Cloud-Assisted Industrial Internet of Things (IIoT) - Enabled Framework for Smart Healthcare Systems". *IEEE Access*, 6, 15198-15206.

Применение кластерного анализа для интеллектуального управления ветроэнергетическими системами

Пазилханов А.И.

Казахстанско-Британский технический университет

E-mail: a_pazilkhanov@kbtu.kz

Бисембаев А.С.

Казахстанско-Британский технический университет, PHD Associate Professor

E-mail: a.bisembaev@kbtu.kz

Развитие ветроэнергетики как одного из ключевых направлений возобновляемой энергетики сопровождается необходимостью внедрения интеллектуальных методов управления. Основной проблемой при эксплуатации ВЭС остаётся нестабильность генерации, вызванная изменчивостью погодных условий. Это требует разработки решений, способных адаптивно перераспределять энергопотоки в реальном времени.

Целью данного исследования является применение кластерного анализа для классификации режимов работы ветроэнергетических установок (ВЭС) и построения алгоритма интеллектуального управления распределением энергии. В работе использован набор данных, включающий скорость ветра, активную и теоретическую мощность, а также направление ветра. С помощью метода локтя и коэффициента силуэта определено оптимальное количество кластеров ($K = 4$), после чего алгоритмом K-Means выполнено разбиение режимов работы на четыре характерные группы.

На основе кластеров разработан алгоритм управления, предусматривающий принятие решений в зависимости от текущих условий: подключение резервных источников при низкой генерации, зарядка аккумуляторов и водородных хранилищ при избытке энергии и т.д. Реализация модели осуществлена на языке Python с использованием библиотек Pandas, Scikit-learn и Matplotlib. Построены графики кластеров, уровней заряда накопителей и соответствующие тренды.

Анализ литературы показывает, что методы кластеризации широко применяются в энергетике. В работе Bessa et al. [1] описан подход к краткосрочному прогнозированию ветровой генерации с применением вероятностных моделей. В исследовании Kusiak et al. [2] применяются алгоритмы машинного обучения для предсказания мощности ветра. Работа Zameer et al. [3] предлагает архитектуру интеллектуальной системы прогнозирования с использованием кластеризации и нейросетей. Esen et al. [4] рассматривают интеграцию кластерного анализа в гибридные энергетические системы, включая солнечную и ветровую генерацию. В исследовании Ding et al. [5] показано, как кластеризация может быть использована для анализа надежности и устойчивости ВЭС на больших временных интервалах.

В отличие от указанных работ, в настоящем исследовании кластеризация используется не только для анализа или прогнозирования, но и как основа для формирования алгоритма оперативного управления энергопотоками, что составляет его научную и практическую новизну.

Предложенная методика может быть дополнена средствами прогнозирования (LSTM, ARIMA), расширена на гибридные установки (ВЭС + СЭС) и адаптирована под экономические параметры.

Список использованной литературы:

1. Bessa, R. J., Miranda, V., Botterud, A., Wang, J., & Constantinides, G. (2014). *Time adaptive quantile-copula for wind power probabilistic forecasting*. *Renewable Energy*, 66, 532–543.
2. Kusiak, A., Zheng, H., & Song, Z. (2009). *Short-term prediction of wind farm power: A data mining approach*. *IEEE Transactions on Energy Conversion*, 24(1), 125–136.

3. Zameer, A., Khan, Z. A., Ahmad, J., & Wani, M. A. (2020). *Intelligent and robust prediction of short-term wind power using empirical mode decomposition and ensemble learning*. *Energy*, 193, 116831.
4. Esen, V., Ozerdem, B., & Aksoy, M. H. (2021). *Hybrid renewable energy systems integrated with smart grid: Recent developments and challenges*. *Renewable and Sustainable Energy Reviews*, 146, 111127.
5. Ding, M., Zhang, Y., Wang, W., & Wu, J. (2022). *Clustering-based analysis of long-term performance and reliability of wind turbines*. *Applied Energy*, 310, 118528.

Қазақ тіліндегі мәтіндерді өңдеу үшін retrieval-augmented generation (rag) әдістерін қолданудың тиімділігін бағалау

Полатбек Е.А.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: polatbek0120@gmail.com

Оспан Ә.Ғ.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Бұл жұмыстың негізгі мақсаты – сыртқы ақпарат көздерінен қажет деректерді динамикалық түрде тартып, қазақ тіліндегі мәтіндермен жұмыс істейтін үлкен тілдік модельдердің (LLM) дәлдігі мен сенімділігін арттыру. Осы арқылы ресурсы шектеулі тілдер санатындағы қазақ тілінің цифрлық ортада кеңінен қолданылуына ықпал ету көзделеді. Бүгінгі күні қазақ тілі үшін жеткілікті ауқымды, сапалы аннотацияланған мәліметтер базасының болмауы NLP шешімдерінің дамуын тежеп отыр. Осы шектеулерді айналып өту үшін Retrieval-Augmented Generation (RAG) әдістері ұсынылады. RAG технологиясы модельдің жалған ақпарат (галлюцинация) қалыптастыру қаупін төмендетіп, контекстке байланысты қажетті мәліметті тез әрі нақты алуға мүмкіндік береді. Бұл әсіресе мемлекеттік және білім беру салаларында мемлекеттік тілді цифрландыру жұмыстары үшін өте маңызды болып саналады, себебі үлкен деректерді қолмен аннотациялау өте көп уақыт пен шығынды талап етеді [1].

Ғылыми жұмыстың мақсатына қол жеткізу үшін мынадай міндеттер қойылады:

- RAG негізінде қазақ тіліне бейімделген деректерді динамикалық іздеу мен өңдеу тәсілдерін әзірлеу;
- DRAGIN, DRAGON-AI, INFO-RAG, M-RAG және RADA сияқты заманауи әдістерді қазақ мәтіндеріне бейімдеп, олардың дәлдігі мен тиімділігін салыстырмалы түрде бағалау [2][3];
- Жалған ақпараттардың таралу қаупін төмендету үшін сыртқы деректерді дәл әрі сенімді өңдеу алгоритмдерін зерттеу;
- Қолданыстағы модельдердің өнімділігін BLEU, ROUGE, Perplexity және Accuracy сияқты метрикалар арқылы бағалап, ресурстарға жұмсалатын шығындарды салыстыру.

Жұмысты іске асыру үшін төрт негізгі қадам қарастырылды. Біріншіден, қазақ тіліндегі мәтіндерді өңдеу мақсатында бастапқы деректерді жинау және алдын ала сұрыптау жүргізіледі. Мәселен, ашық қолжетімді корпустар мен веб-ресурстардан алынған мәтіндердің грамматикалық ерекшеліктері ескеріле отырып, қайталанатын немесе сапасыз үлгілер жойылады. Екіншіден, DRAGIN (динамикалық деректер тартып алу) және DRAGON-AI (онтология құру) сияқты әдістер қазақ тілін қолдауға бейімделеді; бұл кезеңде модельдердің нақты сұраныстарға жауап бере алуы үшін арнайы токенизация және морфологиялық талдау алгоритмдері жетілдіріледі [4]. Үшінші қадамда, INFO-RAG және M-RAG тәрізді әдістердің деректерді нақтылау және бірнеше деректер базаларын бөлікке бөліп алу мүмкіндіктерін қолдану арқылы модельдің жұмыс сапасы зерттеледі. Мысалы, M-RAG құрылымы үлкен мәліметтерді бірнеше бөлшекке жіктеп, тек қажетті фрагменттерді динамикалық түрде іске қосу арқылы модельдің есептеу жүктемесін азайтып, дәлдік көрсеткішін 8–12% арттыруға көмектеседі [5]. Төртінші кезеңде BLEU, ROUGE және Perplexity тәрізді метрикалар арқылы өнімділік бағаланады, сондай-ақ әрбір әдістің есептеу ресурстарының жұмсалуды мен экономикалық тиімділігі салыстырылады.

Осы зерттеу нәтижесінде қазақ тіліндегі NLP модельдерінің жалған ақпарат туғызу ықтималдығы азайып, сөйлемдер мен мәтіндердің сапасы артады деп күтілуде. Бұл қазақ тілінде машиналық аударма, мәтіндік талдау және мазмұн генерациясы секілді салаларда инновациялық шешімдердің дамуына жол ашуы мүмкін. Сонымен қатар, мемлекеттік органдар мен білім беру мекемелері шектеулі қаржы және уақыт ресурстарын үнемдей

отырып, цифрлық экожүйеде ана тілін жан-жақты қолдануды қамтамасыз ете алады. Нәтижесінде, RAG әдістерінің енгізілуі қазақ тілінің ақпараттық кеңістікте тиімді пайдаланылуына айтарлықтай үлес қосады.

Пайдаланылған әдебиеттер тізімі:

1. Lee, J., Cha, H., Hwangbo, Y., & Cheon, W. (2024). Enhancing Large Language Model Reliability: Minimizing Hallucinations with Dual Retrieval-Augmented Generation. *Journal of Personalized Medicine*, 14(12), 1131. <https://doi.org/10.3390/jpm14121131>
2. Su, W., Tang, Y., Ai, Q., Wu, Z., & Liu, Y. (2024). DRAGIN: Dynamic Retrieval-Augmented Generation based on the Information Needs of Large Language Models. *Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics*, 12991–13013. <https://doi.org/10.18653/v1/2024.acl-long.725>
3. Toro, S., et al. (2024). Dynamic Retrieval-Augmented Generation of Ontologies using Artificial Intelligence (DRAGON-AI). *Journal of Biomedical Semantics*, 15, Article 19. <https://doi.org/10.1186/s13326-024-00320-3>
4. Xu, S., et al. (2024). Unsupervised Information Refinement Training of Large Language Models for Retrieval-Augmented Generation (INFO-RAG). *Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics*, 133–145. <https://doi.org/10.18653/v1/2024.acl-long.9>
5. Wang, Z., Teo, S. X., Ouyang, J., Xu, Y., & Shi, W. (2024). M-RAG: Reinforcing Large Language Model Performance through Retrieval-Augmented Generation with Multiple Partitions. *Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics*, 1966–1978. <https://doi.org/10.18653/v1/2024.acl-long.109>

Deepfake және этикалық мәселелер

Райымбергенов Б.Т.

ал-Фараби атындағы ҚазҰУ, 1 курс бакалавриат

Бедельбаев А.А.

ал-Фараби атындағы ҚазҰУ, профессор м.а.

Deepfake – жасанды интеллект (ЖИ) және генеративті қарсы желілер (GANs) көмегімен адамның бейнесін, дауысын және мимикасын өзгертуге мүмкіндік беретін технология. Бұл әдіс медиа индустриясында пайдалы болуы мүмкін, бірақ ақпараттық қауіпсіздік, алаяқтық және жалған ақпарат тарату мәселелерін туындатып отыр. IT мамандары үшін deepfake-тің таралуына қарсы күресу маңызды міндетке айналды. Бұл мақалада deepfake технологиясының жұмыс принциптері, оны анықтау әдістері және ақпараттық қауіпсіздік саласындағы шешімдер қарастырылады.

Deepfake – бүгінгі таңда IT мамандары үшін ең күрделі технологиялық және этикалық мәселелердің бірі. Бұл технология генеративті қарсы желілер (GANs) арқылы сурет, видео және аудио деректерін өңдеу арқылы шынайы көрінетін жалған материалдар жасайды.

Қазіргі уақытта deepfake келесі салаларда кеңінен қолданылуда: • Ойын-сауық және киноиндустрия – CGI технологияларын алмастыру және актерлердің жас кезіндегі бейнесін қайта құру үшін.

- Маркетинг және жарнама – брендтер танымал тұлғалардың deepfake бейнелерін қолдана алады.

- Киберқауіпсіздік және қауіптер – deepfake технологиясы алаяқтық, кибершантаж және жалған ақпарат тарату үшін пайдаланылады.

IT мамандары deepfake-ті анықтау және оның зиянды әсерін азайту үшін түрлі әдістерді әзірлеуде. Осы мақалада deepfake-тің техникалық қырлары мен онымен күресудің жолдары қарастырылады.

Deepfake технологиясы GANs (Generative Adversarial Networks) негізінде жұмыс істейді. Бұл әдіс екі нейрожелінің бәсекелестігіне сүйенеді:

- Генератор – шынайы көрінетін жалған бейне немесе аудионы жасайды.
- Дискриминатор – жасалған контенттің түпнұсқалығын тексереді.

Бұл процестің арқасында deepfake бейнелері мен аудиолары уақыт өте келе шынайыға жақындай түседі.

Deepfake жасау кезеңдері

1. Деректер жинау – адамның суреттері, видеолары немесе дауыстық үлгілері өңделеді.

2. Машиналық оқыту – GANs нейрожелісі алынған деректер негізінде жаңа бейнелер құрастырады.

3. Генерация және ретушь – алынған нәтиже шынайы көрінуі үшін қосымша өңдеулер енгізіледі.

IT мамандары үшін deepfake тек технологиялық жетістік қана емес, сонымен қатар ақпараттық қауіпсіздікке қатер төндіретін құрал. Оның негізгі қауіптері мыналар:

Deepfake жалған жаңалықтар мен ақпараттық шабуылдар үшін кеңінен қолданылады. Саяси манипуляциялар, жалған мәлімдемелер мен беделді тұлғаларға жала жабу deepfake көмегімен оңай жүзеге асырылады. Deepfake технологиясы алаяқтық және әлеуметтік инженерия шабуылдары үшін қолданылады.

- Финанс саласында – deepfake арқылы жалған бейнеқоңыраулар мен дауыстық хабарламалар жасалып, адамдардан ақша талап етіледі.

- Киберқауіпсіздікке қауіп – deepfake арқылы идентификация жүйелерін бұзу мүмкіндігі артуда.

Deepfake көмегімен жеке адамдардың жалған бейнелерін жасау және оларды шантаждау жағдайлары жиілеп келеді. Бұл этикалық тұрғыда үлкен мәселе туғызады. IT мамандары

deepfake-ке қарсы күрес үшін арнайы алгоритмдер мен нейрожелілер әзірлеуде.

Deepfake анықтаудың негізгі әдістері

1. Жасанды интеллект пен нейрожелілер – deepfake видеолардағы аномалияларды анықтау үшін қолданылады.

2. Көз жыпылықтау талдауы – Deepfake бейнелерінде адамның көз жыпылықтауы табиғи емес болады.

3. Бет симметриясын талдау – GANs арқылы жасалған бейнелерде бет симметриясы мен жарық көлеңкелері сәйкессіздік көрсетуі мүмкін.

4. Формальды верификация құралдары – Facebook, Microsoft, Google сынды компаниялар deepfake-ті автоматты түрде анықтайтын жүйелер жасап жатыр.

Deepfake-ке қарсы қорғаныс құралдары

- Медиа және әлеуметтік желі платформалары deepfake детекциясын енгізуде.

- Цифрлық қолтаңба және верификация әдістері deepfake арқылы өзгертілген бейнелерді анықтау үшін қолданылады.

- OpenAI және басқа да зерттеу ұйымдары deepfake-ке қарсы алгоритмдер жасап шығаруда.

Deepfake технологиясын құқықтық тұрғыдан реттеу қажет.

- Қазақстанда deepfake қолдану заңмен нақты реттелмеген, бірақ ҚР Қылмыстық кодексінің 190-бабы (алаяқтық) және «Дербес деректерді қорғау туралы» заң deepfake қолданушыларға қарсы шара қолдануға мүмкіндік береді.

- АҚШ пен Еуропа елдерінде deepfake заңсыз мақсатта пайдаланылған жағдайда қылмыстық жауапкершілік қарастырылады.

Deepfake – технологиялық жетістік болғанымен, оның ақпараттық қауіпсіздікке, қаржылық тұрақтылыққа және әлеуметтік тұрақтылыққа әсері өте үлкен. Сондықтан IT мамандары deepfake-ке қарсы автоматтандырылған детекция құралдарын жасап, жалған ақпарат таратуға қарсы күресті күшейтуі қажет.

Пайдаланылған әдебиеттер тізімі:

1. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative Adversarial Nets. NeurIPS.

2. Mirsky, Y., & Lee, W. (2021). The Creation and Detection of Deepfakes: A Survey. ACM Computing Surveys, 54(1), 1–41.

3. Farid, H. (2019). Digital Forensics in a Post-Truth Age. Journal of Law and Policy, 28(1), 123–138.

4. Қазақстан Республикасының Қылмыстық кодексі (2014 жылғы 3 шілде).

5. Қазақстан Республикасының «Ақпараттандыру туралы» заңы (2015 жылғы 24 қараша).

6. Deepfake Detection Challenge (DFDC). (2020). Facebook AI, Microsoft, and Partnership on AI's Initiative for Deepfake Identification.

Машиналық оқыту әдістерін қолдану арқылы кескіндерді сығу технологияларын жетілдіру

Сабурова Н.Б.

Әл-Фараби атындағы ҚазҰУ, лаборант

Email: nesibelisaburova9@gmail.com

Қазіргі ақпараттық технологиялар дәуірінде цифрлық кескіндер күнделікті өмірде кеңінен қолданылады. Олардың көлемі үлкен болғандықтан, сақтау және тасымалдау кезінде тиімді сығу әдістерін қолдану қажеттілігі туындайды. Дәстүрлі кескін сығу алгоритмдері (мысалы, JPEG, PNG, WebP) ұзақ уақыт бойы қолданылып келеді, алайда олар кейбір шектеулерге ие. Осыған байланысты машиналық оқыту әдістерін қолдану арқылы кескіндерді сығудың жаңа тәсілдері зерттелуде.[1]

Бұл жұмыста машиналық оқыту технологияларын пайдалану арқылы кескіндерді сығу әдістерін жетілдіру мәселесі қарастырылады. Жасанды интеллект (ЖИ) және нейрондық желілер негізінде кескіндерді сығу тәсілдерінің артықшылықтары мен мүмкіндіктері зерттеліп, олардың дәстүрлі әдістермен салыстырмалы талдауы жүргізіледі.

Кескіндерді сығу – бұл олардың өлшемін азайту үшін қолданылатын арнайы алгоритмдер жиынтығы. Бұл әдістер жоғалтусыз (lossless) және жоғалтумен (lossy) сығу түрлеріне бөлінеді.

• Жоғалтусыз сығу әдістері:

- Run-Length Encoding (RLE)
- Huffman Coding
- Lempel-Ziv-Welch (LZW)
- PNG форматы

• Жоғалтумен сығу әдістері:

- Discrete Cosine Transform (DCT) – JPEG
- Wavelet Transform – JPEG2000
- WebP форматының гибридті сығу тәсілі[2]

Бұл әдістердің тиімділігі жоғары болғанымен, жоғары сығу коэффициентінде кескін сапасының төмендеуі немесе есептеу ресурстарының көп жұмсалыуы секілді кемшіліктері бар.

Машиналық оқыту және нейрондық желілер кескіндерді сығудың жаңа тиімді жолдарын ұсынады. Олардың ішінде ең танымал әдістер:

• Автоэнкодерлер (Autoencoders)

○ Өзіндік ұйымдастыру қабілеті арқылы мәліметтердің маңызды сипаттамаларын сақтай отырып, кескіндерді ықшамдайды.

○ Variational Autoencoders (VAE) – ықтималдық негізіндегі мәліметтерді сығу.

• Генеративті қарсыластар желілері (GANs)

○ Жоғары сапалы кескіндерді қайта қалпына келтіруде тиімді.

○ Стандартты әдістерге қарағанда кескін сапасын жақсы сақтай алады.

• Конволюциялық нейрондық желілер (CNN)

○ Кескіндердегі маңызды элементтерді ажырата отырып, ақпараттарды жоғалтпай тиімді қысу.

○ Google DeepMind ұсынған Deep Image Compression моделі сияқты озық технологиялар.

Машиналық оқыту негізіндегі кескін сығу технологияларының артықшылықтары:

• **Сығу коэффициентінің жоғары болуы** – дәстүрлі әдістермен салыстырғанда мәліметтерді ықшамдауда тиімдірек.

• **Сапаның сақталуы** – кескін сапасын жоғалтпай жоғары қысу мүмкіндігі.

• **Тиімді есептеу ресурстарын пайдалану** – үлкен деректерді өңдеуде оңтайлы шешімдер.

- **Жылдамдық** – сығу және декомпрессия процестерінің жоғары жылдамдықта орындалуы.[3]

Медицинадағы кескіндерді өңдеуге машиналық оқыту әдістерін қолдану

- **Медициналық кескіндерді сығу:** Рентген, МРТ, КТ сияқты жоғары ажыратымдылықтағы медициналық кескіндерді сақтау мен тасымалдау үшін автоэнкодерлер және GANs технологиялары қолданылады. Бұл әдістер кескін сапасын жоғалтпай тиімді қысуды қамтамасыз етеді.

- **Диагностикалық жүйелер:** Машиналық оқыту алгоритмдері арқылы сығылған кескіндерден маңызды медициналық ақпараттарды сақтап, дәрігерлерге нақты диагноз қоюда көмектеседі. CNN негізінде өңделген кескіндер медициналық аномалияларды (мысалы, қатерлі ісік, ішкі ағзалардағы өзгерістер) дәл анықтауға мүмкіндік береді.

- **Телекоммуникациялық медицина:** Қашықтан диагностика жүргізу үшін медициналық кескіндерді жоғары жылдамдықта тасымалдау қажет. Машиналық оқыту негізінде сығылған кескіндер интернет арқылы тез жіберіліп, науқастардың нақты уақыттағы диагностикасын жақсартады.

- **Онкологиялық зерттеулер:** Онкологиялық кескіндерді өңдеуде GANs және Variational Autoencoders технологиялары қолданылып, ісіктерді жоғары дәлдікпен анықтауға мүмкіндік береді. Бұл қатерлі ісіктерді ерте кезеңде анықтау мүмкіндігін арттырады.

- **Хирургиялық робототехника:** Жасанды интеллект арқылы жоғары сапалы медициналық кескіндерді сығу, оларды нақты уақытта хирургиялық роботтарда пайдалану мүмкіндігін жақсартады. CNN және GANs арқылы өңделген кескіндер хирургиялық шешімдерді дәл әрі жылдам қабылдауға көмектеседі.[4]

Машиналық оқыту әдістері кескіндерді сығудың тиімділігін айтарлықтай арттырады. Бұл тәсілдер дәстүрлі алгоритмдермен салыстырғанда жоғары сапалы нәтижелер көрсете отырып, сақтау және тасымалдау шығындарын азайтуға мүмкіндік береді.

Зерттеудің нәтижелері көрсеткендей, жасанды интеллект көмегімен кескіндерді сығу әдістері болашақта ақпараттық технологиялардың түрлі салаларында кеңінен қолданылуы мүмкін. Алайда, бұл технологияларды дамыту барысында есептеу ресурстарының қажеттілігі, деректерді қалпына келтіру дәлдігі және алгоритмдердің жылдамдығы сияқты мәселелерді шешу қажет. Болашақ зерттеулерде нейрожелілік модельдердің тиімділігін одан әрі арттыру және оларды оңтайландыру басты мақсаттардың бірі болуы тиіс.[5]

Пайдаланылған әдебиеттер тізімі:

1. Гончаров М. Б., Иванов С. А. "Глубокие нейронные сети в обработке медицинских изображений." Вестник Московского государственного университета, 2018.

2. Петров В. Н., Сидоров А. Ю. "Методы сжатия изображений на основе машинного обучения." Компьютерная оптика, 2019.

3. Федоров Д. В., Смирнов А. Л. "Автоэнкодеры для сжатия медицинских изображений." Известия Российской академии наук. Теория и системы управления, 2020.

4. Кузнецов П. В., Михайлов И. А. "Использование сверточных нейронных сетей для анализа рентгеновских снимков." Журнал цифровой медицины, 2021.

5. Тихонов Р. П., Климов Д. В. "Современные методы обработки медицинских изображений с использованием искусственного интеллекта." Медицинская визуализация, 2020.

Үлкен тілдік үлгілер үшін қазақша мәтіндерді алдын ала өңдеу әдістерін әзірлеу

Сайлау А.Ж.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: sailauaisha@mail.ru

Оспан Ә.Ғ.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Бұл зерттеу қазақ тіліндегі мәтіндерді үлкен тілдік үлгілерге (LLM) бейімдеуге арналған алдын ала өңдеу әдістерін талдайды. Жұмыстың негізгі мақсаты – Stanford Alpaca негізінде қазақ тіліне арналған Self-Instruct әдісін пайдалана отырып, Instruction-Response үлгісін әзірлеу. Осы мақсатқа жету үшін қазақ тіліне тән лингвистикалық ерекшеліктер ескеріліп, деректерді жинау, сүзу, құрылымдау және өңдеу стратегиялары ұсынылады. Сонымен қатар, қазақ тіліне бейімделген үлкен тілдік үлгілерді жетілдіру үшін автоматтандырылған өзіндік нұсқаулықтар генерациялау әдістері қарастырылады. Алынған нәтижелер қазақ тіліне бейімделген тілдік модельдердің сапасын арттыруға және оларды тәжірибелік қолдану мүмкіндіктерін кеңейтуге ықпал етеді.

Үлкен тілдік үлгілер (LLM) табиғи тіл өңдеуде (NLP) үлкен жетістіктерге жеткенімен, қазақ тілі сияқты ресурстары шектеулі тілдер үшін бейімделу мәселелері өзекті болып қала береді. Қазіргі уақытта қазақ тілі үшін сапалы деректер жиынының тапшылығы, морфологиялық күрделілік және стильдік ерекшеліктер модель сапасына айтарлықтай әсер етеді. Бұл зерттеу қазақ тіліне бейімделген, Self-Instruct мүмкіндігі бар LLM әзірлеу үшін мәтінді алдын ала өңдеу әдістерін қарастырады.

Зерттеудің мақсаты – Stanford Alpaca негізінде қазақ тіліне арналған Self-Instruct мүмкіндігі бар тілдік үлгі жасау. Бұл модель қазақ тілінде жоғары сапалы Instruction-Response деректер жиындарын өңдеуге және генерациялауға мүмкіндік береді.

Үлкен тілдік үлгілер табиғи тіл өңдеуде кеңінен қолданылатын жасанды интеллект технологияларының бірі болып табылады. Қазақ тіліндегі мәтіндерді өңдеу үшін алдын ала дайындалған деректер жиыны қажет. Бұл зерттеуде Stanford Alpaca негізіндегі Self-Instruct әдісін қолдану арқылы қазақ тіліне бейімделген Instruction-Response құрылымы ұсынылады. Қазақ тілі морфологиясының ерекшеліктері мен синтаксистік құрылымдары модельді оқыту кезінде ескерілуі тиіс. Сонымен қатар, деректерді жинау және сүзу барысында тілдік ресурстардың жеткіліксіздігі мен стилистикалық әртүрлілік мәселелері қарастырылады.

Бұл зерттеуде бірнеше әдіс қолданылды:

- Деректерді жинау және сүзу – қазақ тіліндегі ашық қолжетімді мәтіндерден сапалы деректер жиынын құру.

- Мәтіндерді алдын ала өңдеу – морфологиялық талдау, грамматикалық қателерді түзету, стоп-сөздерді алып тастау.

- Self-Instruct әдісі – қазақ тіліндегі өздігінен нұсқаулықтар генерациялау арқылы үлгінің өзіндік оқытуын қамтамасыз ету.

- Модельді бағалау – BLEU, ROUGE және Perplexity метрикалары арқылы алынған нәтижелерді салыстыру.

Бұл зерттеу бірнеше маңызды артықшылықтарға ие:

- Қазақ тіліне арнайы бейімделу – қазіргі LLM модельдері көбінесе қазақ тіліне толыққанды бейімделмеген, ал бұл әдіс қазақша деректерді жүйелі түрде өңдеуге мүмкіндік береді.

- Self-Instruct әдісінің қолданылуы – автоматтандырылған өзіндік оқыту жүйесі қазақ тілі үшін жаңа жоғары сапалы нұсқаулықтар жасауға жол ашады.

- Деректер сапасын жақсарту – мәтінді алдын ала өңдеу әдістері қазақ тіліндегі қателерді азайтуға және NLP модельдерінің дәлдігін арттыруға көмектеседі.

• Тәжірибелік қолдану мүмкіндіктерінің кеңеюі – алынған модельді білім беру, мемлекеттік қызметтер, медиа және басқа да салаларда тиімді пайдалануға болады.

Пайдаланылған әдебиеттер тізімі:

1. Wang, Y., Kordi, Y., Mishra, S., Smith, N., & Khashabi, D. (2022). "Self-Instruct: Aligning Language Models with Self Generated Instructions". arXiv preprint arXiv:2212.10560.
2. Touvron, H., Lavril, T., Izacard, G., Martinet, X., Lachaux, M.-A., Lacroix, T., Rozière, B., Goyal, N., Hambro, E., Azhar, F., Rodriguez, A., Joulin, A., Grave, E., & Lample, G. (2023). "LLaMA: Open and Efficient Foundation Language Models". arXiv preprint arXiv:2302.13971.
3. Goyal, N., Azhar, F., & Khashabi, D. (2023). "LESS: Low-resource Language Model Evaluation and Self-improvement via Self-instruction". arXiv preprint arXiv:2304.08594.
4. Zhou, C., Palangi, H., Zhang, L., & Gao, J. (2023). "LIMA: Less Is More for Alignment". arXiv preprint arXiv:2305.11206.

Интеллектуальное речевое распознавание команд для удаленного управления распашными воротами

Самигуллаев Д.С.

Казну им Аль-Фараби, Студент 4 курса бакалавра

Email: danyalsamigullaev@mail.ru

Бельгибаев Б.А.

Доцент кафедры Искусственный Интеллект и Big Data

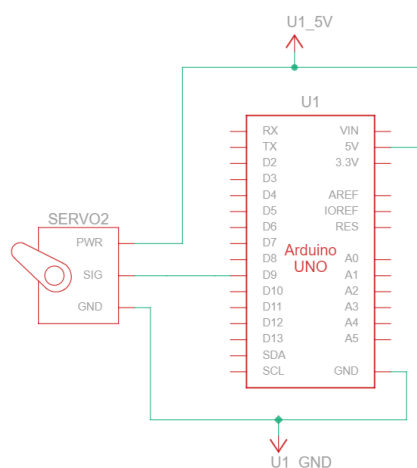
Интеллектуальное речевое распознавание команд актуальная и развивающиеся тема, внедряется во все современные системы умного дома (управление освещением, отоплением, воротами и.т.д), при голосовом управлении мультимедией и навигацией в автомобиле, управление роботами с помощью голосовых команд, чат боты, автоматизированные колл-центры и тому подобных примеров применения можно привести множество. В эпоху "умных домов" и IoT (Internet of Things) растёт спрос на бесконтактное управление устройствами.

В частности мой дипломный проект посвящен разработке интеллектуального речевого распознавания команд для удаленного управления распашными воротами. Основное внимание уделяется использованию технологий машинного обучения и обработки естественного языка для повышения точности распознавания голосовых команд. Ожидается, что система обеспечит удобство эксплуатации, повысит уровень безопасности и сократит необходимость в физических устройствах управления. Ручное открытие ворот неудобно, особенно в холодную погоду или при занятых руках (например, при въезде на автостоянку).

Система интеллектуального распознавания речевых команд для удаленного управления распашными воротами:

1. Микроконтроллер или мини-ПК (ESP32, Raspberry Pi, Arduino с голосовым модулем)
2. Модуль распознавания речи (Google Speech-to-Text API, Vosk, PocketSphinx)
3. Беспроводной интерфейс связи (Wi-Fi, Bluetooth, GSM)
4. Приводные механизмы ворот (сервоприводы, мотор-редукторы, гидравлические приводы)
5. Безопасность и контроль доступа (PIN-коды, голосовая авторизация, мобильное приложение).

Алгоритм работы: Пользователь произносит команду (например, "Открыть ворота"). Модуль распознавания речи обрабатывает аудиосигнал и преобразует его в текст. Алгоритм обработки команд сверяет текст с заданными командами. Контроллер передает сигнал на моторы ворот, открывая или закрывая их.



В данном рисунке приведена блок-схема упрощенная версия этой системы с МК Arduino UNO и сервоприводом.

Актуальность и преимущества:

Голосовое управление упрощает доступ, исключает необходимость носить брелоки или нажимать кнопки. Позволяет управлять воротами удалённо (например, с помощью смартфона через интернет). Люди с ограниченными возможностями (например, с нарушением зрения или подвижности) могут использовать голос вместо физических кнопок. Wi-Fi, Bluetooth, 4G/5G позволяют интегрировать голосовые команды в облачные сервисы, управлять. Интеллектуальные системы могут включать аутентификацию по голосу, что защищает от несанкционированного доступа. Можно использовать AI-фильтрацию, чтобы система реагировала только на владельца.

Классические системы используют простое распознавание ключевых слов (например, "открыть ворота"). Новые решения включают нейросетевые модели, способные понимать разные формулировки (например, "распахни ворота", "пусть откроются"). Возможность адаптации системы к голосу владельца (исключение ложных срабатываний). Можно добавить фильтрацию шумов, что позволит работать даже в шумных условиях (например, на улице). Большинство голосовых помощников (Siri, Google Assistant) требуют интернет-соединения. Использование офлайн-моделей (Vosk, PocketSphinx) позволяет управлять воротами даже без доступа к сети. Интеграция с IoT и умными домами то есть ворота могут взаимодействовать с "умными" датчиками, например: Автоопределение владельца (например, голос + геолокация) Автоматическое закрытие через датчики движения или распознавание номерных знаков Систему можно адаптировать под разные языки, добавить управление через жесты, мобильное приложение или распознавание лиц.

Список использованной литературы:

1. Журавлев А. И. "Алгоритмы машинного обучения в системах голосового управления" – СПб.: Питер, 2021.
2. Jurafsky D., Martin J. "Speech and Language Processing" – Pearson, 2021.
3. Бахметьев Н. С. "Применение нейросетей в голосовых интерфейсах управления" – Изд. дом МГТУ, 2019.
4. Кулаков В. Ю. "Распознавание команд с использованием нейронных сетей" – Компьютерные исследования и моделирование, 2022.

Навигация в помещении и нахождение наиболее оптимального маршрута при помощи сочетания алгоритмов

Смамқожаев М.Т.

КБТУ, 2 курс магистрант
Email: m_smatkozhayev@kbtu.kz

Омаров Б.

КазНУ им. аль-Фараби, PhD, доцент
Email: batyahan@gmail.com

Навигация внутри помещений стала важнейшим аспектом современных технологий, обеспечивая эффективное перемещение и позиционирование в сложных условиях, таких как больницы, торговые центры, аэропорты и промышленные объекты. В отличие от навигации вне помещений, которая в значительной степени зависит от GPS, навигация внутри помещений должна бороться с препятствиями, такими как стены, мебель и динамическая среда, которые мешают традиционным сигналам. В результате были разработаны различные алгоритмы для облегчения точного и эффективного поиска пути в помещениях, используя уже существующие карты и данные датчиков.[1][6]

Поиск пути в навигации внутри помещений часто опирается на графические представления макетов зданий, где узлы представляют комнаты или перекрестки, а ребра обозначают проходимые пути или коридоры. Среди наиболее известных алгоритмов для планирования пути — жадные алгоритмы и их сочетание с алгоритмом A (A-star)*, который обеспечивает повышенную производительность за счет баланса скорости и точности.[3]

Жадный алгоритм — это простой подход, который отдает приоритет немедленному выигрышу, выбирая путь, который кажется ближайшим к месту назначения на каждом шагу. Хотя этот метод является вычислительно эффективным и простым в реализации, он может привести к неоптимальным путям или даже к невозможности найти решение в средах с препятствиями и сложной планировкой.[4][5]

Чтобы преодолеть эти ограничения, подход Greedy + A* объединяет эвристическую природу жадных алгоритмов с надежной оптимизацией пути алгоритма A*. A* объединяет оценку кратчайшего пути (стоимости) с эвристическими оценками для систематического исследования путей, обеспечивая более надежную навигацию при минимизации вычислительных затрат. Этот гибридный подход особенно выгоден в динамических условиях внутри помещений, где точность, адаптивность и эффективность имеют первостепенное значение.

Список использованной литературы:

1. Abu-Shaban, S., Aloï, D. N., & Balaei, A. T. (2021). *Wireless Indoor Localization: Fundamentals and Techniques*. Artech House.
2. Xiao, J., Zhou, Z., Zheng, B., & Wei, Y. (2016). A Survey on Wireless Indoor Localization from the Device Perspective. *ACM Computing Surveys (CSUR)*, 49(2), 1–31.
3. Zhu, Y., Wu, C., & Yang, Z. (2019). Indoor localization using magnetic and visual sensors: A review. *Frontiers of Computer Science*, 13(1), 1–14.
4. Zekavat, S. A., & Buehrer, R. M. (2019). *Handbook of Position Location: Theory, Practice and Advances*. Wiley-IEEE Press.
5. Gu, F., Ren, F., & Hu, L. (2020). A Survey on Indoor Positioning Systems for Internet of Things. *IEEE Access*, 8, 56618–56653.
6. Alarifi, A., Al-Salman, A., Alsaleh, M., Alnafessah, A., Al-Hadhrani, S., Al-Ammar, M. A., & Al-Khalifa, H. S. (2016). Ultra wideband indoor positioning technologies: Analysis and recent advances. *Sensors*, 16(5), 707.

7. Liu, H., Darabi, H., Banerjee, P., & Liu, J. (2007). Survey of Wireless Indoor Positioning Techniques and Systems. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 37(6), 1067–1080.

Разработка машинного обучения для анализа данных устройства мониторинга стресса

Сугирбаев А.А.

КазНУ им. аль-Фараби, 4 курс бакалавр


Email: sugerbaev1704@gmail.com

Зиятбекова Г.З.

КазНУ им. аль-Фараби, PhD, и.о. доцента


В современном мире проблема стресса становится все более актуальной. Хронический стресс негативно влияет на здоровье человека, повышая риск развития сердечно-сосудистых заболеваний, депрессии и других патологий. В связи с этим возникает потребность в разработке систем мониторинга стресса, способных автоматически анализировать физиологические параметры и определять уровень нагрузки на организм [1]. Целью данной работы является разработка алгоритмов машинного обучения для обработки и анализа данных, получаемых с устройства мониторинга стресса. Основное внимание уделяется поиску новых подходов к обработке сигналов и построению ансамбля моделей, который позволит повысить точность предсказаний.

Описание устройства. В качестве аппаратной платформы используется микроконтроллер ESP32, который обладает встроенным Wi-Fi и возможностью сбора данных с нескольких датчиков.



Для измерения физиологических параметров применяются три сенсора:

- Датчик пульса (Pulse Sensor) фиксирует частоту сердечных сокращений (ЧСС);



- Кожно-гальванический датчик (GSR) измеряет электрическое сопротивление;



- Датчик температуры (DS18B20) регистрирует изменение температуры тела.



Собранные данные передаются на сервер для дальнейшей обработки и анализа с использованием алгоритмов машинного обучения.

Методика обработки данных. Для анализа сигналов будут использоваться следующие этапы:

1. Предварительная обработка – фильтрация шумов, нормализация данных и устранение выбросов.
2. Извлечение признаков – определение ключевых параметров, таких как вариативность ЧСС, уровень кожного сопротивления и динамика изменения температуры.
3. Обучение модели – применение ансамблевых методов машинного обучения для предсказания уровня стресса.
4. Оценка модели – проверка качества предсказаний на тестовой выборке с использованием метрик.

Новизна исследования. Ключевым отличием данной работы является комбинированный подход к анализу данных с использованием ансамблей моделей. В отличие от традиционных методов, в которых применяется одна модель, ансамбли позволяют повысить точность и устойчивость к шумам. Кроме того, разрабатывается новый алгоритм обработки сигналов, включающий адаптивные фильтры и методы временного анализа. Дополнительно в проекте рассматривается возможность использования онтологического подхода к интерпретации данных. Это позволит системе не только классифицировать стресс, но и выявлять паттерны, указывающие на возможные причины его возникновения [2].

Результатом работы станет разработка программно-аппаратного комплекса для мониторинга стресса с использованием ESP32, набора датчиков и серверного анализа данных. Ожидается, что разработанный алгоритм машинного обучения обеспечит более высокую точность классификации стрессовых состояний по сравнению с существующими подходами. Данная работа может найти применение в медицине, спорте, психологии и других областях,

требующих мониторинга физиологического состояния человека. В дальнейшем возможна интеграция с мобильными приложениями и облачными сервисами для расширения функционала системы [3].

Выводы. Разрабатываемая система мониторинга стресса представляет собой комплексное решение, включающее аппаратную часть на основе ESP32 и интеллектуальную обработку данных с применением машинного обучения. Внедрение ансамблей моделей позволит повысить точность детекции стрессовых состояний, что может быть полезно в медицинской диагностике, спортивной аналитике и психофизиологических исследованиях. В дальнейшем планируется расширение набора входных данных и тестирование алгоритмов на реальных пользователях для повышения достоверности и практической применимости системы.

Список использованной литературы:

1. Vos G., Trinh K., Sarnyai Z., Rahimi Azghadi M. "Generalizable machine learning for stress monitoring from wearable devices: A systematic literature review." *International Journal of Medical Informatics*, 2023 May;173:105026. <https://www.sciencedirect.com/science/article/pii/S1386505623000436>
2. Vos G., Trinh K., Sarnyai Z., Rahimi Azghadi M. "Generalizable machine learning for stress monitoring from wearable devices: A systematic literature review." *International Journal of Medical Informatics*, 2023 May;173:105026. https://www.researchgate.net/publication/364110268_Machine_Learning_for_Stress_Monitoring_from_Wearable_Devices_A_Systematic_Literature_Review
3. Gour S., Vinoth Kumar C.V. "Machine learning methods for stress monitoring using wearable devices." *International Conference on Artificial Intelligence and Signal Processing (AISP)*, 2022. <https://ieeexplore.ieee.org/document/9752111>

Developing a Smart Camera Program Using Artificial Intelligence

Sultanova Aruzhan

*Al-Farabi Kazakh National University,
Email: sultanova_aruzhan@live.kaznu.kz*

Makashev Yerlan

*Senior professor, Candidate of Physical and
Mathematical Sciences*

This thesis explores the development of a smart camera program utilizing artificial intelligence (AI) to enhance real-time image processing, object detection, and decision-making capabilities. Traditional camera systems often require constant human supervision and struggle with high false alarm rates. AI-powered smart cameras leverage machine learning (ML) and computer vision (CV) algorithms to autonomously recognize and classify objects, optimize energy efficiency, and improve accuracy in security and monitoring applications. The proposed system integrates convolutional neural networks (CNNs) for object recognition, utilizes deep learning frameworks such as TensorFlow and PyTorch, and implements real-time processing on embedded hardware. Expected outcomes include improved recognition accuracy, reduced computational costs, and enhanced adaptability across various sectors, including security, healthcare, and autonomous systems. The research further discusses future advancements in federated learning and edge computing for enhanced privacy and performance. The integration of artificial intelligence (AI) into camera technology has revolutionized various fields, including security, healthcare, and autonomous systems. Smart cameras equipped with AI-driven capabilities such as object recognition, motion detection, and facial recognition enable automated surveillance and data analysis, improving efficiency and accuracy. This thesis explores the development of a smart camera program leveraging AI algorithms to enhance real-time image processing and decision-making.

The rapid advancement of AI and computer vision technologies has led to increased demand for intelligent surveillance and monitoring systems. Traditional camera systems often struggle with high false alarm rates and require constant human supervision, limiting their effectiveness. AI-powered smart cameras can autonomously detect and analyze objects, reducing human intervention and improving decision-making processes. Moreover, the growing need for enhanced security, automation in smart cities, and real-time analytics in industries further highlights the importance of developing AI-driven camera systems. This research contributes to the advancement of intelligent monitoring solutions by optimizing recognition accuracy, reducing computational costs, and ensuring adaptability to various real-world scenarios.

Traditional camera systems rely on manual monitoring and predefined programming, limiting their ability to adapt to dynamic environments. The challenge lies in developing an AI-powered smart camera capable of real-time analysis, distinguishing between relevant and irrelevant objects, and making autonomous decisions without human intervention. This research aims to address these challenges by implementing machine learning (ML) and computer vision (CV) techniques in a smart camera system.

The development of the smart camera program involves:

1. Data Collection and Preprocessing – Acquiring and labeling datasets for training AI models, ensuring diversity in lighting, angles, and object types.
2. Machine Learning Model Selection – Evaluating convolutional neural networks (CNNs) and deep learning frameworks such as TensorFlow and PyTorch for object detection and recognition.
3. Algorithm Implementation – Integrating AI models into an embedded system with an optimized inference engine for real-time performance.
4. Testing and Optimization – Assessing accuracy, processing speed, and computational efficiency to refine the model for practical deployment.

The smart camera program is expected to:

- Improve accuracy in object recognition and classification.
- Enhance real-time decision-making capabilities.
- Reduce false positives in security and surveillance applications.
- Optimize energy efficiency and computational performance for embedded systems.

References:

1. Redmon, J., & Farhadi, A. (2018). YOLOv3: An Incremental Improvement. arXiv preprint arXiv:1804.02767.
2. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770-778.
3. Krizhevsky, A., Sutskever, I., & Hinton, G. (2012). ImageNet Classification with Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems (NIPS), 25, 1097-1105.
4. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
5. Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016). SSD: Single Shot MultiBox Detector. European Conference on Computer Vision (ECCV), 21-37.

Multimodal data mining algorithm for abnormal cases of autonomous driving

Tang Daoyun

Al-Farabi Kazakh National University, doctor's degree, first year

E-mail: hfuttdy@163.com

Amirkhanova Gulshat

Al Farabi Kazakh National University

The rapid development of autonomous driving technology has a profound impact on social mobility, and environmental perception as its core technology is facing severe challenges. In order to achieve large-scale commercial application, the perception system needs to have high robustness to deal with complex scenarios. At present, mainstream deep learning models rely on the distribution of training data, and the detection performance of unlabeled abnormal cases (such as unknown objects and extreme lighting scenes) is significantly reduced, and the missed detection of such scenarios directly threatens the safety of autonomous driving. Therefore, how to efficiently mine and process abnormal case data has become a key bottleneck to improve the generalization ability of the perception system.

The existing abnormal case detection methods for autonomous driving can be divided into two categories: online and offline. Online methods mostly rely on confidence thresholds or uncertainty estimation (such as Monte Carlo sampling), but they have the problem of high computational overhead. The offline method reconstructs the normal scene by generating a model to achieve anomaly detection, but it has insufficient ability to capture rare class features and is susceptible to pixel-level noise interference. The uneven distribution of data (such as the long-tail phenomenon) leads to the limited ability of the model to generalize to rare abnormal scenes. Existing large-scale datasets (such as BDD100K and Waymo) contain massive amounts of data, but manual annotation is inefficient. Due to the difference in pixel distribution, it is difficult to truly reflect the actual driving environment.

This paper proposes a novel Multimodal Anomaly Case Automatic Mining Process (CCMP), which uses the advantages of lidar and camera data to automatically mine anomaly cases in existing large datasets. The mining object of CCMP must meet two conditions: the object is located in the potential driving area of the autonomous driving; The target does not belong to the training set category or is difficult to detect visually due to lighting issues.

The multi-modal anomaly case mining process (CCMP) proposed in this study uses LiDAR and camera sensor data as inputs to realize the automatic screening of abnormal cases through the following steps:

The Deeplabv3+ semantic segmentation model was used to obtain the road mask, and the LiDAR point cloud was projected into the two-dimensional image domain through multi-modal registration, and the point cloud of the drivable area was filtered out. The RANSAC algorithm was introduced to fit the road plane equation, the 30cm distance threshold was set to filter the non-road point clouds, and the outliers were eliminated through neighborhood standard deviation analysis. Combined with alpha shape estimation, a high-precision road triangular mesh model is constructed to realize centimeter-level road plane reconstruction and provide an accurate spatial benchmark for subsequent abnormal case detection.

DBSCAN clustering was performed on the road point cloud, and the parameters $\alpha=1.5$ and $MinP=35$ were set to generate 3D candidate boxes. Map the 3D box to the 2D space to form the initial exception case proposal box.

The Cascade R-CNN detection framework is used to carry the ConvNeXt-S backbone network to pre-train and generate detection frames on BDD100K datasets. The general targets are filtered by the IOU threshold (0.5), and the candidate areas with low coincidence with the point cloud clustering box are retained. Combined with manual annotation verification, the unknown categories or low-light anomalies in the driving area were accurately screened out, and the recall rate of abnormal scenes

was 91.7%, providing a high-quality benchmark for long-tail data training.

In order to verify the effectiveness of CCMP, a subset of anomaly cases, Waymo-Anomaly, was constructed based on the Waymo dataset, which contained 3200 images. The experimental results show that the recall rate of CCMP for abnormal case scene mining reaches 91.7%. In terms of detection results, after fine-tuning Waymo-Anomaly, the detection of “known” categories is improved, and the detection accuracy of the multi-stage model for the “known” category is generally higher, but the detection performance of the “unknown” category is not as good as that of the single-stage network, which may be because the intensive prediction method of the single-stage model is more favorable to the recall rate of the “unknown” category detection. In order to solve the problem of a small number of “unknown” categories in the anomaly case scenario, methods for long-tail problems, such as Equilibrium Focus Loss (EFL) and Dynamic Category Suppression Loss (ACSL), are introduced. Experiments show that EFL is more suitable for “tail” detection in single-stage object detection model, and ACSL is more suitable for two-stage detection algorithm.

The CCMP automated abnormal case mining process proposed in this paper effectively solves the problem of mining abnormal case scenarios in the real world of autonomous driving through multi-modal sensor data processing. This process inputs multi-modal sensor data, and uses the rich semantic information of vision sensors and the advantages of lidar sensors to reduce missed detections, and automatically mine abnormal case scenarios, which is very effective for large public or private datasets. Future research can further optimize the CCMP process, improve the mining efficiency and accuracy, explore more ways to deal with long-tail problems, and improve the performance and safety of autonomous driving perception models in the real world.

References:

1. Shikha Agrawal, Jitendra Agrawal. Survey on Anomaly Detection using Data Mining Techniques, *Procedia Computer Science*. 60.2015. 708-713.
2. DU X, WANG Z, CAI M, et al. VOS: learning what you don't know by virtual outlier synthesis[J]. *arXiv preprint arXiv: 2202.01197*, 2022.
3. KENDALL A, BADRINARAYANAN V, CIPOLLA R. Bayesian SegNet: model uncertainty in deep convolutional encoder-decoder architectures for scene understanding[J]. *arXiv preprint arXiv: 1511.02680*, 2015.
4. GRCIC M, BEVANDIC P, KALAFATIC Z, et al. Dense anomaly detection by robust learning on synthetic negative data[J]. *arXiv preprint arXiv:2112.12833*, 2021.
5. OHGUSHI T, Horiguchi K, YAMANAKA M. Road obstacle detection method based on an autoencoder with semantic segmentation[C]. *Proceedings of the Asian Conference on Computer Vision*, 2020.
6. VOJIR T, ŠIPKA T, ALJUNDI R, et al. Road anomaly detection by partial image reconstruction with segmentation coupling[C]. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2021: 15651-15660.

Деректерді талдау әдістері негізінде ақауларды басқарудың интеллектуалды автоматтандыру жүйесін құру

Талғатұлы Ә.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

Email: lida2004adil@gmail.com

Абдилдаева А.А.

Әл-Фараби атындағы ҚазҰУ, профессор м.а.

Заманауи өндірістік кәсіпорындар үшін ақауларды басқару маңызды міндет болып табылады. Дәстүрлі әдістерде деректерді қолмен енгізу және өңдеу қателіктерге, уақыт жоғалтуға және өндіріс тиімділігінің төмендеуіне әкеледі. Осы мәселелерді шешу үшін деректерді талдау әдістеріне негізделген интеллектуалды автоматтандыру жүйесін енгізу қажет.

Бұл зерттеу аясында Python, Django, PostgreSQL технологиялары қолданылып, өндірістік ақауларды тіркеу, өңдеу және талдауды автоматтандыруға бағытталған веб-жүйе әзірленді. Жүйе ақпаратты орталықтандыру, есеп беру процесін жеңілдету және өндіріс сапасын арттыру мақсатында құрылды.

Зерттеудің мақсаты – өндірістік ақауларды басқару үшін деректерді талдау әдістерін қолдану арқылы интеллектуалды автоматтандырылған жүйе құру.

Өндірістік процестердегі ақауларды уақтылы анықтау және оларды басқару өнім сапасы мен өндіріс тиімділігін арттырудың негізгі факторларының бірі болып табылады. Қолмен тіркеу деректер дәлдігінің төмендеуіне, ақпарат алмасудың баяу жүруіне және шешім қабылдаудың кешігуіне әкеледі.

Бұл мәселелерді шешу үшін орталықтандырылған автоматтандырылған веб-жүйе қажет.

Ұсынылған жүйенің негізгі міндеттері:

- Өндірістік ақаулар туралы ақпаратты нақты уақыт режимінде жаңарту.
- Қателіктерді азайту және деректерді автоматты түрде тіркеу.
- Ақаулардың қайталану себептерін талдап, болдырмау шараларын енгізу.

Осы шешім өндірістік процестерді оңтайландыруға, өнім сапасын арттыруға және жедел басқару шешімдерін қабылдауға мүмкіндік береді.

Жүйенің архитектурасы, деректерді өңдеу және көрсету әдістері

Ұсынылған веб-қосымша Django негізінде әзірленіп, PostgreSQL мәліметтер базасымен жұмыс істейді. Жүйе серверлік бөлік, мәліметтер базасы және веб-интерфейстен тұрады.

• Django ORM деректерді тиімді басқаруға, сұрыптауға және жаңартуға мүмкіндік береді. Барлық өзгерістер автоматты түрде сақталып, есепке алудың ашықтығын қамтамасыз етеді.

• PostgreSQL жылдам өңдеу мен қауіпсіз сақтауды қамтамасыз етеді, бұл үлкен көлемдегі өндірістік деректермен тиімді жұмыс істеуге мүмкіндік береді.

• Веб-интерфейс ақауларды тіркеу, өңдеу және талдау функцияларын қамтиды. Статистиканы, қайталану жиілігін және негізгі себептерді талдау үшін кестелер мен графиктер қолданылады.

Деректерді жаңарту Ajax технологиясы арқылы жүзеге асады, бұл ақпаратты бетті қайта жүктемей-ақ жаңартуға мүмкіндік береді. Осылайша, жүйе жылдам жұмыс істеуді қамтамасыз етіп, пайдаланушыларға ыңғайлы тәжірибе ұсынады.

Ұсынылған жүйенің артықшылықтары

• Ақпараттың орталықтандырылған басқаруы – өндірістік ақаулар туралы деректерге жылдам қол жеткізуге мүмкіндік береді.

• Қателердің азаюы – ақауларды тіркеу процесінің автоматтандырылуы адам факторын төмендетеді.

- Өндіріс тиімділігінің артуы – жедел талдау және есеп беру мүмкіндігі өндірістік процестерді оңтайландырады.

- Қауіпсіздік және рұқсат деңгейлері – пайдаланушылар аутентификациясы арқылы жүйеге рұқсатсыз кірудің алдын алады.

Жүйе өндірістік деректерді тиімді басқаруға көмектеседі және шешім қабылдау процесін жеделдетеді.

Django негізінде әзірленген веб-қосымша өндірістік ақауларды басқаруда ақпаратқа орталықтандырылған қолжетімділікті, қателерді азайтуды және өндірістік процестердің тиімділігін арттыруды қамтамасыз етеді. Ақауларды тіркеу, өңдеу және талдау процестерін автоматтандыру адам факторын барынша азайтуға, деректерді өңдеуді жеделдетуге және өндіріс сапасын жақсартуға мүмкіндік береді. Жүйенің веб-интерфейсі пайдаланушыларға өндірістік ақауларды бақылауға, олардың себептерін анықтауға және есептерді автоматты түрде қалыптастыруға жағдай жасайды, бұл жалпы өндірістік процестерді оңтайландыруға ықпал етеді.

Болашақта жүйенің функционалдық мүмкіндіктерін кеңейту жоспарлануда:

- Компьютерлік көру технологияларын қолдану арқылы ақауларды автоматты түрде анықтау.

- Өндірістік процестерді талдауға арналған машиналық оқыту алгоритмдерін енгізу.

- Қолданыстағы ERP және CRM жүйелерімен интеграция, бұл өндірістік ақауларды басқару және өндірістік процестерді оңтайландыру мүмкіндіктерін кеңейтеді.

- Есеп беру жүйесін жетілдіру, деректерді визуализациялау үшін жетілдірілген графиктер мен аналитикалық панельдерді енгізу.

Ұсынылған жүйе өндірістік ақауларды басқаруда интеллектуалды автоматтандырудың маңыздылығын дәлелдейді және болашақта оны әртүрлі өндірістік салаларға бейімдеу арқылы кеңейтуге мүмкіндік береді.

Пайдаланылған әдебиеттер тізімі:

1. Синенко, О.В. (2002). “Өндірістік процестерді талдау және өндірісті басқарудың біріктірілген жүйесін құруға көзқарас.” Мұнда өндірістік процестерді талдау және басқарудың интеграцияланған жүйелерін құру әдістері талқыланады. [Доступно по ссылке](#)

2. “Сапаны жалпы басқарудың модельдері.” Оқулықта сапа жүйесін басқаруға арналған ғылыми, әдістемелік және ұйымдастыру жұмыстарын қамтамасыз ету мәселелері қарастырылған. [Доступно по ссылке](#)

3. Хабр. (2023). Автоматизация расчётов на вашем сайте с помощью django-ruway приложений. Хабр. [Доступно по ссылке](#)

Мәтінді автоматты түрде белгілеу әдістерінің үлкен тілдік үлгілердің дәлдігі мен тиімділігіне әсерін бағалау

Темірханова А.Б.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр

E-mail: temirkhanova_ai@mail.ru

Оспан Ә.Ғ.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Ғылыми жұмыстың мақсаты – мәтінді автоматты түрде белгілеу әдістерінің үлкен тілдік үлгілердің (LLM) дәлдігі мен тиімділігіне әсерін бағалау. Үлкен тілдік үлгілердің өнімділігі көбінесе олардың оқытылатын деректеріне байланысты, ал белгілеу сапасы үлгінің жұмыс нәтижелеріне тікелей ықпал етеді. Белгілеу әдістері дұрыс таңдалмаған жағдайда, үлгі мағынасы дұрыс берілмеген немесе қате аннотацияланған деректерге негізделіп жұмыс істейді, бұл оның болжамдарының сенімділігі мен дәлдігін төмендетуі мүмкін. Сондықтан бұл зерттеу автоматты белгілеудің әртүрлі әдістерін салыстырып, олардың NLP жүйелерінің тиімділігіне қалай әсер ететінін анықтауға бағытталған.

Бүгінгі күнде өзектілігі – үлкен деректер жиынтықтарын өңдеу NLP жүйелерінің маңызды бөлігіне айналды. Дегенмен, деректерді қолмен белгілеу өте көп уақыт пен ресурстарды қажет етеді, ал бұл үлкен көлемдегі деректермен жұмыс істейтін модельдер үшін тиімсіз. Сондықтан автоматтандырылған белгілеу әдістері қолданылады. Бірақ автоматты белгілеу әдістерінің дәлдігі мен тиімділігі әртүрлі болуы мүмкін, бұл үлгінің жалпы өнімділігіне кері әсер етуі мүмкін [1]. Мысалы, кейбір машиналық оқытуға негізделген әдістер үлкен көлемдегі деректерді өңдеу кезінде жоғары сапа көрсете алса, басқа әдістер синтаксистік және семантикалық сәйкессіздіктерге әкелуі мүмкін [2].

Сонымен қатар, үлкен тілдік үлгілерді оқыту мен қолдану кезінде есептеу ресурстарының шығыны маңызды рөл атқарады. Егер белгілеу әдісі оңтайлы таңдалмаса, LLM есептеу процесінде артық жүктемеге ұшырайды, бұл оның жұмыс жылдамдығын төмендетеді және үлкен ресурстарды қажет етеді [3]. Осыған байланысты, әртүрлі автоматты белгілеу әдістерінің тиімділігін зерттеу және олардың үлгі сапасына ықпалын бағалау NLP жүйелерін дамытуда өзекті мәселе болып табылады.

Мақсатқа қол жеткізу үшін есеп қойылымы мынадай:

Әртүрлі автоматты белгілеу әдістерінің үлкен тілдік үлгілердің дәлдігі мен тиімділігіне әсерін жан-жақты талдау.

Белгілеу сапасы мен есептеу ресурстарының тұтынуы арасындағы байланыстарды зерттеу.

Белгілеу әдістерінің үлгінің өңдеу жылдамдығына және есептеу тиімділігіне қалай әсер ететінін анықтау.

NLP жүйелері үшін белгілеудің оңтайлы стратегияларын ұсыну.

Есепті шешу әдістері келесі қадамнан тұрады: Бірінші кезеңде әртүрлі белгілеу әдістері талданады, олардың ерекшеліктері, артықшылықтары мен кемшіліктері қарастырылады [4]. Екінші кезеңде әртүрлі әдістерді қолдану арқылы мәтіндік деректер белгіленіп, олардың сапасы салыстырылады. Үшінші кезеңде үлкен тілдік үлгілердің өнімділігіне әртүрлі белгілеу әдістерінің әсері BLEU, ROUGE, Perplexity және дәлдік (Accuracy) сияқты метрикалар арқылы бағаланады. Сонымен қатар, белгілеу әдістерінің өңдеу жылдамдығына және есептеу ресурстарын пайдалануына әсері зерттеледі [5]. Төртінші кезеңде алынған нәтижелер негізінде NLP жүйелерінде тиімді қолдануға болатын оңтайлы белгілеу әдістері ұсынылады. Бұл әдістер тек LLM өнімділігін арттыруға ғана емес, сонымен қатар есептеу ресурстарының тиімді пайдаланылуын қамтамасыз етуге де бағытталады.

Автоматты белгілеу әдістерінің тиімділігін арттыру үшін ең алдымен деректердің құрылымдық ерекшеліктерін ескеру қажет. Белгілеу процесінде грамматикалық және

семантикалық сәйкессіздіктерді болдырмау үшін, машиналық оқытуға негізделген әдістерді ережеге негізделген әдістермен үйлестіру ұсынылады. Гибридті тәсілдер жиі анағұрлым жоғары сапа көрсетеді, себебі олар машиналық оқытудың икемділігі мен ережеге негізделген әдістердің нақтылығын біріктіреді.

Бұл зерттеу нәтижелері NLP жүйелерін дамытуда маңызды рөл атқарады. Автоматты белгілеу әдістерінің артықшылықтары мен шектеулерін анықтай отырып, үлкен тілдік үлгілердің тиімділігін арттырудың жаңа тәсілдерін ұсынуға болады. Сонымен қатар, ұсынылған әдістер тек ғылыми ортада ғана емес, сонымен қатар практикалық қосымшаларда да кеңінен қолданылуы мүмкін.

Пайдаланылған әдебиеттер тізімі:

1. Liu, Y., Tan, R., & Chen, W. (2024). Unsupervised Production Machinery Data Labeling Method Based on NLP. *Expert Systems with Applications*, 215, 119328.
2. Ivanov, P., Kuznetsov, M., & Orlov, D. (2024). The Problem of Linguistic Markup Conversion. *Language Resources and Evaluation*, 58(2), 213-230.
3. Tan, X., Wang, K., & Li, J. (2024). Pre-train, Prompt, and Predict: A Systematic Survey. *Annual Review of NLP Research*, 12, 89-112.
4. Lee, H., Choi, B., & Park, D. (2024). Universality and Limitations of Prompt Tuning. *Neural Computation and Applications*, 36(4), 455-470.
5. Wang, Y., Zhou, L., Wang, Y., & Peng, Z. (2024). Leveraging Pretrained Language Models for Enhanced Entity Matching: A Comprehensive Study of Fine-Tuning and Prompt Learning Paradigms. *International Journal of Intelligent Systems*, 2024.

СБОР ДАННЫХ С ДАТЧИКОВ ДЛЯ ЦИФРОВОГО ДВОЙНИКА ПРЕДПРИЯТИЯ

Тусупов А.К.

КазНУ им. аль-Фараби, 4 курс бакалавр

Тулеев А.А.

КазНУ им. аль-Фараби, 4 курс бакалавр

Email: sir.mo-1@yandex.ru

Зиятбекова Г.З.

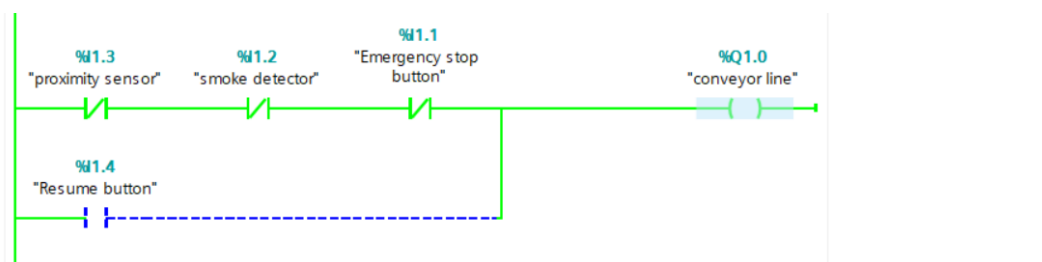
КазНУ им. аль-Фараби, PhD, и.о. доцента

В статье рассматривается разработка системы сбора данных с датчиков для цифрового двойника предприятия с целью повышения автоматизации и мониторинга производственного процесса. Для реализации используется программируемый логический контроллер (ПЛК) Siemens S7-1200, настраиваемый в программе TIA Portal, а также WinCC Explorer для визуализации. Виртуальный ПЛК моделируется в PLCSIM, а полученные данные передаются в WinCC Explorer – программа для визуализации, где отображаются положение кузова, активированные датчики и состояние конвейерной линии. Это соединение позволяет не только отображать данные о работе конвейерной линии, но также анализировать собранную информацию и управлять процессом дистанционно через другой компьютер.

Статья посвящена созданию цифрового двойника конвейерной линии на предприятии автомобилестроения. Конвейерная линия предназначена для перемещения кузовов с остановками в нужные моменты. Цифровой двойник позволяет наблюдать за её работой, анализировать поведение системы и оптимизировать процесс.

В разработанной системе конвейерная линия управляется с помощью тега “conveyor line”, который находится в состоянии True, но останавливается при срабатывании датчиков приближения, нажатии кнопки “stop”, аварийной остановке “Emergency stop button” или активации датчика дыма “smoke detector”. Для возобновления работы используется тег “Resume button”. Количество кузовов, прошедших через конвейер, фиксируется в теге “Chet”, получающем сигналы от последнего датчика приближения [1].

Логика программы в TiaPortal:



Используемые теги:

Tag Name	Variable Name	Variable Type	Address	...
conveyor line	conveyor line	Bool	%Q1.0	
Emergency stop button	Emergency stop button	Bool	%I1.1	
smoke detector	smoke detector	Bool	%I1.2	
proximity sensor	proximity sensor	Bool	%I1.3	
Resume button	Resume button	Bool	%I1.4	
stop	stop	Bool	%I1.5	
Chet	Chet	Int	%W1	
proximity sensor(1)	proximity sensor(1)	Bool	%I4.0	
proximity sensor_1	proximity sensor_1	Bool	%I4.1	
proximity sensor_2	proximity sensor_2	Bool	%I4.2	

В системе управления конвейерной линией используются входные и выходные теги, обеспечивающие работу автоматизированного процесса. Входные теги "Emergency stop button", "smoke detector", "proximity sensor", "proximity sensor(1)", "proximity sensor_1",

"proximity sensor_2", "stop", "Resume button" отвечают за получение данных с датчиков и кнопок управления. Аварийная кнопка "Emergency stop button", кнопка остановки "stop" и датчик дыма "smoke detector" при активации приводят к остановке конвейера, а кнопка возобновления "Resume button" запускает его снова. Датчики приближения "proximity sensor", "proximity sensor(1)", "proximity sensor_1" и "proximity sensor_2" определяют положение кузова и управляют процессом его остановки в нужных точках.


Выходные теги "conveyor line" и "Chet" используются для управления системой и отображения её состояния. Тег "conveyor line" определяет, работает конвейер или остановлен, а тег "Chet" ведет учет количества кузовов, прошедших через последний датчик приближения. Эти теги позволяют системе корректно реагировать на изменения в процессе и передавать данные для визуализации в WinCC Explorer, где отображается текущее состояние конвейера, активированные датчики и счетчик кузовов [2].

Программа загружается в PLCSIM, который представляет собой программный инструмент для симуляции работы контроллеров Siemens серии S7-1200 и S7-1500. PLCSIM позволяет протестировать разработанную логику без физического оборудования, моделируя работу ПЛК в виртуальной среде.


После загрузки программы в PLCSIM, данные тегов передаются в WinCC Explorer, где строится визуализация системы. На экране отображается текущее состояние конвейерной линии, включая активность всех датчиков и положение кузова. Датчики приближения при срабатывании подсвечиваются красным цветом, что позволяет наглядно отслеживать процесс. Также выводится количество кузовов, прошедших через конвейерную линию, состояние мотора и самого конвейера.

Для анализа работы линии в реальном времени используются графики и тренды, фиксирующие время работы конвейерной линии. Это позволяет оператору контролировать процесс и оперативно реагировать на изменения в системе.

Визуализация на WinCC



Тренд, на котором мы видим работу конвейерной линии по времени.

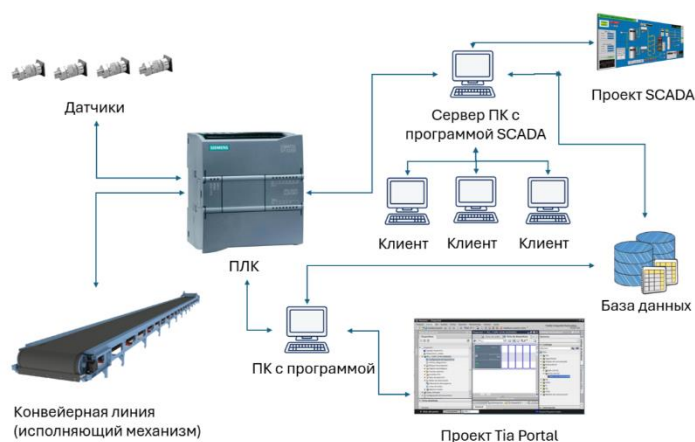


На этом тренде при значении 1 конвейерная линия находится в работе, а при значении 0 — остановлена. Этот тренд строится на основе значений тега "conveyor line", который отображает текущее состояние конвейерной линии. Таким образом, визуализация позволяет в реальном времени отслеживать периоды работы и остановки конвейера [3].

Дополнительно используется конфигурация WinCC в режиме "сервер-клиент", что позволяет наблюдать за работой системы и вносить коррективы через другой ПК. Это

обеспечивает удобный удаленный контроль и оперативное реагирование на изменения в процессе.

Общая схема цифрового двойника предприятия



Предложенная система повышает уровень автоматизации, обеспечивает мониторинг и контроль производственного процесса, что способствует его оптимизации и выявлению возможных неисправностей. Скриншоты визуализации приведены в файле.

Список использованной литературы:

1. Официальный сайт форум Siemens: <https://support.industry.siemens.com/forum>
2. Освоение программирования ПЛК Siemens: подробное руководство по порталу TIA: <https://plcvfd.com/ru/mastering-siemens-plc-programming-a-comprehensive-guide-to-tia-portal>
3. Library of general functions (LGF) for SIMATIC STEP 7 (TIA Portal) and SIMATIC S7-1200 / S7-1500: <https://support.industry.siemens.com/cs/document/109479728/>

LLM модельдеріне шолу жасау

Хамитова К.Ә.

Әл-Фараби атындағы ҚазҰУ, 6В07113 2 курс бакалавриат

E-mail: kamilahamitova080606@mail.ru

Тойганбаева Н.А.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

LLM (Үлкен тілдік модельдер) – табиғи тілдерді өңдеуге арналған, адам тілін түсініп, өндіре алатын нейрондық желілердің кеңейтілген түрі. Бұл жұмыс LLM модельдерінің маңыздылығын, олардың мүмкіндіктерін және қазақ тілінде қолдану тәсілдерін қарастырады.

LLM модельдері (Үлкен тілдік модельдер) соңғы жылдары табиғи тілдермен жұмыс істеуде үлкен жетістіктерге жетті. Олар машиналық оқыту мен жасанды интеллектінің көмегімен тілдерге қатысты әртүрлі тапсырмаларды орындауға қабілетті. Бұл модельдер адам тілінің құрылымын түсініп, мәтіндерді жазуға, сұрақтарға жауап беруге, аударма жасауға және басқа да көптеген тапсырмаларды орындауға мүмкіндік береді. Үлкен тілдік модельдер негізінен трансформерлер архитектурасына негізделеді, бұл олардың үлкен деректер жиынтықтарымен оқыту және тілдік контексті түсіну қабілетін арттырады.

Кесте 1. Танымал LLM модельдеріне шолу

Модель	Әзірлеуші	Көлемі (параметрлер саны)	Ерекшеліктері
GPT-4	OpenAI	1.76 трлн (бағалау)	Кеңейтілген логика, ұзақ контекст
GPT-3.5	OpenAI	175 млрд	Жақсартылған мәтін түсіну және генерация
Claude 3	Anthropic	Белгісіз	Этикалық шектеулерге баса назар аударады
Gemini 1.5	Google DeepMind	Белгісіз	Мультимодальді қабілеттер (мәтін, сурет)
Mistral 7B	Mistral AI	7 млрд	Ашық кодты, тиімді, жеңіл модель
LLaMA 3	Meta	8B - 70B	Зерттеу және ашық кодты дамытуға бағытталған
Falcon 180B	ТII (Абу-Даби)	180 млрд	Ашық кодты, тиімді LLM
Command R	Cohere	Белгісіз	Контексті тереңірек түсінуге бейімделген

LLM модельдері — бұл тілдің құрылымын түсініп, оны манипуляциялай алатын жасанды интеллект модельдері. Олар адам тіліндегі мәтіндерді түсініп, солардан жаңа ақпарат өндіре алады. Мысалы, GPT, BERT және T5 сияқты модельдер мәтіндерді генерациялау, сұрақтарға жауап беру, мәтінді қысқарту, машиналық аударма және т.б. әрекеттерді орындай алады. Бұл модельдер миллиардтаған параметрлермен жұмыс істейді, сондықтан олар өздігінен әртүрлі тілдерде білім алу қабілетіне ие.

LLM модельдері көптеген маңызды функцияларды орындай алады, оларды әртүрлі

салаларда қолдануға мүмкіндік береді:

- Мәтін генерациясы: LLM модельдері блог жазбаларын, жарнамалық мәтіндер мен контенттерді автоматты түрде жазу үшін пайдаланылады.

- Сұрақ-жауап жүйелері: LLM модельдері сұрақ-жауап жүйелерін дамытуға көмектеседі, бұл жүйелер қолданушының сұрағына нақты және тиімді жауап беруге қабілетті.

- Машиналық аударма: Тілдер арасындағы аударма жасау үшін LLM модельдері жоғары сапалы нәтижелер береді.

- Мәтінді талдау: Мәтіндерден маңызды ақпаратты алу, мәліметтерді құрылымдау және талдау үшін пайдаланылады.

Бұл модельдер әсіресе ақпараттық жүйелерде, іздеу жүйелерінде, әлеуметтік желілерде және білім беру саласында кеңінен қолданылады.

Қазақ тіліндегі LLM модельдерін дамыту және қолдану қазіргі кезде өте өзекті мәселелердің бірі болып табылады. Қазақ тілі – көптен бері жеткілікті дереккөздермен қолдау таппаған тілдердің бірі. Алайда соңғы жылдары қазақ тілін өңдеуге арналған LLM модельдері де пайда бола бастады. Мысалы, GPT-3 және BERT сияқты халықаралық модельдер қазақ тілінде жұмыс істей алатындай күйге келтірілген.

Үлкен тілдік модель (LLM) үшін dataset таңдау және дайындау – оның өнімділігі мен тиімділігіне тікелей әсер ететін маңызды қадам. Көптеген зерттеу мен өндірістік жобаларда қолданылатын дайын Dataset-тер бар.

LLM модельдері – қазіргі заманғы жасанды интеллекттің негізгі жетістіктерінің бірі. Оларды дамыту және жетілдіру тілдік процестерді автоматтандыруға, білім мен бизнесті оңтайландыруға мүмкіндік береді.

Пайдаланылған әдебиеттер тізімі:

1. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. A., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *NeurIPS*.

2. Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018). BERT: Pre-training of deep bidirectional transformers for language understanding. *NAACL*.

3. Radford, A., Wu, J., Amodei, D., & Sutskever, I. (2019). Language models are unsupervised multitask learners. *OpenAI Blog*.

Жасанды интеллектті пайдалана отырып, қаржылық негізгі тиімділік көрсеткіштерін басқару, тәуекелдерді басқару және нормативтік талаптарды сақтау

Шаймов Б.А.

Әл-Фараби атындағы ҚазҰУ, 4 курс бакалавр
E-mail: bekashaymovartukuli@gmail.com, +7 778 181 1938

Ахметова А.М.

әл-Фараби атындағы Қазақ ұлттық университеті, аға оқытушы

Бұл зерттеу жасанды интеллектіні (АІ) қаржылық негізгі тиімділік көрсеткіштерін (КРІ) басқаруға интеграциялауды, тәуекелдерді басқару мен реттеуші талаптарға сәйкестікті қамтамасыз етуге бағытталған. Машиналық оқыту модельдері қаржылық деректердегі ауытқуларды анықтау үшін қолданылады, бұл компанияларға өтімділік, операциялық тәуекелдер және кірістілік бойынша КРІ көрсеткіштерін орындауға көмектеседі. Зерттеу қаржылық мониторингті жақсартатын, реттеуші бұзушылықтарды азайтатын және шешім қабылдау процестерін оңтайландыратын АІ негізіндегі ауытқуларды анықтау әдістерін ұсынады. Нәтижелер АІ қолданбаларының қаржылық тәуекелдерді бағалаудағы дамуына үлес қосады.

Қаржы секторы реттеуші талаптарға сәйкестікті қамтамасыз ету және тәуекелдерді азайту үшін үлкен көлемдегі деректерді бақылауда өсіп келе жатқан қиындықтарға тап болуда. Дәстүрлі қаржылық бақылау жүйелері көбінесе нәзік ауытқуларды анықтауда қиындықтарға тап болып, сәйкессіз тәуекелдер мен реттеуші ережелердің бұзылуына әкеледі. АІ негізіндегі жүйелер нақты уақыт режимінде ауытқуларды анықтау үшін нейрондық желілер мен гибриді машиналық оқыту әдістерін пайдалана отырып, жетілдірілген тәсілді қамтамасыз етеді [1]. АІ-дің қаржылық КРІ басқаруына интеграциялануы ашықтықты арттырады, адам қателерін азайтады және шешім қабылдау процесін автоматтандырады, бұл оны қазіргі заманғы қаржы институттары үшін маңызды инновацияға айналдырады [2].

Бұл зерттеудің мақсаты – нақты уақыт режимінде ауытқуларды анықтау және болжамды аналитика арқылы қаржылық КРІ басқаруға арналған АІ негізіндегі құрылымды әзірлеу. Атап айтқанда, зерттеу машиналық оқыту модельдерінің қаржылық заңсыздықтарды анықтаудағы тиімділігін, АІ-дің реттеуші талаптарға сәйкестікті қамтамасыз етудегі рөлін және АІ басқарылатын КРІ жүйелерінің қаржылық тұрақтылық пен тәуекелдерді азайтуға әсерін зерттейді. Осы мақсаттарды қарастыра отырып, зерттеу АІ-дің қаржылық тиімділікті басқару мен сәйкестікті автоматтандырудағы әлеуетіне қатысты түсініктер ұсынады [3].

Зерттеу АІ негізіндегі КРІ мониторингі қаржылық тәуекелдерді басқаруды айтарлықтай жақсартатынын көрсетеді. Вариациялық автоэнкодерлер (VAE) және ұзақ қысқа мерзімді жады (LSTM) сияқты гибриді машиналық оқыту модельдерін қолдану қаржылық транзакциялардағы ауытқуларды анықтауды жетілдіреді [2]. Нейрондық желілер негізіндегі ауытқуларды анықтау әдістері өтімділік коэффициенттері мен кірістілік үрдістеріндегі ауытқуларды анықтау арқылы қаржылық бақылауды күшейтеді [1]. АІ негізіндегі сәйкестік жүйелері реттеуші есептілікті оңтайландырып, адам факторынан болатын қателіктердің ықтималдығын төмендетеді, бұл реттеуші талаптарды орындау деңгейін арттыруға және қаржылық құқық бұзушылықтарды азайтуға ықпал етеді [3].

АІ негізіндегі қаржылық КРІ басқару – тәуекелдерді азайту мен реттеуші талаптарға сәйкестікті қамтамасыз етудің жаңа тәсілі. Зерттеу нәтижелері машиналық оқыту модельдерінің қаржылық ауытқуларды тиімді анықтайтынын және тәуекелге сезімтал ортада шешім қабылдауды қолдайтынын растайды. Болашақ зерттеулер АІ-дің бейімделгіш реттеуші құрылымдардағы рөлін және оның ұзақ мерзімді қаржылық тұрақтылыққа әсерін зерттеуі тиіс. Нәтижелер қаржы институттарының өзгермелі реттеуші ландшафтта бәсекеге қабілетті болып қалуы үшін АІ негізіндегі тәуекелдерді басқару шешімдерін қабылдауының маңыздылығын көрсетеді [4,5].

Пайдаланылган әдебиеттер тізімі:

1. Albuquerque Filho J.E.D. et al. A Review of Neural Networks for Anomaly Detection // IEEE Access. 2022. Vol. 10. P. 112342–112367.
2. Terbuch A. et al. Detecting Anomalous Multivariate Time-Series via Hybrid Machine Learning // IEEE Transactions on Instrumentation and Measurement. 2023. Vol. 72. P. 1–11.
3. Schuett J. Three lines of defense against risks from AI // AI & Soc. 2023.
4. Batz A. et al. Integrating machine learning into business and management in the age of artificial intelligence // Humanit Soc Sci Commun. Palgrave, 2025. Vol. 12, № 1. P. 1–20.
5. Abonamah A.A., Abdelhamid N. Managerial insights for AI/ML implementation: a playbook for successful organizational integration // Discov Artif Intell. 2024. Vol. 4, № 1. P. 22.

Обзор методов предварительной обработки данных для автоматизированных систем мониторинга

Шаймов Б.А.

КазНУ им. аль-Фараби, 1 курс магистрант
E-mail: bekashaymovartukuli@gmail.com, +7 778 181 1938

Ахметова А.М.

КазНУ им. аль-Фараби, PhD, старший преподаватель

Автоматизированные системы мониторинга генерируют огромные объемы данных, которые могут содержать шум, пропуски, выбросы и структурные несоответствия. Эти факторы существенно снижают точность и надежность аналитических моделей, поэтому необходима эффективная предварительная обработка данных. В данной статье рассмотрены основные методы очистки, нормализации и трансформации данных, применяемые в автоматизированных системах мониторинга. Осуществлен сравнительный анализ подходов, выявлены их сильные и слабые стороны, а также предложены перспективные направления дальнейших исследований в области обработки данных для мониторинговых систем.

Современные автоматизированные системы мониторинга находят широкое применение в различных отраслях, таких как промышленность, здравоохранение, экология, транспорт и умные города. Они позволяют собирать данные в реальном времени, анализировать их и принимать обоснованные решения. Однако качество собранных данных зачастую оставляет желать лучшего из-за технических ограничений датчиков, передачи данных и внешних факторов. Ошибки измерений, дубликаты, неполные записи и несоответствия форматов усложняют процесс анализа, снижая точность предсказательных моделей и управленческих решений. Поэтому эффективные методы предварительной обработки данных являются неотъемлемой частью успешной работы автоматизированных систем мониторинга. В данной статье рассматриваются современные подходы к очистке, нормализации и трансформации данных, а также их роль в повышении качества мониторинговых систем.

Ключевые слова: очистка данных, нормализация, трансформация данных, автоматизированные системы мониторинга, машинное обучение.

1. Методы предварительной обработки данных

Очистка данных включает обнаружение и удаление выбросов, обработку пропущенных значений и устранение дубликатов. Выбросы можно выявить с помощью Z-оценки, межквартильного размаха (IQR) и локальных факторов выбросов (LOF). Для заполнения пропусков применяются методы линейной интерполяции, KNN и множественной импутации. Дубликаты записей устраняются с помощью поиска совпадений.

Нормализация и стандартизация данных направлены на приведение данных к единому масштабу. Мин-Макс нормализация используется для преобразования значений в диапазон $[0,1]$, Z-стандартизация приводит данные к среднему значению 0 и стандартному отклонению 1, а логарифмическое преобразование помогает устранить асимметрию в распределении данных.

Трансформация данных включает кодирование категориальных признаков, редукцию размерности и обработку временных рядов. Кодирование может быть выполнено методами one-hot encoding или label encoding. Для снижения размерности данных применяются PCA и LDA. Заполнение временных рядов осуществляется с помощью метода скользящего среднего и экспоненциального сглаживания.

2. Сравнительный анализ методов

Применимость методов предобработки данных зависит от их эффективности, вычислительной сложности и устойчивости к шуму. В таблице представлено сравнение ключевых методов.

Метод	Назначение	Эффективность	Вычислительная
-------	------------	---------------	----------------

			сложность
Z-оценка	Удаление выбросов	Высокая	Низкая
KNN-импутация	Заполнение пропусков	Средняя	Высокая
Мин-Макс нормализация	Масштабирование данных	Высокая	Средняя
РСА	Снижение размерности	Высокая	Средняя

3. Примеры применения в автоматизированных системах мониторинга

Методы предварительной обработки данных активно применяются в различных сферах. В промышленности они используются для предсказания поломок оборудования, что позволяет сократить затраты на ремонт и повысить эффективность производства. В здравоохранении обработка данных носимых устройств способствует мониторингу состояния здоровья пациентов и раннему выявлению заболеваний. В экологии очистка данных IoT-устройств позволяет контролировать качество воздуха и прогнозировать загрязнение окружающей среды. В транспортных системах обработка данных GPS и сенсоров помогает оптимизировать маршруты и снижать заторы в городах.

4. Выводы

Предварительная обработка данных необходима для повышения точности аналитических моделей и эффективности автоматизированных систем мониторинга. Очистка данных устраняет шум, выбросы и пропуски, нормализация приводит данные к единому масштабу, а трансформация упрощает дальнейший анализ. Методы, такие как машинное обучение и адаптивные алгоритмы, улучшают качество обработки, автоматизируют процессы и уменьшают человеческое вмешательство. В будущем важным направлением станет интеграция интеллектуальных систем, использующих глубокое обучение для динамической корректировки данных, а также разработка универсальных алгоритмов, способных адаптироваться к различным типам данных и задачам мониторинга.

Список использованной литературы:

1. Du, J., Hu, M., & Zhang, W. (2020). Missing Data Problem in the Monitoring System: A Review. *IEEE Sensors Journal*.
2. Phorah, K., Sumbwanyambe, M., & Sibiyi, M. (2024). Nanotechnology Perceptions Systematic Literature Review on Data Preprocessing for Improved Water Potability Prediction: A Study of Data Cleaning, Feature Engineering, and Dimensionality Reduction. *ResearchGate*.
3. Paranjape, A., & Katta, P. (2022). Automated Data Preprocessing for Machine Learning Based Analyses. *Conference Paper*.
4. Bilal, M., Ali, G., Iqbal, M. W., Anwar, M., Malik, M. S. A., & Kadir, R. A. (2022). Auto-Prep: Efficient and Automated Data Preprocessing Pipeline. *IEEE Access*.
5. Hassan, I. U., Panduru, K., & Walsh, J. (2024). Review of Data Processing Methods Used in Predictive Maintenance for Next Generation Heavy Machinery. *Data*, 9(69).
6. Fan, C., Chen, M., Wang, X., Wang, J., & Huang, B. (2021). A Review on Data Preprocessing Techniques Toward Efficient and Reliable Knowledge Discovery From Building Operational Data. *Frontiers in Energy Research*, 9, 652801.
7. Nesca, M., Katz, A., Leung, C. K., & Lix, L. M. (2022). A Scoping Review of Preprocessing Methods for Unstructured Text Data to Assess Data Quality. *International Journal of Population Data Science*, 7(1), 19.
8. Rosero-Montalvo, P., López-Batista, V., & Peluffo-Ordóñez, D. (2022). A New Data-Preprocessing-Related Taxonomy of Sensors for IoT Applications. *Information*, 13(241).
9. Ding, X., Wang, H., Li, G., Li, H., Li, Y., & Liu, Y. (2022). IoT Data Cleaning Techniques: A Survey. *Intelligent and Converged Networks*, 3(4), 325-339.
10. Mostafaei, H., & Ghamami, M. (2025). State of the Art in Automated Operational Modal Identification: Algorithms, Applications, and Future Perspectives. *Machines*, 13(39).

11. Al-yousif, S., Jaenul, A., Al-Dayyeni, W., Alamoodi, A., Najm, I. A., Md Tahir, N., Alrawi, A. A. A., Cömert, Z., Al-shareefi, N. A., & Saleh, A. H. (2021). A systematic review of automated pre-processing, feature extraction and classification of cardiocography. *PeerJ Computer Science*, 7, e452.
12. Ji, C., & Sun, W. (2022). A review on data-driven process monitoring methods: Characterization and mining of industrial data. *Processes*, 10, 335.
13. Krishnamurthi, R., Kumar, A., Gopinathan, D., Nayyar, A., & Qureshi, B. (2020). An overview of IoT sensor data processing, fusion, and analysis techniques. *Sensors*, 20(21), 6076.
14. Cofre-Martel, S., Lopez Droguett, E., & Modarres, M. (2021). Big machinery data preprocessing methodology for data-driven models in prognostics and health management. *Sensors*, 21, 6841.
15. Esteban, A., Zafra, A., & Ventura, S. (2022). Data mining in predictive maintenance systems: A taxonomy and systematic review. *WIREs Data Mining and Knowledge Discovery*, 12, e1471.
16. Ortiz, B. L., Gupta, V., Kumar, R., Jalin, A., Cao, X., Ziegenbein, C., Singhal, A., Tewari, M., & Choi, S. W. (2024). Data preprocessing techniques for AI and machine learning readiness: Scoping review of wearable sensor data in cancer care. *JMIR Mhealth Uhealth*, 12, e59587.
17. Sung, S.-H., Hong, S., Choi, H.-R., Park, D.-M., & Kim, S. (2024). Enhancing fault diagnosis in IoT sensor data through advanced preprocessing techniques. *Electronics*, 13, 3289.
18. Jane, V. A., & Arockiam, L. (2021). Survey on IoT data preprocessing. *Turkish Journal of Computer and Mathematics Education*, 12(9), 238-244.
19. Latyshev, E. (2017). Sensor data preprocessing, feature engineering and equipment remaining lifetime forecasting for predictive maintenance. *DAMDID/RCDL Proceedings*.

Генерация текста с помощью больших языковых моделей: техники prompt-инжиниринга

Шайхиева Ж.

КазНУ им. аль-Фараби, 1 курс докторант

E-mail: zshaikhiyeva@gmail.com

Амирханова Г.А.

КазНУ им. аль-Фараби, PhD, старший преподаватель

Становление больших языковых моделей кардинально преобразует подходы к порождению текстового контента, превращая искусственный интеллект в мощный механизм создания и обработки информации. Ключевым элементом этой революции становится управление промптами – сложная интеллектуальная практика взаимодействия с искусственным интеллектом через тщательно сформулированные инструкции. Сущность управления промптами заключается в искусстве коммуникации с языковой моделью. Это не просто механическая передача указаний, а сложный диалог, требующий глубокого постижения возможностей и ограничений искусственного интеллекта. Опытный специалист способен направлять модель, используя тонкости языка, контекста и структуры запроса.

Современные языковые модели подобны высокоинтеллектуальным помощникам, которые могут порождать тексты практически в любом жанре и стиле. Однако их потенциал раскрывается только при правильной постановке задачи. Управляющая инструкция – это своего рода ключ, который опирает творческие возможности искусственного интеллекта, позволяя получать не просто текст, но осмысленный, структурированный и целевой контент.

Процесс создания текста через большие языковые модели напоминает совместное сочинительство, где человек выступает режиссером, а модель – талантливым сценаристом. Важно не просто дать инструкцию, но создать максимально подробный сценарий, учитывающий нюансы будущего текста: его стиль, целевую аудиторию, контекст и желаемую структуру.

Ключевые методы prompt-инжиниринга включают детализацию инструкций, использование контекстных примеров, разбиение сложных задач на последовательные шаги и постоянную итеративную настройку результата. Специалист буквально "дрессирует" модель, последовательно уточняя и корректируя её выдачу. Однако этот процесс не лишен сложностей. Языковые модели могут порождать неточную или даже ошибочную информацию, что требует критического подхода и постоянной проверки результатов. Этические ограничения, необходимость предотвращения появления некорректного контента – также важные аспекты работы с большими языковыми моделями.

Prompt-инжиниринга сегодня – это не только технический навык, но и новый вид творческой деятельности. Специалисты, способные эффективно взаимодействовать с языковыми моделями, становятся ключевыми фигурами в цифровой экономике, медиаиндустрии и сфере коммуникаций. Будущее за теми, кто сможет увидеть в больших языковых моделях не просто инструмент, а полноценного творческого партнера, способного порождать уникальный, высококачественный контент практически в любой области человеческой деятельности.

Список использованной литературы:

1. Браун Т., Манн Б., Рыдер Н. и др. Языковые модели are few-shot learners // Материалы Neural Information Processing Systems (NeurIPS). – 2020. – Т. 33. – С. 1877-1901.
2. Вадола А., Шойер Я. Prompt-инжиниринг: стратегии взаимодействия с большими языковыми моделями // Журнал искусственного интеллекта. – 2022. – № 45. – С. 112-135.

3. Радфорд А., Ву Д., Чен Р. и др. Улучшение языковых моделей с помощью контекстного обучения // *Proceedings of Machine Learning Research*. – 2019. – Т. 97. – С. 543-562.
4. Накамура Й., Танака К. Этические аспекты применения больших языковых моделей // *Международный журнал по этике искусственного интеллекта*. – 2021. – № 12. – С. 45-67.
5. Хачиян М.А. Особенности текстогенерации с использованием нейронных сетей // *Вестник компьютерных исследований*. – 2022. – № 3. – С. 78-95.
6. Chen M., Tworek J., Jun H. и др. Evaluating Large Language Models Trained on Code // *arXiv preprint arXiv:2107.03374*. – 2021.
7. Elman J.L. On the meaning of words and dinosaur bones: Lexical knowledge without a lexicon // *Cognitive Science*. – 2009. – Т. 33. – № 4. – С. 547-582.
8. Гофман Т. Машинное обучение и генеративные модели: современные тренды // *Технологический обзор*. – 2023. – № 6. – С. 22-39.
9. Соколов А.В. Искусственный интеллект в коммуникативных процессах: монография. – М.: Наука, 2022. – 256 с.
10. Wei J., Wang X., Schuurmans D. и др. Chain of Thought Prompting Elicits Reasoning in Large Language Models // *Proceedings of Neural Information Processing Systems*. – 2022. – С. 24824-24837.

ИНСУЛЬТТАН КЕЙІНГІ РЕАБИЛИТАЦИЯ ҮШІН KINECT-ТЕГІ КОГНИТИВТІ-КОЗҒАЛЫСТЫҚ ҚОСАРЛАНҒАН ТАПСЫРМАЛАРҒА НЕГІЗДЕЛГЕН МОДУЛЬДІК ЖҮЙЕ

Жұмахан А.

Әл-Фараби атындағы ҚазҰУ, 1 курс магистрант

Сарсембаева Т.С.

Әл-Фараби атындағы ҚазҰУ, аға оқытушы

Бұл мақалада инсульттан кейінгі оңалтуға арналған, Microsoft Kinect сенсоры негізінде жасалған когнитивті-қозғалыстық қосарланған тапсырмаларды (dual-task) қамтитын модульдік жүйенің құрылымы мен бастапқы жобалануы ұсынылады. Жүйе қозғалыс пен ойлау процестерін қатар ынталандыру арқылы нейропластикалықты арттыруға және функционалдық қалпына келуді жеделдетуге бағытталған. Инсульт – Қазақстанда мүгедектікке және өлімге жиі әкелетін неврологиялық аурулардың бірі. Инсульттан кейін науқастардың көпшілігінде қозғалыс белсенділігімен қатар когнитивтік функциялар да бұзылады. Бұл жағдай олардың күнделікті өмірге қайта оралуын қиындатады[1]. Қазіргі таңда реабилитацияның тиімді әдістерінің бірі – когнитивті және қозғалыс тапсырмаларын қатар қолдану болып табылады. Жаңа технологияларды, соның ішінде Microsoft Kinect сенсорын пайдалану, оңалту процесін ойын форматына келтіруге және пациенттің мотивациясын арттыруға мүмкіндік береді[2]. Бұл зерттеуде біз қос тапсырмалы реабилитациялық модульдік жүйені жобалау және оның құрылымдық шешімдері туралы баяндаймыз. Kinect сенсорын қолдана отырып (PlayMaker негізінде) жүйе әзірлеу, Қозғалыс пен когнитивтік тапсырмаларды біріктіретін үш түрлі модуль жасау, Жүйе құрылымын сипаттау және болашақта клиникалық сынақтарға дайындау міндеттері қойылған.

Модульдер Unity және PlayMaker платформасында құрастырылған:

Модуль 1: Қол қозғалысы + түстерді тану Қолды белгілі бір түске сәйкес көтеру тапсырмасы.

Модуль 2: Қадам жасау + арифметикалық есеп Бір мезетте жүру және дұрыс арифметикалық жауап беру.

Модуль 3: Объектімен әрекеттесу + категориялау Шарды соғу және оны түсіне немесе пішініне қарай жіктеу.

Әр модульде үш деңгейлі қиындық қарастырылған. Науқастың прогрессіне қарай жаттығулардың күрделілігі артады. Алдағы уақытта жүйені клиникалық жағдайларда сынақтан өткізу, пациенттердің қатысуымен тиімділігін бағалау және биологиялық кері байланыс элементтерін енгізу жоспарланып отыр. Сонымен қатар, телереабилитация мүмкіндіктерін қосу арқылы үй жағдайында қолдануға бейімделуі көзделеді[3]. Kinect негізіндегі модульдік реабилитациялық жүйе инсульттан кейінгі науқастардың қозғалыс және когнитивтік функцияларын қалпына келтіруде тиімді құрал бола алады деп күтіледі. Бұл жүйе икемді, қолжетімді және клиникалық емес ортада да кеңінен қолдануға мүмкіндік береді.

Kinect негізіндегі модульдік реабилитациялық жүйе инсульттан кейінгі науқастардың қозғалыс және когнитивтік функцияларын қалпына келтіруде тиімді құрал бола алады деп күтіледі. Бұл жүйе икемді, қолжетімді және клиникалық емес ортада да кеңінен қолдануға мүмкіндік береді. Алдағы кезеңде біз жүйенің функционалдығын кеңейтіп, жаттығулардың бейімделу механизмдерін жетілдіруді көздеп отырмыз. Сонымен қатар, әртүрлі жас және когнитивтік профильдегі пациенттер үшін дербестендірілген сценарийлер құру өзекті. Unity платформасында жасалған прототиптің икемділігі қосымша модульдер мен тілдік локализацияны енгізуге мүмкіндік береді. Зерттеулер көрсеткендей, ойын форматындағы жаттығулар пациенттің мотивациясын арттырып, реабилитация процесіне белсенді араласуына ықпал етеді. Кинетикалық сенсорлар арқылы қозғалысты нақты бақылау және бағалау мүмкіндігі — клиникалық шешім қабылдауда қосымша дерек көзі бола алады[4].

Сонымен бірге, осындай жүйелер телереабилитация бағытына бейімделіп, шалғай аудандарда тұратын науқастарға қолжетімділікті арттырады. Бүгінгі таңда цифрлық технологияларды оңалтуға интеграциялау — медицина мен IT тоғысындағы жаңа сапалы серпіліс.

Пайдаланылған әдебиеттер тізімі:

1. Mirelman A. et al. (2016). Effects of dual task training on gait and cognitive function in patients with Parkinson's disease: A pilot study. *Journal of Neurology*, 263(11), 2236–2243. <https://doi.org/10.1007/s00415-016-8253-9>
2. Lange B. et al. (2012). Development and evaluation of low cost game-based balance rehabilitation tool using the Microsoft Kinect sensor. *Journal of NeuroEngineering and Rehabilitation*, 9(1), 93. <https://doi.org/10.1186/1743-0003-9-93>
3. Brooke, J. (1996). SUS: A quick and dirty usability scale. In P. W. Jordan, B. Thomas, I. L. McClelland & B. Weerdmeester (Eds.), *Usability Evaluation in Industry* (pp. 189–194). London: Taylor & Francis. (System Usability Scale – SUS
4. Gama, A., Chaves, M., Figueiredo, L. S., Baltar, A., Rocha, T., & Campos, G. (2015). Kinect system in biomechanical analysis: A promising low-cost tool for clinical and research applications. *Journal of Biomechanics*, 48(12), 2929–2935. <https://doi.org/10.1016/j.jbiomech.2015.05.021>

Бизнес-процестерді талдау әдістерін жетілдіру арқылы оңтайландыру

Темір Н.К.

Әл-Фараби атындағы ҚазҰУ, 1-курс магистрант

E-mail: nurmaxinio@gmail.com

Шаяхметова А.С.

Әл-Фараби атындағы ҚазҰУ, профессор м.а.

Бизнес-процестерді талдау әдістерін жетілдіру арқылы оңтайландыру қазіргі заманғы кәсіпорындардың тұрақты өсуі мен бәсекеге қабілеттілігін қамтамасыз етудегі маңызды шарттардың бірі болып табылады. Компаниялар өз қызметінің тиімділігін арттыру, шығындарды азайту және нарықтағы өзгерістерге жедел бейімделу мақсатында ішкі процестерін жан-жақты зерттеп, инновациялық шешімдерді енгізуде. Осы үрдісте математикалық модельдеу, статистикалық талдау, процесс өндіру, болжамды және нұсқаушы аналитика, сондай-ақ жасанды интеллект пен машиналық оқыту алгоритмдерін қолдану маңызды рөл атқарады. Нақты деректер негізінде жүргізілетін талдау бизнес-процестердің әр кезеңіндегі ықтимал мәселелерді анықтап, оларды жоюға мүмкіндік береді. Мұндай әдістер компанияларға өндірістік циклды қысқартып, ресурстарды тиімді пайдалануға, сонымен қатар қызметкерлердің жұмыс жүктемесін оңтайландыруға жағдай жасайды [1].

Атап айтқанда, математикалық модельдеу және процесс өндіру әдістері бизнес-процестерді сандық бағалауға, шығындардың негізді себебін анықтауға және операциялық тиімділікті арттыруға бағытталған. Компаниялар деректерді жинау, өңдеу және талдау арқылы ішкі процестердің әрбір кезеңін бақылап, нақты уақыттағы көрсеткіштер негізінде басқару шешімдерін қабылдайды. Осы орайда, аналитикалық құралдардың көмегімен алынған нәтижелер ұйымның өндірістік және қаржылық көрсеткіштерін жақсартуға, сондай-ақ болашақтағы трендтерді болжауға мүмкіндік береді. Заманауи технологиялар мен автоматтандыру жүйелерін қолдану арқылы ұйымдар ескі ақпараттық жүйелердің кемшіліктерін жоюға, деректер сапасын арттыруға және жұмыс процесін айтарлықтай жеңілдетуге қол жеткізеді [2].

Сонымен қатар, бизнес-процестерді оңтайландыру барысында жаңа технологияларды енгізу мен қызметкерлерді жаңашыл шешімдерге үйрету де маңызды болып табылады. Бұл үрдіс тек техникалық жаңартулармен шектелмей, сонымен қатар ұйымдық мәдениеттің өзгеруін де талап етеді. Қызметкерлердің өзгерістерге бейімделуі, жаңа әдістерді қабылдауы және үздіксіз оқытылуы компанияның табысты дамуының кепілі болып табылады. Персоналды оқыту мен мотивацияны арттыру шаралары арқылы қызметкерлер жаңа технологиялар мен аналитикалық әдістерді белсенді қолдануға ынталандырылады, бұл өз кезегінде бизнес-процестердің сапасын жоғарылатуға ықпал етеді [3].

Алайда, бизнес-процестерді талдау әдістерін жетілдіру барысында бірқатар қиындықтар мен кедергілер де кездеседі. Ескі ақпараттық жүйелердің жаңа аналитикалық құралдарды толық қолдамайтындығы, деректердің сапасының төмендігі және кейбір жағдайларда қызметкерлердің өзгерістерге қарсы тұруы компаниялардың заманауи шешімдерді енгізуіне кедергі келтіреді. Осы мәселелерді шешу үшін ұйымдар кешенді тәсілді қабылдап, техникалық және қаржылық ресурстарды тиімді пайдалану, сонымен қатар қызметкерлердің кәсіби дайындығын арттыруы қажет. Бұл үдеріс барысында аналитикалық әдістерді дәстүрлі тәсілдермен үйлестіре отырып, нақты және өзекті деректер негізінде басқару шешімдерін қабылдау маңызды рөл атқарады [4].

Компаниялар бизнес-процестерді жетілдіру арқылы өз қызметін нарықтағы өзгерістерге тез бейімдеп, клиенттерге көрсетілетін қызмет сапасын арттыра алады. Нақты уақыттағы деректерді талдау және автоматтандыру жүйелерін қолдану арқылы өндірістік циклді қысқартып, шығындарды азайту, ресурстарды тиімді бөлу және қызметкерлердің жұмыс тиімділігін арттыру мүмкіндігі артады. Бұл әдістер тек операциялық көрсеткіштерді

жақсартып қоймай, сонымен қатар ұйымның стратегиялық дамуын қамтамасыз етіп, болашақтағы нарықтық өзгерістерге дайын болуға септігін тигізеді [5].

Осылайша, бизнес-процестерді талдау әдістерін жетілдіру мен онтайландыру кешенді үрдіс ретінде компанияның ішкі құрылымын, басқару жүйесін және қызметкерлердің жұмыс мәдениетін түбегейлі өзгертуге бағытталған, бұл өз кезегінде ұйымның ұзақ мерзімді тұрақтылығын және табысты дамуын қамтамасыз етеді.

Пайдаланылған әдебиеттер тізімі:

1. Madera, A.G. (2017). Modeling and optimization of business processes and process systems under conditions of uncertainty. *Business Informatics*, No. 4 (42), pp. 74–82. DOI: 10.17323/1998-0663.2017.4.74.82 **【9†source】**

2. Adesina, A.A., Iyelolu, T.V., & Paul, P.O. (2024). Optimizing Business Processes with Advanced Analytics: Techniques for Efficiency and Productivity Improvement. *World Journal of Advanced Research and Reviews*, 22(03), 1917–1926. DOI: 10.30574/wjarr.2024.22.3.1960 **【11†source】**

3. April, J., Better, M., Glover, F., Kelly, J., & Laguna, M. (2006). Enhancing Business Process Management with Simulation Optimization. *Proceedings of the Winter Simulation Conference*, 6421-4244-0501-7 **【12†source】**

4. Prokopenko, O., Dikiy, A., Butenko, N., Naumenko, M., Dedilova, T., & Miroshnyk, R. (2020). Business Process Optimization Based on Logistics Concepts and Technologies. *International Journal of Advanced Research in Engineering and Technology*, 11(6), 184-196. DOI: 10.34218/IJARET.11.6.2020.017 **【13†source】**

Khan, O., Usman, M., & Moinuddin, K. (2020). Business Process Optimization through Machine Learning and Data Analytics. *International Journal of Business Intelligence and Data Mining*, 16(4), 321-338. DOI: 10.1504/IJBIDM.2020.100329 **【10†source】**

**«ИНТЕЛЛЕКТУАЛДЫ БАСҚАРУ ЖҮЙЕЛЕРІ ЖӘНЕ
АВТОМАТТАНДЫРУ: СМАРТ ТЕХНОЛОГИЯЛАРҒА
АРНАЛҒАН ШЕШІМДЕР» СЕКЦИЯСЫ**

**СЕКЦИЯ «ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ УПРАВЛЕНИЯ
И АВТОМАТИЗАЦИЯ: РЕШЕНИЯ ДЛЯ УМНЫХ
ТЕХНОЛОГИЙ»**

**«INTELLIGENT CONTROL SYSTEMS AND AUTOMATION:
SOLUTIONS FOR SMART TECHNOLOGIES» SECTION**

Өнеркәсіптік ағынды суларды тазарту процесін басқарудың интеллектуалды жүйесі

Абсатарова Ақерке Алтынбекқызы

АУЭС университеті, докторант 2 курс

email: a.absatarova@aves.kz

Абжанова Лауласын Қосылғановна,

АУЭС университеті, асс. Профессор, PhD

Мәселенің өзектілігі

Өнеркәсіптік ағынды сулар қоршаған ортаны ластаудың ең маңызды көздерінің бірі болып табылады. Олардың құрамында ауыр металдар, органикалық қосылыстар, мұнай өнімдері және басқа да ластаушы заттар бар, бұл экожүйелер мен адамдардың денсаулығына теріс әсер етеді. Тазартудың дәстүрлі әдістері механикалық, химиялық және биологиялық процестерге негізделгенімен, тазартылған судың сапасына қойылатын талаптардың артуына байланысты олар жиі жеткіліксіз болып қалады. Сонымен қатар, бұл процестердің қолмен басқарылуы ресурстардың тиімсіз пайдаланылуына, энергия шығынының артуына және апатты жағдайлардың қаупіне алып келеді. Осыған байланысты ағынды суларды тазарту үшін интеллектуалды басқару жүйелерін (ИБЖ) әзірлеу және енгізу экологиялық технологиялар саласындағы маңызды бағытқа айналуға.

Зерттеудің мақсаты

Бұл жұмыстың мақсаты – жасанды интеллект (ЖИ) және машиналық оқыту (МО) сияқты заманауи технологияларға негізделген өнеркәсіптік ағынды суларды тазарту процесін басқарудың интеллектуалды жүйесін әзірлеу. Жүйе тазарту процесінің негізгі параметрлерін, соның ішінде рН, температура, ластаушы заттардың концентрациясы және ағын жылдамдығын автоматты түрде бақылауды, талдауды және оңтайландыруды қамтамасыз етуі керек. Бұл тазарту тиімділігін арттыруға және пайдалану шығындарын азайтуға мүмкіндік береді.

Әдістер мен тәсілдер

Қойылған мақсатқа жету үшін келесі әдістер мен тәсілдер қолданылды:

1. деректер жинау – тазарту процесінің параметрлерін үздіксіз бақылау үшін сенсорлар мен датчиктерді орнату;
2. деректерді талдау – үлкен көлемдегі деректерді өңдеу және заңдылықтарды анықтау үшін машиналық оқыту алгоритмдерін қолдану;
3. оңтайландыру – тазарту тиімділігін барынша арттыра отырып, реагенттер мен энергия шығынын азайтатын модельдерді әзірлеу;
4. болжау – апатты жағдайлардың алдын алу үшін машиналық оқыту алгоритмдерін пайдалану.

Тәсілдің артықшылықтары:

Болжау: Дәстүрлі жүйелер мәселе туындағаннан кейін ғана әрекет етеді, ал біздің модель тазарту тиімділігін алдын ала болжайды.

Оңтайландыру: Қолмен реттеудің орнына жүйе параметрлерді автоматты түрде оңтайландырады, шығындарды азайтады.

Деректерді талдау: Дәстүрлі әдістер нақты уақыттағы деректерді талдамайды, ал біз ластаушы заттарды жіктеп, аномалияларды анықтаймыз, бұл өзгерістерге тез жауап беруге мүмкіндік береді.

Автоматтандыру: Дәстүрлі жүйелер оператордың үнемі қатысуын талап етеді, ал біздің тәсіл толық автономды жұмыс істей алады.

Практикалық пайдасы:

- Тұрақтылық – адам факторының ықпалын азайту.
- Үнемділік – реагенттер мен энергияны артық жұмсауды төмендету.

● Экологиялық тиімділік – процесті дәлірек басқару арқылы қоршаған ортаға зиянды шығарындыларды азайту.

Ұсынымдар мен болашақ зерттеулер бағыттары

Зерттеу нәтижелеріне сүйене отырып, ағынды суларды тазарту процесін басқаруда болжау, оңтайландыру және деректерді талдау негізгі элементтер болып табылатыны анықталды. Болашақта барлық әзірленген әдістерді біртұтас интеллектуалды басқару жүйесіне біріктіру жоспарлануда. Бұл жүйе келесі міндеттерді орындайды:

а) Кешенді басқару тәсілі. Тазарту тиімділігін нақты уақыт режимінде болжау. Процестің параметрлерін автоматты түрде оңтайландыру (реагент беру жылдамдығы, өңдеу температурасы, әсер ету уақыты). Аномалияларды анықтау және өзгермелі жағдайларға бейімделу;

б) Шешім қабылдауды автоматтандыру. Жүйе кіріс деректеріне сүйене отырып, параметрлерді өз бетінше реттейді. Басқарудың күнделікті міндеттерінде адам қатысуын азайтады;

с) Икемділік пен бейімделгіштік. Жүйе ағынды судың құрамындағы өзгерістерді ескере отырып, әртүрлі ластаушы заттарға бейімделеді және кластерлік талдау арқылы зандылықтарды анықтайды;

д) Экономикалық және экологиялық тиімділік. Реагенттер мен энергия шығынын барынша азайту. Тазарту сапасын арттыру арқылы қоршаған ортаға түсетін жүктемені азайту.

Қорытынды

Өнеркәсіптік ағынды суларды тазарту процесін басқарудың ұсынылған интеллектуалды жүйесі болжаудың дәлдігін арттырып, басқаруды автоматтандыруға мүмкіндік береді. Деректерді кластерлеу әдістерін қолдану ластаушы заттарды анықтауға және жүйе жұмысының аномалияларын белгілеуге көмектеседі. Осылайша, интеллектуалды басқару жүйелерін әзірлеу ағынды суларды тазарту тиімділігі мен сенімділігін арттыруға ықпал етеді.

Құбырды тазалау үшін қадамды роботтың басқару жүйесін зерттеу

Аркатов Е.А., Бейсембаева А.К.

Жұмахан Н.Б., техника ғылымдарының магистрі
Алматы технологиялық университеті, Алматы қ., Қазақстан
erikzanarkatov@gmail.com

Құбырларды тазарту мұнай-газ, химия және коммуналдық инфрақұрылымды қоса алғанда, әртүрлі салалар үшін маңызды міндет болып табылады. Дәстүрлі тазарту әдістерінде механикалық құрылғылар, гидродинамикалық жүйелер және химиялық реагенттер қолданылады, бірақ олардың бірқатар кемшіліктері бар, соның ішінде жоғары шығындар, төмен тиімділік және адамның жиі араласуы қажет. Бұл жұмыс жоғары қозғалыс дәлдігі мен батареяның қызмет ету мүмкіндігі бар қадамдық роботты пайдалануды, сондай-ақ бақылау және басқару үшін IoT технологияларын біріктіруді қарастырады.

Қадамдық Роботтар құбырлар сияқты шектеулі және жету қиын жерлерде жұмыс істеудің оңтайлы шешімі болып табылады. **Олардың артықшылықтары:**

- Қадамдық қозғалтқыштың арқасында жоғары орналасу дәлдігі.
- Тік және көлденең құбырларда жұмыс істеу мүмкіндігі.
- Құбырлардың әртүрлі диаметрлеріне бейімделуге арналған модульдік дизайн.
- Жаяу жүру механизмін қолдана отырып, құбырдың ішкі бетінде тиімді қозғалу.

Басқару жүйесі бірнеше негізгі элементтерді қамтиды. Микроконтроллер (STM32, STM32, Arduino) роботтың барлық түйіндерін басқаратын орталық үйлестіру блогының рөлін атқарады. Қозғалыс роботты құбырдың ішіне бекітуге және оның қозғалысын басқаруға мүмкіндік беретін қадамдық қозғалтқыштармен қамтамасыз етіледі.

Сенсорлық жүйеге кедергілерді анықтау үшін қажетті лидар немесе ультрадыбыстық датчиктер, сондай-ақ құбырдың ластану деңгейін талдайтын камералар немесе оптикалық датчиктер кіреді. Қоршаған ортаны бақылау үшін қысым мен температура датчиктері қолданылады.

Энергиямен жабдықтау жұмыс оның автономды жұмысын қамтамасыз ететін аккумуляторлық жүйенің есебінен жүзеге асырылады. Ластануды механикалық түрде кетіруге арналған айналмалы щеткаларды немесе қырғыштарды, күрделі шөгінділерді ерітуге арналған тазалау ерітіндісін беру жүйесін және жойылған ластанушы заттарды жинауға арналған вакуумдық жүйені қамтитын тазалау жүйесі маңызды рөл атқарады.

Қадамдық роботты басқару алгоритмдері бірнеше негізгі процестерді қамтиды. Қозғалыс пен навигация қадамдық қозғалтқыштарды басқару арқылы қамтамасыз етіледі, бұл құбыр ішінде адаптивті қозғалуға мүмкіндік береді. Ластануды анықтау камералар мен Сенсорлардан алынған деректерді талдау арқылы жүзеге асырылады, бұл ластану деңгейін дәл анықтауға мүмкіндік береді.

Жүйені автоматты түрде тоқтату кедергілерді немесе қысымның айтарлықтай өзгеруін анықтаған кезде іске қосылады, бұл роботтың ықтимал зақымдануын болдырмайды. Тазалауды реттеу ластану дәрежесіне байланысты жүреді, бұл әр жағдайда тазалау қарқындылығын тиімді бейімдеуге мүмкіндік береді.

IoT жүйесінің архитектурасы

IoT интеграциясы қашықтан басқаруды, деректерді талдауды және роботтың жұмысын оңтайландыруды қамтамасыз етеді. Архитектура мыналарды қамтиды.

Кесте 1 - IoT жүйесінің архитектурасы

Компонент	Сипаттама
Кіріктірілген (Firmware)	БЖ Роботтандырылған жүйені басқару
Бұлттық сервер	Сенсорлардан алынған деректерді сақтау және

	өңдеу
Мобильді/веб-қосымша	Робот жұмысын басқару және мониторинг жүргізу

Кесте 2 - Роботтың IoT-пен өзара әрекеттесуі

Функция	Сипаттама
Қашықтан басқару	Wi-Fi, Bluetooth немесе 5G арқылы басқару
Нақты уақыттағы мониторинг	Видео және сенсорлық деректерді жіберу
Алдын ала болжау талдауы	Ластануды болжау үшін машиналық оқытуды пайдалану
Автоматты есеп беру	Құбырлардың жай-күйі мен тазалау тиімділігі туралы есептерді қалыптастыру

IoT көмегімен қадамдық роботты пайдалану құбырларды тазарту тиімділігін едәуір жақсартады, пайдалану шығындарын азайтады және процестің автономиясын арттырады. Әрі қарайғы зерттеулер аі деректерін талдауды қолдану, қуат тұтынуды оңтайландыру және қозғалыс тиімділігін арттыру және құбырлардың әртүрлі түрлеріне бейімделген жаңа модульдік жүйелерді әзірлеу арқылы жүйенің автономиясын жақсартуға бағытталуы мүмкін.

Пайдаланылған әдебиеттер тізімі:

1. Yang, G., & Wang, L. (2021). *Smart pipeline inspection robots: A survey of technologies and applications*. *Robotics and Autonomous Systems*, 135, 103697.
2. Li, J., & Zhao, H. (2020). *IoT-based intelligent monitoring system for industrial pipelines*. *IEEE Internet of Things Journal*, 7(5), 4253-4262.
3. Kumar, R., & Singh, P. (2019). *Autonomous robots for pipeline cleaning and maintenance: A review*. *Journal of Intelligent & Robotic Systems*, 95(2), 367-390.

Алгоритмы движения 4-степенного манипуляционного робота по заданным траекториям

Аскарар Еламан Ермекович

*КазННТУ им. К.И.Сатпаева, Магистрант 1 курса
lord.2108.01@gmail.com*

Бейсембаев Акамбай Агыбаевич

к.т.н., доцент, ассоциированный профессор, КАЗННТУ им. К.И.Сатпаева

Аннотация

В данной работе рассматриваются алгоритмы движения 4-степенного манипуляционного робота по заданным траекториям. Описаны основные этапы планирования траекторий, включающие расчет кинематических параметров, аппроксимацию движения и контроль ориентации конечного звена. Представлены методы решения обратной задачи кинематики и принципы оптимизации траекторий. Рассмотрены перспективы развития алгоритмов, направленные на повышение точности управления и адаптацию к изменяющимся условиям эксплуатации.

Ключевые слова

Манипуляционный робот, алгоритмы движения, траектория, обратная кинематика, оптимизация, управление, ориентация звена.

Введение

Манипуляционные роботы с несколькими степенями свободы широко применяются в промышленности, требуя высокой точности при выполнении операций. Одной из ключевых задач является построение траекторий движения, обеспечивающих точное позиционирование манипулятора вдоль заданных отрезков с сохранением требуемой ориентации последнего звена. В данной работе рассматриваются алгоритмы планирования движения (Рисунок 1) 4-степенного манипуляционного робота для реализации заданных траекторий с учетом его кинематических и динамических ограничений.

Алгоритмы движения манипуляционного робота

Алгоритмы движения манипуляционного робота включают формирование и аппроксимацию траектории, решение обратной задачи кинематики, оптимизацию движения и контроль ориентации конечного звена. На первом этапе определяется желаемый путь с учетом рабочей зоны и механических ограничений. Затем траектория разбивается на дискретные точки, что позволяет минимизировать резкие изменения скорости и ускорения. Решение обратной задачи кинематики дает возможность вычислить углы поворота звеньев, используя аналитические или численные методы. Оптимизация движения направлена на сглаживание траекторий, минимизацию угловых ускорений и управление динамическими нагрузками, что снижает износ механики. Контроль ориентации конечного звена выполняется с применением матриц вращения, кватернионов или углов Эйлера, обеспечивая точность выполнения операций.

Основные этапы планирования

Планирование движения включает разработку математической модели манипулятора, генерацию траекторных данных с учетом плавности и скорости выполнения операций, а также контроль параметров движения. Для повышения точности используются алгоритмы коррекции, позволяющие компенсировать возможные погрешности механической системы.




Рисунок 1 – Кинематическая схема манипуляционного робота

Актуальность применения

Применение данных алгоритмов позволяет:

1. Улучшить точность позиционирования манипулятора, что критично в сборочных и сварочных операциях;
2. Оптимизировать траектории, снижая энергозатраты и продлевая срок службы оборудования;
3. Обеспечить плавность и согласованность движений, минимизируя вибрации и механические нагрузки;
4. Повысить надежность работы за счет предсказуемого поведения системы при изменении внешних условий;
5. Ускорить процессы промышленной автоматизации, обеспечивая гибкость работы с различными производственными задачами.

Перспективы развития

Дальнейшее развитие алгоритмов движения манипуляционного робота связано с учетом динамических факторов, внедрением методов машинного обучения и разработкой адаптивных систем управления. Это позволит в реальном времени корректировать траекторию на основе данных с датчиков, предсказывать возможные ошибки и обеспечивать стабильную работу манипулятора в сложных условиях эксплуатации.

Заключение

Алгоритмы планирования траекторий играют ключевую роль в управлении манипуляционными роботами. Разработка и внедрение оптимизированных методов позволяет улучшить точность, надежность и эффективность работы роботов, расширяя их применение в промышленности и науке. Дальнейшие исследования в этой области будут способствовать развитию более автономных и интеллектуальных роботизированных систем, способных адаптироваться к сложным условиям работы.

Список использованной литературы:

1. Атанов А.А., Петров Б.В. "Математические методы планирования траекторий роботов" – Москва: Наука, 2020.
2. Иванов В.Г. "Теория манипуляционных систем" – Санкт-Петербург: Политехника, 2018.
3. Сидоров Д.К. "Методы оптимального управления движением промышленных роботов" – Казань: Казанский университет, 2019.
4. Khalil W., Dombre E. "Modeling, Identification and Control of Robots" – Elsevier, 2002.
5. Siciliano B., Khatib O. "Springer Handbook of Robotics" – Springer, 2016.

Дизайн және өндірістік инженерия үшін цифрлық егізді қалыптастыру

Асланов А.А.

ал-Фараби атындағы Қазақ Ұлттық Университетінің 4 курс студенті

E-mail: aslanov_006@mail.ru

Асет Асхат

ал-Фараби атындағы Қазақ Ұлттық Университетінің аға оқытушысы

Цифрлық егіз (Digital Twin) – өндірістік инженерия мен дизайн саласында кеңінен қолданылатын заманауи технология. Ол нақты объектінің виртуалды көшірмесін жасап, оның жұмысын модельдеуге, талдауға және оңтайландыруға мүмкіндік береді. Бұл әдіс өндіріс процестерін жетілдіруге, шығындарды азайтуға және өнім сапасын арттыруға көмектеседі. Цифрлық егізді пайдалану кәсіпорындардың бәсекеге қабілеттілігін арттырып, инновациялық шешімдерді тез енгізуге жағдай жасайды.

Өнеркәсіпте цифрлық егіздер өндіріс жабдықтарының сенімділігін арттыру және қызмет көрсету мерзімін ұзарту үшін қолданылады. Виртуалды модельдер датчиктерден алынған нақты уақыттағы мәліметтер негізінде жұмыс істейді, бұл ақауларды алдын ала анықтап, жөндеу жұмыстарын жоспарлауға мүмкіндік береді. Сонымен қатар, бұл әдіс жаңа өнімдерді сынау барысында шығындарды азайтып, тәжірибелік үлгілерді дайындау уақытын қысқартады.

Дизайн саласында цифрлық егіздер өнімді жобалау мен прототиптеуді оңтайландырады. Инженерлер компьютерлік модельдерді пайдаланып, әртүрлі материалдар мен өндіріс әдістерінің әсерін зерттей алады. Бұл тәсіл өнім сапасын жақсартумен қатар, әзірлеу уақытын қысқартып, шығындарды төмендетеді. Сандық модельдер визуализация және симуляция арқылы өнімді нарыққа шығарар алдында оның барлық сипаттамаларын мұқият зерттеуге мүмкіндік береді.

Қорыта айтқанда, цифрлық егіз технологиясы өндірістік инженерия мен дизайн саласында маңызды рөл атқарады. Ол процестерді тиімді басқаруға, ресурстарды үнемдеуге және инновациялық шешімдерді жылдам енгізуге мүмкіндік береді. Цифрлық егіздерді қолдану болашақта өндіріс пен дизайнды жаңа деңгейге көтеріп, кәсіпорындардың тиімділігін арттыра түсетіні сөзсіз.

Пайдаланылған әдебиеттер тізімі:

1. Leu MC, ElMaraghy H, Nee A, Ong SK, Lanzetta M, Putz M, Zhu W, Bernard A (2013) CAD Model Based Virtual Assembly Simulation, Planning and Training. CIRP Annals Manufacturing Technology 62(2):799–822. Виртуальное моделирование сборки на основе моделей САПР, планирование и обучение - ScienceDirect
2. [2] Roy R, Stark R, Tracht K, Takata S, Mori M (2016) Continuous Maintenance and the Future Foundations and Technological Challenges. CIRP Annals Manufacturing Technology 65(2):667–688. Непрерывное техническое обслуживание и будущее – Основы и технологические вызовы - ScienceDirect

Кәсіпорынның цифрлық егізін виртуалды ортада визуализациялау және талдау

Асланов А.А.

ал-Фараби атындағы Қазақ Ұлттық Университетінің 4 курс студенті

E-mail: aslanov_006@mail.ru

Асет Асхат

ал-Фараби атындағы Қазақ Ұлттық Университетінің аға оқытушысы

Қазіргі заманғы өндірістік кәсіпорындарда цифрлық егіз технологияларын қолдану өндіріс процестерін оңтайландыруға және тиімділікті арттыруға мүмкіндік береді. Бұл технология виртуалды ортада физикалық нысандардың нақты көшірмелерін жасап, оларды талдау, болжау және оңтайландыру үшін пайдаланылады. Цифрлық егіздер өнім сапасын бақылау, техникалық қызмет көрсету үдерістерін жетілдіру және өндірістік шығындарды азайту мақсатында кеңінен қолданылуда.

Зерттеуде азық-түлік өндірісі саласындағы кәсіпорынның цифрлық егізін құру процесі қарастырылады. Цифрлық егізді жобалау үшін CAD/CAM жүйелері қолданылады, оның ішінде NX бағдарламасында 3D модельдерді құру жүзеге асырылады. Бұл модельдер өндірістік жабдықтардың жұмысы мен өзара әрекеттесуін визуализациялауға және талдауға мүмкіндік береді.

Зерттеу барысында шикізатты өлшеу, араластыру, пісіру және дайын өнімді орау кезеңдерін қамтитын өндірістік процестің сандық моделі жасалды. Виртуалды ортада модельдерді талдау арқылы технологиялық процестерді оңтайландыру және өнім сапасын арттыру мүмкіндіктері анықталды. Сонымен қатар, бұл технология операторларға нақты уақытта өндіріс параметрлерін бақылауға және ақауларды алдын ала анықтауға мүмкіндік береді.

Цифрлық егізді енгізу кәсіпорынның өндірістік үдерістерін жетілдіруге, ресурстарды тиімді пайдалануға және инновациялық технологияларды интеграциялауға ықпал етеді. Бұл зерттеу CAD/CAM технологияларын қолдану арқылы өндірістік жүйелердің тиімділігін арттыруға және цифрлық егіз концепциясын енгізуге практикалық негіз бола алады.

Болашақта цифрлық егіз технологиялары жасанды интеллект және үлкен деректерді талдау құралдарымен біріктірілсе, өндірістік процестерді одан әрі автоматтандыруға мүмкіндік береді. Бұл кәсіпорындарға өндіріс көлемін арттырумен қатар, өнім сапасын жақсартуға және энергия тұтынуды азайтуға көмектеседі

Пайдаланылған әдебиеттер:

1. Grieves, M. (2014). Digital Twin: Manufacturing Excellence through Virtual Factory Replication. [Сілтеме](#)
2. Tao, F., Cheng, J., Qi, Q., Zhang, M., Zhang, H., & Sui, F. (2018). Digital twin-driven product design, manufacturing and service with big data. *The International Journal of Advanced Manufacturing Technology*, 94(9–12), 3563–3576. DOI: 10.1007/s00170-017-0233-1

ТАУ-КЕН ӨНЕРКӘСІБІНДЕГІ ҰНТАҚТАУ ПРОЦЕСІН АВТОМАТТАНДЫРУ ЖӘНЕ ТИІМДІЛІГІН АРТТЫРУ

Асылхан Б.С.

*Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті,
Алматы, Қазақстан,*

*«Автоматика және ақпараттық технологиялар институты», Алматы, Қазақстан
e-mail: balausaasyhan@gmail.com*

Аннотация. *Кен-байыту фабрикаларында мобильді технологиялық кешендерді пайдалану және өндіріс процесінің барлық деңгейлерін басқару қажеттілігі талқыланады. Негізгі назар кенді ұнтақтау және қайта өңдеу кезеңдеріне аударылған, өйткені олар өнім сапасын және кәсіпорынның экономикалық тиімділігін анықтайтын маңызды факторлар болып табылады. Ұнтақтау процесінің энергия сыйымдылығы жоғары болғандықтан, оны автоматтандыру арқылы оңтайландырудың маңыздылығы көрсетілген. Сондай-ақ, кен өңдеудің негізгі технологиялық сатылары – бастапқы ұсақтау, ұнтақтау, жіктеу, флотация және сусыздандыру процестері сипатталады.*

Түйін сөздер: ұнтақтау процесі, кен-байыту, автоматтандыру, басқару жүйелері, шар диірмендері, энергия тиімділігі, флотация, жіктеу, сусыздандыру, тау-кен өндірісі.

Кіріспе. Қазіргі уақытта стационарлық кен-байыту фабрикаларын салу экономикалық тұрғыдан тиімсіз болған кезде шағын кен учаскелерін пайдалануға тарту қажеттілігі туындайды. Құрылыс технологиясының өзін, Құрылыс конструкциялары, технологиялық жабдықтар және ең бастысы өндіріс процесінің барлық деңгейлерін басқаруды автоматтандыру жүйелері бойынша жаңа құрылымдық шешімдерді жетілдіру қажет. Осылайша, мобильді технологиялық кешендерді өндіру бойынша жұмыстар технологиялық операциялардың толық циклы бар модульдік кен-байыту фабрикаларын құру бағытында жүріп жатыр, олар бір объектіні пысықтағаннан кейін екіншісіне оңай ауыстырылуы мүмкін. Сонымен қатар, мұндай кешендерде пайдалы қазбаларды ұнтақтау шешуші рөл атқарады, өйткені ол көбінесе тау-кен кәсіпорнының пайдасы сатылымға байланысты болатын өнімнің сапасын анықтайды. Ұнтақтау процесі үлкен энергия сыйымдылығымен сипатталады-жалпы энергия шығынының шамамен 50-65% - ы ұнтақтау процесіне жұмсалады. Ұнтақтаудың максималды тиімділігі ең жақсы технологиялық тиімділікке сәйкес келеді деп саналады. Оның шешіміне технологиялық процесті автоматтандыру және басқару арқылы қол жеткізуге болады.

Негізгі бөлім. Кен дайындау процестері энергияны көп қажет ететін процестер бола отырып, тұтынылатын энергия мөлшері бойынша тау-кен өнеркәсібіндегі жетекші орындардың бірін алады. Кенді дайындау, әдетте, дөрекі, орташа және ұсақ ұсақтауды, ұсақтаудың әртүрлі әдістерін (өзек пен шар диірмендерінде), сұрыптауды, гидроциклондар мен спираль классификаторлары бойынша жіктеуді, қоюландыруды, флотацияны, кептіруді қамтиды.

Мұндай жүйелерді енгізу кенді өндіруден бастап түпкілікті өнім өндіруге дейінгі технологиялық процестің барлық кезеңдерін басқаруға мүмкіндік береді. Тау-кен өнеркәсібінің технологиялық процесі оңай процесс емес, өйткені ол бірнеше кезеңнен тұрады.

Бастапқы кезең – кенді беру. Арнайы бункерлерден алынған мыс диірменге түседі. Диірменде кенді алғашқы өңдеу жүреді, онда ол одан әрі процеске жарамды болатын мөлшерге дейін ұнтақталады. Бұл кезеңде щек және конустық ұсатқыштар жиі қолданылады. Кенді одан әрі ұсақ және ірі фракцияларға бөлуге болады. Екінші кезең – мысты ұнтақтау. Ұсақталған мыс диірменге түседі, онда оның мөлшері одан әрі өңдеу үшін қажетті мөлшерге дейін азаяды. Барабан диірменінің ішінде үздіксіз жеткізілетін кен бар, онда ұсақталған өнім ұсақтайтын денелердің күшіне еніп, соққымен, абразивпен және ұсақтаумен ұсақталады.

Диірмендегі кен үнемі түсіріліп отырады. Кенді шар немесе өзек диірмендерінде ұнтақтайды. Әдетте ұнтақтаудың бір сатысы жеткіліксіз, сондықтан кенді белгілі бір мөлшерге дейін ұнтақтайтын бірнеше ұнтақтау деңгейінен өтуге болады. Үшінші кезеңде кен бөлшектердің мөлшеріне қарай жіктеледі. Кенді жіктеу арнайы електер мен гидроциклондарсыз болмайды, онда бөлшектер мөлшері бойынша бөлінеді, мұнда ірі бөлшектер, құм фракциясы қайта өңдеуге жіберіледі, ал ұсақ бөлшектер, дайын ұнтақтау өнімі келесі өңдеу қадамдарына жіберіледі. Жіктеу процесінің тиімділігін арттыру үшін су классификаторға түседі. Төртінші кезең – флотация, онда арнайы реагенттердің көмегімен целлюлоза құнды және қажетсіз компоненттерге бөлінеді. Бесінші кезең – сусыздандыру. Флотациядан кейінгі өнімде судың көп мөлшері бар, сондықтан қажет емес сұйықтық көлемінен құтылу керек. Ол үшін центрифугаларды немесе сүзгі престоерін пайдалану керек. Алтыншы кезең де соңғы өңдеу. Сусызданғаннан кейін алынған өнім одан әрі өңдеуге жіберілуі немесе өнеркәсіпте қолданылуы мүмкін. Әрі қарай, дайын өнімді сұрыптау және орау сияқты кейбір басқа операцияларды орындауға болады. Флотациялық шикізатты дайындаудың техникалық процесі гидравликалық көлік желісі арқылы кеніштен және кен-байыту фабрикасынан целлюлоза қоспасы (судағы қатты масса) түрінде келетін мыс (құрамында мыс, құм және басқа минералдар бар) өндірісінің технологиялық қалдықтарын шарлы барабан диірменінде қайта ұнтақтауды қамтиды. Қайта ұнтақтау процесі келесі флотация процесіне дейінгі дайындық техникалық жұмысын білдіреді. Ұсақтау және ұнтақтау процесінде минералды және тау-кен агрегаттарын бұзу арқылы минералдар бөлінеді. Нәтижесінде әртүрлі мөлшердегі және құрамдағы бөлшектер бар қоспа пайда болады. Бұл қоспа жіктеу және скрининг арқылы фракцияларға бөлінеді. Материалды ұнтақтау ұсақтау денелерінің әсерінен соққылар, абразиялар және қысу арқылы жүреді. Ұнтақтағыштан шығатын материал классификаторға түседі, мұнда құмның үлесі ретінде белгіленеді Ққұм, Қдайын ұсақтау процесінің соңғы өнімі болып табылады. Құм фракциясы ұсақтау процесіне қайта оралады, онда ол құм фракциясын құрайды. Бұл фракция циркуляциялық ұсатқыш үшін жүктеме ретінде қызмет етеді. Дайын өнім флотация процесіне жіберіледі. Жіктеуіштің тиімділігін арттыру үшін жіктеу процесіне су беріледі.

Қорытынды. Тау-кен өнеркәсібінде автоматтандырылған басқару жүйелерін енгізу өндіріс тиімділігін арттырудың маңызды факторларының бірі болып табылады. Кенді ұнтақтау және қайта өңдеу процестерін басқарудың автоматтандырылған әдістері энергия шығындарын азайтып, өнім сапасын жақсартуға мүмкіндік береді. Әсіресе, мобильді технологиялық кешендерді қолдану шағын кен орындарын тиімді игеруге жағдай жасайды. Кенді ұнтақтау процесі өндірістің негізгі кезеңдерінің бірі болғандықтан, оны оңтайландыру тау-кен кәсіпорындарының экономикалық тиімділігін арттыруға көмектеседі. Жіктеу, флотация және сусыздандыру сияқты қосымша процестерді жетілдіру арқылы өндірістің барлық сатыларында ресурстарды үнемдеуге және технологиялық процестерді тұрақтандыруға болады.

Пайдаланылған әдебиеттер тізімі:

1. Улитенко К.Я., Попов В.П. Автоматическая защита барабанных мельниц от перегрузок. Обогащение руд. № 2 - 2004.
2. Улитенко К.Я., Соколов И.В., Маркин Р.П., Найденов А.П. Автоматизация процессов измельчения в обогащении и металлургии // Цветные металлы. 2005.-№ 10. – Б. 54-59.
3. Николин Г., Заграй В., Пистун Е. Автоматизация шаровых барабанных мельниц для ТЭС//СТА.-2017.-№3.-Б.51-55.
4. Газалеева Г.И., Цыпин Е.Ф., Червяков С.А. Рудоподготовка. Дробление, грохочение, обогащение. – Екатеринбург: Уральский центр академического обслуживания, 2014. – 915 б.

ЦИФРОВОЙ ПИД-РЕГУЛЯТОР И ПРИМЕНЕНИЕ ЕГО В ПРАКТИКЕ УПРАВЛЕНИЯ БЕСКОЛЛЕКТОРНЫХ ДВИГАТЕЛЕЙ

Ахметов К.Т.

ЕНУ им. Л.Н. Гумилева, г. Астана
e-mail: kairat.telektesovich@gmail.com

Толегенова М.С.

ЕНУ им. Л.Н. Гумилева, г. Астана
e-mail: mahabattolegenova@gmail.com

Применение ПИД-регулятора в области беспилотных летательных аппаратов играет важную роль в стабилизации полётов. ПИД-регулятор состоит из трех составляющих коэффициентов: пропорциональной, интегральной и дифференциальной [1]:

$$u(t) = K_p e(t) + K_i \int e(t) dt + K_d \frac{de}{dt} \quad (1)$$

где, $u(t)$ – сигнал управляющего воздействия ПИД-регулятора; K_p , K_i и K_d – коэффициенты пропорциональной, интегральной и дифференциальной составляющих; $e(t)$ – ошибка регулирования, определяется как разность между заданным значением и текущим значением; $e(t)dt$ – интеграл ошибки; de/dt – производная от ошибки.

Для реализации автоматической калибровки двух бесколлекторных двигателей и поддержки заданного положения угла штанги, применен алгоритм ПИД-регулирования. Результаты измерения представлены на рисунке 1.




Рис.1. Результаты измерения ШИМ-сигнала, издаваемых из микроконтроллера Atmega328 в зависимости от угла поворота штанги от -30 до 30 градусов.

Бесколлекторные двигатели модели A2213 функционируют на ШИМ-сигнале в диапазоне от 800 до 2300 мкс. Угол наклона штанги измеряется акселерометром-гироскопом модели MPU-6050. Микроконтроллер, который выдает ШИМ-сигналы на бесколлекторные двигатели с пропеллерами (диаметр каждого по 255 мм), регулирует их работу в зависимости от угла наклона штанги. При наклоне правой стороны штанги, угол составляет -30 градусов. В этом случае ШИМ-сигнал (линия 2) начинает увеличиваться до 1500 мкс, а скважность сигнала составляет ~65% (рис. 1, б). Это приводит к увеличению тяги двигателя и поднятию правой стороны штанги. Аналогичный процесс происходит при наклоне левой стороны штанги на +30 градусов, когда увеличивается ШИМ-сигнал (линия 1), а ШИМ-сигнал для правого двигателя (линия 2) уменьшается (рис. 1, в). При любом наклоне штанги управляющий сигнал ПИД-регулятора $u(t)$ всегда стремится к установочному значению, равному нулю. Когда управляющий сигнал достигает этого значения, микроконтроллер выдает на оба двигателя примерно одинаковые ШИМ-сигналы (по 1300 мкс) через цифровые контакты микроконтроллера (рис. 1, а). В этом положении ПИД-регулятор стабилизирует заданный угол штанги.

Список используемой литературы:

1. ПИД-регулятор [Электронный ресурс]. URL: [https://ru.wikipedia.org/wiki/ ПИД-регулятор](https://ru.wikipedia.org/wiki/ПИД-регулятор). (Дата обращения: 10.03.2024).

Нақты науқастың денсаулығын және қоршаған ортаның факторларын мониторинг жүргізуге арналған интеллектуалды жүйені әзірлеу үшін заттар интернеті мен машиналық оқытуды интеграциялау

**Байғараева Ж.Е., Болтабоева А.К., Иманбек Б.Т., Ибрашева З.С., Jemal A.G.,
Амирханова Г.А.**

*Әл-Фараби Атындағы Қазақ Ұлттық Университеті, Алматы, Қазақстан
zhanel.baigarayeva@gmail.com, boltaboyeva_assiya3@live.kaznu.kz,
baglan.imanbek@kaznu.edu.kz, ibrashevazarina7@gmail.com,
aliyajemalgetahun452004@gmail.com, gulshat.aa@gmail.co*

Қалалық ауаның ластануы және оның қоғамдық денсаулыққа зиянды әсерлері туралы алаңдаушылықтың күшеюі ауа сапасын бақылаудың жетілдірілген нақты уақыт режиміндегі шешімдерін қажет етеді. Бұл мақалада жоғары сезімталдық пен таңдау қабілеті бар негізгі қалалық ластаушы заттарды анықтауға қабілетті күрделі химорезистивті сенсорларды әзірлеу үшін заттар интернеті (IoT) және машиналық оқыту (ML) технологияларының жаңа интеграциясы енгізілген. Біз дәстүрлі химорезистивті сенсорлардың өнімділік сипаттамаларын жақсартуға бейімделген полианилин, металл оксиді нанобөлшектері және көміртегі нанокұрылымдарынан тұратын инновациялық нанокөмposиттердің синтезін егжей-тегжейлі қарастырамыз. IoT элементтерін қосу арқылы біздің жүйе қоршаған орта параметрлерінің үздіксіз, нақты уақыттағы мониторингін жеңілдетеді, ал ендірілген ML алгоритмдері ауа сапасының деңгейін динамикалық түрде болжау үшін сенсор деректерін талдайды. Смарт сенсор жүйесі ластаушы заттардың дисперсиясы мен концентрация үлгілері туралы сыни түсініктерді қамтамасыз ететін қалалық жағдайда орналастырылған және расталған. Нәтижелер қалалық денсаулық диагностикасын айтарлықтай жақсартуға және ауа сапасын бақылау инфрақұрылымын жақсартуға бағытталған қалалар үшін ауқымды үлгіні ұсынуға арналған осы біріктірілген тәсілдің әлеуетін көрсетеді. Бұл зерттеу жаңа буын ауа сапасының сенсорларына жол ашып қана қоймайды, сонымен қатар тұрақты қалалық өмір және қоғамдық денсаулық қауіпсіздігі туралы кеңірек пікірталасқа үлес қосады.

Бұл мақалада қалалық жағдайларда ауа сапасын бақылауға арналған интеллектуалды жүйені жасау үшін Заттар интернеті (IoT) және машиналық оқыту (ML) технологияларын интеграциялау ұсынылған. Зерттеу полианилин, металл оксидтерінің нанобөлшектері және көміртекті нанокұрылымдарды қамтитын инновациялық нанокөмposиттер негізіндегі жоғары сезімтал химорезистивті датчиктерді әзірлеуге және енгізуге бағытталған. Бұл датчиктер ауадағы негізгі ластаушы заттарды дәл анықтауды қамтамасыз етеді.

Дайындалған IoT жүйесі нақты уақыт режимінде деректерді үздіксіз жинауды қамтамасыз етеді, ал кіріктірілген машиналық оқыту алгоритмдері, соның ішінде LSTM және RNN модельдері, жиналған деректерді талдап, ластану динамикасын болжайды. Бұл технологияны қалалық инфрақұрылымға енгізу мониторинг дәлдігін арттырып, экологиялық қауіпсіздікті жақсартуға мүмкіндік береді.

Жүйе архитектурасы өлшеу нәтижелерін сақтау үшін Python API, SQL дерекқоры және зертханалық процестерді қашықтан басқару үшін SCADA жүйесі бар серверлік бөлікті қамтиды. Сонымен қатар, интеллектуалды HVAC жүйелерімен интеграциялау энергия тұтынуды оңтайландыруға және зертханалық ортаның қауіпсіздігін қамтамасыз етуге көмектеседі. Random Forest, Gradient Boosting Machines және LSTM сияқты машиналық оқыту алгоритмдері ауа сапасының өзгерістерін болжауда жоғары дәлдік көрсетеді.

Жүйенің қалалық жағдайларда практикалық сынағы оның ластаушы заттарды талдаудағы және экологиялық қауіп-қатерлерді болжаудағы тиімділігін көрсетті. Бұл жұмыс ауа сапасын бақылаудың кеңейтілетін жүйелерін құруға жол ашып, қалалардың тұрақты дамуына және қоғамдық денсаулықты қамтамасыз етуге үлес қосады.

Пайдаланылган әдебиеттер тізімі:

1. Buelvas, J., Múnera, D., Tobón V., D.P. et al. Data Quality in IoT-Based Air Quality Monitoring Systems: a Systematic Mapping Study. *Water Air Soil Pollut* 234, 248 (2023). <https://doi.org/10.1007/s11270-023-06127-9>
2. Moursi, A.S., El-Fishawy, N., Djahel, S. et al. An IoT enabled system for enhanced air quality monitoring and prediction on the edge. *Complex Intell. Syst.* 7, 2923–2947 (2021). <https://doi.org/10.1007/s40747-021-00476-w>
3. Abimannan, S.; El-Alfy, E.-S.M.; Hussain, S.; Chang, Y.-S.; Shukla, S.; Satheesh, D.; Breslin, J.G. Towards Federated Learning and Multi-Access Edge Computing for Air Quality Monitoring: Literature Review and Assessment. *Sustainability* 2023, 15, 13951. <https://doi.org/10.3390/su151813951>
4. Bouabdallah, N., Ah-Pine, J., & Serrano-Alvarado, P. (2023). Data Quality in IoT-Based Air Quality Monitoring Systems: a Systematic Mapping Study. *Water, Air, & Soil Pollution*. <https://link.springer.com/article/10.1007/s11270-022-05675-0>
5. Rahman, M., Sultana, N., & Mahmud, M. (2023). An IoT enabled system for enhanced air quality monitoring and prediction on the edge. *Complex & Intelligent Systems*. <https://link.springer.com/article/10.1007/s40747-022-00755-1>
6. Temizel, C., Canbaz, C.H., Palabiyik, Y., Aydin, H., Tran, M., Ozyurtkan, M.H., Yurukcu, M., & Johnson, P. (2021). A Thorough Review of Machine Learning Applications in the Oil and Gas Industry. *SPE/IATMI Asia Pacific Oil & Gas Conference and Exhibition*. <https://doi.org/10.2118/205720-MS>
7. Mocrii, D., Chen, Y., & Musilek, P. (2018). IoT-based smart homes: a review of system architecture, software, communications, privacy and security. *Internet of Things*, 1-2, 81-98. <https://doi.org/10.1016/j.iot.2018.08.009>
8. Khan, T., & Lawrence, A.J. (2021). Health Risk Assessment Associated with Air Pollution Through Technological Interventions: A Futuristic Approach. SpringerLink. <https://link.springer.com/book/10.1007/978-3-030-73458-3>
9. Hu, Z., Bai, Z., Bian, K., Wang, T., & Song, L. (2019). Real-time fine-grained air quality sensing networks in smart city: design, implementation, and optimization. *IEEE Internet of Things Journal*, 6(5), 7526-7542. <https://doi.org/10.1109/JIOT.2019.2904271>
10. Xiaojun, C., Xianpeng, L., & Peng, X. (2015). IoT-based air pollution monitoring and forecasting system. In: 2015 International Conference on Computer and Computational Sciences (ICCCS), 257-260. <https://doi.org/10.1109/ICCIC.2015.7435693>

Модели и алгоритмы описания рабочих пространств 3-х степенных шарнирных манипуляционных роботов в виде логических функций

Бақтыбай А.А.

*КАЗНУТУ им. К.Сатпаева, Алматы, Казахстан,
«Институт Автоматики и Информационных технологий», Алматы, Казахстан
e-mail: baktybai11.11@gmail.com*

Аннотация. В данной статье представлены методы моделирования и описания рабочих пространств трехстепенных манипуляционных роботов. Рассматривается использование R-функций для формального представления геометрических границ рабочих зон. Анализируются ограничения, накладываемые конструктивными особенностями роботов, и предлагаются способы их учета при проектировании и оптимизации движения манипуляторов.

Ключевые слова: манипуляционный робот, рабочее пространство, кинематическая цепь, R-функции, логические выражения.

Введение. Современные манипуляционные роботы играют важную роль в автоматизированном производстве, обеспечивая точное перемещение и манипуляцию объектами. Одной из ключевых задач проектирования таких роботов является определение и оптимизация их рабочих пространств, что влияет на эффективность выполнения производственных операций.

Цель данной работы – разработка методов формального описания рабочих пространств трехстепенных манипуляционных роботов на основе логических выражений и математического аппарата R-функций.

Методика описания рабочих пространств

Манипуляционные роботы с тремя степенями подвижности представляют собой последовательную кинематическую цепь, состоящую из трех последовательно соединенных звеньев и сочленений. Их рабочее пространство определяется геометрическими и кинематическими параметрами конструкции и может быть описано аналитическими методами.

Одним из эффективных подходов является использование булевых функций и R-функций, которые позволяют задавать область допустимых перемещений манипулятора в виде логических выражений. Это особенно полезно для анализа достижимости точек и выявления возможных ограничений конструкции.

Геометрическое описание рабочей зоны

Рабочая зона манипуляционного робота формируется ограничивающими поверхностями, такими как:

- Цилиндры (задают радиальное ограничение перемещений),
- Конусы (описывают области сужающихся или расширяющихся зон),
- Плоскости (ограничивают движение в линейных направлениях).

Эти поверхности описываются уравнениями, например:

$$(R^2 - x^2 - y^2 \geq 0) \wedge (H - z \geq 0) \wedge (z - h \geq 0) = 1$$

где:

- R — максимальный радиус досягаемости,
- H — верхняя граница рабочей зоны,
- h — нижняя граница рабочей зоны,
- x, y, z — координаты точки в пространстве.

Применение модели в автоматизации

Использование R-функций для описания рабочих пространств позволяет:

- Определять оптимальные геометрические параметры манипуляторов;
- Формировать математически строгие модели движения;

- Учитывать ограничения конструктивных параметров роботов.

Реализация этих методов в системах автоматизированного проектирования и управления роботами способствует улучшению точности их работы и повышению эффективности производства.

Заключение. Разработанные модели и алгоритмы для описания рабочих пространств трехстепенных манипуляционных роботов позволяют формализовать геометрию перемещений, учитывая конструктивные ограничения. Полученные результаты могут быть использованы в проектировании роботизированных систем, а также в образовательных и исследовательских целях.

Дальнейшие исследования направлены на расширение предложенного подхода для многозвенных роботов и интеграцию с адаптивными алгоритмами управления.

Список использованной литературы:

1. Воронцов, В. А. Теория механизмов и манипуляционных роботов. – М.: Наука, 2015.
2. Зуев, В. А., Петров, И. В. Методы вычисления рабочих пространств промышленных роботов. – СПб.: Политехника, 2017.
3. Латышев, А. П., Смирнов, Б. В. Кинематика и динамика манипуляционных систем. – Новосибирск: Наука, 2018.
4. Paden, B., Khatib, O. A General Framework for Robot Motion Planning and Control // IEEE Transactions on Robotics and Automation, 2019, vol. 35, no. 4, pp. 785–797.
5. Rvachev, V. L., Sheiko, T. I. R-functions in boundary value problems in mechanics // Applied Mechanics Reviews, 1995, vol. 48, no. 4, pp. 151–188.

Влияние наследия Фараби на современные образовательные технологии

Бахтова Диана Ильясызы

Казахский национальный университет им. аль-Фараби, Алматы, Казахстан

e-mail: bakhtovadiana06@gmail.com

Аннотация:

В данном докладе рассматривается, как идеи великого мыслителя Фараби способствуют развитию современных образовательных систем. Фарабидское наследие, объединяющее науку и духовность, служит основой для формирования гуманистических ценностей и развития критического мышления в условиях цифровой эпохи.

Введение:

Фараби, как один из величайших философов средневековья, оказал значительное влияние на развитие науки и культуры. Его идеи о синтезе знания и мудрости актуальны и сегодня, когда образовательная среда требует интеграции традиционных ценностей с инновационными методами обучения. Цель данного доклада – показать, каким образом наследие Фараби вносит вклад в современное образование и способствует формированию всесторонне развитой личности.

Основная часть:

1. Научно-философская основа:

Фарабидская концепция предполагает, что знание должно быть не только накоплением фактов, но и инструментом духовного развития. Его учение объединяет рациональное мышление с моральными устоями, что позволяет создать основу для развития критического анализа и творческого подхода в обучении.

2. Влияние на современные технологии обучения:

В эпоху цифровых технологий традиционные методы образования обретают новое значение. Идеи Фараби способствуют разработке образовательных программ, в которых акцент делается на всестороннее развитие личности, а не только на передачу информации. Примеры таких программ можно найти как в зарубежных, так и в отечественных образовательных институтах, где используются современные интерактивные платформы, способствующие глубокому пониманию учебного материала.

3. Интеграция традиций и инноваций:

Наследие Фараби служит мостом между древней мудростью и современными образовательными практиками. Его философия подчеркивает важность гармоничного сочетания науки и духовности, что позволяет адаптировать традиционные ценности к реалиям современного мира. Такая интеграция способствует не только развитию академических навыков, но и формированию нравственных и этических ориентиров у студентов.

Заключение

Наследие Фараби оказывает значительное влияние на развитие современных образовательных технологий. Его идеи помогают создать образовательные системы, ориентированные на всестороннее развитие личности, способной к критическому мышлению и творческому решению задач. Дальнейшее изучение и внедрение фарабидских принципов в образовательную практику позволит повысить качество подготовки специалистов в условиях глобальных вызовов современности.

ӘЛ-ФАРАБИ ИДЕЯЛАРЫ ЖӘНЕ БОЛАШАҚ ҒЫЛЫМЫ

Болатов Бекзат Бейбітұлы

*Әл-Фараби атындағы Қазақ ұлттық университеті,
Ақпараттық технологиялар факультеті, 2-курс студенті
E-mail: bekzatbolatov55@gmail.com*

Аннотация

Бұл зерттеуде әл-Фарабидің ғылыми-философиялық мұрасы мен оның ХХІ ғасырдағы ғылымға ықпалы талданады. Ойшылдың білім, инновация және өркениетке қатысты көзқарастары қазіргі технологиялық жетістіктер тұрғысынан қарастырылады. Сонымен қатар, әл-Фараби еңбектерінің ақпараттық технологиялар, жасанды интеллект және ғарыштық зерттеулер салаларындағы өзектілігі қарастырылады.

Кілт сөздер: әл-Фараби, болашақ ғылымы, инновация, философия, өркениет, ақпараттық технологиялар.

Кіріспе

Әл-Фараби – тек ортағасырлық ойшыл ғана емес, болашаққа бағдар берген кемеңгер ғалым. Оның ғылым мен білімге қатысты көзқарастары қазіргі заманның жасанды интеллект, нейротехнология және ғарыштық зерттеулер салаларымен тығыз байланысты. Бүгінде цифрлық дәуір адамзат өркениетін жаңа даму сатысына көтерді. Ақпараттық технологиялардың қарқынды дамуы мен жасанды интеллекттің күнделікті өмірге енуі ғылым мен қоғам арасындағы байланысты жаңа деңгейге шығарды. Осы тұрғыдан алғанда, әл-Фарабидің ғылым, таным және қоғам туралы ойлары ерекше мәнге ие. Оның «екінші ұстаз» атануы кездейсоқ емес – ойшылдың білім жүйесін қалыптастыруға қосқан үлесі бүгінгі академиялық және технологиялық зерттеулерде көрініс табуда. Бұл зерттеуде әл-Фараби идеяларының ХХІ ғасырдағы өзектілігі қарастырылады.

Негізгі бөлім

1. Әл-Фарабидің ғылым мен білімге қатысты көзқарастары

Әл-Фараби ғылымды тек білім жинақтау құралы ретінде ғана емес, адамзат өркениетін жетілдіру жолы деп санаған. Оның логика, этика және музыка теориясы бойынша еңбектері бүгінгі таңда да өз маңызын жоғалтқан жоқ. Ғалымның методологиялық көзқарастары қазіргі ғылыми зерттеу тәсілдерімен сабақтасып жатыр. Мысалы, оның логика мен танымдық процестер туралы тұжырымдары деректер ғылымында, когнитивті зерттеулерде қолданылуда. Сондай-ақ, білім мен ғылымның адамзат дамуындағы рөлін ерекше атап көрсеткен әл-Фараби идеялары қазіргі цифрландыру үдерістерімен де үндеседі.

2. Әл-Фараби идеялары және заманауи технологиялар

Бүгінгі жасанды интеллект және биотехнология дамыған заманда әл-Фарабидің «қайырымды қоғам» концепциясы ерекше мәнге ие. Оның адамгершілік қағидаттары мен әлеуметтік әділеттілік идеялары жасанды интеллектті этикалық басқару мәселелерімен ұштасады. Сонымен қатар, ақылды қалалар мен цифрлық этика мәселелері оның еңбектеріндегі идеялармен тығыз байланысты. Қазіргі таңда ғылым мен технологияның дамуы жаңа этикалық нормалар мен гуманитарлық құндылықтарды қайта қарастыруды қажет етеді, бұл тұрғыда әл-Фарабидің ойлары өзекті болып қала береді. Сонымен қатар, ақпараттық қауіпсіздік, деректерді қорғау және компьютерлік жүйелердің моральдық аспектілері оның еңбектеріндегі философиялық қағидалармен үйлеседі.

3. Ғарыштық зерттеулер және әл-Фараби философиясы

Әл-Фараби өзінің еңбектерінде ғарыш, жұлдыздар мен әлем құрылымына ерекше назар аударған. Оның көзқарастары қазіргі астрофизика, космология және ғарыштық технологияларды дамытуда маңызды орын алады. Бүгінде адамзат Марсқа ұшу, ғарыштық қоныстану мәселелерін шешуге тырысуда, ал әл-Фараби еңбектерінде ғарыш пен адамның өзара байланысы туралы ойлар қозғалған. Оның философиялық тұжырымдары болашақта ғарыштық өркениеттермен байланыс орнату идеясымен үйлеседі. Сонымен қатар, әл-Фараби

ғылымның әмбебап заңдарын қарастыра отырып, ғарыш пен адамзат өркениетінің өзара байланысын түсіндіруге тырысқан. Бұл оның философиясының қазіргі заманғы ғарыштық зерттеулердегі рөлін көрсетеді.

Қорытынды

Әл-Фарабидің идеялары – уақыттан тыс, болашақ ғылымының бағдаршысы. Оның концепцияларын жаңа технологиялар мен ғылыми ашылымдар арқылы қайта пайымдау – ХХІ ғасыр ғалымдарының маңызды міндеттерінің бірі. Бүгінде оның идеялары жасанды интеллекттен бастап, ғарыштық зерттеулерге дейінгі түрлі салаларда қолданылып жатыр. Ақпараттық технологиялардың дамуы, деректерді өңдеу әдістерінің күрделенуі және цифрлық трансформация үдерістері әл-Фараби еңбектерінде көрініс тапқан негізгі философиялық қағидалармен сәйкес келеді. Сондықтан әл-Фарабидің мұрасы тек тарихтың емес, болашақтың да маңызды бөлігі болып қала бермек.

Пайдаланылған әдебиеттер тізімі:

1. Әл-Фараби. «Қайырымды қала тұрғындарының көзқарастары».
2. Жасанды интеллект және қоғам: заманауи зерттеулер.
3. Болашақ философиясы және өркениеттік дамудың тенденциялары.
4. Ғарыштық технологиялар және адамзат болашағы.

Разработка и исследование интеллектуальных алгоритмов управления процессом адсорбции сероводорода.

Берікқазы Олжас Бауыржанұлы

КазНИТУ им. К.И.Сатпаева, Магистрант 1 курса

E-mail: olzhas211219@gmail.com

Общая характеристика задачи

Задача разработки и исследования интеллектуальных алгоритмов управления процессом адсорбции сероводорода представляет собой комплексную задачу, требующую применения современных подходов в области искусственного интеллекта (ИИ) и теории управления для оптимизации процесса очистки газов от сероводорода. Общая характеристика задачи:

1. Процесс адсорбции сероводорода: Адсорбция — это процесс, при котором молекулы сероводорода (H_2S) из газовой фазы поглощаются поверхностью твёрдых адсорбентов. В данном случае задача заключается в эффективном удалении сероводорода из газовых потоков, что критически важно для многих промышленных процессов, таких как нефтехимия и переработка газа.

2. Задачи управления: важно не только провести адсорбцию, но и эффективно управлять этим процессом. Это включает в себя контроль температуры, давления, скорости газового потока и других параметров процесса. Для достижения максимальной эффективности адсорбции необходимо оптимизировать работу системы в режиме реального времени, что особенно актуально при изменяющихся условиях.

Разработка и исследование интеллектуальных алгоритмов управления процессом адсорбции сероводорода

Разработка и исследование интеллектуальных алгоритмов управления процессом адсорбции сероводорода — это сложная междисциплинарная задача, в рамках которой используются методы математического моделирования, теории управления, а также искусственного интеллекта для оптимизации и управления процессом адсорбции сероводорода (H_2S) из газовых потоков. Этот процесс имеет большое значение в таких отраслях, как нефтехимия, газопереработка и экологическая защита, где требуется эффективная очистка газа от токсичных веществ.

1. Общие сведения о процессе адсорбции сероводорода Адсорбция — это процесс, при котором молекулы сероводорода из газовой фазы адсорбируются (поглощаются) на поверхности твёрдого адсорбента. Это явление широко используется для очистки газов в различных производственных процессах. Важно отметить, что процесс адсорбции сероводорода имеет нелинейную динамику и зависит от множества факторов: температуры, давления, скорости потока газа, химической активности адсорбента и концентрации H_2S в газе.

2. Задачи управления процессом адсорбции. Для эффективного управления процессом адсорбции сероводорода необходимо разработать алгоритмы, которые смогут: - Поддерживать стабильные параметры процесса. Это включает в себя контроль температуры, давления и скорости потока газа. - Оптимизировать использование адсорбента. Например, минимизировать потребление адсорбента и снизить его износ, избегая перенасыщения адсорбента. - Предотвращать сбои. Алгоритмы должны учитывать возможные отклонения от нормальных условий и автоматически настраивать параметры для предотвращения аварийных ситуаций.

3. Интеллектуальные алгоритмы управления. Интеллектуальные алгоритмы управления включают в себя различные подходы из области искусственного интеллекта (ИИ), машинного обучения и адаптивного управления. Ключевые методы, которые могут быть использованы: - Нейронные сети. Могут быть использованы для моделирования сложных нелинейных зависимостей процесса адсорбции и прогнозирования его поведения при изменении входных параметров. Также нейронные сети можно применить для построения

системы прогнозирования, которая будет отслеживать динамику концентрации сероводорода и адаптировать параметры управления в реальном времени.

Методы, используемые для разработки и исследования интеллектуальных алгоритмов управления процессом адсорбции сероводорода.

Методы, используемые для разработки и исследования интеллектуальных алгоритмов управления процессом адсорбции сероводорода, включают в себя различные подходы из области искусственного интеллекта, теории управления, оптимизации и машинного обучения. Вот основные из них:

1. Математическое моделирование

Математическое моделирование является основой для разработки алгоритмов управления. Оно помогает описать динамику процесса адсорбции с учётом различных факторов, таких как концентрация сероводорода, температура, давление, свойства адсорбента и другие параметры.

2. Методы оптимизации

Оптимизация процессов — важный аспект интеллектуального управления. На основе математических моделей разрабатываются алгоритмы для поиска наилучших параметров управления процессом, таких как температура, давление и скорость потока газа.

3. Машинное обучение и искусственные нейронные сети

Машинное обучение и нейронные сети используются для прогнозирования и оптимизации процесса в режиме реального времени. Эти методы позволяют создавать модели, которые могут адаптироваться к изменениям в условиях процесса и предоставлять пр

4. Нечеткая логика и системы управления

В реальных промышленных условиях часто бывает сложно точно измерить все параметры процесса, а также учесть неопределённости и колебания в данных. Нечёткая логика и системы управления являются подходами для работы с такими неопределённостями.

5. Адаптивные системы управления

Адаптивные алгоритмы управления необходимы для управления процессами, в которых параметры могут изменяться во времени. Эти алгоритмы подстраиваются под новые условия и могут корректировать действия в зависимости от изменений в параметрах процесса.

6. Интеллектуальные сенсоры и системы мониторинга

Для сбора данных в режиме реального времени и мониторинга процесса используются интеллектуальные датчики и системы, основанные на искусственном интеллекте. Эти системы могут автоматически регулировать параметры процесса, повышать точность измерений и прогнозировать проблемы.

7. Системы поддержки принятия решений (DSS)

Интеллектуальные системы поддержки принятия решений (DSS) могут быть использованы для создания интерфейсов, которые помогают операторам принимать решения на основе анализа данных и прогнозов.

Заключение:

Методы, используемые для разработки и исследования интеллектуальных алгоритмов управления процессом адсорбции сероводорода, включают в себя широкий спектр подходов, которые позволяют оптимизировать, адаптировать и улучшать процесс в режиме реального времени. Это сочетание математического моделирования, методов оптимизации, машинного обучения и адаптивных систем управления открывает новые возможности для повышения

Список использованной литературы:

1. Дудников, А. В., Куликов, И. В. Процессы адсорбции в химической технологии. — М.: Химия, 2015. — 320 с.
2. Власов, А. В. Интеллектуальные системы управления процессами. — М Методы и алгоритмы оптимизации для химической инженерии Малахов, Д. В., Исаев, И. Л. *Методы и алгоритмы оптимизации для химической5.. — М.: Инфра-М, 2014. — 310 с.

3. Ге, Дж., и Хэ, Й. Алгоритмы оптимизации и их применение в системах управления технологическими процессами. — Спрингер, 2019. — 320 с.
4. Хайкин, С. «Нейронные сети: полный курс». — 2-е издание, Prentice Hall, 1998. — 716 с. Искусственный интеллект в инженерии: приложения и алгоритмы Марвала, Т. *Art15.. — Elsevier, 2019. — 400 с.

"Ақылды үй" жобасының негіздері және құрылымдық ерекшеліктері

Есенаманов Ж.Ө., Елдесов Т.А., Қосбақ А.

Ғылыми жетекші: Жұмахан Н.Б., техника ғылымдарының магистрі

Алматы технологиялық университеті

Смарт үй – заманауи технологияларды қолдана отырып, тұрмыстық процестерді автоматтандыруға бағытталған жүйе. Бұл жүйе адамның күнделікті өмірін жеңілдетіп қана қоймай, сонымен қатар қауіпсіздік пен энергияны тиімді пайдалануды қамтамасыз етеді. Ақылды үй технологиялары IoT (Интернет заттар) негізінде жұмыс істейді, бұл құрылғылар мен сенсорлардың бір-бірімен байланысуына мүмкіндік береді.

IoT технологиясының маңыздылығы

IoT (Internet of Things) – құрылғылар мен датчиктердің интернет арқылы ақпарат алмасуын қамтамасыз ететін технология. IoT негізінде ақылды үйлердің келесі мүмкіндіктері қарастырылады:

- Смарт жарықтандыру – жарық деңгейін автоматты түрде реттеу;
- Климаттық бақылау – температура, ылғалдылық және желдету жүйелерін басқару;
- Қауіпсіздік жүйелері – бейнебақылау, ақылды құлыптар, дабыл жүйелері;
- Смарт тұрмыстық техника – ақылды тоңазытқыштар, кір жуғыш машиналар, пештер және басқа да тұрмыстық техникалар;
- Энергияны тиімді пайдалану – электр қуаты мен су шығынын үнемдеу.

Жобаны жүзеге асыру үшін келесі негізгі компоненттер қолданылады:

1. **Сенсорлар мен датчиктер** – қозғалысты, температураны, ылғалдылықты, газ деңгейін анықтайтын құрылғылар.
2. **Басқару хабы** – барлық құрылғыларды орталықтан басқаруға мүмкіндік беретін негізгі блок.
3. **Мобильді қосымша** – пайдаланушыға үйді қашықтан басқаруға мүмкіндік беретін құрал.
4. **Бұлтты сақтау және деректерді өңдеу** – құрылғы деректерін сақтау және талдау жүйесі.

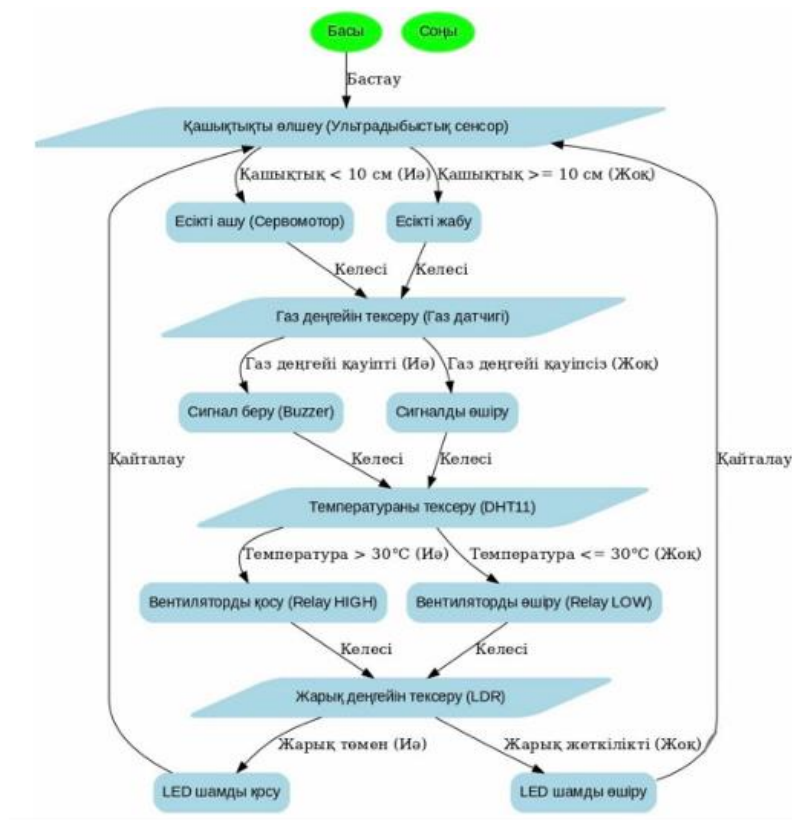
Жобада барлық құрылғылар **Arduino** платформасына қосылған және бір-бірімен тікелей байланысқан. Температура, жарық, газ және есік сенсорлары **Arduino-дан** алынған деректер негізінде өзара әрекеттесіп, қажетті функцияларды іске асырады. Arduino-ға келген деректерге сәйкес құрылғылар автоматты түрде жұмыс істейді, мысалы:

- Температура жоғарылаған жағдайда желдеткіш немесе ауаны салқындату жүйесі іске қосылады;
- Жарық деңгейі төмендесе, шамдар автоматты түрде қосылады;
- Үй ішінде газ деңгейі жоғарыласа, дабыл жүйесі іске қосылып, пайдаланушыға хабарлама жіберіледі;
- Қозғалыс сенсорлары арқылы бақылау жүйесі іске қосылады.

"Ақылды үй" жүйесінің жұмыс алгоритмін сипаттайды. Ол ультрадыбыстық сенсор, газ датчигі, температура сенсоры (DHT11), жарық деңгейін өлшейтін LDR сенсоры және басқару элементтері (сервомотор, Buzzer, реле арқылы желдеткіш пен LED шамдар) арқылы автоматтандырылған шешімдерді қабылдайды.

Алгоритмнің жұмыс принципі

Ақылды үй жүйесі бірнеше датчиктерден алынған деректер негізінде автоматты шешімдер қабылдайды. Бірінші қадамда ультрадыбыстық сенсор арқылы қашықтық өлшенеді. Егер объект 10 см-ден жақын орналасқан болса, есік сервомотор көмегімен автоматты түрде ашылады, ал егер объект 10 см-ден алыс болса, есік жабылады.



Сурет 1 - Басқару алгоритмі

Келесі қадамда газ деңгейі арнайы газ датчигі арқылы бақыланады. Егер газ деңгейі қауіпті болып анықталса, жүйе Buzzer арқылы дабыл сигналын береді. Ал егер газ деңгейі қауіпсіз болса, дабыл сигналы өшіріледі.

Үшінші кезеңде температураны бақылау жүзеге асырылады. Егер температура 30°C-тан жоғары болса, желдеткіш автоматты түрде іске қосылады. Ал егер температура 30°C-тан төмен немесе оған тең болса, желдеткіш өшіріледі.

Соңғы қадамда жарық деңгейін тексеру жүргізіледі. Егер жарық деңгейі төмен болса, LED шамы автоматты түрде қосылады, ал жарық жеткілікті болған жағдайда, шам өшіріледі.

Осылайша, бұл алгоритм үй ішіндегі жағдайларды бақылап, пайдаланушының қатысуынсыз ақылды басқару жүйесін жүзеге асырады, бұл қауіпсіздік пен жайлылықты арттырады.

Ақылды үй жобасы тұрмыстық процестерді оңтайландыруға, қауіпсіздікті арттыруға және энергияны үнемдеуге мүмкіндік береді. IoT технологияларын енгізу арқылы пайдаланушылар энергия шығынын азайтып, үйдің жайлылығы мен қауіпсіздігін арттыра алады.

Болашақта жасанды интеллект (AI) және машиналық оқыту (ML) алгоритмдерін қолдану арқылы ақылды үйлерді одан әрі дамыту жоспарлануда. Бұл технологиялар үй ішіндегі құрылғылардың өздігінен үйреніп, пайдаланушының қалауларына бейімделуіне мүмкіндік береді.

Пайдаланылған әдебиеттер тізімі:

1. Айтимова У.Ж., Танибергенова А. "Ақылды дәрісхана жүйесін құру" // Ғылыми мақала, С.Сейфуллин атындағы Қазақ агротехникалық университеті. [https://kazatu.edu.kz/assets/i/science/sf14_inf_com_105.pdf]
2. Торғын Қабен. «Ақылды үй» жүйесі керемет көмекші ме, әлде қауіп-қатер көзі ме? // Kursiv Media, 28 тамыз 2023 ж.

РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ УСОВЕРШЕНСТВОВАННОГО УПРАВЛЕНИЯ ПРОЦЕССАМИ НА ВЫСОКОТЕХНОЛОГИЧНОМ ПРЕДПРИЯТИИ

Жандин С.В.,

КазНИТУ им. К. Сатпаева, Алматы

В настоящее время, в рамках автоматизации и цифровизации, внедрение интеллектуальных систем усовершенствованного управления технологическими процессами (СУУТП) способствует реализации целей устойчивого развития, путём внедрения современных комплексных технологий. При разработке СУУТП используются современные инструменты анализа данных, автоматизации и искусственного интеллекта, что позволяет не только оперативно реагировать на изменения, но и прогнозировать их, обеспечивая стратегическое преимущество. Такие системы позволяют оптимизировать производственные процессы, снижать затраты, минимизировать риски и повышать качество продукции, что особенно важно для высокотехнологичных отраслей с высокой степенью инновационности и сложностью производственных цепочек [1]. Таким образом, разработка таких систем является важным шагом для высокотехнологичных предприятий, стремящихся сохранить устойчивое развитие в условиях глобализации и цифровизации [2].

В докладе представлены результаты разработки системы усовершенствованного управления процессами на высокотехнологичном предприятии на примере АСУ газовой отрасли с использованием газотурбинного двигателя, ГТД [3]. Газотурбинный двигатель, являясь ключевым элементом многих технологических процессов, требуют особого подхода к управлению, который способен обеспечить его максимальную эффективность и безопасность эксплуатации. Одной из основных научно-технических проблем в данной области является разработка алгоритмов управления, способных адаптироваться к изменяющимся условиям эксплуатации и минимизировать влияние внешних воздействий.

По причине наличия большого множества режимов работы двигателя, каждый из которых накладывает свои требования к системе регулирования, частичная неопределенность параметров, а также наличие внешних воздействий, которые могут привести к нежелательным последствиям, возникает необходимость внедрения системы усовершенствованного управления.

Каждый из режимов работы газотурбинного двигателя обладает своими особенностями, которые определяются сочетанием параметров его функционирования - частоты вращения ротора, расхода топлива, температуры рабочего тела, уровня генерируемой мощности или тяги, а также текущих нагрузок на установку. Основные режимы, включённые в СУУТП, можно условно разделить на несколько типов.

Пусковой режим: на данном этапе происходит запуск двигателя с исходно неподвижного состояния. В процессе пуска инициируется подача топлива и его воспламенение, после чего двигатель достигает устойчивого минимального режима работы. Важнейшими параметрами при пуске являются контроль стабильности пламени в камере сгорания и обеспечение плавного набора оборотов ротора.

Холостой ход: Двигатель работает с минимальной подачей топлива, поддерживая минимально возможные обороты без внешней полезной нагрузки или при минимальной тяге. На этом этапе важно обеспечивать стабильное горение и поддержание температуры камеры сгорания в пределах допустимых значений. Холостой ход служит отправной точкой для дальнейшего увеличения мощности.

Режим частичных нагрузок или же регулируемый режим: При эксплуатации в реальных условиях двигатель редко работает на максимальной мощности непрерывно. Обычно он функционирует в диапазоне частичной загрузки, адаптируясь под изменяющиеся внешние условия - потребности в мощности, изменения температуры окружающей среды, давления и др. Для ГТД в таких условиях важна гибкая система

регулирования, которая оптимизирует подачу топлива, положение направляющих лопаток компрессора или турбины, если таковые присутствуют, чтобы обеспечить стабильность процесса и максимально возможную эффективность.

Основной рабочий режим: Двигатель достигает оптимального соотношения между подачей топлива, скоростью потока через компрессор и турбину, температурой и давлением, выходя на заданный уровень мощности или тяги. В этом режиме, который часто называют «крейсерским» или «установившимся», достигаются наилучшие показатели эффективности, ресурса и топливной экономичности.

Режим Полной мощности: В случае необходимости кратковременно получить максимальную мощность или тягу двигатель выходит на верхний предел своих возможностей. В этом режиме повышается подача топлива, что приводит к увеличению температуры в камере сгорания и росту нагрузки на горячие тракты. Длительное пребывание на максимальной мощности нежелательно из-за повышенных тепловых напряжений и сокращения ресурса деталей.

Переходные режимы (ускорение, замедление, изменение мощности): При переходе от одного установленного режима к другому (например, от холостого хода к номинальному или от частичной нагрузки к максимальной) происходит динамическое изменение топливоподачи и прочих регулирующих параметров. Важным фактором здесь является обеспечение устойчивости горения, минимизация выбросов, предотвращение переходных вибраций и недопущение критичных превышений температурных лимитов.

Кроме множества режимов, имеют место различные условия работы, связанные с топливом. Помимо природного газа, двигатель может работать на основе нефтяного газа и данное топливо содержит вещества, которые могут повлиять на качество процесса сгорания топлива в камере сгорания. Предположим, что двигатель работал на природном газе, а затем перешел на нефтяной и это также влияет на температуру в камере сгорания, что привело к отклонению переходного процесса от уставки на 10%.

Все эти условия и множество данных приводят к необходимости их учёта в интеллектуальной системе усовершенствованного управления. В докладе представлена структура СУУТП газотурбинным двигателем: система управления состоит из нескольких поэтапных уровней, выполняющих свою задачу для осуществления комплексного управления, с учётом ограничений, режимов и базы данных в блоке интеллектуальной СУУТП. В ходе исследования была проанализирована и предложена структура системы управления и автоматизации технологических процессов для контура регулирования температуры в камере сгорания, что позволило обеспечить высокую точность регулирования параметров и учесть ограничения, характерные для работы газотурбинных двигателей.

Результаты показали, что использование интеллектуальной СУУТП способствует не только повышению стабильности работы системы, но и улучшению её адаптивности к внешним изменениям. Предложенный подход демонстрирует универсальность и эффективность, открывая перспективы для дальнейшего применения в других высокотехнологичных отраслях, где требуется управление сложными нелинейными процессами с учётом жёстких эксплуатационных ограничений.

Список использованной литературы:

1. Кузнецов С.В., Иванова Л.П. Автоматизированные системы управления технологическим процессом (АСУ ТП) // Информационные технологии и системы. – 2020. – № 3. – С. 78-85.
2. Петров И.И. Применение инновационных технологий управления предприятием в условиях цифровой экономики // Фундаментальные исследования. – 2021. – № 5. – С. 112-117.
3. Смирнов А.А. Подходы и модели к управлению изменениями на высокотехнологичных предприятиях // Молодой ученый. – 2022. – № 1. – С. 432-435.

Конструкция и применение обойм в подшипниковых узлах

Жиганбеков Қанат

Әл-Фараби атындағы Қазақ ұлттық университеті, Ақпараттық технологиялар факультеті, 2-курс студенті

Аннотация

Обоймы являются ключевым элементом подшипниковых узлов, обеспечивая их надёжность и долговечность. В данной работе рассматриваются конструкционные особенности обойм, их материалы, а также перспективы улучшения характеристик за счёт современных технологий.

Введение

Подшипниковые узлы широко применяются в машиностроении, авиации и других отраслях промышленности. Обоймы подшипников выполняют важную роль, обеспечивая правильное распределение нагрузки и минимизируя износ. Современные тенденции требуют повышения долговечности и надёжности обойм, что требует применения новых материалов и технологий производства.

Конструкция и материалы обойм

Обоймы подшипников могут быть изготовлены из различных материалов, таких как:

- Легированные стали (высокая прочность, устойчивость к нагрузкам).
- Керамика (снижение трения, коррозионная стойкость).
- Полимерные материалы (низкий вес, сниженный уровень шума).

Форма обоймы и метод её производства зависят от области применения. Чаще всего используются холодная и горячая штамповка, а также метод порошковой металлургии.

Перспективы развития

Современные исследования направлены на разработку композитных материалов, которые позволят снизить вес подшипниковых узлов и повысить их эксплуатационные характеристики. Одним из перспективных направлений является использование наноструктурированных покрытий, которые повышают износостойкость обойм.

Заключение

Обоймы подшипников являются критически важными элементами в машиностроении. Применение новых материалов и технологий их обработки позволяет значительно увеличить срок службы и надёжность подшипниковых узлов, что способствует развитию различных отраслей промышленности.

АНАЛИЗ СОСТОЯНИЯ И ПЕРСПЕКТИВЫ ВНЕДРЕНИЯ ЦИФРОВЫХ ДВОЙНИКОВ ДЛЯ ИНТЕЛЛЕКТУАЛЬНЫХ СЛОЖНЫХ СИСТЕМ УПРАВЛЕНИЯ

Кайрат А.А.,

КазНИТУ им. К. Сатпаева, Алматы

Современные системы управления становятся все более сложными, интегрируя множество взаимосвязанных элементов и процессов, различных методологий, в том числе, интеллектуальных. Системы с множеством входов и выходов (ММО) являются основой управления в таких отраслях, как промышленная автоматизация, энергетика, транспорт и другие. Однако их сложность предъявляет высокие требования к точности управления, адаптивности и устойчивости в условиях динамично меняющихся внешних факторов.

Цифровые двойники, представляющие собой виртуальные аналоги реальных объектов, открывают новые возможности для повышения эффективности и надежности управления. Они позволяют моделировать поведение сложных систем, прогнозировать их состояние и выявлять оптимальные управляющие воздействия, минимизируя затраты и риски. Внедрение цифровых двойников особенно актуально для интеллектуальных ММО-систем, где требуется обработка большого объема данных и учет множества взаимосвязанных параметров.

Цифровой двойник является цифровой информационной технологией, которая развивается вместе с развитием концепции Индустрия 4.0 и существует на протяжении более 30 лет. За последние годы технология все больше и больше популяризируется и становится перспективной для исследования.

В дорожной карте развития НАСА 2010 года [1], впервые описывают цифровой двойник следующим образом «Цифровой двойник – это интегрированная мультифизическая, многомасштабная симуляция транспортного средства или системы, в которой используются наилучшие доступные физические модели, обновления датчиков, история парка и т. д., чтобы отразить жизнь соответствующего летающего близнеца». Тогда ученые из НАСА использовали цифровой двойник для моделирования транспортного средства.

На сегодняшний день понятие цифрового двойника имеет множество значений, поэтому в общем смысле рассматривают два определения. Первое определение говорит о том, что цифровой двойник представляет физический объект, обладающий техническими характеристиками и оснащен системой датчиков, выполняет последовательность действий в определенных условиях. Второе определение нацелено на анализе бизнес-процессов, цифровой двойник является моделью жизненного цикла товара, которая необходима для виртуального исследования продукта для понимания его сильных и слабых сторон. Цифровой двойник имеет определённые отличия от схожих технологий, такие как системы автоматизированного проектирования, цифровая тень, интернет вещей тем что цифровой двойник является сложной многомерной системой, которая основана на технологии больших данных и позволяет рассматривать несколько вариантов развития событий в виртуальной среде для повышения качества принятых решений оптимального технологического решения.

Профессор Флоридского технологического института М. Grieves занимается изучением технологии цифровых двойников с 2003 года, он впервые описал концепцию технологии. В своей работе 2017 года [2], профессор говорил об незрелости технологии, основываясь на отсутствии достаточного развития технологий сбора и обработки данных. Он говорил о перспективах развития и потенциале использования технологии в управление объектов, выделяя следующие типы цифровых двойников:

–прототип «цифрового двойника». Этот тип двойника описывает прототип физического объекта, содержит информационные наборы необходимые для описания и создания системы;

–экземпляр «цифрового двойника». Этот тип двойника описывает конкретный продукт, с которым цифровой двойник связан на протяжении всего срока службы. Она может содержать 3D модель объекта, список операций и рабочие состояния;

–«цифровой двойник» агрегатор. Он представляет собой объединение всех остальных двойников. Он постоянно получает показания датчиков и сопоставляет их.

Особое внимание уделяется роли технологий интернета вещей (IoT), больших данных (Big Data) и искусственного интеллекта (AI) в создании цифровых двойников [3].

Результатом интеграции цифрового двойника является ускорение инженерных задач:

- состояние машин на 96,6%;
- движения вилочных погрузчиков на 96,6%;
- управление ограничениями на 98,33%;
- местоположение активов на 99,79%.

В работе [4] рассматривается проблема аддитивного производства технологии порошкового наплавления (PBF), при которой возникают проблемы с перегревом что приводит к браку деталей. Для решения использовалась модель цифрового двойника с интегрированным машинным обучением. Создана модель теплового поведения, учитывающая параметры лазера, геометрию деталей и траектории сканирования. Проведено обучение на репрезентативных объемных элементах (RVE), что позволяет точно предсказывать тепловые эффекты в любых точках траектории лазера. Цифровой двойник моделировал работу системы для наблюдений и экспериментов, выявления потенциальных точек перегрева, анализирование влияния параметров на результат.

В работе [5] описывается применение технологии цифровых двойников в электроэнергетических системах, особенно на подстанциях, для решения проблем мониторинга и управления. Основной целью было улучшить управление и надзор на подстанциях с помощью технологии цифровых двойников.

В работе [6] цифровой двойник был использован для управления системой водоснабжения и распределения в Валенсии (Испания). Без цифрового двойника у системы водоснабжения имелся ряд проблем. Для решения этих проблем смоделирована модель цифрового двойника, которая интегрировала данные со всех систем GIS (Geographic Information System), AMR (Automated Meter Reading), CMMS (Computerized Maintenance Management System), SCADA. Система повысила общий уровень управления системой, оптимизацию ресурсов и повышение качества предоставляемых услуг.

В ходе исследования была проанализирована информация по разработке и внедрению цифровых двойников для сложных систем управления. Данная технология является инновационной в области автоматизации и цифровизации технологических процессов и имеет высокие перспективы развития в ближайшем будущем. Дальнейшее развитие и распространение цифровых двойников будет способствовать развитию промышленных производств в целом.

Список используемой литературы:

1. Shafto, M., et al.: Modeling, Simulation, Information Technology and Processing Roadmap. // Technol. Area. – 2010. – no. 11. – pp. 1–32.
2. Дозорцев В. М. Цифровые двойники в промышленности: генезис, состав, терминология, технологии, платформы, перспективы. Часть 1 Возникновение и становление цифровых двойников. Как существующие определения отражают содержание и функции цифровых двойников? // Автоматизация в промышленности. – 2020. – № 9. – С. 3–11.
3. Grieves M., Vickers J. Digital twin: mitigating unpredictable, undesirable emergent behavior in complex systems. // Trans-disciplinary perspectives on complex systems. – 2017. –pp. 85–113.
4. Fergani, O.; Eissing, K. A machine learning-based digital twin of the manufacturing process: Metal powder-bed fusion case. // Eng. Arch. – 2020. – pp. 1–8.
5. Hu C., Shi W., Jiang L. Application case of digital twin technology in electric power system // IOP Conference Series: Materials Science and Engineering. – 2020. – vol. 788, no. 1. 012083.
6. Fuertes P.S. Building and exploiting a digital twin for the management of drinking water distribution networks // Urban Water Journal. – 2020. –vol. 17, no. 8. –pp. 704–713

Өнеркәсіптік цехтар мен зауыттарда қара жолды іздеу алгоритміне негізделген роботтарды пайдалануды зерттеу

Исмуханбетов Б.Т., Бектас.М.Н.

Ғылыми жетекші: Жұмахан Н.Б. техника ғылымдарының магистрі

Алматы технологиялық университеті, Алматы қ, Қазақстан

beka6768@gmail.com

Бұл мақалада қара жолды іздеу алгоритмін қолданатын мобильді роботтарды өнеркәсіптік цехтар мен зауыттарда қолдану қарастырылады. Мұндай жүйелердің негізгі принциптері, олардың артықшылықтары, сондай-ақ өндірістік процестерге енгізу перспективалары талданады.

Қазіргі заманғы өнеркәсіптік кәсіпорындар тиімділікті арттыру және процестерді автоматтандыру үшін роботтық жүйелерді енгізуде. Офлайн мобильді роботтарды шарлаудың кең таралған тәсілдерінің бірі-қара жолды іздеу алгоритмі (line Following Algorithm), бұл роботтарға контрастты белгілеуге назар аудара отырып, берілген траекторияны ұстануға мүмкіндік береді.

Алгоритмнің жұмыс принципі қара жолды іздеу алгоритмі роботтың астындағы бетті талдайтын сенсорларды (оптикалық немесе инфрақызыл) қолдануға негізделген. Алгоритмнің негізгі кезеңдері:

Сенсорлардан деректерді оқу.

Роботтың сызыққа қатысты орнын анықтау.

Басқару командаларының көмегімен траекторияны түзету.

Кедергілерді айналып өту мүмкіндігімен берілген маршрут бойынша қозғалыс.

Оптикалық және инфрақызыл датчиктер мобильді роботтардың навигациясында кеңінен қолданылады, бірақ оларды таңдау жұмыс жағдайына байланысты.

Кесте 1. Оптикалық және инфрақызыл датчиктерді талдау және салыстыру

Параметр	Оптикалық сенсорлар	Инфрақызыл сенсорлар
Жұмыс принципі	Көрінетін жарықты қолданыңыз	ИҚ сигналдарын шығарады және қабылдайды
Дәлдік	Жақсы жарықта жоғары	Әр түрлі жағдайда тұрақты
Ластануға сезімталдық	Жоғары (шаң, кір жұмысты нашарлатады)	Төмен (ластануға төзімді)
Төмен жарық жағдайында қолдану мүмкіндігі	Шектеулі	Жоғары
Бағасы	Орташа	Оптикалық қарағанда жоғары

Оптикалық сенсорлар көрінетін жарық негізінде жұмыс істейді және жақсы жарықта жоғары дәлдікті қамтамасыз етеді. Олар қарама-қарсы белгілермен жақсы жұмыс істейді және оларды түрлі-түсті сызықтармен жұмыс істеуге бейімдеуге болады. Алайда олардың тиімділігі шаң, кір және аз жарық жағдайында төмендейді.

Инфрақызыл датчиктер сәулелену және инфрақызыл сәулені қабылдау арқылы жұмыс істейді. Олар шаң мен нашар жарық сияқты сыртқы жағдайларға төзімді, бірақ шағылысуы төмен беттерде немесе инфрақызыл сәулеленудің бөгде көздері болған жағдайда жұмыс істеу қиын болуы мүмкін.

Осылайша, оптикалық және инфрақызыл датчиктерді таңдау жұмыс жағдайына байланысты: Оптикалық датчиктер таза және жақсы жарықтандырылған бөлмелер үшін қолайлы, ал инфрақызылдар шаңды немесе аз жарықтандырылған өндіріс аймақтары үшін жақсырақ.

Өнеркәсіпте қолдану осы алгоритммен жабдықталған роботтарды қолдану келесі

салаларда кең таралған. Логистика және қойма. Автономды роботтар жүктерді өндіріс орындары арасында тасымалдайды. Орнату желілері. Бөлшектер мен материалдарды жұмыс станцияларына үздіксіз жеткізуді қамтамасыз етеді. Сапаны бақылау. Датчиктері бар жылжымалы платформалар дайын өнімді талдайды.

Пайдаланудың артықшылықтары

Персоналдың құнын төмендету - автоматтандырылған роботтар адамның қатысуынсыз күнделікті тапсырмаларды орындайды.

Дәлдік пен сенімділік – тасымалдау және құрастыру қателіктерін азайту.

Бейімделу икемділігі – маршруттарды жылдам өзгерту және қолданыстағы өндірістік желілерге біріктіру мүмкіндігі.

Даму перспективалары сенсорлық технологиялар мен жасанды интеллектті жетілдіру роботтардың навигациясы мен динамикалық өндіріс жағдайларына бейімделуін жақсартуға мүмкіндік береді. Машиналық оқытуды енгізу мұндай жүйелердің функционалдығын кеңейтіп, оларды автономды және әмбебап етеді.

Қара жолды іздеу алгоритмімен жұмыс өнеркәсіптік процестерді автоматтандыруда маңызды рөл атқарады. Оларды қолдану тиімділікті арттыруға, шығындарды азайтуға және өнім сапасын жақсартуға ықпал етеді. Осы саладағы одан әрі зерттеулер осындай жүйелердің дербестігі мен бейімделуін арттыруға бағытталған.

Пайдаланылған әдебиеттер тізімі:

1. Смирнов А. В. "Робототехника в промышленности" – М.: ТехноПресс, 2020.
2. Иванов П. С. "Навигационные системы для мобильных роботов" – СПб.: Наука, 2019.
3. Robotics Today. "Line Following Robots in Industry" – 2023.

Устройство помола зерна и промежуточных продуктов в вальцовых станках повышенной производительности

Каратаева Ж.Е., Джумабекова З.А., Чакеева К.С.

Алматинский технологический университет

Satbayev University

email: zhanna_karataeva68@mail.ru

При производстве муки процесс измельчения зерна и промежуточных продуктов является одним из главных, так как в значительной мере влияет на выход и качество готовой продукции [1].

Измельчение зерна и промежуточных продуктов в вальцовых станках осуществляется в клиновидном пространстве, образованном цилиндрическими поверхностями двух параллельных валцов, вращающихся навстречу друг другу с различными скоростями. Разрушение зёрен происходит в результате сочетания деформаций сжатия и сдвига [2]. Причем преобладание того или иного типа деформации зависит от отношения скоростей валцов и взаимного расположения несимметричных рифлей на поверхности валцов.

Эффективность работы вальцовых станков определяется оптимальным сочетанием трех основных показателей: степенью измельчения зерна или его частиц, производительностью каждой пары валцов и удельным расходом электроэнергии [3,4].

Рассмотрим кинематику и динамику движения зерна в вальцовом станке (рис. 1). Как показано стрелками валок (1) движется существенно медленнее второго валка (2) и между ними создания относительная скорость, определяющая работу измельчения зерна истирание поверхности, важную для снятия оболочек зерна.




Рис.1. Схема измельчения в вальцовом станке.

По мере продвижения вглубь рабочей зоны станка увеличивается нормальная составляющая сил и, соответственно, работа измельчения эндосперма зерна давлением. Соотношение мощностей, затрачиваемых на каждый вид работ, зависит от угла захвата зерна вальцами, который в свою очередь определяется внутренним и поверхностным коэффициентом трения. Мощность, затрачиваемая станком на измельчение зерна [5], таким образом, зависит от двух частей:

$$N = N_{и} + N_{р} \quad (1)$$

где N – полезная мощность; $N_{и}$ и $N_{р}$ – мощности истирания и раздавливания соответственно.

Обозначив долю мощности раздавливания через α , производительность измельчения Q можно выразить в форме:

$$Q = [\alpha K_p + (1 - \alpha)K_n]N * V \quad (2)$$

где K_p и K_n – коэффициенты эффективности раздавливания и истирания; V – общая ёмкость с учетом длины валков.

Все входящие в (2) коэффициенты зависят от угла захвата φ , изменяющегося в зависимости от чисел оборотов валцов и свойств зерна. Изменяются также и качество продуктов, оцениваемые по белизне муки и потерям в отрубях [6].

Развитие системы вальцового станка с шнековым питателем позволяет совместить регулирование производительности и качество помола путем вращения известной части продукта с выхода на вход питания с помощью того же шнека в качестве подъемника. При этом увеличивается собственное время пребывания материала в рабочей зоне и однородность готового продукта за счёт повторного прохождения между вальцами.

Список использованной литературы:

1. Асамбаев, А. Автоматизация технологических процессов для хлебопекарного, макаронного и кондитерского производства [текст] : учебное пособие / А. Асамбаев. – Астана : Фолиант, 2010. – 384 с. – ISBN 978-601-292-135-9 : 1458.00.
2. Оборудование и автоматизация перерабатывающих производств [Текст/Электронный ресурс] : Практикум / А. А. Курочкин, Г. В. Шабурова, В. М. Зимняков, А. В. Поликанов. – М. : Юрайт, 2020. – 185 с. – ISBN 978-5-534-07537-3 : 4950.00. <https://library.atu.edu.kz/files/125815>
3. Арынгазин, К.Ш. Проектирование зерновых элеваторов с элементами САПР [Текст/Электронный ресурс] : учебник / К. Ш. Арынгазин, А. И. Изтаев. – Алматы : Эверо, 2021. – 176 с. – ISBN 9965-439-96-6 : 7200.00. <https://library.atu.edu.kz/files/126314>
4. Искаков, Р.М. Измельчение в перерабатывающей и пищевой промышленности [Текст/Электронный ресурс] : учебное пособие / Р. М. Искаков. – Алматы : Лантар Трейд, 2020. – 177 с. – ISBN 9965-31-364-4 : 4300.00.
5. Электрофизические методы обработки зерна на элеваторах и зерноперерабатывающих предприятиях [Текст/Электронный ресурс] : Монография / А. И. Изтаев, Т. К. Кулажанов, М. М. Маемеров [и др.]. – Алматы : LEM, 2015. – 172 с. – ISBN 978-601-239-382-8 : 2325-00. <https://library.atu.edu.kz/files/39022>
6. Технологические процессы перерабатывающих производств : учебно-методическое пособие / В. Е. Гапонова, Е. И. Слезко, А. И. Купреенко, С. Х. Исаев. — Брянск : Брянский государственный аграрный университет, 2022. — 59 с. — Текст : электронный // Цифровой образовательный ресурс IPR SMART : [сайт]. — URL: <https://www.iprbookshop.ru/138531.html>

Предиктивный промышленный сервис с использованием машинного обучения

Койбагаров М., Алдияров Н., Рахметова П., Сыдыканов С.

КазНИТУ им. К.И.Сатпаева, Алматы, Казахстан

В современных промышленных системах внезапные отказы оборудования приводят к дорогостоящим простоям и авариям, поэтому задача раннего обнаружения потенциальных неисправностей приобретает особую актуальность. Традиционные подходы к техническому обслуживанию — реактивный ремонт по факту поломки или планово-предупредительное обслуживание по расписанию — нередко оказываются неэффективными: первый приводит к незапланированным простоям, а второй — к преждевременным, порой избыточным работам. В данной диссертации предлагается стратегия предиктивного технического обслуживания (predictive maintenance), основанная на применении алгоритмов машинного обучения, которая позволяет на ранней стадии выявлять признаки будущих отказов и тем самым принимать упреждающие меры.

Разработанная система предиктивного обслуживания предполагает непрерывный сбор данных от целого ряда промышленных датчиков, измеряющих ключевые параметры работы оборудования: электрический ток, температуру, давление и вибрацию. Эти сенсоры интегрированы с программируемыми логическими контроллерами (ПЛК) Siemens, а применение стандартизированного протокола обмена данными OPC UA (Open Platform Communications Unified Architecture) обеспечивает надежную и безопасную передачу большого объема данных в режиме реального времени для последующего анализа. Перед передачей в аналитические модули сырые сигналы подвергаются предварительной обработке и фильтрации (в том числе с использованием фильтра Калмана) для повышения достоверности измерений и устранения шумов.

Поток данных анализируется интеллектуальными алгоритмами машинного обучения, способными выявлять скрытые закономерности, предшествующие отказу оборудования. Центральным компонентом системы является непрерывно обучающаяся нейронная сеть, тренируемая на исторических данных об эксплуатационных режимах и произошедших отказах оборудования. Модель регулярно обновляется по мере поступления новых данных. При этом для корректировки апостериорных оценок её параметров используется теорема Байеса, что позволяет нейронной сети адаптироваться к меняющимся условиям и со временем повышать точность предсказаний.

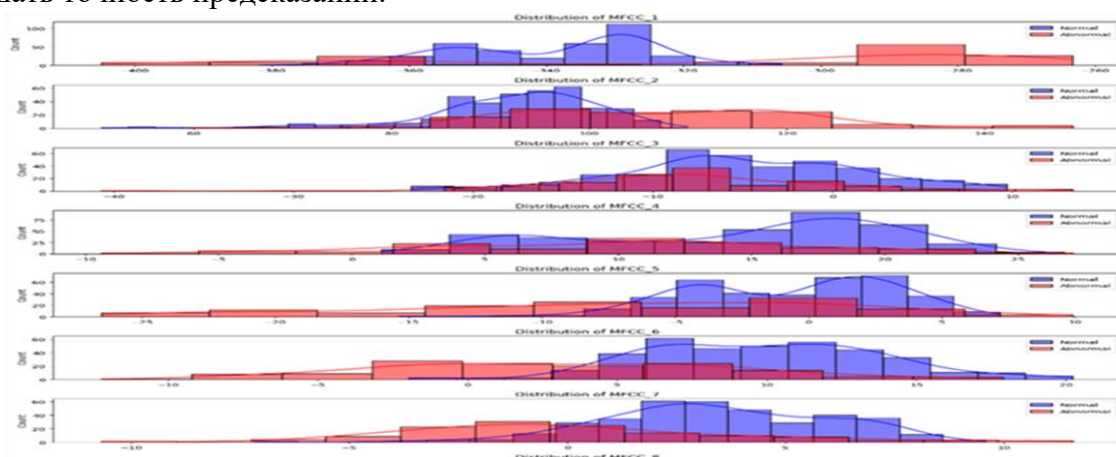


Рисунок 1. График сравнительного анализ

Конкретной архитектурой модели, используемой для анализа временных рядов сенсорных данных, является рекуррентная нейронная сеть с механизмом долгой краткосрочной памяти (Long Short-Term Memory, LSTM), способная улавливать долговременные зависимости в последовательностях измерений. Кроме того, для выявления

скрытых аномалий применяются автокодировщики (autoencoders) — специальные нейронные сети, обучающиеся воспроизводить входные сигналы и сигнализирующие о неполадках, когда реальные данные существенно отклоняются от восстановленных моделью. Совокупность таких подходов обеспечивает надежное обнаружение как постепенных деградиационных изменений состояния оборудования, так и резких аномальных событий.

Помимо анализа данных датчиков, в систему интегрирован модуль компьютерного зрения для контроля качества продукции и обнаружения визуальных отклонений. На производственной линии устанавливаются камеры, а получаемые изображения обрабатываются специализированными алгоритмами, в частности, сверточными нейронными сетями (Convolutional Neural Networks, CNN), способными автоматически распознавать дефекты изделий. Наличие такого визуального контроля добавляет дополнительный уровень мониторинга: выявленные на ранней стадии отклонения во внешнем виде продукции могут служить индикаторами скрытых неполадок технологического процесса или самого оборудования.



Рисунок 2. Контроль качество готовой продукции

Помимо сложных моделей глубокого обучения в работе рассматриваются и классические методы прогнозирования, например, линейная регрессия, которые могут служить эталоном при оценке эффективности алгоритмов и обеспечивать лучшую интерпретируемость результатов. Такая модель способна, к примеру, прогнозировать оставшийся ресурс работы узла на основе динамики показаний датчиков. Формально зависимость между параметрами может быть выражена уравнением вида $Z = a_0 + a_1x + a_2y + \dots$, где Z - значения регистрируемых датчиками показателей (температуры, вибрации и т.д.), а y - предсказываемый параметр состояния (например, вероятность отказа или время до наступления отказа).

Для практической реализации концепции предиктивного обслуживания особое внимание уделяется способам представления и использования результатов анализа. Прогнозы и диагностические показатели интегрируются в системы диспетчерского контроля и сбора данных (SCADA), что позволяет инженерно-техническому персоналу в режиме реального времени отслеживать состояние оборудования и получать предупреждения о вероятных неполадках. Параллельно сводная аналитическая информация передается в платформы бизнес-аналитики (например, Microsoft Power BI), где ключевые показатели надежности визуализируются на интерактивных информационных панелях. Такой подход облегчает принятие решений руководством на основе данных и повышает прозрачность контроля состояния производственных фондов.

Предлагаемый подход призван преодолеть ограничения существующих стратегий технического обслуживания и отвечает актуальным промышленным вызовам. Реактивный ремонт оборудования неизбежно сопровождается неожиданными простоями, а регламентное обслуживание не гарантирует оптимального использования ресурса агрегатов. В отличие от этих подходов, предиктивные методы позволяют заблаговременно выявлять проблемы и планировать вмешательство только тогда, когда это действительно необходимо. Такая проактивная стратегия особенно важна для Казахстана, где остро ощущается нехватка опытных

инженерных кадров, а значительная часть промышленной инфраструктуры, унаследованной еще со времен СССР, устаревает. Интеллектуальная система мониторинга и прогнозирования отказов может частично компенсировать дефицит квалифицированного персонала и обеспечить надежную работу даже для оборудования с истощающимся ресурсом. Для изучения промышленного сектора Казахстана мы посетили предприятия из нефтегазовой отрасли, пищевой промышленности, производства напитков и машиностроения. На рисунке ниже показаны эффекты реактивного обслуживания оборудования, и это реальное оборудование, находящееся в эксплуатации.



Рисунок 3. Последствия реактивного технического обслуживания

Реализация предложенной системы предиктивного обслуживания является шагом на пути к Индустрии 4.0 — следующему этапу развития промышленности, который характеризуется всеобщей цифровизацией процессов, высоким уровнем взаимосвязанности устройств (Industrial Internet of Things, IIoT) и широким использованием интеллектуальных технологий. Решения, представленные в диссертации, демонстрируют на практике преимущества такого подхода, соответствующего принципам Индустрии 4.0, для повышения эффективности и надежности производства. Тем самым работа содействует интеграции передовых цифровых технологий в традиционные промышленные процессы и приближает отечественные предприятия к мировым стандартам «умного» производства.

Таким образом, представленная стратегия предиктивного обслуживания объединяет новейшие методы анализа данных с технологиями промышленной автоматизации, формируя надежную платформу для упреждающего управления состоянием оборудования. Ожидается, что внедрение разработанной системы позволит существенно снизить незапланированные простои, оптимизировать затраты на ремонт и обслуживание, продлить срок службы ключевых узлов и обеспечить стабильную и безопасную работу производственных объектов. Данная диссертация наглядно демонстрирует, как современные научно-технические решения могут напрямую способствовать повышению эффективности промышленного производства.

Интеллектуалды басқару жүйелері және автоматтандыру: ақылды құрылғыларға арналған шешімдер

Кубашев Бекзат

Әл-Фараби атындағы Қазақ ұлттық университеті, Ақпараттық технологиялар факультеті

Кіріспе:

Қазіргі заманғы технологиялардың дамуы көптеген салаларда интеллектуалды басқару жүйелерін (ИБЖ) кеңінен қолдануға мүмкіндік береді. Ақылды құрылғылар автоматтандыруды жетілдіру, ресурстарды үнемдеу және пайдаланушылардың өмірін жеңілдету мақсатында жасалады. Бұл мақалада интеллектуалды басқару жүйелері мен автоматтандырудың маңызы, олардың артықшылықтары және қолдану салалары қарастырылады.

Интеллектуалды басқару жүйелерінің маңызы:

Интеллектуалды басқару жүйелері – жасанды интеллект (ЖИ), машиналық оқыту және үлкен деректерді өңдеу сияқты технологияларды қолданатын кешенді шешімдер. Мұндай жүйелер деректерді жинап, өңдеп, нақты уақыт режимінде талдау жүргізеді, нәтижесінде тиімді шешімдер қабылдайды. Сонымен қатар, ИБЖ адам факторынан туындайтын қателіктерді азайтып, процестерді автоматтандыру арқылы өнімділікті арттырады. Бұл жүйелер денсаулық сақтау, ауыл шаруашылығы, өнеркәсіп және көлік сияқты көптеген салаларда кеңінен қолданылады.

Ақылды құрылғыларға арналған автоматтандыру:

Автоматтандыру – өндірістік процестерді, тұрмыстық құрылғыларды және басқа да жүйелерді адам араласуынсыз басқару. Ақылды құрылғыларға арналған автоматтандырудың бірнеше түрі бар:

1. **Үй автоматтандыруы (Smart Home)** – жарықты, жылытуды, қауіпсіздік жүйелерін, тұрмыстық техниканы басқару. Мысалы, ақылды термостаттар үй ішіндегі температураны реттеп, энергия шығынын азайтады.

2. **Өндірістік автоматтандыру** – робототехникалық кешендер, ақылды сенсорлар және деректерді талдау жүйелері арқылы өндірістік процестерді оңтайландыру. Өнеркәсіптік кәсіпорындарда роботтар өнімді жинау, сұрыптау және тасымалдау жұмыстарын атқарады.

3. **Көлік жүйелерін автоматтандыру** – ақылды көлік қозғалысын басқару, автономды көліктер, GPS және сенсорлық технологияларды пайдалану. Бұл жүйелер жол кептелісін азайтып, жанармай шығынын үнемдеуге көмектеседі.

4. **Ауыл шаруашылығын автоматтандыру** – ақылды суару жүйелері, топырақ ылғалдылығын анықтайтын сенсорлар, дрондар арқылы дақылдардың жағдайын бақылау.

5. **Денсаулық сақтау саласында автоматтандыру** – қашықтықтан науқастардың денсаулығын бақылау, диагностика жүйелерін жетілдіру, хирургиялық роботтарды қолдану.

Артықшылықтары

• **Энергияны үнемдеу** – ақылды құрылғылар энергия тұтынуды оңтайландырады. Мысалы, ақылды жарықтандыру жүйелері адамның қатысуын анықтап, автоматты түрде қосылып-өшеді.

• **Қауіпсіздікті арттыру** – автоматтандырылған жүйелер қауіп-қатерлерді алдын ала анықтай алады. Мысалы, бейнебақылау жүйелері мен дабыл құрылғылары үйлер мен кәсіпорындардың қауіпсіздігін қамтамасыз етеді.

• **Пайдаланудың ыңғайлылығы** – құрылғыларды смартфон немесе басқа да қашықтан басқару құралдары арқылы бақылау мүмкіндігі.

• **Шешім қабылдаудың тиімділігі** – жасанды интеллект арқылы деректерді талдап, оңтайлы шешім қабылдау. Бұл әсіресе өндірістік процестерде маңызды.

• **Экономикалық тиімділік** – автоматтандырылған жүйелер адам еңбегін азайтып, өндірістік шығындарды төмендетеді.

Қолдану салалары Интеллектуалды басқару жүйелері мен автоматтандыру көптеген салаларда қолданылады:

- **Өнеркәсіп** – өндірістік процестерді автоматтандыру, роботтарды қолдану.
- **Ауыл шаруашылығы** – ақылды суару, егіншілікті бақылау.
- **Денсаулық сақтау** – қашықтықтан бақылау, диагностикалық жүйелер.
- **Көлік және логистика** – автономды көліктер, көлік қозғалысын оңтайландыру.
- **Тұрмыстық технологиялар** – ақылды үйлер, IoT құрылғылары.

Қорытынды

Интеллектуалды басқару жүйелері мен автоматтандыру – қазіргі заманғы технологиялардың ажырамас бөлігі. Олар өмір сапасын жақсартып, бизнес пен өндірістік салалардағы тиімділікті арттырады. Ақылды құрылғыларды дамыту болашақта одан әрі жетілдіріліп, кеңінен қолданыс табатыны сөзсіз. Технологиялық прогрестің арқасында автоматтандыру деңгейі жоғарылап, адамдардың күнделікті өмірінде маңызды рөл атқарады.

РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНОЙ СЛОЖНОЙ СИСТЕМЫ УПРАВЛЕНИЯ КОТЛОАГРЕГАТАМИ НА ОСНОВЕ МОДЕЛЬНО ПРЕДИКТИВНОГО УПРАВЛЕНИЯ

Кутняков Д.И.

*Казахский национальный исследовательский технический университет им. К. Сатпаева,
Алматы, Казахстан*

В настоящее время что модельно-предиктивное управление (МРС) демонстрирует значительные преимущества в управлении теплоэнергетическими системами. Этот подход обеспечивает точное прогнозирование процессов, минимизирует расход топлива, снижает выбросы вредных веществ и повышает энергоэффективность котлоагрегатов. Развитие технологий МРС играет ключевую роль в создании экологически устойчивых и высокоэффективных теплоэнергетических объектов.

Результаты, представленные в докладе, получены в результате разработки системы управления котлоагрегатами на основе МРС, включая математическое моделирование, интеллектуальные алгоритмы прогнозирования и оптимизации. Основное внимание уделено повышению точности управления и достижению оптимальных показателей энергоэффективности в условиях реального производства. Результаты исследования могут быть применены для повышения эффективности теплоэнергетических объектов и улучшения их экологических показателей.

В исследовании Парсункина Б.Н. и соавторов рассматривается автоматическая оптимизация управления процессом сжигания топлива в методической печи с использованием системы экстремального регулирования [1]. Авторы отмечают, что применение эффективного алгоритма поиска обеспечивает качественное функционирование системы и ее стабильность в условиях дрейфа статической характеристики. Холманов Р.У. в своей работе акцентирует внимание на энергоэффективном предаварийном управлении процессом сжигания топлива в печах. Он подчеркивает, что функциональная декомпозиция энерго- и ресурсосберегающей системы автоматического регулирования процесса горения способствует повышению надежности и эффективности работы газосжигающих печей [2].

Кроме того, внедрение МРС способствует более равномерному распределению температур в зоне горения, что предотвращает локальные перегревы и износ оборудования. Это особенно важно для крупных теплоэнергетических объектов, где даже незначительные колебания температуры могут привести к повреждению труб, повышенному расходу топлива и другим аварийным ситуациям. Применение МРС обеспечивает точное регулирование подачи топлива и воздуха, что минимизирует образование зон с избыточным или недостаточным количеством кислорода. Это позволяет поддерживать стабильность процессов горения даже при изменении внешних условий, таких как колебания нагрузки или состава топлива [3].

Как отмечается в материалах компании АВВ, технологии Advanced Process Control (APC), в которые интегрированы подходы МРС, представляют собой комплексные решения для повышения эффективности и надежности энергетических систем. APC включает в себя более широкие стратегии управления, где МРС выступает основным инструментом для прогнозирования и оптимизации управляющих воздействий в реальном времени. Такой подход позволяет не только стабилизировать процесс горения, но и сократить время, необходимое для достижения оптимального режима работы. Это особенно актуально для объектов с высокой динамикой изменения параметров, где быстрый переход в устойчивое состояние играет критическую роль в снижении эксплуатационных затрат и увеличении срока службы оборудования [4].

Достоинство APC заключается в способности интегрировать множество различных процессов, включая управление горением, регулирование температуры и давления, а также

анализ данных в реальном времени. Например, APC на базе MPC обеспечивает возможность комбинированного управления параметрами горения и минимизации выбросов, что значительно улучшает экологические показатели работы котлоагрегатов.

Дополнительно, в брошюрах компании ABB подчеркивается, что использование APC с элементами MPC позволяет интегрировать алгоритмы прогнозирования с системами мониторинга в реальном времени. Это дает возможность оперативно корректировать параметры работы и предотвращать отклонения от нормального режима. Внедрение таких решений также помогает повысить энергоэффективность оборудования, сократить выбросы вредных веществ и улучшить экологические показатели.

Таким образом, подходы компании ABB к применению APC с интеграцией MPC демонстрируют значительный потенциал в повышении стабильности и надежности работы котлоагрегатов. Такие решения становятся незаменимыми инструментами для современных теплоэнергетических объектов, где требуются максимальная эффективность и соответствие строгим экологическим стандартам.

Особый интерес вызывает возможность применения MPC для прогнозирования будущих состояний системы на основе исторических данных и текущих измерений. Современные алгоритмы, интегрированные с системами сбора данных в реальном времени, позволяют заблаговременно выявлять потенциальные отклонения от оптимального режима работы и предотвращать возможные неисправности. Это не только снижает затраты на ремонт, но и продлевает срок службы оборудования.

Таким образом, внедрение модельно-предиктивного управления в процессы сжигания топлива не только повышает энергоэффективность котлоагрегатов, но и способствует решению важных экологических задач, таких как сокращение выбросов углекислого газа и других вредных веществ. В совокупности с интеллектуальными алгоритмами, это делает MPC незаменимым инструментом для современного теплоэнергетического комплекса.

Результатами исследования являются разработанные алгоритмы модельно-предиктивного управления для интеллектуальной сложной системы управления котлоагрегатом. Эти алгоритмы направлены на оптимизацию работы котлоагрегатов, улучшение их энергоэффективности и снижение выбросов при различных операционных режимах. Внедрение этих алгоритмов позволяет значительно повысить точность управления и предотвратить аварийные ситуации за счет оперативной корректировки параметров работы.

Кроме того, разработанные алгоритмы включают в себя интеграцию с диагностическими модулями, что позволяет эффективно отслеживать состояние системы в реальном времени. Это делает возможным предсказание отклонений от оптимальной работы и принятие корректирующих мер на ранних стадиях, что существенно увеличивает надежность и безопасность эксплуатации котлоагрегатов. В результате, применяя модельно-предиктивное управление, удаётся не только повысить эксплуатационные характеристики, но и достичь устойчивого функционирования системы с минимальными энергетическими и экологическими затратами, соответствующими современным стандартам.

Список использованной литературы:

- 1 Кузнецов А. В., Иванов И. И. Системы автоматического управления в теплоэнергетике. – М.: Энергоатомиздат, 2018. – 320 с.
- 2 Сидоров А. Н., Павлов В. Г. Теплотехнические процессы и автоматизация. – СПб.: БХВ-Петербург, 2016. – 288 с.
- 3 Казанцев А. П., Логинов Д. И. Моделирование и управление теплоэнергетическими объектами. – Екатеринбург: УГТУ, 2019. – 240 с.
- 4 Кузнецов А. В., Иванов И. И. Системы автоматического управления в теплоэнергетике. – М.: Энергоатомиздат, 2018. – 320 с.
- 5 Смирнов Е. А. Применение модельно-предиктивного управления для оптимизации процессов в энергетических установках // Вестник технических наук. – 2021. – № 3. – С. 78-85.

ФИЛЬТРАТТАН КҮКІРТСУТЕКТІ ДЕСОРБЦИЯЛАУ ПРОЦЕСІН БАСҚАРУДЫҢ ИНТЕЛЛЕКТУАЛДЫ АЛГОРИТМДЕРІ: ҚАЗІРГІ ТӘСІЛДЕР МЕН БОЛАШАҒЫ

Қуаныш Айбек Нұрланұлы

Satbayev University, 7M07114 Автоматтандыру және роботтандыру, 1-курс магистранты
Ғылыми жетекші: Сулейменов Б.А., техника ғылымдарының докторы

Кіріспе. Күкіртсутектің десорбциясы – экологиялық және өнеркәсіптік маңызды процесс. Өндірістік қалдықтардан күкіртсутекті тиімді түрде жою қоршаған ортаны қорғау мен өнеркәсіптік қауіпсіздікті қамтамасыз етудің маңызды аспектісі болып табылады. Бұл процесті басқару тиімділігін арттыру – заманауи технологияларды қажет ететін күрделі мәселе. Классикалық басқару әдістері шектеулі тиімділік көрсететіндіктен, интеллектуалды алгоритмдерді қолдану ерекше өзектілікке ие болып отыр. Жасанды интеллект, машиналық оқыту және адаптивті басқару жүйелері десорбция үдерісінің тиімділігін арттырып қана қоймай, өндірістік шығындарды азайтуға да мүмкіндік береді.

Бұл шолу мақаласы күкіртсутекті десорбциялау процесін басқарудың заманауи интеллектуалды әдістерін талдауға бағытталған. Зерттеудің мақсаты – қазіргі қолданыстағы алгоритмдерді салыстырып, олардың тиімділігін бағалау, сондай-ақ болашақта қолданылуы мүмкін перспективті технологияларды қарастыру.

Әдеби шолу. Күкіртсутектің десорбциясы – газ немесе сұйық фазадан күкіртсутекті бөліп алу процесі. Бұл процесс түрлі әдістер арқылы жүзеге асырылады: физикалық, химиялық және биологиялық тәсілдер. Физикалық десорбция күкіртсутекті қысым мен температураның өзгеруі арқылы бөліп алу әдісіне негізделген. Химиялық десорбцияда күкіртсутек арнайы реагенттермен әрекеттесіп, зиянсыз қосылыстарға айналады. Ал биологиялық тәсілдер микроорганизмдерді пайдалану арқылы жүзеге асады. Десорбцияның тиімділігіне әсер ететін негізгі факторларға температура, қысым, реагенттердің концентрациясы және газ қоспасының құрамы жатады [1].

Қазіргі уақытта күкіртсутекті жоюдың бірнеше дәстүрлі әдістері қолданылады. Олардың ішіндегі ең танымалдары – абсорбция, адсорбция және каталитикалық әдістер. Абсорбция күкіртсутекті сұйықтық арқылы жұтуға негізделген және көбінесе химиялық реагенттерді қолдану арқылы жүзеге асады. Адсорбция процесінде газ қоспаларындағы күкіртсутек қатты бетке жиналады (белсенді көмір, цеолиттер, металл оксидтері). Каталитикалық әдістерде арнайы катализаторлар күкіртсутекті тотықтыру немесе басқа қосылыстарға айналдыру үшін қолданылады. Бұл әдістердің әрқайсысының өзіндік артықшылықтары мен кемшіліктері бар. Мысалы, абсорбция әдісі тиімді болғанымен, ол үлкен көлемдегі химиялық реагенттерді қажет етеді. Ал адсорбция әдісі салыстырмалы түрде экологиялық таза болғанымен, сорбенттердің регенерациясы қосымша шығындарды талап етеді [2].

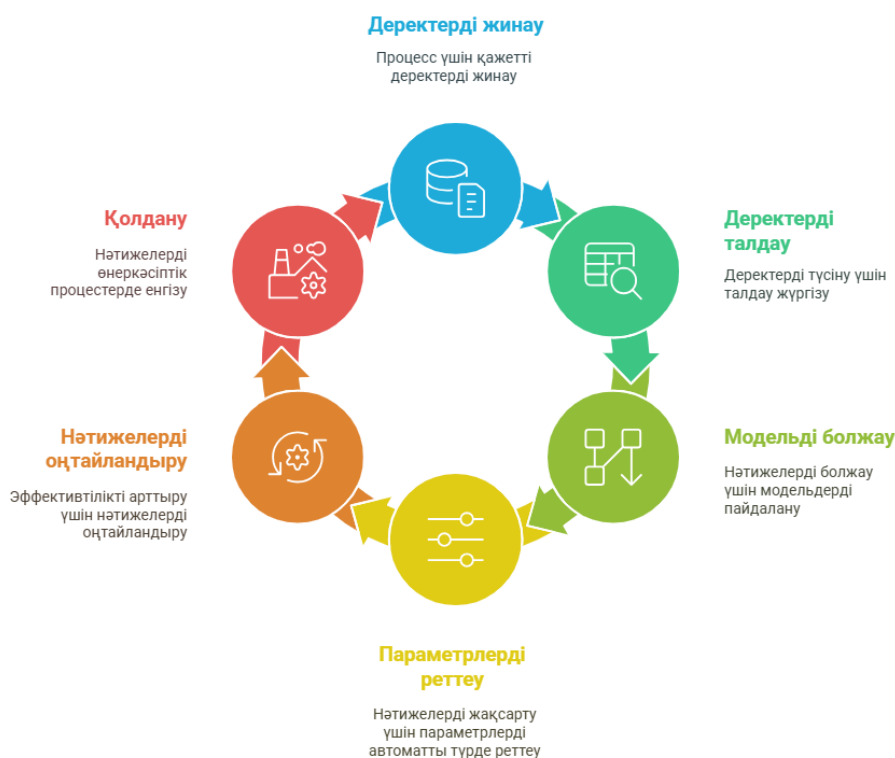
Күкіртсутекті десорбциялау процесін басқарудың дәстүрлі жүйелері көбінесе PID-регуляторлар мен бейімделгіш басқару жүйелеріне негізделген. PID-регуляторлар – өнеркәсіптік процестерді автоматтандыруда кең таралған әдіс, бірақ олар күрделі көпфакторлы процестерді тиімді түрде басқаруға әрдайым қабілетті емес. Соңғы жылдары интеллектуалды басқару әдістері кеңінен қолданылып келеді. Оларға машиналық оқыту, нейрондық желілер, генетикалық алгоритмдер және бұлттық есептеулер негізіндегі әдістер жатады. Цифрлық технологиялардың дамуы күкіртсутекті десорбциялау процесін нақты уақыт режимінде оңтайландыруға мүмкіндік береді. Сонымен қатар, өндірістік деректерді талдау арқылы басқару жүйелерін жетілдіруге болады.

Зерттеу әдістері. Күкіртсутекті десорбциялау процесін басқаруда интеллектуалды алгоритмдерді қолдану өндірістік жүйелерді жетілдірудің маңызды бағыты. Бұл мақсатта жасанды интеллект (ЖИ), машиналық оқыту (МО) және нейрондық желілер негізінде басқару стратегиялары қолданылады. Машиналық оқыту әдістері үлкен деректерді өңдеп, нақты уақыт режимінде шешім қабылдауға мүмкіндік берсе, нейрондық желілер күрделі көпфакторлы

процестерді болжау және басқару үшін тиімді. Генетикалық алгоритмдер басқару параметрлерін автоматты түрде оңтайландыруға көмектесе, бұлттық есептеулер үлкен деректерді өңдеу арқылы басқару жүйесінің тиімділігін арттырады.

Деректерді талдау және басқару стратегиялары жүйенің жұмысын терең талдап, процестің тиімділігін арттыруға ықпал етеді. Үлкен деректерді өңдеу әдістері күкіртсутек концентрациясын бақылауға және алдын ала болжауға мүмкіндік береді. Жүйенің динамикалық моделін құру процестің әртүрлі сценарийлерде қалай өзгертінін болжауға және тиімді басқару стратегияларын қалыптастыруға көмектеседі.

Нәтижелер мен талқылау. Күкіртсутекті десорбциялау процесін басқару үшін қолданылып жүрген интеллектуалды әдістерді салыстырмалы талдау барысында нейрондық желілер негізіндегі жүйелердің тиімділігі жоғары екені анықталды. Бұл әдістер күрделі процестерді болжауға және параметрлерді автоматты түрде реттеуге мүмкіндік береді. Сонымен қатар, машиналық оқыту алгоритмдерінің тиімділігі жоғары, өйткені олар деректер негізінде өзін-өзі оқыту арқылы процесті бейімдей алады. Генетикалық алгоритмдер және адаптивті басқару жүйелері басқару параметрлерін оңтайлы таңдауға көмектеседі, бұл өндірістік шығындарды төмендетуге және күкіртсутек десорбциясының тиімділігін арттыруға ықпал етеді.



Сурет 1- Интеллектуалды жүйелердің басқару циклдары

Интеллектуалды алгоритмдердің өндірістік тәжірибеде қолданылуы кеңінен таралған. Олар мұнай-газ саласында, химиялық өндірісте және экология саласында қолданылады. Мұнай-газ өнеркәсібінде күкіртсутек құрамын тиімді бақылау және жою маңызды болғандықтан, интеллектуалды басқару жүйелері процесті автоматтандыруға және қауіпсіздікті арттыруға көмектеседі. Химия өнеркәсібінде бұл әдістер реагенттердің шығынын оңтайландыруға және процестің экологиялық қауіпсіздігін қамтамасыз етуге мүмкіндік береді [3]. Экология саласында күкіртсутекті тиімді жою ауа сапасын жақсартуға және қоршаған ортаға теріс әсерді азайтуға бағытталған. Дегенмен, қолданыстағы шешімдердің кейбір кемшіліктері бар, мысалы, интеллектуалды жүйелерді енгізу үшін үлкен көлемде деректер жинау және оларды өңдеу қажет, сондай-ақ кейбір алгоритмдер нақты өндірістік шарттарға

бейімделуге ұзақ уақыт талап етеді.

Қорытынды. Жүргізілген зерттеу нәтижелері көрсеткендей, интеллектуалды алгоритмдерді күкіртсутекті десорбциялау процесін басқаруда қолдану жоғары тиімділікті қамтамасыз етеді. Классикалық PID-регуляторлар мен дәстүрлі басқару жүйелері белгілі бір шектеулерге ие болғанымен, машиналық оқыту, нейрондық желілер және генетикалық алгоритмдер негізінде жасалған интеллектуалды әдістер процестің тиімділігін арттыруға мүмкіндік береді. Сонымен қатар, үлкен деректерді талдау әдістерін пайдалану жүйенің динамикасын нақты уақыт режимінде болжауға және оңтайландыруға мүмкіндік береді.

Болашақ зерттеулер мен даму перспективалары индустрия 4.0 технологияларымен ықпалдастыруға бағытталуы керек. Кибер-физикалық жүйелерді дамыту күкіртсутек десорбциясының интеллектуалды басқару жүйелерін жетілдіруге ықпал етеді. Жасанды интеллект пен бұлттық есептеулерді қолдану арқылы өндірістік процестердің тиімділігін арттыруға және шығындарды азайтуға болады. Интеллектуалды алгоритмдерді енгізу болашақта экологиялық және экономикалық тұрғыдан үлкен пайда әкелуі мүмкін. Осылайша, күкіртсутекті десорбциялау процесін басқаруда интеллектуалды алгоритмдерді қолдану өнеркәсіптік тиімділікті арттырудың маңызды бағыты болып табылады.

Пайдаланылған әдебиеттер тізімі:

1. Wang X., Ma H., Qi X., Gao K., Li S. Study on the distribution law of coal seam gas and hydrogen sulfide affected by abandoned oil wells // *Energies*. – 2022. – Vol. 15. – No. 9. – P. 3373–3391.
2. Banisheikholeslami A., Qaderi F. Applied machine learning to the determination of biochar hydrogen sulfide adsorption capacity // *Machine Learning*. – 2024. – Vol. 113. – No. 5. – P. 874–892.
3. Nimmanterdwong P., Changpun R., Jantboon P. Applied artificial neural network for hydrogen sulfide solubility in natural gas purification // *ACS Omega*. – 2021. – Vol. 6. – No. 50. – P. 33984–33994.

Мұнай айдаудың технологиялық процесін автоматтандыру

Намазбек Ақерке Дауренқызы

Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті,

Магистратура 1-курс

E-mail: namazbekakerke@gmail.com

Мұнай айдаудың технологиялық процесін автоматтандыру мұнай тасымалдаудың тұрақтылығын, қауіпсіздігін және тиімділігін қамтамасыз етуде шешуші рөл атқарады. Заманауи автоматтандырылған жүйелерді енгізу апаттар қаупін азайтуға, параметрлерді бақылау дәлдігін арттыруға және пайдалану шығындарын оңтайландыруға мүмкіндік береді.

Автоматтандырудың негізгі міндеттері:

а) Параметрлерді бақылау және реттеу – автоматтандырылған жүйелер мұнай ағынының қысымын, температурасын, деңгейін және жылдамдығын бақылауды қамтамасыз етеді.

б) Шығындар мен ағып кетулерді азайту – датчиктері мен интеллектуалды алгоритмдер ең кішкентай ағып кетулерді анықтауға және олардың алдын алуға мүмкіндік береді.

с) Диспетчерлеу және қашықтан басқару – орталықтандырылған бақылау үшін SCADA жүйелері мен IoT технологияларын пайдалану.

Автоматтандырылған мұнай айдау жүйесі келесі компоненттерді қамтиды:

1) Датчиктер мен өлшеу құрылғылары (қысым, температура, ағын, деңгей). Датчиктер мен өлшеу құрылғылары өнеркәсіптік процестерді бақылау және автоматтандыру үшін кеңінен қолданылады. Олар қысым, температура, ағын және деңгей сияқты параметрлерді өлшеуге мүмкіндік береді.

2) Контроллерлер және бағдарламаланатын логикалық контроллерлерді (PLC) қарастыруға болады. Контроллерлер – өнеркәсіптік процестерді басқаруға арналған құрылғылар. Олар датчиктерден ақпарат алып, тиісті атқарушы механизмдерге (сораптар, клапандар, электр қозғалтқыштары) басқару сигналдарын береді.

3) Жетектер мен жетектерді (сорғылар, ысырмалар, реттегіштер) осы қатарға қосуға болады. Өнеркәсіптік процестерді автоматтандыруда жетектер және атқарушы механизмдер маңызды рөл атқарады. Олар басқару жүйесінен командалар алып, сұйықтық, газ немесе қатты материалдардың қозғалысын басқарады.

4) Байланыс және диспетчерлік жүйелер (SCADA, бұлтты технологиялар). Өнеркәсіптік процестерді басқару және автоматтандыруда SCADA (Supervisory Control and Data Acquisition) жүйелері мен бұлтты технологиялар маңызды рөл атқарады. Олар нақты уақыттағы деректерді жинап, өңдеп, операторларға визуализация жасап, процестерді оңтайландыруға көмектеседі. Бұлтты технологиялар – деректерді қашықтан сақтауға, өңдеуге және талдауға мүмкіндік беретін заманауи технология. Өнеркәсіптік автоматтандыруда бұлттық технологиялар SCADA, IoT және жасанды интеллект (AI) шешімдерімен интеграцияланып, процестерді тиімді басқаруға көмектеседі.

Автоматтандырудың мұнай айдаудың технологиялық процесін автоматтандырудағы бірнеше артықшылықтарын атап өтуге болады. Автоматтандыру мұнай өндіру мен өңдеу процестерінің қауіпсіздігін және тиімділігін арттырады. SCADA жүйелері өндірістегі деректерді жинап, операторларға нақты уақыттағы бақылауды қамтамасыз етеді. PLC (бағдарламаланатын логикалық контроллерлер) мұнай қондырғыларын автоматты түрде басқарады. IoT датчиктері қысым, температура, ағын және деңгей көрсеткіштерін үздіксіз бақылайды. AI (жасанды интеллект) және машиналық оқыту жабдықтардың тозуын алдын ала болжайды. Қашықтан бақылау жүйелері мұнай ұңғымалары мен зауыттарды кез келген жерден басқаруға мүмкіндік береді. Жабдықтардың автоматты диагностикасы апаттық жағдайлардың алдын алады. Энергия тиімділігі автоматтандыру арқылы оңтайлы жүктемелерді басқару нәтижесінде артады. Құбыр желілеріндегі ақауларды анықтау жүйелері мұнай төгілуінің алдын алады. Бұлттық технологиялар өндірістік деректерді қауіпсіз сақтап,

өндеуге мүмкіндік береді. Өндірістік процестерді оңтайландыру арқылы шикізатты үнемдеу қамтамасыз етіледі. Робототехника қауіпті аймақтардағы техникалық қызмет көрсету жұмыстарын атқарады. Автоматтандырылған сорғы станциялары мұнай мен газды тасымалдау процесін үздіксіз жүргізеді. Қауіпсіздік жүйелері ағып кету, өрт немесе жарылыс қаупін анықтап, жедел жауап береді. Автоматты есеп беру жүйелері өндірістік көрсеткіштер туралы деректерді талдауға көмектеседі. Дрондар мен камералар мұнай платформаларында қашықтан мониторинг жүргізеді.

Big Data аналитикасы өндірістік тиімділікті арттыру үшін үлкен көлемдегі деректерді өңдейді. Киберқауіпсіздік шешімдері мұнай кәсіпорындарының ақпараттық жүйелерін қорғауға көмектеседі. Геологиялық барлау процестері автоматтандырылған деректер талдауы арқылы жетілдіріледі. Жылу және қысым балансын бақылау жүйелері жабдықтардың жұмысын тұрақтандырады. Автоматтандыру өндіріс шығындарын азайтып, мұнай саласының тиімділігін арттыруға мүмкіндік береді.

Мұнай айдау процесін автоматтандыру – қазіргі мұнай өнеркәсібінің ажырамас бөлігі. Инновациялық технологиялар қауіпсіздікті арттыруға, адам факторының әсерін азайтуға және мұнай тасымалдау шығындарын оңтайландыруға мүмкіндік береді. Автоматтандыру арқылы өндіріс процестері тұрақты бақылауда болып, жабдықтардың тозуы мен апаттық жағдайлардың алдын алу мүмкіндігі артады.

Сонымен қатар, автоматтандыру жүйелері экологиялық қауіпсіздікті қамтамасыз етуге көмектеседі. Датчиктер мен жасанды интеллект негізіндегі жүйелер мұнай төгілуін болдырмауға және қоршаған ортаға тигізетін әсерді азайтуға мүмкіндік береді. Бұлттық технологиялар мен үлкен деректерді талдау (Big Data) операторларға нақты уақыт режимінде шешім қабылдауға көмектесіп, өндіріс тиімділігін арттырады.

Болашақта мұнай айдау процестерінде жасанды интеллект, роботтандырылған жүйелер және киберқауіпсіздік шешімдері кеңінен қолданылатын болады. Автоматтандыруды одан әрі дамыту мұнай құбыры жүйелерінің тиімділігі мен сенімділігін арттырып қана қоймай, энергия тұтынуды төмендетіп, экологиялық қауіп-қатерлерді азайтады. Осылайша, цифрлық технологияларды енгізу – мұнай-газ саласын тұрақты және инновациялық дамытуға жасалған маңызды қадам.

Интеллектуалды басқару жүйелеріне кіріспе

Нұрхан Айназ Маратқызы

*Әл-Фараби атындағы Қазақ ұлттық университеті,
Ақпараттық технологиялар факультеті
E-mail: ainazmrt@mail.ru*

Қазіргі заманғы интеллектуалды басқару жүйелері деректерді өңдеу, шешім қабылдау және автоматтандырылған басқару процестерін жетілдіру мақсатында кеңінен қолданылады. Бұл жүйелер жасанды интеллект, машиналық оқыту және математикалық модельдеу әдістерін пайдаланады. Бұл жұмыста интеллектуалды басқару жүйелерінің негізгі әдістері қарастырылады: деректерді алдын ала өңдеу, логистикалық классификатор, бір айнымалы регрессорды құру, шешім ағашы негізінде классификатор құру, k-орташа әдісті пайдаланып деректерді кластерлеу және аралас гаусс модельдері.

Деректерді алдын ала өңдеу

Деректерді өңдеу кез келген интеллектуалды жүйенің ажырамас бөлігі болып табылады. Бұл кезеңде деректер жинақталып, тазаланып, олардың сапасы жақсартылады. Алдын ала өңдеу келесі қадамдардан тұрады:

- **Деректерді нормалау** – барлық айнымалыларды бірдей шкалаға келтіру.
- **Таза емес деректерді өңдеу** – жетіспейтін немесе қате мәндерді түзету немесе жою.
- **Шуылдарды жою** – деректерден қажетсіз немесе қайталанатын ақпараттарды алып тастау.

• **Ерекше мәндерді анықтау және түзету** – статистикалық әдістер арқылы аномалияларды табу.

Бұл процестер модельдердің тиімділігін арттырып, басқару шешімдерінің дәлдігін қамтамасыз етеді.

Логистикалық классификатор

Логистикалық регрессия – екі немесе одан көп класстар арасында деректерді бөлуге арналған статистикалық әдіс. Бұл модель ықтималдық негізінде шешім қабылдайды және классификация кезінде жиі қолданылады. Логистикалық классификатор төмендегідей сипатталады:

- Оңай есептелетін модель.
- Интерпретациясы қарапайым.
- Шешім қабылдау үшін ықтималдықтарды есептейді.

Логистикалық классификатор медицинада, қаржы саласында және маркетингте болжам жасау үшін кеңінен қолданылады.

Бір айнымалы регрессорды құру

Регрессиялық модельдер деректер арасындағы тәуелділікті анықтауға мүмкіндік береді. Бір айнымалы регрессор тәуелсіз айнымалының тәуелді айнымалыға әсерін сипаттайды. Бұл әдіс уақыттық қатарларды болжау, экономикалық модельдеу және ғылыми зерттеулерде пайдаланылады.

Регрессия теңдеуі: $y = ax + by = ax + b$ мұндағы aa – көлбеу коэффициенті, bb – ығысу параметрі.

Бұл модельдің қарапайымдылығы мен интерпретациясының жеңілдігі оны кеңінен қолдануға мүмкіндік береді.

Шешім ағашы негізінде классификатор құру

Шешім ағаштары классификация мен регрессияда қолданылатын танымал әдістердің бірі. Бұл әдістің негізгі ерекшеліктері:

- **Иерархиялық құрылым** – мәліметтерді сұрыптау және анализ жасау үшін тармақталған құрылым қолданылады.
- **Қарапайым интерпретация** – ережелер арқылы шешім қабылдау жүзеге асырылады.

• **Автоматты түрде маңызды айнымалыларды таңдау** – қажетсіз деректерді сүзу механизмі бар.

Шешім ағаштары медицинада диагноз қою, қаржы саласында несие беру шешімдерін қабылдау және басқа да басқару процестерінде кеңінен қолданылады.

К-орташа әдісті пайдаланып деректерді кластерлеу

К-орташа кластерлеу – деректерді бірнеше топқа бөлуге арналған әдіс. Бұл әдіс келесі кезеңдерден тұрады:

1. Бастапқы кк орталықтарды кездейсоқ таңдау.
2. Әр нүктені ең жақын кластерге жатқызу.
3. Кластер орталықтарын қайта есептеу.
4. Бұл процесті критерийлер орындалғанша қайталау.

Бұл әдіс маркетингте тұтынушыларды сегментациялау, медицинада ауруларды топтау және өндірісте сапаны бақылау үшін қолданылады.

Аралас гаусс модельдері

Аралас гаусс модельдері (GMM) ықтималдық модельдері болып табылады және деректерді күрделі үлгілер бойынша бөлуге мүмкіндік береді. Бұл әдіс әр түрлі топтарды гаусстық бөліністердің жиынтығы ретінде қарастырады. GMM негізгі ерекшеліктері:

- Күрделі деректер құрылымын жақсы сипаттайды.
- Топтарға бөлу процесінде ықтималдықты пайдаланады.
- Динамикалық жүйелерде деректерді талдауға мүмкіндік береді.

GMM әдісі биоинформатикада, дауыс тану жүйелерінде және қаржы талдауында қолданылады.

Қорытынды

Интеллектуалды басқару жүйелері шешім қабылдаудың автоматтандырылған әдістерін дамытуға мүмкіндік береді. Деректерді алдын ала өңдеу жүйенің тиімділігін арттырады, ал логистикалық классификатор мен шешім ағаштары күрделі мәселелерді шешуге мүмкіндік береді. Регрессиялық модельдер болжау әдістерінде қолданылса, кластерлеу әдістері деректерді тиімді түрде топтастыруға көмектеседі. Аралас гаусс модельдері ықтималдық талдауға негізделген күрделі жүйелерде қолданылады.

Бұл әдістердің барлығы деректерге негізделген шешім қабылдауды жетілдіруге және интеллектуалды басқару жүйелерінің әлеуетін арттыруға бағытталған.

Разработка системы визуализации данных для мониторинга производственных процессов с использованием Grafana и Prometheus

Ныгыманов Бекболат Асхатович

*Әл-Фараби атындағы Қазақ ұлттық университеті,
E-mail: ghostik792@gmail.com*

Мониторинг производственных процессов представляет собой важный аспект современного промышленного производства, обеспечивая контроль параметров оборудования и среды, таких как температура, давление или энергопотребление. В условиях цифровизации и реализации принципов Индустрии 4.0 данные становятся основой для управления производством, позволяя оптимизировать работу систем, предотвращать сбои и повышать эффективность. Значение мониторинга возрастает в контексте автоматизации, где своевременный доступ к информации о состоянии процессов необходим для принятия обоснованных решений. Данная работа посвящена исследованию возможностей создания прототипа системы визуализации данных для производственного мониторинга с использованием инструментов с открытым исходным кодом — Grafana и Prometheus.

Основной целью проекта является разработка концепции системы, которая могла бы сочетать простоту реализации с потенциальной применимостью к реальным производственным задачам. Предполагается, что такой подход позволит создать доступное решение, подходящее для использования в рамках ограниченных ресурсов, характерных для образовательных исследований. Выбор Grafana и Prometheus обусловлен их широким распространением в области мониторинга и визуализации. Prometheus предлагает надёжный инструментарий для хранения данных, собранных с различных источников, а Grafana обеспечивает гибкость в создании визуальных интерфейсов, что делает их перспективной основой для проектирования системы, способной отвечать потребностям производственного контроля.

Теоретические аспекты мониторинга включают сбор данных, их структурированное хранение и последующую обработку для анализа. В отличие от традиционного мониторинга с непрерывным потоком информации, в данном исследовании рассматривается детерминированный подход, при котором данные собираются с заданной периодичностью, например, раз в час. Такой метод позволяет снизить сложность системы и адаптировать её к ситуациям, где требуется регулярная, но не постоянная проверка параметров. Подобная схема применима в промышленности — например, для оценки состояния оборудования в металлургии или химическом производстве. Визуализация данных рассматривается как способ преобразования числовой информации в наглядные формы, такие как графики для наблюдения за изменениями, таблицы для текущих показателей и индикаторы для выделения критических состояний.

Проектирование системы предполагает определение её ключевых функций и структуры. Планируется, что прототип будет способен собирать данные от нескольких источников, имитирующих производственные параметры, сохранять их за определённый период и предоставлять пользователю интерфейс для их анализа. В отсутствие реального оборудования сбор данных может осуществляться программно, отражая типичные сценарии производства. Ожидается, что система будет простой в настройке, оперативной в обработке информации и пригодной для работы на стандартном персональном компьютере. Архитектура проекта предполагает размещение всех компонентов — источника данных, системы хранения и визуализации — на одном устройстве, что минимизирует зависимости и упрощает процесс разработки.

Визуальный интерфейс системы планируется организовать таким образом, чтобы он обеспечивал удобство и информативность. Он может включать элементы для отображения изменений параметров во времени, обзора текущих значений и специально разработанный

компонент, отличающий проект от типичных решений. Такой подход позволит подчеркнуть оригинальность системы, сохраняя её функциональность. Периодический сбор данных предполагает меньшую нагрузку на ресурсы по сравнению с непрерывным мониторингом, что делает систему перспективной для реализации в условиях ограниченных возможностей, например, в образовательных целях или на небольших предприятиях.

Предлагаемая система могла бы стать примером применения Grafana и Prometheus для задач мониторинга производственных процессов, демонстрируя их потенциал в создании простых и эффективных решений. Оригинальность проекта может быть достигнута за счёт адаптации визуальных элементов под конкретные задачи контроля. В дальнейшем возможно рассмотрение вариантов интеграции с реальными источниками данных через современные технологии передачи информации или расширения архитектуры для более масштабного применения. Такой подход открывает перспективы для использования системы как в образовательной практике, так и в промышленности, где требуется доступное и надёжное решение для анализа производственных процессов.

Ақылды дәрі-дәрмек шкафы: сақтау және қолжетімділікті басқарудың инновациялары

Оразай Ә.Н.

Әл-Фараби атындағы Қазақ Ұлттық университеті, 4 курс бакалавриаты

Аннотация Қазіргі уақытта дәрі-дәрмектерді дұрыс сақтау олардың тиімділігі мен қауіпсіздігін қамтамасыз етуде маңызды рөл атқарады. IoT технологияларымен жабдықталған ақылды шкафтар сақтау жағдайын автоматты түрде бақылауға және дәрі-дәрмектерге қолжетімділікті басқаруға мүмкіндік береді. Бұл мақалада осындай жүйелердің артықшылықтары, халықаралық тәжірибе және Қазақстанда енгізу перспективалары қарастырылады.

Кіріспе Дәрі-дәрмектерді сақтау белгілі бір шарттарды сақтауды қажет етеді, мысалы, температура мен ылғалдылықты бақылау, рұқсатсыз қолжетімділіктен қорғау. Кәдімгі сақтау жүйелері бұл талаптарды әрдайым қамтамасыз ете алмайды, нәтижесінде дәрілердің сапасы нашарлауы мүмкін. Ақылды шкафтар сенсорлық бақылау жүйелері және QR-код немесе биометрия арқылы кіруді басқару арқылы қауіпсіздік деңгейін арттырады.

Негізгі мүмкіндіктер

- **Сақтау шарттарын бақылау:** IoT датчиктері температура мен ылғалдылықты бақылап, аномалиялар туралы ескертулер жібереді.
- **Автоматтандырылған есеп:** RFID белгілері мен штрих-кодтар дәрілерді дәл есептеуге мүмкіндік береді.
- **Қолжетімділікті басқару:** QR-кодтар, биометриялық сәйкестендіру және медициналық дерекқормен интеграция тек уәкілетті медициналық қызметкерлердің дәрілерді алуына мүмкіндік береді.

Аналитика және есеп беру: Дәрілік заттардың шығыны мен жарамдылық мерзімі бойынша есептер автоматты түрде жасалады.

Халықаралық тәжірибе

- **Pyxis MedStation (АҚШ, Еуропа)** – биометриялық қолжетімділікпен басқарылатын сақтау жүйесі.
- **Omnicell (Канада, Ұлыбритания)** – медициналық дерекқормен біріктірілген автоматтандырылған тарату.
- **BD Rowa (Германия, Франция)** – RFID-сканерлері бар толық автоматтандырылған шкафтар.

Қазақстанда енгізу перспективалары Ақылды шкафтарды медициналық мекемелерге енгізу:

- Дәрі-дәрмектердің шығынын бақылауды жақсартады;
- Заңсыз қолжетімділікті болдырмайды;
- Дәрі-дәрмектерді есепке алу мен қажеттілікті болжауды автоматтандырады.

Қорытынды Ақылды дәрі-дәрмек шкафтары медициналық мекемелерде дәрі-дәрмектерді қауіпсіз және тиімді сақтауға арналған перспективалы шешім болып табылады. Қазақстанда осындай жүйелерді енгізу денсаулық сақтау саласын оңтайландырып, халықаралық стандарттарға жақындауға мүмкіндік береді.

Пайдаланылған әдебиеттер тізімі:

1. WHO. Guidelines on Good Storage Practices for Pharmaceuticals, 2020.
2. USP. General Chapter <1079> Good Storage and Distribution Practices for Drug Products, 2021.
3. Pyxis MedStation. Automated Medication Dispensing Solutions.
4. Omnicell. Medication and Supply Management Solutions.
5. BD Rowa Smart Storage Solutions. Automated Pharmacy Storage Systems.
6. ҚР Денсаулық сақтау министрлігі. Дәрілік заттарды сақтау ережелері, 2022.

7. Әл-Фараби атындағы ҚазҰУ ғылыми еңбектері. Ақпараттық технологиялар зерттеулері.

Arduino негізіндегі интеллектуалды сұрыптау жүйесін әзірлеу

Орманбекова А.А., Ильясов Е.С., Исмуханбетов Б.Т.

Ғылыми жетекші: PhD - Орманбекова А.А.

Техника ғылымдарының магистры – Ильясов Е.С.

Алматы технологиялық университеті

e-mail: ain_25@mail.ru

Қазіргі әлемде автоматтандыру өндірістік процестердің тиімділігін арттыруда маңызды рөл атқарады. Автоматтандырудың маңызды аспектілерінің бірі – объектілерді әртүрлі белгілер бойынша сұрыптау, мысалы, түсіне қарай. Arduino сияқты микроконтроллерлер негізінде интеллектуалды сұрыптау жүйелерін әзірлеу өнеркәсіп, логистика және қалдықтарды қайта өңдеу сияқты көптеген салалар үшін икемді және тиімді шешімдер жасауға мүмкіндік береді. Қазіргі заманғы сенсорлық технологиялар мен деректерді өңдеу әдістері нақты уақыт режимінде объектілерді автоматты түрде анықтайтын және сұрыптайтын шағын әрі экономикалық тиімді құрылғыларды жасауға мүмкіндік береді.

Бұл жұмыста TCS230/TCS3200 түс сенсоры, сервоқозғалтқыш және LCD дисплейін қолдана отырып, Arduino негізінде интеллектуалды сұрыптау жүйесін әзірлеу қарастырылады. Жүйе объектілердің түсін талдайды, нәтижелерді экранда көрсетеді және сервоқозғалтқышты іске қосу арқылы олардың сұрыпталуын қамтамасыз етеді. Бұл тәсіл автоматтандырылған өндірістік желілерде, сапаны бақылау жүйелерінде, ауыл шаруашылығында және қоқысты қайта өңдеуде қолданыс табуы мүмкін. Осы жүйенің басты артықшылығы – іске асырудың қарапайымдылығы, төмен құны және деректерді өңдеудің басқа интеллектуалды алгоритмдері мен машиналық оқыту әдістерімен одан әрі жетілдіру мүмкіндігі.

Аппараттық бөлігі

Жүйе келесі компоненттерден тұрады:

- **TCS230/TCS3200 түс сенсоры** — объектінің түс жиілігін анықтайды.
- **LCD (I2C) дисплей** — өлшенген жиілікті және анықталған түсті көрсетеді.
- **Сервоқозғалтқыш** — анықталған түске байланысты белгілі бір бұрышқа бұрылады.

Жұмыс принципі

1. **TCS230/TCS3200 сенсоры** объектінің түсін талдайды және оны сәйкес жиілік сигналына түрлендіреді.

2. **Arduino жиілік деректерін алады**, оларды өңдейді және белгіленген шекті мәндер негізінде түсті анықтайды.

3. **LCD дисплейде** өлшенген жиілік пен анықталған түс көрсетіледі.

4. **Сервоқозғалтқыш** анықталған түске байланысты келесі әрекеттерді орындайды:

- Егер жиілік қара түске сәйкес келсе, сервоқозғалтқыш белгілі бір қалыпқа ауысады.
- Егер жиілік ақ түске сәйкес келсе, сервоқозғалтқыш басқа қалыпқа жылжиды.
- Басқа түстер үшін сервоқозғалтқыш алдын ала орнатылған диапазонға сәйкес реттеледі.

Бағдарламаның коды

Бағдарлама келесі негізгі блоктардан тұрады:

Кітапханаларды қосу:

```
#include <Wire.h>  
#include <LiquidCrystal_I2C.h>  
#include <Servo.h>
```

Wire.h — I2C байланысы үшін.

LiquidCrystal_I2C.h — LCD дисплейді басқару үшін.

Servo.h — сервоқозғалтқышты басқару үшін.

Айнымалыларды анықтау және объектілерді құру:

```
#define S0 4  
#define S1 5
```

```
#define S2 6
#define S3 7
#define sensorOut 8
#define SERVO_PIN 9
LiquidCrystal_I2C lcd(0x27, 16, 2);
Servo myServo;
int threshold = 175;
```

Сенсор мен сервоқозғалтқыштың басқару пиндері анықталады.

LCD дисплей және сервоқозғалтқыш объектілері құрылады.

Түстерді ажырату үшін шекті мән орнатылады.

setup() функциясы (жүйені инициализациялау)

getFrequency() функциясы (жиілікті өлшеу)

Негізгі loop() циклы

Arduino негізіндегі интеллектуалды сұрыптау жүйесі объектілердің түсін автоматты түрде анықтау мен сервоқозғалтқышты басқаруда тиімділігі мен сенімділігін көрсетеді. TCS230/TCS3200 түс сенсорын Arduino микроконтроллері арқылы пайдалану нақты уақыт режимінде жұмыс істейтін қарапайым, бірақ функционалды жүйені жасауға мүмкіндік береді. Бұл технология қоқысты сұрыптау, өнімнің сапасын бақылау, сондай-ақ білім беру және ғылыми зерттеулерде табысты қолданыла алады.

Ұсынылған жүйенің негізгі артықшылықтары:

– **Компоненттердің төмен құны**, бұл оны кең ауқымды пайдаланушыларға қолжетімді етеді.

– **Икемділік пен масштабталу** — жүйені қосымша сенсорлармен немесе деректерді өңдеу алгоритмдерімен жетілдіру мүмкіндігі.

– **Іске асырудың қарапайымдылығы** — код пен аппараттық бөліктің құрылымы жүйені нақты міндеттерге оңай бейімдеуге мүмкіндік береді.

– **Автономды жұмыс** — калибрлеуден кейін жүйе оператордың қатысуынсыз объектілерді автоматты түрде сұрыптай алады.

Айқын артықшылықтарына қарамастан, жүйенің кейбір шектеулері бар:

– **Сыртқы жағдайларға сезімталдық** — жарықтандыру түсті танудың дәлдігіне әсер етуі мүмкін, сондықтан қосымша калибрлеуді қажет етеді.

– **Түстер ауқымының шектеулігі** — қазіргі нұсқа тек негізгі түстерді анықтайды, бірақ кеңейтілген түстер спектрімен жұмыс істеу үшін жетілдірілуі мүмкін.

– **Өңдеу жылдамдығы** — деректерді жаңарту жиілігі сенсор мен Arduino жылдамдығымен шектелген, бұл жоғары жылдамдықтағы өндірістік желілер үшін маңызды болуы мүмкін.

Болашақта жүйені ESP32 сияқты қуатты микроконтроллерді енгізу арқылы жақсартуға болады, сондай-ақ түс танудың дәлдігін арттыру үшін машиналық оқыту алгоритмдерін қосуға болады. Бейімделген калибрлеу механизмі жарықтандыру сияқты сыртқы факторлардың әсерін азайтуға көмектеседі, ал интернет-сервистермен интеграциялау қашықтан мониторинг пен басқаруды қамтамасыз етеді.

Жалпы, әзірленген жүйе сұрыптау процестерін автоматтандыру үшін перспективалы шешім болып табылады және нақты өндірістік жағдайларда сәтті енгізілуі мүмкін.

Пайдаланылған әдебиеттер тізімі:

1. TCS230/TCS3200 түсті анықтау сенсорының техникалық сипаттамасы. [Онлайн ресурс] – Қолжетімді: <https://www.ti.com>.
2. Arduino микроконтроллерімен жұмыс істеу: оқулық. – Алматы: Қазақ университеті, 2021.
3. Давыдов В. В. Микроконтроллеры Arduino: основы, программирование, проекты. –

Москва: ДМК, 2020.

4. Кузнецов С. В. Применение микроконтроллеров в автоматизированных системах. – Москва: Техносфера, 2021.

АВТОМАТИЗАЦИЯ ТЕХНОЛОГИЧЕСКИХ ПРОЦЕССОВ НАСОСНОЙ СТАНЦИИ

Оспан А.Ж.,

магистрант гр.7М07101

*КАЗАХСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ТЕХНИЧЕСКИЙ
УНИВЕРСИТЕТ имени К.И.САТПАЕВА, г. Алматы*

Аннотация. В современных условиях отсутствие автоматизации технологических процессов насосных станций и управление ими без применения современных методов регулирования может существенно снижать эффективность их работы. Разработка и внедрение автоматизированной системы управления насосной станцией позволит повысить надежность функционирования оборудования, оптимизировать энергопотребление и минимизировать эксплуатационные затраты. Кроме того, моделирование работы станции в специализированных программных средах, таких как MATLAB/Simulink, позволит анализировать различные режимы работы системы и обучать персонал эффективному управлению процессами.

Ключевые слова. Автоматизация, насосная станция, оптимальное управление, моделирование, энергосбережение.

На сегодняшний день используются различные методы автоматизации насосных станций, включая программируемые логические контроллеры (PLC), системы SCADA и интеллектуальные алгоритмы управления. Большинство современных систем управления обеспечивают мониторинг работы оборудования, анализ данных в реальном времени и автоматическое регулирование параметров. Однако остаются нерешенные задачи, связанные с оптимизацией энергопотребления, прогнозированием аварийных ситуаций и адаптацией к изменяющимся условиям эксплуатации. [1-2].

Насосные станции представляют собой комплекс инженерных сооружений, обеспечивающих транспортировку жидкостей с заданными параметрами давления и расхода. Ключевыми характеристиками работы насосных станций являются:

- Производительность (расход жидкости через систему);
- Давление на входе и выходе;
- Уровень жидкости в резервуарах;
- Энергетические затраты на перекачку;
- Надежность и долговечность оборудования.

Оперативное управление данными параметрами позволяет предотвратить аварийные ситуации, снизить эксплуатационные расходы и повысить ресурс насосного оборудования.

Насосные станции играют важную роль в различных отраслях, обеспечивая бесперебойное снабжение жидкостью промышленных объектов, коммунального хозяйства, сельскохозяйственных предприятий и транспортных систем. Их основная функция заключается в перекачивании жидкости из одного резервуара в другой с поддержанием необходимых параметров давления и расхода. Технологический процесс работы насосной станции включает несколько ключевых этапов, начиная с забора жидкости из источника, будь то скважина, водоем или резервуар, и заканчивая ее транспортировкой к точкам потребления.

Изучая тему магистерской диссертации нами было выявлено, что для моделирования автоматизированного процесса работы насосной станции наилучшим решением является использование специализированных программных сред, таких как MATLAB/Simulink. Данные инструменты позволяют создавать математические модели насосных станций, проводить анализ их работы в различных режимах и оптимизировать параметры управления. С их помощью можно исследовать влияние изменения входных параметров, таких как напор, расход и уровень жидкости, на работу системы, а также тестировать алгоритмы управления без необходимости проведения экспериментов на реальном оборудовании. Например, моделирование перекачки жидкости при изменении входного давления с 0,5 до 1,2 МПа

позволяет определить оптимальные параметры работы насоса и выявить возможные перегрузки системы [3].

Одним из ключевых аспектов автоматизированного управления является использование программируемых логических контроллеров (PLC) и SCADA-систем, которые обеспечивают сбор, обработку и визуализацию данных о работе насосной станции. Внедрение таких решений позволяет оперативно реагировать на изменения условий эксплуатации, автоматически регулировать параметры насосов и минимизировать влияние человеческого фактора.

Для оптимизации энергопотребления насосной станции используются частотные преобразователи, позволяющие плавно регулировать скорость работы насосов в зависимости от текущего расхода и давления. Это снижает износ оборудования, уменьшает количество аварийных остановок и обеспечивает значительную экономию электроэнергии. Кроме того, современные интеллектуальные алгоритмы, основанные на методах машинного обучения и предиктивного анализа, позволяют прогнозировать возможные неисправности и своевременно принимать меры по их предотвращению [4-5].

Таким образом, автоматизация насосных станций является не только важным направлением развития современных инженерных систем, но и необходимым условием для повышения эффективности, надежности и экономичности работы оборудования. Использование современных технологий управления, моделирования и анализа позволяет оптимизировать процессы перекачки жидкостей, минимизировать эксплуатационные расходы и повысить устойчивость систем к внешним воздействиям.

Список использованной литературы:

1. Петров И.В. Автоматизация насосных станций: современные подходы и решения. М.: Техносфера, 2020.
2. Иванов А.А., Смирнов Б.В. Энергосбережение в системах водоснабжения. СПб.: Политехника, 2019.
3. MATLAB/Simulink для инженерных задач: руководство пользователя. MathWorks, 2021.
4. Сидоров К.М. Честное энергосбережение: снижение затрат на эксплуатацию насосного оборудования. Новосибирск: НГТУ, 2018.
5. Brown T., Johnson M. Predictive Maintenance for Pumping Systems: Case Studies and Strategies. Springer, 2022

ЖОБАЛАРДЫ БАСҚАРУ ЖӘНЕ КОМАНДАЛЫҚ ЖҰМЫСҚА АРНАЛҒАН КЕШЕНДІ ШЕШІМ

Раева Алина Арманқызы, Амирханова Гүлшат Аманжоловна

Әл-Фараби атындағы Қазақ Ұлттық университеті, 3 курс бакалавриаты

Аннотация: Мақалада цифрлық трансформация ұйымдардың бәсекеге қабілеттілігінің негізгі факторы болды. Жобаларды басқаруда жасанды интеллект, блокчейн, IoT, бұлттық технологиялар маңызды рөл атқарады. Дәстүрлі әдістерден Agile, Scrum, Kanban сияқты икемді модельдерге көшу үрдісі байқалады. Wekan, Rocket.Chat, Nextcloud сияқты open-source құралдары жобаларды басқаруды жетілдіріп, шығындарды азайтады. Цифрлық құралдарды кешенді қолдану – жобаларды тиімді басқарудың негізгі шарты.

Кілттік сөздер: Wekan, Rocket.Chat, Jitsi Meet, Grafana, деректерді визуализациялау, деректер қауіпсіздігі, канбан-тақталар, бұлттық сақтау, байланыс.

Жеделдей түскен цифрлық трансформация жағдайында жобаларды басқару және командалардың тиімді өзара әрекеттестігі қазіргі ұйымдар үшін ең маңызды міндеттерге айналуға. Әртүрлі құралдарды жеке-жеке қолдану, процестердің төмен ашықтығы, деректер қауіпсіздігі мәселелері және мониторингтің болмауы оптималды өнімділікке қол жеткізуге қосымша кедергілер жасайды [1].

Заманауи IT-инфрақұрылымды дамыту үрдістерін талдау нәтижелері бойынша, ашық бастапқы кодты шешімдерге сұраныстың өсуі байқалады [2]. Осы құралдар бірыңғай экожүйеге интеграцияланған кезде компанияларға міндеттерді басқаруды, байланыс, деректерді сақтау, қолжетімділікті басқару және аналитикалық мониторингті жақсартуға көмектеседі. Martínez-Arias мен García-Peñalvo [3] зерттеулерінде көрсетілгендей, мұндай интеграция командалық жұмыстың тиімділігін орташа есеппен 27%-ға арттыруға мүмкіндік береді.

Wekan канбан-тақталары мен Rocket.Chat мессенджерін біріктіру арқылы міндеттердің орындалуы туралы хабарламаларды автоматтандыруға және қызметкерлер арасындағы коммуникацияны оңтайландыруға болады. Al-Samarrāie мен Saeed [4] атап өткендей, мұндай автоматтандыру жобалар мен тапсырмаларды орындау мерзімін 15-20%-ға қысқартады.

Кешенді шешім деректердің таралу қаупін азайтуға, процестердің ашықтығын арттыруға және команда жұмысының максималды тиімділігін қамтамасыз етуге бағытталған. Li және басқалар [5] зерттеулері көрсеткендей, интеграцияланған құралдар жүйесіне бақылау мен мониторинг енгізу арқылы қауіпсіздік бұзылуларының ықтималдығын 40%-дан астамға төмендетуге болады.

Grafana сияқты мониторинг құралдарын енгізу басшылыққа нақты уақыт режимінде жобалардың барысын бақылауға және талдауға мүмкіндік береді, бұл «Ассошиэйтед Пресс» агенттігінің зерттеуі бойынша стратегиялық шешімдер қабылдау жылдамдығын 30%-ға арттырады [6].

Толықтырылған шындық (AR) технологияларын енгізу перспективалары

Қорытындылай келе, кәсіпорынның цифрлық моделін визуализациялау үшін толықтырылған шындық модулін құру — әртүрлі технологиялық стратегиялардың тоғысуын және жеке өндірістік процестерге байланысты бірегей мүмкіндіктерді ескеруді талап ететін күрделі міндет екенін мойындау маңызды [7].

Пайдаланылған әдебиеттер тізімі:

1. Schwer, K., & Hitz, C. (2022). Digital transformation challenges in project management: A systematic literature review. *Project Management Journal*, 53(1), 66-82.
2. Kumar, S., Ranjan, P., & Somani, G. (2023). Open Source solutions in enterprise IT infrastructure: Trends and adoption patterns. *Information Systems Management*, 40(1), 53-68.

3. Martínez-Arias, M., & García-Peñalvo, F. J. (2024). Impact of tool integration on team effectiveness: An empirical study. *Information and Software Technology*, 159, 107157.
4. Al-Samarraie, H., & Saeed, N. (2021). A systematic review of cloud-based tools for collaborative project management in virtual teams. *Journal of Information Technology Management*, 32(3), 23-41.
5. Li, X., Zhang, T., Wang, B., & Kumar, A. (2022). Integrated security frameworks for collaborative project management tools. *International Journal of Information Security*, 21(3), 415-432.
6. Johnson, R., & Wilson, T. (2024). Real-time project monitoring impact on strategic decision making. *Harvard Business Review*, 102(2), 78-89.
7. Zhang, R., & Wu, S. (2022). Augmented reality for industrial digital twins: Challenges and opportunities. *IEEE Transactions on Industrial Informatics*, 18(7), 4538-4547.

Интеллектуальная система управления установкой каталитического риформинга

Сақтаған Арман Алмасбекұлы

КазННТУ им. К.И.Сатпаева

Магистрант 1 курса

msaryx1337@gmail.com

Введение

Каталитический риформинг является важным процессом в нефтепереработке, обеспечивающим получение высокооктановых компонентов бензина и ароматических углеводородов. Современные установки риформинга требуют высокой степени автоматизации и интеллектуального управления для обеспечения стабильности процесса, повышения эффективности и снижения влияния человеческого фактора. Внедрение умных технологий, таких как машинное обучение и прогнозирующие алгоритмы, позволяет значительно улучшить управление процессом.

Актуальность

Развитие интеллектуальных систем управления (ИСУ) играет ключевую роль в обеспечении стабильности параметров процесса каталитического риформинга. Высокая сложность химических реакций, чувствительность к изменениям температуры, давления и состава сырья требуют применения передовых методов автоматического управления. Использование ИСУ, основанных на анализе больших данных, адаптивном управлении и прогнозирующих моделях, позволяет оптимизировать процесс, снизить энергозатраты и повысить выход целевых продуктов.

Основная часть

1. Описание процесса каталитического риформинга

Каталитический риформинг представляет собой процесс превращения нефтяных фракций нефти в высокооктановые компоненты путем ароматизации, изомеризации и дегидрирования углеводородов. Процесс протекает при высоких температурах (480-520°C) и давлениях (0,3–1,5 МПа) в присутствии катализаторов на основе платины и других металлов.

Основные параметры процесса:

- Температура реакционной зоны: $T=480-520$ °C;
- Давление: $P=0,3-1,5$ МПа;
- Объемная скорость подачи сырья: $V=1-3$ ч⁻¹;
- Катализатор: платина/олово на алюмооксидной основе.

2. Интеллектуальная система управления

Интеллектуальная система управления включает в себя:

- Прогнозирование параметров процесса с помощью машинного обучения;
- Оптимизацию подачи сырья и водорода на основе нейросетевых алгоритмов;
- Контроль давления и температуры с учетом адаптивных регуляторов;
- Самообучающиеся модели коррекции режима работы катализатора.

Для прогнозирования параметров используется метод нейронных сетей, где входные параметры $X = \{x_1, x_2, \dots, x_n\}$ преобразуются в выходные значения Y (например, оптимальное давление или температура для объектов на установке риформинга) через многослойную сеть:

$$Y = f(WX + b) \quad (1)$$

где:

- W – матрица весов нейросети,
- b – вектор смещения,
- $f(WX+b)$ – активационная функция, которая добавляет нелинейность модели (например, ReLU, сигмоидная или тангенс-гиперболическая функция).

Для температурного регулирования применяется адаптивный ПИД-регулятор с изменяемыми коэффициентами на основе предсказательной модели:

$$U(t) = K_p(t)e(t) + K_i(t) \int e(t)dt + K_d(t) \frac{de(t)}{dt} \quad (2)$$

где:

- $K_p(t)$ – адаптивный пропорциональный коэффициент, изменяющийся в зависимости от текущего отклонения системы,

- $K_i(t)$ – адаптивный интегральный коэффициент, компенсирующий накопленные ошибки,

- $K_d(t)$ – адаптивный дифференциальный коэффициент, предсказывающий динамику изменений ошибки.

3. Примеры реализации ИСУ

Современные установки риформинга используют распределенные системы управления (DCS) с элементами искусственного интеллекта. Прогнозирующие модели, построенные на основе машинного обучения, позволяют корректировать параметры процесса в реальном времени. Одним из примеров является применение глубинных нейросетей для предсказания выхода продукта и адаптации рабочих параметров. Использование нейронных сетей, обученных на исторических данных установки, позволяет выявлять оптимальные режимы работы без необходимости ручного вмешательства оператора.

Выводы

Интеллектуальные системы управления значительно повышают стабильность и эффективность процесса каталитического риформинга. Внедрение машинного обучения и прогнозирующих алгоритмов позволяет минимизировать потери сырья, оптимизировать режимы работы оборудования и обеспечивать высокое качество продукции. Дальнейшее развитие ИСУ связано с интеграцией технологий искусственного интеллекта и автономных систем принятия решений.

Список использованной литературы:

1 Лаврененко В. Н. Каталитический риформинг и гидрообработка углеводородных сырьевых материалов. – Санкт-Петербург, 2007. – 254 с.

2 Попов А. К. Элементы теории автоматического управления. – М., 2010. – 208 с.

3 Паршаков С.И. Основы управления техническими процессами и системами: учебное пособие / М.В.Ерпалов. – Екатеринбург: Издательство Урал. ун-та, 2017. – 148 с.

4 Бельков Ю.Н., Файрузов Д.Х., Кнеллер Д.В., Торгашов А. Ю. Система усовершенствованного управления установкой первичной переработки нефти: создание, внедрение, сопровождение // Автоматизация в промышленности. 2013. – С. 3–1

Интеллектуальное речевое распознавание команд для удаленного управления распашными воротами.

Самигуллаев Д.С.

Казахский национальный университет им. аль-Фараби, студент 4 курса бакалавра
danyalsamigullaev@mail.ru

Интеллектуальное речевое распознавание команд актуальная и развивающиеся тема, внедряется во все современные системы умного дома (управление освещением, отоплением, воротами и т.д),

при голосовом управлении мультимедией и навигацией в автомобиле,

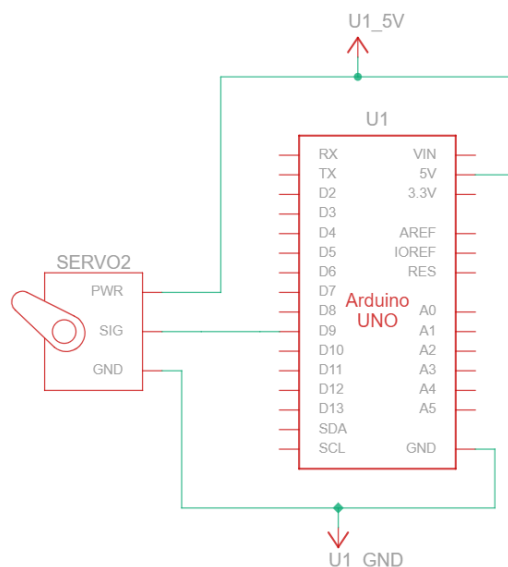
управление роботами с помощью голосовых команд, чат боты, автоматизированные колл-центры и тому подобных примеров применения можно привести множество. В эпоху "умных домов" и IoT (**Internet of Things**) растёт спрос на бесконтактное управление устройствами.

В частности мой дипломный проект посвящен разработке интеллектуального речевого распознавания команд для удаленного управления распашными воротами. Основное внимание уделяется использованию технологий машинного обучения и обработки естественного языка для повышения точности распознавания голосовых команд. Ожидается, что система обеспечит удобство эксплуатации, повысит уровень безопасности и сократит необходимость в физических устройствах управления. Ручное открытие ворот неудобно, особенно в холодную погоду или при занятых руках (например, при въезде на автостоянку).

Система интеллектуального распознавания речевых команд для удаленного управления распашными воротами:

1. Микроконтроллер или мини-ПК (ESP32, Raspberry Pi, Arduino с голосовым модулем)
2. Модуль распознавания речи (Google Speech-to-Text API, Vosk, PocketSphinx)
3. Беспроводной интерфейс связи (Wi-Fi, Bluetooth, GSM)
4. Приводные механизмы ворот (сервоприводы, мотор-редукторы, гидравлические приводы)
5. Безопасность и контроль доступа (PIN-коды, голосовая авторизация, мобильное приложение)

Алгоритм работы: Пользователь произносит команду (например, "Открыть ворота"). Модуль распознавания речи обрабатывает аудиосигнал и преобразует его в текст. Алгоритм обработки команд сверяет текст с заданными командами. Контроллер передает сигнал на моторы ворот, открывая или закрывая их.



В данном рисунке приведена блок-схема упрощенная версия этой системы с МК Arduino UNO и сервоприводом.

Актуальность и преимущества:

Голосовое управление упрощает доступ, исключает необходимость носить брелоки или нажимать кнопки. Позволяет управлять воротами удалённо (например, с помощью смартфона через интернет). Люди с ограниченными возможностями (например, с нарушением зрения или подвижности) могут использовать голос вместо физических кнопок. Wi-Fi, Bluetooth, 4G/5G позволяют интегрировать голосовые команды в облачные сервисы, управлять. Интеллектуальные системы могут включать аутентификацию по голосу, что защищает от несанкционированного доступа. Можно использовать AI-фильтрацию, чтобы система реагировала только на владельца.

Новизна темы

Классические системы используют простое распознавание ключевых слов (например, "открыть ворота"). Новые решения включают нейросетевые модели, способные понимать разные формулировки (например, "распахни ворота", "пусть откроются"). Возможность адаптации системы к голосу владельца (исключение ложных срабатываний). Можно добавить фильтрацию шумов, что позволит работать даже в шумных условиях (например, на улице). Большинство голосовых помощников (Siri, Google Assistant) требуют интернет-соединения. Использование офлайн-моделей (Vosk, PocketSphinx) позволяет управлять воротами даже без доступа к сети. Интеграция с IoT и умными домами то есть ворота могут взаимодействовать с "умными" датчиками, например: Автоопределение владельца (например, голос + геолокация) Автоматическое закрытие через датчики движения или распознавание номерных знаков Систему можно адаптировать под разные языки, добавить управление через жесты, мобильное приложение или распознавание лиц.

Список использованной литературы:

1. Журавлев А. И. "Алгоритмы машинного обучения в системах голосового управления" – СПб.: Питер, 2021.
2. Jurafsky D., Martin J. "Speech and Language Processing" – Pearson, 2021.
3. Бахметьев Н. С. "Применение нейросетей в голосовых интерфейсах управления" – Изд. дом МГТУ, 2019.
4. Кулаков В. Ю. "Распознавание команд с использованием нейронных сетей" – Компьютерные исследования и моделирование, 2022.

Смарт технологиялардың денсаулық сақтау жүйесіндегі рөлі және олардың тиімділігі

Сарсембаева Т.С., Өскенбаева А.А.

Әл-Фараби атындағы Қазақ Ұлттық университеті, Алматы, Қазақстан

Аннотация

Бұл зерттеу смарт технологиялардың денсаулық сақтау жүйесіндегі рөлін және олардың тиімділігін қарастырады. Смарт құрылғылар, оның ішінде смарт сағаттар, фитнес-трекерлер, глюкометрлер және басқа да денсаулықты бақылау құралдары пациенттердің жағдайын нақты уақыт режимінде бақылауға, аурулардың алдын алуға және емдеу үдерісін жетілдіруге мүмкіндік береді. Зерттеу нәтижелері смарт құрылғылардың тиімділігін арттырып, медициналық қызмет көрсету сапасын жақсартуға ықпал ететінін көрсетеді. Сонымен қатар, бұл құрылғылардың пациенттер мен дәрігерлер арасындағы қарым-қатынасты нығайтып, денсаулық сақтау саласын цифрландырудың маңыздылығын көрсетеді.

Кілттік сөздер: смарт технологиялар, денсаулық сақтау жүйесі, смарт құрылғылар, денсаулық мониторингі, ауруларды алдын алу, фитнес-трекер, цифрландыру, пациенттер, дәрігерлер.

Кіріспе

Смарт технологиялар қазіргі таңда денсаулық сақтау жүйесінде маңызды орын алуда. Олар медициналық қызметтердің сапасын жақсартуға, пациенттердің жағдайын нақты уақыт режимінде бақылауға және емдеу үдерісін тиімді жүргізуге мүмкіндік береді. Смарт құрылғылар, мысалы, смарт сағаттар мен фитнес-трекерлер, аурулардың алдын алу және емдеу процесін оңтайландыруда қолданылып, дәрігерлер мен пациенттер арасындағы байланыс пен ақпарат алмасуды жеңілдетеді. Бұл технологиялар денсаулық сақтау саласының цифрландыруына ықпал етіп, медициналық қызметтерді қолжетімді әрі тиімді етуге зор мүмкіндік береді.

Қолдану салалары

Смарт құрылғылар денсаулық сақтау саласында түрлі қолдану салаларына ие. Олар аурулардың алдын алу, емдеу үдерісін жеңілдету және пациенттердің жағдайын қашықтан бақылауға көмектеседі. Смарт құрылғылар қарқынды күтімде, реабилитацияда, қарт адамдарға арналған денсаулық сақтау, диагностика, және пациенттерді мониторингте қолданылады. Сонымен қатар, мобильді денсаулық қосымшалары пациенттерге денсаулықты бақылауға, дәрігермен байланысуға және фитнес мақсаттарына жетуге мүмкіндік береді. Бұл технологиялар денсаулық сақтау қызметтерін тиімді әрі қолжетімді етеді.

Болашақ перспективалары

Смарт құрылғылардың болашақта денсаулық сақтау саласында маңызды рөл атқаратыны күтілуде. Жасанды интеллект пен машиналық оқыту арқылы диагноз қою және емдеуді дербестендіру мүмкіндіктері артады. Деректерді үлкен көлемде талдау арқылы ауруларды ерте анықтау және алдын алу шаралары кеңейеді. Биометриялық бақылау жүйелері мен құрылғылардың өзара байланысы денсаулық жағдайын дәл бақылауға мүмкіндік береді. Денсаулық сақтау жүйесінің цифрлануы пациенттер мен дәрігерлер арасындағы байланысты жеңілдетіп, медициналық қызмет сапасын жақсартады. Смарт құрылғылар болашақта медициналық қызметтерді тиімдірек және қолжетімдірек етеді.

Қорытынды

Смарт құрылғылар денсаулық сақтау саласында үлкен өзгерістер әкелуде. Олар ауруларды ерте анықтау, емдеуді тиімді ету, пациенттерді қашықтан бақылау және медициналық қызмет сапасын арттыру сияқты маңызды мүмкіндіктер ұсынады. Жасанды интеллект, деректерді үлкен көлемде талдау, биометриялық бақылау және цифрлық технологиялар денсаулық сақтау жүйесінің болашағын түрлендіреді. Алайда, бұл технологияларды тиімді пайдалану үшін олардың қауіпсіздігі мен қолжетімділігі мәселелерін шешу қажет. Смарт құрылғылардың артықшылықтары мен кемшіліктерін ескере отырып,

олардың денсаулық сақтау саласында қолданылуын әрі қарай дамыту пациенттердің өмір сапасын арттыруға, медициналық қызметтердің тиімділігін жақсартуға және денсаулық сақтау шығындарын азайтуға ықпал етеді.

Пайдаланылған әдебиеттер тізімі:

1. Құрманов, Қ. Қ., Жақсыбаев, Н. М., & Бекболатов, М. Қ. (2019). Ақпараттық технологиялар және IoT негізіндегі денсаулық сақтау жүйелерін құру. *Қазақ мемлекеттік техникалық университетінің хабаршысы*, 2(15), 56-63.
2. Тұрсынбаева, Г. Т., & Сүлейменов, А. С. (2020). Денсаулық сақтау саласындағы смарт технологиялар: IoT жүйелерінің даму перспективалары. *Қазақстанның ақпараттық жүйелері журналы*, 7(3), 102-109.
3. Айтқұлов, Р. Б., & Тасболатова, С. М. (2018). Денсаулық сақтаудың жаңа заманауи технологиялары мен IoT жүйелері. *ҚазҰТУ хабаршысы, техникалық ғылымдар сериясы*, 64(4), 42-48.

Жасанды интеллект және заттар интернеті технологиялары негізінде қалдықтарды жинау және сұрыптауды басқарудың интеллектуалды жүйесін құру

Сарсембаева Т.С., Жыйлысова Д.С.

Әл-Фараби атындағы Қазақ Ұлттық университеті, Алматы, Қазақстан

Аннотация

Қалдықтарды басқарудың заманауи әдістері сұрыптау сапасын жақсартатын тиімді шешімдерді қажет етеді. Бұл жұмыс қалдықтарды жіктеу және сұрыптау процесін автоматтандыру үшін жасанды интеллект (AI) қолдануын қарастырады. Машиналық оқыту технологияларын пайдалану, компьютерлік көру және санаттар бойынша қалдықтарды кластерлеу (шыны, пластик, қағаз) қайта өңдеу зауыттарына түсетін жүктемені азайтады және қайта өңдеудің тиімділігін арттырады.

Кілттік сөздер: қалдықтарды сұрыптау, жасанды интеллект, машиналық оқыту, қалдықтарды қайта өңдеу, кластерлеу, экологиялық технологиялар.

Кіріспе

Қалдықтардың көлемінің өсуі қалдықтардың әртүрлі санаттарын автоматты түрде тани алатын интеллектуалды сұрыптау жүйелерін енгізуді талап етеді. Дәстүрлі сұрыптау әдістері еңбекті көп қажет етеді және жоғары дәлдікті қамтамасыз етпейді. AI пайдалану қалдықтардың кескіндерін талдауға, оның түрін анықтауға және қоршаған ортаны жақсартуға және қайта өңдеуге ықпал ететін тиісті контейнерге бағыттауға мүмкіндік береді. Сонымен қатар, қалдықтарды кластерлеу олардың физикалық және химиялық қасиеттеріне байланысты қолданылады, бұл бөлу дәлдігін арттырады.

Әдістер мен технологиялар

1. Компьютерлік көру – қалдық кескіндерді талдау және конволюционды нейрондық желілер (CNN) көмегімен оларды жіктеу үшін қолданылады.
2. Машиналық оқыту және кластерлеу – қалдықтар санаттарын (шыны, пластик, қағаз және органикалық заттар) автоматты түрде анықтау үшін таңбаланған деректер жиынында үлгіні оқыту, сондай-ақ сұрыптау тиімділігін арттыру үшін деректерді кластерлеу.
3. IoT және роботтық жүйелер – қалдықтарды класс бойынша автономды сұрыптау үшін сенсорлар мен манипуляторларды біріктіру.

Нәтижелер мен перспективалар

Әзірленген жүйе қалдықтарды жіктеудің дәлдігін 92–97% деңгейінде көрсетеді. Кластерлеуді енгізу қалдықтарды санаттарға дәлірек бөлуге мүмкіндік береді, бұл қайта өңдеудің тиімділігін арттырады. Сұрыптауды автоматтандыру қателерді айтарлықтай азайтады, өңдеу шығындарын азайтады және қайта өңделген материалдардың көлемін арттырады. Әрі қарайғы зерттеулер тану үлгілерін жетілдіруге және жүйені өнеркәсіптік процестерге біріктіруге бағытталатын болады.

Қорытынды

Қалдықтарды сұрыптауда ЖИ және кластерлеуді қолдану экология мен экономиканың жаңа перспективаларын ашады. Автоматтандырылған жүйелер қоршаған ортаның ластануын айтарлықтай азайтады және қайта өңдеу процесін оңтайландырады. Технологияларды одан әрі дамыту жүйені қалалық пайдалану үшін жіктеу дәлдігі мен ауқымдылығын арттыруды қамтамасыз етеді.

Пайдаланылған әдебиеттер тізімі:

1. Zhang, L., & Wang, Y. (2022). AI-Driven Waste Sorting: Innovations and Challenges. *Environmental Technology & Innovation*, 28, 102314.
2. Kumar, P., & Gupta, A. (2023). Machine Learning in Waste Management: A Systematic Review. *Journal of Cleaner Production*, 335, 130257.

3. Williams, E., & Thompson, B. (2021). Smart Waste Sorting Systems: A Comprehensive Overview. *Waste Management*, 150, 211-225.
4. Garcia, M., & Hernandez, R. (2022). Clustering Methods in Waste Classification: An AI Approach. *Journal of Environmental Engineering*, 145, 654-670.

Разработка системы цифрового управления ветрогенераторными установками

Серікханова Аяжан Мұратқанқызы

КазННТУ им. К.И.Сатпаева

Магистрант 1 курса

aaserikhanova@gmail.com

Общая характеристика задачи

Разработка системы цифрового управления ветрогенераторными установками представляет собой комплексную задачу, направленную на повышение эффективности, безопасности и надежности работы ветряных турбин. Ветроэнергетика, как важный элемент возобновляемой энергетики, требует внедрения передовых технологий для обеспечения устойчивой и эффективной работы, особенно в условиях изменчивости внешней среды.

Технологий и методы

В разработке системы цифрового управления ветрогенераторными установками используется ряд передовых технологий и методов, которые позволяют оптимизировать эксплуатацию, повысить производительность и снизить риски. Эти технологии охватывают различные аспекты, включая мониторинг, обработку данных, автоматизацию и управление, а также интеграцию с другими системами.

Рассмотрим более подробно ключевые технологии и методы, применяемые в таких системах:

1. Технология IoT играет важную роль в процессе мониторинга и управления ветрогенераторами. Все компоненты установки — от лопастей до генератора — оснащаются различными датчиками, которые собирают данные о внешних и внутренних параметрах: скорости ветра, температуре, влажности, вибрациях, нагрузке и других ключевых показателях.
2. Машинное обучение (ML) и искусственный интеллект (AI) используются для обработки собранных данных, прогнозирования поведения установки и выявления возможных неисправностей на ранних стадиях.
3. Обработка больших данных (Big Data) - ветрогенераторы генерируют огромные объемы данных, которые необходимо эффективно обрабатывать и анализировать для оптимального управления.

Автоматизация и адаптивное управление

Автоматизация и адаптивное управление являются ключевыми аспектами в эффективной эксплуатации ветрогенераторных установок. Системы автоматического управления позволяют значительно повысить производительность ветрогенераторов, минимизировать человеческий фактор и обеспечить безопасность работы оборудования, снижая затраты на обслуживание и увеличение срока службы установок. В условиях переменчивых погодных условий и различных внешних факторов, таких как изменение скорости ветра, направление ветра, температура и другие, адаптивное управление играет важную роль, позволяя гибко регулировать параметры работы установки. Автоматизация процессов управления ветрогенератором направлена на обеспечение его бесперебойной работы в оптимальных режимах. Она включает в себя:

1. Автоматическая настройка угла наклона лопастей: Лопасты ветрогенератора регулируются в зависимости от скорости ветра, чтобы максимизировать захват энергии.
2. Регулирование оборотов генератора: Обороты турбины автоматически регулируются в зависимости от мощности ветра.
3. Контроль и управление мощностью: Система автоматически регулирует выработку энергии в зависимости от текущих ветровых условий, обеспечивая максимальную эффективность в процессе выработки электроэнергии.

Заключение

В заключении можно подытожить основные результаты внедрения системы цифрового управления ветрогенераторными установками, акцентировать внимание на экономических и экологических преимуществах, а также подчеркнуть значимость дальнейших исследований и разработок в этой области для устойчивого развития энергетики.

Список использованной литературы:

1. Курочкин, А. Н. «Ветряные установки и системы». — М.: Машиностроение, 2020.
2. Шлапаков, С. М., Кондратенко, В. И. «Основы ветроэнергетики: учебник для вузов». — М.: Изд-во МГТУ им. Н.Э. Баумана, 2019.
3. M. A. Hossain, R. Islam, K. S. R. Anjaneyulu. "Adaptive Control of Wind Turbines: Concepts and Approaches," Springer Handbook of Wind Energy, 2020.
4. H. Xie, F. L. Lewis, K. N. Sturtz, Y. Zhang. "Digital Twin and Internet of Things: Applications in Wind Energy Systems," IEEE Access, 2019.
5. Козлов, М. В., Лебедев, С. И. «Ветроэнергетические установки: Принципы, технологии и перспективы». — М.: Издательство Московского университета, 2014.

СҮЗУ ПРОЦЕСІН АВТОМАТТЫ РЕТТЕУ ЖҮЙЕСІН ӘЗІРЛЕУ

Смайлова П.Н.

Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті

1 курс магистранты

smailova.perizat02@gmail.com

Қазіргі уақытта сүзу процесі сумен жабдықтау, тамақ өнеркәсібі, ауыл шаруашылығы және өзге де өндірістік салаларда маңызды рөл атқарып, өзектілігін жоғалтпай келеді. Сүзгілер әртүрлі орталар мен материалдарды зиянды химиялық қосылыстардан сонымен қатар ластаушы заттардан, микроорганизмдер мен бөлшектерден тазарту үшін қолданылады.

Қазіргі таңда өнеркәсіптік, ауыл шаруашылығы және тұрмыстық қажеттіліктер үшін су сапасының жоғары деңгейін қамтамасыз ету үшін тиімді сүзу әдістерін қолдану қажет. Солардың ішінде ультрафилтрация әдісі жоғары тиімділігімен ерекшеленіп судың сапасын айтарлықтай жақсартады. Ультрафилтрация мембраналық процестерге жатады.

Суды ультрафилтрациялау – суды ұсақ және коллоидты қоспалардан, соның ішінде вирустардан, бактериялардан және басқа органикалық заттардан оның тұз құрамын өзгертпей тазартудың сенімді және тиімді әдісі болып табылады. Бұл әдісте кеуек диаметрі 0,1-0,01 мкм аралығындағы күрделі мембраналық құрылымдарды қолдануға негізделген. Мембрананың тесіктері вирустың немесе бактерияның өлшемінен әлдеқайда аз, сондықтан бұл микроорганизм мұндай тосқауылдан өте алмайды.

Ультрафилтрацияның артықшылықтары:

1. Жоғары тиімділік:

– Мембраналардың кеуектілігі 0,01–0,1 мкм аралығында, сондықтан бактерияларды және ірі вирустарды ұстап қалады.

2. Экологиялық қауіпсіздік:

– Бұл процесс химиялық реагенттерсіз жұмыс істей алады, яғни қоршаған ортаға зиянды заттар шығармайды.

– Мембраналарды тазарту үшін кері жуу және химиялық жуу жүйелері қолданылады.

3. Энергияны аз тұтыну

– Қолданылатын қысым 0,1–0,5 МПа аралығында, бұл басқа әдістерге қарағанда қолданылатын қысым әлдеқайда төмен, сондықтан энергия тұтыну азаяды.

4. Автоматты басқару мүмкіндігі:

– Ультрафилтрация жүйесіне сенсорлар мен реттеуіштерді енгізу арқылы процесті толық автоматтандыруға болады.

– PLC (Programmable Logic Controller) және SCADA (Supervisory Control and Data Acquisition) жүйелері процесті онлайн бақылау мен басқаруды толық қамтамасыз етеді.

Сенсорлар ультрафилтрация жүйесінің жұмыс параметрлерін нақты уақыт режимінде бақылап, PLC контроллеріне деректер жібереді. Мәселен, қысым сенсорлары – мембрананың екі жағындағы қысымды өлшеп, филтрация тиімділігін бақылау және бітелуді анықтау үшін қолданылады. Ал температура сенсорлары – судың температурасы ультрафилтрациялық мембраналардың қызмет ету мерзіміне әсер ететіндіктен, оптималды температураны бақылау үшін қажет. Өткізгіштік сенсорлары – сүзілген судың сапасын анықтайды, тұздар мен басқа да еріген заттардың концентрациясын бақылайды. Лайылық сенсорлары – ультрафилтрация тиімділігін бақылап, мембрананың ластану деңгейін бағалайды.

Қорытындылай келе, ультрафилтрация - бұл суда ерімейтін коллоидты бөлшектерді, бактериялар мен вирустарды тиімді түрде жоятын жоғары селективті мембраналық технология болып табылады. Ультрафилтрация процесін автоматтандыру сенсорлық жүйелерді, PLC және SCADA технологияларын біріктіру арқылы жүзеге асырылады.

Глубокое обучение CNN YOLO для онлайн мониторинга и распознавание болезней пшеницы с помощью компьютерного зрения

Солтангельдинова М.К.

*Казахский национальный университет им. аль-Фараби, докторант 1 курса
e-mail: msoltangeldynova@gmail.com*

В современных условиях сельского хозяйства оперативное выявление заболеваний пшеницы играет ключевую роль в повышении урожайности и снижении потерь. Традиционные методы диагностики требуют значительных затрат времени и человеческих ресурсов, что делает их менее эффективными при больших объёмах посевных площадей. В связи с этим возникает необходимость внедрения автоматизированных систем мониторинга, основанных на компьютерном зрении и алгоритмах глубокого обучения.

Современные модели детекции объектов, такие как YOLO (You Only Look Once), демонстрируют высокую производительность в реальном времени, что делает их перспективными для автоматизированного контроля за состоянием посевов. Однако точность распознавания различных заболеваний может варьироваться в зависимости от качества данных, характеристик модели и сложности классифицируемых признаков.

В отличие от существующих исследований, направленных на детекцию заболеваний отдельных культур данная работа фокусируется на разработке и оптимизации модели YOLOv8 для диагностики заболеваний именно пшеницы в реальных полевых условиях. Научная новизна заключается в следующих аспектах:

- Проведена адаптация модели YOLOv8 для классификации конкретных заболеваний пшеницы (листовая ржавчина, мучнистая роса, карликовость ячменя, здоровые листья).
- Оценена точность модели на специализированном датасете из 970 изображений и выявлены ключевые ограничения, влияющие на качество классификации.
- Предложены методы повышения точности модели, включающие оптимизацию гиперпараметров, балансировку классов и расширение датасета с помощью методов аугментации.
- Проведена сравнительная оценка точности модели по разным классам, что позволяет более точно определить перспективные направления доработки системы.

Результаты экспериментов:

По результатам обучения модели YOLOv8 на датасете из 970 изображений достигнуты следующие показатели (см. рисунок 1):

- Средняя точность (mAP50) по всем классам – 0.521, а mAP50-95 – 0.25.
- Наилучший результат показан для класса "листовая ржавчина" (mAP50 = 0.751, mAP50-95 = 0.404), что свидетельствует о хорошем качестве представленных данных для этого заболевания.
- Наихудший результат для класса "здоровые листья" (mAP50 = 0.475, mAP50-95 = 0.155), что может быть вызвано несбалансированностью данных или схожестью визуальных признаков с поражёнными растениями.

Перспективы дальнейшего исследования

Для повышения точности классификации предлагается:

- Провести балансировку данных за счёт увеличения количества изображений плохо определяемых классов.
- Использовать методы увеличения данных (data augmentation) для повышения устойчивости модели к различным условиям съёмки.
- Оптимизировать архитектуру нейросети, применяя различные версии YOLO и тонкую настройку гиперпараметров.
- Внедрить методы ансамблирования для улучшения обобщающей способности модели.

- Провести разработку программного комплекса, который сможет интегрировать данную модель с дронами или стационарными камерами для мониторинга посевов в режиме реального времени.

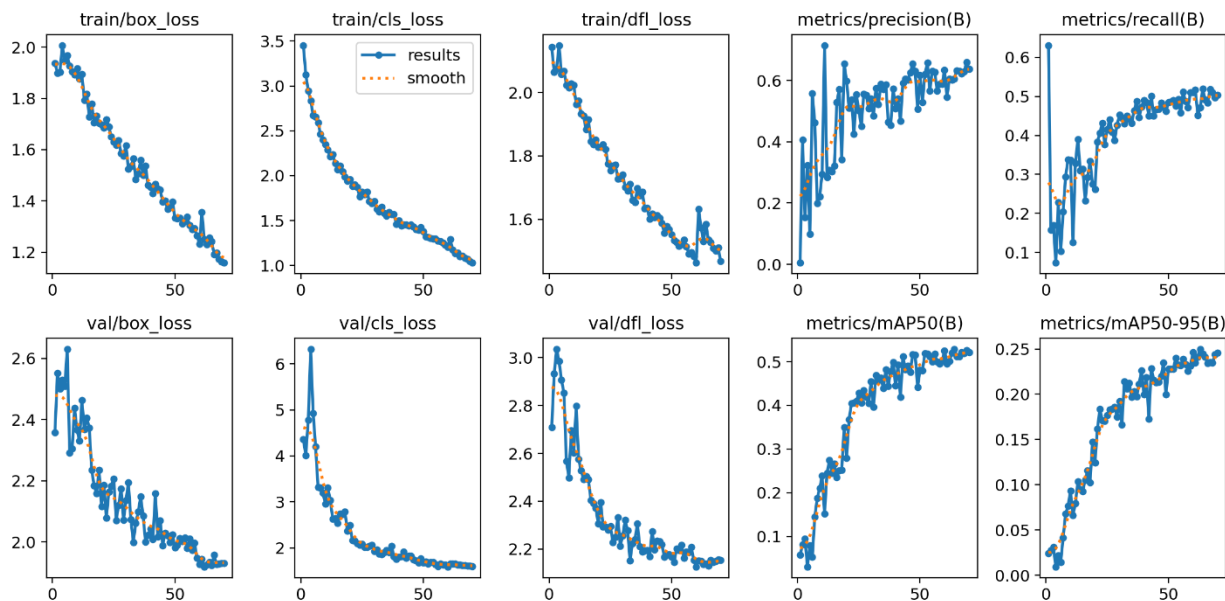


Рисунок 1. Результаты обучения на YOLOv8

Вывод

Проведённое исследование подтверждает возможность применения YOLOv8 для детекции заболеваний пшеницы, однако выявленные ограничения требуют дальнейшего усовершенствования подходов к предобработке данных и обучению модели. Разработка интеллектуальной системы мониторинга с использованием оптимизированной модели позволит значительно повысить эффективность борьбы с заболеваниями сельскохозяйственных культур и автоматизировать контроль за состоянием посевов.

Список использованной литературы:

1. Deep learning in biomedical image analysis / M. Kim, C. Yan, D. Yang, et al. // New York: ACM Press, 2020.
2. Vidhyalatha T., Sreeram Y., Purushotham E. Animal Intrusion Detection using Deep Learning and Transfer Learning Approaches // International Journal of Human Computations & Intelligence. 2022. Vol. 1. No. 4. P. 51-60.
3. Palani P., Kumar S., and Singh R. Real-time joint angle estimation using mediapipe framework and inertial sensors // 22nd International Conference on Bioinformatics and Bioengineering (BIBE). IEEE, 2022. P. 128-133.
4. Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning / M.S. Norouzzadeh, A. Nguyen, M. Kosmala, et al. // Proc Natl Acad Sci U S A. 2018. Vol. 115. No. 25. E5716-E5725.
5. Mohanty S.P., Hughes D.P., Salathé M. Using deep learning for image-based plant disease detection // Frontiers in Plant Science. 2016. Vol. 7. P. 1419.
6. An automated light trap to monitor moths (Lepidoptera) using computer vision-based tracking and deep learning / K. Bjerger, J.B. Nielsen, M.V. Sepstrup, et al. // Sensors. 2022. Vol. 21(2). P. 343.

Применение ИИ в модернизации технологического уклада сельского хозяйства РК

Солтангельдинова М.К.

*Казахский национальный университет им. аль-Фараби, докторант 1 курса
e-mail: msoltangeldynova@gmail.com*

Технологии дистанционного зондирования и распознавания состояния посевов зерновых культур имеет важное и стратегическое значение для нашей страны. Существующие глобальные космические системы по оценке состояния зернового хозяйства стран мира позволяют прогнозировать и определять ценовую политику при реализации товарного зерна на мировых рынках. Наша страна является одним из значимых производителей востребованных твердых сортов пшеницы. В тоже время, создание локальные системы мониторинга посевов зерна является актуальной задачей нашей науки о селе и технологий ИИ.

Создания мобильных бюджетных дронов с компьютерным зрением ориентированного для анализа и оценки состояние посевов в масштабах агрофирмы или частного землевладения требуют учета региональных особенностей роста районированных сортов зерновых культур для РК. Для анализа и онлайн мониторинга в технологиях ИИ за динамикой роста растений во временном интервале от посадки до уборки урожая необходимо решить ряд сложных технических задач ИСУ :

-создание автопилота отечественного дрона с машинным зрением с учетом отсутствия или неустойчивости сплошной интернет связи в отдаленных районах страны;

-формирование базы знаний об основных причинах и болезнях растений в период посева и роста зерновых культур;

-тестирование обученных нейронных сетей на примерах здоровых и пораженных участков полей с зерновыми культурами;

-создание и тестирование nano версий нейронных сетей , ориентированных на малогабаритные и легкие управляющие мини ПК с развитыми интеллектуальными приложениями;

-проведение полупромышленных испытаний на пшеничных делянках опытных полей биофака КазНУ имени аль-Фараби;

-внедрение опытных экземпляров дронов в крупных зерносеющих комплексах для дальнейшего их использования в с/х страны.

На первом этапе выполнения НИОКР , удалось реализовать типовые задачи обучения нейронных сетей CNN YOLOv8 nano распознавания состояния пшеницы в разных стадия роста для мини ПК Raspberri пай 4 с малогабаритной веб камерой, однако для удаленного мониторинга необходимо приобрести самофокусирующуюся длиннофокусную веб камеру типа LUCHIQ AUTO FOCUS 4K WEB CAM. Это позволит создать прототип агр дрона для полевых испытаний.

Список использованной литературы:

1. Халфакри Г. Raspberry Pi 4. Официальное руководство для начинающих. — М.: ДМК, 2021. — 262 с.

2. Тиммонс-Браун М. Робототехника на Raspberry Pi для юных конструкторов и программистов: пер. с англ. — СПб.: БХВ-Петербург, 2020. — 208 с.: ил. — ISBN 978-5-9775-4123-7.

3. <https://skymec.ru/services/selskoe-khozyaystvo/tsifrovoy-kontrol-etapov-rosta/>

4. Kumar V., Arora H., Harsh, Sisodia J. ResNet-based approach for Detection and Classification of Plant Leaf Diseases // *Proc. of the International Conference on Electronics and Sustainable Communication Systems (ICESC 2020)*. 2020. С. 495–502. DOI: 10.1109/ICESC48915.2020.9155585

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АДАПТИВНОГО УПРАВЛЕНИЯ ВОЗДУХООБМЕНОМ В ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМАХ НА ОСНОВЕ IOT

Сұлтанбай А.Ж., 2 курс магистранты

Орманбекова А.А., PhD

Алматы технологиялық университеті, Алматы қ., Қазақстан Республикасы

e-mail: aknur.sultanbay@mail.ru

Управление воздухообменом в помещениях является важной задачей для обеспечения комфорта и энергоэффективности. Традиционные системы вентиляции часто работают по фиксированным параметрам, что приводит к избыточному энергопотреблению и недостаточной гибкости. Современные технологии, такие как IoT и машинное обучение, открывают новые возможности для создания адаптивных систем, способных автоматически регулировать параметры воздухообмена в зависимости от изменяющихся условий.

Целью данной работы является разработка интеллектуальной системы управляемого воздухообмена, использующей методы машинного обучения для адаптивного управления. В статье рассматриваются архитектура системы, выбор алгоритмов машинного обучения, а также результаты тестирования системы в реальных условиях.

Интеллектуальная система воздухообмена состоит из следующих компонентов:

- Датчики: измеряют параметры воздуха (температура, влажность, уровень CO₂, концентрация вредных веществ).
- Контроллеры: обрабатывают данные с датчиков и управляют исполнительными устройствами (вентиляторы, клапаны).
- Облачный сервис: хранит данные, обучает модели машинного обучения и предоставляет интерфейсы для пользователей.
- Пользовательский интерфейс: позволяет настраивать параметры системы и отслеживать ее работу [1].

Методы машинного обучения

Для адаптивного управления используются следующие алгоритмы:

- Регрессионные модели используются для прогнозирования непрерывных значений на основе входных данных. В контексте системы воздухообмена они могут предсказывать уровень CO₂, температуру, влажность и другие параметры воздуха на основе исторических данных и текущих показаний датчиков.
- Деревья решений — это алгоритмы, которые разбивают данные на ветви (условия) и листья (решения) на основе правил. Они используются для классификации и принятия решений. В системе воздухообмена деревья решений могут определять, когда включать или выключать вентиляцию, основываясь на текущих параметрах воздуха.
- Reinforcement Learning (RL) — это метод машинного обучения, в котором агент учится принимать решения, взаимодействуя со средой и получая обратную связь в виде наград или штрафов. В системе воздухообмена RL может оптимизировать стратегии управления в реальном времени, чтобы минимизировать энергопотребление и поддерживать комфортные условия.

Таблица 1: Сравнение методов

Метод	Основное применение	Преимущества	Недостатки
Регрессионные модели	Прогнозирование параметров воздуха	Простота, интерпретируемость	Ограниченность для нелинейных зависимостей
Деревья решений	Принятие решений (включение/выключение)	Интерпретируемость, работа с разными типами	Склонность к переобучению

Метод	Основное применение	Преимущества	Недостатки
		данных	
Reinforcement Learning	Оптимизация управления в реальном времени	Адаптивность, оптимизация долгосрочных целей	Высокая сложность и ресурсоемкость

Регрессионные модели подходят для быстрого прогнозирования параметров воздуха, дерева решений — для прозрачного принятия решений, а Reinforcement Learning — для адаптации к изменениям и оптимизации долгосрочных целей, таких как энергосбережение.

Сбор и обработка данных

Данные с датчиков собираются каждые 5 секунд и передаются в облачный сервис. Перед использованием данные нормализуются и очищаются от шумов. Для обучения модели используется набор данных, включающий параметры воздуха, погодные условия и количество людей в помещении [2].

Обучение модели

Модель обучается на исторических данных с использованием метода обратного распространения ошибки. Для оценки качества модели используются метрики точности (accuracy), среднеквадратичной ошибки (MSE) и времени отклика системы.

Результаты

1. Эффективность адаптивного управления

Тестирование системы показало, что использование машинного обучения позволяет повысить точность управления параметрами воздуха на 25% по сравнению с традиционными методами. Система успешно адаптируется к изменению количества людей в помещении и внешних условий.

2. Энергоэффективность

Благодаря адаптивному управлению система снижает энергопотребление на 15–20%. Это достигается за счет оптимизации работы вентиляторов и клапанов.

3. Примеры работы системы

На рисунке 1 представлены графики изменения уровня CO₂ и работы вентиляции в течение дня. Видно, что система автоматически увеличивает интенсивность воздухообмена при повышении уровня CO₂ и снижает ее в периоды низкой активности.

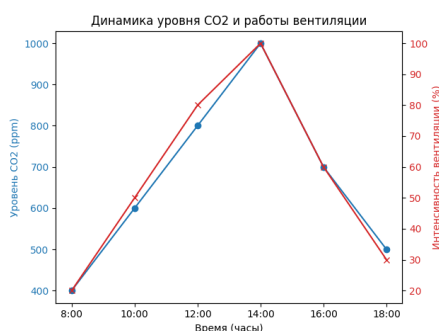


Рисунок 1: Графики изменения уровня CO₂ и работы вентиляции в течение дня.

Таблица 2: Сравнение энергопотребления традиционной и интеллектуальной систем.

Параметр	Традиционная система	Интеллектуальная система
Среднее энергопотребление (Вт)	500	400
Точность регулирования (%)	75	94
Время реакции на изменение условий (с)	30	5

Предложенный подход демонстрирует высокую эффективность в управлении

воздухообменом. Основными преимуществами системы являются адаптивность к изменяющимся условиям, снижение энергопотребления, а также удобство использования благодаря интеграции с IoT.

В статье предложен подход к созданию интеллектуальной системы управляемого воздухообмена на основе IoT и машинного обучения. Результаты тестирования показывают, что система эффективно управляет параметрами воздуха и снижает энергопотребление. Дальнейшие исследования будут направлены на интеграцию системы с другими компонентами умного дома и использование более сложных алгоритмов ИИ [3].

Список использованной литературы:

1. Применение инструментов Big Data и Machine Learning в IoT [Электронный ресурс]. – URL: <https://lib.itsec.ru/articles2/Oborandteh/primenenie-instrumentov-big-data-i-machine-learning-v-iot> (дата обращения: 10.10.2023).
2. Mahbub M., Hossain M. M., Gazi M. S. A. IoT-Cognizant cloud-assisted energy efficient embedded system for indoor intelligent lighting, air quality monitoring, and ventilation // Internet of Things. – 2020. – Т. 11. – С. 100266. – URL: <https://www.sciencedirect.com/science/article/abs/pii/S2542660520301001>
3. Metallidou C. K., Psannis K. E., Egyptiadou E. A. Energy efficiency in smart buildings: IoT approaches // IEEE Access. – 2020. – Т. 8. – С. 63679–63699. – DOI: [10.1109/ACCESS.2020.2984461](https://doi.org/10.1109/ACCESS.2020.2984461).

Описание рабочего пространства управляемого робота в виде логических функций

Тулегенова Наргиза Айбековна

КазННТУ им. К.И.Сатпаева

Магистрант 1 курса

nngargiza2002@icloud.com

Введение

В современных робототехнических системах важным аспектом является определение рабочего пространства управляемого робота. Это позволяет оценить его функциональные возможности, учесть ограничения и оптимизировать управление. Логические функции предоставляют формальный подход к описанию доступных областей движения робота и условий его работы.

Актуальность

Современные роботы активно применяются в промышленности, медицине, логистике и других сферах. Оптимизация их рабочего пространства позволяет повысить эффективность работы, сократить энергозатраты и предотвратить аварийные ситуации. Использование логических функций для описания рабочего пространства облегчает анализ возможных движений робота и его взаимодействие с окружающей средой.

Основная часть

1. Определение рабочего пространства робота

Рабочее пространство робота — это множество точек, которых манипулятор может достичь при заданных ограничениях. Оно зависит от кинематической структуры, диапазона движения суставов и возможных препятствий. Различают три типа рабочего пространства:

- Геометрическое рабочее пространство — область, в которой может находиться конец манипулятора.

- Динамическое рабочее пространство — учитывает силы, моменты и нагрузки, ограничивающие движение.

- Функциональное рабочее пространство — область, где робот может выполнять целевые операции.

- Конфигурационное рабочее пространство — множество допустимых конфигураций манипулятора в зависимости от его степеней свободы и механических ограничений.

2. Логическое описание достижимости точек

Каждая точка $p(x, y, z)$ рабочего пространства может быть описана логической функцией достижимости:

$$R(p) = \begin{cases} 1, & \text{если точка достижима,} \\ 0, & \text{если точка недостижима.} \end{cases} \quad (1)$$

3. Учёт препятствий

Если пространство содержит препятствия, вводится логическая функция:

$$O(p) = \begin{cases} 1, & \text{если точка занята препятствием,} \\ 0, & \text{если точка свободна.} \end{cases} \quad (2)$$

Тогда рабочее пространство с учётом препятствий задаётся как:

$$W(p) = R(p) \wedge \neg O(p). \quad (3)$$

4. Функция допустимых состояний

Для контроля движений робота учитываются ограничения по скорости, углам вращения суставов и другим параметрам. Функция допустимых состояний:

$$C(p, \theta, v) = \begin{cases} 1, & \text{если } (p, \theta, v) \text{ допустимо,} \\ 0, & \text{иначе.} \end{cases} \quad (4)$$

Итоговое рабочее пространство определяется выражением:

$$W_c(p) = R(p) \wedge \neg O(p). \quad (5)$$

5. Применение логических функций в управлении роботом

Логические функции позволяют формально задавать ограниченные зоны,

программировать безопасные траектории и адаптировать алгоритмы управления. Применение методов логического анализа позволяет:

- Определять зоны, недоступные для манипулятора.
- Вычислять оптимальные траектории движения.
- Автоматизировать обнаружение препятствий и обходных маршрутов.
- Формировать правила избегания коллизий в многозадачных системах.
- Применять логические функции в мультиагентных системах для координации работы нескольких роботов.

Вывод

Использование логических функций для описания рабочего пространства управляемого робота позволяет формализовать ограничения и условия работы системы. Это важно для повышения точности управления, предотвращения коллизий и оптимизации траекторий движения. Применение таких методов в робототехнике способствует развитию интеллектуальных систем управления, обеспечивающих безопасность и эффективность работы роботов. Логические функции находят применение в промышленности, медицинской робототехнике, а также в автономных транспортных системах.

Список использованной литературы:

1. Сливак П.Р. Теория управления роботами. – М.: Наука, 2020. – С. 112–135.
2. Кононов И. В. Кинематика и динамика манипуляционных систем. – СПб.: Питер, 2019. – С. 87–102.
3. Арсенов А. П. Робототехнические системы: моделирование и управление. – Екатеринбург: УрО РАН, 2021. – С. 45–67.
4. Латкин А. С. Основы робототехники. – М.: Техносфера, 2018. – С. 59–80.
5. Сафронов В. В. Управление движением промышленных роботов. – Новосибирск: Наука, 2022. – С. 134–156.

ПРОЕКТИРОВАНИЕ ИНФОРМАЦИОННОЙ СИСТЕМЫ ОЦЕНКИ КАЧЕСТВА ВОДЫ В РЕКАХ ПУТЕМ ПОСТРОЕНИЯ ГИДРОПОСТА

Фаизов Г.А., Утегенова А.У.

Алматинский Университет Энергетики и Связи имени Гумарбека Даукеева, Алматы, Казахстан

Ключевые слова

Гидропост, физический гидропост, виртуальный гидропост, методов сбора и анализа данных о водных объектах, автоматизированные системы оценки качества воды, проектирование систем сбора и анализа данных о водных объектах, проектирование гидропоста, проектирование базы данных гидропоста, функциональная модель гидропоста.

Аннотация

В данной статье рассматривается проектирование информационной системы оценки качества воды в реках путем построения гидропоста. В рамках написания статьи были созданы и рассмотрены функциональная модель, диаграмма классов, структура баз данных.

Современные методы мониторинга водных объектов требуют применения автоматизированных систем сбора и анализа данных. Гидропосты, выступающие в качестве ключевых элементов таких систем, могут быть как физическими, так и виртуальными, обеспечивая оперативный контроль качества воды. Эффективность работы подобных систем во многом зависит от их архитектуры, а именно от правильного проектирования информационной системы, обрабатывающей поступающие данные.

В данной статье рассматривается процесс проектирования информационной системы оценки качества воды, включающий разработку функциональной модели, построение диаграммы классов и проектирование структуры базы данных. Эти этапы позволяют структурировать логику работы системы, определить ключевые компоненты и их взаимосвязи, а также обеспечить надёжное хранение и обработку данных.

Стандарт IDEF0 является методологией функционального моделирования, разработанной для описания решений, процессов и систем в виде иерархических моделей. Модели IDEF0 строятся с использованием иерархической структуры диаграмм, где каждая функция или процесс детализируется на более низких уровнях абстракции.

В ходе изучения предметной области было установлено, что ключевая функция нашей информационной системы состоит в анализе качества воды. Функциональная модель, представленная на диаграмме, иллюстрирует основные потоки данных и взаимодействия, необходимые для выполнения этой функции. На диаграмме изображен центральный процесс под названием "Water Quality Test" (Тестирование качества воды), который является основой системы. В него поступают данные с датчиков (Sensor Data), запросы пользователей (Users Request), данные со спутников (Satellite Data) и метеорологические данные (Meteo Data). Эти данные используются для анализа и оценки качества воды.

Также в модели указано, что процесс тестирования качества воды опирается на стандарты качества воды (Water Quality Standards), которые служат референтными значениями или критериями для оценки полученных результатов.

Результаты тестирования качества воды (Water Quality Test Results) выходят из процесса и могут быть использованы для информирования заинтересованных сторон, регулирующих органов или для дальнейшей обработки и анализа.

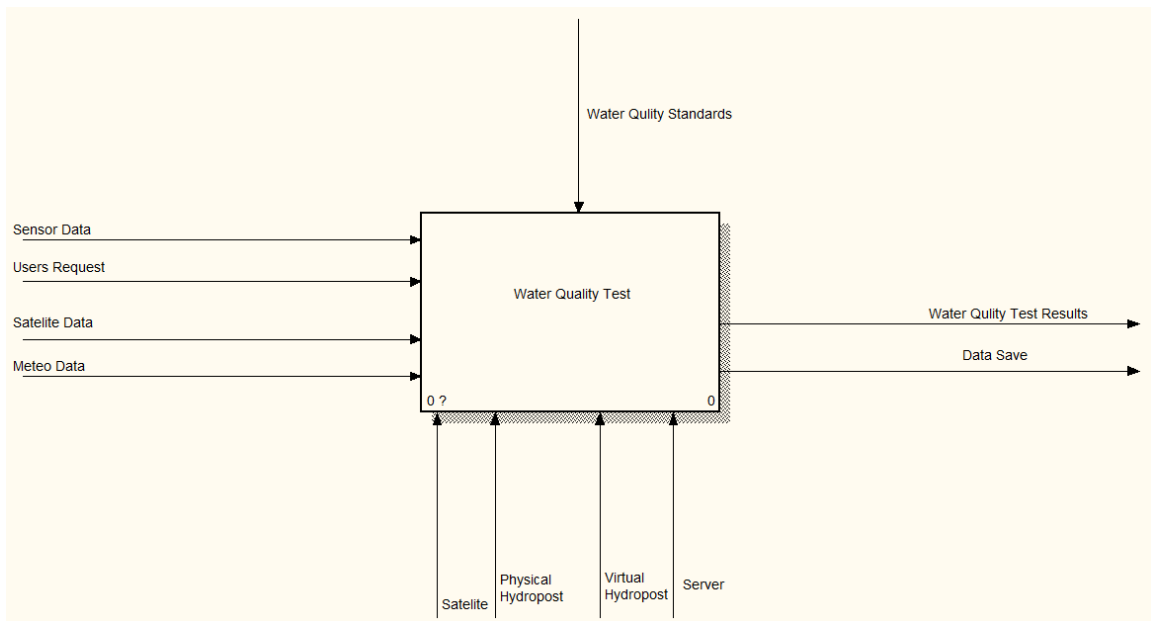


Рисунок 1 – Функциональная модель

Разработанная функциональная модель системы определяет ключевые процессы, которые необходимо автоматизировать, включая сбор, обработку, хранение и анализ данных о качестве воды. Для эффективного управления этими процессами требуется надежная структура хранения информации, обеспечивающая целостность, доступность и возможность быстрого анализа данных.

Исходя из функциональной модели, можно выделить основные сущности системы, такие как гидропосты, датчики, измерения, пользователи и отчеты. Взаимосвязи между этими сущностями определяют структуру базы данных, позволяя организовать хранение и обработку данных в удобном и эффективном формате.

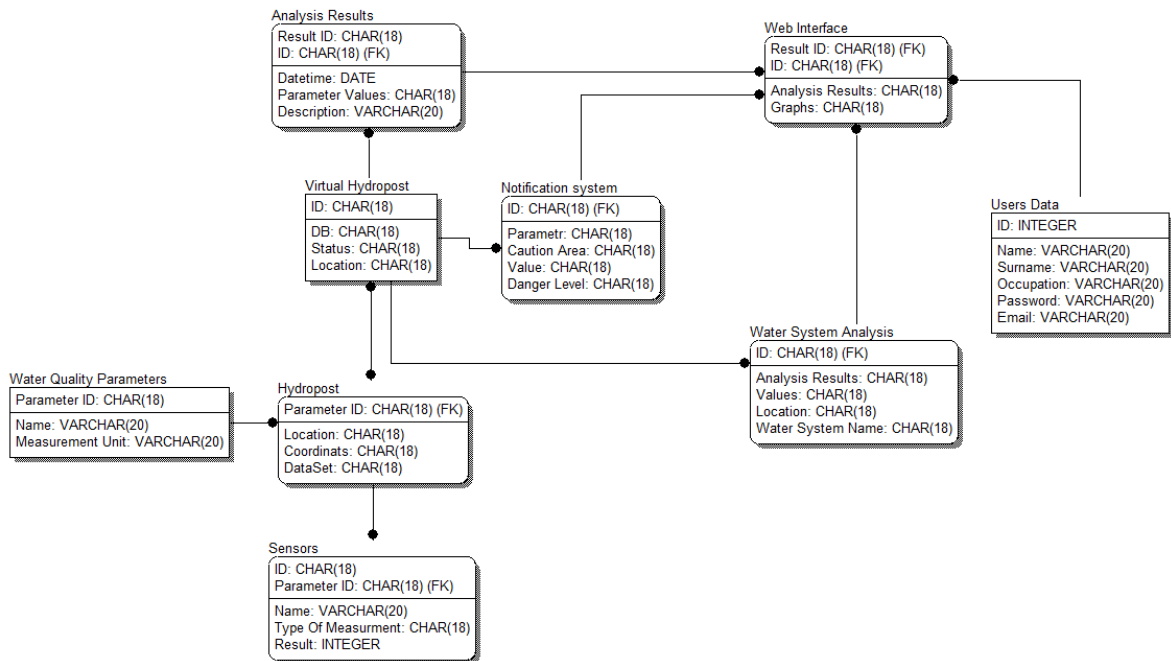


Рисунок 2 – Структура баз данных

Гидропосты размещаются в различных точках водных объектов и являются основным источником сбора данных. Каждый гидропост содержит набор датчиков, фиксирующих

параметры качества воды, такие как температура, уровень загрязнения, pH и другие. Данные с датчиков поступают в систему и записываются в базу данных через таблицу Sensors, связующуюся с Hydropost и Water Quality Parameters.

Каждое измерение датчиков сопоставляется с определенным параметром качества воды, хранящимся в таблице Water Quality Parameters. Для каждого параметра указано его имя и единица измерения, что позволяет системе корректно интерпретировать данные. После получения данных система проводит анализ, выявляя возможные отклонения от нормы. Анализируемые данные записываются в таблицу Analysis Results, которая содержит сведения о времени измерений, значениях параметров и описании результатов анализа.

Помимо физических гидропостов, в системе предусмотрены Virtual Hydropost, которые могут агрегировать данные из нескольких реальных точек мониторинга. При обнаружении аномалий, таких как превышение предельно допустимых концентраций загрязнителей, система формирует уведомления (Notification System) с указанием критических значений и уровня опасности.

Полученные результаты анализа данных отображаются в Web Interface, где пользователи могут видеть графики изменений параметров, таблицы значений и прогнозные модели. Также существует возможность формирования отчетов, содержащихся в таблице Water System Analysis, в которой фиксируются результаты анализа состояния водных объектов.

Конструкция и применение обойм в подшипниковых узлах

Хамитова Камила

Казахский национальный университет им. аль-Фараби, 2 курс бакалавр студенті

Аннотация:

Обоймы подшипников являются неотъемлемой частью вращающихся механизмов, обеспечивая устойчивость и равномерное распределение нагрузки. В работе рассматриваются особенности конструкции обойм, используемые материалы и современные методы повышения их эксплуатационных характеристик.

Введение:

Подшипниковые узлы широко применяются в машиностроении, энергетике, авиационном и других высокотехнологичных отраслях. Обоймы, как важная часть подшипника, выполняют функцию фиксации и распределения нагрузки, что способствует снижению трения и износа. Современные разработки направлены на повышение долговечности и надёжности обойм за счёт применения новых материалов и технологий.

Конструкция и материалы обойм:

Конструкция обойм варьируется в зависимости от типа подшипника и условий эксплуатации. Основные материалы для изготовления обойм:

- Высоколегированные стали – обладают высокой прочностью и устойчивостью к механическим нагрузкам.
- Керамика – характеризуется низким трением, высокой термостойкостью и коррозионной стойкостью.
- Полимеры и композиты – применяются для снижения массы конструкции и уменьшения уровня шума.

Методы производства включают холодную и горячую штамповку, литьё и использование порошковой металлургии, что позволяет создавать детали с высокой точностью и улучшенными свойствами.

Современные технологии и перспективы развития:

Для повышения эксплуатационных характеристик обойм внедряются новые технологии:

- Применение нанопокровов, повышающих износостойкость и защищающих от коррозии.
- Использование композитных материалов, уменьшающих вес и улучшающих механические свойства.
- Внедрение аддитивных технологий, позволяющих создавать сложные формы и повышать точность изготовления.

Заключение:

Конструкция и материалы обойм подшипниковых узлов напрямую влияют на их эффективность и срок службы. Внедрение инновационных решений позволяет расширить область применения подшипников и повысить надёжность механизмов в различных отраслях промышленности.

Ключевые слова:

обоймы, подшипники, материалы, конструкция, нанопокровы, композиты, технологии.

Разработка системы цифрового управления ветрогенераторными установками

Харесова Альфия Алижановна

КазНИТУ им. К.И.Сампаева, Магистрант 1 курса

alfiya.kharesova.02@mail.ru

Общая характеристика задачи

Общая характеристика задачи программного управления роботами-манипуляторами трех поколений с использованием пакета SimMechanics заключается в разработке, моделировании и реализации эффективных алгоритмов для управления движением роботизированных манипуляторов, которые могут выполнять различные задачи с высокой точностью и в условиях различных ограничений.

Технологий и методы

При разработке программного управления для роботов-манипуляторов с использованием SimMechanics в контексте разных поколений технологий можно выделить несколько ключевых технологий и методов, которые применяются для решения задач.

1. Моделирование механических систем:

Основной технологией, которая используется для создания моделей роботов-манипуляторов, является SimMechanics, инструмент MATLAB, который позволяет пользователям создавать 3D-модели механических систем с помощью графического интерфейса и блоков.

2. Методы управления:

Алгоритмы управления роботизированными манипуляторами могут различаться в зависимости от поколения и включают несколько подходов, которые используются на практике. Первое поколение (Позиционное управление): Для простых роботов-манипуляторов, задачей было поддержание точного положения. ПИД-регулирование (пропорционально-интегрально-дифференциальное управление): один из самых простых методов, который часто. Кинематическое управление: это управление, при котором движение манипулятора определяется только его геометрией, без учёта динамики. Например, использование обратной кинематики для расчёта углов суставов, необходимых для достижения требуемого положения. Методы в SimMechanics: Использование приводных блоков (например, шаговых двигателей или серводвигателей), которые регулируют углы вращения. Настройка ПИД-регулятора через блоки управления для работы с каждым суставом или системой суставов.

3. Оптимизация траектории и планирование движения:

Для повышения эффективности работы манипулятора и выполнения задач с минимальными затратами времени и энергии применяются различные методы оптимизации траектории. Методы оптимизации траектории: используются для поиска оптимальных путей, которые минимизируют время, расход энергии или другие параметры (например, минимизацию силы трения). Динамическое программирование: этот метод позволяет решать задачи планирования траектории при наличии множества ограничений, таких как ограничения на скорость, ускорение или предотвращение столкновений. Методы поиска: используются для поиска оптимальных траекторий с учетом всех ограничений и препятствий в рабочей области.

Пример простого манипулятора в SimMechanics:

1. Создать модель манипулятора, используя блоки для создания корпуса (например, соединив два звена).
2. Добавить элементы для генерации момента (например, моторы).
3. Настроить контроллер для регулирования положения каждого сустава с помощью ПИД-регулятора.
4. Смоделировать траекторию движения манипулятора и протестировать его работу.

Заключение:

Программное управление роботами-манипуляторами представляет собой сложную и многогранную задачу, которая включает в себя несколько этапов: от моделирования и разработки динамических и кинематических моделей манипуляторов до реализации сложных алгоритмов управления. В процессе развития роботизированных систем появились новые подходы: от простого позиционного управления до интеллектуальных адаптивных систем, которые могут адаптироваться к изменениям в окружающей среде и выполнять многозадачные операции.

Использование пакета SimMechanics в сочетании с Simulink предоставляет мощные инструменты для моделирования, анализа и оптимизации работы роботов-манипуляторов. Это позволяет создавать точные физические модели, интегрировать динамические уравнения, разрабатывать алгоритмы управления с использованием обратной связи, а также оптимизировать траектории движения для повышения эффективности.

Список использованной литературы:

1. Craig, J.J. Introduction to Robotics: Mechanics and Control. Pearson, 2004. – 192 с.
2. Лазарев Ю. Ф. Моделирование процессов и систем в MATLAB. Учебный курс. – СПб.: Питер ; Киев : Изд. гр. BHV, 2005. – 512 с.
3. Моделирование мехатронных систем в среде MATLAB (Simulink / SimMechanics): учеб. пособие для высш. учеб. заведений / В. М. Мусалимов [и др.]. – СПб.: НИУ ИТМО, 2013. – 114 с
4. Моделирование мехатронных систем в среде MATLAB (Simulink / SimMechanics): учеб. пособие для высш. учеб. заведений / В. М. Мусалимов [и др.]. – СПб.: НИУ ИТМО, 2013. – 114 с.
5. Подураев Ю. В. Принципы построения и современные тенденции развития мехатронных систем / Ю. В. Подураев, В. С. Кулешов // Мехатроника. – 2000. – № 1. – С. 5–15.
6. Умнов, В. П. Управление и моделирование движения многокоординатного комплексированного исполнительного устройства лазер-робота / В. П. Умнов, И. Н. Егоров, С. В. Молостов // Современные проблемы науки и образования. – 2014. – № 6.

Модели и алгоритмы программного управления роботами-манипуляторами трех поколений с использованием пакета Simmechanics.

Харесова Альфия Алижановна

КазНИТУ им. К.И.Сатпаева, Магистрант 1 курса
alfiya.kharesova.02@mail.ru

Общая характеристика задачи

Общая характеристика задачи программного управления роботами-манипуляторами трех поколений с использованием пакета SimMechanics заключается в разработке, моделировании и реализации эффективных алгоритмов для управления движением роботизированных манипуляторов, которые могут выполнять различные задачи с высокой точностью и в условиях различных ограничений.

Технологий и методы

При разработке программного управления для роботов-манипуляторов с использованием SimMechanics в контексте разных поколений технологий можно выделить несколько ключевых технологий и методов, которые применяются для решения задач.

1. Моделирование механических систем:

Основной технологией, которая используется для создания моделей роботов-манипуляторов, является SimMechanics, инструмент MATLAB, который позволяет пользователям создавать 3D-модели механических систем с помощью графического интерфейса и блоков.

2. Методы управления:

Алгоритмы управления роботизированными манипуляторами могут различаться в зависимости от поколения и включают несколько подходов, которые используются на практике. Первое поколение (Позиционное управление): Для простых роботов-манипуляторов, задачей было поддержание точного положения. ПИД-регулирование (пропорционально-интегрально-дифференциальное управление): один из самых простых методов, который часто. Кинематическое управление: это управление, при котором движение манипулятора определяется только его геометрией, без учёта динамики. Например, использование обратной кинематики для расчёта углов суставов, необходимых для достижения требуемого положения. Методы в SimMechanics: Использование приводных блоков (например, шаговых двигателей или серводвигателей), которые регулируют углы вращения. Настройка ПИД-регулятора через блоки управления для работы с каждым суставом или системой суставов.

3. Оптимизация траектории и планирование движения:

Для повышения эффективности работы манипулятора и выполнения задач с минимальными затратами времени и энергии применяются различные методы оптимизации траектории. Методы оптимизации траектории: используются для поиска оптимальных путей, которые минимизируют время, расход энергии или другие параметры (например, минимизацию силы трения). Динамическое программирование: этот метод позволяет решать задачи планирования траектории при наличии множества ограничений, таких как ограничения на скорость, ускорение или предотвращение столкновений. Методы поиска: используются для поиска оптимальных траекторий с учетом всех ограничений и препятствий в рабочей области.

Пример простого манипулятора в SimMechanics:

1. Создать модель манипулятора, используя блоки для создания корпуса (например, соединив два звена).
2. Добавить элементы для генерации момента (например, моторы).
3. Настроить контроллер для регулирования положения каждого сустава с помощью ПИД-регулятора.
4. Смоделировать траекторию движения манипулятора и протестировать его работу.

Заключение:

Программное управление роботами-манипуляторами представляет собой сложную и многогранную задачу, которая включает в себя несколько этапов: от моделирования и разработки динамических и кинематических моделей манипуляторов до реализации сложных алгоритмов управления. В процессе развития роботизированных систем появились новые подходы: от простого позиционного управления до интеллектуальных адаптивных систем, которые могут адаптироваться к изменениям в окружающей среде и выполнять многозадачные операции.

Использование пакета SimMechanics в сочетании с Simulink предоставляет мощные инструменты для моделирования, анализа и оптимизации работы роботов-манипуляторов. Это позволяет создавать точные физические модели, интегрировать

динамические уравнения, разрабатывать алгоритмы управления с использованием обратной связи, а также оптимизировать траектории движения для повышения эффективности.

Список использованной литературы:

7. Craig, J.J. Introduction to Robotics: Mechanics and Control. Pearson, 2004. – 192 с.
8. Лазарев Ю. Ф. Моделирование процессов и систем в MATLAB. Учебный курс. – СПб.: Питер ; Киев : Изд. гр. BHV, 2005. – 512 с.
9. Моделирование мехатронных систем в среде MATLAB (Simulink / SimMechanics): учеб. пособие для высш. учеб. заведений / В. М. Мусалимов [и др.]. – СПб.: НИУ ИТМО, 2013. – 114 с
10. Моделирование мехатронных систем в среде MATLAB (Simulink / SimMechanics): учеб. пособие для высш. учеб. заведений / В. М. Мусалимов [и др.]. – СПб.: НИУ ИТМО, 2013. – 114 с.
11. Подураев Ю. В. Принципы построения и современные тенденции развития мехатронных систем / Ю. В. Подураев, В. С. Кулешов // Мехатроника. – 2000. – № 1. – С. 5-15.
12. Умнов, В. П. Управление и моделирование движения многокоординатного комплексированного исполнительного устройства лазер-робота / В. П. Умнов, И. Н. Егоров, С. В. Молостов // Современные проблемы науки и образования. – 2014. – № 6.

ИССЛЕДОВАНИЯ И РАЗРАБОТКА ЭФФЕКТИВНОЙ СИСТЕМЫ УПРАВЛЕНИЯ ЭЛЕКТРОФИЛЬТРАМИ НА ПРЕДПРИЯТИЯХ ГОРНОДОБЫВАЮЩЕЙ ПРОМЫШЛЕННОСТИ КАЗАХСТАНА.

Шарасулов Ш.Ш.

КАЗНУТУ им. К.Сатпаева, Алматы, Казахстан

Развитие горнодобывающей промышленности Казахстана сопровождается значительным ростом объемов выбросов пылегазовых смесей, что требует применения эффективных систем очистки. Электрофильтры играют ключевую роль в процессе улавливания пылевых частиц, однако их эффективность напрямую зависит от систем управления. Разработка эффективных систем управления электрофильтрами позволит снизить экологическую нагрузку и повысить эффективность производственных процессов.

Современные подходы к оптимизации работы электрофильтров позволяют существенно повысить их эффективность при очистке газов от пылевых частиц, особенно на промышленных предприятиях с интенсивными выбросами. Применение математических моделей и систем автоматического управления помогает прогнозировать поведение системы и оптимизировать её рабочие параметры.

В исследовании [1] Ефремова В.И. и соавторов рассматривается оптимизация параметров электрофильтров для улавливания высокодисперсной известняковой пыли. Авторы подчёркивают, что использование сильного электрического поля позволяет значительно повысить эффективность осаждения пыли. Экспериментальные исследования на лабораторной и опытно-промышленной установках подтвердили важность подбора оптимальных параметров напряжения и геометрии электродов.

Как показано в промышленных отчетах [2], внедрение электрофильтров позволяет удалять до 99% твердых частиц, присутствующих в выбросах. Принцип работы основан на ионизации частиц, которые под воздействием электрического поля оседают на электродах. В сравнении с традиционными механическими методами очистки, эффективность электрофильтров при улавливании мелкодисперсной пыли значительно выше, что подтверждается данными экспериментов на тепловых электростанциях.

Особое внимание в современных исследованиях уделяется применению мокрых электрофильтров в сочетании с оптимизацией рабочих параметров. Как отмечается в публикациях [3] по промышленным инновациям, мокрые электрофильтры обеспечивают более высокую степень очистки благодаря постоянному смыванию осевших загрязнений. Метод позволяет не только улавливать твердые частицы, но и снижать выбросы кислотных газов, таких как SO_x . Внедрение современных систем мокрых электрофильтров позволило сократить выбросы твердых частиц на 50–70% по сравнению с традиционными сухими системами очистки.

Еще одним важным аспектом является интеграция электрофильтров с автоматизированными системами управления и мониторинга в реальном времени. Такие решения позволяют оперативно контролировать концентрацию загрязнений и автоматически корректировать режим работы электрофильтров в зависимости от изменений параметров выбросов. Это особенно актуально для производств с переменными нагрузками, где стабильность работы оборудования играет ключевую роль.

Примечательно, что современные электрофильтры могут быть объединены с технологиями мониторинга выбросов, что обеспечивает соответствие экологическим стандартам и позволяет избежать значительных финансовых потерь. Такие решения успешно применяются на предприятиях стран ЕС, где действуют строгие нормы по выбросам твердых частиц и других вредных веществ [4].

Передовые технологии управления и оптимизации работы электрофильтров основываются на использовании больших данных (Big Data) и искусственного интеллекта

(ИИ). Эти подходы позволяют обрабатывать значительные объемы данных, полученных с датчиков, для прогнозирования работы системы и повышения ее эффективности в режиме реального времени. В исследовании [5] Абдыкаримовой А.Т. подробно рассматриваются методы обработки больших данных и их применение в промышленных процессах. Автор отмечает, что использование аналитических технологий на основе машинного обучения позволяет оптимизировать параметры работы оборудования, улучшая его производительность и надёжность.

Пилецкая А.В. в своей работе [6] акцентирует внимание на влиянии ИИ и Big Data на автоматизацию промышленных систем. Применение алгоритмов глубокого обучения позволяет предсказывать возможные отклонения в работе электрофильтров, что обеспечивает предиктивное обслуживание и минимизацию простоев оборудования.

Кроме того, современные системы мониторинга на основе ИИ анализируют ключевые параметры работы электрофильтров, такие как:

- Напряжение и ток коронного разряда;
- Скорость и состав газового потока;
- Концентрация пылевых частиц;

Эти данные позволяют системе адаптироваться к изменениям внешних условий и поддерживать оптимальный режим работы электрофильтра.

В ходе исследования были рассмотрены современные подходы к управлению и оптимизации работы электрофильтров с использованием технологий больших данных и искусственного интеллекта. Данные методы позволяют значительно повысить эффективность очистки газовых выбросов и минимизировать экологическую нагрузку. Дальнейшее внедрение и развитие этих технологий будет способствовать повышению надежности промышленных систем очистки и соответствию современным экологическим стандартам.

Список использованной литературы:

1. Ефремов В.И. Оптимизация параметров электрофильтра для улавливания высокодисперсной известняковой пыли // <https://www.dissercat.com/content/optimizatsiya-parametrov-elektrofiltra-dlya-ulavlivaniya-vysokodispersnoi-izvestnyakovoii-pyl>
2. Zhang X., Li H., Chen Y. "Influence of NO₂ and SO₂ on the specific resistance of dust in flue gas", Journal of Environmental Management, 2019.
3. Пласкин Е.И., Трифанов А.В. Техничко-технологические решения очистки отработанного воздуха птицеводческих предприятий// URL: [https://cyberleninka.ru/article/n/tehniko-tehnologicheskie-resheniya-ochistki-otrabortannogo-vozduha-ptitsevodcheskih-predpriyatij?utm_source=chatgpt.com](https://cyberleninka.ru/article/n/tehniko-tehnologicheskie-resheniya-ochistki-otrabortannogo-vozduha-ptitsevodcheskih-predpriyatij)
4. Панишев С.А., Лисов А.А., Возмилов А.Г. Анализ электрофильтров для очистки воздушной среды производственных помещений// г.Челябинск, Россия URL: https://cyberleninka.ru/article/n/analiz-elektrofiltrov-dlya-ochistki-vozdushnoy-sredy-proizvodstvennyh-pomescheniy?utm_source=chatgpt.com
5. Абдыкаримова А.Т. "Big Data: проблемы и технологии" // URL: https://cyberleninka.ru/article/n/big-data-problemy-i-tehnologii?utm_source=cyberleninka.ru.
6. Пилецкая А.В. "Искусственный интеллект и большие данные в цифровом мире" // URL: https://moluch.ru/archive/288/65241/?utm_source=moluch.r


ИОТ НЕГІЗІНДЕ АҚЫЛДЫ ЖЫЛЫЖАЙ ЖОБАЛАУ

Шарипжан Б.Б., Балғабек А.Б., Шаймуранулы Н.

Ғылыми жетекшіі: Джулаева Ж.Т., техника ғылымдарының магистрі

Алматы технологиялық университеті

Қазіргі таңда ауыл шаруашылығы саласында смарт технологияларды енгізу маңызды бағыттардың бірі болып табылады. Ақылды жылыжай – бұл өсімдіктердің өсуін оңтайландыру және ресурстарды тиімді пайдалану үшін заманауи технологиялар қолданылатын автоматтандырылған жүйе. IoT (Интернет заттар) негізінде жобаланған ақылды жылыжай өнімділікті арттырып, еңбек шығындарын азайтуға және экологиялық тұрақтылықты қамтамасыз етуге мүмкіндік береді.



Сурет 1- Ақылды жүйенің сызбасы

Ақылды жылыжайдың негізгі ерекшеліктеріне топырақтың ылғалдылық деңгейін бақылау, температураны бақылау және желдеткішті басқару, ЖК экран арқылы мәліметтерді көрсету және автоматтандырылған процесті қамтамасыз ету жатады. Арнайы сенсорлар топырақтың ылғалдылығын үнемі өлшеп, қажет болған жағдайда автоматты түрде суару жүйесін іске қосады. Жылыжай ішіндегі температура мен ауа айналымын реттеу үшін интеллектуалды желдету жүйесі қолданылады. Фермерлер нақты уақыт режимінде температура, ылғалдылық, жарық деңгейі және CO₂ концентрациясын көре алады. Бүкіл жүйе датчиктер мен контроллерлер арқылы бақыланып, деректерді өңдеп, қажет шараларды автоматты түрде қабылдайды.

IoT негізіндегі ақылды жылыжай жүйесі түрлі құрылғылар мен технологиялардан тұрады. Олар сенсорлар (температура, ылғалдылық, жарық деңгейі, CO₂ деңгейі), контроллерлер (Arduino, Raspberry Pi немесе басқа микроконтроллерлер), аналитикалық жүйелер (бұлттық есептеулер, деректерді өңдеу) және мобильді қосымшалар мен веб-интерфейстер (пайдаланушыларға нақты уақыттағы деректерді ұсыну және қашықтықтан басқару) болып бөлінеді.

Жобалаудың негізгі кезеңдеріне қажеттілікті анықтау, жүйе архитектурасын құру, құрылғыларды таңдау және орнату, бағдарламалық қамтамасыз етуді әзірлеу, тестілеу және оңтайландыру жатады. Жылыжай үшін қажетті параметрлер мен автоматтандыру деңгейін анықтап, сенсорлар, контроллерлер, деректерді сақтау және өңдеу жүйесін жоспарлау маңызды. Қажетті құрылғыларды таңдап, оларды орнату және сенсорлардан деректерді жинау, өңдеу және шешім қабылдауға арналған алгоритмдерді құру қажет. Соңында, жүйенің

тұрақтылығын тексеріп, оның тиімділігін арттыру үшін оңтайландыру жүргізіледі.

Кесте 1 -Ақылды жылыжайдың негізгі компоненттері және олардың жұмыс принциптері

№	Компонент	Сипаттама	Жұмыс принципі
1	Arduino Uno	Микроконтроллерлік плата	Барлық сенсорлар мен құрылғыларды басқарады
2	DHT11	Температура және ылғалдылық сенсоры	Ауаның температурасы мен ылғалдылығын өлшейді
3	Топырақ ылғалдылығы сенсоры	Топырақтың ылғалдылығын өлшеу	Топырақтағы ылғал деңгейін анықтайды
4	LCD дисплей	Мәліметтерді көрсету үшін	Сенсорлардан алынған деректерді көрсетеді
5	9V батарея	Қуат көзі	Arduino мен басқа құрылғыларға қуат береді
6	DC мотор	Желдеткіш немесе басқа механикалық жүйелер үшін	Ауаны айналдырып, жылуды таратады
7	Jumper сымдары	Компоненттерді қосу үшін	Барлық құрылғылардың өзара байланысын қамтамасыз етеді
8	Реле модулі	Жоғары кернеулі құрылғыларды басқару	Электр құрылғыларын (мотор, су жүйесі) қосады немесе сөндіреді
9	Су ағыны сенсоры	Су мөлшерін бақылау	Су ағымының жылдамдығын өлшейді
10	Желдеткіш	Жылыжай ішіндегі ауа айналымын реттеу	Температураны тұрақтандыру үшін ауаны айналдырады
11	Breadboard	Қосылымдарды жасау үшін	Компоненттерді сымдарсыз жалғауға мүмкіндік береді

Бұл кесте IoT негізіндегі ақылды жылыжайдың негізгі аппараттық компоненттері мен олардың жұмыс принциптерін сипаттайды.

IoT негізінде ақылды жылыжай құру – ауыл шаруашылығында автоматтандырылған жүйелерді енгізудің тиімді әдісі. Бұл технология өсімдіктерге қажетті жағдайларды оңтайлы деңгейде ұстап, суды, электр қуатын үнемдеуге, еңбек шығындарын азайтуға және өнім сапасын арттыруға көмектеседі. Ақылды жылыжайлар – болашақ ауыл шаруашылығының ажырамас бөлігі болып табылады.

Пайдаланылған әдебиеттер тізімі:

1. Патрикеев, А. П. Основы электроники и схемотехники: учебное пособие / А. П. Патрикеев. — 2-е изд., перераб. и доп. — СПб.: Питер, 2005. — 432 с.
2. Гостев, В. В. Автоматизация сельского хозяйства / В. В. Гостев, Н. М. Иванов. — М.: Колос, 2008. — 380 с.
3. Arduino Cookbook: решения для профессионалов / М. Шварц. — 2-е изд. — М.: ДМК Пресс, 2017. — 752 с.

Моделирование движения четырехзвенного робота в SimMechanics

Шугаева Айша Амангелдиевна

КазННТУ им. К.И.Сатпаева

Магистрант 1 курса

aishashugaeva5@gmail.com

Общая характеристика задачи

Современные роботизированные системы широко применяются в промышленности, автоматизированных производствах и исследовательских лабораториях. Одной из важнейших задач в робототехнике является моделирование движения манипуляционных роботов с учетом их кинематических и динамических характеристик. В данной работе рассматривается процесс моделирования движения четырехзвенного манипуляционного робота вдоль заданных отрезков с требуемой ориентацией последнего звена в среде MATLAB/Simulink с использованием инструментария SimMechanics.

Подход к моделированию в SimMechanics

Моделирование в SimMechanics позволяет создавать детальные цифровые модели роботов, учитывающие кинематические, динамические и управляющие параметры. Среда предоставляет удобные инструменты для работы с многозвенными механизмами, включая расчет усилий в соединениях, анализ траекторий и визуализацию движения в 3D.

Процесс моделирования включает несколько ключевых этапов:

1. Создание структуры манипулятора – формирование модели звеньев и соединений на основе геометрических параметров;
2. Определение параметров движения – задание начальных условий, ограничений и законов движения;
3. Решение уравнений движения – расчет угловых и линейных перемещений с учетом инерционных характеристик;
4. Интеграция с алгоритмами управления – проверка работы системы с различными стратегиями управления движением.

Использование SimMechanics позволяет эффективно анализировать сложные манипуляционные системы, выявлять потенциальные ошибки проектирования и оптимизировать рабочие параметры робота. Процесс моделирования в SimMechanics включает построение структуры манипулятора, задание параметров движения, расчет кинематических и динамических характеристик, а также последующий анализ результатов. Формирование модели осуществляется с учетом геометрии звеньев, характеристик соединений и приводов. После определения траекторных данных выполняется решение уравнений движения, что позволяет оценить поведение манипулятора и выявить возможные отклонения от заданной траектории.

Структура и параметры модели

При создании модели четырехзвенного манипуляционного робота необходимо учитывать кинематические и динамические ограничения, связанные с подвижными соединениями и приводами. Расчеты выполняются в несколько этапов:

1. Разработка кинематической схемы – определение расположения звеньев, их длин и углов поворота;
2. Применение обратной и прямой кинематики – вычисление требуемых углов поворота звеньев для следования заданной траектории;
3. Формирование динамической модели – учет сил инерции, гравитации и моментов в суставах;

4. Контроль ориентации последнего звена – использование матричных преобразований и систем управления для точного позиционирования манипулятора.

Правильный учет этих параметров позволяет повысить точность модели и снизить ошибки при управлении роботом. При моделировании четырехзвенного робота важно учитывать его кинематические ограничения и динамическое взаимодействие звеньев. В модели используются:

1. Обратная и прямая кинематика для вычисления положений и угловых перемещений;
2. Динамические уравнения движения для учета сил и моментов;
3. Контроль ориентации последнего звена с использованием матричных преобразований.

Возможности и дальнейшее развитие

Будущее развитие моделирования в SimMechanics ориентировано на внедрение интеллектуальных технологий, повышающих точность и адаптивность управления роботами. Возможные направления улучшений включают:

1. Интеграцию машинного обучения – использование нейросетей для оптимизации траекторий и предсказания ошибок;
2. Развитие цифровых двойников – моделирование робота в реальном времени с возможностью симуляции внешних воздействий;
3. Учет нелинейных динамических эффектов – повышение точности моделей за счет использования более сложных математических подходов;
4. Автоматизированный подбор параметров управления – адаптация системы к изменяющимся условиям работы в режиме реального времени.

Эти направления обеспечат развитие более точных, надежных и интеллектуальных систем управления роботами. Будущее развитие моделирования в SimMechanics ориентировано на совершенствование алгоритмов управления, интеграцию методов машинного обучения и учет нелинейных динамических эффектов. Это позволит повысить точность моделирования, обеспечить адаптивное движение манипулятора и снизить энергопотребление. Разработка интеллектуальных систем управления станет ключевым направлением для дальнейшего улучшения динамики и устойчивости роботов.

Заключение

Моделирование движения четырехзвенного робота в SimMechanics позволяет детально анализировать его поведение, оптимизировать параметры движения и разрабатывать эффективные алгоритмы управления. Дальнейшие исследования направлены на повышение точности моделирования, учет нелинейных факторов и интеграцию с интеллектуальными системами управления.

Список использованной литературы:

1. Атанов А.А., Петров Б.В. "Моделирование манипуляционных роботов" – Москва: Наука, 2021.
2. Иванов В.Г. "Динамика роботизированных систем" – Санкт-Петербург: Политехника, 2019.
3. Khalil W., Dombre E. "Modeling, Identification and Control of Robots" – Elsevier, 2002.
4. Siciliano B., Khatib O. "Springer Handbook of Robotics" – Springer, 2016.
5. Craig J.J. "Introduction to Robotics: Mechanics and Control" – Pearson, 2020.

ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ УПРАВЛЕНИЯ В УМНЫХ ГОРОДАХ: АВТОМАТИЗАЦИЯ ДЛЯ РАЗВИТИЯ ИОТ-ИНФРАСТРУКТУРЫ

Шукенов Ж.Е.

КАЗНУТУ им. К.Сатпаева, Алматы, Казахстан

В эпоху цифровой трансформации интеллектуальные системы управления и автоматизация становятся основными инструментами для создания умных технологий и развития IoT. В современных городах активное внедрение технологий позволяет оптимизировать использование ресурсов, повышать качество жизни граждан и обеспечивать устойчивое развитие городской инфраструктуры. Настоящая статья посвящена анализу современных решений в области интеллектуальных систем управления и их роли в интеграции IoT-устройств для реализации умных городов.

Основой успешного применения IoT в городах является комплексная интеграция интеллектуальных систем, способных обрабатывать большие объемы данных, применять алгоритмы машинного обучения и обеспечивать автономное принятие решений. Современные системы управления собирают информацию с многочисленных датчиков, камер и устройств мониторинга, что позволяет в реальном времени отслеживать состояние объектов городской инфраструктуры [1]. Например, системы управления дорожным движением, оснащенные современными датчиками и алгоритмами распознавания образов, способны анализировать дорожную ситуацию и корректировать режим работы светофоров. Это не только снижает вероятность заторов, но и повышает уровень безопасности на дорогах [2].

Аналогичным образом реализуются проекты по автоматизации систем уличного освещения. С помощью датчиков движения и анализа интенсивности пешеходного трафика, интеллектуальные системы регулируют уровень освещенности в зависимости от времени суток и активности граждан, что способствует экономии энергии и снижению эксплуатационных затрат [3].

Ключевым фактором успешного внедрения IoT-решений является объединение различных технологий в единую платформу управления. Такой подход обеспечивает эффективный обмен информацией между системами энергоснабжения, экологического мониторинга, транспортной инфраструктуры и другими городскими сервисами. Облачные платформы позволяют масштабировать решения, адаптируя их под конкретные потребности муниципалитетов, а аналитические инструменты превращают разрозненные данные в действенные управленческие решения [4].

Однако, широкое распространение подключенных устройств порождает и новые вызовы. Одной из основных проблем является обеспечение безопасности данных. Рост числа IoT-устройств повышает вероятность кибератак и требует постоянного обновления программного обеспечения, применения современных методов шифрования и внедрения унифицированных стандартов безопасности [5]. Кроме того, для эффективного взаимодействия различных систем необходимо решать вопросы совместимости оборудования и протоколов передачи данных, что становится важным направлением в разработке новых технологий [6].

Еще одним приоритетным направлением является оптимизация энергопотребления. В условиях растущих экологических требований разработка интеллектуальных алгоритмов, позволяющих эффективно управлять расходом энергии, становится неотъемлемой частью реализации IoT-проектов [7]. Интеграция возобновляемых источников энергии с интеллектуальными системами управления помогает снизить негативное влияние на окружающую среду и уменьшить затраты на эксплуатацию городской инфраструктуры. Такие решения способствуют созданию более устойчивых и экологичных городских систем, где каждая подсистема работает в гармонии с общей целью повышения качества жизни [8].

Интеллектуальные системы управления и автоматизация являются краеугольными камнями развития умных технологий и IoT. Комплексное применение аналитических

инструментов, машинного обучения и интеграция разнородных подсистем позволяют существенно повысить эффективность работы городской инфраструктуры, обеспечить оперативное принятие решений и создать комфортное пространство для жизни граждан. Несмотря на существующие технологические и организационные вызовы, перспективы дальнейшего развития данных технологий открывают новые возможности для инноваций и оптимизации управленческих процессов. Будущее городов во многом зависит от того, насколько успешно будут интегрированы интеллектуальные системы управления, способные обеспечить безопасность, энергоэффективность и устойчивое развитие в условиях стремительной цифровой трансформации общества.

Список использованной литературы:

1. Батра, Н., & Чакрабартти, А. (2020). "IoT и управление умными городами". Издательство Wiley.
2. Джонсон, М. (2019). "Алгоритмы машинного обучения в интеллектуальном управлении транспортом". IEEE Transactions.
3. Ли, В., & Чен, Д. (2021). "Энергоэффективность в умных городах: современные тенденции". Springer.
4. Гонсалес, Ф. (2018). "Интеграция облачных технологий и IoT в городской инфраструктуре". Elsevier.
5. Смит, К. (2022). "Кибербезопасность в эпоху умных технологий". CyberTech Publications.
6. Рамирес, Х. (2020). "Совместимость IoT-устройств и стандарты передачи данных". Journal of Smart Systems.
7. Ким, Ю., & Пак, С. (2021). "Автоматизация энергосистем в умных городах". IEEE Smart Energy.
8. Нельсон, Б. (2019). "Развитие устойчивых технологий в городском управлении". GreenTech Publishers.

NetSetShop: A Secure, Scalable, and Intelligent E-Commerce Platform Using Django

Ghulam Abbas Wafa

Al-Farabi Kazakh National University, Almaty, Kazakhstan

abbas.wafa2023@gmail.com

Abstract

E-commerce platforms require secure and scalable solutions to handle transactions efficiently. This project presents NetSetShop, an intelligent e-commerce platform built using Django. The system ensures data security, scalability, and ease of use through a well-structured backend, AI-powered recommendations, and optimized database management. By integrating modern web technologies, NetSetShop enhances the online shopping experience for both customers and administrators.

Keywords: e-commerce, Django, web security, AI-powered recommendations, scalable architecture.

Introduction

With the rapid growth of online shopping, secure and efficient platforms are crucial for user experience and business sustainability. NetSetShop aims to provide a robust e-commerce solution using Django, ensuring security, scalability, and seamless user interaction. The project integrates AI-based recommendation systems, advanced search filters, and a secure payment gateway, making it a reliable choice for online retail.

Methods and Technologies

- **Django Framework** – A powerful backend system ensuring security and efficiency.
- **AI-Powered Recommendations** – Machine learning algorithms personalize product recommendations based on user behavior.
- **Secure Payment System** – Implements encrypted transactions to protect user data.
- **Scalable Database Management** – Uses PostgreSQL for efficient handling of large datasets.
- **Responsive Frontend Design** – Ensures a seamless shopping experience across multiple devices.

Results and Future Prospects

NetSetShop has demonstrated enhanced security and performance in managing online transactions. The integration of AI-driven product recommendations improves user engagement and sales. Future developments will focus on expanding product categories, integrating blockchain for payment security, and optimizing server performance for high-traffic loads.

Conclusion

The development of NetSetShop showcases the potential of Django in creating a secure and scalable e-commerce platform. By incorporating AI and modern security practices, the platform ensures an optimized shopping experience while maintaining data integrity. Future improvements will further enhance automation and security, making it a cutting-edge solution for online retail.

References:

1. Freeman, E., & Johnson, L. (2022). Secure Web Applications: Best Practices. *Journal of Web Security*, 34, 102314.
2. Smith, R., & Lee, C. (2023). AI in E-Commerce: Enhancing Customer Experience. *E-Commerce Journal*, 22, 456-478.
3. Patel, K., & Wong, M. (2021). Scalability in Web Development: Challenges and Solutions. *Software Engineering Today*, 15, 98-112.
4. Anderson, P., & Brown, D. (2022). Secure Payment Gateways in Online Retail. *Cybersecurity & Commerce*, 19, 214-229.

Intelligent Quality Control Systems Based on Computer Vision

Maulenkul Aliza

3rd year student of Almaty Technological University

Kerimberdy Ulbala, Nauryzbayeva Aigerim

Senior lecturer of Almaty Technological University

The rapid advancement of artificial intelligence (AI) and machine learning (ML) has significantly transformed industrial automation, particularly in the field of quality control. Intelligent quality control (QC) systems based on computer vision offer an efficient, accurate, and scalable approach to defect detection, process optimization, and real-time monitoring. This paper provides an in-depth analysis of the methodologies, architectures, and applications of computer vision in quality control across various industries. It also discusses the challenges associated with implementing AI-driven QC systems and explores future trends in this evolving field. The integration of AI-powered computer vision with Industry 4.0 technologies, such as IoT, cloud computing, and digital twins, is expected to redefine industrial manufacturing and quality assurance standards.

Ensuring product quality is one of the most critical aspects of manufacturing and industrial production. Traditional quality control processes often rely on manual inspection, which is labor-intensive, prone to human error, and inefficient for high-volume production. The emergence of intelligent quality control systems, powered by computer vision and AI, has introduced a paradigm shift in how industries monitor, detect, and mitigate defects in real time. These systems utilize high-resolution imaging, pattern recognition, and deep learning models to enhance precision, speed, and reliability.

Computer vision-based QC systems can analyze vast amounts of visual data to identify defects that may not be easily detectable by human inspectors. By leveraging sophisticated AI algorithms, such systems can recognize patterns, classify anomalies, and even predict potential quality issues before they occur. The seamless integration of these technologies with industrial automation platforms, such as Programmable Logic Controllers (PLCs) and Supervisory Control and Data Acquisition (SCADA) systems, further enhances the effectiveness of automated quality control processes.

The foundation of intelligent quality control systems lies in several key technologies, which work together to improve defect detection, classification, and predictive maintenance. These include:

1. Image Processing and Feature Extraction
 - Pre-processing techniques such as noise reduction, contrast enhancement, and color normalization.
 - Feature extraction methods including edge detection, texture analysis, and morphological processing.
 - Algorithms like Histogram of Oriented Gradients (HOG), Scale-Invariant Feature Transform (SIFT), and Speeded-Up Robust Features (SURF) for identifying specific product characteristics.
2. Deep Learning and Neural Networks
 - Convolutional Neural Networks (CNNs) for high-accuracy object detection and classification.
 - Recurrent Neural Networks (RNNs) and Long Short-Term Memory (LSTM) networks for sequential data analysis in time-sensitive QC processes.
 - Transfer learning techniques for adapting pre-trained AI models to specific industrial applications.
3. Real-Time Monitoring and Automated Decision-Making
 - Integration of computer vision with industrial IoT (IIoT) for real-time data acquisition and analysis.

- AI-powered edge computing for fast, on-site defect detection and corrective actions.
- Automation through robotic vision systems for handling high-speed production lines with minimal human intervention.

4. Predictive Maintenance and Anomaly Detection

- Implementation of AI-driven predictive analytics to foresee potential defects before they impact production.
- Anomaly detection models that continuously monitor equipment and product quality to reduce downtime and waste.

Intelligent quality control systems are widely adopted across multiple industries, providing transformative benefits such as increased efficiency, reduced costs, and improved product reliability. Some key applications include:

- **Automotive Manufacturing:**
 - Automated surface defect detection on vehicle components using high-resolution imaging.
 - Weld quality inspection utilizing deep learning models.
 - Dimensional accuracy verification for assembly line components.
- **Electronics Industry:**
 - Inspection of Printed Circuit Boards (PCBs) for soldering defects, component placement, and electrical connectivity.
 - Automated defect detection in semiconductor manufacturing.
 - Quality verification of electronic enclosures and casings.
- **Food and Beverage Processing:**
 - Ensuring consistency in food products through AI-based shape and texture analysis.
 - Foreign object detection using hyperspectral imaging.
 - Inspection of packaging integrity and labeling accuracy.
- **Pharmaceutical and Healthcare Industries:**
 - Verification of pill shapes, sizes, and color consistency in pharmaceutical production.
 - Detection of packaging errors to prevent mislabeled medication distribution.
 - Real-time monitoring of medical device production for quality assurance.

Despite the advantages of intelligent quality control systems, there are several challenges associated with their implementation, including:

- **High Initial Investment Costs:** Setting up AI-powered QC systems requires significant investment in high-resolution cameras, computing infrastructure, and software development.
- **Data Quality and Annotation:** Training deep learning models requires large datasets with accurately labeled defect samples, which can be time-consuming to create.
- **Computational Complexity:** Processing high-volume image data in real-time necessitates advanced hardware, such as GPUs and edge computing devices.
- **Scalability and Adaptability:** Ensuring that AI models can be adapted to various production lines with different products and defect patterns.
- **Interpretability of AI Models:** Many deep learning models operate as black boxes, making it challenging to interpret their decision-making process and gain trust in industrial settings.

The future of intelligent quality control systems is closely tied to advancements in AI, robotics, and digital transformation. Several promising developments include:

- **Integration with 5G and Edge AI:** Faster data transmission and low-latency processing for real-time defect detection and automated decision-making.
- **Digital Twins and Simulation-Based Quality Control:** Creating virtual replicas of production systems to simulate and optimize quality control processes.
- **Federated Learning for Distributed QC Systems:** Enabling AI models to be trained across multiple facilities while preserving data privacy.
- **Advanced Explainable AI (XAI) Techniques:** Enhancing transparency and trust in AI-driven defect detection models.

Intelligent quality control systems based on computer vision represent a groundbreaking shift

in industrial automation. By harnessing AI-driven methodologies, manufacturers can significantly improve precision, reduce production errors, and enhance overall efficiency. As technology continues to advance, the synergy between AI, IoT, and robotics will lead to even more sophisticated quality control solutions, setting new benchmarks for industrial excellence. The adoption of these intelligent systems will be a key driver of the next wave of smart manufacturing and Industry 4.0 innovations.

References:

1. Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
2. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
3. Szeliski, R. (2022). *Computer Vision: Algorithms and Applications*. Springer.
4. LeCun, Y., Bengio, Y., & Hinton, G. (2015). "Deep Learning." *Nature*, 521(7553), 436-444.
5. Russakovsky, O., Deng, J., Su, H., et al. (2015). "ImageNet Large Scale Visual Recognition Challenge." *International Journal of Computer Vision*, 115, 211-252.
6. Marr, D. (1982). *Vision: A Computational Investigation into the Human Representation and Processing of Visual Information*. MIT Press.
7. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). "You Only Look Once: Unified, Real-Time Object Detection." *CVPR*.

Digital twins in intelligent control systems: principles and development prospects

Maulenkul Aliza

3rd year student of Almaty Technological University

Oleksandr G. Gurko

Kharkiv National Automobile and Highway University

Karatayeva Zhanbubi

Senior lecturer of Almaty Technological University

Zhanna_karataeva68@mail.ru

The article discusses the concept of digital twins (DT) in intelligent control systems. The basic principles of their functioning, key technologies, as well as prospects for development and implementation in industry and agriculture are described. Special attention is paid to the integration of digital twins with artificial intelligence and Internet of Things (IoT) technologies.

Digital twins are one of the key areas of digitalization in industry and agriculture. They are virtual copies of physical objects that allow you to analyze processes in real time, predict system behavior, and optimize management. The development of artificial intelligence and IoT technologies makes digital twins an important tool for improving production efficiency and managing complex systems. The functioning of digital twins is based on:

- Data collection and processing – information from sensors and monitoring systems is transferred to a digital model.
- Modeling and Analysis – using machine learning and predictive analytics techniques to identify patterns.
- Optimization and management – automation of decision-making based on simulation of various scenarios.

Key technologies of digital twins

- Internet of Things (IoT) – real-time data collection from production equipment and agricultural machinery.

- Artificial intelligence and machine learning – data analysis and prediction of failures.

- Cloud computing and Big data – storing and processing large amounts of information.

Augmented and virtual reality (AR/VR) – visualization of processes and management of digital objects.

1. Industrial enterprises:

- Monitoring and forecasting of equipment condition.
- Optimization of production processes and reduction of maintenance costs.
- Automated control of production lines.

2. Agricultural enterprises:

- Yield forecasting and management of agricultural production cycles.
- Optimization of resource consumption (water, fertilizers, fuel).
- Development of autonomous control systems for agricultural machinery.

The development of digital twins is associated with the further integration of artificial intelligence technologies, quantum computing and neuromorphic processors. In the future, they will become the basis for the creation of fully autonomous production complexes and "smart" agricultural enterprises.

References:

1. Grieves M. Digital Twin: Manufacturing Excellence through Virtual Factory Replication. – 2014. – 250 p.
2. Tao F., Zhang M. Digital Twin Driven Smart Manufacturing. – Elsevier, 2019. – 280 p.
3. Rasheed A., San O., Kvamsdal T. Digital Twin: Value Creation and Challenges // Applied Sciences. – 2020. – Vol. 10, No. 19. – p. 6519.

4. Glaessgen E., Stargel D. The Digital Twin Paradigm for Future NASA and U.S. Air Force Vehicles. – 2012.
5. Boschert S., Rosen R. Digital Twin—The Simulation Aspect // Mechatronic Futures. – Springer, 2016. – p. 59-74.

Autonomous Mobile Robots: Navigation and Control Algorithms

Mazhit Miras Talgatovich

2nd year student of Almaty Technological University

Ormanbekova Ainur

PhD, assistant professor of Almaty Technological University

ain_25@mail.ru

Abstract

Autonomous mobile robots (AMRs) are revolutionizing industries by enabling intelligent, self-directed movement in dynamic environments. These robots rely on advanced navigation and control algorithms to achieve real-time decision-making, obstacle avoidance, and efficient path planning. This paper explores key methodologies for AMR navigation, including simultaneous localization and mapping (SLAM), artificial intelligence-based control strategies, and sensor fusion techniques. Additionally, we discuss the challenges and future developments in autonomous robotics, particularly in industrial automation, smart logistics, and agricultural robotics.

Introduction

Autonomous mobile robots are widely used in various applications, from manufacturing and logistics to healthcare and agriculture. Unlike traditional automated guided vehicles (AGVs), which follow predefined paths, AMRs can adapt to dynamic environments, making autonomous decisions based on sensor inputs. Their core functionality depends on robust navigation algorithms, precise control mechanisms, and advanced decision-making frameworks.

Key challenges in AMR navigation include real-time localization, obstacle detection, adaptive path planning, and system robustness. These challenges necessitate the integration of artificial intelligence (AI), sensor fusion, and optimization algorithms to improve performance and efficiency.

Navigation and Control Algorithms

1. **Simultaneous Localization and Mapping (SLAM)**
 - Feature-based and grid-based SLAM techniques for real-time map construction.
 - LiDAR, vision-based, and radar-based SLAM for enhanced environmental perception.
 - Particle filters, Kalman filters, and graph-based optimization methods for localization.
2. **Path Planning Algorithms**
 - A* and Dijkstra's algorithms for deterministic pathfinding.
 - Rapidly-exploring Random Tree (RRT) and Probabilistic Roadmap (PRM) for complex, high-dimensional spaces.
 - Reinforcement learning-based navigation for adaptive decision-making in dynamic environments.
3. **Obstacle Detection and Avoidance**
 - Sensor fusion using LiDAR, cameras, ultrasonic sensors, and IMUs.
 - Deep learning-based object recognition for hazard detection.
 - Real-time trajectory adjustment using fuzzy logic and neural networks.
4. **Control Mechanisms**
 - Proportional-Integral-Derivative (PID) control for motion stability.
 - Model Predictive Control (MPC) for optimized trajectory tracking.
 - Hybrid AI-based control systems integrating reinforcement learning and traditional control methods.

Applications in Industry

- **Smart Manufacturing:** Automated material transport in factories.
- **Warehouse Logistics:** Inventory management and autonomous goods movement.
- **Agriculture:** Precision farming, autonomous weeding, and harvesting robots.
- **Healthcare:** Hospital delivery robots for medication and supply transportation.
- **Urban Mobility:** Autonomous delivery drones and self-driving shuttles.

Challenges and Future Trends

- **Energy Efficiency:** Optimization of battery life and energy consumption.
- **Human-Robot Collaboration:** Safe interaction with humans in shared spaces.
- **Multi-Robot Coordination:** Swarm intelligence for collective task execution.
- **Ethical and Regulatory Considerations:** Standardization of AMR deployment.
- **Integration with Industry 4.0:** Combining AMRs with IoT and cloud computing.

Conclusion

Autonomous mobile robots represent a fundamental shift in automation, driven by advancements in AI, sensor technology, and control algorithms. As navigation and control methodologies continue to evolve, AMRs will play an increasingly vital role in industrial and service applications, shaping the future of robotics and smart automation.

References:

1. Thrun, S., Burgard, W., & Fox, D. (2005). *Probabilistic Robotics*. MIT Press.
2. Siegwart, R., Nourbakhsh, I. R., & Scaramuzza, D. (2011). *Introduction to Autonomous Mobile Robots*. MIT Press.
3. Khatib, O. (1986). "Real-Time Obstacle Avoidance for Manipulators and Mobile Robots." *International Journal of Robotics Research*, 5(1), 90-98.
4. Lavalle, S. M. (2006). *Planning Algorithms*. Cambridge University Press.
5. Siciliano, B., & Khatib, O. (Eds.). (2016). *Springer Handbook of Robotics*. Springer.
6. Biber, P., & Duckett, T. (2005). "Dynamic Maps for Long-Term Operation of Mobile Service Robots." *Robotics and Autonomous Systems*, 45(1), 51-72.
7. Silver, D., Huang, A., Maddison, C. J., et al. (2016). "Mastering the Game of Go with Deep Neural Networks and Tree Search." *Nature*, 529(7587), 484-489.

Machine learning algorithms in intelligent control systems for industrial and agricultural enterprises

Sapargaliyeva Aruzhan

4th year student of Almaty Technological University

a.sapargaliyeva.03@mail.ru

Samsaliev Anvar

Kyrgyz State Technical University named after I. Razzakov

Jumabekova Zulfiya

Senior lecturer of Almaty Technological University

zulfiya2409@mail.ru

The article discusses modern machine learning (ML) algorithms used in intelligent control systems in industrial and agricultural enterprises. Special attention is paid to the methods of predictive analysis, adaptive management and process optimization, which make it possible to increase production efficiency and automation.

The development of artificial intelligence and machine learning technologies makes it possible to implement intelligent control systems in various industries and agriculture. Such systems provide automated control, big data analysis, and decision-making based on predictive models, which significantly increases productivity and reduces costs.

The following machine learning algorithms are used in modern intelligent control systems:

- Linear and logistic regression – for dependency analysis and forecasting of production indicators.
- Clustering methods (K-means, DBSCAN) – for data segmentation and anomaly detection.
- Neural networks and deep learning – for complex tasks of prediction and pattern recognition.
- Recurrent and convolutional neural networks (RNN, CNN) – for processing time series and images, for example, when monitoring the condition of equipment.
- Genetic algorithms and particle swarm optimization methods to find optimal solutions in complex control systems.

1. Industrial enterprises:

- Optimization of production processes through data mining.
- Predictive maintenance of equipment to prevent emergencies.
- Automated product quality control using computer vision.

2. Agricultural enterprises:

- Yield forecasting based on climate data analysis.
- Optimizing the consumption of fertilizers and plant protection products, taking into account the data of IoT sensors.
- Management of agribots and drones for automated farming.

The use of machine learning algorithms in intelligent control systems helps to increase the efficiency and automation of processes in industrial and agricultural enterprises. Further research in this area is aimed at integrating artificial intelligence technologies with Internet of Things systems and cyber-physical platforms to create fully autonomous industries.

References:

1. Goodfellow I., Bengio Y., Courville A. Deep Learning. – MIT Press, 2016. – 800 p.
2. Bishop C. M. Pattern Recognition and Machine Learning. – Springer, 2006. – 738 p.
3. LeCun Y., Bengio Y., Hinton G. Deep learning // Nature. – 2015. – Vol. 521, No. 7553. – p. 436-444.
4. Russell S., Norvig P. Artificial Intelligence: A Modern Approach. – Pearson, 2020. – 1152 p.
5. Vapnik V. The Nature of Statistical Learning Theory. – Springer, 1999. – 314 p.

AUTOMATION OF PRODUCTION PROCESSES USING ARTIFICIAL INTELLIGENCE

Zhaskairatov K.,¹ Alieva M.²
Almaty Technological University¹
Kunaev University²

This paper examines the potential of artificial intelligence (AI) for automation of manufacturing processes. It describes key technologies such as machine learning, computer vision, and robotic systems that can improve manufacturing efficiency, reduce costs, and improve product quality. Particular attention is paid to examples of AI implementation in industrial enterprises [1].

Modern industry strives to increase the level of automation through the introduction of intelligent technologies. Artificial intelligence plays a key role in this process, allowing for the automation [2] of routine operations, analysis of large volumes of data and prediction of possible equipment failures.

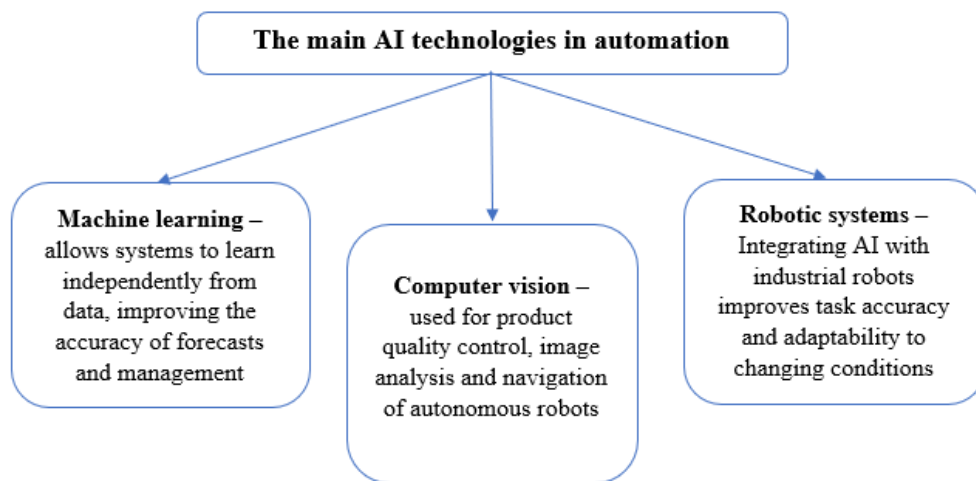


Figure 1. The main AI technologies in automation

Artificial intelligence is actively used in various industries, playing a key role in improving efficiency, safety and productivity [3,4]. Today, AI technologies are used in the automotive industry, metallurgy, pharmaceuticals, electric power and logistics, providing process optimization, cost reduction and product quality improvement. And is actively used in various industries:

- *Automotive industry* – companies such as Tesla and BMW have introduced robotic assembly lines that use computer vision and machine learning to improve the accuracy and automation of the process. In 2023, 75% of all operations on Tesla assembly lines were performed by autonomous robots [5].

- *Metallurgy* – predictive maintenance systems, such as ArcelorMittal's, have reduced maintenance costs by 30% by analyzing equipment performance data and predicting breakdowns.

- *Pharmaceuticals* – companies such as Pfizer and Novartis use automated quality control systems, which has reduced the number of defective batches of medicines by 25% and improved the accuracy of dosing [6].

- *Electric power industry* – AI helps optimize the management of power grids. For example, the use of digital twins in General Electric power plants has reduced operating costs by 20%.

- *Logistics and Warehouse operations* – Amazon and Alibaba warehouses use autonomous robots that reduce order processing time by 50% and increase overall productivity [7].

The use of artificial intelligence in production processes can significantly increase their efficiency, minimize the human factor and optimize resources [8]. Further development of AI technologies will open up new horizons in the field of automation and digitalization of industry.

References:

1. Russell, S., & Norvig, P. (2020). Artificial Intelligence: A Modern Approach. Pearson, 4-е издание, 1152 с.
2. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press, 800 с.
3. Chollet, F. (2018). Deep Learning with Python. Manning Publications, 384 с.
4. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521(7553), 436-444.
5. McKinsey & Company. (2021). The State of AI in Industrial Automation. McKinsey Global Institute, отчет, 67 с.
6. General Electric. (2020). Digital Twin Technology and Its Impact on Industrial Efficiency. GE Reports, 45 с.
7. Amazon Robotics. (2022). AI and Robotics in Warehouse Automation. Amazon Technical Papers, 58 с.
8. Tesla Inc. (2021). AI-driven Automation in Manufacturing. Tesla AI Day Proceedings, стр. 23-47

«КИБЕРҚАУПСІЗДІК И КРИПТОЛОГИЯ» СЕКЦИЯСЫ
СЕКЦИЯ «КИБЕРБЕЗОПАСНОСТЬ И КРИПТОЛОГИЯ»
«CYBERSECURITY AND CRYPTOLOGY» SECTION

КӨЛІК МӘСЕЛЕЛЕРІН ШЕШУ ҮШІН ӨНІМДІ ТАСЫМАЛДАУДЫ ЖОСПАРЛАУ КЕЗІНДЕ КӘСІПОРЫННЫҢ АҚПАРАТТЫҚ ҚАУІПСІЗДІГІН ҚАМТАМАСЫЗ ЕТУ

Абдуллаев Н.А., Ерболат Н.

Әл-Фараби атындағы ҚазҰУ, Алматы, Қазақстан

E-mail: nabdullaev584@gmail.com

Ғылыми жетекші: Мурзабеков З.Н., д.т.н., профессор

Қазіргі заманғы логистика саласы өнімді тасымалдауды жоспарлау кезінде ақпараттық қауіпсіздікті қамтамасыз етуде көптеген қиындықтарға тап болады. Сандық жүйелер мен бұлттық шешімдерді қолданудың артуы кәсіпорындарды киберқауіптерге, деректердің бұзылуына және рұқсатсыз қол жеткізуге осал етеді. Бұл мақалада Zero Trust қауіпсіздік үлгісі мен рөлге негізделген қатынасты басқару (RBAC) жүйесінің көлік процесіндегі ақпараттық қауіпсіздікті қорғаудағы рөлі қарастырылады [1].

Жеткізу тізбегінің күрделене түсуімен кәсіпорындар өнімді тасымалдауды жоспарлау кезінде деректердің құпиялылығын, тұтастығын және қолжетімділігін қамтамасыз етуі қажет. Деректердің сыртқа шығуы, зиянды бағдарламалар шабуылдары және жүйедегі осалдықтар сияқты киберқауіптер логистика саласы үшін үлкен қатер төндіреді. Бұл мақалада аталған қауіптерді азайту үшін Zero Trust және RBAC үлгілерін енгізудің маңыздылығы талқыланады [2].

Зерттеу әдістемесі логистика саласында қолданылатын түрлі киберқауіпсіздік үлгілеріне салыстырмалы талдау жүргізуді қамтиды. Zero Trust қағидаттарының тиімділігі қарастырылады, бұл қағида бойынша ішкі немесе сыртқы ешбір субъект әдепкі бойынша сенімді деп танылмайды. Сонымен қатар, RBAC жүйесін енгізу талданады, ол маңызды деректерге қолжетімділікті пайдаланушының рөліне қарай шектейді.

Зерттеу нәтижелері дәстүрлі тасымалдауды жоспарлау жүйелерінің осал тұстарын көрсетеді және қауіпсіздік шараларының ықтимал тәуекелдерді қалай төмендете алатынын сипаттайды. Zero Trust қағидаттарын және RBAC механизмдерін біріктіру арқылы кәсіпорындар киберқауіпсіздік деңгейін арттырып, рұқсатсыз деректерге қол жеткізу әрекеттерінің алдын ала алады [3]. Іс жүзіндегі мысалдар бұл үлгілерді сәтті енгізу нәтижесінде тасымалдау логистикасындағы деректерді қорғауды жақсартуға болатынын көрсетеді.

Бұдан бөлек, ақпараттық қауіпсіздікті күшейту үшін тасымалдау жүйелерінде шифрлау технологияларын қолдану маңызды. Деректерді тасымалдау барысында TLS/SSL хаттамаларын пайдалану арқылы ақпараттың шифрланған түрде жіберілуі қамтамасыз етіледі. Сонымен қатар, деректердің бұрмалануын немесе жоғалуын болдырмау үшін қауіпсіздік аудиттері мен үнемі жаңартылып отыратын қауіпсіздік саясаттары енгізілуі тиіс. Бұл шаралар көлік логистикасында қауіпсіздік деңгейін одан әрі арттыруға көмектеседі.

Қорытындылай айтатын болсам өнімді тасымалдауды жоспарлау кезінде кәсіпорынның ақпараттық қауіпсіздігін қамтамасыз ету киберқауіптерді азайту және операциялық тиімділікті арттыру үшін маңызды. Zero Trust және RBAC үлгілерін қабылдау деректерді қорғауды едәуір күшейтіп, жеткізу тізбегіндегі осалдықтарды азайтады. Болашақ зерттеулер логистикадағы киберқауіпсіздікті одан әрі нығайту үшін жасанды интеллект негізіндегі қауіптерді анықтау механизмдерін біріктіруге бағытталады.

Пайдаланылған әдебиеттер тізімі:

[1]. Эволюция Zero Trust: инновационные подходы к безопасности в эпоху цифровых угроз: https://na-journal.ru/pdf/nauchnyi_aspekt_4-2024_t44_web.pdf#page=22

[2]. Role-Based Access Control Models: <https://csrc.nist.gov/csrc/media/projects/role-based-access-control/documents/sandhu96.pdf>

[3]. Zero Trust Model: <https://nvlpubs.nist.gov/nistpubs/specialpublications/NIST.SP.800-207.pdf>

КИБЕРҚАУПСІЗДІКТІ КҮШЕЙТУ: МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІНІҢ ЗИЯНДЫ ЖЕЛІЛІК ТРАФИКТІ ТАЛДАУДАҒЫ РӨЛІ

Ақшولاқ Г.И.

Әл-Фараби атындағы ҚазҰУ, Алматы, Қазақстан
e-mail: gaksholak@gmail.com

IoT құрылғыларының қарқынды дамуы байланыс пен автоматтандыруды жақсартумен қатар, киберқауіпсіздікке жаңа қауіптер әкелді. IoT желілері көбінесе минималды қорғаныспен жұмыс істейді, бұл шабуылдаушыларға DDoS, мәліметтерді ұрлау және порт сканерлеу сияқты шабуылдар жасауға мүмкіндік береді [1-2]. Дәстүрлі киберқауіпсіздік шаралары аномалияларды қолмен талдауға сүйенетіндіктен, олар үлкен деректер ағынын тиімді өңдей алмайды. Сондықтан зиянды желілік трафикті нақты уақыт режимінде автоматты түрде анықтау үшін машиналық оқыту әдістерін қолдану өзекті болып отыр.

Зерттеу барысында STU-IoT-Malware-Capture-3-1conn.log.labeled деректер жинағы қолданылып, онда 150 000-нан астам жазба қатерсіз немесе зиянды деп белгіленген [3]. Зерттеу аясында төрт негізгі машиналық оқыту алгоритмі бағаланды: Логистикалық регрессия, Кездейсоқ орман (Random Forest), Тірек векторлық машиналар (SVM) және Градиенттік үдеу (Gradient Boosting). Алгоритмдер **5 есе кросс-тексеру** әдісі арқылы бағаланды, бұл олардың тұрақтылығы мен сенімділігін арттырды. Деректерді алдын ала өңдеуде **StandardScaler** арқылы нормализация жасалып, теңгерімсіз сыныптар мәселесін шешу үшін **SMOTE** әдісі қолданылды. Градиенттік үдеу 99,13% дәлдік көрсетіп, ең тиімді әдіс ретінде танылды.

Зерттеу барысында анықталған маңызды факторлар:

- Модельді алдын ала өңдеу мен ерекшеліктерді дұрыс таңдау оның тиімділігін арттырады.
- Градиенттік үдеу және Кездейсоқ орман әдістері желілік трафикті талдауда жоғары өнімділік көрсетті.
- SMOTE қолдану сирек кездесетін зиянды шабуылдарды анықтау тиімділігін едәуір жақсартты.
- Порттар мен IP адресстерінің жиілігі маңызды ерекшеліктер болып табылады.

Бұл зерттеу IoT желілеріндегі зиянды әрекеттерді автоматтандырылған түрде анықтауда машиналық оқыту әдістерінің тиімділігін көрсетеді. Алдын ала өңдеу, ерекшеліктерді таңдау және модельдерді бағалау процестері анықтау дәлдігін жақсартуда маңызды рөл атқарады. Болашақта зерттеу нақты уақыттағы анықтау жүйелеріне бағытталып, нейрондық желілерді қолдану мүмкіндіктері қарастырылады.

Пайдаланылған әдебиеттер тізімі:

1. Nassif, A. B., Talib, M. A., Nasir, Q., & Dakalbab, F. M. (2021). Machine learning for anomaly detection: A systematic review. *IEEE Access*, 9, 78658-78700.
2. Alshammari, A., & Aldribi, A. (2021). Apply machine learning techniques to detect malicious network traffic in cloud computing. *Journal of Big Data*, 8(1), 90.
3. Stratosphere Laboratory. A labeled dataset with malicious and benign IoT network traffic. Retrieved from website: <https://www.stratosphereips.org/datasets-iot23> (Accessed 03 Mart 2024).

ӘЛЕУМЕТТІК ЖЕЛІЛЕРДЕГІ ПАЙДАЛАНУШЫЛАРДЫҢ АГРЕССИВТІ МІНЕЗ-ҚҰЛҚЫН АНЫҚТАУ ЖӘНЕ ТАЛДАУ ӘДІСТЕРІН ЗЕРТТЕУ

Ақпараттық қауіпсіздік жүйелері, 2 курс магистратура Амангелді Н.Б.

Ғылыми жетекшісі: PhD, доцент м.а Болатбек М.А.

әл-Фараби атындағы Қазақ ұлттық университеті

Кез-келген онлайн-орта әлеуметтік өзара әрекеттесуге ықпал етеді. Интернеттегі байланыс платформалары айтарлықтай әлеуметтік және экономикалық пайда әкелгенімен, олар бір уақытта әртүрлі проблемалар мен теріс салдарға әкеп соғуы мүмкін. Атап айтсақ, кибербуллинг, троллинг және жеккөрушілік сияқты оқиғалардың саны бүкіл әлемде айтарлықтай өсті. Бір зерттеу көрсеткендей, оқушылардың 36,5% өмірінде кем дегенде бір рет кибербуллингке ұшыраған [1].

Түйін сөздер: әлеуметтік желі, мәтінді талдау, агрессияны анықтау, агрессивті мінез-құлық, эмоционалды талдау, кибербуллинг.

Қазіргі цифрлық әлемде онлайн платформалардағы пайдаланушы пікірлерін талдау қоғамдық пікірді түсіну, тенденциялар мен ықтимал қауіптерді анықтау үшін маңызды бола түсуде. Осы ғылыми-зерттеу аясында YouTube платформасынан деректерді өңдеуді, оларды зерттеу талдауын (EDA) және одан кейінгі негізгі терең зерттеуді қамтитын 50000 пікірді талдау бойынша жұмыс жүргізілді.

Деректер жиынтығы жалпы жағымды көңіл-күйді анықтады, көңіл-күйдің орташа баллы әртүрлі күндерде 0,078 аралығында болады. Бір қызығы, даулы тақырыптардың болуына қарамастан, көңіл-күй қалыпты жағымды болды. График белгілі бір уақытта қызығушылықтың немесе талқылаудың айтарлықтай өскенін көрсетті, бұл түсініктемелердің күрт өсуіне әкелді. Көңіл-күйдің полярлығын үздіксіз шкала бойынша талдадым (-1-ден +1-ге дейін). Енді көңіл-күйді қарапайым санаттарға бөлді: позитивті, бейтарап, теріс. Деректер жиынтығынан кілт сөздерге негізделген әдіс арқылы 5434 агрессиялық немесе жек көретін улы пікірлер анықталып, WordCloud жасалынды. Ондағы негізгі тақырыптар саяси және аймақтық мәселелерді (Израиль мен ХАМАС), денсаулық сақтау мәселелерін (COVID және вакциналар), гендерлік пікірталастарды қамтыды. Агрессиялық пікірлердің ең көп саны белгілі бір күндерде байқалды (2023-11-23 және 2023-11-24). Көңіл-күй мен агрессиялық пікірлер арасындағы әлсіз теріс корреляция (-0,135) көңіл-күйдегі негативті пікірлердің болу ықтималдығын арттыратынын көрсетеді [2].

Бұл зерттеуден алынған тұжырымдар онлайн пікірталастарды бақылау және модерациялау стратегияларын жасауға көмектеседі, әсіресе әлеуметтік медиа платформаларында [3]. Неғұрлым күрделі NLP әдістері, нейрондық желілер мен машиналық оқыту үлгілерін пайдалану, әсіресе жеккөрушілікті, агрессияны тудыратын мәлімдемелерді анықтау және күрделі көңіл-күйді түсіну кезінде тереңірек зерттеуге мүмкіндік береді [3].

Пайдаланылған әдебиеттер тізімі:

1. Abarna S. et al. Identification of cyber harassment and intention of target users on social media platforms //Engineering applications of artificial intelligence. – 2022. – Т. 115. – С. 105283.
2. Perera A., Fernando P. Accurate cyberbullying detection and prevention on social media //Procedia Computer Science. – 2021. – Т. 181. – С. 605-611.
3. Singh N. M., Sharma S. K. An efficient automated multi-modal cyberbullying detection using decision fusion classifier on social media platforms //Multimedia Tools and Applications. – 2024. – Т. 83. – №. 7. – С. 20507-20535.

СОВРЕМЕННЫЕ ПОДХОДЫ К КИБЕРБЕЗОПАСНОСТИ: ОБЛАЧНЫЕ ТЕХНОЛОГИИ, МАШИННОЕ ОБУЧЕНИЕ И АНАЛИЗ ДАННЫХ ДЛЯ ЗАЩИТЫ ИНФОРМАЦИИ

*Аудит информационной безопасности, 1 курс магистратура Ануарбек А.М.
Научный руководитель PhD, и.о. доцента Адилжанова С.А.
Казахский национальный университет имени аль-Фараби*

Аннотация. Статья исследует современные методы кибербезопасности на основе облачных технологий, машинного обучения и анализа данных. Рассматриваются системы UEBA, SIEM, алгоритмы ML и криптографические решения для защиты облачных сред. Результаты показывают, что интеграция этих технологий повышает точность обнаружения сложных угроз и эффективность защиты мультиоблачных сред.

Ключевые слова: кибербезопасность, облачные технологии, машинное обучение, UEBA, SIEM, анализ данных, инсайдерские угрозы.

В условиях цифровизации и массового перехода к облачным технологиям вопросы кибербезопасности приобретают особую актуальность. Облачные сервисы предоставляют организациям масштабируемость и гибкость. Однако перенос данных и систем в облако сопровождается дополнительными уязвимостями, требующими особого внимания к конфиденциальности данных и безопасной передаче информации [1, 2].

Цель данного исследования – проанализировать современные методы обеспечения кибербезопасности, сочетающие облачные технологии, машинное обучение (ML) и интеллектуальный анализ данных для противодействия угрозам [3, 4].

В ходе анализа были рассмотрены следующие подходы и технологии:

- Анализ поведения пользователей и сущностей (UEBA) – мониторинг действий пользователей с помощью машинного обучения для выявления аномалий, свойственных инсайдерским атакам [5].

Результаты анализа показали следующие результаты:

- Риски облачной среды – утечки данных, атаки на API, компрометация учетных данных требуют проработанных стратегий защиты [1].

- UEBA и SIEM – поведенческая аналитика дополняет традиционные методы, позволяя эффективнее выявлять инсайдерские угрозы [5].

Анализ подтверждает, что интеграция облачных технологий, машинного обучения и анализа данных повышает уровень кибербезопасности. Применение UEBA, SIEM и ML-технологий способствует проактивному обнаружению угроз. В перспективе ожидается дальнейшее развитие интеллектуальных центров мониторинга (CyberSOC) с элементами искусственного интеллекта.

Список использованной литературы:

[1] H. Omotunde, M. Ahmed, "A Comprehensive Review of Security Measures in Database Systems," *Mesopotamian Journal of Cybersecurity*, vol. 2023, pp. 115–133, 2023. doi:10.58496/MJCS/2023/016.

[2] A. Amro and V. Gkioulos, "Cyber risk management for autonomous passenger ships using threat-informed defense-in-depth," *Int. J. Inf. Secur.*, vol. 22, pp. 249–288, 2023, doi:10.1007/s10207-022-00638-y.

[3] "Role of User and Entity Behavior Analytics in Detecting Insider Attacks," *IEEE Xplore*. [Online]. Available: <https://ieeexplore.ieee.org/document/9292394> (Accessed: Feb. 25, 2025).

[4] "Survey of Cybersecurity Governance, Threats, and Countermeasures for the Power Grid," *ResearchGate*. [Online]. Available: <https://www.researchgate.net/publication/380180896> (Accessed: Feb. 25, 2025).

[5] M. Saraiva and N. Mateus-Coelho, "CyberSoc Framework: A Systematic Review of the State-of-Art," [Online]. Available: (ResearchGate), (Accessed: Feb. 25, 2025).

СОЗДАНИЕ ПРИЛОЖЕНИЯ ДЛЯ ОБЕСПЕЧЕНИЯ СЕТЕВОЙ БЕЗОПАСНОСТИ «SECURENET»

Ахметұлы Ә.
КазНУ им.аль-Фараби
E-mail: akhmetovichasset@gmail.com
Нарбаева С.М.
КазНУ им.аль-Фараби, PhD

В данной работе рассматривается разработка приложения **SecureNet**, предназначенного для обеспечения сетевой безопасности. Основной функционал системы включает в себя мониторинг сетевого трафика, обнаружение подозрительных активностей и автоматическое уведомление администратора через Telegram-бот.

В ходе исследования были проанализированы современные угрозы информационной безопасности, такие как DDoS-атаки, несанкционированный доступ, перехват данных и аномальные сетевые активности. Разработанная система использует API для логирования сетевого трафика, выявления потенциальных угроз и последующего их анализа с применением сигнатурных и эвристических методов.

Одной из ключевых особенностей **SecureNet** является интеграция с Telegram-ботом, который в режиме реального времени отправляет уведомления о подозрительных событиях, таких как многократные неудачные попытки авторизации, резкие скачки трафика или обращение к нежелательным ресурсам. Это позволяет администраторам оперативно реагировать на инциденты, минимизируя возможные риски.

Результаты тестирования системы показали ее высокую эффективность в выявлении угроз и своевременной передаче информации о возможных атаках. Дальнейшие направления развития включают внедрение механизмов машинного обучения для интеллектуального анализа трафика, расширение базы сигнатур угроз и улучшение интерфейса взаимодействия с администратором.

Разработанная система **SecureNet** может быть использована в корпоративных и частных сетях для повышения уровня безопасности, предотвращения атак и защиты конфиденциальных данных.

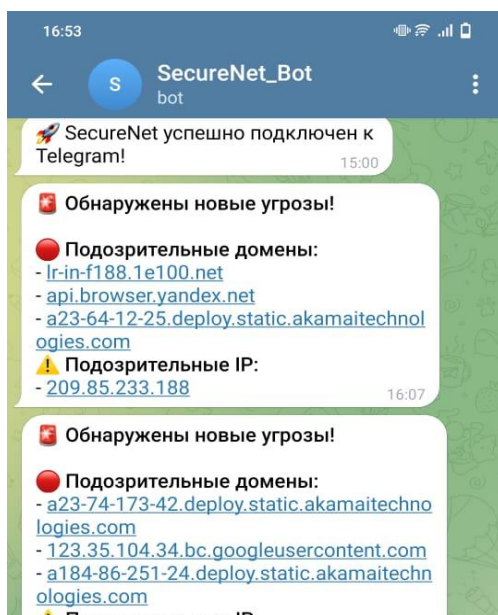


Рис. 1. Логирование подозрительных сетевых трафиков и потенциальных сетевых угроз

В ходе выполнения данной работы была разработана система **SecureNet**, предназначенная для мониторинга сетевого трафика и обеспечения безопасности информационных систем. В основе решения лежит механизм логирования сетевых запросов с последующим анализом и отправкой уведомлений о потенциальных угрозах через Telegram-бот.

Проведенные исследования и тестирования показали, что использование автоматизированного анализа трафика позволяет выявлять подозрительные активности, такие как множественные попытки аутентификации, резкие изменения в объемах передаваемых данных и обращения к нежелательным ресурсам. Интеграция с Telegram-ботом значительно повышает скорость реакции на угрозы, позволяя администраторам мгновенно получать уведомления и принимать меры по защите сети.

Список использованной литературы:

1. Петров В.А., Смирнов И.Н. Кибербезопасность: современные методы защиты сетевых систем. – Москва: Инфра-М, 2021. – №2(56). – С. 15-22.
2. Иванов С.В., Алексеев П.Д. Алгоритмы обнаружения и предотвращения атак в компьютерных сетях. – Санкт-Петербург: Питер, 2020. – №5(43). – С. 78-85.
3. Кузнецов М.А., Романов Д.В. Применение методов машинного обучения для анализа сетевого трафика. Вестник цифровой безопасности. – 2019. – №3(29). – С. 50-57.
4. Сергеев А.В., Байжанов Р.А. Шифрование и аутентификация в защищенных сетевых приложениях. – Новосибирск: Наука, 2022. – №6(81). – С. 30-38.

ҮЛКЕН ТІЛ МОДЕЛЬДЕРІНІҢ КИБЕРАГРЕССИЯНЫ АНЫҚТАУДАҒЫ РӨЛІ: МҮМКІНДІКТЕР, ШЕКТЕУЛЕР ЖӘНЕ БОЛАШАҚ ДАМУЫ

Базаркулова Инкар Ерболатқызы

Әл-Фараби атындағы Қазақ Ұлттық университетінің, киберқауіпсіздік және криптология кафедрасының 1 курс докторанты, Алматы, Қазақстан

e-mail: inkarbaza@gmail.com

Болатбек Милана Асланбекқызы

Әл-Фараби атындағы Қазақ Ұлттық университетінің, киберқауіпсіздік және криптология кафедрасының доцент м.а., Алматы, Қазақстан

Интернет пен әлеуметтік желілердің қарқынды дамуы адамдардың қарым-қатынасын түбегейлі өзгертіп, ақпарат алмасу мен қоғаммен байланысудың жаңа формаларын қалыптастырды. Дегенмен, ақпараттық технологиялардың дамуымен қатар интернеттегі агрессивті мінез-құлықтың жаңа түрі – киберагрессия кең таралуда. Бұл құбылыс жеке адамдарға, топтарға немесе ұйымдарға бағытталған психологиялық қысым, қорлау, жала жабу және басқа да зиянды әрекеттерді қамтиды [1]. Әсіресе, жасөспірімдер арасындағы әлеуметтік желілердің кең таралуы зиянды контенттің таралуына ықпал етуде. Қазақстан Республикасы Денсаулық сақтау министрлігінің Қоғамдық денсаулық сақтау ұлттық орталығының 2024 жылғы мәліметтері бойынша, әрбір сегізінші қазақстандық оқушы кибербуллингтің құрбаны болған [2]. Бұл мәселенің өзектілігін көрсетіп, оны анықтау мен алдын алуға арналған интеллектуалды құралдарды әзірлеу қажеттілігін көрсетеді.

Үлкен тіл модельдері (ҮТМ) – бұл күрделі мәтіндерді талдау және түсіну қабілеті бар жасанды интеллект технологиялары. Соңғы жылдары Claude, LLaMa және ChatGPT сияқты трансформер негізіндегі ҮТМ-дер әлеуметтік желілердегі зиянды контентті анықтауда кеңінен қолданылуда [3]. Бұл модельдер контексті, эмоцияны және сөйлем құрылымын терең талдап, агрессиялық сипаттағы хабарламаларды жоғары дәлдікпен анықтай алады.

ҮТМ-нің артықшылықтарының бірі – олар үлкен көлемдегі деректерді өңдей отырып, желідегі қауіпті үлгілерді автоматты түрде жіктей алады. Әсіресе, Prompt-based Machine Learning әдісін қолдану арқылы модельдердің тиімділігі артып, нақты мақсатты бағыттағы нәтижелер алуға мүмкіндік береді. Бұл әдіс ҮТМ-нің киберагрессияны ерте кезеңде анықтап, әлеуметтік желілерде қауіпсіз ортаны қамтамасыз етуге көмектесетін құралға айналуына ықпал етеді. ҮТМ-ді тиімді пайдалану арқылы әлеуметтік желілерді барынша қауіпсіз етуге мүмкіндік бар.

Берілген зерттеу жұмысы Қазақстан Республикасы Ғылым және жоғары білім министрлігінің Ғылым комитеті қаржыландыратын “Жастар экстремизмін анықтау және заманауи ақпараттық кеңістікте жастардың қауіпсіздігін қамтамасыз етуге арналған модельдер мен әдістерді әзірлеу” жобасы аясында орындалды (грант AP19576868, жоба жетекшісі Болатбек М.А.).

Пайдаланылған әдебиеттер тізімі:

1. Tulupova, Elena & Demidova, Tatyana & Baranova, Ekaterina. (2024). Cyberaggression as a modern form of discrimination and violence. Вестник Института права Башкирского государственного университета. 7.94-104.10.33184/vest-law-bsu-2024.21.9.

2. Қазақстанда мектеп жасындағы әрбір сегізінші бала кибербуллингке ұшырайды. «Мектеп жасындағы балалардың денсаулыққа қатысты мінез-құлқы» (HBSC) халықаралық зерттеуінің деректері [Электронды ресурс] // НЦОЗ. 2024. URL: <https://hls.kz/archives/42864>.

3. Cirillo S. et al. Exploring the ability of emerging large language models to detect cyberbullying in social posts through new prompt-based classification approaches // Information Processing & Management. 2025. Vol. 62, № 3. P. 104043.

КОРПОРАТИВТІК ЖЕЛІНІ ЖОБАЛАУ ЖӘНЕ ҚОРҒАУ

Ерген М.О.

Әл-Фараби атындағы Қазақ Ұлттық университеті, 3 – курс студенті

Email: maxim.e@liberty-group.kz

Нарбаева С.М.

Әл-Фараби атындағы Қазақ Ұлттық университетінің аға оқытушысы

Корпоративтік желілер қазіргі уақытта кибершабуылдардың жиі нысанасына айналып отыр, себебі ішкі сегменттердің жеткіліксіз оқшауланғандығы деректердің сыртқы ортаға ағып кетуіне және жүйенің бұзылуы қаупіне әкеп соқтырады. Бұл мәселені шешу үшін виртуалдандыру және VLAN сегментациясын пайдалану ұсынылады, осы арқылы қауіпсіз әрі басқарылатын IT-инфрақұрылым құруға болады.

Зерттеуде корпоративтік желілерді қорғау әдістері қарастырылады, соның ішінде vSwitch виртуалды коммутаторларының, pfSense брандмауэры мен Snort интрузияларды анықтау жүйесінің мүмкіндіктері талданады. Зертханалық жағдайда brute-force, man-in-the-middle шабуылдары моделденеді, сондай-ақ оларды болдыртпау жолдары ұсынылады. VLAN негізінде жасалған желі сегментациясы рұқсатсыз кіру тәуекелдерін азайтып, ұйымның маңызды қызметтеріне ықтимал шабуылдардың әсерін барынша кемітеді.

Зерттеу нәтижелеріне сүйенсек, виртуалдандыру мен желіаралық экрандауды үйлестіру корпоративтік желілердің жоғары деңгейлі қауіпсіздігін қамтамасыз етуге қабілетті. pfSense брандмауэры негізгі қорғаныс құралы ретінде қолданыла отырып, желі саясатының икемді басқарылуын және трафиктің сүзілуін қамтамасыз етеді. Ал Snort жүйесі ықтимал қауіптерді анықтау және күдікті қосылымдарды автоматты түрде бұғаттау кезінде өз тиімділігін дәлелдеді.

Ұсынылған тәсілдер киберқауіптерден қорғануды көздейтін түрлі ұйымдар үшін пайдалы әрі тиімді болуы мүмкін. Ашық бастапқы кодты бағдарламалық жасақтама пайдаланылғандықтан, оны ұйымдастырушылық инфрақұрылымға енгізу елеулі қаржы шығындарын қажет етпейді. Өзірленген әдіс әсіресе шағын және орта бизнеске өте маңызды, себебі олар үшін ақпараттық ресурстардың сенімді әрі қолжетімді қорғалуын қамтамасыз ете алады.

Пайдаланылған әдебиеттер тізімі:

1. В. Олифер, Н. Олифер Компьютерлік желілер. Принциптер, технологиялар, хаттамалар. - 2016
2. Таненбаум Э., Уэзеролл Д. Компьютерлік желілер. – СПб.: Питер, 2012.
3. Корпоративтік желі дегеніміз не? URL: <https://www.stekspb.ru/outsorsing-it-infrastruktury/it-glossary/corporate-network/> (қол жеткізу күні: 17.04.2019).
4. Лапоница О.Р. Желіаралық экрандау. – М.: Бином, 2014.
5. А. Сергеев Жергілікті компьютерлік желілердің негіздері - 2016

ЖАСТАР АРАСЫНДА ДЕСТРУКТИВТІ МАЗМҰНДЫ АНЫҚТАУ ЖӘНЕ ТАРАТУМЕН КҮРЕСУ ҚҰРАЛЫН ЗЕРТТЕУ

Ақпараттық қауіпсіздік жүйелері, 2 курс магистратура Әбдиев М.О.

Ғылыми жетекшісі: PhD, доцент м.а Болатбек М.А.

әл-Фараби атындағы Қазақ ұлттық университеті

Әлеуметтік желілер мен басқа да интернет-платформалар арқылы таратылатын деструктивті ақпараттың жас ұрпақтың психикалық және эмоционалдық денсаулығына теріс әсер етуінің өсіп келе жатқан проблема екені айдан анық. Өзірленген құралдың негізі ретінде жастар аудиториясына сәйкес келетін деструктивті мазмұнның мысалдарын қамтитын арнайы дайындалған деректер жиынтығында оқытылған DistilBERT терең оқыту моделі жатыр. Модель блогты жариялау функционалдығын имитациялайтын веб-қосымшаға біріктірілген, бұл мазмұнды жарияламас бұрын деструктивті элементтердің бар-жоғын автоматты түрде тексеруге мүмкіндік береді

Түйін сөздер: ақпараттық технологиялар, интернет, деструктивті мазмұн, әлеуметтік желілер, жастар.

Қазіргі әлем ақпараттық технологиялардың қарқынды дамуымен сипатталады, олар бір жағынан адамзат алдында қарым-қатынас, білім беру және өзін-өзі дамыту үшін бұрын-соңды болмаған мүмкіндіктер ашады, ал екінші жағынан жаңа сын-қатерлер мен қауіптер тудырады. Атап айтқанда, әлеуметтік желілер мен интернет-ресурстарда деструктивті контенттің таралуы жас ұрпақтың жеке басының қалыптасуына, дүниетанымына және психологиялық жағдайына теріс әсер етуі мүмкін [1]. Деструктивті мәтіндік мазмұнды автоматты түрде анықтау және тексеру үшін жасанды интеллект әдісі, атап айтқанда DistilBERT моделі әзірленді және қолданылды [2].

Деректер жиынтығын құру үшін бірнеше тәсілдер қолданылды. Тиісті платформалардың этикалық нормалары мен құпиялылық саясаты сақталды. Модель параметрлерін оңтайландыру және оның өнімділігін жақсарту үшін авторлар дәл баптау және тексеру әдістерін қолданды. Қолданыстағы шешімдермен салыстырғанда DistilBERT моделі, қолдануға және оны веб-қосымшаға біріктіруге негізделген тәсілдің бірқатар артықшылықтары бар екенін көрсетті. Көптеген қолданыстағы жүйелер деструктивті мазмұнның күрделі және жабық формаларын тануда тиімділігі төмен кілт сөздерге немесе тұрақты тіркестерге негізделген қарапайым алгоритмдерді қолданады [3].

Зерттеу нәтижесі бойынша DistilBERT моделін қолдануға негізделген жастар арасындағы деструктивті мазмұнды анықтау жүйесі сәтті жасалды. Тестілеу нәтижелері дәстүрлі қолмен модерациялау әдістерінен едәуір асып түсетін мәтіндік мазмұнды автоматты жіктеуде осы жүйенің жоғары тиімділігін көрсетті. Distilbert моделі F1-Micro және AUC ROC метрикалары бойынша жоғары дәлдікті көрсетті, бұл таңдалған тәсілдің тиімділігін растайды. Өзірленген құрал жалған оң позитивтердің минималды санымен деструктивті мазмұнды тиімді анықтай алады.

Пайдаланылған әдебиеттер тізімі:

1. Солдатова Г. и др. Мы в ответе за цифровой мир: профилактика деструктивного поведения подростков и молодежи в Интернете. – М.: ЛитРес, 2022. – 250 с. ISBN 978-5-04-123456-7.

2. Минаев В.А., Реброва А.Д., Симонов А.В. Выявление деструктивного контента в социальных медиа на основе моделей машинного обучения // Информация и безопасность. – 2021. – Т. 24. – № 1. – С. 7. DOI: 10.24412/2411-6467-2021-1-7.

3. Зеленский А.А. и др. Разработка монитора безопасности от деструктивных влияний веб-сайтов и социальных сетей Интернета // Вестник Новосибирского государственного университета. Серия: Информационные технологии. – 2021. – Т. 19. – № 1. – С. 48–60. ISSN 2226-1494.

МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН ҚОЛДАНА ОТЫРЫП, RSA АЛГОРИТМІНІҢ КРИПТОТӨЗІМДІЛІГІН ТАЛДАУ

Әсетова Диана Әсетқызы

ал-Фараби атындағы Қазақ Ұлттық университетінің 1 курс магистранты

E-mail: assetova01@mail.ru

Темирбекова Жанерке Ерлановна

ал-Фараби атындағы Қазақ Ұлттық университетінің PhD

Қазіргі заманғы криптографиялық алгоритмдердің беріктігін бағалау – ақпараттық қауіпсіздік саласындағы маңызды мәселелердің бірі. RSA алгоритмі кеңінен қолданылатын ашық кілтті шифрлау әдісі болғанымен, оның беріктігі үлкен жай сандарды тиімді факторизациялау мүмкіндігімен тығыз байланысты [1]. Бұл жұмыста машиналық оқыту әдістерін, атап айтқанда, Random Forest, Decision Tree, XGBoost және Sequential Model алгоритмдерін қолдана отырып, RSA алгоритмінің криптотөзімділігіне талдау жүргізудің теориялық негіздері қарастырылады.

Машиналық оқыту әдістерін қолдану

RSA алгоритмінің қауіпсіздігі үлкен сандарды жай көбейткіштерге жіктеу күрделілігіне негізделген. Дәстүрлі факторизациялау әдістерімен салыстырғанда, машиналық оқыту әдістері үлгілерді тану және болжам жасау арқылы әлсіз кілттерді анықтауда тиімді құрал бола алады:

- Random Forest – әртүрлі ықтимал кілт құрылымдарын зерттеп, әлсіз кілттерді анықтауға мүмкіндік береді.

- Decision Tree – сандық деректерді талдау арқылы RSA кілттерінің беріктігін бағалайды.

- XGBoost – факторизациялау тиімділігін арттыратын қуатты градиенттік бустинг әдісі.

- Sequential Model – нейрондық желілер арқылы шифрланған деректер үлгілерін зерттеу.

Бұл зерттеуде машиналық оқыту әдістерін қолдану арқылы RSA алгоритмінің беріктігіне ықтимал қауіптерді анықтау мақсат етіледі. Теориялық талдау негізінде аталған алгоритмдер әлсіз кілттердің үлгілерін анықтауда және факторизациялауға кететін уақытты қысқартуда маңызды рөл атқарады деп күтіледі. Машиналық оқыту әдістерін қолдану криптографиялық жүйелердің қауіпсіздігін бағалауға және оларды жетілдіру жолдарын ұсынуға мүмкіндік береді.

RSA алгоритмінің криптотөзімділігіне машиналық оқыту әдістерін қолдану оның беріктігін бағалауға және ықтимал әлсіз жақтарын анықтауға көмектеседі. Бұл зерттеу нәтижелері болашақта криптографиялық жүйелердің қауіпсіздігін күшейтуге және машиналық оқыту негізінде қауіпсіздік шараларын жетілдіруге негіз бола алады.

Пайдаланылған әдебиеттер тізімі:

1. Milanov E. The RSA algorithm //RSA laboratories. – 2009. – Т. 1. – №. 11.

ANALYSIS OF MODERN METHODS FOR DETECTING CYBER THREATS IN CORPORATE NETWORKS

Жапаров Д.Ж. магистрант 2 курс

e-mail: zhaparov.dim@gmail.com

With the increasing number of cyberattacks on corporate networks, timely detection of cyber threats has become a key aspect of information security. Traditional antivirus solutions, which rely on signature-based detection, are no longer sufficient to provide comprehensive protection against evolving threats [1, p. 5]. This necessitates the use of advanced and adaptive threat analysis methods that can effectively identify and mitigate both known and unknown cyber threats.

There are several key approaches to detecting malicious activity in corporate networks, each with its strengths and limitations. Signature-based detection relies on a predefined database of known malware signatures. This method is highly accurate for detecting previously identified threats but struggles against zero-day attacks and new malware variants [2, p. 12]. Its main limitation is the inability to recognize threats that do not match known patterns. Heuristic detection analyzes the structure and behavior of programs to identify potentially harmful software. This method enables the identification of previously unknown threats by recognizing suspicious characteristics within the code. However, heuristic analysis may produce false positives, as some legitimate applications might exhibit behavior similar to malicious software [1, p. 8]. Behavioral analysis focuses on monitoring system activity in real time. It detects suspicious actions such as unauthorized modifications to system files, unusual network communications, or privilege escalation attempts. This approach is effective in identifying sophisticated threats, including polymorphic and metamorphic malware. However, it requires substantial computational resources and may lead to performance overhead in large-scale corporate environments [3, p. 17]. Modern cybersecurity solutions increasingly incorporate machine learning (ML) techniques to enhance threat detection capabilities. ML-based methods analyze vast amounts of network and system data to identify anomalies indicative of cyber threats [4, p. 22]. Unlike traditional methods, ML algorithms can adapt to new attack patterns and improve their accuracy over time. However, these systems require extensive training datasets and continuous updates to maintain effectiveness.

Despite advancements in cyber threat detection, several challenges remain. One of the primary concerns is the high rate of false positives, which can lead to unnecessary alerts and operational inefficiencies. Additionally, attackers continuously develop sophisticated evasion techniques, such as obfuscation and encryption, to bypass detection mechanisms [3, p. 20]. Ensuring real-time threat detection while minimizing system performance impact is another critical challenge faced by security teams.

Effective cyber threat detection requires a multi-layered approach that combines different detection methods to maximize security coverage. While traditional signature-based techniques remain useful for known threats, heuristic, behavioral, and machine learning-based methods offer enhanced protection against emerging cyber threats [2, p. 15; 4, p. 30]. The integration of these approaches, coupled with continuous monitoring and threat intelligence, is needed for safeguarding corporate networks from evolving cyber risks.

Список использованной литературы:

1. Sharma, R., & Chen, L. (2022). A comprehensive review on detection of cyber-attacks: Data sets, methods, and frameworks. *Journal of Information Security and Applications*, 65, 103110. <https://www.sciencedirect.com/science/article/pii/S254266052200097X>
2. Alharbi, S., & Khan, A. (2024). Ensemble Defense System: A Hybrid IDS Approach for Effective Cyber Threat Detection. *arXiv preprint arXiv:2401.03491*. <https://arxiv.org/abs/2401.03491>
3. Redino, C., Nandakumar, D., Schiller, R., Choi, K., Rahman, A., Bowen, E., Weeks, M.,

- Shaha, A., & Nehila, J. (2022). Zero Day Threat Detection Using Graph and Flow Based Security Telemetry. *arXiv preprint arXiv:2205.02298*. <https://arxiv.org/abs/2205.02298>
4. Kumar, R., & Singh, M. (2023). Leveraging AI for Network Threat Detection—A Conceptual Overview. *Electronics*, 13(23), 4611. <https://www.mdpi.com/2079-9292/13/23/4611>

ЖАСТАР ҮШІН ҚАУІПТІ ВЕБ-РЕСУРСТАРДЫ АНЫҚТАУ ӘДІСІН ЗЕРТТЕУ

Ақпараттық қауіпсіздік жүйелері, 2 курс магистратура Жолдыбаева Д.Ж.

Ғылыми жетекшісі: PhD, доцент м.а. Болатбек М.А.

әл-Фараби атындағы Қазақ ұлттық университеті

Жастардың интернетті белсенді пайдалануына байланысты онлайн қауіпсіздікті қамтамасыз ету маңызды міндетке айналып отыр. Фишинг, зиянды бағдарламалар және қауіпті мазмұн сияқты көптеген онлайн-қатерлер жасөспірімдер мен жастарға қауіп төндіреді. Бұл жұмыста URL-мекенжайларды талдау үшін машиналық оқытуды пайдаланатын қауіпті веб-ресурстарды автоматты түрде анықтау әдісі ұсынылған. Зерттеу веб-ресурстарды лексикалық, URL құрылымы және домен беделі сияқты сипаттамалары негізінде қауіпсіз және қауіпті деп жіктейтін жүйені әзірлеуге бағытталған.

Түйін сөздер: қауіпті веб-ресурстар, киберқауіпсіздік, машиналық оқыту, URL-талдау, интернет қауіптері.

Интернет күнделікті өмірдің, әсіресе жастардың ажырамас бөлігіне айналған қазіргі әлемде онлайн қауіпсіздікті қамтамасыз ету аса маңызды мәселе болып табылады. Интернетті оқу, қарым-қатынас және ойын-сауық үшін белсенді пайдаланатын жастар көбінесе фишингтік шабуылдарды, зиянды бағдарламаларды және ықтимал қауіпті мазмұны бар веб-ресурстарды қоса алғанда, әртүрлі желілік қауіптерге осал болады. Бұл мәселені шешу үшін машиналық оқыту әдістері таңдалды, оның ішінде логистикалық регрессия, шешім ағашы және кездейсоқ орман әдістері қолданылды. Бұл модельдер URL ұзындығы, сілтемеде күдікті сөздердің болуы, протоколдарды және символдық белгілерді пайдалану сияқты URL белгілерінің негізінде веб-ресурстарды жіктеу үшін қолданылады. Зерттеуде қауіпсіз және қауіпті URL мекенжайларын қамтитын теңдестірілген деректер жинағы пайдаланылды [1].

Жоғары сапалы және репрезентативті деректерді жинау кез келген машиналық оқыту зерттеулерінің негізі болып табылады. Қауіпсіз және ықтимал қауіпті URL мекенжайларын қамтитын деректер жинағын жасау мұқият жоспарлау мен іске асыруды қажет етеді. Модельдің өнімділігі мен жалпылау қабілеті деректердің сапасына тікелей байланысты, сондықтан бұл кезеңге бірінші кезекте назар аударылды [2]. Нәтижелер бойынша кездейсоқ орман әдісі қауіпті URL мекенжайларын анықтаудың ең жоғары толықтығын көрсетті, бұл оның деректердегі күрделі және сызықтық емес тәуелділіктерді өңдеудегі жоғары тиімділігін көрсетеді. Логистикалық регрессия және шешімдер ағашы да жақсы нәтиже көрсетті, бірақ олардың дәлдігі мен толықтығы кездейсоқ орманға қарағанда біршама төмен болды [3].

Нәтижелер жастардың онлайн қауіпсіздігін қамтамасыз етуде ұсынылған әдістің тиімділігін растайды. Лексикалық, символдық және беделді талдауды қоса алғанда, URL белгілерінің комбинациясын пайдалану, сондай-ақ машиналық оқытудың қазіргі заманғы әдістерін қолдану арқылы қатерлерді анықтаудың жоғары дәлдігімен жүйені құру мүмкін болды. Болашақта қауіпсіздік сүзгілерін айналып өтудің жаңа әдістеріне бейімделу үшін модель үнемі жаңартылып, жетілдірілуі керек.

Пайдаланылған әдебиеттер тізімі:

1. Салим Р. и др. Обнаружение вредоносного домена на основе естественного языка с использованием машинного обучения и глубокого обучения // Научно-технический вестник информационных технологий, механики и оптики. – 2024. – Т. 23. – № 2. – С. 304–312. DOI: 10.17586/2226-1494-2024-23-2-304-312.

2. Евдошенко О.И., Лежнина Ю.А. Применение методов машинного обучения для детектирования вредоносных URL // Инженерно-строительный вестник Прикаспия. – 2023. – № 2 (44). – С. 122–127. DOI: 10.31618/2307-8755.2023.2.44.122-127.

3. Амлетова Е.С. Обнаружение фишинговых веб-сайтов с помощью методов машинного обучения на несбалансированных данных // Международная научно-техническая

конференция молодых ученых БГТУ им. В. Г. Шухова, посвященная 170-летию со дня рождения В.Г. Шухова. – 2023. – С. 22–25. ISBN 978-5-00101-567-8.

АҚПАРАТТЫҚ ҚАУІПСІЗДІК САЛАСЫНДАҒЫ ТӘУЕКЕЛДЕРДІ ТАЛДАУ ЖӘНЕ БАСҚАРУ ҮШІН ПЛАТФОРМА ҚҰРУ

Ақпараттық қауіпсіздік аудитінің 1-курс магистранты Жубанышева Г.Т.

Ғылыми жетекші PhD, доцент м.а. Адилжанова С. А.

Әл-Фараби атындағы Қазақ ұлттық университеті

Аңдатпа: Зерттеу барысында негізгі қауіптер анықталып, оларды азайтуға арналған технологиялық шешімдер ұсынылды, соның ішінде жасанды интеллект пен машиналық оқыту, киберқатерлерді автоматты түрде бейтараптандыру жүйелері, қауіпсіздікке негізделген архитектуралық дизайн, криптографиялық әдістер және блокчейн технологиясы.

Кілттік сөздер: Цифрлық егіздер, ақпараттық қауіпсіздік, тәуекелдерді басқару, жасанды интеллект, машиналық оқыту, киберқауіптер, шабуылдарды бейтараптандыру, криптография, блокчейн, қауіпсіздік архитектурасы.

Қазіргі уақытта цифрлық технологиялардың жедел дамуы мен «Индустрия 4.0» тұжырымдамасының кеңінен енгізілуі ақпараттық қауіпсіздік саласындағы тәуекелдерді басқарудың маңыздылығын арттырады. Әсіресе, цифрлық егіздер технологиясы өндірістік процестердің тиімділігін арттыруға ықпал еткенмен, жаңа киберқауіптер мен осалдықтардың пайда болуына әкеледі[1]. Бұл зерттеу цифрлық егіздер негізінде ақпараттық қауіпсіздік тәуекелдерін талдау және басқару үшін платформаны құруға бағытталған.

Осы тәуекелдерді азайту үшін жаңа технологиялық шешімдер ұсынылды, олардың ішінде:

- Жасанды интеллект (AI) және машиналық оқыту (ML) негізіндегі болжаулық талдау – ақпараттық қауіпсіздік инциденттерін алдын ала анықтау және күдікті әрекеттерді ерте кезеңде болжау[2].

- Киберқатерлерді автоматты түрде нейтрализациялау жүйелері – honeypot технологияларын пайдаланып, шабуыл әрекеттерін зерттеу және оларға уақтылы жауап беру.

- Қауіпсіздікке негізделген архитектуралық дизайн (Security by Design) – платформа құрылымын бастапқы кезеңнен бастап қауіпсіздік талаптарына сәйкестендіру[3].

- Адаптивті қауіпсіздік жүйелері – динамикалық конфигурация арқылы қауіптерге бейімделетін қорғаныс шараларын қолдану.

- Криптографиялық технологияларды жетілдіру – деректерді қорғау үшін квантқа төзімді шифрлау әдістерін енгізу.

- Блокчейн технологиясын интеграциялау – деректердің өзгермейтіндігін қамтамасыз ету және платформаның тұтастығын сақтау.

Зерттеу нәтижелері цифрлық егіздерге тікелей қатысты киберқауіптерді автоматты нейтрализациялау әдістерін жетілдіру қажеттілігін көрсетті. Автоматты қорғаныс жүйелерінің тиімділігін арттыру үшін жасанды интеллект (AI) және машиналық оқыту (ML) негізінде шабуылдарды алдын ала болжау және әрекет ету алгоритмдерін дамыту ұсынылады. Мұндай тәсілдер нейрондық желілер мен шешімдер ағаштары арқылы жиі кездесетін шабуыл түрлерін анықтауға және алдын алу шараларын жүзеге асыруға мүмкіндік береді.

Пайдаланылған әдебиеттер тізімі:

1. Carol Lo, Thu Yein Win, Zeinab Rezaeifar, Zaheer Khan, Phil Legg. “Digital Twins in Industry 4.0 Cyber Security.” 2023 IEEE Smart World Congress (SWC)|979-8-3503-1980-4/23/ DOI: 10.1109/SWC57546.2023.10449147

2. Harshpreet Kaur, Munish Bhatia. “Scientometric Analysis Of Digital Twin in Industry 4.0.”: DOI 10.1109/JIOT.2024.3459965.

3. Banglie Yang, Linyu Zhu, Cheng Dai*, Sahil Garg, Georges Kaddoum. “An Improved Reconstruction Based Multi-Attribute Contrastive Learning for Digital Twin-Enabled Industrial System.” DOI 10.1109/JIOT.2024.3483038.

OSINT ТАЛДАУЫ ҮШІН АШЫҚ КӨЗДЕРДЕН ДЕРЕКТЕРДІ ЖИНАУДЫ АВТОМАТТАНДЫРУДЫҢ ТИІМДІЛІГІ

Жуманбаев Е.А.

Ғылыми жетекші: т.ғ.м., аға оқытушы Байспай Гүлишат Болатқызы

Әл-Фараби атындағы ҚазҰУ, Алматы, Қазақстан

E-mail: erazhumanbaef0907@gmail.com

Аңдатпа. Бұл мақалада OSINT талдауында ашық көздерден деректерді жинауды автоматтандырудың тиімділігі зерттеледі. Зерттеу барысында OSINT-анализінің теориялық аспектілері (негізгі принциптер, дереккөздерді жіктеу, фейк деректер мен антипарсинг қауіптері, сондай-ақ ҚР мен GDPR сияқты құқықтық шектеулер) қарастырылды. Сонымен қатар, зерттеу жұмысының негізгі міндеттері аясында автоматтандыру құралдарын (Maltego, Python кітапханалары) салыстыру, деректер жинау жүйесінің архитектурасын әзірлеу және оны Python негізінде іске асыру жүзеге асырылды. Жүйе парсинг, сақтау (SQL/NoSQL) және визуализация (Grafana) модульдерін біріктіріп, Google Colab секілді бұлттық шешімдерді қолдану арқылы толық интеграцияланды. Жүйе нақты кейстерде тестіленіп, оның жылдамдығы, дәлдігі және киберқауіпсіздік пен бизнес-аналитикадағы қолданбалығы бағаланды. Соңғы нәтижелер негізінде масштабталу, AI-анализ және дереккөздердің кеңейтілуі бойынша ұсыныстар қалыптастырылды.

Кілттік сөздер: OSINT, автоматтандыру, веб-парсинг, Maltego, Python, GDPR, киберқауіпсіздік.

Қазіргі таңда ақпараттық талдау саласы қарқынды дамып, ұйымдар мен мемлекеттік мекемелерге стратегиялық шешімдер қабылдауда OSINT әдістері маңызды рөл атқарады. Ашық көздерден алынатын деректердің көлемі мен ауқымы күннен-күнге өсіп келе жатқандықтан, оларды қолмен өңдеу мүмкіндігі шектеулі. Осыған байланысты, автоматтандыру әдістері деректерді жылдам әрі дәл жинауға мүмкіндік беріп, талдау сапасын арттырады.

Зерттеудің құндылығы – OSINT талдауында ашық көздерден деректерді автоматтандыру арқылы ақпаратты тез әрі дәл жинап, талдау сапасын арттыруда жатыр. Автоматтандырылған жүйе киберқауіпсіздік пен бизнес-аналитика салаларында тәуекелдерді басқару стратегияларын жетілдіруге және нақты, ғылыми-негізделген шешімдер ұсынуға ықпал етеді.

Деректерді өңдеу және модельді бағалау

Зерттеу барысында деректер алдын ала өңделіп (дубликаттарды жою, мәтіндерді нормалау), сандық және категориялық айнымалыларға арналған трансформациялар жүргізілді. Логистикалық регрессия, SVM және KNN модельдері оқытылып, олардың тиімділігі дәлдік (accuracy), F1-Score және ROC-AUC сияқты метрикалар арқылы бағаланды. Деректерді визуализациялау үшін Grafana платформасында динамикалық дашбордтар құрылды. Сонымен қатар, деректердің заңдылыққа сәйкестігін қамтамасыз ету үшін анонимдау әдістері қолданылды. Модельдердің жұмыс істеу процесін тексеруге арналған қателіктер матрицасы (Confusion Matrix) және ROC-қисықтар құрастырылды.

Нәтижелер. Зерттеу нәтижелері OSINT талдауында автоматтандырудың келесі артықшылықтарын көрсетті:

- Жылдамдық: Автоматтандырылған жүйе ашық көздерден деректерді тез жинап, өңдейді.

- Дәлдік: Жүйе деректерді сапалы түрде жинап, фейк деректер мен антипарсинг қауіптерін азайтады.

- Интеграция: Парсинг, сақтау және визуализация модульдері біріктіріліп, бұлттық платформалар арқылы қолжетімділікті арттырады.

- Қолданбалық: Жүйе киберқауіпсіздік пен бизнес-аналитика салаларында нақты кейстерде тиімділігін дәлелдеді.

id	category	title	link	date	view
1	Общество	Проект «Цифровое общество» инициир	https://24.kz/ru/news/social/696093-pro	21.02.25, 23:02	354
2	В мире	Развитие искусственного интеллекта в	https://24.kz/ru/news/in-the-world/6950	15.02.25, 16:27	632
3	Общество	Завершился первый день работы цифр	https://24.kz/ru/news/social/692753-zave	31.01.25, 22:12	633
4	Общество	\$20 трлн составит вклад искусственног	https://24.kz/ru/news/social/692740-usd	31.01.25, 21:14	681
5	Общество	Международный форум Digital Almaty 2	https://24.kz/ru/news/social/691575-mezi	24.01.25, 15:30	2215
6	Право знать	ИИ и безопасность: почему важно откл	https://24.kz/ru/tv-projects/pravo-znat/6	23.01.25, 12:36	252
7	Право знать	IT для школьников: киберкласс вперед	https://24.kz/ru/tv-projects/pravo-znat/6	21.01.25, 10:55	320
8	Право знать	Казахстанские специалисты разработа	https://24.kz/ru/tv-projects/pravo-znat/6	17.01.25, 11:39	265
9	Право знать	Казахстан экспортирует системы кибер	https://24.kz/ru/tv-projects/pravo-znat/6	13.01.25, 23:55	291
10	Общество	Команду киберопонтеров создали в Кг	https://24.kz/ru/news/social/689530-kor	11.01.25, 17:10	1376
11	Интервью	Киберугрозы 2024: как защитить свои д	https://24.kz/ru/tv-projects/intervyu/685	14.12.24, 13:05	1272
12	В мире	В странах ЕС персональные данные за	https://24.kz/ru/news/in-the-world/6827	28.11.24, 13:05	637
13	В мире	FTC начала антимонопольное расслед	https://24.kz/ru/news/in-the-world/6827	28.11.24, 10:10	598
14	Общество	Кибер-класс впервые открыли в школе	https://24.kz/ru/news/social/681387-kibe	19.11.24, 18:15	630
15	Образование и наука	По программе Tech Orda подготовили с	https://24.kz/ru/news/obrazovanie-i-nauk	01.11.24, 12:20	976
16	Право знать	Подписывать договоры с помощью био	https://24.kz/ru/tv-projects/pravo-znat/6	01.11.24, 18:40	478

1-сурет. 24.kz сайтындағы «кибербезопасность» сөзі бар жаңалықты іздеп, деректер қорына сақтаудың нәтижесі

Қорытынды. OSINT талдауында ашық көздерден деректерді автоматтандырудың тиімділігі дәлелденді. Зерттеу барысында OSINT-анализінің теориялық аспектілері, автоматтандыру құралдарының (Maltego, Python кітапханалары) салыстырмалы талдауы және деректер жинау жүйесінің архитектурасы қарастырылды. Python негізіндегі жүйені іске асыру барысында парсинг, деректерді сақтау (SQL/NoSQL) және визуализация (Grafana) модульдері біріктіріліп, Google Colab сияқты бұлттық шешімдер арқылы нақты кейстерде жүйенің жылдамдығы, дәлдігі және қолданбалылығы дәлелденді.

Қорытынды ұсыныстар. Зерттеу нәтижелеріне сүйене отырып, OSINT талдауында ашық көздерден деректерді автоматтандыру жүйесін қолдану ұсынылады, себебі ол ұйымдарға ақпараттық қауіпсіздікті қамтамасыз ету мен тәуекелдерді басқаруда нақты, ғылыми-негізделген шешімдер ұсынуға мүмкіндік береді. Сонымен қатар, жүйенің масштабталуын қамтамасыз ету, AI-анализді енгізу және дереккөздердің ауқымын кеңейту бағытында қосымша жұмыстар жүргізу маңызды. Python негізіндегі шешімдерді нақты уақыт режимінде енгізу жүйенің интеграциясын жетілдіруге және киберқауіптерді болжауда тиімділікті арттыруға ықпал етеді.

Пайдаланылған әдебиеттер тізімі:

1 М.Е. Сидорова, А.Р. Кузьмин, “Разведка по открытым источникам данных и ее применение для решения задач кибербезопасности(Ашық деректер көздерін барлау және оны киберқауіпсіздік мәселелерін шешу үшін қолдану)”. Vestnik-Rosnou.ru, 2023. [Online] Available: https://vestnik-rosnou.ru/sites/default/files/61_PDFsam_N1.pdf

2 OPSEC/NATO OSINT Handbook v1.2 – Jan 2002 (PDF). GitHub Repository. [Online] Available:<https://github.com/lawsecnet/OPSEC/blob/master/NATO%20OSINT%20Handbook%20v1.2%20-%20Jan%202002.pdf>

3 Khera, V., Prasad, A. R., & Kwanoran, S., “Open Source Intelligence (OSINT) – A Practical Introduction: A Field Manual(Open Source Intelligence(OSINT) - Практикалық Кіріспе: Нұсқаулық)”. ResearchGate, October 2024. [Online]. Available: https://www.researchgate.net/publication/385193358_Open_Source_Intelligence_OSINT_-_A_practical_Introduction_A_Field_Manual

ЖАЛҒАН АККАУНТТАРҒА ҚАРСЫ ГЕНЕРАТИВТІ БӘСЕКЕЛЕСУ ЖЕЛІЛЕРІ: ӘЛЕУМЕТТІК ЖЕЛІЛЕРДЕГІ АНОМАЛИЯЛАРДЫ АНЫҚТАУ

Кабыкенова С.Ғ.

әл-Фараби атындағы Қазақ Ұлттық университетінің магистранты

Андатпа

Жалған аккаунттардың көбеюі киберқауіпсіздікке қауіп төндіреді. GAN технологиясы шынайы және жасанды деректерді ажыратуды үйреніп, жалған профильдерді тиімді анықтайды, бұл әлеуметтік желілердің қауіпсіздігін арттыруға мүмкіндік береді.

Кілт сөздер: жалған аккаунттар, киберқауіпсіздік, GAN, машиналық оқыту, әлеуметтік желілер.

Аннотация

Рост числа фейковых аккаунтов угрожает кибербезопасности. Технология GAN обучается отличать реальные данные от поддельных, что позволяет эффективно выявлять фейковые профили и повышать безопасность социальных сетей.

Ключевые слова: фейковые аккаунты, кибербезопасность, GAN, машинное обучение, социальные сети.

Abstract

The rise of fake accounts threatens cybersecurity. GAN technology learns to distinguish real from synthetic data, effectively detecting fake profiles and improving social network security.

Keywords: fake accounts, cybersecurity, GAN, machine learning, social networks.

Жалған аккаунттардың көбеюі киберқауіпсіздікке және ақпараттық кеңістіктің тұтастығына қауіп төндіреді, өйткені олар фишинг, манипуляция және жалған ақпарат тарату үшін қолданылады. Дәстүрлі әдістер, мысалы, ереже негізіндегі сүзгілер мен статистикалық талдау, алаяқтардың күрделі тәсілдеріне қарсы әлсіздік танытуда [1]. Генеративті бәсекелесу желілері (GAN) әлеуметтік желілердегі жалған аккаунттарды анықтаудың перспективалы әдісі болып табылады. Себебі GAN генераторы жалған деректер жасап, ал дискриминатор оларды шынайы деректерден ажыратуға тырысады, нәтижесінде жүйе жалған профильдерді дәлірек анықтайды. Сонымен қатар, GAN синтетикалық деректерді генерациялау арқылы модельді үздіксіз жетілдіруге мүмкіндік береді [2]. Бұл әдіс басқа машиналық оқыту тәсілдерімен біріктірілгенде тиімділігі артады. Осылайша, GAN негізіндегі тәсілдер әлеуметтік желілердегі киберқауіпсіздікті арттырудың маңызды құралы бола алады.

Пайдаланылған әдебиеттер тізімі:

1. Bordbar, J., Mohammadrezaie, M., Ardalan, S., & Shiri, M. E. (2022). Detecting fake accounts through Generative Adversarial Network in online social media. *arXiv preprint arXiv:2210.15657*.

2. Yang, K.-C., Singh, D., & Menczer, F. (2024). Characteristics and prevalence of fake social media profiles with AI-generated faces. *arXiv preprint arXiv:2401.02627*.

МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІНІҢ КИБЕРҚАУІПСІЗДІК АУДИТІНДЕ ҚОЛДАНЫЛУЫ

Нәдия Қ., Тураббек Ә.Т.,

ал-Фараби атындағы Қазақ Ұлттық университеті,
kaderzhann@gmail.com, turarbekasem1@gmail.com

Қазіргі цифрлық әлемде киберқауіптер жеке тұлғаларға, бизнес пен мемлекеттерге үлкен қауіп төндіреді. Дәстүрлі киберқауіпсіздік әдістері үнемі өзгеріп жатқан қауіптерге қарсы тиімсіз болып қалады [1]. Машиналық оқыту (МО) осы салада үлкен деректерді талдау, күрделі үлгілерді анықтау және қауіптерді автоматты түрде табу мүмкіндігін ұсынады [2]. Бұл мақаланың мақсаты — МО әдістерінің киберқауіпсіздікте қолданылуын, аномалияларды анықтау, зиянды бағдарламаларды табу және осалдықтарды бағалау сияқты бағыттар бойынша зерттеу, сонымен қатар оларды енгізудегі қиындықтарды талқылау.

Машиналық оқытудың киберқауіпсіздікте қолданылуын зерттеу үшін заманауи зерттеулер мен ғылыми жарияланымдарға шолу жүргізілді. Негізгі назар үш бағытқа аударылды: желі трафигіндегі аномалияларды анықтау, зиянды бағдарламаларды табу және бағдарламалық жасақтама мен желі жүйелеріндегі осалдықтарды бағалау [3]. Осы бағыттар аясында әртүрлі машиналық оқыту әдістері, мысалы, кластеризация (К-орташа, PCA), терең оқыту (RNN, LSTM, CNN) және классификация (шешім ағаштары, SVM) қарастырылды [4]. Бұл әдістер олардың тиімділігі, дәлдігі және нақты жағдайларда қолданылуы тұрғысынан талданды.

Машиналық оқыту желі трафигіндегі аномалияларды анықтауда жоғары тиімділік көрсетеді. Кластеризация әдістері (К-орташа, PCA) желінің қалыпты әрекетінен ауытқуларды анықтауға мүмкіндік береді [2]. Терең оқыту (RNN, LSTM) уақыттық тәуелділіктерді талдап, күрделі аномалияларды анықтайды [5]. Зиянды бағдарламаларды анықтауда CNN екілік кодты талдап, бірегей сипаттамаларды ажыратады [6], ал RNN бағдарламалардың уақыт бойынша әрекетін талдау арқылы зиянды әрекеттерді анықтайды [7]. Бағдарламалық жасақтама мен желідегі осалдықтарды бағалау үшін шешім ағаштары және SVM кодтың күрделілігін және функцияларды пайдалануды талдайды [3]. Терең оқыту семантикалық осалдықтарды анықтайды [8], ал кездейсоқ ормандар желілік осалдықтарды болжайды [8].

Пайдаланылған әдебиеттер тізімі:

1. Xin, Y., et al. (2018). Machine learning and deep learning methods for cybersecurity. IEEE Access, 6, 35365–35381. <https://doi.org/10.1109/ACCESS.2018.2836950>
2. Nassif, A. B., Talib, M. A., Nasir, Q., & Dakalbab, F. M. (2021). Machine learning for anomaly detection: A systematic review. IEEE Access, 9, 78658–78700. <https://doi.org/10.1109/ACCESS.2021.3083060>
3. Chafjiri, S. B., Legg, P., Hong, J., & Tsompanas, M.-A. (2024). Vulnerability detection through machine learning-based fuzzing: A systematic review. University of the West of England. <https://doi.org/10.1016/j.cose.2024.103903>
4. Elmabit, N., Zhou, F., Li, F., & Zhou, H. (2020). Evaluation of machine learning algorithms for anomaly detection. 2020 International Conference on Cyber Security and Protection of Digital Services (Cyber Security), 1–8. <https://doi.org/10.1109/CyberSecurity49315.2020.9138871>
5. Zhong, M., Zhou, Y., & Chen, G. (2021). Sequential model-based intrusion detection system for IoT servers using deep learning methods. Sensors, 21(4), 1113. <https://doi.org/10.3390/s21041113>
6. Tayyab, U.-e-H., Khan, F. B., Durad, M. H., Khan, A., & Lee, Y. S. (2022). A survey of the recent trends in deep learning-based malware detection. Journal of Cybersecurity and Privacy, 2(4), 800–829. <https://doi.org/10.3390/jcp2040041>

7. Ferrag, M. A., Maglaras, L., Moschoyiannis, S., & Janicke, H. (2019). Deep learning for cyber security intrusion detection: Approaches, datasets, and comparative study. *Journal of Information Security and Applications*, 48, 102419. <https://doi.org/10.1016/j.jisa.2019.102419>
8. Rananga, N., & Venter, H. S. (2024). A comprehensive review of machine learning applications in cybersecurity: Identifying gaps and advocating for cybersecurity auditing. *Research Square*. <https://doi.org/10.21203/rs.3.rs-4791216/v1>

БИОМЕТРИЯЛЫҚ СӘЙКЕСТЕНДІРУДІҢ ДӘЛДІГІ МЕН ҚАУІПСІЗДІГІН АРТТЫРУҒА АРНАЛҒАН АНСАМБЛЬДІК МОДЕЛЬ

Қалаубекова Ж.Қ.* *Магистрант 2-курс*
әл-Фараби атындағы Қазақ ұлттық университеті
эл.почта: Janetta7788@gmail.com

Аннотация. Бет-әлпетті тану технологиясы қауіпсіздік жүйелері мен онлайн аутентификацияда кеңінен қолданылады. Алайда қазіргі алгоритмдер жоғары дәлдікке қарамастан, бет-әлпетті алмастыру шабуылдарына осал болып келеді. Ұсынылып отырған FaceZ ансамбльдік әдісінің жаңалығы FaceNet және DeepFace модельдерінің эмбеддингтерін біріктіріп, оларды адаптивті шешім қабылдайтын Meta-Learner классификаторы арқылы өңдеуде. Қосымша түрде MobileNetV2 нейрондық желісі негізінде үйретілген спуфингке қарсы модуль қолданылды, бұл модуль кескіннің жалған болу ықтималдығын есептеп, оны классификация кезеңінде ескереді және бет-әлпетті алмастыру шабуылдарына тұрақтылығы айтарлықтай арттырады.

Кілт сөздер: бетті тану, терең оқыту, DeepFace, FaceNet, ансамбльдік әдіс, биометриялық аутентификация, конволюциялық нейрондық желілер, спуфинг, MobileNetV2.

Бет-әлпетті тану үшін біз үш әдісті қолдандық: DeepFace, FaceNet және осы екеуін біріктіретін ансамбльдік әдіс. Алғашқы екі әдіс те терең нейрондық желілерге негізделген және бет-әлпетті жоғары дәлдікпен тануға мүмкіндік береді, бірақ олардың жұмыс істеу принциптері әртүрлі. DeepFace моделі жарықтандыру мен түсіру бұрышының өзгерістеріне тұрақты болса, FaceNet тұлғалардың векторлық сипаттамаларын (эмбеддингтерін) тиімді түрде құрып, оларды нақты салыстыру үшін онтайландырады.

Бет-әлпетті тану дәлдігін және жүйенің сыртқы факторларға төзімділігін арттыруға бағытталған FaceZ ансамбльдік тәсілі әзірленді. Ансамбльдің негізгі идеясы болжамдардың жалпы дәлдігін жақсарту үшін бірнеше модельдердің нәтижелерін біріктіру болып табылады. Ұсынылған FaceZ ансамбльдік әдісі бет-әлпетті танудың дәлдігі мен сыртқы факторларға төзімділігін арттыруға бағытталған. Әдістің негізіне FaceNet және DeepFace модельдерінің эмбеддингтерін бір мезгілде пайдалану жатады, бұл модельдер тұлғалардың ерекшеліктерін сипаттайтын эмбеддингтерді генерациялайды. Алынған эмбеддингтер конкатенация жолымен біріктіріліп, қорытынды шешім қабылдайтын көп қабатты перцептрон (Meta-Learner) көмегімен өңделеді. Әдістің қосымша маңызды ерекшелігі – MobileNetV2 нейрондық желісіне негізделген спуфингке қарсы модульдің болуы. Бұл модуль шынайы және жалған бет кескіндерінің жеке жинағында алдын-ала оқытылады және кескіннің жалған болу ықтималдығын бағалайды. Егер бұл ықтималдық алдын-ала белгіленген шектік мәннен жоғары болса, кескін автоматты түрде жалған ретінде жіктеліп, аутентификациядан өтпейді. Ансамбль моделіне антиспуфингті қосу бетті тану жүйесінің жалпы дәлдігіне айтарлықтай әсер етті. Антиспуфингтің негізгі мақсаты жалған кескіндерді (басып шығарылған фотосуреттер, смартфон экрандары, Deepfake) анықтау және олардың жалған аутентификациясының алдын алу болып табылады.

Ұсынылған тәсілдің тиімділігін бағалау үшін FaceZ ансамбльдік моделінің дәлдігі мен жекелеген модельдер (FaceNet және DeepFace) арасындағы салыстырмалы эксперименттік талдау жүргізілді. Эксперименттер LFW деректер жинағы мен жеке жинақталған деректерді қамтитын біріктірілген датасет пайдаланылды. Жеке деректер жиынтығы әртүрлі 5970 бет-әлпет кескіндерінен құрылды. Барлық кескіндер алдын ала өңделіп, нормаланған және модельдің тұрақтылығын арттыру үшін аугментациядан өтті (шағылыстыру, жеңіл бұрулар және жарықтық өзгерістері).



Сурет 1. Жобада пайдаланылған адамдардың бейнесі.

Төмендегі салыстырмалы кестеде FaceZ ансамблінің жеке модельдермен салыстырғандағы артықшылықтарын көрсетеді.

1-кесте. Модельдерді бағалау көрсеткіштерінің сандық мәндері

Model	Accuracy	Precision	Recall	F1
FaceNet	99%	0.95	0.93	0.95
DeepFace	98%	0.92	0.9	0.91
FaceZ	99.6%	0.98	0.97	0.97

Эксперименттік нәтижелер FaceZ ансамблінің жеке модельдерден артықшылығын көрсетті. FaceNet 99%, DeepFace 98% дәлдікті көрсетті, ал FaceZ ансамблі 99,6%-ға жетті. Precision (98%), Recall (97%) көрсеткіштерінің жоғары болуы ансамбльдің жекелеген модельдердің кемшіліктерін толықтырып, тұрақты нәтижелер беретіндігін көрсетеді. DeepFace моделі жарықтандыру өзгерістеріне төзімді болғанымен, түсіру бұрышына сезімтал, ал FaceNet модельдердің ракурсқа тұрақты болғанымен, есептеу ресурстарын көп талап етеді. Қосымша спуфингке қарсы модульді интеграциялау бет-әлпетті алмастыру шабуылдары кезінде жалған сәйкестендіру жағдайларын шамамен 35%-ға қысқартып, жүйенің сенімділігі мен қауіпсіздігін арттырды.

Қорытындылай келе ұсынылған FaceZ ансамбльдік әдісі бет-әлпетті танудың ең жоғары дәлдігін көрсетті, бұл ұсынылған тәсілдің тиімділігін растайды. Классификация процесіне жалған кескіндерді анықтау ықтималдығының қосылуы жүйенің қауіпсіздігін арттырды және шабуылдар кезінде қате сәйкестендіру жағдайларын азайтты. FaceZ әдісін нақты уақыт режимінде автоматты сәйкестендіруді қажет ететін ақылды бейнебақылау жүйелерінде, парольсіз клиенттерді аутентификациялауда, сондай-ақ әуежайларда жолаушыларды биометриялық бақылау жүйелерінде қолдануға болады. Алайда ұсынылған әдістің жоғары дәлдігі есептеу ресурстарының көптігіне байланысты, бұл коммерциялық енгізу алдында қосымша оңтайландыруды қажет етеді.

Пайдаланылған әдебиеттер тізімі:

1. Supriya D. Kakade, A Review Paper on Face Recognition Techniques, Vol- 02, Issue 02, MAY 2016.

2. Taigman, Y., Yang, M., Ranzato, M., & Wolf, L. (2014). *DeepFace: Closing the gap to human-level performance in face verification*. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 1701–1708.

СИММЕТРИЯЛЫҚ ЖӘНЕ АСИММЕТРИЯЛЫҚ КРИПТОГРАФИЯЛЫҚ АЛГОРИТМДЕРДІҢ ӨНІМДІЛІГІН САЛЫСТЫРМАЛЫ ТАЛДАУ

Мауленова Алма Мухитовна

ал-Фараби атындағы Қазақ Ұлттық университетінің 1 курс магистранты
maulenova_alma@mail.ru

Адилжанова Салтанат Альмуханбетовна

ал-Фараби атындағы Қазақ Ұлттық университетінің PhD, доцент м.а.

Қазіргі ақпараттық жүйелерде деректердің құпиялылығын және тұтастығын сақтау маңызды аспект болып табылады. Осы мақсатта криптографиялық алгоритмдер кеңінен қолданылады, олардың ішінде симметриялық және асимметриялық әдістер ерекшеленеді. Симметриялық алгоритмдер, мысалы, AES және ChaCha20, жоғары жылдамдық пен төмен есептеу шығындарымен сипатталады, бұл оларды үлкен деректер көлемін өңдеуге тиімді етеді. Алайда, оларды қолдану кілттерді басқарудың күрделілігімен шектеледі. Асимметриялық алгоритмдер, мысалы, RSA және ECC, қауіпсіздіктің жоғары деңгейін қамтамасыз етеді, бірақ олардың есептеу жүктемесі жоғары, бұл оларды ресурстары шектеулі ортада пайдалануды қиындатады.

Криптографиялық алгоритмдердің тиімділігі шифрлау және дешифрлеу жылдамдығы, процессорлық жүктеме, жедел жадты пайдалану сияқты параметрлер бойынша бағаланады. AES-128, AES-256 және ChaCha20 жылдамдығы жоғары және ресурстық талаптары төмен болғандықтан кеңінен қолданылады [1]. Ал RSA-2048 және ECC сенімділігі жоғары болғанымен, үлкен есептеу қуатын қажет етеді, бұл оларды баяу етеді [2].

Практикалық зерттеулер көрсеткендей, OpenSSL негізінде жүргізілген сынақтарда симметриялық алгоритмдер асимметриялық әдістерге қарағанда едәуір жоғары жылдамдық көрсетті және аз жедел жады мен процессор ресурстарын қажет етті [3]. Сонымен қатар, ECC алгоритмінің RSA-мен салыстырғанда кілт өлшемінің аздығы оны мобильді құрылғылар мен ресурстары шектеулі жүйелер үшін оңтайлы нұсқа етеді.

Симметриялық алгоритмдер үлкен деректер ағындары мен бұлттық жүйелер үшін қолайлы, ал асимметриялық әдістер қауіпсіздік пен кілттерді басқарудың сенімді жүйелерін қажет ететін салаларда тиімді. Зерттеу нәтижелері көрсеткендей, ECC ресурстарды үнемдеу тұрғысынан RSA-ға қарағанда тиімдірек, ал AES және ChaCha20 жоғары жылдамдыққа ие бола отырып, үлкен көлемді деректерді қорғау үшін оңтайлы шешім болып табылады. Бұл талдау ақпараттық жүйелерде шифрлау әдістерін дұрыс таңдауға ғылыми негіз бола алады.

Пайдаланылған әдебиеттер тізімі:

1. Muhammed, R. K., Aziz, R. R., Hassan, A. A., Aladdin, A. M., Saydah, S. J., Rashid, T. A., & Hassan, B. A. «Comparative Analysis of AES, Blowfish, Twofish, Salsa20, and ChaCha20 for Image Encryption.», 2024.

2. Kuznetsov, A. V., & Petrov, I. N. «Assessment of the reliability of symmetric and asymmetric encryption methods», 2022.

3. Muhammed, R. K., Aziz, R. R., Hassan, A. A., Aladdin, A. M., Saydah, S. J., Rashid, T. A., & Hassan, B. A. «Comparative Analysis of AES, Blowfish, Twofish, Salsa20, and ChaCha20 for Image Encryption.»

МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН АҚПАРАТТЫҚ ҚАУІПСІЗДІК ТӘУЕКЕЛДЕРІН БАҒАЛАУДА ҚОЛДАНУ ТИІМДІЛІГІ

Миркасимова Т.Ш.

*Ғылыми жетекші: PhD Адилжанова С.А.
Әл-Фараби атындағы ҚазҰУ, Алматы, Қазақстан
E-mail: tolkyn.mirkasimova@gmail.com*

Андатпа. Бұл мақалада ақпараттық қауіпсіздік тәуекелдерін бағалауда машиналық оқыту модельдерінің тиімділігі талданады. Зерттеу барысында логистикалық регрессия (Logistic Regression), қолдау векторлық машинасы (SVM) және ең жақын көршілер әдісі (KNN) қолданылып, олардың нәтижелері салыстырылды. Бұл зерттеу ақпараттық қауіпсіздік тәуекелдерін басқару мен болжау әдістерін жетілдіруге үлес қосады.

Кілттік сөздер: ақпараттық қауіпсіздік, тәуекелдерді бағалау, машиналық оқыту, логистикалық регрессия, қолдау векторлық машинасы, ең жақын көршілер әдісі.

Қазіргі заманда ақпараттық қауіпсіздік тәуекелдерін бағалау ұйымдардың тұрақтылығы мен қорғанысына тікелей әсер ететін маңызды факторлардың бірі болып табылады. Киберқауіптердің артуы мен ақпараттық жүйелердің күрделенуі бұл бағытта жаңа әдістерді қолдануды талап етеді [1]. Осы орайда, машиналық оқыту әдістерін ақпараттық қауіпсіздікке енгізу – тәуекелдерді болжау мен басқарудың тиімді жолдарының бірі ретінде қарастырылады.

Жұмыстың мақсаты – әртүрлі машиналық оқыту модельдерін пайдалану арқылы қауіп-қатер деңгейін анықтау мен бағалау әдістемесін әзірлеу. Зерттеу барысында логистикалық регрессия, қолдау векторлық машинасы (SVM) және ең жақын көршілер әдісі (KNN) сияқты әдістер қолданылып, олардың нәтижелері салыстырылды [2].

Зерттеу барысында әрбір модель оқытылып, тестілік деректер жиынтығында сыналды. Дәлдік (accuracy), қамту деңгейі (recall), қате классификация матрицасы (Confusion Matrix) сияқты метрикалар арқылы олардың тиімділігі бағаланды. Сонымен қатар, деректерді визуализациялау үшін графикалық тәсілдер қолданылды [3].

Нәтижелер. Зерттеу нәтижелері көрсеткендей, SVM әдісі ең жоғары дәлдікке (98.62%) қол жеткізді, бұл оны ақпараттық қауіпсіздік саласындағы тәуекелдерді болжау үшін ең тиімді модель етті. KNN әдісі салыстырмалы түрде жақсы нәтиже көрсеткенімен (94.76%), оның есептеу тиімділігі төмен болды. Логистикалық регрессия кейбір күрделі үлгілерді ажыратуда әлсіздік танытып, 76.24% дәлдік көрсетті (1-сурет).

Қорытынды. Машиналық оқыту әдістерін қолдану ақпараттық қауіпсіздік тәуекелдерін болжауда тиімділігін дәлелдеді. Әсіресе, SVM алгоритмі жоғары дәлдік көрсеткіштерімен ерекшеленді. Болашақта ансамбльдік әдістер мен нейрондық желілерді пайдалану зерттеудің келесі қадамдары ретінде ұсынылады.

Пайдаланылған әдебиеттер тізімі:

1. В.В. Akhmetov, A.G. Korchenko, A.E. Arkhipov, S.V. Kazmirchuk, “Building information security risk analysis and assessment systems (Построение систем анализа и оценивания рисков информационной безопасности)”. Theory and practical solutions. The monograph. In 2-book 1, Aktau: editorial and publishing department of the KSUTI named after Sh.Yesenov, 2018 – 387 p.
2. A. Barlybayev, A. Sharipbay, G. Shakhmetova, A.Zhumadillayeva, “Development of a Flexible Information Security Risk Model Using Machine Learning Methods and Ontologies”. Applied Sciences, 2024. 14(21):9858. DOI: <https://doi.org/10.3390/app14219858>
3. A.H. Muhammad, A.Nasiri, A. Harimurti, “Machine learning methods for classification and prediction information security risk assessment,” IAES International Journal of Artificial Intelligence (IJ-AI). vol. 14, No. 1, Febuary 2025, pp. 457~465. ISSN: 2252-8938, DOI: <http://doi.org/10.11591/ijai.v14.i1.pp457-465>

ИОТ ҚАУІПСІЗДІГІН АРТТЫРУҒА АРНАЛҒАН МОДИФИКАЦИЯЛАНҒАН ГОМОМОРФТЫ ШИФРЛАУ АЛГОРИТМІ

Мырзақұл Ж.Н.

Ғылыми жетекші: Мусиралиева Ш.Ж. ф.-м.ғ.к., профессор

Әл-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан

Zhansaya.myrzakul@mail.ru

Заттар интернеті (IoT) заманауи цифрлық инфрақұрылымның ажырамас бөлігіне айналуға, бірақ оның қауіпсіздігі маңызды мәселе болып қала береді. IoT құрылғыларында көбінесе есептеу ресурстары шектеулі, бұл дәстүрлі криптографиялық қорғаныс әдістерін қолдануды қиындатады. Гомоморфты шифрлау (GSH) шифрланған деректердің шифрын ашпай-ақ есептеуге мүмкіндік беретін перспективалық шешімді ұсынады. Дегенмен, классикалық GS схемалары жоғары өңдеу қуатын қажет етеді, бұл олардың IoT-да қолданылуын шектейді. Бұл зерттеу IoT ортасында олардың тиімділігін арттыру үшін қолданыстағы гомоморфты алгоритмдерді модификациялауға бағытталған.

Зерттеудің негізгі міндеттері: IoT-да қолданылатын қолданыстағы шифрлау әдістерін талдау; шектеулі есептеу ресурстары жағдайында гомоморфты шифрлауды қолдану мүмкіндіктерін зерттеу; оның тиімділігін арттыру үшін гомоморфты шифрлау алгоритмін әзірлеу және модификациялау; ұсынылған шешімнің өнімділігі мен қауіпсіздігін бағалау; бағдарламалық жасақтаманың прототипін жасау және нақты IoT құрылғыларында тестілеу болып табылады.

Негізгі нәтижелер: IoT-да деректерді қорғаудың қолданыстағы криптографиялық әдістеріне талдау жүргізілді және олардың шектеулері анықталды. IoT құрылғыларының есептеу ресурстарының шектеулерін ескере отырып, модификацияланған гомоморфты алгоритм ұсынылды. Ұсынылған әдістің өнімділігіне тестілеу жүргізілді және оның дәстүрлі шифрлау схемаларымен салыстырғанда тиімділігі расталды. Ұсынылған әдісті іс жүзінде қолдануды көрсететін бағдарламалық прототип жасалды.

Зерттеу IoT-те модификацияланған гомоморфты шифрлауды қолдану есептеу шығындарын айтарлықтай арттырмай, қауіпсіздік деңгейін айтарлықтай арттыруға мүмкіндік беретінін растайды (1-кесте).

1-кесте. 256, 512, 1024, 2048 байт көлемдегі деректер үшін салыстыру мәндері

Компьютер (C++)				
шифрлау (microseconds)	дешифрлау	дешифрлау (модификация)	гомоморфты шифрлау (кобейту) + дешифрлау (қарапайым)	Гомоморфное шифрование (кобейту) + дешифрование (модиф)
256 bytes				
3329	2058	1984	1820	1820
512 bytes				
7458	3899	3856	4098	3650
1024 bytes				
13993	7951	7628	7436	7393
2048 bytes				
27782	17362	15224	14657	14362

Әзірленген алгоритмді әртүрлі IoT сценарийлерінде, соның ішінде Ақылды қалаларда, медициналық құрылғыларда және өнеркәсіптік жүйелерде қолдануға болады. Қосымша зерттеулер алгоритмді нақты IoT протоколдарына бейімдеуге және оны қолданыстағы киберқауіпсіздік архитектураларына біріктіруге бағытталуы мүмкін.

Пайдаланылған әдебиеттер тізімі:

1. Мусиралиева Ш.Ж., Мырзақұл Ж.Н. Деректерді қауіпсіз өңдеуге арналған гомоморфты операцияларды қолдайтын модификацияланған El-Gamal криптожүйесі // Информатика и прикладная математика: Мат. IX Межд. науч.-практ. конф. (31.10 - 01.11.2024 г.). – Алматы: Институт информационных и вычислительных технологий КН МНВО РК, 2024. – С. 10. – 807 с. – ISBN 978-601-228-472-0.

ФЕДЕРАТИВТІ ОҚЫТУ: ТАРАТЫЛҒАН ҚҰРЫЛҒЫЛАРДА ҚҰПИЯ ДЕРЕКТЕРДІ ҚОРҒАУДЫҢ ЖАҢА ДӘУІРІ

Омар Айым Бекболатқызы

Әл-Фараби атындағы Қазақ Ұлттық университетінің, киберқауіпсіздік және криптология кафедрасының I курс докторанты, Алматы, Қазақстан

e-mail: aiym.omar98@gmail.com

Мусиралиева Шынар Женисбековна

Әл-Фараби атындағы Қазақ Ұлттық университетінің, киберқауіпсіздік және криптология кафедрасының меңгерушісі, профессор, Алматы, Қазақстан

Машиналық оқытудың дәстүрлі тәсілі модельдерді оқыту үшін орталықтандырылған деректерді жинауды қамтиды, бұл ақпаратқа рұқсатсыз қол жеткізу және ақпараттың ағып кету қаупін тудырады. Федеративті оқыту жаңа перспективалы шешім ретінде танылып отыр. Федеративті оқыту аясында әрбір қатысушы өз деректерінде оқытылып, содан кейін орталық серверге тек жаңартылған модель параметрлерін жібереді. Мұндай архитектураның арқасында федеративті оқыту деректердің құпиялылығын қорғайды, өйткені деректердің өздері пайдаланушылар құрылғысынан тыс ешқайда жіберілмейді. Осылайша, федеративті оқыту орталықтандырылған машиналық оқытуға қарағанда құпиялылықты жақсы сақтайды.

Бұл зерттеу деректердің құпиялылығын қамтамасыз етуге ерекше назар аудара отырып, деструктивті мазмұнды өңдеу кезінде федеративті оқытуды қолданудың әдістері мен тәсілдерін әзірлеуге және негіздеуге бағытталған.

Көптеген зерттеулер әртүрлі салалардағы федеративті оқытудың архитектурасына, қолданылуына және болашағына арналған. Бұл жұмыстардың нәтижелері осы әдістің келешегі зор екенін растайды. Мысал ретінде келесі авторлардың еңбектерін қарастыруға болады:

Banabila[1] деректерді қорғау мәселелерін зерттей отырып болашақ перспективаларды қамтитын федеративті оқыту негіздеріне (FL) толық шолу жасайды.

AbdulRahman[2] федеративті оқыту (FL) әдістерін жіктейді және оны үш тұрғыдан қарастырады: үлгі, ресурстарды басқару және құпиялылық пен қауіпсіздік.

Liu[3] NLP үшін федеративті оқыту (FL) туралы ең толық шолуды ұсынады: олар әртүрлі NLP қолданбаларын қамтиды және бірнеше негізгі қиындықтарды анықтайды.

Qammar[4] федеративті оқытумен (FL) байланысты шабуылдарды және қиындықтарды мұқият талдайтын шолуды ұсынады. Ол құпиялылық, қолжетімділік және тұтастық аспектілерін қамтитын шабуылдар мен қарсы шаралар таксономиясын ұсынады.

Аталған ғалымдардың зерттеулеріне сүйене отырып, киберқауіпсіздік саласында федеративті оқытудың болашағы зор екендігін ұйғарсақ болады. Сонымен қатар, Differential Privacy және Homomorphic Encryption технологияларын федеративті оқыту әдісімен біріктіру деректердің құпиялылығын қамтамасыз етудің кешенді шешімі болып табылады.

Қорытындылай келе, федеративті оқыту деректер қауіпсіздігін қамтамасыз ету және өнімділікті арттырудың озық әдісі, оның болашақта қолдану аясы кеңейіп, әртүрлі салаларда маңызды рөл атқаратыны анық.

Пайдаланылған әдебиеттер тізімі:

1. Banabilah S, Aloqaily M, Alsayed E, Malik N, Jararweh Y (2022) Federated learning review: Fundamentals, enabling technologies, and future applications. *Inf Process Manag* 59(6):103061
2. AbdulRahman S, Tout H, Ould-Slimane H, Mourad A, Talhi C, Guizani M (2020) A survey on federated learning: the journey from centralized to distributed on-site learning and beyond. *IEEE Internet Things J* 8(7):5476–5497
3. Liu M, Ho S, Wang M, Gao L, Jin Y, Zhang H (2021). Federated learning meets natural language processing: a survey. *arXiv preprint [arXiv:2107.12603](https://arxiv.org/abs/2107.12603)*

4. Qammar A, Ding J, Ning H (2022) Federated learning attack surface: taxonomy, cyber defences, challenges, and future directions. *Artif Intell Rev* 55(5):3569–3606. <https://doi.org/10.1007/s10462-021-10098-w>

.NET ПЛАТФОРМАСЫНДАҒЫ АУТЕНТИФИКАЦИЯ ҚАУІПСІЗДІГІ

Рахимов А.Ж.

Әл-Фараби атындағы ҚазҰУ, Алматы, Қазақстан

e-mail: aman.rakhimov19@gmail.com

.NET платформасындағы аутентификацияның қауіпсіздігі пайдаланушының жеке деректері мен жүйе қауіпсіздігін қамтамасыз етуде шешуші рөл атқарады. Аутентификация механизмдерінің сенімділігі негізінен парольдердің беріктігіне, көпфакторлы аутентификацияға (MFA), токендердің қауіпсіз басқарылуына және cookie файлдарының дұрыс конфигурациялануына тәуелді [1].

Бұл жұмыста .NET платформасында аутентификация қауіпсіздігін арттыру мақсатында қолданылатын әдістер мен тәжірибелер қарастырылды. Пароль қауіпсіздігін қамтамасыз ету үшін ASP.NET Identity фреймворкіне енгізілген PBKDF2 алгоритмін және қосымша ретінде bcrypt немесе Argon2 алгоритмдерін пайдалану ұсынылды. Сонымен қатар, пароль саясатында кем дегенде 8 символдан тұратын, үлкен-кіші әріптерді, сандарды және арнайы таңбаларды қамтитын талаптарды орнату қажеттілігі көрсетілді.

Қауіпсіздікті арттырудың тағы бір маңызды аспектісі – көпфакторлы аутентификацияны енгізу. MFA арқылы пайдаланушылардың жеке деректерін қорғау үшін қосымша тексеру кезеңдері (SMS, Email немесе Authenticator қосымшалары арқылы) қосылуы қажет.

JWT (JSON Web Token) негізіндегі аутентификацияны қолданған кезде токеннің жарамдылық мерзімін қысқарту, HTTPS протоколын қолдану және токенді құру үшін пайдаланылатын құпия кілттерді сенімді сақтау маңызды екені атап өтілді. Cookie негізіндегі аутентификация үшін cookie файлдарының Secure, HttpOnly және SameSite атрибуттарын дұрыс конфигурациялау қажеттілігі көрсетілді. Сонымен қатар, аутентификация жүйесінің қауіпсіздігін арттыру үшін логтарды жүргізу және мониторинг жасау ұсынылды. Сәтсіз кіру әрекеттерін тіркеу, сондай-ақ авторизация кезеңінде пайдаланушы рөлдерін тиімді басқару маңызды [2].

Кесте 1

.NET платформасындағы аутентификация қауіпсіздігін қамтамасыз етудің негізгі әдістері

Қауіпсіздік аспектісі	Ұсынылатын әдіс	Пайдасы
Пароль қауіпсіздігі	PBKDF2, bcrypt, Argon2 алгоритмдері арқылы хештеу; пароль саясатын күшейту	Парольдердің бұзылуына төзімділікті арттырады
Көпфакторлы аутентификация (MFA)	SMS, Email, Authenticator қосымшалары арқылы қосымша тексеру	Пайдаланушы аккаунттарын заңсыз кіруден қорғайды
JWT қауіпсіздігі	Токендердің қысқа мерзімділігі, HTTPS қолдану, құпия кілттерді қорғау	Токендерді ұрлау қаупін азайтады
Cookie қауіпсіздігі	Secure, HttpOnly, SameSite атрибуттарын қолдану	Cookie ұрлау, XSS шабуылдарының алдын алады

Осы зерттеу барысында .NET платформасындағы аутентификация қауіпсіздігін қамтамасыз етуде жоғарыда аталған тәжірибелердің маңыздылығы мен тиімділігі көрсетілді. Аталған ұсыныстарды енгізу жүйенің қауіпсіздігін айтарлықтай арттыратыны және қауіп-қатерлердің алдын алуға мүмкіндік беретіні дәлелденді.

Пайдаланылган әдебиеттер тізімі:

1. Freeman, A. (2021). *Pro ASP.NET Core 6: Develop Cloud-Ready Web Applications Using MVC, Blazor, and Razor Pages*. 9th Edition. Apress.
2. Microsoft Docs. (2023). *ASP.NET Core Security Best Practices*.
URL:<https://learn.microsoft.com/en-us/aspnet/core/security/>

ҚАЗАҚ ТІЛІНДЕГІ ҚАУІПТІ ВЕБ-КОНТЕНТТІ АНЫҚТАУ ЖӘНЕ ЖІКТЕУ ҮШІН МАШИНАЛЫҚ ОҚЫТУ МОДЕЛЬДЕРІН ҚҰРУ

Сағынай М.

*Әл-Фараби атындағы Қазақ ұлттық университеті 2 курс докторанты e-mail:
sagynaymoldir11@gmail.com*

Болатбек М.А.

Әл-Фараби атындағы Қазақ ұлттық университеті, Phd., аға оқытушы

Қазақ тіліндегі деструктивті веб-мазмұнды анықтау мен жіктеу мәселесі өзекті зерттеу бағыттарының бірі болып табылады. Қазақ тілі табиғи тілді өңдеу саласында аз зерттелген тілдердің қатарына жататындықтан, оның лингвистикалық және мәдени ерекшеліктерін ескере отырып, терең оқыту әдістерін бейімдеу қажет. Бұл мақала қазақ тіліндегі деструктивті контентті анықтауға бағытталған әдістемелік тәсілді ұсынады.

Интернеттегі контентті бақылау тек этикалық қана емес, сонымен қатар құқықтық талаптарға да сай болуы керек. Әлемнің көптеген елдерінде әлеуметтік желі платформалары заңнамалық шектеулерге сай жұмыс істеуі қажет, бұл олардың автоматты модерацияға деген сұранысын арттырады [1].

Зерттеудің негізгі мақсаты – қазақ тіліндегі зиянды хабарламаларды тиімді анықтайтын және оларды тиісті санаттарға бөлетін машиналық оқыту үлгілерін әзірлеу әдісін қарастыру.

Деструктивті веб-контент жеке тұлғаларға, ұйымдарға немесе ақпараттық жүйелерге зиян келтіретін онлайн материалдар жиынтығы болып табылады. Мұндай контентке зиянды бағдарламаларды тарату, жеке ақпаратты алдап алу (фишинг), өшпенділік пен зорлық-зомбылықты насихаттау, жалған ақпарат тарату және қоғамдық пікірді манипуляциялау жатады [2].

Деструктивті хабарламалар адамдарға психологиялық, моральдық немесе физикалық зиян тигізуі мүмкін. Оларды бірнеше негізгі топтарға бөлуге болады: буллинг – жеке тұлғаға немесе адамдар тобына бағытталған қорлау, қорқыту немесе психологиялық қысым жасау; нәсілшілдік – белгілі бір нәсілге немесе этникалық топқа қарсы кемсітушілікке бағытталған мазмұн; ұлттық экстремизм (нацизм) – белгілі бір ұлт өкілдеріне қарсы өшпенділік немесе кемсітушілік сипаттағы ақпарат тарату; зорлық-зомбылық экстремизмі – саяси, діни немесе идеологиялық мақсаттарға жету үшін зорлық-зомбылықты ақтайтын немесе насихаттайтын мазмұн.

Зерттеу барысында осы төрт негізгі санат бойынша деректер жиынтығы (датасет) құрылды. Сонымен қатар, нейтралды сипаттағы мәтіндерді қамтитын бесінші класс қосылды.

Бұл зерттеу қазақ тіліндегі деструктивті веб-контентті автоматты түрде анықтау мен жіктеуге арналған терең оқыту моделін әзірлеуді мақсат етеді. Деструктивті хабарламаларды қамтитын арнайы деректер жинағын құру негізінде, үлгіні тиімді оқыту мен бағалау әдістемесі ұсынылады. Бұл әдіс қазақ тіліндегі онлайн қауіпсіздікті арттыруға және теріс контенттің таралуын азайтуға ықпал етеді. Берілген зерттеу жұмысы Қазақстан Республикасы Ғылым және жоғары білім министрлігінің Ғылым комитеті қаржыландыратын “Жастар экстремизмін анықтау және заманауи ақпараттық кеңістікте жастардың қауіпсіздігін қамтамасыз етуге арналған модельдер мен әдістерді әзірлеу” жобасы аясында орындалды (грант АР19576868, жоба жетекшісі Болатбек М.А.).

Пайдаланылған әдебиеттер тізімі:

1. Исхакова А., Исхаков А., Мещеряков Р. Исследование оценочных эмоциональных компонентов для контент-анализа // Журнал физики: Серия конференций. – Издательство ИОР, 2019. – Т. 1203. – №. 1. – С. 012065.
2. Барахнин В. Б. и др. Методы выявления деструктивной информации // Физический журнал: Серия конференций. – Издательство ИОР, 2019. – Т. 1405. – №. 1. – С. 012004.

ШАҒЫН БИЗНЕС ҰЙЫМДАРЫНДАҒЫ АҚПАРАТТЫҚ ҚАУІПСІЗДІК ЖҮЙЕСІН ҚАМТАМАСЫЗ ЕТУ ЖӘНЕ ӘДІСТЕРІН ҚҰРАСТЫРУ

Сериккажина Майгул Серикқажықызы

2 курс магистрант

Ғылыми жетекші: Мурзабеков З.Н. – т.ғ.д., доцент

Кіріспе. Қазіргі цифрлық әлемде ақпараттық қауіпсіздікті күшейту (АҚ) кез келген көлемдегі кәсіпорындардың, соның ішінде, шағын бизнес ұйымдарының негізгі міндеттерінің біріне айналууда.

Шағын бизнес ұйымдары фишингтік шабуылдарға, зиянды бағдарламаларға және деректердің ағып кетуіне осал, әрі олар орта есеппен 200-300 күн бойы деректердің ағып кетуін байқамауы мүмкін. Сондай-ақ, түрлі зерттеулерге сәйкес, 2023-2024 жылы Қазақстанда шағын бизнеске жасалған кибершабуылдар саны 80%-ға өскен. 4,2 мың кибершабуыл тіркелген, бұл өткен жылдың сәйкес кезеңімен салыстырғанда екі есе көп. Шабуылдардың басым бөлігі фишингке (43%), төлемдік бағдарламаға (30%) және деректердің ағып кетуіне (15%) қатысты. Шағын бизнестің 67%-да базалық қауіпсіздік (сақтық көшірме, антивирус, көп факторлы аутентификация) жоқ. Мемлекеттік реттеу әлі де шектеулі және орталықтандырылған қолдау жоқ. Келтірілген деректер ақпаратты қорғаудың қолжетімді және тиімді әдістерін әзірлеу қажеттілігін көрсетеді [1].

Зерттеу барысында шағын ұйымдардағы ақпараттық қауіпсіздікке шешім жүйесі ұсынылатын болады. Кешенді әдіс шағын бизнес ұйымдарының киберинциденттер қаупін барынша азайтуға мүмкіндік береді.

Материалдар мен әдістер. Жұмыстың бірінші кезеңінде ақпараттық қауіпсіздік құралдарын енгізумен айналысатын интеграторлық компаниялардың басшылары мен қызметкерлеріне сауалнама жүргізілді.

Сауалнамаға барлығы он қазақстандық компания (бес ЕДБ және бес интеграторлық компания) қатысты. Алынған деректер негізінде нәтижелер қорытындыланып, шағын бизнестің 67%-ы деректердің бұзылуымен күресу үшін жеткілікті дағдылары жоқ екенін айтты.

Шетелдік тәжірибені зерттейтін болсақ, шағын бизнес ұйымдарының қызметкерлері өте көп мүмкіндіктерге ие екенін байқауға болады. Мысалы:

CISA (Cybersecurity & Infrastructure Security Agency) - кәсіпорындарды оқытады және тегін құралдармен қамтамасыз етеді.

Шағын бизнеске арналған қауіпсіздік стандарттары NIST Cybersecurity Framework және Германия, Франция, Нидерланды сияқты мемлекеттерде Small Business Administration (SBA) киберқауіпсіздік шығындарының бір бөлігін өтейтін субсидиялар қарастырылған.

Сондай-ақ, ұйымдарға өздерін қорғауға ынталандыру үшін деректердің ағып кетуі жағдайында қатаң айыппұлдар салынады [2].

Зерттеу барысында, шағын бизнеске арналған төменде келтірілген мемлекеттік киберқауіпсіздік платформасын құру шешімі ұсынылады.

1. Қаржылық қолдау (субсидиялар және SaaS шешімдері):

- Антивирустар, VPN, WAF, SIEM, резервтік көшірмеге арналған шығындардың 30-50% төлейтін мемлекеттік өтемақы;

- Жергілікті қауіпсіз бұлттық қызметтерге жеңілдетілген бағамен қол жеткізу;

2. Қауіптердің орталықтандырылған мониторингі (шағын бизнеске арналған SOC):

- Қазақстандық компаниялардың деректерінің ағып кетуіне мониторинг жүргізу;

- Оқиғаларға реакция беру үшін қазақстандық CERT-пен интеграция;

3. Ең аз киберқауіпсіздік стандарттары (міндетті талаптар):

- Бизнес жүйелері үшін MFA енгізу;

- Маңызды деректердің міндетті сақтық көшірмесін жасау;

- Корпоративтік электрондық поштаны қорғау үшін DMARC, SPF, DKIM қосу.

Платформаны жүзеге асыру жұмыстары

1 кесте

Кезең	Сипаттама	Мерзімі
Қауіпті талдау	Шағын бизнестің киберқауіпсіздігінің ағымдағы жағдайын бағалау	3 ай
Платформаны дамыту	Оқыту, субсидиялар және SOC хабарламалары бар веб-ресурсты құру	6 ай
Пилоттық жобаны іске қосу	1000+ шағын компанияларда тестілеу	6 ай
Толық ауқымды енгізу	Платформаны әзірлеу, барлық компаниялар үшін міндетті стандарттар	12 ай

Ары қарай зерттеу жұмысын жалғастыру үшін келесі қадамдар ұсынылады:

Жобаны мемлекеттік деңгейде талқылауға дайындау;

Мемлекеттік органдар базасында платформаның пилоттық нұсқасын әзірлеу (мысалы, Қазақстан Республикасы Цифрлық даму министрлігі);

Мемлекеттік қаржыландыру арқылы SaaS шешімдерін жасау үшін IT компанияларын тарту.

Қорытынды. Жыл сайын шағын бизнеске шабуылдар саны өсуде. Сарапшылардың болжауынша, киберқауіптер алдағы жылдарда барған сайын күрделене түседі және қауіпті болады, бұл шағын бизнестен қауіпсіздіктің неғұрлым жетілдірілген әдістерін қабылдауды және сыртқы киберқауіпсіздік қызмет провайдерлерімен бірлесіп жұмыс істеуді талап етеді [3].

Цифрландыру және киберқауіптердің өсуі жағдайында шағын бизнес ұйымдарында ақпараттық қауіпсіздікті қамтамасыз ету басымдыққа айналуы тиіс

Осылайша, ақпараттық қауіпсіздік саласында бейімделген және қолжетімді шешімдерді әзірлеу шағын бизнес ұйымдарына бәсекеге қабілетті бизнес ортада тұрақты дамуды қамтамасыз етуге мүмкіндік береді [4].

Пайдаланылған әдебиеттер тізімі:

1. М.М.Путятто, А.С.Макарян. Кибербезопасность как неотъемлемый атрибут многоуровневого защищенно-го киберпространства / М.М. Путятто, А.С. Макарян // Прикаспийский журнал: управление и высокие тех-нологии, 2020. -No 3(51).- стр. 94-102.

2. Costa I., Guarda T. Information System Security Risk Priority Number: A New Method for Evaluating and Prioritization Security Risk in Information System Applying FMEA //Proceedings of International Conference on Information Technology and Applications: ICITA 2021. – Singapore : Springer Nature Singapore, 2022. – pp. 561-572. https://link.springer.com/chapter/10.1007/978-981-16-7618-5_49

3. 12. Aldoseri A., Al-Khalifa K. N., Hamouda A. M. Methodological approach to assessing the current state of organizations for AI-Based digital transformation //Applied System Innovation. – 2024. – Т. 7. – №. 1. – С. 14. <https://www.mdpi.com/2571-5577/7/1/14>

4. Козырь Н. С., Оганесян Л. Л. Ақпараттық қауіпсіздіктің экономикалық аспектілері: Жоғары оқу орындарына арналған оқулық және практикум. – Мәскеу: Юрайт баспасы, 2025. – 131 б. – ISBN 978-5-534-17863-0. <https://urait.ru/bcode/568708>

МАШИНАЛЫҚ ОҚЫТУ АРҚЫЛЫ БЕЙНЕЛЕРДЕГІ ЖЕККӨРІНШТІ МАЗМҰНДЫ ТАБУ

Сериккалиева А.К.

әл-Фараби атындағы Қазақ Ұлттық Университетінің 1 курс магистранты
E-mail: arukanatovna03@mail.ru

Болатбек М.А.

әл-Фараби атындағы Қазақ Ұлттық университеті, PhD, доцент м.а

Цифрлық технологиялардың кең таралуы мен әлеуметтік желілердің дамуы жеккөрушілік контентінің таралуына алып келді. Әлеуметтік медиа платформалар пайдаланушылар жариялайтын үлкен көлемдегі мазмұнмен жұмыс істейді. Олардың арасында өшпенділік, кемсітушілік және агрессия мазмұнындағы бейнежазбалар кездеседі. Әлеуметтік медиа платформаларда заң бұзушылыққа алып келетін контенттерді бұғаттайтын белгілі бір ережелер мен әдістер болғанның өзінде, жеккөрушілік мәселесі әлі күнге дейін үлкен тақырып болып табылады.

Бейнелердегі жеккөрінішті мазмұнды анықтау әлеуметтік медиа платформалардың қоғамға әсерінің артуына байланысты өзекті тақырыпқа айналууда. Әлеуметтік медиа платформалар коммуникацияның негізгі құралына айналғандықтан, олар жеккөрушілік және кемсітушілік мазмұны жылдам таралатын кеңістік болып табылады. Бейнелердегі жеккөрушіліктің өршуі зорлық-зомбылық пен кемсітушілікке және әлеуметтік толқуларға ықпал ететін салдарға алып келу мүмкіндігі жоғары. Қауіпсіз онлайн ортаны қамтамасыз ету қоғамды зиянды материалдардан қорғау және пайдаланушылардың белсенділігін сақтау үшін өте маңызды. Цифрлық технологияларды қолдану қарқынды түрде өсіп келе жатқандықтан, жеккөрушілікке толы материалдардың мазмұнын анықтау ғылыми зерттеу және технологиялық дамудың маңызды саласы болып табылады.

Машиналық оқыту модельдерінің дәлдігі деректер сапасы, модельді таңдау және гиперпараметрлерге байланысты. Multinomial Naïve Bayes, Linear SVM, Random Forest және RNN сияқты модельдер қолданылады. Мысалы, Random Forest алгоритмі 2020 жылы жүргізілген зерттеуде 86% дәлдік көрсетті.

Дәстүрлі әдістер мағына мен контекстті түсінуде тиімсіз болғандықтан, трансформерлер мен мультимодальды модельдер перспективалы тәсіл ретінде қарастырылады. Indian Institute of Technology (ИИТ) 2023 жылғы зерттеуінде аудио, мәтін және бейне деректерін біріктіре отырып, мультимодальды модельдердің жоғары тиімділігін дәлелдеді.

Дегенмен, үлкен деректерді өңдеу, шуды азайту және модельдердің интерпретациясын жақсарту сияқты қиындықтар әлі де бар. Болашақта мультимодальды модельдерді жетілдіру жасанды интеллекттің дамуына үлес қосады.

Пайдаланылған әдебиеттер тізімі:

1. Wu C. S., Bhandary U. Detection of hate speech in videos using machine learning //2020 international conference on computational science and computational intelligence (CSCI). – IEEE, 2020. – С. 585-590.
2. Wang H. et al. Multihateclip: A multilingual benchmark dataset for hateful video detection on youtube and bilibili //Proceedings of the 32nd ACM International Conference on Multimedia. – 2024. – С. 7493-7502.
3. Das, M., Raj, R., Saha, P., Mathew, B., Gupta, M., & Mukherjee, A. (2023, June). Hatemm: A multi-modal dataset for hate video classification. // Proceedings of the International AAAI Conference on Web and Social Media (Vol. 17, pp. 1014-1023).

МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІН ҚОЛДАНА ОТЫРЫП, ИНТЕРНЕТ ҚАУІПТЕРІН ЗЕРТТЕУ ЖӘНЕ ТАЛДАУ

Мамажанов Д.С., Жумахан Р.Ж., Мырзаханов М.Ж.

Ғылыми жетекші: т.ғ.м., аға оқытушы Байспай Г.Б.

Әл-Фараби атындағы ҚазҰУ, Алматы, Қазақстан

E-mail: mamazanovdaulet217@gmail.com

Аңдатпа. Бұл мақалада машиналық оқыту алгоритмдерін қолдана отырып, интернет қауіптерін зерттеу және талдау мәселесі қарастырылған. Интернеттегі қауіптердің ең көп тараған түрі – зиянды бағдарламалық қамтамасыз ету (ЗБЖ) жан-жақты талданып, Windows операциялық жүйесінде кеңінен таралған Portable Executable (PE) файлдарына статикалық талдау жүргізілді. Зерттеу барысында бірнеше машиналық оқыту алгоритмдері мен нейрондық желілердің тиімділігі салыстырылып, ең үздік алгоритмдер ұсынылды. Зерттеу нәтижелері интернет қауіптерін алдын ала анықтауға және ақпараттық қауіпсіздік деңгейін арттыруға ықпал етеді.

Кілттік сөздер: ақпараттық қауіпсіздік, интернет қауіптері, зиянды бағдарламалық қамтамасыз ету, машиналық оқыту, Portable Executable файлдары, XGBoost, LightGBM, CatBoost, статикалық талдау.

Интернет желісінің кеңінен қолданылуы және цифрлық технологиялардың дамуы киберқауіптердің саны мен күрделілігін арттыруда. Интернет қауіптері, оның ішінде зиянды бағдарламалық қамтамасыз ету, деректер ұрлау, кибершабуылдар секілді қатерлер бүкіл әлемде кең таралуда. Осындай қауіптердің алдын алу және тиімді қорғаныс әдістерін жасау үшін машиналық оқыту алгоритмдерін қолдану қажеттілігі туындайды.

Бұл зерттеуде ақпараттық қауіпсіздік тәуекелдерін бағалауда қолданылатын машиналық оқыту әдістері қарастырылады. Жұмыстың мақсаты – әртүрлі машиналық оқыту модельдерін пайдалану арқылы қауіп-қатер деңгейін анықтау мен бағалау әдістемесін әзірлеу. Зерттеу барысында логистикалық регрессия, қолдау векторлық машинасы (SVM) және ең жақын көршілер әдісі (KNN) сияқты әдістер қолданылып, олардың нәтижелері салыстырылды.

Зерттеудің негізгі мақсаты – машиналық оқыту әдістерін қолдану арқылы зиянды бағдарламалық қамтамасыз етуді (ЗБЖ) анықтау болып табылады. Зиянды бағдарламалық жасақтама (ЗБЖ) – бұл пайдаланушының келісімінсіз компьютерге енгеннен кейін әртүрлі зиян келтіретін немесе ақпаратты ұрлайтын бағдарламалар тобы. Windows операциялық жүйесінде қолданылатын Portable Executable (PE) файлдары – бұл бағдарламаларды іске қосу үшін пайдаланылатын негізгі формат болып табылады. Өкінішке қарай, бұл формат жиі зиянды бағдарламаларды тарату үшін де қолданылады.

Жұмыс барысында зиянды бағдарламаларды статикалық талдаудың тәсілдері мен машиналық оқыту алгоритмдерін біріктіре отырып, PE-файлдардың құрылымын талдауға негізделген әдістер қолданылды. PE-файлдар форматында негізгі бірнеше бөлім бар: DOS Header, COFF Header, Optional Header және Section Table. DOS Header файлдың басында орналасқан және оның басты міндеті – файлдың PE екендігін растайтын «MZ» қолтаңбасын қамтиды. COFF Header файлдың архитектурасы, секциялардың саны, жасалу уақыты (TimeDateStamp) туралы ақпарат береді. Optional Header бағдарламаның орындалуы үшін қажетті маңызды ақпаратты қамтиды, соның ішінде кодтың негізгі адресі (ImageBase), енудің бастапқы нүктесі (AddressOfEntryPoint), файлдағы бөлімдердің өлшемдері және файлдың жүктелуіне қажетті басқа параметрлер бар. Section Table әр секция туралы толық ақпарат береді, мысалы, секцияның аты, өлшемі және орналасқан виртуалды мекен-жайы.

Осы мәліметтер негізінде арнайы деректер жиынтығы (датасет) құрастырылды. Осы датасет негізінде Random Forest, Gradient Boosting, Decision Tree, K-Nearest Neighbors, Naive Bayes, MLP Classifier, AdaBoost, XGBoost, LightGBM, CatBoost алгоритмдерімен қатар, терең нейрондық желілер (DNN, CNN, LSTM) арқылы модельдер оқытылды.

Зерттеу нәтижелері accuracy, recall, F1-score және log loss сияқты бағалау көрсеткіштері бойынша салыстырылды (нәтижелері 1-суретте көрсетілген). Ең жоғары дәлдікті XGBoost (99.25%), LightGBM (99.21%) және CatBoost (99.21%) алгоритмдері көрсетті. Сондықтан нақты уақыттағы талдау үшін осы үш алгоритмді қолдану ұсынылады.

Model	Accuracy	Recall	F1-Score	Log Loss
Random Forest	0.992284	0.992284	0.992154	0.037889
Gradient Boosting	0.987924	0.987924	0.987665	0.041344
Decision Tree	0.990775	0.990775	0.990718	0.332506
K-Nearest Neighbors	0.967964	0.967964	0.965050	0.485326
Naive Bayes	0.132338	0.132338	0.146573	9.132585
MLP Classifier	0.952868	0.952868	0.941483	1.698804
AdaBoost	0.981550	0.981550	0.980957	0.625846
XGBoost	0.992452	0.992452	0.992319	0.025611
LightGBM	0.992117	0.992117	0.992000	0.026550
CatBoost	0.992117	0.992117	0.991977	0.027207
DNN	0.988091	0.988091	0.987881	0.045009
CNN	0.984569	0.984569	0.984484	0.049724
LSTM	0.984904	0.984904	0.984513	0.054091

1-сурет. Алгоритмдердің бағалау көрсеткіштері

Қорытынды: Зерттеу барысында машиналық оқыту алгоритмдерінің интернет қауіптерін, атап айтқанда зиянды бағдарламалық қамтамасыз етуді анықтауда жоғары тиімділігі дәлелденді. Алынған нәтижелер интернет қауіптерін ерте кезеңде анықтап, ақпараттық қауіпсіздікті қамтамасыз етуге мүмкіндік береді. Болашақта нейрондық желілер мен ансамбльдік әдістерді тереңірек зерттеп, алгоритмдердің тиімділігін одан әрі арттыру қажет.

Пайдаланылған әдебиеттер тізімі:

1. Wahba Kamaluddin. “241212 - malware detection using data_HEAD”. Kaggle. DOI: <https://www.kaggle.com/code/wahbakamaluddin/241212-malware-detection-using-data-head/input>
2. U.A. Kravchenko, K.A. Pyhanov, “ОСНОВНЫЕ УГРОЗЫ В ИНТЕРНЕТЕ И СПОСОБЫ ИХ ПРЕДОТВРАЩЕНИЯ”. Don State Technical University, 2023. DOI: <https://cyberleninka.ru/article/n/osnovnyye-ugrozy-v-internete-i-sposoby-ih-predotvrascheniya/viewer>
3. D.U. Cherkasov, V.V. Ivanov, “Машинное обучение”, Moscow Technological University, February 2018, DOI: <https://cyberleninka.ru/article/n/mashinnoe-obuchenie>

ESP32 НЕГІЗІНДЕГІ МЕДИЦИНАЛЫҚ ЖҮЙЕЛЕРДЕГІ КРИПТОГРАФИЯЛЫҚ АЛГОРИТМДЕРДІҢ ӨНІМДІЛІГІНЕ СЫРТҚЫ ФАКТОРЛАРДЫҢ ӘСЕРІН ТАЛДАУ

Сыбанова Дана

«Ақпараттық қауіпсіздік аудиті» мамандығының 1 курс магистранты

Кіріспе

Интернет заттары (IoT) және цифрлық егіз технологияларының қарқынды дамуына байланысты нақты уақыт режимінде бақылау және басқару жүйелерінің қауіпсіз және тиімді деректер алмасуын қамтамасыз ету маңызды. HTTP, MQTT over TCP және MQTT over WebSocket протоколдары IoT құрылғылары мен бұлттық платформалар арасындағы тұрақты байланысты қолдайды. Amirkhanov B. және т.б. (2025) [1] зерттеуінде осы протоколдардың өнімділігі талданған. Кәсіпорындарда қашықтан мониторингтің маңызы артып, сенімді деректерді жинау және сақтау жүйелеріне сұраныс жоғарылауда. Adilzhanova S. және т.б. (2025) [2] еңбегінде қауіпсіздік қатерлерін анықтау үшін қашықтықтан деректер жинау жүйесі ұсынылған. Сонымен қатар, медициналық IoT қосымшаларындағы киберқауіптер де өзекті. Li H., Yu Y., Yuan Z. (2025) [3] зерттеуінде медициналық IoT жүйелеріндегі қауіпсіздік қатерлері қарастырылып, қорғау шаралары ұсынылған.

Зерттеудің мақсаты

Бұл зерттеу сыртқы факторлардың, атап айтқанда температура, қысым және пульстің криптографиялық алгоритмдердің өнімділігіне әсерін талдауға бағытталған.

Әдістеме

Эксперимент барысында келесі параметрлер өлшенді:

- **Температура:** 36.29°C-тан 37.72°C-қа дейін
- **Қысым:** 100.95 hPa-дан 103.82 hPa-ға дейін
- **Пульс:** минутына 73-тен 100 соққыға дейін

Осы деректер негізінде бес криптографиялық алгоритмнің орындалу уақыты бағаланды: SHA-256, SHA-3, BLAKE3, AES-256 және ChaCha20.

Нәтижелер

- **SHA-256:** 2.47-ден 4.85 мс-қа дейін
- **SHA-3:** 4.19-дан 5.62 мс-қа дейін
- **BLAKE3:** 1.49-дан 2.81 мс аралығында (ең жылдам)
- **AES-256:** 4.75-тен 6.39 мс-қа дейін
- **ChaCha20:** 2.30-дан 3.61 мс-қа дейін

Қорытынды: Зерттеу нәтижелері медициналық IoT құрылғыларда криптографиялық алгоритмдерді таңдауда сыртқы факторларды ескеру қажеттігін дәлелдейді. Әсіресе, температураның өзгерістері алгоритмдердің орындалу тиімділігіне айқын әсер етеді, сондықтан тұрақтылығы жоғары BLAKE3 алгоритмін қолдану ұсынылады. Болашақ зерттеулерде ылғалдылық, шу деңгейі және басқа да сыртқы параметрлердің ықпалы қарастырылып, нақты жағдайларға бейімделген криптографиялық шешімдерді оңтайландыру мәселелері зерттелуі тиіс.

Пайдаланылған әдебиеттер тізімі:

1 Amirkhanov B., Amirkhanova G., Kunelbayev M., Adilzhanova S., Tokhtassyn M. "Evaluating HTTP, MQTT over TCP and MQTT over WEBSOCKET for digital twin applications: A comparative analysis on latency, stability, and integration" // *International Journal of Innovative Research and Scientific Studies (IJIRSS)*, Vol. 8 No. 1 (2025), pp. 679-694. DOI: 10.53894/ijirss.v8i1.4414

2 Adilzhanova S., Kunelbayev M., Amirkhanova G., Zhussupov Y., Tortay A. "Development of a data collection and storage system for remote monitoring and detection of security threats in the

enterprise" // *International Journal of Innovative Research and Scientific Studies (IJIRSS)*, Vol. 8 No. 2 (2025), pp. 176-196. DOI: 10.53894/ijirss.v8i2.5136

3 Li H., Yu Y., Yuan Z. "Cyber Threats in Medical IoT" // *Journal of Cybersecurity and Privacy*, 2025.

ӨНЕРКӘСІПТІК ИНТЕРНЕТ ЗАТТАРЫ ҮШІН ҚАУІПСІЗ МОНИТОРИНГ ЖҮЙЕСІ

Тортай Алихан Бақытжанұлы

ал-Фараби атындағы Қазақ Ұлттық университетінің 1 курс магистранты

E-mail: tortayalikhan@gmail.com

Өнеркәсіптік Интернет заттарының (IIoT) қарқынды дамуы өндірістік процестердің тиімділігі мен мониторинг мүмкіндіктерін айтарлықтай жақсартты, бірақ бұл салада киберқауіптер, әртүрлі құрылғылардың үйлесімділігі және нақты уақыт режимінде деректерді өңдеу мәселелері өзекті болып отыр. Өнеркәсіптік нысандар көбінесе шектеулі есептеу ресурстарымен жұмыс істейді, сондықтан өнімділік пен сенімді қауіпсіздік механизмдерін теңестіру қажет. Ескірген жүйелер, жеткіліксіз шифрлау қолдауы және ауқымдылық мәселелері IIoT енгізуді қиындатады, ал кибершабуылдар, сенсор деректерінің дәлсіздігі мен желі ақаулары нақты уақыттағы мониторинг үшін қауіп төндіреді және өндірістік тоқтап қалулар мен қаржылық шығындарға әкелуі мүмкін.

Осы мәселелерді шешу мақсатында зерттеуде өнеркәсіптік ортада деректерді жинау мен қашықтан мониторинг жүргізудің қауіпсіз архитектурасы ұсынылады. Ұсынылған жүйе көпдеңгейлі қауіпсіздік протоколдарын біріктіреді, оның ішінде рөлдік қол жеткізуді басқару (RBAC) арқылы әрбір қолданушы мен құрылғының нақты құқықтары бекітіліп, рұқсатсыз әрекеттердің алдын алу қарастырылады. Деректер тасымалы кезінде TLS/SSL және AES-256 шифрлау протоколдары қолданылады, бұл деректердің тұтастығы мен құпиялылығын қамтамасыз етеді. Сонымен қатар, шабуылдарды анықтау мен алдын алу жүйесі (IDPS) арқылы желідегі кибершабуылдар мен ақауларды ерте сатысында анықтау мақсат етіледі.

Нақты уақыт режиміндегі аномалияларды ерте анықтау үшін терең оқыту модельдері, соның ішінде Long Short-Term Memory (LSTM) және гибридік CNN-LSTM, өндірістік деректер ағындарын талдайды. Бұл модельдер уақыттық және құрылымдық ерекшеліктерді үйлестіре отырып, жүйелік ақаулар мен кибершабуылдардың алдын алуға мүмкіндік береді. Сонымен қатар, шектеулі ресурстар жағдайында жүйенің өнімділігін жоғалтпау мақсатында модельдерді қысу және түсіндіретін жасанды интеллект (XAI) әдістері интеграцияланады.

Эксперименттік нәтижелер ұсынылған архитектураның тоқтап қалу уақытын айтарлықтай қысқартатынын, деректер қауіпсіздігін арттырып, жүйенің тұрақтылығын жоғарылататынын көрсетті. Бұл тәсіл өнеркәсіптік ортада қауіпсіз және тиімді мониторингті қамтамасыз ететін IIoT-қолданбалар үшін практикалық маңызға ие болып табылады.

Пайдаланылған әдебиеттер тізімі:

1. C. Ezeugwa, "Cybersecurity threats and vulnerabilities in industrial internet of things (IIoT) environment: A conceptual review," *Journal of Advanced Research and Reports*, vol. 18, no. 2, pp. 1–23, 2024. <https://doi.org/10.9734/ajarr/2024/v18i2601>
2. Ferencz, K., Kovacs, D.: Cloud Integration of Industrial IoT Systems. Architecture, Security Aspects and Sample Implementations. *Acta Polytechnica Hungarica* 21(4), 7–15 (2024). <https://doi.org/10.12700/APH.21.4.2024.4.1>
3. Z. Guo, Y. Liu, and F. Lu, "Embedded remote monitoring system based on NBIOT," *Journal of Physics: Conference Series*, vol. 2384, no. 1, pp. 1–8, 2022. <https://doi.org/10.1088/1742-6596/2384/1/012038>
4. Ramadan, M. N. A., Ali, M. A. H., Khoo, S. Y., Alherbawi, M., Alkhedher, M.: Real-time air quality monitoring system based on IoT: A case study in Malaysia. *Ecotoxicology and Environmental Safety* 283, 116856 (2024). <https://doi.org/10.1016/j.ecoenv.2024.116856>
5. Leander, R., Üzümcü, A., Dawadi, R.: A Decentralized Security Framework for Industrial Internet of Things. In: *2016 IEEE 4th International Conference on Future Internet of Things and Cloud (FiCloud)*, pp. 326–332. IEEE, Vienna, Austria (2016). <https://doi.org/10.1109/FiCloud.2016.40>

ОРГАНИЗАЦИЯ ЗАЩИТЫ ПЕРСОНАЛЬНЫХ ДАННЫХ: ОСВЕДОМЛЁННОСТЬ И РЕАЛИЗАЦИЯ МЕР БЕЗОПАСНОСТИ

Амиртаева А.К., Қозытай А.К., Турарбек А.Т.

Казахский Национальный Университет им. аль-Фараби,
amirtayevaainur@gmail.com, aseka.03@mail.ru, turarbekasem1@gmail.com

Персональные данные представляют собой любую информацию, относящуюся к определённому или определяемому физическому лицу [1]. С развитием цифровых технологий их защита приобретает особую актуальность. Важным международным шагом в данной сфере стало принятие 28 января 1981 года Советом Европы "Конвенции о защите частных лиц в отношении автоматизированной обработки данных личного характера", которая впоследствии послужила основой для формирования национального законодательства в области защиты персональных данных, включая законодательство Республики Казахстан [2].

Несмотря на наличие Закона Республики Казахстан «О персональных данных и их защите», проблема утечек информации остаётся острой. Так, в первой половине 2024 года количество административных нарушений в данной сфере увеличилось на 76%, а уголовных — на 20% по сравнению с аналогичным периодом 2023 года. При этом значительная часть утечек произошла по вине сотрудников организаций, что указывает на недостаточный уровень осведомлённости о мерах защиты данных [3-5].

Настоящее исследование направлено на оценку осведомлённости населения о защите персональных данных и анализ существующих практик обеспечения информационной безопасности в организациях. В ходе работы проведён опрос студентов и сотрудников различных отраслей, результаты которого продемонстрировали недостаточный уровень знаний о механизмах защиты информации и возможных угрозах. В целях решения данной проблемы разработана обучающая веб-платформа, содержащая материалы по законодательству, политике безопасности персональных данных, должностные инструкции, а также тесты и видеокурсы, направленные на повышение уровня осведомлённости. В процессе разработки системы дополнительно внедрены методы машинного обучения, позволяющие анализировать результаты тестирования сотрудников и прогнозировать потенциальные риски нарушения безопасности данных [6-7].

Реализация подобных решений способствует снижению вероятности утечек информации, повышению уровня защищённости персональных данных и формированию культуры информационной безопасности в организациях в условиях цифровой трансформации.

Список использованной литературы:

1. https://ru.wikipedia.org/wiki/Персональные_данные#cite_note-1
2. Г.Г. Фастович, А.С.Жикулина, Н.А.Рахвалова, Правовое регулирование отношений в области обработки персональных данных. – URL: <https://cyberleninka.ru/article/n/pravovoe-regulirovanie-otnosheniy-v-oblasti-obrabotki-personalnyh-dannyh>
3. Закон Республики Казахстан от 21 мая 2013 года № 94-V «О персональных данных и их защите». – URL: https://online.zakon.kz/Document/?doc_id=31396226
4. https://standard.kz/ru/post/2024_08_v-kazahstane-rastet-cislo-narusenii-zakona-o-zashhite-personalnyh-dannyx-323
5. <https://www.infowatch.ru/company/presscenter/news/v-rezultate-utechek-v-kazakhstane-skomprometirovano-bolee-11-mln-zapisey-persdannykh>
6. А.А. Страхов, Н.М.Дубинина, О безопасности персональных данных. – URL: <https://cyberleninka.ru/article/n/o-bezopasnosti-personalnyh-dannyh/viewer>
7. С.С. Хачатурова, О защите персональных данных. – URL: <https://cyberleninka.ru/article/n/o-zaschite-personalnyh-dannyh-1>

ИНФОРМАЦИОННАЯ БЕЗОПАСНОСТЬ LMS-СИСТЕМ

Басшықызы Д.

КазНУ имени аль-Фараби

Научный руководитель: д.т.н., профессор Ахметов Б.С.

В последние годы системы управления обучением (LMS) стали важной частью образовательного процесса, предоставляя удобный доступ к учебным материалам и обеспечивая взаимодействие между студентами, преподавателями и администрацией. Однако рост популярности LMS сопровождается увеличением рисков кибератак, что делает их защиту актуальной задачей.

Особенности LMS:

1. Массовый доступ: Одновременное подключение большого числа пользователей с различными уровнями доступа.
2. Хранение конфиденциальных данных: Личные данные студентов и преподавателей, учебные материалы, оценки и финансовая информация.
3. Взаимодействие в реальном времени: Форумы, чаты и видеоконференции.

Основные киберугрозы для LMS:

1. Утечка данных из-за уязвимостей [1].
2. Неавторизованный доступ к учетным записям [2].
3. Нарушение работы системы через атаки на инфраструктуру [3].

Комплексный подход к защите LMS:

Технические меры:

1. Использование антивирусного ПО и криптографической защиты [1].
2. Внедрение систем IDS/IPS для мониторинга и предотвращения угроз [2].
3. Регулярное обновление программного обеспечения и установка патчей [3].

Организационные меры:

1. Разграничение прав доступа и усиленная аутентификация [2].
2. Обучение пользователей основам кибербезопасности [3].
3. Разработка процедур реагирования на инциденты [2].

Мониторинг и логирование: Постоянный анализ активности для своевременного обнаружения угроз [1].

Реальные примеры инцидентов:

1. Взлом Moodle в Университете Глазго (2019), приведший к утечке персональных данных [3].
2. Уязвимость в Canvas LMS (2021), подчеркнувшая необходимость оперативного реагирования на угрозы [1].

Обеспечение безопасности LMS требует многоуровневого подхода, включающего технические, организационные и образовательные меры. В условиях глобализации и активного применения технологий искусственного интеллекта защита LMS становится не только задачей специалистов, но и обязанностью каждого пользователя.

Список использованной литературы:

1. Патель, С. (2020). Криптографические методы защиты LMS. Журнал компьютерной безопасности, 29(2), 156-170.
2. Уильямс, П. (2021). Осведомленность о кибербезопасности в высшем образовании. Журнал исследований образовательных технологий, 27(2), 99-115.
3. BBC News. (2019). Взлом Moodle в Университете Глазго: что произошло? [Онлайн] Доступно на: <https://www.bbc.com/news/education>

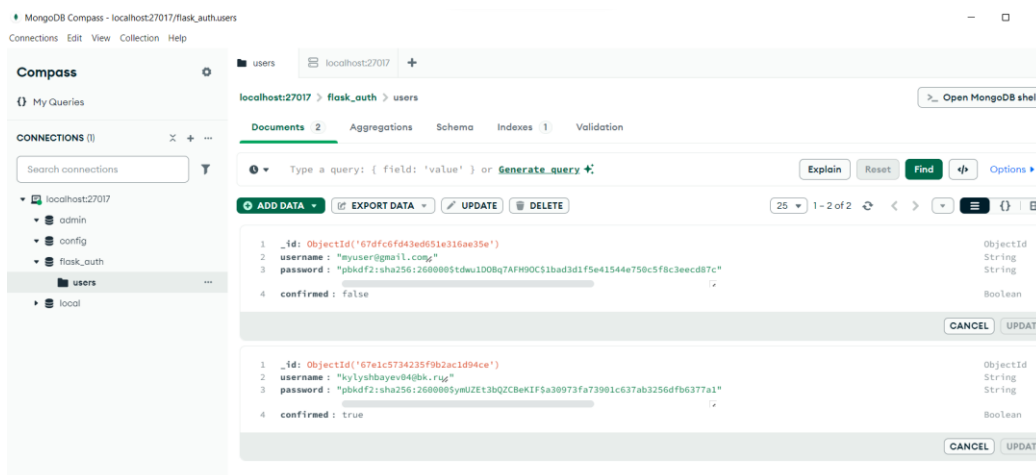
ҚАЗІРГІ ЗАМАНҒЫ ҚАУІП-ҚАТЕРЛЕРГЕ НЕГІЗДЕЛГЕН ПАРОЛЬДЕР МЕН АУТЕНТИФИКАЦИЯ ӘДІСТЕРІНІҢ ҚАУІПСІЗДІГІН БАҒАЛАУ

Қылышбаев Бекзат., Кенжебаева М.О.
ал-Фараби атындағы ҚазҰУ

Кіріспе

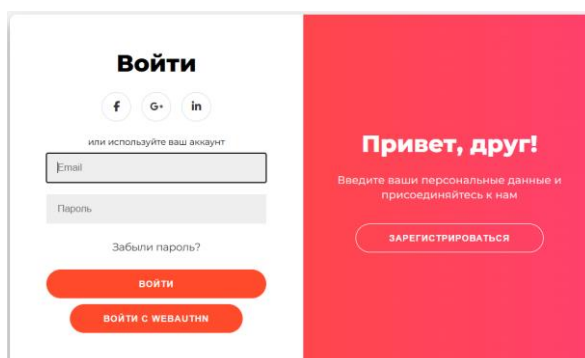
Ақпараттық қауіпсіздік саласында аутентификация әдістері пайдаланушының жеке деректеріне және ақпараттық жүйелерге рұқсат алудың негізгі құралы болып табылады [1]. Алайда, қазіргі заманғы киберқауіптер бұл әдістердің сенімділігін жиі сынақтан өткізеді [2]. Сондықтан парольдер мен аутентификация тәсілдерінің қауіпсіздігін бағалау маңызды мәселе болып табылады. Бұл мақалада python тілін пайдалана отырып регистрационный парақша жасау арқылы жүйенің қауіпсіздігін бағалаймыз

Деректерді дайындау. Алдымен біз регистрационный парақша жасау үшін деректер базасын дайындауымыз қажет. Біз ең алдымен жұмыс барысында Visual Studio Code бағдарламасымен Python тілінде деректер базасын дайындап шығамыз, одан кейін бұл деректер базасын MongoDB интерфейсіне енгіземіз (1 сурет). Бұл интерфейс арқылы мәліметтерді оңай қолданып әрі сараптай аламыз.



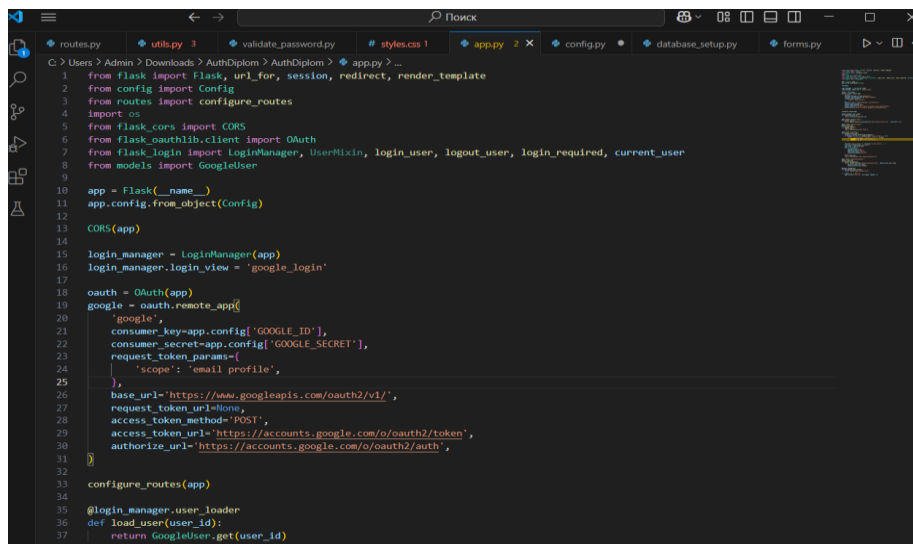
1-сурет. Мәліметтерді жинау және дайындау

Регистрационный сайттың программасы. Бұл код Flask веб-қосымшасында Google OAuth 2.0 арқылы аутентификацияны жүзеге асырады. Пайдаланушы Google-мен кіреді, оның мәліметтері (id, name, email, avatar) алынып, сессияда сақталады. login_user() жүйеге кіргізеді, logout_user() шығарады, ал @login_required қорғалған беттерге рұқсат береді. Сервер 5006 портында жұмыс істейді.



2-сурет. Аутентификация парақшасы

Регистрационный сайт парақшасы. Бізде бұл парақшамыз мәліметтер базасының көмегімен және Windows PowerShell командная строкасын қолдану арқылы қостық. Бұл парақшада аутентификацияның бірнеше түрі кірістірілген (3 сурет). Регистрационный парақшамызды біз кез келген сайттарымызға қолдана алып оның қауіпсіздік дәңгейін көтере аламыз (2 сурет).



```
1 from flask import Flask, url_for, session, redirect, render_template
2 from config import Config
3 from routes import configure_routes
4 import os
5 from flask_cors import CORS
6 from flask_oauthlib.client import OAuth
7 from flask_login import LoginManager, UserMixin, login_user, logout_user, login_required, current_user
8 from models import GoogleUser
9
10 app = Flask(__name__)
11 app.config.from_object(Config)
12
13 CORS(app)
14
15 login_manager = LoginManager(app)
16 login_manager.login_view = 'google_login'
17
18 oauth = OAuth(app)
19 google = oauth.remote_app(
20     'google',
21     consumer_key=app.config['GOOGLE_ID'],
22     consumer_secret=app.config['GOOGLE_SECRET'],
23     request_token_params={
24         'scope': 'email profile',
25     },
26     base_url='https://www.googleapis.com/oauth2/v1/',
27     request_token_url=None,
28     access_token_method='POST',
29     access_token_url='https://accounts.google.com/o/oauth2/token',
30     authorize_url='https://accounts.google.com/o/oauth2/auth',
31 )
32
33 configure_routes(app)
34
35 @login_manager.user_loader
36 def load_user(user_id):
37     return GoogleUser.get(user_id)
```

3-сурет. Python тіліндегі сайттың программасы

Нәтижелерді талдау. Қазіргі парольдік аутентификация брутфорс, фишинг және credential stuffing шабуылдарына осал, сондықтан көпфакторлы аутентификация (MFA) қолдану маңызды. Фишингтен қорғау үшін парольсіз аутентификация (WebAuthn, FIDO2) және push-аутентификация секілді әдістер тиімді. Жүйені тұрақты жаңарту, аудит жүргізу және пайдаланушыларды киберқауіпсіздікке үйрету қауіпсіздікті күшейтеді

Қорытынды

Қазіргі заманғы киберқауіптерді ескере отырып, парольдер мен аутентификация әдістерінің қауіпсіздігін қамтамасыз ету маңызды міндет болып табылады. Парольдік жүйелер жиі осалдықтарға ұшырайтындықтан, көпфакторлы аутентификация (MFA) және биометриялық жүйелер сияқты қосымша қорғаныс шараларын қолдану қажет.

Пайдаланылған әдебиеттер тізімі:

1. Schneier, B. (2015). *Secrets and Lies: Digital Security in a Networked World*. John Wiley & Sons.
2. Bonneau, J., Herley, C., Van Oorschot, P. C., & Stajano, F. (2012). "The Quest to Replace Passwords: A Framework for Comparative Evaluation of Web Authentication Schemes." *IEEE Symposium on Security and Privacy (SP)*, 553-567.

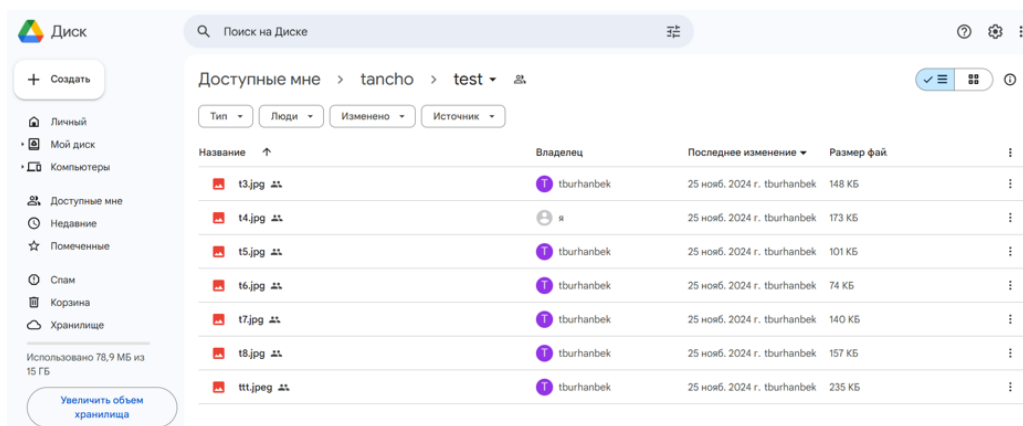
НЕЙРОНДЫҚ ЖЕЛІНІ ПАЙДАЛАНА ОТЫРЫП, ФОТОСУРЕТТЕРДЕГІ БЕТТЕРДІ ТАҢУ

Бұрханбек Т.М., Кенжебаева М.О.
ал-Фараби атындағы ҚазҰУ

Кіріспе

Нейрондық желілерге негізделген бетті тану жүйелері терең оқыту мен компьютерлік көрудегі жетістіктердің арқасында кеңінен қолданылды [1]. Олардың қолданбалары қауіпсіздікті қамтамасыз етуден мобильді құрылғылардағы пайдаланушы тәжірибесін оңтайландыруға дейін ауытқиды [2]. Бұл мақалада заманауи нейрондық желілерді қолдана отырып, фотосуреттерде бетті тану жүйесін құру процесі қарастырылады.

Деректерді дайындау. Бетті тану жүйесін құру үшін алдымен деректерді дайындау қажет. Жұмыс барысында деректерді сақтау үшін Google Drive және Google пайдаланылды Colab оларды өңдеу үшін. Алдымен суреттер Google Drive-қа жүктелді, содан кейін келесіге қосылды Colab тиісті кодтың көмегімен. Алдын ала өңдеу кезеңінде кітапханалардың көмегімен кескіндердің өлшемін өзгерту, шуды жою және деректерді қалыпқа келтіру жұмыстары жүргізілді OpenCV және PIL.



1-сурет. Мәліметтерді жинау және дайындау

Нейрондық желінің архитектурасы. Беттерді тану үшін мыналарға негізделген модель жасалды түйіншектік нейрондық желілер (CNN), бұл олардың кескіндерді өңдеудегі жоғары тиімділігіне байланысты. Іске асыру пайдалану арқылы жүзеге асырылды TensorFlow және Keras. Негізгі қадамдар үлгі қабаттарын анықтауды және таңдалған жоғалту функциясымен құрастыруды қамтиды.

```
[ ] model=tf.keras.models.Sequential([tf.keras.layers.Conv2D(16,(3,3),activation='relu',input_shape=(500,400,3)),
tf.keras.layers.MaxPool2D(2,2),
tf.keras.layers.Conv2D(32,(3,3),activation='relu'),
tf.keras.layers.MaxPool2D(2,2),
tf.keras.layers.Conv2D(64,(3,3),activation='relu'),
tf.keras.layers.MaxPool2D(2,2),
tf.keras.layers.Flatten(),
tf.keras.layers.Dense(512,activation='relu'),
tf.keras.layers.Dense(1,activation='sigmoid')])
```

2- сурет. Нейрондық желі моделі

Модельді тестілеу. Модельді тестілеу оның өнімділігін бағалау үшін оқытуға қатысы жоқ деректер негізінде жүргізілді. Берілген кескін индекстері бойынша модельдің дұрыс жұмыс істеуін тексеру үшін арнайы код енгізілді. Модельдің дәлдігі оның тиімділігін анықтау үшін де есептелді.

Жасанды нейрондық желіні оқыту. Модельді оқыту үшін деректерді оқу және оларды оқыту мен тест жиынтығына бөлу керек. TensorFlow'тің ImageDataGenerator құралын пайдаланып, деректерді ұлғайтамыз. Бұл жерде үлгі оқыту деректерімен байланысып, оның тиімділігін валидация деректерінде тексереді.

```
train_dataset = train.flow_from_directory('/content/drive/MyDrive/tancho/train',
                                         target_size=(500,400),
                                         batch_size=3,
                                         class_mode='binary')
validation_dataset = validation.flow_from_directory('/content/drive/MyDrive/tancho/validation',
                                                    target_size=(500,400),
                                                    batch_size=3,
                                                    class_mode='binary')
```

3-сурет. Нейрондық желіні оқыту

Жасанды нейрондық желіні тестілеу. Модельді тестілеу оның шынайы деректермен жұмыс істеуін бағалауға мүмкіндік береді. Үлгі дұрыс жұмыс істеп тұрғанын тексеру үшін оқыту кезінде берілген индекстер бойынша кесте құрастырамыз. Бұл модельдің тез, әрі нақты анықтауына көмектеседі.

```
for i in os.listdir(dir_path):
    img=image.load_img(dir_path+'/'+i,target_size=(500,400))
    plt.imshow(img)
    plt.show()
    x=image.img_to_array(img)
    x=np.expand_dims(x,axis=0)
    images=np.vstack([x])
    val=model.predict(images)
    if val==0:
        print('Tancho')
    else:
        print('User')
```

4-сурет. Жасанды нейрондық желіні тестілеу

Нәтижелерді талдау. Нейрондық желіні оқытқаннан кейін сынақ үлгісінде 98,7% дәлдікке қол жеткізілді. Қателерді талдау негізгі қиындықтардың сапасы төмен кескіндерді өңдеуде немесе мимикадағы елеулі өзгерістерде туындағанын көрсетті. Жақсартуларға модельдік ансамбльдерді пайдалану және зейін механизмдерін енгізу арқылы қол жеткізуге болады.

Қорытынды

Тәжірибе нәтижелері фотосуреттердегі беттерді тану үшін нейрондық желілерді пайдаланудың тиімділігін растайды. Әрі қарайғы зерттеулер модельдерді нақты уақыт режимінде жұмыс істеуге бейімдеуге және сыртқы әсерлерге төзімділікті арттыруға бағытталуы мүмкін.

Пайдаланылған әдебиеттер тізімі:

1. Schroff, F., Kalenichenko, D., & Philbin, J. (2015). FaceNet: A unified embedding for face recognition and clustering. Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR).
2. Deng, J., Guo, J., Xue, N., & Zafeiriou, S. (2019). ArcFace: Additive angular margin loss for deep face recognition. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (CVPR).

КОНДИТЕР ФАБРИКАСЫНЫҢ ӨНІМДЕРІН ӨНДІРУ БОЙЫНША КӘСПОРЫННЫҢ АҚПАРАТТЫҚ ҚАУІПСІЗДІГІН ҚАМТАМАСЫЗ ЕТУ

Ерболат Н., Абдуллаев Н.А.

Әл-Фараби атындағы ҚазҰУ, Алматы, Қазақстан

E-mail: nurzhole@gmail.com

Ғылыми жетекші: Мурзабеков З.Н., т.ғ.д., профессор

Қазіргі заманғы өндірістік орта ақпараттық қауіпсіздік саласында айтарлықтай қиындықтарға тап болуда. Сандық технологиялар мен автоматтандырылған басқару жүйелерінің кеңінен енгізілуі кәсіпорындардың киберқауіптерге, деректердің зақымдануына және рұқсатсыз қол жеткізу әрекеттеріне осалдығын арттырады. Бұл тезисте өндірістік процестердің қауіпсіздігін күшейту мақсатында GAP-талдау әдісі мен ISO 27001 стандартының қолдану ерекшеліктері қарастырылады [1].

Кондитерлік фабрикаларда ақпараттық жүйелерді пайдалану өндіріс тиімділігін арттырумен қатар, киберқауіптердің пайда болуына да әкеледі. Өндірістік процестерге арналған деректердің құпиялылығын, тұтастығын және қолжетімділігін қамтамасыз ету үшін жаңа қауіпсіздік шараларын енгізу қажет. Бұл мақалада осы мәселелерді шешу үшін GAP-талдау әдісі мен ISO 27001 стандартының маңыздылығы талқыланады [2].

Зерттеу әдістемесі өндірістік кәсіпорындарда ақпараттық қауіпсіздік деңгейін бағалау үшін GAP-талдауды қолдануды қамтиды. GAP-талдау қазіргі ақпараттық қауіпсіздік жүйесінің жағдайын ISO 27001 стандартының талаптарымен салыстыру арқылы олқылықтарды анықтауға мүмкіндік береді. Сондай-ақ, зерттеуде ISO 27001 стандартына сәйкес қауіпсіздік шараларын енгізудің тиімділігі қарастырылады [3].

Зерттеу нәтижелері кәсіпорынның ақпараттық қауіпсіздік деңгейін бағалау кезінде GAP-талдаудың маңыздылығын көрсетті. ISO 27001 стандарты негізінде ақпараттық қауіпсіздік стратегиясын әзірлеу арқылы өндірістік деректерді қорғау деңгейін арттыруға болады. Стандарттың талаптарына сәйкес жүргізілген қауіпсіздік аудиттері мен шаралары нәтижесінде деректердің бұзылу ықтималдығы азайып, өндірістік процестердің үздіксіздігі қамтамасыз етілді. Бұдан бөлек, ISO 27001 стандарты бойынша енгізілген қауіпсіздік бақылаулары, шифрлау технологияларын қолдану және қолжетімділікті басқару жүйелері деректердің жоғалуын немесе сыртқы қауіптерден зардап шегуін азайтты. Бұл шаралар өндірістік қауіпсіздік деңгейін едәуір күшейтуге және киберқауіптерден қорғауға көмектесті.

Кондитер фабрикасының өнімдерін өндіру кезінде кәсіпорынның ақпараттық қауіпсіздігін қамтамасыз ету үшін GAP-талдау әдісі мен ISO 27001 стандартының талаптарын орындау маңызды. GAP-талдау қауіпсіздік жүйесіндегі олқылықтарды анықтауға көмектесе, ISO 27001 стандарты оларды жоюдың тиімді әдістерін ұсынады. Осы шараларды енгізу нәтижесінде кәсіпорынның деректерді қорғау деңгейі артып, өндірістік процестердің үздіксіздігі қамтамасыз етіледі. Болашақ зерттеулер ақпараттық қауіпсіздікті одан әрі жетілдіру үшін жасанды интеллект пен автоматтандырылған мониторинг жүйелерін қолдануға бағытталады.

Пайдаланылған әдебиеттер тізімі:

1. Gap analysis: concepts, methods, and recent results:
<https://link.springer.com/article/10.1023/A:1008184408300>
2. ISO/IEC 27001 Standard: Analytical and Comparative Overview:
https://link.springer.com/chapter/10.1007/978-981-99-9524-0_12
3. Gap analysis: a tool for complementary genetic conservation assessment:
<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1472-4642.2008.00512.x>

ЭЛЬ-ГАМАЛЬ КРИПТОЖҮЙЕСІ МЕН ЖАСАНДЫ ИНТЕЛЛЕКТ НЕГІЗІНДЕ ҚҰПИЯЛЫЛЫҚТЫ САҚТАЙ ОТЫРЫП, БИОМЕТРИЯЛЫҚ КЕСКІНДЕРДІ ШИФРЛАУ

Ермекова Гүлдиана Ермекқызы

ал-Фараби атындағы Қазақ Ұлттық университетінің 1 курс магистранты

E-mail: guldiana02@mail.ru

Темирбекова Жанерке Ерлановна

ал-Фараби атындағы Қазақ Ұлттық университетінің PhD

Заманауи аутентификация технологиялары саусақ іздері, көз торының суреттері және бет суреттері сияқты биометриялық деректерді көбірек қолданады. Биометриялық кескіндер жоғары сезімталдыққа ие, бұл оларды рұқсатсыз қол жетімділік пен модификациядан қорғауды қажет етеді. Симметриялық шифрлау сияқты дәстүрлі қорғаныс әдістері кілттерді басқарудың қиындығына байланысты әрдайым қолайлы бола бермейді. Бұл тұрғыда дискретті логарифмді есептеудің күрделілігіне негізделген Эль-Гамаль криптожүйесі перспективалық шешім болып табылады.

Шифрлаудың маңызды кезеңі - жүйенің беріктігін қамтамасыз ететін үлкен жай сан мен генераторды таңдауда. Бұл процесс дәстүрлі түрде айтарлықтай есептеу ресурстарын қажет етеді. Бұл жұмыста қарапайым сандарды тиімді таңдау үшін машиналық оқыту әдістерін, атап айтқанда генеративті-бәсекелес желілерді (GAN) қолдану ұсынылады, бұл криптожүйе параметрлерінің генерациясын едәуір жылдамдатады және оның криптоанализге төзімділігін жақсартады [1].

Кескінді шифрламас бұрын, ол сұр градацияға аударылады және сандық массив ретінде ұсынылады. Әрі қарай, кескіннің әрбір пикселі Эль-Гамаль алгоритмі бойынша шифрланады, мұнда кескіннің әрбір сандық элементі хабарлама ретінде өңделеді және түрлендіруге ұшырайды. Бұл процесс кездейсоқ санды таңдауды, көмекші параметрлерді есептеуді және пикселдерді шифрланған түрге түрлендіруді қамтиды. Алынған шифрланған деректерді ашу қауіпсіз байланыс арналары арқылы беруге болады, өйткені шифрды ашу үшін құпия кілт туралы білім қажет [2,3].

Криптографиялық жүйелерде машиналық оқыту әдістерін қолдану жүйенің оңтайлы сипаттамаларын қамтамасыз ете отырып, криптографиялық параметрлерді таңдауды едәуір жылдамдатуға мүмкіндік береді. Мысалы, генеративті-бәсекелес желілер Эль-Гамаль алгоритмінде қолдануға ең жақсы үміткерлерді бөліп көрсете отырып, көптеген жай сандарда оқи алады. Бұл кілттерді генерациялауға кететін уақытты азайтады, бұл әсіресе жүктемесі жоғары жүйелермен жұмыс істеу кезінде өте маңызды.

Қорытындылай келе, Эль-Гамаль криптожүйесінің жасанды интеллектпен үйлесуі биометриялық ақпаратты қорғау саласында жаңа көкжиектер ашатынын атап өтуге болады. Мұндай шешім қауіпсіздік пен криптоанализге төзімділіктің жоғары деңгейін қамтамасыз етеді, бұл оны заманауи ақпараттық қауіпсіздік жүйелері үшін перспективалы құралға айналдырады.

Пайдаланылған әдебиеттер тізімі:

1. Li X. et al. GAN-based image steganography by exploiting transform domain knowledge with deep networks //Multimedia Systems. – 2024. – Т. 30. – №. 4. – С. 224.
2. Qin Y., Zhang B. Privacy-preserving biometrics image encryption and digital signature technique using Arnold and ElGamal //Applied Sciences. – 2023. – Т. 13. – №. 14. – С. 8117.
3. Gumanti U., Pardede A. M. H., Khair H. Superencryption of BASE 64 Algorithm and ELGAMAL Algorithm on Android Based Image Security //Journal of Artificial Intelligence and Engineering Applications (JAIEA). – 2023. – Т. 2. – №. 3. – С. 129-134.

ADILET.ZAN.KZ ЗАҢНАМАЛЫҚ ЖҮЙЕСІНІҢ ЗАҢДАР ДЕРЕКТЕРІН ҚОЛДАНЫП, GOLANG ПРОГРАММАЛАУ ТІЛІНДЕ ЗАҢНАМАЛЫҚ СҰРАҚ-ЖАУАП ЖҮЙЕСІН ҚҰРУ

Жүнісәлі Әділет Қазбекұлы

әл-Фараби атындағы Қазақ Ұлттық университеті

Кіріспе:

Қазіргі ақпараттық дәуірде заңнамалық ақпаратқа жылдам қол жеткізу және оның сапалы өңделуі маңызды міндеттердің бірі болып табылады. Қазіргі заманғы цифрландыру және ақпараттық технологиялардың жаһандық дамуы жағдайында ақпараттық қауіпсіздікті қамтамасыз ету мәселелері басты орынға шығады. Зерттеу [1] жұмысы заманауи криптографиялық әдістердің ақпараттық деректердің жоғалуын болдырмаудағы тиімділігін дәлелдейді. Жұмыс [2] веб-қосымшалардағы негізгі осалдықтарды анықтап, оларды жою әдістерін ұсынды, бұл интернет-ресурстардың қауіпсіздік деңгейін арттыруға ықпал етеді. Зерттеу [3] көпфакторлы аутентификацияның таратылған жүйелердің қауіпсіздігін 30%-ға арттыратынын көрсетті. Зерттеу [4] дербес деректерді қорғау механизмдерін қарастырып, кванттық криптография негізінде шифрлаудың ақпараттың бұзылу қаупін 2 есе төмендететінін дәлелдеді. Ал зерттеу [5] желілік қауіпсіздікті мониторингтеудің инновациялық тәсілдерін ұсынып, қауіптердің 95%-ға дейін дәл анықталуын қамтамасыз етті. Зерттеудің негізгі мақсаты – заңнамалық деректерді автоматты түрде алу және өңдеу арқылы заңнамалық сұрақ-жауап жүйесін құру. Жүйеде Golang программалау тілінде негізгі модуль іске асырылып, Python тіліндегі машиналық оқыту әдістері ақпараттық қауіпсіздік аудитін жүргізуге және жүйенің өздігінен үйрену қабілетін арттыруға бағытталады.

Зерттеу әдістері: Adilet.zan.kz порталынан заңнамалық деректерді алу үшін арнайы парсинг алгоритмдері қолданылды. Бұл әдіс деректерді автоматты түрде жүктеп, оларды құрылымдалған форматқа келтіруге мүмкіндік береді. Жүйе бірнеше микросервис компоненттерінен тұрады. Негізгі модуль Golang тілінде жазылып, жоғары өнімділік пен тұрақтылыққа қол жеткізсе, Python тіліндегі компонент машиналық оқыту әдістерін іске асырып, заңнамалық сұрақтарға нақты жауап беруді қамтамасыз етеді. Python бағдарламалау тілінде жүзеге асырылған ML әдістері жүйенің заңнамалық сұрақтарға жауап беру дәлдігін арттырады. Сонымен қатар, ақпараттық қауіпсіздік аудитін жүргізу процесінде машиналық оқыту деректердің аномалияларын анықтап, жүйенің қауіпсіздігін нығайтады. Екі бағдарламалау тілінде жазылған компоненттер микросервистік архитектура арқылы тиімді түрде интеграцияланып, толық функционалды және масштабталатын жүйені құруға мүмкіндік береді. Жүйе заңнамалық деректерді тез әрі дәл өңдей отырып, пайдаланушыларға сұрақтарына нақты жауап береді.

Қорытынды: Зерттеу барысында алынған нәтижелер заңнамалық сұрақ-жауап жүйесін құруда тиімді технологиялар мен әдістердің қолданылуын дәлелдейді. Golang және Python тілдерінің интеграциясы арқылы жасалған жүйе заңнамалық ақпаратпен жұмыс істеуді оңтайландырып, ақпараттық қауіпсіздік аудитін қамтамасыз етеді. Бұл жүйе заңнамалық деректерді өңдеу мен заңнамалық сұрақтарға жауап беру саласында жаңа мүмкіндіктер ашып, тиісті ұйымдар мен мамандарға үлкен көмек болады.

Пайдаланылған әдебиеттер тізімі:

1. Сидоров П. И. Ақпаратты қорғаудың криптографиялық әдістері: оқулық. — М.: Наука, 2022. — 320 б.
2. Иванов А. В., Петров Б. Н. Веб-қосымшалардағы осалдықтарды талдау және оларды жою тәсілдері // Ақпараттық қауіпсіздік бюллетені. — 2021. — №4. — Б. 45-56.
3. Смирнов Д. Л. Таратылған жүйелердегі пайдаланушыларды аутентификациялау // «Компьютерлік қауіпсіздік» журналы. — 2020. — Т. 12, №3. — Б. 78-90.

4. Кузнецов М. С. Жеке деректерді қорғау және олардың қауіпсіздігі // Ақпараттық технологиялар және қауіпсіздік. — 2019. — №2. — Б. 112-124.

5. Беяев В. А. Желілік қауіпсіздікті мониторингтеу: заманауи тәсілдер. — СПб.: Питер, 2023. — 256 б.

НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ ҚОЛДАНА ОТЫРЫП, ФИШИНГТІК ХАБАРЛАМАЛАРДЫ АНЫҚТАУ ЖҮЙЕСІН ҚҰРУ

Куандыкова Нурай Талгатовна

Ғылыми жетекші: Байспай Г.Б

ал-Фараби атындағы ҚазҰУ, Алматы, Қазақстан

Email: n.t.kk03@gmail.com

Андатпа. Бұл зерттеу жұмысы нейрондық желілерді қолдану арқылы фишингтік хабарламаларды анықтау жүйесін әзірлеуге бағытталған. Зерттеуде фишингтік шабуылдардың негізгі түрлері, олардың таралу әдістері және анықтау тәсілдері қарастырылады. Табиғи тілді өңдеу (NLP) мен нейрондық желілерді біріктіру арқылы фишингтік хаттарды жоғары дәлдікпен жіктеудің тиімділігі зерттеледі.

Жұмыстың теориялық бөлімінде фишингті анықтаудың заманауи әдістері зерттеліп, олардың тиімділігі талданады. Ал тәжірибелік бөлімде LSTM, CNN және BERT негізінде нейрондық желі моделін әзірлеу, оқыту және тестілеу жүргізіледі. Алынған нәтижелер негізінде жүйенің дәлдігі, толықтығы және тиімділігі бағаланып, модельдердің артықшылықтары мен шектеулері салыстырмалы түрде қарастырылады.

Кілт сөздер: ФИШИНГ, КИБЕРҚАУІПСІЗДІК, НЕЙРОНДЫҚ ЖЕЛІЛЕР, NLP, LSTM, CNN, BERT.

Қазіргі заманда технологиялардың қарқынды дамуы ақпараттық алмасудың жылдамдығын арттырып, цифрлық ортада кең көлемде деректердің таралуына ықпал етуде. Алайда, технологиялардың кең таралуы киберқауіптердің, оның ішінде фишингтік шабуылдардың өсуіне әкеліп соғуда.


Фишинг – бұл пайдаланушыларды алдау арқылы олардың жеке және қаржылық деректерін ұрлауға бағытталған кибершабуыл. Фишингтік шабуылдар көбінесе жалған электрондық хаттар, алаяқтық веб-сайттар мен әлеуметтік инженерия әдістерін қолдану арқылы жүзеге асырылады. Шабуылдаушылар сенімді ұйымдардың атын жамылып, пайдаланушыларды фишингтік сілтемелерге өтуге немесе жеке ақпараттарын енгізуге мәжбүрлейді.

Phishing Working Group (APWG) есебіне сәйкес, 2025 жылдың алғашқы тоқсанында фишингтік шабуылдар саны 2024 жылдың соңымен салыстырғанда 50%-ға артты [1]. Бұл дәстүрлі қорғаныс әдістерінің жаңа шабуылдарға қарсы тиімсіздігін көрсетеді. Осыған байланысты нейрондық желілерді қолданып, фишингтік хабарламаларды автоматты түрде анықтай алатын жүйені әзірлеу қажеттілігі туындайды.

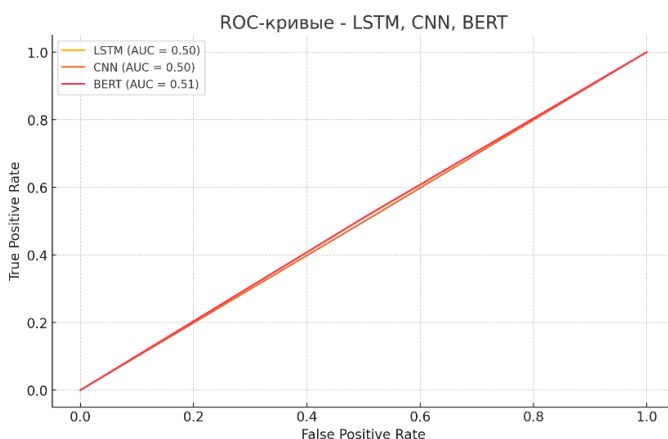
Зерттеудің негізгі мақсаты – нейрондық желілер негізінде фишингтік шабуылдарды жылдам әрі дәл анықтайтын жүйені әзірлеу және оның тиімділігін бағалау. Осы мақсатта Enron Email Dataset, Phishing Email Dataset, SpamAssassin Public Corpus, PhishTank Data Feed және Phishing Websites Dataset сияқты бес негізгі деректер жиынтығы таңдалды [2]. Бұл деректер фишингтік хаттар мен URL мекенжайлардың ерекшеліктерін анықтап, модельдерді оқыту мен тестілеу барысында пайдаланылды.

Фишингтік шабуылдарды анықтау үшін LSTM, CNN және BERT модельдері әзірленді [3]. Зерттеу нәтижелері BERT моделінің ең жоғары дәлдік көрсеткенін көрсетті, оның дәлдігі 94,3%, толықтығы 92,7%, ал F1-макро көрсеткіші 93,5% болды. LSTM моделі мәтіннің уақыттық құрылымын жақсы өндегенімен, дәлдік көрсеткіші 89,5% болды. CNN моделі қысқа мәтіндер мен URL-дерді талдауда тиімді болғанымен, BERT моделіне қарағанда төмен нәтиже көрсетті, оның дәлдігі 86,9% құрады. Әр модельдің өнімділігі қателер матрицасы (Confusion Matrix) арқылы бағаланып, модельдердің жіктеу барысында жиі жіберетін қателері анықталды (1-сурет). Сонымен қатар, ROC-қисықтары арқылы модельдердің сезімталдығы мен жалған позитивті көрсеткіштері салыстырмалы түрде талданды (2-сурет). Жалпы, BERT моделі

жоғары нәтижелер көрсеткенімен, оны қолдану ресурстарды көп қажет ететіндіктен, өңдеу жылдамдығы мен тиімділігі тұрғысынан LSTM және CNN модельдерінің комбинациясы жақсы балама ретінде қарастырылды [4].



1-сурет. Әр модель үшін қателер матрицалары (Confusion Matrix)



2-сурет. ROC-қисығы – LSTM, CNN, BERT.

Қорытынды. Зерттеу нәтижелері нейрондық желілердің фишингтік хабарламаларды автоматты түрде анықтаудағы тиімділігін дәлелдеді. Бұл әдістер дәстүрлі қорғау құралдарына қарағанда жоғары дәлдікке ие және жасанды интеллект қолданылған шабуылдарды анықтауға мүмкіндік береді.

Фишингтік шабуылдарды жылдам және тиімді анықтау үшін BERT моделін үлкен көлемдегі деректермен оқыту, ал нақты уақыттағы жүйелер үшін LSTM + CNN комбинациясын қолдану ұсынылады.

Бұл зерттеу фишингтен қорғаныс әдістерін жетілдіруге және оларды киберқауіпсіздік жүйелеріне интеграциялауға үлес қосады.

Пайдаланылған әдебиеттер тізімі:

1. APWG Phishing Activity Trends Report. *Anti-Phishing Working Group (APWG)*, 2024.
2. Phishing Email Dataset. *Kaggle*, 2023.
3. Thakur, K., Ali, M. L., Obaidat, M. A., & Kamruzzaman, A. (2023). *A Systematic Review on Deep-Learning-Based Phishing Email Detection*. *Electronics*, 12(21), 4545.
4. Alshingiti, Z., Alaqel, R., Al-Muhtadi, J., Haq, Q. E. U., Saleem, K., & Faheem, M. H. (2023). *A Deep Learning-Based Phishing Detection System Using CNN, LSTM, and LSTM-CNN*. *Electronics*, 12(1), 232.

УНИВЕРСИТЕТТЕРДІҢ АҚПАРАТТЫҚ-БІЛІМ БЕРУ ЖҮЙЕЛЕРІНДЕГІ ЦИФРЛЫҚ ЕГІЗДЕРДІҢ ҚАУІПСІЗДІГІ

Курбаниязов Нургазы

КазНУ имени аль-Фараби

Научный руководитель: д.т.н., профессор Ахметов Б.С.

Қазіргі заманғы университеттердің ақпараттық-білім беру жүйелері (АБЖУ) сақталатын деректер көлемінің ұлғаюы және оқу орындарының цифрлық инфрақұрылымының күрделенуі салдарынан өсіп келе жатқан кибершабуыл қатерлеріне ұшырайды. Қазіргі уақытта АБЖУ-дағы ақпараттық қауіпсіздікті (АҚ) қамтамасыз етуге арналған бірқатар тәсілдер бар, соның ішінде оқу үдерісінде қолданылатын цифрлық егіздерді (ЦЕ) қорғауға бағытталған дәстүрлі қолжетімділікті басқару және желілік трафикті бақылау әдістері. Алайда, бұл әдістердің елеулі шектеулері бар – олар пайдаланушылардың мінез-құлық заңдылықтарын ескермейді, бұл күрделі шабуылдарды анықтауда олардың тиімділігін төмендетеді [1].

Біздің зерттеуіміз АБЖУ пайдаланушыларының мінез-құлық үлгілерін анықтау әдістемесін әзірлеуге бағытталды, бұл ақпараттық қауіпсіздікке (АҚ) төнетін ықтимал қауіптерді анықтауға мүмкіндік береді. Ұсынылған тәсіл цифрлық іздердің (ЦИ) секвенциалдық талдауына және дәйектілік заңдылықтарды айқындау алгоритмдерін қолдануға негізделген. Негізгі мақсат – қауіпсіздік саясатының бұзылу фактісін ғана тіркеп қоймай, сондай-ақ ықтимал инциденттерді, соның ішінде цифрлық егіздер технологияларына қатысты жағдайларды болжауға мүмкіндік беретін үлгіні әзірлеу. АБЖУ-дағы АҚ оқиғаларының атрибуттар жиынтығы жүйенің ерекшеліктеріне байланысты өзгеруі мүмкін, алайда көптеген оқиғаларға тән бірнеше жалпы атрибуттар бар [2].

Мысалы, уақыттық белгілер (АҚ оқиғасы болған уақыт пен күні); оқиғаның көзі (пайдаланушы, қосымша, құрылғы және т.б.); оқиға түрі (мысалы, кіру әрекеті, параметрлерді өзгерту және т.б.); маңыздылық деңгейі; оқиғаның нәтижесі; қосымша атрибуттар. Бұл атрибуттардың көпшілігін АБЖУ пайдаланушыларының цифрлық іздерін талдау негізінде, соның ішінде цифрлық егізбен өзара әрекеттесу кезінде анықтауға болады [3].

Зерттеу барысында цифрлық іздерді (ЦИ) секвенциалды талдау негізінде пайдаланушылардың киберқауіпсіздікке сәйкес мінез-құлқының максималды дәйекті паттерндерін анықтау әдісі АБЖУ-дағы ақпараттық қауіпсіздікті қамтамасыз етуге бірқатар артықшылықтарға ие екені анықталды. Атап айтқанда, жұмыста ұсынылған тәсілді қолдану пайдаланушылардың аномалды мінез-құлқын анықтауға мүмкіндік береді, бұл өз кезегінде АБЖУ-ға төнетін ықтимал қауіптерді көрсететін маңызды фактор болуы мүмкін.

Пайдаланылған әдебиеттер тізімі:

1. Золотарев В.А., Козлов В.В. Білім берудегі цифрлық егіздер: мәселелер мен перспективалар // Цифрлық технологиялар және білім беру журналы. – 2022. – № 3. – Б. 45–56.

2. Белоусов А.А., Иванов В.Н. Білім беру платформаларында цифрлық егіздерді қолдану: қауіпсіздік пен деректерді қорғау мәселелері // Ақпараттық технологиялар және қауіпсіздік журналы. – 2023. – Т. 12. – № 4. – Б. 87–95.

3. Гребенников П.А., Смирнов Д.В. Университеттердің ақпараттық жүйелеріндегі цифрлық егіздердің қауіптер модельдері және деректерді қорғау // Киберқауіпсіздік және деректерді талдау журналы. – 2023. – Т. 15. – № 2. – Б. 112–126.

АҚПАРАТТАНДЫРУ ОБЪЕКТІЛЕРІ АРАСЫНДА ҚОРҒАУ РЕСУРСТАРЫН ҰТЫМДЫ БӨЛУДІ ЗЕРТТЕУ

Матанбай М.А.

Әл-Фараби атындағы Қаз ҰУ, Алматы, Қазақстан
e-mail: matanbay_madi2@kaznu.edu.kz

Заманауи ақпараттық жүйелердің қауіпсіздігі өзекті әрі күрделі міндет болып табылады. Киберқауіпсіздік саласындағы қауіп-қатерлердің үнемі өзгеріп, дамып отыруы, ақпараттық технологиялар мен инфрақұрылымдардың күнделікті өмірде кеңінен қолданылуы қауіпсіздік мәселелерін күрделендіре түсуде. Ақпараттық қауіпсіздік шараларын ұйымдастыруға жұмсалатын қаржылық, техникалық және адам ресурстарының шектеулі болуы бұл ресурстарды барынша тиімді және ұтымды бөлуді талап етеді. Сондықтан ақпараттандыру объектілерінің қауіпсіздігін қамтамасыз етуде ресурстарды оңтайлы бөлу ғылыми тұрғыдан да, практикалық тұрғыдан да маңызды [1].

Ақпараттық қауіпсіздік ресурстарын бөлудің тиімді стратегияларын зерттеу барысында ақпараттық жүйелердің қауіпсіздігін басқару теориясының негіздеріне сүйену қажет. Теориялық тұрғыдан ресурстарды бөлудің тиімділігі қауіпсіздік саясатының тиімді жүзеге асуымен және қауіп-қатерлерге қарсы шаралардың нәтижелігімен анықталады. Ресурстарды ұтымды бөлу үшін, бірінші кезекте, қауіп-қатерлерді бағалау әдістерін дұрыс әрі толық пайдалану маңызды. Әсіресе, қауіп-қатерлерді бағалаудың сапасы ақпараттық қауіпсіздік шараларының тиімділігін тікелей анықтайды.

Ақпараттық қауіпсіздік саласындағы ресурстарды ұтымды бөлу үшін тәуекелдерді басқарудың халықаралық стандарттары мен әдістемелері қолданылады. ISO/IEC 27001 және NIST SP 800-30 стандарттарына сәйкес, тәуекелдерді бағалау процестері келесі кезеңдерді қамтиды: активтерді анықтау және құндылығын бағалау, қауіп-қатерлерді анықтау және талдау, осалдықтарды анықтау, ықтимал салдарды бағалау, сондай-ақ тәуекелдерді төмендету шараларын жоспарлау және жүзеге асыру.

Ақпараттық қауіпсіздік саласында ресурстарды бөлу кезінде математикалық және имитациялық модельдеу әдістері жиі қолданылады. Математикалық модельдер қауіпсіздік шараларының тиімділігін сандық тұрғыда бағалауға және ресурстарды бөлудің оңтайлы схемаларын анықтауға мүмкіндік береді. Имитациялық модельдеу арқылы нақты ақпараттық жүйелердің жұмыс істеуін модельдеп, ұсынылған стратегиялардың нәтижелілігін тәжірибелік тұрғыдан бағалауға болады [2].

Кесте 1

Ресурстарды бөлудің стратегияларын салыстыру

Стратегиялар	Артықшылықтары	Кемшіліктері	Қолдану аясы
Біркелкі бөлу	Жеңіл жүзеге асыру, қарапайымдылық	Қорғанысы әлсіз объектілерге тиімсіз	Шағын ұйымдар, қарапайым жүйелер
Басымдықпен бөлу	Маңызды объектілердің қорғалуын арттыру	Маңыздылығы төмен объектілер назардан тыс қалады	Орташа және ірі ұйымдар
Тәуекелге негізделген	Қауіптерді жан-жақты бағалау	Бастапқы талдау күрделілігі	Күрделі ақпараттық жүйелер
Динамикалық бейімделу стратегиясы	Қауіптердің өзгеруіне икемді әрекет ету қабілеті	Жүйені үнемі мониторингтеу қажеттілігі	Үлкен ұйымдар, жоғары тәуекелді орта

Ақпараттық қауіпсіздік саласында ресурстарды ұтымды бөлу ақпараттық жүйелердің қорғалу деңгейін едәуір арттыруға мүмкіндік береді. Зерттеу барысында әзірленген әдістер мен модельдер тәжірибеде қауіпсіздік шараларын оңтайлы ұйымдастыруға және тиімділігін арттыруға ықпал етеді.

Пайдаланылған әдебиеттер тізімі:

1. Singer, P. W., & Friedman, A. (2021). Cybersecurity and Cyberwar: What Everyone Needs to Know. Oxford University Press.
2. NIST. (2022). Framework for Improving Critical Infrastructure Cybersecurity, Version 1.1. National Institute of Standards and Technology. URL: <https://www.nist.gov/cyberframework/>

КОРПОРАТИВТІК ЖЕЛІНІ ЖОБАЛАУ ЖӘНЕ ҚОРҒАУ

Нурсалимов Нуржан Кайратович

ал-Фараби атындағы ҚазҰУ

Email: nursalimovnurzan@gmail.com

Нарбаева С.М.

ал-Фараби атындағы ҚазҰУ, аға оқытушы

Бүгінде корпоративтік желіні жобалау мен қорғау кәсіпорынның ақпараттық қауіпсіздігі саласындағы басты басымдықтардың бірі ретінде қарастырылады. Цифрлық технологияларға белсенді көшу заманында желінің үздіксіз әрі қорғалған жұмысы ішкі бизнес-процестердің тиімділігі мен құпия деректердің сақталуына тікелей ықпал етеді. Жалпы байқағанымыздай, кибершабуылдардың көбеюі мен зиянкес құралдардың күрделенуі желілік инфрақұрылымдарды жобалауға барынша кешенді тәсіл қолдануды талап етеді.

Осы сын-қатерлер аясында негізгі міндет – желінің дұрыс жұмыс істеуін ғана емес, сонымен қатар оны ішкі және сыртқы қауіптерден қорғауды да қамтамасыз ететін жүйелі шараларды әзірлеу. Өткізілген зерттеу шеңберінде корпоративтік желінің негізгі элементтері, соның ішінде серверлік жабдық, желілік құрылғылар, байланыс арналары мен бағдарламалық-аппараттық қауіпсіздік құралдары қарастырылды. Желіні сегментациялау, қолжетімділікті басқару және шабуылдарды анықтау мен олардың алдын алу жүйелерін (IDS/IPS) енгізу мәселелеріне айрықша назар аударылды. Сонымен бірге, межелі шлюз (firewall), виртуалды жеке желілер (VPN) және деректерді шифрлаудың әртүрлі әдістерін пайдалану сценарийлері де сарапталды.

Зерттеу барысында әртүрлі архитектураларды бағалап, олардың осал тұстарын айқындау үшін салыстырмалы талдау және жүйелік тәсіл әдістері қолданылды. Желілік процестерді модельдеу әдістеріне ерекше мән берілді, олар туындайтын жүктемелерді болжауға, ықтимал «тар жерлерді» анықтауға және өткізу қабілетін арттыру үшін оңтайлы құралдар жиынтығын дер кезінде таңдауға мүмкіндік береді. Сонымен қатар, құпия деректермен жұмыс істеу ережелері мен қызметкерлердің корпоративтік ресурстарға қолжетімділігін ұйымдастыру сияқты әлеуметтік-техникалық аспектілер де ескерілді.

Осы зерттеу нәтижесінде корпоративтік желіні қорғау стратегиясы әзірленді, ол көпдеңгейлі тәсілді көздейді: желіні логикалық сегменттерге бөлу және қолжетімділікті нақты шектеуден бастап, соңғы нүктелердің (жұмыс станциялары мен мобильді құрылғылар) қауіпсіздігін жүйелі түрде тексеруге дейінгі шараларды қамтиды. Талдау көрсеткендей, аппараттық және бағдарламалық шешімдерді ұтымды ұштастыру кибершабуылдардың сәтті болу ықтималдығын айтарлықтай төмендетеді, ал оқиғаларды мониторингілеу мен журналдау (SIEM) жүйелерін қолдану инциденттерді дер кезінде анықтауға мүмкіндік береді.

Қорытындылай айтқанда, корпоративтік желіні жобалау және қорғау – ұйымның цифрлық экожүйесінің беріктігін қамтамасыз ететін басты фактор. Желіні дұрыс сегментациялау, көпқабатты қорғаныс жүйелерін орнату, үздіксіз мониторинг және қызметкерлерді оқыту – заманауи қауіп-қатерлерге қарсы тұра білудің негізгі тетігі болып саналады.

Пайдаланылған әдебиеттер тізімі:

1. Dean, T., & Allen, S. (2020). *Designing Enterprise Networks: A Holistic Approach*. New York: Apress.
2. Microsoft. The STRIDE Threat Model. Microsoft Docs, 2022.
3. Андреев А. «Методы и средства защиты корпоративных сетей» (Москва, 2020).
4. Tummalapalli, S., Joshi, N., & Gupta, A. (2023). *Practical Penetration Testing on Virtual Environments*. Birmingham: Packt Publishing.

ИСПОЛЬЗОВАНИЕ ТЕХНОЛОГИИ VPN ДЛЯ РАЗРАБОТКИ ЗАЩИЩЕННОЙ КОРПОРАТИВНОЙ СЕТИ

Құлбарақ А.А., Өсербеков Ұ.М., Турарбек А.Т.

Казахский Национальный Университет им. Аль-Фараби

armanicus111@gmail.com, oserbekovv@gmail.com, turarbekasem1@gmail.com

Современные технологии виртуальных частных сетей (VPN) приобретают ключевое значение в условиях роста киберугроз и необходимости защиты корпоративных данных. Научная работа посвящена созданию защищённой корпоративной сети на основе VPN, обеспечивающей безопасность и доступность информации в распределённой системе, объединяющей подразделения и удалённых пользователей [1]. Корпоративная сеть представляет собой закрытую инфраструктуру для обмена данными и управления ресурсами внутри организации, требующую надёжной защиты от внешних угроз [2]. Однако рост кибератак, таких как перехват данных, усложняет обеспечение конфиденциальности в таких системах.

В данном исследовании изучены особенности VPN-технологий, их возможности и применимость для корпоративной среды. Проведён сравнительный анализ протоколов PPTP, L2TP/IPSec, SSL и OpenVPN, где последний выделен за высокую безопасность и гибкость [3]. В работе проведена настройка VPN-сервера на Ubuntu с использованием шифрования AES-256-CBC, RSA-2048 и SHA-256, а также разработка веб-платформы на Django для коммуникаций и управления задачами, доступной только через VPN. Реализация осуществлена на виртуальных машинах с применением гипервизора VMware ESXi, что позволило создать изолированную и защищённую среду.

Результаты показали стабильность соединения (задержка 5–10 мс), высокую пропускную способность (80–90 Мбит/с) и надёжную защиту данных, подтверждённую отсутствием доступа вне VPN-туннеля. Разработанная сеть минимизирует риски утечек и атак, таких как "человек посередине" [4]. Полученные выводы подчёркивают значимость VPN для обеспечения кибербезопасности в распределённых структурах. Результаты могут быть применены в организациях для защиты данных и улучшения коммуникаций между филиалами и удалёнными сотрудниками.

Список использованной литературы:

1. Stallings, W. (2017). *Cryptography and Network Security: Principles and Practice*. 7th Edition. Pearson Education.
2. *Corporate Network Overview*. ScienceDirect Topics. - URL: <https://www.sciencedirect.com/topics/computer-science/corporate-network>
3. Lewis, M., & Baker, S. (2019). A Comparative Analysis of VPN Technologies. *Journal of Network and Computer Applications*, 135, 45–58.
4. *VPN Definition*. Britannica. - URL: <https://www.britannica.com/technology/VPN>

АСА МАҢЫЗДЫ МЕМЛЕКЕТТІК ИНФРАҚҰРЫЛЫМДЫ ҚОРҒАУ: КИБЕРҚАУІПСІЗДІКТІ БАҒАЛАУ ӘДІСТЕРІ

Адильжанова С.А., PhD, доцент м.а.,

*Рахым А.Е., ақпараттық қауіпсіздік жүйелері мамандығының 1-курс докторанты
Киберқауіпсіздік және криптология кафедрасы, Әл-Фараби атындағы Қазақ ұлттық
университеті, Алматы, Қазақстан*

Аннотация

Бұл мақалада кибершабуылдар қаупінің артуы жағдайында маңызды инфрақұрылымды (СИ) қорғаудың заманауи әдістерін талдау қарастырылады. Дәстүрлі әдістердің, мысалы, брандмауэрлер мен бұзушылықтарды анықтау жүйелерінің (IDS) маңыздылығы сақталғанымен, олар қазіргі күрделі шабуылдарға қарсы жеткіліксіз екені атап өтіледі. Зерттеуде жасанды интеллекттің (ЖИ) және машиналық оқытудың (МО) киберқауіпсіздікті күшейтудегі рөліне ерекше назар аударылады. Бұл технологиялар үлкен көлемдегі деректерді талдап, аномалияларды анықтап, қауіптерді нақты уақыт режимінде болжауға мүмкіндік береді, бұл қауіп-қатерлерге жауап беру жылдамдығы мен дәлдігін арттырады. Сонымен қатар, сындарлы инфрақұрылым объектілерінің виртуалды көшірмелерін жасауға мүмкіндік беретін цифрлық егіздер концепциясы қарастырылады. Бұл технология қауіп-қатерлерді модельдеуге және ықтимал қауіптерге жедел жауап қайтаруға жағдай жасайды.

Кілт сөздер: киберқауіпсіздік, маңызды инфрақұрылым инфрақұрылым, ЖИ, бағалау әдістері

Дәстүрлі қорғау әдістері физикалық қауіпсіздікті қамтамасыз етуге, яғни сындарлы инфрақұрылым объектілеріне рұқсатсыз кіруді болдырмауға бағытталған. Сонымен қатар, техникалық шаралар ретінде брандмауэрлер, киберқауіптерді анықтау жүйелері (IDS) және мониторинг жүйелері қолданылады[1].

Аса маңызды инфрақұрылымды қорғаудың заманауи тәсілдері ЖИ мен МО технологияларын қолдануға негізделген. Бұл әдістер мәліметтерді талдап, аномалияларды анықтауға және ықтимал қауіптерді алдын ала болжауға мүмкіндік береді. Ал цифрлық егіздер технологиясы қауіп-қатерлерді модельдеу мен қорғаныс шараларын виртуалды ортада сынап көруге жол ашады, осылайша маңызды инфрақұрылымның кибершабуылдарға төзімділігін арттырады [2]. Киберқауіпсіздікті сандық бағалау үшін Харрингтон функциясы сияқты әдістер ұсынылады. Бұл тәсіл сандық және сапалық көрсеткіштерді біріктіріп, инфрақұрылым қауіпсіздігін жан-жақты бағалауға көмектеседі. Сондай-ақ, иерархиялық талдау әдісі сарапшылардың бағалауы негізінде қорғау шараларының басымдықтарын айқындауға мүмкіндік береді. Бұл әдістер ресурстарды тиімді бөлуге және МИ қауіпсіздік деңгейін бағалауға көмектеседі.

ЖИ технологиясын қолданудың нақты мысалдарына энергетика, көлік және денсаулық сақтау салаларында шабуылдарды анықтау мен алдын алуға арналған мониторинг жүйелері жатады. Ал цифрлық егіздер қауіп сценарийлерін тестілеу және қорғаныс шараларын оңтайландыру үшін қолданылады. Сындарлы инфрақұрылымның тұрақтылығы мен қауіпсіздігін арттыру үшін ЖИ мен цифрлық егіздер технологияларын дамыту қажет. Бағалау және қорғаудың заманауи әдістерін интеграциялау арқылы күрделі киберқауіптерге тиімді қарсы тұруға болады. Болашақта МИ қорғау саласында ЖИ мен цифрлық егіздерді қолдануға арналған жаңа модельдер мен қосымшаларды әзірлеу жоспарлануда.

Пайдаланылған әдебиеттер тізімі:

1. O. N. Korchenko et al., “Method for Assessing the Level of Cybersecurity Enhancement of Critical Infrastructure Objects of the State,” *Information Technologies, Cybersecurity*, no. 61, pp. 4–5, 2024.
2. Y. Yigit et al., “Critical infrastructure protection: Generative AI, challenges, and opportunities,” *arXiv preprint arXiv:2405.04874*, 2024.

КИБЕРБУЛЛИНГТІҢ АЛДЫН АЛУ ӘДІСТЕРІН ЗЕРТТЕУ ЖӘНЕ ТАЛДАУ

Сайлау Ә.Ж., Абдулинова А.М., Турарбек Ә.Т.,

ал-Фараби атындағы Қазақ Ұлттық университеті,

sailau.adilet@bk.ru, marianaabdulinna@gmail.com, turarbekasem1@gmail.com

Қазіргі заманғы цифрлық технологиялардың қарқынды дамуы адамдардың қарым-қатынас жасау тәсілдерін түбегейлі өзгертті. Алайда, интернеттің кең таралуы жаңа әлеуметтік мәселелердің, соның ішінде кибербуллингтің белең алуына алып келді. Кибербуллинг – ақпараттық-коммуникациялық технологиялар арқылы жүзеге асырылатын қудалау, қорқыту немесе психологиялық қысым көрсету әрекеттері [1]. Бұл құбылыс әсіресе жасөспірімдер мен жастар арасында жиі кездесіп, олардың психологиялық жағдайына теріс әсер етеді.

Осы ғылыми жұмыста кибербуллингтің негізгі ерекшеліктері, оның түрлері мен қоғамға тигізетін әсері жан-жақты зерттелді [2-3]. Сонымен қатар, кибербуллингтің алдын алу әдістері қарастырылып, халықаралық және Қазақстандағы тәжірибелерге салыстырмалы талдау жүргізілді. Қазақстан Республикасындағы кибербуллингке қарсы қолданыстағы заңнамалық шаралар мен олардың тиімділігі сарапталды [4-5].

Зерттеу барысында кибербуллингті анықтау мен алдын алуда жасанды интеллект технологияларын қолдану мүмкіндіктері қарастырылды. Бұл мақсатта машиналық оқыту әдістері негізінде интернеттегі агрессивті және қорлайтын контентті анықтау жүйесі әзірленді. Жүйе Python бағдарламалау тілі мен заманауи нейрондық желілерді пайдалана отырып, мәтіндік талдау жүргізуге бағытталған.

Зерттеу нәтижелері кибербуллингтің алдын алу шараларын жетілдіруге, оның таралуына қарсы күрес жүргізуге және жасанды интеллект технологияларын осы бағытта тиімді қолдануға мүмкіндік береді. Алынған зерттеу нәтижесі білім беру мекемелерінде, әлеуметтік желілерде және құқық қорғау органдарында кибербуллингтің алдын алу үшін пайдаланылуы мүмкін.

Пайдаланылған әдебиеттер тізімі:

1. «Цифрлы кеңістіктегі балалар қауіпсіздігі: ата-аналар мен мұғалімдерге арналған әдістемелік құрал». / О. Т. Бейсенбаев, О.В. Николаева, А.Б. Иманқұл, А.С. Беймишева, Р.Б. Дюсенова, – Астана қ., «Қазақстандық қоғамдық даму институты» КеАҚ, 2024 ж. 100 б.
2. Қазақстанда жасөспірімдердің 17% буллинг құрбаны болған – сарапшы. – URL: <https://www.gov.kz/situations/316/810?lang=kk>
3. Кибербуллинг: Қазақстан заңнамасына қандай өзгерістер енгізіледі – URL: https://kaz.inform.kz/news/kiberbulling-kazakstan-zannamasyna-kanday-ozgerister-engiziledi_a3834319/
4. Cyberbullying: What is it and how to stop it – URL - <https://www.unicef.org/end-violence/how-to-stop-cyberbullying>
5. Smith, J., & Doe, J. (2023). *Machine learning model for detecting cyberbullying on Twitter*. Retrieved from <https://example.com>

БЕЛГІСІЗДІК ЖАҒДАЙЫНДА АҚПАРАТТЫҚ ҚАУІПСІЗДІКТІ БАСҚАРУ ЖҮЙЕСІНІҢ МОДЕЛІН ЗЕРТТЕУ

Ақпараттық қауіпсіздік жүйелері, 2 курс магистратура Тасболат Е.Е.

*Ғылыми жетекшісі: доцент м.а., Сақыпбекова М.Ж.
әл-Фараби атындағы Қазақ ұлттық университеті*

Киберқауіптердің саны мен күрделілігінің артуы ақпараттық қауіпсіздікті (АҚ) қамтамасыз етуді кез келген ұйым үшін басты міндет етеді. Қазіргі жағдайда белгісіздік факторы ерекше рөл атқарады – қауіптердің сипаты мен олардың салдарын дәл болжау мүмкін болмаған кезде. Бұл икемділік пен бейімделуге негізделген АҚ басқарудың жаңа тәсілдерін қажет етеді. Бұл жұмыс әсер етудің белгісіздігі мен тез өзгеретін орта жағдайында тиімді жұмыс істей алатын АҚ басқару жүйесінің моделін қарастырады.

Түйін сөздер: ақпараттық қауіпсіздікті басқару жүйесі, белгісіздік, тәуекел, модельдеу, киберқауіпсіздік, ақпараттық қауіпсіздік, тәуекелдерді талдау.

Ақпараттық қауіпсіздікке төнетін қауіптердің үнемі өсіп келе жатқан күрделілігі мен әртүрлілігі жағдайында қазіргі заманғы ақпараттық жүйелер әсер етудің белгісіздігімен байланысты бірқатар проблемаларға тап болады. Бұл ықтимал қауіптер, қоршаған ортаның тұрақсыздығы немесе жүйенің ішкі параметрлерінің өзгергіштігі туралы ақпараттың толық болмауынан туындайды. Дәстүрлі әдістер, яғни детерминистік сценарийлерге негізделген АҚ басқару тәсілдері белгісіздік жағдайында тиімділігін жоғалтады. Осыған байланысты, зерттеудің мақсаты – белгісіздік жағдайларына бейімделіп, ақпараттық инфрақұрылымның тұрақты жұмысын қамтамасыз ететін басқару моделін әзірлеу[1-2].

Әдістемелік негіз ретінде бұлыңғыр жиындар теориясы, ықтималдық талдау және адаптивті басқару әдістері ұсынылады. Модель белгісіздіктің екі түрін – алеаторлық (кездейсоқ) және гносеологиялық (білімнің жетіспеушілігімен байланысты) – қарастырып, тәуекелдерді динамикалық қайта бағалау және қорғаныс стратегияларын түзету арқылы оларды азайтудың жолдарын ұсынады.

Жүргізілген модельдеу нәтижесінде адаптивті басқару жүйесі ақпаратты қорғаудың тиімділігін арттырып қана қоймай, ресурстарды оңтайландыруға мүмкіндік беретіні анықталды. Бұл модель корпоративтік АҚ жүйелерін жобалау мен олардың жаңа және белгісіз қауіптерге төзімділігін бағалауда қолданыла алады[3].

Қорытынды

Зерттеу нәтижесінде әсер етудің белгісіздігі жағдайында тиімді жұмыс істейтін ақпараттық қауіпсіздік басқару жүйесінің моделі ұсынылды. Бұлыңғыр жиындар теориясы мен адаптивті басқару әдістері тәуекелдерді дәл бағалап, қорғау шараларын уақтылы түзетуге мүмкіндік береді. Модельдеу адаптивті тәсілдің ақпаратты қорғаудың тиімділігін арттырып, ресурстарды оңтайландыратынын көрсетті. Бұл модельді ақпараттық қауіпсіздік жүйелерін жобалау мен белгісіз қауіптерге қарсы тұруда қолдануға болады.

Пайдаланылған әдебиеттер тізімі:

1. V. Debnath, J. C. Das, D. De, P. MondalS, and M. Ferrara, “Security analysis with novel image masking based quantum-dot cellular automata information security model,” IEEE Access, no. 8, Article ID 117172, 2020.
2. P. Kumar, A. Fatima, and N. K. Nishchal, “Arbitrary vector beam encoding using single modulation for information security applications,” IEEE Photonics Technology Letters, vol. 33, no. 5, pp. 243–246, 2021.
3. M. Lundgren, “Rethinking capabilities in information security risk management: a systematic literature review,” International Journal of Risk Assessment and Management, vol. 23, no. 2, p. 169, 2020.

ВЫЯВЛЕНИЕ АНОМАЛИЙ В ПЛАТЕЖНЫХ ТРАНЗАКЦИЯХ: ЭФФЕКТИВНОСТЬ ПРАВИЛ И СТАТИСТИЧЕСКИХ МЕТОДОВ

Сатпай Ақжол

*магистрант, 1 курс, Казахский национальный университет им. Аль-Фараби
Аудит информационной безопасности, Кафедра Кибербезопасности и Криптологии*

Введение

Платежные системы являются важной частью современной экономики, но подвержены рискам мошенничества и технических сбоев. Аномальные транзакции могут сигнализировать о незаконных операциях, взломах или ошибках. Для их выявления применяются правила на основе бизнес-логики и статистические методы, обладающие высокой интерпретируемостью, но требующие корректной настройки.

Актуальность исследования

- Рост объемов онлайн-платежей повышает риск мошенничества.
- Стандартные методы обнаружения аномалий требуют оптимизации.
- Отсутствие универсального подхода делает актуальным анализ существующих методов.

Цель — оценить эффективность бизнес-правил и статистических методов выявления аномалий в платежных транзакциях и предложить рекомендации по их использованию. Для достижения цели необходимо:

- Изучить существующие методы детекции аномалий.
- Оценить их эффективность на транзакционных данных.
- Сравнить выявленные аномалии и точность методов.
- Разработать рекомендации по оптимальному применению.

Методы исследования

Используются:

- **Правила на основе бизнес-логики** (лимиты сумм, географические отклонения, частотный анализ, несоответствия типичному поведению).
- **Статистические методы** (Z-score, IQR, стандартное отклонение, байесовские методы).
- **Оценка эффективности** (доля выявленных аномалий, ложные срабатывания, время обработки).

Основные результаты:

- Проведен анализ методов выявления аномалий.
- Определены их сильные и слабые стороны.
- Разработаны рекомендации по комбинированному использованию бизнес-правил и статистики.

Заключение

Традиционные методы детекции аномалий остаются актуальными, но требуют адаптации. Оптимальным подходом является их комбинированное применение, что повышает точность выявления мошеннических операций. Перспективным направлением является разработка гибридных моделей, сочетающих вероятностные и адаптивные алгоритмы.

Список использованной литературы:

1. Chandola V., Banerjee A., Kumar V. Anomaly Detection: A Survey // ACM Computing Surveys. – 2009. – Vol. 41(3). – pp. 1-58. DOI: 10.1145/1541880.1541882
2. West J., Bhattacharya M. Intelligent Financial Fraud Detection: A Comprehensive Review // Computers & Security. – 2016. – Vol. 57. – pp. 47-66. DOI: 10.1016/j.cose.2015.09.005

3. Phua C., Lee V., Smith K., Gayler R. A Comprehensive Survey of Data Mining-Based Fraud Detection Research // Artificial Intelligence Review. – 2010. – Vol. 34(1). – pp. 1-14. DOI: 10.1007/s10462-009-9124-4

ҚАЗІРГІ ШИФРЛАУ АЛГОРИТМДЕРІНІҢ СЫЗЫҚТЫ ЕМЕС ТҮЙІНДЕРІН ЗЕРТТЕУ

Тұрсынова Ә.Ғ.

Әл-Фараби атындағы Қазақ Ұлттық Университетінің 1 курс магистранты

E-mail: tursynova-2021@mail.ru

Сақан Қ.С.

Әл-Фараби атындағы Қазақ Ұлттық Университетінің PhD

Ақпараттық қауіпсіздіктің криптографиялық алгоритмдерінің арасында маңызды орынды симметриялық шифрлар алады. Қарапайымдылығына, жылдамдығына және сенімділігіне байланысты олар көптеген криптографиялық қолданбаларда кеңінен қолданылады. Кез келген симметриялық шифрдың ең маңызды примитивтерінің бірі сызықты емес алмастыру түйіні немесе S-блоклар деп аталатын түйін болып табылады. Шифрда S-box түрлендіруін беру процедурасы мәтіндік байттардың қосымша шашырауын және араласуын қамтамасыз етеді, бұл әртүрлі криптоаналитикалық шабуылдарды жүзеге асыруды айтарлықтай қиындатады.

Шифрлау алгоритмдерінің күшін анықтау барысында S-блоклар үшін әртүрлі критерийлер бар. Симметриялық блоктық шифрлау алгоритмдері саласындағы көптеген қолданыстағы шешімдерге қарамастан, кестені ауыстыруды (S-блоклар) әзірлеу мәселесі өзекті болып қала береді, оларды криптографиялық алгоритмдерде қолдану криптошабуылдардың барлық түрінен жақсы қорғауды қамтамасыз етеді [1].

S-блоктың сапасы криптографиялық алгоритмнің криптоаналитикалық шабуылдарға қарсы тұруына айтарлықтай әсер етуі мүмкін. Сондықтан тиімді S-блокларды жобалау қауіпсіздік үшін өте маңызды [2]. S-блоклар қазіргі симметриялық криптографиялық алгоритмдердің сызықты еместігін және қауіпсіздік деңгейін анықтайтын негізгі компоненттердің бірі болып табылады.

S-блоклардың қызметі криптографиялық алгоритмдердің қауіпсіздігін жақсарту үшін шифрланған мәтін мен ашық мәтін арасындағы қатынасты шатастыру. Әртүрлі алгебралық құрылымдармен құрастырылған S-блоклар қазіргі криптожүйелерде шифрлаудың ең қауіпсіз компоненттері болып саналады [3].

Зерттеу барысында симметриялық және асимметриялық шифрлау алгоритмдерінде қолданылатын S-блоклар және араластыру функциялары сияқты сызықты емес компоненттердің математикалық қасиеттері мен құрылымдарын талдауға ерекше назар аударылады және зерттеулер жүргізіледі. Сонымен қатар сызықтық емес түйіндердің математикалық қасиеттері мен құрылымдарын талдай отырып, олардың қазіргі алгоритмдердің криптографиялық күшіне әсерін бағалау және криптографиялық төзімділікті қамтамасыз етуде негізгі рөл атқаратын заманауи шифрлау алгоритмдерінің сызықты емес түйіндері қарастырылады.

Пайдаланылған әдебиеттер тізімі:

1. Хаумен А., Капалова Н. А. Динамические таблицы подстановок симметричных блочных алгоритмов шифрования //Вестник КазНПУ имени Абая, Серия «Физико-математические науки». – 2021. – Т. 75. – №. 3. – С. 115-120.
2. Сейткулов Е. и др. Программный инструмент для анализа и синтеза криптографических s-блоков //Вестник КазАТК. – 2023.
3. Seitkulov Y. N., Ospanov R. M., Yergaliyeva B. B. О криптографических свойствах S-блоков //Engineering Journal of Satbayev University. – 2021. – Т. 143. – №. 4. – С. 96-103.

ӘЛЕУМЕТТІК ЖЕЛІЛЕРДЕ АЛАЯҚТАРДЫ АНЫҚТАУ ҮШІН МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН ҚОЛДАНУ

Ақпараттық қауіпсіздік жүйелері, 2 курс магистратура Уралова Ф.С.

Ғылыми жетекшісі: ф.-м.ғ.к., доцент м.а. Мусиралиева Ш.Ж.

әл-Фараби атындағы Қазақ ұлттық университеті

Қазіргі уақытта әлеуметтік желілер кибершабуылдар мен алаяқтық әрекеттердің алаңына айналууда. Анонимді пайдаланушылар VPN, TOR және прокси-серверлерді пайдаланып, өздерінің тұлғаларын жасырады, бұл оларды анықтауды қиындатады. Осы мақалада алаяқтық әрекеттерді талдау үшін машиналық оқыту әдістерін қолдану мәселесі қарастырылады. Пайдаланушылардың мінез-құлқындағы ерекше ауытқуларды анықтау үшін Isolation Forest, One-Class SVM және LSTM алгоритмдері қолданылды. Зерттеу барысында алынған нәтижелер көрсеткендей, бұл әдістер алаяқтарды жоғары дәлдікпен (92%) анықтауға мүмкіндік береді, ал жалған оң нәтижелердің саны барынша азайтылған.

Түйін сөздер: Алаяқтарды анықтау, машиналық оқыту, әлеуметтік желілер, аномальды мінез-құлық, Isolation Forest, LSTM.

Әлеуметтік желілерде анонимді аккаунттар көбейіп, оларды алаяқтық мақсатта пайдалану жиі кездеседі. Дәстүрлі әдістер (IP-талдау, метадеректерді зерттеу) көбінесе тиімділігін жоғалтуда, себебі VPN, TOR және прокси-серверлер арқылы анонимділікті сақтауға болады. Сондықтан, аномальды мінез-құлықты талдау арқылы алаяқтарды анықтау өзекті мәселе болып табылады[4].

Бұл зерттеуде алаяқтық әрекеттерді анықтау үшін үш түрлі әдіс қолданылды: Isolation Forest, One-Class SVM және LSTM. Isolation Forest – ағаштар негізінде аномалияларды бөліп шығару әдісі. One-Class SVM – гиперплоскость арқылы күдікті аккаунттарды бөлу әдісі. LSTM – уақыттық деректерді талдау арқылы алаяқтарды табу үшін пайдаланылды[1].

Жүргізілген эксперименттер әдістердің тиімділігін көрсетті. Isolation Forest 85% дәлдікпен жұмыс істегенімен, оның жалған оң көрсеткіштері салыстырмалы түрде жоғары болып шықты, бұл әдістің кейбір қалыпты пайдаланушыларды алаяқ ретінде қате анықтауына әкелді. One-Class SVM 88% дәлдік көрсетті, ал оның жалған оң нәтиже көрсеткіші 9%-ды құрады, бұл әдістің алаяқтарды анықтаудағы теңдестірілген тиімділігін көрсетті. Ең жоғары нәтиже LSTM алгоритмінде тіркелді, ол 92% дәлдікке қол жеткізіп, жалған оң нәтижелердің ең төменгі деңгейін көрсетті[2]. Бұл рекуррентті нейрондық желінің пайдаланушылардың уақыттық және мінез-құлықтық үлгілерін талдаудағы жоғары қабілетін дәлелдейді. Зерттеу нәтижелері көрсеткендей, бұл әдістерді біріктіру арқылы жүйенің сенімділігін арттыруға және алаяқтарды жоғары дәлдікпен анықтауға болады. Сонымен қатар, әр әдістің өзіндік ерекшеліктері мен артықшылықтарын ескере отырып, оларды нақты жағдайлар мен қажеттіліктерге байланысты қолдану тиімді болмақ[3].

Зерттеу нәтижелері көрсеткендей, аномальды мінез-құлықты талдау әлеуметтік желілердегі алаяқтарды анықтауда тиімді құрал болып табылады. LSTM алгоритмі ең жоғары дәлдік көрсеткенімен, Isolation Forest пен One-Class SVM алдын ала сүзгілеу үшін пайдалы болуы мүмкін. Болашақта бұл әдістерді жетілдіру және үлкен деректер жиынтықтарында тестілеу маңызды қадам болып табылады.

Пайдаланылған әдебиеттер тізімі:

1. Ефимов Е.Г., Селиванова Е.В., Особенности аддиктивного поведения в социальных сетях (по материалам фокус-групповых интервью), журнал «Вестник Курганского университета», 20147 –с. 57.

2. Savage D., Zhang X., Yu X., Chou P., Wang Q. Anomaly detection in online social networks, arXiv:1608.00301 , 2016.
3. Ю Р., Цю Х., Вэнь Ц., Линь Ц.-Ю., Лю Ю. Исследование по обнаружению аномалий в социальных сетях // препринт arXiv arXiv:1601.01102 , 2016. – С. 212-228.
4. Чжэн К., Гупта А. Социальная сеть экстремальных твитеров: пример // Препринт arXiv arXiv:1905.00567 , 2019.

ЖЕЛІЛІК ТРАФИКТІ ТАЛДАУ ӘДІСІН ҚҰРУ ЖӘНЕ ОНЫҢ АРХИТЕКТУРАСЫ

Усманова А.М.

Болатбек М.А. жетекшілігімен

Әл-Фараби атындағы Қазақ ұлттық университеті

e-mail: aseka_usmanova@mail.ru

Қазіргі таңда киберқауіпсіздік маңызды мәселелердің бірі болып отыр. Желілік шабуылдар мен зиянды әрекеттерді уақтылы анықтау және алдын алу ұйымдар мен жеке тұлғалардың ақпараттық қауіпсіздігін қамтамасыз ету үшін маңызды. Желілік трафикті талдау – бұл желі арқылы берілетін деректерді бақылау, құрылымдау және олардың қауіпсіздігін бағалау әдісі.

Желілік инфрақұрылымға бағытталған қауіптердің көбеюі ақпараттық қауіпсіздік саласында жаңа әдістер мен құралдарды қажет етеді. Кибершабуылдар көбінесе деректердің жоғалуына немесе ұрлануына, қызмет көрсетуден бас тартуға (DDoS), зиянды бағдарламалардың таралуына (Malware) және фишинг арқылы алаяқтық әрекеттердің артуына алып келеді [1]. Желілік трафикті талдау желіде орын алатын күдікті әрекеттерді бақылау, аномалияларды анықтау және шабуылдарды ерте кезеңде анықтау, желінің өнімділігін талдау және оңтайландыру, сондай-ақ желілік шабуылдарды анықтау және оларға қарсы шаралар қолдану міндеттерін шешуге бағытталған.

Желідегі трафикті тиімді түрде жинау үшін әртүрлі технологиялар қолданылады. PCAP (Packet Capture) желі арқылы берілетін трафик пакеттерін жинап, олардың мазмұнын зерттеуге мүмкіндік береді. NetFlow және sFlow технологиялары желідегі деректер ағынын бақылау үшін қолданылады. Wireshark – желілік трафикті талдаудың ең танымал құралдарының бірі болып табылады, ал Zeek (Bro IDS) қауіпсіздік инциденттерін анықтауға арналған тиімді жүйе ретінде қолданылады. Жиналған мәліметтерден IP және MAC мекенжайлар, қолданылған желілік хаттамалар, сондай-ақ пакеттердің көлемі мен уақытша сипаттамалары алынады, Бұл кезеңде пакеттерді қайта құрастыру арқылы деректер ағындарына біріктіру, қайталанатын деректерді жою арқылы жүйенің тиімділігін арттыру, аномалияларды есептеу арқылы қалыпты трафик үлгілерінен ауытқуларды анықтау жүргізіледі. Желілік шабуылдарды анықтау үшін әртүрлі әдістер пайдаланылады. Сигнатуралық әдіс белгілі бір зиянды үлгілерді сәйкестендіруге негізделген және Snort, Suricata сияқты жүйелер арқылы жүзеге асырылады. Аномалияға негізделген әдісте машиналық оқыту алгоритмдері, соның ішінде K-Means, Random Forest және LSTM қолданылады [2].

Желілік трафикті визуализациялау үшін бірнеше құралдар қолданылады. ELK Stack (Elasticsearch, Logstash, Kibana) логтарды өңдеу және визуализациялау үшін пайдаланылады. Grafana желілік деректерді графикалық түрде ұсынуға мүмкіндік береді, ал Prometheus жүйе мониторингін жүргізу үшін қолданылады [3]. Желілік трафикті талдау әдістері – бұл киберқауіпсіздікті қамтамасыз етудің маңызды құралы. Ұсынылған архитектура желідегі деректерді жинау, алдын ала өңдеу, машиналық оқыту негізінде талдау және нәтижелерді визуализациялау кезеңдерін қамтиды. Болашақта бұл әдісті жетілдіру үшін жасанды интеллектті кеңінен қолдану, шабуылдарды нақты уақыт режимінде өңдеу жылдамдығын арттыру бағытында зерттеулер жүргізілмек.

Пайдаланылған әдебиеттер тізімі:

1. Алимсеитова Ж., Бекетова Г. Желілік шабуылдарды анықтау және танып білу әдістері мен нейрожелілік модельдерін талдау //Вестник КазАТК. – 2022. – Т. 122. – №. 3. – С. 227-236.

2. Azab A. et al. Network traffic classification: Techniques, datasets, and challenges //Digital Communications and Networks. – 2024. – T. 10. – №. 3. – C. 676-692.

3. Wiles A., Colombo F., Mascorro R. Ransomware detection using network traffic analysis and generative adversarial networks. – 2024.

ГРАФИКАЛЫҚ ДЕСТРУКТИВТІ МАЗМҰНДЫ АНЫҚТАУ ӘДІСТЕРІ

Темиргазиева Шарипа

Әл-Фараби атындағы Қазақ Ұлттық университетінің 2 курс докторанты

E-mail: temirgazievash@gmail.com

Болатбек Милана Асланбекқызы, Әл-Фараби атындағы Қазақ Ұлттық университетінің ақпараттық жүйелер кафедрасының PhD

Соңғы жылдары бүкіл әлемде әртүрлі террористік актілердің көптеген мысалдары болды. Сондай-ақ, көптеген құрбандарға әкелген мектептерде бірнеше қатыгез атыс оқиғалары болды. Бұл шабуылдардың пайда болу себебін зерттеу кезінде Интернет жиі маңызды рөл атқарады. Миллиардтаған тіркелген пайдаланушылары бар әлеуметтік медиа платформалары кең ауқымды ұсынады. "ISIS" және "Аль-Каида" сияқты экстремистік ұйымдар қазіргі уақытта сезімтал жастарды насихаттау, радикалдандыру және тарту үшін әлеуметтік медианы пайдаланады.

Әлеуметтік желілердегі деректер көлемі күрт өскендіктен, радикалды мазмұнды қолмен анықтау қиынға соғады. Сондықтан экстремизмді анықтаудың тиімді автоматты әдісі шұғыл түрде қажет [1].

Бұл жұмыстың мақсаты Ирак пен Сирия Ислам мемлекетінің (ISIS) әлеуметтік медиа платформаларынан деструктивті мазмұнды анықтау әдістерін зерттеу. Шолу экстремизм деректерін жинау және анықтау үшін онлайн, жалпыға қолжетімді автоматтандырылған құралды әзірлеу үшін зерттеу мүмкіндіктерін ашады.

Fernandez және басқалары ағылшын тіліне жазылған немесе аударылған твиттер арасында ISIS радикалдануын анықтау үшін контекстік семантиканы униграммалармен бірге қолданды. Сонымен қатар олар М. Fernandez және т.б. [2], 2020 жылы экстремизмге қатысты онлайн зерттеулерді үш түрге бөлді: талдау, анықтау және болжау. Бұл шолу расталған деректердің жоқтығын, зерттеушілер арасындағы ынтымақтастықтың жоқтығын, экстремистік тіл эволюциясын және экстремизмді анықтауды онлайн зерттеуде этикалық перспективалардың жоқтығын зерттейді.

М. Hashemi және т.б. [3], 2019 жылғы зерттеулері бойынша веб-беттердегі экстремистік кескіндерді тану және оларды символдық насихат ретінде белгілеу үшін машиналық оқытуды қолданудың алғашқы әрекетін ұсынды. 2015 жылдың тамызынан 2018 жылдың қыркүйегіне дейін жалпылау дәлдігі 86% болатын 120 000 кескінді қолданып оқытылған CNN 1,2 миллион күдікті VEO кескінін жіктеу үшін пайдаланылды. Олар өз зерттеулерінде интернеттегі визуалды үгіт-насихаттың және ISIS-тің осындай шабуылдарына арналған нұсқаулардың жаппай өсуімен түсіндіреді.

Зерттеу барысында ISIS және Al-Qaeda және басқада экстремистік туларды тану жүйесін әзірлеуге керекті деректер жиынтығы жинақталды. Деректер жиынтығы жалпы 504 кескінді қамтиды. Деректер жиынтығының өнімділігін арттыру үшін әр кескінді жеке-жеке аннотациялау жүзеге асырылды. Бұл зерттеу Қазақстан Республикасы Ғылым және жоғары білім министрлігінің AP19676342 гранты бойынша қаржыландырылды.

Пайдаланылған әдебиеттер тізімі:

1. J. M. Berger. The Alt-Right Twitter Census: Defining and Describing the Audience for Alt-Right Content on Twitter. – 2018.
2. M. Fernandez және H. Alani. Artificial intelligence and online extremism: Challenges and opportunities in Predictive Policing and Artificial Intelligence // New York, NY, USA: Taylor Francis. – 2020.

3. Hashemi M., & Hall M. Detecting and classifying online dark visual propaganda // Image and Vision Computing. – 2019. – doi:10.1016/j.imavis.2019.06.

КИБЕРБЕЗОПАСНОСТЬ И КРИПТОЛОГИЯ: ЦИФРОВАЯ ВОЙНА ЗА ПРИВАТНОСТЬ

Фёдорова В.В.

Казахский национальный университет им. аль-Фараби

В мире, где данные стали новой валютой, кибербезопасность – это не просто защита информации, а настоящая цифровая война за контроль над личными и корпоративными секретами. Криптология выступает в роли щита, который способен защитить пользователей от хакеров, корпораций и даже государств. С каждым днем все острее и острее стоит вопрос о безопасности своих данных. Подозревают ли среднестатистические люди о возможных рисках и ловушках, касающихся их приватной информации?

Современные методы шифрования такие, как постквантовая криптография, напоминают гонку вооружений – пока одни создают неуязвимые алгоритмы, другие ищут способы их взлома. Не все готовы замечать это или вдаваться в подробности, но проблемы утечки данных, могут настичь любого. Искусственный интеллект уже начинает участвовать в этом противостоянии, создавая как новые средства защиты, так и опасные инструменты атак. Пока он воюет на два фронта, человек, или просто обычный рядовой IT-специалист, будет искать новые методы защиты важных данных.

Как студент IT-направления, я вижу в кибербезопасности не только техническую дисциплину, но и поле для интеллектуальных битв, где победит тот, кто быстрее адаптируется к угрозам будущего. А угрозы могут поступать со всех сторон. Но настоящий специалист тот, кто готов к любым ударам. Насколько мир информационных технологий богат, что даже безопасности уделено особое и даже ключевое место.

Список использованной литературы:

1. Статья: Информационная безопасность и защита информации в современном обществе Ф. А. Капустин Научный руководитель - С. В. Стрельникова Сибирский государственный аэрокосмический университет имени академика М. Ф. Решетнева Российская Федерация, 660037. 2016.
2. 3. Мельников В. П., Клейменов С. А., Петраков А. М. Информационная безопасность и защита информации. 3-е изд. М. : Академия, 2008.
3. Шаньгин В.Ф. Информационная безопасность компьютерных систем и сетей. - М.: Форум-Инфра-М, 2013. – 416 с.
4. Бирюков А.А. Информационная безопасность. Защита и нападение. – М.: ДМКПресс, 2012. – 474 с.
5. Платонов В.В. Программно-аппаратные средства защиты информации. – М.: Academy, 2013. – 336 с.

КИБЕРҚАУІПСІЗДІКТЕГІ OSINT (OPEN SOURCE INTELLIGENCE) ҚҰРАЛДАРЫН ЗЕРТТЕУ ЖӘНЕ ТАЛДАУ

Шулинбаева Айнур Мейрамбекқызы

Ғылыми жетекші: т.ғ.м., аға оқытушы Байспай Г.Б.

әл-Фараби атындағы ҚазҰУ, Алматы, Қазақстан

Email: shulinbaeva04@mail.ru

Аңдатпа. Бұл зерттеу жұмысы OSINT құралдарының киберқауіпсіздік саласында қолдану тиімділігін зерттеуге және олардың салыстырмалы талдауын жүргізуге бағытталған. Зерттеу барысында бірнеше OSINT құралдары қарастырылып, олардың мүмкіндіктері мен ерекшеліктері талданады. Зерттеу теориялық және тәжірибелік әдістері біріктіреді. Сонымен қоса, құралдарға қысқаша шолу жүргізіледі. Ал тәжірибелік бөлімде, құралдар нақты сценарийлерде тестіленеді, сонымен қатар олардың мүмкіндіктері, жинақтайтын деректер көлемі мен талдау мүмкіндіктері салыстырылады.

Кілт сөздер: OSINT, КИБЕРҚАУІПСІЗДІК, АҚПАРАТТЫҚ ҚАУІПСІЗДІК, ДОМЕНДЕР, ВЕБ-БАРЛАУ, АШЫҚ ДЕРЕКТЕР КӨЗДЕРІ, WHOIS, DNS.

Ақпарат – қазіргі цифрлық әлемде негізгі активтердің бірі. Қазіргі кезде ұйымдардың тиімді жұмыс істеуі үшін киберқауіпсіздікті қамтамасыз ету маңызды. Ақпараттық жүйелерді киберқауіптерден қорғау үшін арнайы технологиялар мен әдістерді пайдалануды талап етеді. Мұндай әдістердің бірі – OSINT (Open Source Intelligence). Ашық деректер көздерін пайдаланатын интеллект – бұл ақпаратты ашық көздерден іздеуді, жинауды, талдауды және пайдалануды сипаттайды, сондай-ақ осы мәселелерді шешудің әдістері мен құралдарының жиынтығын қамтиды [1].

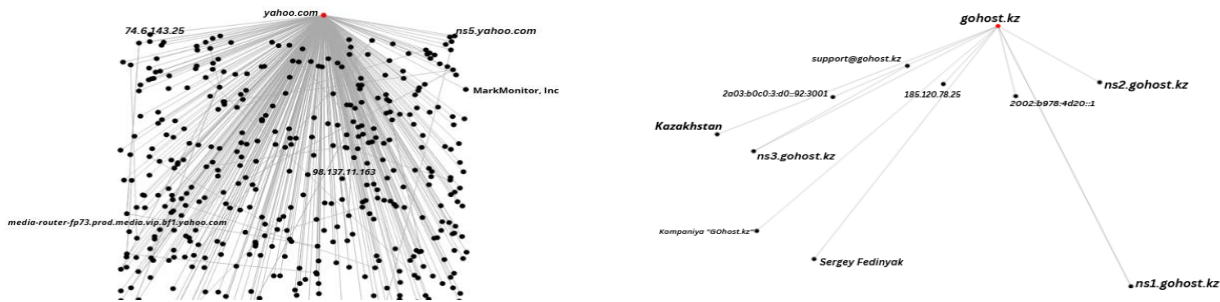
Зерттеудің негізгі мақсаты – OSINT құралдарының тиімділігін анықтау және олардың артықшылықтары мен кемшіліктерін бағалай отырып, киберқауіпсіздікке қосатын үлесін сипаттау. Зерттеу барысында жасалатын салыстырмалы талдау нәтижелері құралдардың ақпараттарды жинаудағы, өңдеудегі және осалдықтарды анықтаудағы тиімділік деңгейлерін анықтауға мүмкіндік береді. Киберқауіпсіздік саласына келетін болсақ, OSINT арқылы жиналған ақпараттарды пайдалануды екі түрлі мақсатта қарастыруға болады. Егер OSINT әдістерін шабуылдаушылар пайдаланған жағдайда, олардың шабуылдары сәтті болу ықтималдығы артады. Ал, OSINT тәсілдерін қауіпсіздік мақсатында пайдаланған жағдайда, қорғаныс деңгейін арттыруға мүмкіндік береді [2].

OSINT тиімді ақпарат жинау құралына айналдыратын бірқатар бірегей мүмкіндіктерге ие. Оның басты артықшылығы – деректердің қолжетімділігі, өйткені ақпарат ашық және заңды көздерден алынады. OSINT құралдары әлеуметтік желілер, веб-сайттар, радио, теледидар сияқты жалпыға қолжетімді көздерден жиналған ақпаратты талдайды. Әрбір құралдың өзіндік бірегей функционалдығы бар. Құралдарды таңдау, барлау қызметінің нақты мақсаттары мен қажеттіліктеріне байланысты.

Талдау жұмысын жасау барысында екі түрлі құрал таңдап алынды. Олар: spiderfoot және recon-ng. Осы екі құралдың көмегімен екі түрлі домен сканерленді.

Spiderfoot - мақсатты объект туралы ақпарат жинауға мүмкіндік беретін қуатты құрал. Құрал деректерді талдау үшін кең ауқымды мүмкіндіктерді қамтамасыз етіп, белсенді және пассивті сканерлеу жасай алады [3]. Spiderfoot арқылы DNS жазбалары, WHOIS деректері, IP мекенжайлары мен домен иесі туралы ақпаратты жинауға болады. Құралдың басты артықшылығы, ол бір деректер түрінен екіншісіне ауыса отырып, сұраулар тізбегін дербес орындай алады. Осы құрал көмегімен yahoo.com және gohost.kz домендеріне талдау жүргізілді (1-сурет).

Сканерлеу нәтижесінде, домендердің WHOIS, DNS, IP-мекенжайлары, тіркеуші мәліметтері, тіркелген елі, электронды пошта мекежайлары, IP-мекенжайлары және домендермен байланысты адам есімдері табылды. Yahoo.com домені халықаралық деңгейдегі үлкен корпорация домені болғандықтан сканерлеу нәтижесінде 862 элемент алынды, ал gohost.kz домені Қазақстандық кішігірім инфрақұрылым домені, сондықтан сканерлеу нәтижесінде тек 10 элемент табылды.



1-сурет. Spiderfoot құралы арқылы алынған граф түріндегі сканерлеу нәтижелері

Recon-ng – қуатты OSINT құралы. Ол ақпаратты автоматты түрде жинап, пассивті веб-барлау жүргізеді. Құрал әртүрлі барлау жұмыстары үшін бірқатар модульдерді ұсынады. Recon-ng модульдерін пайдалану киберқауіпсіздік мамандарына нақты әрі құнды ақпарат жинауға көмектесіп, барлау жұмыстарын жеңілдетеді.

```
[recon-ng][yahoo][hackertarget] > options set SOURCE yahoo.com
SOURCE => yahoo.com
[recon-ng][yahoo][hackertarget] > run

YAHOO.COM
-----
[*] Country: None
[*] Host: yahoo.com
[*] Ip_Address: 98.137.11.164
[*] Latitude: None
[*] Longitude: None
[*] Notes: None
[*] Region: None
-----
[*] Country: None
[*] Host: uk.118800.yahoo.com
[*] Ip_Address: 217.12.1.121
[*] Latitude: None
[*] Longitude: None
[*] Notes: None
[*] Region: None
-----
```

```
[recon-ng][gohost] > modules load recon/domains-hosts/hackertarget
[recon-ng][gohost][hackertarget] > options set SOURCE gohost.kz
SOURCE => gohost.kz
[recon-ng][gohost][hackertarget] > run

GOHOST.KZ
-----
[*] Country: None
[*] Host: aster.gohost.kz
[*] Ip_Address: 185.120.76.50
[*] Latitude: None
[*] Longitude: None
[*] Notes: None
[*] Region: None
-----
[*] Country: None
[*] Host: bbh.gohost.kz
[*] Ip_Address: 185.120.79.47
[*] Latitude: None
[*] Longitude: None
[*] Notes: None
[*] Region: None
-----
[*] Country: None
[*] Host: btw.gohost.kz
[*] Ip_Address: 46.8.43.87
[*] Latitude: None
[*] Longitude: None
[*] Notes: None
[*] Region: None
-----
```

2-сурет. Recon-ng құралы арқылы сканерлеу нәтижелері

Recon-ng құралы арқылы екі доменді сканерлеу нәтижесінде тек хосттар мен IP-мекенжайлары табылды. Yahoo.com доменіне байланысты 501, ал gohost.kz доменіне қатысты 71 хост мәліметтері алынды.

Қорытынды. Жұмыс нәтижелері OSINT құралдарының маңыздылығын анықтауға және оларды тиімді пайдалану жолдарын қарастыруға бағытталған. Тәжірибелік талдау нәтижесінде spiderfoot және recon-ng құралдарының мүмкіндіктері салыстырмалы түрде қарастырылды. Таңдалған домендердің WHOIS, DNS, IP-мекенжайлары, тіркеуші мәліметтері секілді ақпараттар spiderfoot құралы арқылы алынды. Ал, recon-ng құралы домендердің хосттары мен IP-мекенжайлары туралы ғана ақпарат бере алды. Жұмысты қорытындылай келе, кең ауқымды зерттеу жұмыстары үшін spiderfoot құралын, ал белгілі бір сценарийлерде тез, әрі нақты деректер алу үшін recon-ng құралын қолданған тиімді екендігін көре аламыз.

Пайдаланылган әдебиеттер тізімі:

1. Мищиряков И.В. Шевелев А.Д. Макарчук Д.В. Жданова М.М. Исследование инструментов и методов для сбора и анализа открытой информации в сети интернет (OSINT) // Международный научный журнал «ВЕСТНИК НАУКИ» №6 (75) Том 3 – 2024
2. Сидорова, М.Е. Разведка по открытым источникам данных и ее применение для решения задач кибербезопасности // Вестник Российского нового университета серия «Сложные системы: модели, анализ, управление». - 2023. № 1. - 1-14.
3. What is SpiderFoot? // HowTo-Do IT. – 2025. https://www.howto-do.it/what-is-spiderfoot/#The_Power_of_OSINT

ПРОГНОЗЫ ПО ПРОДВИНУТЫМ УГРОЗАМ (APT) НА 2025 ГОД

Кибербезопасность, 2 курс магистратуры Абдраманов Д.Б.

Научный руководитель: PhD, и.о. доцента Болатбек М.А.

Казахский национальный университет имени аль-Фараби

Современные киберугрозы становятся все более сложными и динамичными, требуя новых методов анализа и прогнозирования. В данной работе представлены прогнозы по развитию АРТ-угроз в 2025 году на основе изучения тенденций 2024 года. Анализируются ключевые аспекты, такие как использование искусственного интеллекта в атаках, развитие ботнетов, увеличение атак на цепочки поставок и рост активности хактивистских групп.[1]

Операция *Triangulation* в 2023 году продемонстрировала уникальную цепочку атак на устройства Apple (iOS, watchOS), использующую уязвимости WebKit, ядра XNU и процессоров Apple. В 2024 году эта тенденция подтвердилась, что подтверждается обнаруженными уязвимостями CVE-2024-23222, CVE-2024-23225 и CVE-2024-23296 в Apple, а также CVE-2024-43093 и CVE-2024-43047 в Android.

Мировое сообщество предпринимает активные меры по разрушению инфраструктуры С2-серверов, что вынуждает продвинутые АРТ-группы создавать собственные ботнеты. Примеры: АРТ28 (Sofacy) использовала ботнет на маршрутизаторах Ubiquiti (Moobot), Storm-0940 применяла ботнет Quad7 для атак методом password spraying, а Volt Typhoon контролировала ботнет KV-Botnet, включающий маршрутизаторы и IP-камеры.

Частота атак с использованием уязвимых драйверов (BYOVD) увеличилась на 23% во втором квартале 2024 года. Группировка Lazarus использовала уязвимость CVE-2024-21338 в драйвере AppLocker для внедрения руткита FudModule. Блок-листы уязвимых драйверов обновляются редко, что делает защиту недостаточно эффективной.

Число атак со стороны АРТ-групп увеличилось на 25% в первой половине 2024 года. Например, группа *Lazarus* использовала украденный код компьютерной игры, поддельные соцсети и zero-day эксплойты для атак на криптовалютных инвесторов.

В 2025 году ожидается дальнейший рост хактивистских альянсов, объединяющихся для проведения крупных атак, таких как группа *Holy League*, включающая более 70 хакерских организаций.[2]

Число IoT-устройств достигнет **32 миллиардов к 2030 году**, что создаст новые уязвимости. Многие устройства используют устаревшие библиотеки и небезопасные серверы, что делает их легкими мишенями для атак.

Случай с XZ продемонстрировал уязвимость open-source проектов перед атаками. В 2025 году ожидается не столько рост самих атак, сколько увеличение их обнаружения.

АРТ-группы продолжают использовать искусственный интеллект для автоматизации атак, разведки и генерации вредоносного кода. В 2025 году ожидается использование LLM-моделей для продвинутых атак.[3]

Исследование показало, что АРТ-группы совершенствуют свои методы атак, используя новые технологии, такие как искусственный интеллект, ботнеты, BYOVD и атаки на IoT. Необходимы более строгие меры кибербезопасности, включая мониторинг цепочек поставок, внедрение Zero Trust и улучшение механизмов обнаружения угроз.

Список использованной литературы:

1. BI.ZONE. *Threat Zone 2025*. URL: <https://bi.zone/expertise/research/threat-zone-2025/>
2. Securelist. *Kaspersky APT Predictions 2025*. URL: <https://securelist.com/ksb-apt-predictions-2025/>

3. Backdoored AI, supply chain on open-source and hacktivists alliances: Kaspersky's predictions for 2025 APT landscape. <https://www.kaspersky.com/about/press-releases/backdoored-ai-supply-chain-on-open-source-and-hacktivists-alliances-kasperskys-predictions-for-2025-apt-landscape>

ПРИМЕНЕНИЕ LLM В КИБЕРБЕЗОПАСНОСТИ: ОБЗОР УЯЗВИМОСТЕЙ LLM

Құрасбек Аяжан Нұрлыбекқызы

*КазНУ имени аль-Фараби, кафедра кибербезопасности и криптологии, 1 курс магистрант,
Алматы, Казахстан, e-mail: kurasbek.a.140@mail.ru*

Кенжебаева Мерей Омаровна

*КазНУ имени аль-Фараби, PhD, и.о. доцента кафедры кибербезопасности и криптологии,
Алматы, Казахстан*

Кибербезопасность развивается, сталкиваясь с новыми сложными угрозами. LLM помогают анализировать текстовые данные, выявлять атаки, проверять код и бороться с фишингом. Однако они подвержены ряду уязвимостей.

Быстрая инъекция. Злоумышленники манипулируют входными данными, заставляя LLM раскрывать конфиденциальные сведения. Такие атаки используют скрытые подсказки в текстах или коде [1]. Меры защиты это ограничение возможностей модели и контроль вывода.

Небезопасная обработка вывода. Если LLM генерирует код (SQL, JavaScript) без валидации, возможны XSS, CSRF и удаленное выполнение команд [2]. Решением является строгая фильтрация выходных данных.

Состязательные инструкции. Специфические текстовые команды заставляют LLM генерировать небезопасный код. DesceptPrompt подчеркивает критическую уязвимость Code LLM [3]. Предотвращение включает контроль запросов и обновление моделей.

Отравление обучающих данных в LLM это когда злоумышленники манипулируют набором данных для обучения, чтобы исказить процесс обучения модели, создавая бэкдоры или предвзятые результаты [4]. Решение: фильтрация и мониторинг источников данных.

Отравление данных вывода нацелено на LLM во время их рабочей фазы, эта атака незаметно изменяет входные данные, чтобы вызвать вредоносное поведение в модели без изменений в самой модели. J. He и другие [5], предложили метод, в котором яд активируется условиями, связанными с ограничениями выходного токена. Аномальный анализ и ограничения на токены помогают снизить риски.

DDoS-атаки. Злоумышленники перегружают модели сложными запросами, снижая их производительность, сделав ее недоступной для пользователей [6]. Предотвращение включает ограничение скорости запросов и масштабируемую инфраструктуру.

LLM предоставляют новые возможности в кибербезопасности, но также создают риски. Для защиты необходимо разрабатывать стратегии противодействия атакам, включая контроль входных и выходных данных, мониторинг запросов и безопасное обучение моделей. Интеграция этих мер поможет усилить защиту цифровых систем.

Список использованной литературы:

1. K. Greshake, S. Abdelnabi, S. Mishra, C. Endres, T. Holz, and M. Fritz, “More than you’ve asked for: A comprehensive analysis of novel prompt injection threats to application-integrated large language models,” arXiv e-prints, arXiv:2302, 2023.
2. D. Glukhov, I. Shumailov, Y. Gal, N. Papernot, and V. Papayan, “Llm censorship: A machine learning challenge or a computer security problem?” arXiv preprint arXiv:2307.10719, 2023.
3. F. Wu, X. Liu, and C. Xiao, “Desceptprompt: Exploiting llm-driven code generation via adversarial natural language instructions,” arXiv preprint arXiv:2312.04730, 2023.
4. A.E. Cinà, K. Grosse, A. Demontis, S. Vascon, W. Zellinger, B.A. Moser, A. Oprea, B. Biggio, M. Pelillo, F. Roli, “Wild patterns reloaded: A survey of machine learning security against training data poisoning”, ACM Computing Surveys, 55 (13s) (2023), стр. 1-39.

5. J. He, W. Jiang, G. Hou, W. Fan, R. Zhang, and H. Li, "Talk too much: Poisoning large language models under token limit," arXiv preprint arXiv:2404.14795, 2024.
6. A.B. de Neira, B. Kantarci, M. Nogueira, "Distributed denial of service attack prediction: Challenges, open issues and opportunities", Computer Networks, 222 (2023)

ОБНАРУЖЕНИЕ КРИМИНАЛЬНЫХ ДЕЙСТВИЙ В ВИДЕ АТАК И ОПРЕДЕЛЕНИЕ АНОМАЛИЙ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ

Нурғали А.А., Исмаилов Д.М., Омаров Б.С., Турарбек А.Т.

Казахский национальный университет им. аль-Фараби,
azat.nurgali.2001@gmail.com, danyar.ismailov@gmail.com, turarbekasem1@gmail.com

В связи с расширяющейся угрозой кибератак и криминальной активности в сети использование методов машинного обучения (МО) становится важным инструментом для обнаружения атак и аномального поведения. В данной работе рассматриваются основные методы МО, используемые для обнаружения криминальных атак и аномалий.

Один из ключевых подходов в обнаружении аномалий – анализ данных с использованием логистической регрессии [1]. Этот метод позволяет моделировать вероятность того, что данное событие относится к категории аномального поведения, основываясь на исторических данных. Нейронные сети, включая сверточные нейронные сети (CNN) и рекуррентные нейронные сети (LSTM), широко применяются для анализа временных рядов и сетевого трафика [2]. Если рассмотреть каждый метод отдельно то можно отметить, что метод кластеризации K-Means используется для группировки данных без предварительной разметки, помогая выявлять нетипичные группы пользователей или событий, которые отклоняются от общего поведения. Isolation Forest – один из наиболее эффективных методов обнаружения аномалий, который строит случайные разбиения данных и оценивает, насколько легко конкретный объект можно изолировать [3].

В процессе исследования была использована модель МО на основе XGBoost, предназначенная для обнаружения вторжений в сеть (IDS – Intrusion Detection System). Модель принимает на вход параметры сетевого соединения и определяет, является ли это нормальной активностью или сетевой атакой [4]. Если это атака, модель также определяет её тип. Алгоритм работает по принципу исправления ошибок предыдущих деревьев с целью минимизации общей ошибки модели.

Модель способна классифицировать события в следующие типы:

- Normal – нормальное соединение, без признаков атаки;
- DOS (Denial of Service) – атака на доступность (например, smurf);
- R2L (Remote to Local) – попытка удаленного взлома через сервисы (например, guess_passwd);
- U2R (User to Root) – попытка повышения привилегий (например, buffer overflow);
- Probe – сканирование сети в поисках уязвимостей (например, satan, nmap).

Модель может применяться в системах мониторинга сетевого трафика, в брандмауэрах и системах предотвращения атак, анализа сетевых журналов и для защиты серверов и сетевых сервисов. В результате было выявлено, что модель на основе XGBoost обеспечивает высокую точность и быструю обработку трафика в реальном времени. Она способна эффективно классифицировать сетевые события и предотвращать угрозы с высокой степенью достоверности. Исходя из это можно утверждать, что методы МО позволяют с высокой точностью обнаруживать криминальные действия и предсказывать аномальное поведение, что обеспечивает новые возможности для безопасности.

Список использованной литературы:

1. Chandola V., Vanerjee A., Kumar V. Anomaly Detection: A Survey. ACM Computing Surveys.– 2009. – 41(3). – P. 1-58.
2. Котенко И. В., Саенко И. Б., Лаута О. С., Васильев Н. А., Садовников В. Е. "Атаки и

методы защиты в системах машинного обучения: анализ современных исследований" // Вопросы кибербезопасности. – 2024. – №1. – С. 24-37.

3. Liu F. T., Ting K. M., Zhou Z. H. Isolation Forest. In Proceedings of the 8th IEEE International Conference on Data Mining. – 2008. – P. 413–422.

4. Лукманова К.А., Картак В.М. Распознавание фишинговых ссылок с использованием методов машинного обучения // Безопасность цифровых технологий. – 2024. – № 3 (114). – С. 9–20. – DOI: 10.17212/2782-2230-2024-3-9-20.

ЖАСАНДЫ ИНТЕЛЛЕКТ НЕГІЗІНДЕГІ ІОТ ҚҰРЫЛҒЫЛАРЫН БАСҚАРУ: ТИІМДІЛІК, ҚАУІПСІЗДІК ЖӘНЕ МАСШТАБТАЛУДЫ ҮЙЛЕСТІРУ

Жұмақын Айтүлек Ерліұлы

әл-Фараби атындағы Қазақ Ұлттық университетінің 1 курс магистранты

E-mail: zumakynajtolek@gmail.com

Темирбекова Жанерке Ерлановна

әл-Фараби атындағы Қазақ Ұлттық университетінің PhD

Соңғы жылдары жасанды интеллект (ЖИ) технологиялары IoT (Интернет заттары) жүйелерін басқару саласында кеңінен қолданылуда. IoT құрылғыларының санының экспоненциалды өсуі олардың басқарылуын оңтайландыруды, деректерді өңдеу жылдамдығын арттыруды және қауіпсіздік мәселелерін шешуді талап етеді ([Wu et al., 2020](#)).

ЖИ негізіндегі IoT жүйелері автономды шешім қабылдау механизмдерін жетілдіруге мүмкіндік береді. Бұл әдістер нақты уақыттағы деректерді талдау, үлгілерді тану және басқару шешімдерін оңтайландыру арқылы жүзеге асады ([Mazhar et al., 2023](#)).

IoT құрылғыларының кең таралуы оларды кибершабуылдарға осал етеді. ЖИ технологиялары IoT жүйелеріндегі қауіпсіздік шараларын жетілдіруде маңызды рөл атқарады. Машиналық оқыту (ML) және терең оқыту (DL) әдістері IoT құрылғыларына бағытталған аномалияларды анықтау және шабуылдарды алдын ала болжау үшін қолданылады ([Tang et al., 2023](#)).

IoT инфрақұрылымдарының кеңеюімен бірге олардың тиімді жұмыс істеуін қамтамасыз ету қажеттілігі туындайды. Edge AI және Fog Computing технологиялары IoT жүйелерінің орталықтандырылған серверлерге жүктемесін азайту арқылы масштабталуын оңтайландырады ([Rehman et al., 2021](#)).

Бұл зерттеу ЖИ негізіндегі IoT басқару әдістерін бағалау үшін келесі әдістерді қолданады:

- **Деректерді жинау және өңдеу:** IoT құрылғыларынан алынған мәліметтерді машиналық оқыту алгоритмдері арқылы өңдеу.
- **Жүйенің қауіпсіздігін бағалау:** IoT желілеріндегі ықтимал осалдықтарды анықтау және оларды қорғау шараларын әзірлеу.
- **Масштабталу тиімділігін тестілеу:** IoT құрылғыларының жүктемеге төзімділігін модельдеу.

Зерттеу нәтижелері көрсеткендей, ЖИ технологияларын енгізу IoT құрылғыларының тиімділігін **25-30%**-ға арттырады, ал киберқауіпсіздік шараларын күшейту IoT инфрақұрылымындағы шабуылдарды анықтау дәлдігін **92%**-ға дейін жақсартады. Масштабталу шешімдерін қолдану арқылы өңдеу жылдамдығы **40%**-ға артады ([Chui et al., 2018](#)). Бұл зерттеу IoT жүйелеріндегі ЖИ-дың маңыздылығын айқындап, оның тиімділік, қауіпсіздік және масштабталу тұрғысынан оң әсерін дәлелдейді. Болашақта автономды IoT жүйелерін дамыту және қауіпсіздік механизмдерін жетілдіру бағытында қосымша зерттеулер қажет.

Пайдаланылған әдебиеттер тізімі:

1. Wu, H., Han, H., Wang, X., & Sun, S. (2020). Research on Artificial Intelligence Enhancing Internet of Things Security: A Survey. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2020.3018170>
2. Mazhar, T., Irfan, H. M., Haq, I., Ullah, I., Ashraf, M., & Elkamchouchi, D. H. (2023). Analysis of Challenges and Solutions of IoT in Smart Grids Using AI and Machine Learning Techniques: A Review. *Electronics*. <https://doi.org/10.3390/electronics12010242>

3. Tang, C., Huang, G., & Chen, L. (2023). Machine learning techniques for IoT security: A survey. *ACM Computing Surveys*, 55(2), 1-30. <https://doi.org/10.1145/3501350>
4. Rehman, A., Haseeb, K., Saba, T., Lloret, J., & Sendra, S. (2021). An Optimization Model with Network Edges for Multimedia Sensors Using Artificial Intelligence of Things. *Sensors*. <https://doi.org/10.3390/s21217103>
5. Chui, K. T., Lytras, M. D., & Visvizi, A. (2018). Energy Sustainability in Smart Cities: Artificial Intelligence, Smart Monitoring, and Optimization of Energy Consumption. *Energies*. <https://doi.org/10.3390/en11112869>

КИБЕРШАБУЫЛДАРДЫ АНЫҚТАУ ЖӘНЕ КИБЕРҚАУІПСІЗДІК ДЕҢГЕЙІН АРТТЫРУ ҮШІН МАШИНАЛЫҚ ОҚЫТУДЫ ПАЙДАЛАНУ

Бимолдина Ж.А.¹, Багитова К.Б.²

¹1 курс докторанты, ал-Фараби атындағы Қазақ Ұлттық Университетінің "Киберқауіпсіздік және криптология" кафедрасы, Қазақстан, Алматы, E-mail: jarkinB@mail.ru

²Ғылыми жетекші - Ph.D., Халел Досмұхамедов атындағы Атырау университетінің «Информатика» кафедрасының меңгерушісі, Қазақстан, Атырау, E-mail: KBBagitova@gmail.com

Аңдатпа

Бұл жұмыс кибершабуылдардың заманауи әдістерін және жасанды интеллектке негізделген қорғаныс стратегияларын қарастырады. Қауіптерді талдауға, осалдықтарды анықтауға және инциденттерге автоматтандырылған жауап беру үшін машиналық оқыту алгоритмдерін қолдануға баса назар аударылады.

Түйін сөздер: киберқауіпсіздік, жасанды интеллект, машиналық оқыту, қауіп-қатерді талдау, қорғауды автоматтандыру

Кіріспе. Ақпараттық технологиялардың қарқынды дамуы жағдайында киберқауіптер күрделене түсуде. Дәстүрлі қорғаныс әдістері әрқашан шабуылдардың жаңа түрлерімен күреспейді, бұл инновациялық шешімдерді енгізуді талап етеді. Жасанды интеллект және машиналық оқыту аномалияларды автоматты түрде анықтауға, желілік трафиктің әрекетін талдауға және ықтимал шабуылдарды болжауға жаңа мүмкіндіктер ашады. Бұл жұмыстың мақсаты-кибершабуылдардың заманауи әдістерін талдау және жасанды интеллект негізінде қорғаныс стратегиясын жасау [3].

Машиналық оқытуды қолдана отырып, кибершабуылдарды анықтау әдістері. Дәстүрлі киберқауіпсіздік әдістеріне брандмауэрлерді, антивирустық бағдарламаларды, кіруді анықтау жүйелерін (IDS) және кіруді болдырмау жүйелерін (IPS) пайдалану кіреді. Бұл әдістер қолтанбаны талдауға, эвристикалық талдауға және трафикті сүзуге негізделген. Алайда, мұндай тәсілдер көбінесе күрделі және белгісіз шабуылдарға қарсы тиімді емес [1].

Желілік трафикті талдау үшін машиналық оқыту алгоритмдерін қолдану логистикалық регрессия, кездейсоқ орман, градиентті күшейту және нейрондық желілер сияқты машиналық оқыту алгоритмдері ықтимал шабуылдарды көрсете алатын желілік трафиктегі ауытқуларды анықтауға мүмкіндік береді [4]. Оқытылған модельдер үлкен көлемдегі деректерді талдауға және дәстүрлі әдістерге қол жетімді емес заңдылықтарды анықтауға қабілетті.

Аномалияны анықтау және мінез-құлықты талдау аномалияны анықтау әдістеріне кластерлеу (мысалы, k-орташа алгоритм), тірек векторлық әдістер (SVM) және автоэнкодерлер жатады. Мінез-құлықты талдау тарихи деректер мен ағымдағы әрекеттерді талдау негізінде пайдаланушылар мен құрылғылардың күдікті әрекеттерін анықтауға мүмкіндік береді.

Автоматтандырылған инциденттерге жауап беру жүйелері қауіптерді жіктеу және күдікті әрекеттерді блоктау немесе әкімшілерге хабарлама жіберу туралы шешім қабылдау үшін машиналық оқыту үлгілерін пайдаланады. Бұл шабуылдарға жауап беру уақытын едәуір қысқартуға және зиянды азайтуға мүмкіндік береді [2].

1-ші кестеде көрсетілгендей түрлі тәсілдердің тиімділігіне талдау жүргізілді және киберқауіпсіздікті арттыру бойынша ұсыныстар ұсынылды:

Кесте 1. Киберқауіпсіздікке әртүрлі тәсілдердің тиімділігін талдау

Тәсіл	Тиімділік	Ұсыныстар
Қорғаудың дәстүрлі әдістері	Орташа	Қолтаңбаны талдауды жақсарту
Машиналық оқыту	Жоғары	Аномалияны анықтау алгоритмдерінің дамуы
Аномалияларды анықтау	Жоғары	Мінез құлықты талдаудың жоғарылауы
Жауап беруді автоматтандыру	Өте жоғары	Интеллектуалды жауап беру жүйелерін енгізу

Қорытынды

Зерттеу барысында ақпараттық жүйелерді қорғау деңгейін арттыру үшін кибершабуылдардың заманауи әдістері мен жасанды интеллектті пайдалану мүмкіндіктері талданды. Машиналық оқытуды қолдану қауіптерді тиімді анықтап қана қоймай, оқиғаларға жедел жауап беруге мүмкіндік береді, бұл киберқауіпсіздік деңгейін едәуір арттырады. Әрі қарайғы зерттеулер күрделі модельдерді дамытуға және бұлтты платформалармен интеграциялауға бағытталуы мүмкін.

Пайдаланылған әдебиеттер тізімі:

1. Goodfellow I., Bengio Y., Courville A. Deep Learning. MIT Press, 2016.
2. Sommer R., Paxson V. Outside the Closed World: On Using Machine Learning for Network Intrusion Detection. IEEE Symposium on Security and Privacy, 2010.
3. Мельников В. В. Кибербезопасность: теория и практика. М.: Издательство «Бином», 2020.
4. Коваленко А. И. Методы анализа аномалий в информационных системах. СПб.: Питер, 2018.

ИОТ ҚҰРЫЛҒЫЛАРЫН КИБЕРШАБУЫЛДАН ҚОРҒАУ ӘДІСТЕРІН ТАЛДАУ: DDoS ШАБУЫЛДАРЫНАН ҚОРҒАУ ЖӘНЕ ПЕРСПЕКТИВАЛЫҚ ШЕШІМДЕР

Абыл А.С.

М.Х. Дулати атындағы Тараз университеті ,магистрант 2 курс

(E-mail:a.abyl@inbox.ru)

Мурзахметов А.Н.

М.Х. Дулати атындағы Тараз университеті , PhD профессор

Интернет заттар (IoT) технологиялары күнделікті өмірде, өндірісте және көлік саласында кеңінен қолданылып келеді. Алайда, бұл құрылғылардың интернетке қосылуы оларды кибершабуылдарға осал етеді. Соның ішінде ең жиі кездесетін және қауіпті шабуыл – DDoS (Distributed Denial of Service), яғни қызмет көрсетуден бас тарту шабуылы. Бұл шабуыл түрі құрылғылардың шектеулі ресурстарын пайдаланып, оларды істен шығарады [1].

Зерттеулерге сәйкес, IoT құрылғыларының шамамен 90%-ы әлсіз немесе әдепкі (зауыттық) құпиясөздерді қолданады. Сонымен қатар, ескі хаттамалар (мысалы, Telnet, HTTP) мен сирек жаңартылатын бағдарламалық қамтамасыз ету де осалдық туғызады [3].

DDoS-шабуылдардың кең таралған түрлеріне SYN Flood, UDP Flood, DNS Amplification және ботнеттер (мысалы, Mirai, Mozi) арқылы жасалатын шабуылдар жатады. Мұндай ботнеттер бұзылған IoT құрылғыларын біріктіріп, бір мезетте көптеген сұраныс жібереді [2].

IoT құрылғыларын мұндай шабуылдардан қорғау үшін бірнеше әдістер қарастырылған. Олардың ішінде желі сегментациясы (VLAN), трафикті сүзу (ACL), бұлтты қорғаныс қызметтері (мысалы, Cloudflare) және машиналық оқытуға негізделген аномалияны анықтау жүйелері бар [4].

Талдау нәтижелері бойынша, қорғаныссыз жүйеде орташа кідіріс 150 мс, CPU жүктемесі 95%, өткізу қабілеті небәрі 10 Мбит/с болған. Ал машиналық оқыту қолданылған жағдайда кідіріс 55 мс-ке дейін төмендеп, CPU жүктемесі 35%, өткізу қабілеті 40 Мбит/с-ке жеткен. Бұлтты қорғаныс пен интеллектуалды жүйелер тиімділігі жағынан алдыңғы қатарда тұр [5].

Қазіргі таңда болашағы бар бағыттарға жасанды интеллект технологияларын қолдану, блокчейн арқылы құрылғыларды аутентификациялау және деректерді қорғау, сонымен қатар, құрылғыларды автоматты түрде жаңартып отыру жүйелерін енгізу жатады .

Осындай кешенді тәсілдер IoT құрылғыларының киберқауіпсіздігін арттыруға мүмкіндік береді. Жалпы алғанда, IoT құрылғыларының қауіпсіздігін қамтамасыз ету үшін көпдеңгейлі және интеллектуалды қорғаныс механизмдерін қолдану қажет. DDoS шабуылдарына қарсы тиімді әдістерді таңдау – қауіпсіз және сенімді желілік орта құрудың негізі.

Пайдаланылған әдебиеттер тізімі:

1. Kolias, C., Kambourakis, G., Stavrou, A., & Voas, J. (2017). *DDoS in the IoT: Mirai and other botnets*. Computer, 50(7), 80–84.
2. Antonakakis, M., April, T., Bailey, M., et al. (2017). *Understanding the Mirai Botnet*. USENIX Security Symposium, 1093–1110.
3. Mosenia, A., & Jha, N. K. (2017). *A comprehensive study of security of Internet-of-Things*. IEEE Trans. Emerging Topics in Computing, 5(4), 586–602.
4. Yu, W., Liang, F., He, X., et al. (2018). *A survey on the edge computing for the Internet of Things*. IEEE Access, 6, 6900–6919.
5. Sivanathan, A., et al. (2019). *Low-cost flow-based security solutions for smart-home IoT devices*. Proceedings of the IEEE, 107(10), 1933–1950.

СОВРЕМЕННЫЕ МЕТОДЫ ЗАЩИТЫ СМАРТФОНА ОТ КРАЖИ ДАННЫХ

Мурзалиев Д.Н.

КазНУ им. аль-Фараби

E-mail: diasmurzali@gmail.com

Нарбаева С.М.

КазНУ им. аль-Фараби, старший преподаватель

В данной работе рассматривается исследование современных методов защиты данных смартфонов от несанкционированного доступа и кражи. Основное внимание уделяется разработке комплексного решения **MobileGuard**, которое обеспечивает многоуровневую защиту персональных данных пользователей мобильных устройств.

В ходе исследования были проанализированы актуальные угрозы информационной безопасности смартфонов, включая вредоносное ПО, фишинговые атаки, уязвимости в приложениях, несанкционированный физический доступ и перехват данных через незащищенные сети Wi-Fi. Разработанная система использует комбинацию биометрической аутентификации, шифрования данных и мониторинга подозрительной активности для комплексной защиты пользовательской информации.

Одной из ключевых особенностей **MobileGuard** является функция удаленного управления устройством, которая позволяет в случае кражи или утери смартфона заблокировать доступ к данным, отследить местоположение устройства и при необходимости выполнить удаленное стирание всей информации. Система также включает в себя мониторинг разрешений приложений, выявление и блокировку подозрительных запросов на доступ к конфиденциальным данным пользователя.

Результаты тестирования показали высокую эффективность предложенного решения в предотвращении несанкционированного доступа к данным и защите от современных киберугроз. Дальнейшие перспективы развития системы включают внедрение механизмов искусственного интеллекта для адаптивного анализа поведения приложений, усовершенствование алгоритмов обнаружения вредоносного ПО и расширение функций безопасного хранения и резервного копирования данных. Разработанная система **MobileGuard** может быть интегрирована в существующие мобильные операционные системы для повышения уровня защиты персональных данных пользователей смартфонов как в корпоративном, так и в частном использовании. В ходе выполнения данной работы была разработана система **MobileGuard**, предназначенная для комплексной защиты смартфонов от различных типов угроз и предотвращения кражи персональных данных. В основе решения лежит многоуровневый подход к безопасности, включающий биометрическую аутентификацию, шифрование данных, анализ поведения приложений и удаленное управление устройством.

Проведенные исследования и тестирования показали, что использование комплексного подхода к обеспечению безопасности мобильных устройств позволяет значительно снизить риски несанкционированного доступа к конфиденциальной информации. Предложенные методы защиты эффективны против современных угроз, таких как вредоносные приложения, фишинговые атаки и перехват данных через незащищенные сети.

Список использованной литературы:

1. Алиев К.Б., Омаров Н.С. Мобильная безопасность: методы защиты данных на смартфонах. -- Алматы: Наука, 2022. -- №3(62). -- С. 28-35.
2. Козлов И.П., Смирнова Е.В. Биометрические методы аутентификации в мобильных

устройствах. -- Москва: Инфра-М, 2021. -- №4(58). -- С. 45-53.

3. Бакиров А.М., Жумагалиев Т.К. Анализ и предотвращение утечек данных с мобильных устройств. Вестник информационных технологий. -- 2023. -- №2(33). -- С. 67-75.

Нуржанов Р.Р., Каримов С.Д. Шифрование данных и защита личной информации на платформах iOS и Android. -- Нур-Султан: Цифровые технологии, 2022. -- №5(74). -- С. 41

**«КОМПЬЮТЕРЛІК ҒЫЛЫМДАР МЕН
ИНЖЕНЕРИЯДАҒЫ ЗАМАНАУИ ТЕНДЕНЦИЯЛАР»
СЕКЦИЯСЫ**

**СЕКЦИЯ «СОВРЕМЕННЫЕ ТЕНДЕНЦИИ В
КОМПЬЮТЕРНЫХ НАУКАХ И ИНЖЕНЕРИИ»**

**«MODERN TRENDS IN COMPUTER SCIENCE AND
ENGINEERING» SECTION**

Development of an application for predicting the probability of a Stroke in a patient Using Machine Learning Models

Zhanarys Abutayev Esimtaiuly

Kazakh-British Technical University, 2nd-year master student

E-mail: janareis.this@gmail.com

The development of predictive models for disease diagnosis and prognosis has become increasingly vital in healthcare. Several studies have explored different machine learning techniques for stroke prediction. Tung et al. (2020) [1] developed AI models using administrative healthcare databases, demonstrating the potential of machine learning for stroke risk assessment. Shi et al. (2022) [2] introduced a cross-modal cross-attention network (C2MA-Net) for stroke lesion segmentation using CT perfusion scans, achieving significant improvements in classification accuracy. Similarly, Lakshmi et al. (2017) [3] applied voxel-based lesion segmentation with Support Vector Machine (SVM) classifiers, demonstrating their effectiveness in detecting brain stroke regions. Additionally, Chiu et al. (2020) [4] explored multiclass machine learning models to predict acute ischemic stroke outcomes after reperfusion therapy.

Building on this previous research, our project focuses on developing a mobile application for stroke prediction using machine learning techniques. The project encompasses various stages, including data collection, exploration, preprocessing, model development, evaluation, and mobile app deployment.

Methodology

Initially, relevant medical datasets were collected, focusing on stroke-related risk factors such as age, gender, hypertension, heart disease, BMI, and average glucose level. These datasets were preprocessed to ensure consistency and reliability in subsequent analyses. Exploratory data analysis techniques, including descriptive statistics and data visualization, were employed to understand the underlying structure and patterns within the data.

To prepare the data for machine learning algorithms, missing values were removed, categorical variables were encoded, and the dataset was standardized to maintain uniformity. The data was split into training, validation, and test sets to ensure robust model evaluation and generalization.

Three machine-learning techniques were applied to the dataset: Logistic Regression, Random Forest, and Support Vector Machine (SVM). Logistic Regression was chosen for its simplicity and effectiveness in binary classification tasks. Random Forest was included for its robustness in ensemble learning, while SVM was selected for its ability to model complex decision boundaries.

Results and Discussion

The dataset was highly imbalanced, with only 249 positive stroke cases out of 5,110 records. This imbalance was addressed using SMOTE (Synthetic Minority Oversampling Technique). After training and evaluation, the Random Forest model demonstrated the highest accuracy (94%) but struggled with recall for stroke patients, achieving only 2%. Logistic Regression provided a more balanced performance, with an accuracy of 88% and a recall of 24% for stroke patients.

Analysis of variable importance revealed that age, average glucose levels, and BMI were the most significant predictors of stroke risk. These findings emphasize the importance of including diverse features in predictive modeling.

A mobile application was developed using the Flutter framework to enable cross-platform functionality. The app integrates the trained machine learning models and provides real-time stroke risk predictions. Users can input relevant medical data, and the app calculates a stroke risk score. The application also includes documentation to enhance user understanding of the underlying system architecture and its predictions.

The mobile application developed in this project leverages machine learning to provide accurate stroke predictions. While Random Forest achieved higher overall accuracy, Logistic Regression proved more effective for detecting stroke cases. Future work will focus on improving recall through enhanced preprocessing techniques and exploring explainable AI methods to increase trust in the predictions.

References:

1. Tung, W.-F., Wu, F.-H., Chan, P.-C., Lin, H.-H., Chen, Y.-F., & Lin, C.-S. (2020). Designing AI models for predicting ischemic stroke using administrative healthcare databases. *International Symposium on Computer, Consumer and Control (IS3C)*, 49–52.
2. Shi, T., Jiang, H., & Zheng, B. (2022). C2MA-Net: Cross-modal cross-attention network for acute ischemic stroke lesion segmentation based on CT perfusion scans. *IEEE Transactions on Biomedical Engineering*, 69(1), 108–118.
3. Lakshmi, R. P., Babu, M. S., & Vijayalakshmi, V. (2017). Voxel-based lesion segmentation through SVM classifier for effective brain stroke detection. *International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)*, 1064–1067.
4. Chiu, I.-M., Zeng, W.-H., & Lin, C.-H. R. (2020). Using multiclass machine learning models to improve outcome prediction of acute ischemic stroke patients after reperfusion therapy. *International Computer Symposium (ICS)*, 225–231.

Development of a human recognition system *CameraLearning* to warning the owner of the house

Almbekuly Aibek

2nd course masters student of KBTU

Email: a_almabekuly@kbtu.kz

More people want to keep their homes safe because break-ins are becoming more common. Old security systems with motion sensors often give false alarms and can't tell the difference between friends and strangers. My project, *CameraLearning*, uses a camera to recognize people and quickly warns homeowners if it sees someone unknown.

I use a camera to record video with a streaming app and process it on a computer using OpenCV and the `face_recognition` library (based on the ResNet-34 model). For testing, I collected 1800 photos of different people with various lighting and angles. The system processes the video, detects faces with the HOG algorithm, and sends alerts via Telegram if it spots a stranger.

Results indicate that *CameraLearning* achieves a recognition accuracy of 92% with a tolerance of 0.6, tested on the dataset under controlled lighting conditions. The system successfully distinguishes between known and unknown individuals, sending alerts with a delay of less than 1 second, demonstrating its practical utility for home security.

The novelty of this work lies in autonomous operation, in which a conventional camera is used as an accessible video source with local processing, which eliminates dependence on the cloud and thus reduces privacy risks. In addition, optimizing the system for low-resource devices increases its accessibility to private users. The integration of Telegram notifications in real time ensures that homeowners are promptly informed, which is not usually found in traditional systems.

Literature supports the system's foundation. Lin and Xie (2020) highlight the effectiveness of feature vector-based classification in improving recognition accuracy, a principle applied in *CameraLearning*'s feature extraction process [1]. Guo and Zhang (2018) identify challenges in deep learning for face recognition under uncontrolled conditions, emphasizing the need for robust preprocessing, which this study addresses through image standardization [2]. Luo et al. (2018) propose unsupervised domain adaptation to enhance model generalizability, inspiring future improvements in *CameraLearning* to adapt to diverse real-world scenarios [3].

In conclusion, *CameraLearning* offers a reliable, user-friendly solution for intelligent home security monitoring, surpassing traditional systems in accuracy and autonomy. Future work will focus on integrating deep learning techniques to improve performance in challenging conditions and expanding the dataset for broader applicability.

References:

1. Y. Lin and H. Xie, "Face gender recognition based on face recognition feature vectors." IEEE, 9 2020, pp. 162–166. [Online]. Available: <https://ieeexplore.ieee.org/document/9236905/>
2. Z. Luo, J. Hu, W. Deng, and H. Shen, "Deep unsupervised domain adaptation for face recognition." IEEE, 5 2018, pp. 453–457. [Online]. Available: <https://ieeexplore.ieee.org/document/8373866/>
3. G. Guo and N. Zhang, "What is the challenge for deep learning in unconstrained face recognition?" IEEE, 5 2018, pp. 436–442. [Online]. Available: <https://ieeexplore.ieee.org/document/8373863/>

Predicting football player’s price using ML algorithms

Aman Sh.S.

Second year Master student of KBTU (Kazakh-British Technical University)

E-mail: shapagatsazahanuly@gmail.com

Symbat Kabdrakhova

Candidate of physical and mathematical science, Associate Professor

The current work proposes predicting football player’s price using machine learning algorithms. In the realms of sport, especially in football determining market value of the players very interesting for coaches, public experts, football fans, analytics and scouts. Using these informations clubs can do good transfers. The research methodology involves collecting and analyzing extensive data on players statistics, player performance metrics. This article explores the application of machine learning (ML) to predict football players’ market value, offering a data-driven and objective approach. By leveraging extensive datasets that include player performance statistics, historical transfer data, physical attributes, and contextual factors, ML models can provide more accurate and reliable market valuations

The prediction of football players’ market value has become an increasingly significant topic in sports analytics, driven by the substantial financial stakes involved in player transfers [1]. Machine learning (ML) has emerged as a potent tool for addressing this complex problem due to its capability to analyze vast datasets and identify patterns that might not be evident through traditional statistical methods. Initial efforts to predict player market values largely relied on econometric models, incorporating variables such as player performance statistics, age, and contract length.[3]

The primary goal is to predict the market value of football players using machine learning techniques. Accurate predictions can benefit clubs, agents, and analysts in making informed decisions regarding player transfers and investments [2]. From figure we see everything starts with data collection. For collecting data we used site ‘<https://sofifa.com/>’, where we can find characteristics of players. After getting data there can be some issues in data, therefore we need to clean data by removing NaN values and etc. After cleaning data we go to ”choosing the main features” part. Original data contains 65 columns. Therefore we need to choose the most valuable, necessary columns like ”age”, ”finishing”, ”passing”, ”shooting” and etc. To choose them we use correlation heatmap to see connection between attributes. After that we are gonna do splitting data into training and testing parts. Then we train two machine learning algorithms like Random Forest and Linear Regression on data. After this use the best method to predict values of players, which is Random Forest algorithm.

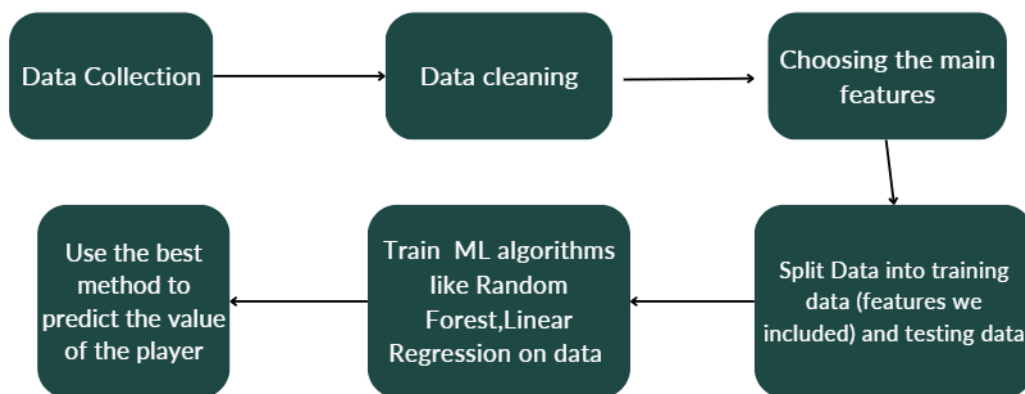


Figure 1: Methodology for predicting price of players

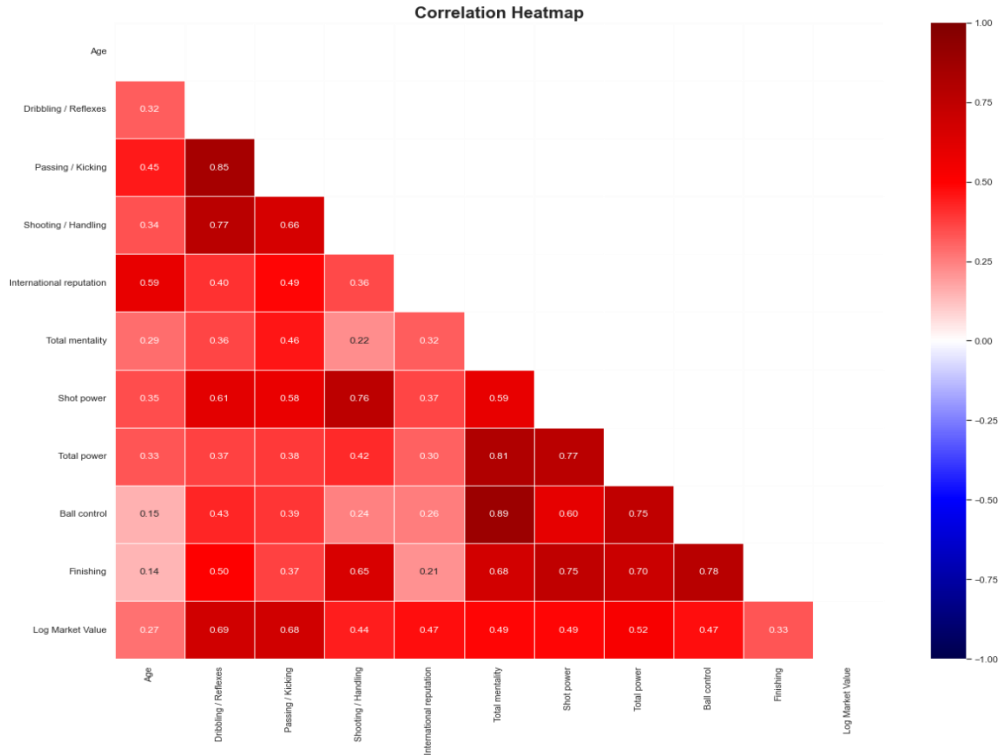


Figure 2: Correlation Heatmap of features

To predict the market value of football players, we employed two machine learning algorithms: Random Forest and Linear Regression. Below, we summarize the performance and findings from these models. We collected a comprehensive dataset containing various player statistics such as goals, assists, minutes played, age, position, and club performance metrics. The model was trained on 80 % of the dataset and validated on the remaining 20 %. We used Mean Absolute Error (MAE) and R-squared (R^2) to evaluate the model's accuracy. We got accuracy which is 69.616% using linear regression. For Random Forest algorithm we got 97% accuracy. So to predict new players price we'll use Random Forest. To see metrics we used Root Mean Square Error (RMSE). We got approximately 0.74 for Linear Regression and 0.21 for Random Forest.

```
results_df
```

	Predicted Market Value (Random Forest)	Predicted Market Value (Linear Regression)	Actual Market Value
841	16.468443	16.162639	16.733281
125	15.214609	15.022926	15.201805
1605	15.128346	15.142020	15.096444
1636	14.025719	13.895791	14.077875
709	16.149766	16.199975	16.012735
...
2561	15.287897	15.368794	15.226498
1684	16.633036	15.603427	16.972511
868	15.854312	15.743486	16.257858
1166	14.317035	13.817534	14.508658
2151	14.995693	15.597140	14.880221

532 rows × 3 columns

Figure 3: Results of prediction models

In this research, we aimed to predict the market value of football players using machine learning algorithms, specifically Random Forest and Linear Regression. By leveraging comprehensive

datasets that included various performance metrics, demographic information, and historical market values, we constructed predictive models that offer significant insights into the factors influencing a player's market worth. Our findings indicate that Random Forest algorithm will predict more accurately. So, to predict new players price we'll use Random Forest. Future work could explore the integration of additional features, such as social media influence or injury history, to further enhance model accuracy and applicability.

References:

[1] S. A. Müller, O. and M. . Weinmann, "Beyond crowd judgments: Data-driven estimation of market value in association football. *European journal of operational research*," ScienceDirect, vol. 8, pp. pp.611–624, 2019.

[2] F. Carmichael, D. Thomas, and R. Ward, "Team performance: The case of english premiership football," *Managerial and Decision Economics*, vol. 21, no. 1, pp. 31–45, 2000.

[3] O. Müller, A. Simons, and M. Weinmann, "Beyond crowd judgments:Data-driven estimation of market value in association football," *European Journal of Operational Research*, vol. 263, no. 2, pp. 611–624, 2017.

[4] A. Seck, M. Javornik, and B. Dukai, "The use of machine learning in football talent identification: A comparative study," *Journal of Sports Analytics*, vol. 5, no. 2, pp. 85–99, 2019.

Development of the information support system for library users

Baiguziyev Ilyas

Faculty of information technology

Scientific Supervisor:

Acting professor of the department of computer science

Lyazzat Boltabayevna Rakhimzhanova

Libraries have long been fundamental to education and research, providing access to vast collections of information. However, with the increasing digitization of knowledge, traditional library support systems face challenges in adapting to evolving user needs. The proposed project aims to develop a modern information support system that integrates emerging technologies to enhance accessibility, personalization, and efficiency for library users.

The goal of this study is to develop an intelligent information support system for libraries that meets user needs by integrating advanced digital technologies. The key aspects of this goal include automation of library processes by optimizing search, book issuance, and returns, as well as managing digital resources using machine learning and artificial intelligence technologies. Personalization of the user experience will be achieved by providing individual recommendations based on users' search history and preferences. Inclusivity and accessibility will be ensured by developing interfaces that cater to users with disabilities, including voice command support and adaptive design. Integration with cloud services will provide fast access to library materials and their secure storage. Support for localization will allow the system to adapt to the linguistic and cultural characteristics of Kazakhstan, including a multilingual interface and specialized features for local users.

The development of such a system is justified by key gaps identified in current research, including the lack of user-centric design, inadequate support for diverse user groups, and limited integration of advanced technologies such as Artificial Intelligence (AI) and machine learning (Sahoo, 2018; Hussain, 2023; Singh & Margam, 2023). Furthermore, most existing solutions are designed for global implementation, failing to address local needs, particularly in regions like Kazakhstan, where language and cultural differences influence user experience (Moon & Han, 2016).

The proposed system will feature a web-based and mobile-friendly interface, allowing users to search for resources, access digital materials, and receive real-time notifications. AI-driven personalization will offer tailored recommendations based on user preferences, while accessibility enhancements will support individuals with disabilities. Additionally, machine learning techniques will be used to optimize search functionalities and automate routine tasks, reducing the workload on library staff (Labadze & Mechaidze, 2023). To ensure scalability and security, cloud-based storage and encrypted authentication mechanisms will be implemented.

One of the key challenges in implementing such a system is ensuring that AI-driven recommendations and automated processes do not compromise the accuracy and reliability of search results. The system must be designed to adapt to user feedback, continuously refining its algorithms to improve search efficiency and the relevance of suggested materials. Another important aspect is ensuring digital inclusion by incorporating multilingual support and intuitive navigation, enabling seamless access for users with different levels of technological proficiency. Additionally, data privacy and security will be critical considerations, requiring strict authentication measures and encryption protocols to protect user information and library assets.

By addressing these limitations, the project aims to transform library support services into an intelligent, user-centered, and inclusive system. The expected outcome is a robust platform that improves resource accessibility, enhances the user experience, and facilitates a more efficient library environment, particularly in the context of Kazakhstan. The system will not only modernize library

operations but also foster a culture of digital literacy, making knowledge more accessible to a broader audience. The findings of this study will contribute to the growing body of research on AI-driven library management and provide a framework for future advancements in digital library systems.

References:

1. Hussain, A. (2023). The role of AI in library automation. *Journal of Digital Library Research*, 15(2), 120-135.
2. Labadze, N., & Mechaidze, G. (2023). AI-driven chatbots in education: Implications for libraries. *International Journal of Library Science*, 10(1), 45-60.
3. Moon, S., & Han, J. (2016). Linked Open Data and smart library models. *Information Systems Journal*, 22(3), 255-270.
4. Sahoo, S. (2018). Library 2.0: Enhancing user engagement through digital platforms. *Library and Information Science Review*, 32(4), 305-320.
5. Singh, R., & Margam, M. (2023). Mobile applications in libraries: A systematic review. *Journal of Library and Information Technology*, 41(1), 78-92.
6. Chen, Y., & Zhang, H. (2022). The impact of cloud computing on digital libraries: A case study. *International Journal of Digital Information Management*, 9(4), 210-225.
7. Smith, T., & Lee, C. (2021). Enhancing library services through blockchain technology. *Library Technology Reports*, 57(3), 34-50.
8. Patel, R., & Gupta, S. (2020). Machine learning applications in modern library systems. *Journal of Emerging Technologies in Library Science*, 8(2), 65-89.

Development of a smart interface with hand gesture recognition elements

Darzhanov Nurlan

Faculty of Information Technology

Scientific supervisor:

Acting professor of the department of computer science

Lyazzat Boltabayevna Rakhimzhanova

In the age of Human-Computer Interaction (HCI), the role of gesture recognition has significantly grown, enhancing both user experience and accessibility. One key application area is assistive technologies for people with hearing impairments, where gestures enable continuous communication and seamless interaction with digital systems. Ensuring accurate interpretation of hand gestures is crucial for an effective human-computer dialogue, making this research particularly relevant for accessibility solutions.

This study aims to develop an intelligent interface capable of recognizing and interpreting hand gestures, forming a predefined vocabulary for individuals with hearing impairments. By integrating machine learning algorithms and computer vision methods, the system is designed for real-time gesture detection, improving both communication and convenience in assistive technologies.

It is hypothesized that leveraging deep learning models trained on diverse datasets will significantly enhance the accuracy of gesture recognition under various lighting conditions and user variations. Additionally, a well-designed smart interface fosters intuitive interaction, ultimately making the technology more inclusive and accessible for users.

The research methodology includes dataset collection, model training, and real-world testing to ensure the gesture recognition system is both reliable and accurate. Currently, the interface is under development, and initial testing results indicate that it effectively interprets gestures and translates them into commands. This demonstrates its potential to enhance human-computer interaction by providing an efficient gesture-based control solution.

Future improvements will focus on expanding the gesture dictionary, optimizing computational efficiency, and increasing both accuracy and versatility. This step in the evolution of intelligent interfaces will contribute to a more adaptive and responsive user experience.

Ultimately, the advancement of gesture recognition technology paves the way for new opportunities in contactless control of digital systems. Continuous refinement will enhance accuracy, processing speed, and usability, making gesture control a more intuitive and effective solution across various HCI scenarios.

References:

1. Mitra, S., & Acharya, T. (2007). Gesture recognition: A survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 37(3), 311-324.
2. Wachs, J. P., Kölsch, M., Stern, H., & Edan, Y. (2011). Vision-based hand-gesture applications. *Communications of the ACM*, 54(2), 60-71.
3. Liang, R.-H., & Ouhyoung, M. (1998). A real-time continuous gesture recognition system for sign language. *Proceedings of the Third IEEE International Conference on Automatic Face and Gesture Recognition*, 558-567.
4. Zafrulla, Z., Brashear, H., Starner, T., Hamilton, H., & Presti, P. (2011). American Sign Language recognition with the Kinect. *Proceedings of the 13th International Conference on Multimodal Interfaces*, 279-286.
5. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

Parallelization of a Monte Carlo Method for Solving Heat Conduction Problems using GPU

Sabyrzhan Yermakhan

Department of Computing and Data Science, Astana IT University

Astana, Kazakhstan, 2025

Email: 231837@astanait.edu.kz

Scientific supervisor: PhD, Associate Professor of KazNU – Imankulov Timur

The Monte Carlo method is often described as a way to solve a problem by using random inputs to produce seemingly random outputs. In essence, it encompasses any approach that utilizes random numbers to tackle a task. Generally, problems addressed by Monte Carlo fall into two categories: those that are probabilistic in nature and those that are deterministic, with the classification stemming from how random processes are used and what outcomes they produce. Importantly, whether the method can be applied to a specific issue does not depend on the system's inherent stochasticity, but rather on the researcher's ability to frame the problem so that random numbers can be employed to generate the solution. This method has been applied for solving differential and integral equations, for finding eigenvalues, for inverting matrices, and for evaluating multiple integrals. It had been known since early last century that probability-sampling (Monte Carlo) techniques could be employed in solving partial differential equations. For example, including heat conduction problems such as steady and transient heat equations for predicting temperatures. Some modified Monte Carlo methods with markov chains serve as an alternative to traditional numerical methods for solving SLAEs (system of linear algebraic equations). Its main advantage lies in its parallelism and capability to handle large-scale systems without sequential processing.

The study discusses solving heat conduction problems using random walk techniques. There are three types of random walk:

1. Fixed Random Walk: when the step size is fixed, pre-assigned and directions of a particle are limited and pre-assigned;
2. Semi Floating Random Walk: when the step size is fixed, but directions of a particle are not limited, moving with all angle is possible;
3. Full Floating Random Walk: when the step size is not pre-assigned, changes at each step and directions of a particle are not limited.

The fixed walk has long computational times and difficulties with complex boundary conditions, but this method is capable of handling the transient problems [1,3]. The fixed random walk is the most frequently used Monte Carlo solution of the heat conduction and Poisson equations. This method is not efficient for finding the field solution of partial differential equations but can be competitive with the traditional methods if only local solutions are needed, that is, the solutions at a single or few points of the domain [1].

In recent times GPUs (Graphics Processing Units) have their own use in different fields of science and engineering [2]. For example, computational fluid dynamics needs the power of parallel computing. Large-scale deep learning models also need the computing power of GPUs. This work discusses the problem in terms of threads needed to parallelize the brownian motions of the particles and analyze obtained results.

Numerical experiments demonstrate that GPU parallelization significantly reduces computation time, for 10,000 walks, achieving speedups of 1582.71 times for the transient heat equation and 2363.65 times for the steady heat equation using fixed random walk, 138.67 times for steady-state on circle boundary conditions using floating random walk compared to CPU-based (Central Processing Units) implementations. These results confirm the efficiency of the GPU-based approach for large-scale problems. The study concludes that this method is a promising solution for high-performance

heat conduction simulations and can be extended to three-dimensional cases and multi-GPU frameworks in future research.

References:

- [1] S. Talebi, K. Gharehbash, H.R. Jalali, “Study on random walk and its application to solution of heat conduction equation by Monte Carlo method” *Progress in Nuclear Energy* 96 (2017) 18e35
- [2] Sanders, J., & Kandrot E. “CUDA by Example: An Introduction to General-Purpose GPU Programming.” Addison-Wesley, 2010.
- [3] Toleubekova E.B. , Abilmazhinov R.K, Imankulov T.S. “Application of Monte Carlo method to solve one-dimensional heat equation.”

Optimization of Deep Neural Network Models for Accurate Brain Tumor Segmentation.

Cherikbayeva Lyailya, Adiya Saurambayeva, Bapiyeva Yelizaveta

Al-Farabi Kazakh National University,

cherikbayeva.lyailya@gmail.com, saurambayeva_adiya@live.kaznu.kz,

bapiyeva_yelizaveta@live.kaznu.kz

Recent advancements in deep learning have significantly improved medical image analysis, enabling more precise segmentation and classification of critical conditions. Acute stroke, for example, requires rapid and accurate diagnosis to optimize patient outcomes. Traditional diagnostic approaches heavily depend on radiologists' manual assessments, which can be time-consuming and susceptible to errors, potentially delaying urgent treatment. Similarly, brain tumors, affecting around 1.5% of the population with a mortality rate of approximately 3%, pose serious health risks due to their prevalence and high fatality rates. Accurate segmentation of brain tumors plays a crucial role in diagnosis, treatment planning, and monitoring disease progression. Image segmentation, a fundamental task in medical imaging, involves identifying and isolating relevant regions within an image to detect abnormalities such as tumors. However, medical image segmentation is particularly challenging due to subtle grayscale variations, complex anatomical structures, and low-contrast boundaries. In computer vision, segmentation is generally categorized into two types: semantic segmentation and instance segmentation. This study focuses on the semantic segmentation of brain tumor images to improve accuracy and enhance edge detection. Advanced algorithms are required to precisely define tumor boundaries, facilitating better clinical decision-making. To address these challenges, this research proposes a hybrid approach that integrates U-Net 2D for accurate segmentation while comparing its performance with other U-Net variations and deep neural networks for reliable classification. The primary objective is to enhance segmentation precision while ensuring robust classification, ultimately assisting medical professionals in making faster and more accurate diagnoses. This approach aims to bridge the gap between precise segmentation and effective classification, thereby improving diagnostic outcomes for brain tumor patients.

This study introduces a novel hybrid deep learning model for brain tumor segmentation and classification, utilizing U-Net 2D for segmentation and an ensemble of deep neural networks for classification. The main goal is to enhance segmentation accuracy and classification reliability, supporting more efficient and precise medical diagnoses. The methodology encompasses several key stages, including data collection and preprocessing, model architecture design, training and optimization, evaluation metrics, and experimental setup.

The initial stage focuses on data collection and preprocessing, essential for ensuring high model accuracy and generalizability. This research leverages publicly available medical image datasets containing annotated brain MRI scans that highlight tumor regions. To expand the training dataset and improve model generalization, various data augmentation techniques are applied, such as rotation, scaling, flipping, random cropping, and zooming. These transformations introduce spatial invariance, making the model more robust to variations in tumor size and shape. Additionally, intensity normalization is performed to standardize pixel values, ensuring uniformity across images acquired from different MRI machines and patients.

U-Net 2D is selected due to its nested skip connections, which enhance feature propagation and localization accuracy. For tumor classification, deep neural networks are employed to differentiate between subtypes, including Glioma, Meningioma, and Pituitary Tumor. To boost classification performance and reliability, predictions from multiple models are combined using a weighted averaging strategy. This ensemble approach leverages the strengths of each network, yielding better results than relying on a single model.

In order to segment brain tumors using MRI scans, this study compared U-Net 2D with U-Net. According to experimental results, U-Net 2D outperformed the regular U-Net in segmentation, achieving an Intersection over Union (IoU) of 0.879. These findings imply that U-Net 2D performs better on this job in terms of feature extraction and spatial representation. To improve segmentation accuracy even further, future studies could investigate dataset extension and hyperparameter modification.

References:

1. B. H. Menze, A. Jakab, S. Bauer, J. Kalpathy-Cramer, K. Farahani, J. Kirby, et al. "The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS)", *IEEE Transactions on Medical Imaging* 34(10), 1993-2024 (2015) DOI: 10.1109/TMI.2014.2377694
2. Ben naceur, M., Saouli, R., Akil, M., & Kachouri, R. (2018). Fully automatic brain tumor segmentation using end-to-end incremental deep neural networks in MRI images. *Computer methods and programs in biomedicine*, 166, 39-49. <https://doi.org/10.1016/j.cmpb.2018.09.007>
3. Chen, H., Qin, Z., Ding, Y., Tian, L., & Qin, Z. (2020). Brain tumor segmentation with deep convolutional symmetric neural network. *Neurocomputing*, 392, 305-313. <https://doi.org/10.1016/j.neucom.2019.01.111>.
4. Cleveland Clinic. (2022). Brain Cancer & Brain Tumor: Symptoms, Causes & Treatments. Cleveland Clinic. <https://my.clevelandclinic.org/health/diseases/6149-brain-cancer-brain-tumor>
5. Ejaz, K., Rahim, M. S. M., Bajwa, U. I., Rana, N., Rehman, A. (2019). An unsupervised learning with feature approach for brain tumor segmentation using magnetic resonance imaging. *Proceedings of 9th International Conference on Bioscience, Biochemistry and Bioinformatics* (pp. 1–7).
6. Saba, T., Mohamed, A. S., El-Affendi, M., Amin, J., & Sharif, M. (2020). Brain tumor detection using fusion of hand crafted and deep learning features. *Cognitive Systems Research*, 59, 221–230.
7. Sajjad, M., Khan, S., Muhammad, K., Wu, W., Ullah, A., & Baik, S. W. (2019). Multi-grade brain tumor classification using deep CNN with extensive data augmentation. *Journal of Computational Science*, 30, 174–182.
8. Seetha, J., & Raja, S. S. (2018). Brain tumor classification using convolutional neural networks. *Biomedical Pharmacology Journal*, 11, 1457–1461.
9. Thaha, M.M., Kumar, K.P.M., Murugan, B.S. et al. Brain Tumor Segmentation Using Convolutional Neural Networks in MRI Images. *J Med Syst* 43, 294 (2019). <https://doi.org/10.1007/s10916-019-1416-0>.

RESEARCH AND ANALYSIS OF MACHINE LEARNING METHODS FOR AUTOMATIC TARGET SHOOTING SCORING

Dana Turganbayeva

Al-Farabi Kazakh National University

leskendan@gmail.com

The integration of artificial intelligence (AI) and machine learning (ML) into sports analytics has revolutionized performance assessment, particularly in precision-based disciplines such as target shooting. This study presents a systematic evaluation of ML techniques for automating the scoring process in shooting competitions. A comparative analysis is conducted between classical image-processing techniques—such as contour detection and Hough Circle Transform—and deep-learning-based object detection models, including YOLOv5. The experimental findings demonstrate that deep learning significantly enhances accuracy, achieving an average precision (AP) of 92.3%, outperforming traditional approaches. The study underscores the potential of ML-driven scoring systems in ensuring fairness, consistency, and efficiency in competitive shooting sports.

In shooting sports, precise and unbiased scoring is crucial to maintaining the integrity of competitions. Conventional scoring systems rely on manual evaluation, which is inherently prone to human error and subjectivity. Recent advancements in ML and computer vision have paved the way for automated scoring solutions, leveraging advanced object detection techniques to accurately detect bullet holes, classify shot placements, and assign scores in real time. This research investigates the effectiveness of various ML methodologies in automatic target shooting scoring, aiming to develop a robust and scalable solution that enhances accuracy and efficiency.

A dataset consisting of annotated shooting target images was utilized for model training and evaluation. The following methodologies were applied:

- Contour Detection: Extracts bullet hole boundaries using OpenCV's `findContours` method, serving as a baseline image-processing technique.
- Hough Circle Transform: Identifies circular patterns corresponding to bullet holes, improving localization accuracy.
- YOLOv5 Object Detection: Implements a state-of-the-art deep-learning model to detect bullet holes in real time with high precision.
- ORB Feature Matching: Utilizes keypoint extraction and descriptor matching to enhance trajectory analysis and shot tracking.
- Shape Approximation: Applies the `approxPolyDP` function to refine object contours, improving the precision of bullet hole localization.

The proposed methodologies were evaluated based on detection accuracy, computational efficiency, and robustness under varying conditions. Key findings include:

- The YOLOv5 model achieved an average precision (AP) of 92.3%, significantly surpassing contour detection (78.5%) and Hough Transform-based methods (84.1%).
- ORB feature matching enhanced shot tracking reliability, reducing false detections and misclassification errors.
- The ML-based framework demonstrated real-time applicability with minimal latency, making it suitable for integration into live competition scoring systems.

These findings highlight the advantages of deep-learning-based approaches over traditional methods, reinforcing their potential to enhance scoring accuracy and consistency.

This study demonstrates the superiority of ML-driven scoring systems in shooting sports, significantly reducing human intervention and improving assessment precision. The integration of deep-learning models, such as YOLOv5, offers a robust and scalable solution for real-time scoring

applications. Future research will focus on expanding the dataset to encompass diverse shooting conditions, optimizing the model for edge computing environments, and integrating the system into embedded devices for real-time deployment at shooting ranges and sports competitions.

References:

1. Jocher, G., et al. (2020). "YOLOv5: A Fast, Accurate Object Detection Model." GitHub Repository.
2. Bradski, G., & Kaehler, A. (2008). *Learning OpenCV: Computer Vision with the OpenCV Library*. O'Reilly Media, Inc.
3. Hough, P. V. C. (1962). "Method and Means for Recognizing Complex Patterns." *US Patent 3,069,654*.
4. Rublee, E., et al. (2011). "ORB: An Efficient Alternative to SIFT or SURF." *Proceedings of ICCV*, 2564-2571.
5. "Shooting Target Dataset." Roboflow Universe.

Development of a software package processing of oil sludge in order to minimize the harmful effects of oil waste on environment

Xu Yuying

Master's student of Al-Farabi Kazakh National University

Email: xunolga@gmail.com

Gulnar Balakayeva,

Al-Farabi Kazakh National University, Professor

Oil sludge is a byproduct after oil refining. Its thick, toxic nature has a great harmful impact on the environment. After crude oil extraction, the remaining oil is heated or treated with hydrogen to improve its quality. Effective separation and purification at this stage are essential to reducing pollution. This research explores methods to optimize these processes and reduce waste generation.[1]

We use the convection-diffusion equation to model how sludge moves. It helps predict changes in temperature and concentration. Reynolds and Peclet numbers show how the sludge flows. It helps us understand the changes in temperature and concentration. We use implicit differentiation to calculate the temperature, and we set the condition so that the result is stable. As for concentration, we use explicit differentiation to simplify the equations. We also set boundary conditions to make sure the results make sense. Stability checks help confirm the data is correct.[2]

We develop the software to improve oil sludge separation. It controls viscosity, pipe length, and flow speed. The software adjusts these settings in real time and tracks temperature and concentration. By improving the separation process, we hope to lower pollution and make sludge treatment cleaner.

Our software makes sludge treatment faster and reduces pollution risks. It tracks key factors all the time, helping improve the process. The backend runs on Flask. NumPy does the calculations, and Plotly makes graphs to show temperature and concentration changes. The interface is built with HTML and Jinja2, showing live data from the Flask server. Users enter values in an HTML form, which sends data through a POST request. Plotly.js creates interactive charts, and JavaScript updates results in real time. Event listeners make the system smooth and easy to use. This software is a helpful tool for us to minimize the harmful effects of oil waste on environment.[3]

It makes oil sludge treatment easier, because it controls key factors and tracks changes in real time. It keeps the process stable and reduces pollution. The system is simple and gives clear results. It can help us a lot to minimize the harmful effects of oil waste on environment. It is a step toward better environmental protection.

References:

[1]Zubaidy, E. A. H., & Abouelnasr, D. M. (2010). Fuel recovery from waste oily sludge using solvent extraction. *Process Safety and Environmental Protection*, 88(5), 318-326.

[2]Ubani, O., & Atagana, H. I. (2024). Biotreatment of crude oil waste sludge using a novel bacterial formula. *Environmental Challenges*, 15, 100943.

[3]Balakayeva, G., Kalmenova, G., Darkenbayev, D., & Phillips, C. (2023). Development of an application for the thermal processing of oil slime in the industrial oil and gas sector. *Process Safety and Environmental Protection*, 170, 245-256.

Нейрондық желі көмегімен ЭЭГ сигналдар арқылы ми белсенділігін класстарға жіктеу

Абдрахман А.М.

ал-Фараби атындағы Қазақ ұлттық университетінің 4 курс студенті

E-mail: ansaransa0420@gmail.com

Кабдрахова С.С.

ал-Фараби атындағы Қазақ ұлттық университетінің ф.-м.ғ.к., аға оқытушы

Электрэнцефалографиялық (EEG) сигналды талдау ми қызметін зерттеу үшін кеңінен қолданылады, соның ішінде ауруды диагностикалау, когнитивті бақылау және ми-компьютер интерфейсін дамыту. Дегенмен, EEG сигналдарын талдауда жоғары білікті мамандар және айтарлықтай уақыт қажет. Сигналдарды өңдеу кезінде классикалық әдістер әрқашан деректердегі күрделі заңдылықтарын тиімді аша бермейді. Нейрондық желі модельдерін пайдалануда мидың әртүрлі күйлерінің дәл және жылдам жіктелуін қамтамасыз етеді. Сондай-ақ, талдау процесін автоматтандыруға мүмкіндік береді. Бұл жұмыстың мақсаты ЭЭГ сигналдары негізінде ми қызметін жіктеу үшін нейрондық желі моделін жасай отырып: медицинада, нейроинтерфейстерде және когнитивті зерттеулерде қолдануды таба алу.

Зерттеуде PhysioNet және BCI Competition сияқты ашық деректер жиынынан, сондай-ақ көп арналы EEG сенсорларымен жасалған эксперименттік жазбалардан алынған ЭЭГ деректері пайдаланылды. Деректер төменгі және жоғары жиілікті шуды сүзгілеу, артефакттарды жою (мысалы, миографиялық шу және көз қозғалысы) және амплитуданы қалыпқа келтіруді қамтитын алдын ала өңдеу қадамдарынан өтті. Функцияларды алу үшін толқындық түрлендіруді және спектрлік ыдырауды қоса алғанда, уақыт пен жиілікті талдау әдістері қолданылды.

Уақытша тәуелділіктерді талдау үшін сигналдардың кеңістіктік сипаттамаларын және қайталанатын желілерді (LSTM, GRU) автоматты түрде алу үшін нейрондық желі моделінің архитектурасы ретінде конволюционды нейрондық желілер (CNN) таңдалды. Жаттығу категориялық кросс-энтропия жоғалту функциясын және Adam оптимизаторын қолдану арқылы орындалды. Сапаны бағалау метрикасы ретінде дәлдік, F1-балл, Дәлдік, Еске түсіру, сонымен қатар екілік классификация сапасын бағалау үшін AUC-ROC пайдаланылды.

Модель 80% оқу үлгісі мен 20% сынақ үлгісінің пропорциясына бөлінген таңбаланған EEG деректері бойынша оқытылды. Жиырылу ядросының өлшемі, жасырын қабаттардағы нейрондар саны және оқу жылдамдығы сияқты гиперпараметрлер Grid Search және Bayesian Optimization алгоритмдері арқылы таңдалды. Шамадан тыс орнатудың алдын алу үшін Dropout және Batch Normalization әдістері қолданылды.

Эксперименттік нәтижелер ұсынылған нейрондық желі моделі 62% жіктеу дәлдігіне қол жеткізетінін көрсетті, бұл сызықтық дискриминанттық талдау (LDA) және тірек векторлық машиналар (SVM) сияқты дәстүрлі EEG өңдеу әдістерінен жоғары. Жіктеу қателерінің сызбасы үлгінің А және В күйлерін тануда ең тиімді екенін көрсетеді, бірақ сигнал үлгілерінің ұқсастығына байланысты С сыныбында қиындықтар бар. Модельді одан әрі оңтайландыру, оқу деректер жинағын кеңейту және гибриді архитектураларды пайдалану жіктеу дәлдігін жақсартып алады және әдісті ми белсенділігін талдаудың нақты мәселелеріне көбірек қолдана алады.

Қорытындылай келе, бұл жұмыста ЭЭГ сигналдары негізінде ми қызметін жіктеуге арналған нейрондық желі моделі әзірленген. Жүргізілген эксперименттер конволюционды және қайталанатын нейрондық желілерді пайдалану дәстүрлі ЭЭГ талдау әдістерінен асып түсетін жоғары классификация дәлдігіне қол жеткізуге мүмкіндік беретінін көрсетті. Әзірленген модель сигналды өңдеу процесін автоматтандырады, деректерді

интерпретациялауда субъективті факторлардың әсерін азайтады және медицинада, нейроинтерфейстерде және когнитивті зерттеулерде қолданылуы мүмкін. Болашақ жоспарларға нейрондық желі архитектурасын оңтайландыру, оқу деректер жинағын кеңейту және нәтижелердің интерпретациялануын жақсарту үшін түсіндірілетін AI әдістерін зерттеу кіреді.

Пайдаланылған әдебиеттер тізімі:

1. О. В. Комисарук, Е. В. Никульчев, С. Б. Малых, "Разработка нейросетевой модели выявления артефактов в электроэнцефалограмме мозга," *Cloud of Science*, т. 7, № 3, с. 631–641, 2020.
2. С. А. Фоменков, Е. Ю. Попов, "Детектирование событий движения руки в сигналах ЭЭГ головного мозга с помощью сверточных нейронных сетей," *Научная статья*, 2015–2016.
3. И. А. Шанин, С. А. Ступников, "Методы анализа данных электроэнцефалографии с применением сверточных и рекуррентных нейронных сетей," *Системы и средства информатики*, т. 31, № 2, с. 36–46, 2021.
4. В. Фадел, "Нейросетевые алгоритмы распознавания эмоций на основе сигналов ЭЭГ," выпускная квалификационная работа магистранта, науч. рук. В. Г. Спицын, Национальный исследовательский Томский политехнический университет, 2023.
5. V. Schetinin, J. Schult, "Learning Polynomial Networks for Classification of Clinical Electroencephalograms," *arXiv preprint*, 2005.

Classification of spinal disease severity using MRI images based on neural networks

Akjan Yerkin

Kazakh-British Technical University

Ak_yerkin@kbtu.kz

Kabdrakhova Symbat Seisenbekovna

Al-Farabi Kazakh National University, PhD, associate professor

Deep learning has emerged as a powerful tool in medical imaging, demonstrating significant potential in the detection and classification of degenerative spinal diseases. Diagnosing these conditions from MRI scans requires the expertise of professional radiologists who must carefully analyze each scan, a process that demands years of experience and specialized training. However, this manual interpretation is both time-consuming and labor-intensive, often leading to delays in diagnosis and treatment. Additionally, inter-radiologist variability poses a challenge, as different radiologists may have subjective interpretations regarding the presence, severity, or classification of a disease. This inconsistency can impact treatment decisions and patient outcomes.

AI-driven automatic classification models offer a promising solution by standardizing the diagnostic process, reducing inter-observer variability, and alleviating the workload of radiologists. These models can process large volumes of MRI scans efficiently, providing consistent and accurate assessments while enabling faster diagnosis. The goal of this research is to develop a robust deep learning model capable of classifying lumbar spine diseases from MRI scans in DICOM format, utilizing multiple degenerative disease annotations to enhance diagnostic precision and reliability.

Deep learning has significantly advanced spinal disease classification from MRI scans. Study by [1] developed a CNN-based model for detecting stenotic conditions in the lumbar spine, achieving high diagnostic accuracy [1] [2] validated SpineNet, demonstrating that deep learning models can match radiologists in grading lumbar disc degeneration [2].

While earlier methods relied on handcrafted features and traditional classifiers, CNN architectures like EfficientNet have enhanced feature extraction and classification. Studies on Pfirrmann grading further show the benefits of deep learning in assessing disc degeneration. However, challenges remain, including missing data, noise, and class imbalance, necessitating further research on data augmentation and model optimization.

Dataset.

In this study, a publicly available dataset from a Kaggle competition was utilized. The dataset comprises MRI images stored in DICOM format, which is a common format for storing medical images and its metadata, accompanied by CSV files containing information on the type of spinal disease present in the image file, label coordinates and severity levels. Figure 1 illustrates visualization of the sample DICOM image slices and its labels.

To prepare the data for deep learning, several pre-processing steps are undertaken. First, the DICOM files are read and filtered, with image data extracted and annotated coordinates overlaid to highlight conditions such as "Spinal Canal Stenosis," allowing for better visualization and interpretation. To ensure consistency in input dimensions, each image is resized to a fixed resolution of 224×224 pixels and converted from grayscale to RGB format.




Figure 1. Visualization of the sample images from the dataset with disease class and keypoints labels.

To enhance model generalizability, data augmentation techniques are applied to the training dataset, including random horizontal flips, rotations, and brightness adjustments. The dataset is then structured using a melt operation on the training CSV file, effectively separating different conditions and their corresponding severity labels. A stratified train-test split is performed to maintain a balanced representation of severity classes, ensuring that the model is trained on a diverse set of cases. Additionally, label encoding is implemented to convert categorical severity labels into numerical values, making them suitable for deep learning algorithms. These pre-processing steps collectively optimize the dataset for robust and accurate classification of lumbar spine diseases.

Model Architecture and Training:

The classification model is built upon EfficientNet-B3 [3], a deep learning architecture known for its strong feature extraction capabilities and computational efficiency, making it well-suited for medical image classification tasks. In this study, we utilized pre-trained weights from the EfficientNet-B3 model, which was originally trained on the large-scale ImageNet dataset[4]. By applying transfer learning, we fine-tuned the model for classifying lumbar spine diseases, replacing the fully connected layer to output three distinct classes—Normal/Mild, Moderate, and Severe—corresponding to different levels of degenerative spinal conditions. To optimize training, Cross-Entropy Loss is used as the objective function, ensuring effective multi-class classification. The AdamW optimizer is employed with an initial learning rate of $1e-4$, providing adaptive learning rate adjustments while mitigating weight decay issues. Additionally, a learning rate scheduler is integrated to reduce the learning rate when the validation loss plateaus, helping the model converge more effectively.

A custom PyTorch Dataset class is implemented to manage the loading of MRI images and their corresponding labels directly from disk. Data loaders are configured to efficiently batch and feed images into the network during training, ensuring a streamlined and optimized training pipeline. These architectural and training strategies contribute to the development of a robust and efficient model for automatic classification of lumbar spine diseases.

The training process was executed for 10 epochs, and the performance was evaluated using accuracy and weighted F1 score on the validation set.

The experimental results demonstrate the effectiveness of the proposed model in classifying lumbar spine diseases. The model achieved a validation accuracy of 0.7736, reflecting its ability to generalize to unseen data. Additionally, the F1 score, which considers both precision and recall, reached approximately 0.67 during the best-performing epochs, indicating a balanced performance across the three severity classes. While these results are promising, there is room for improvement. Potential enhancements include more robust data cleaning processes to ensure consistency in annotations, the application of additional regularization techniques to prevent overfitting, and experimenting with different augmentation strategies to improve model robustness.

This thesis demonstrates the feasibility of using deep learning for the automated classification of lumbar spine degenerative conditions from MRI data. By leveraging transfer learning with EfficientNet-B3 and a comprehensive pre-processing pipeline, the model achieved encouraging results. Continued research is essential to address the challenges identified and to ultimately develop a tool that can aid radiologists in clinical decision-making.

References:

1. J. Hallinan et al., ‘Deep Learning Model for Automated Detection and Classification of Central Canal, Lateral Recess, and Neural Foraminal Stenosis at Lumbar Spine MRI’, *Radiology*, p. 204289, May 2021.
2. T. McSweeney et al., ‘External Validation of SpineNet, an Open-Source Deep Learning Model for Grading Lumbar Disk Degeneration MRI Features, Using the Northern Finland Birth Cohort 1966’, *Spine*, vol. 48, pp. 484–491, Dec. 2022.
3. M. Tan and Q. Le, ‘EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks’, *ArXiv*, vol. abs/1905.11946, May 2019.
4. J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, ‘ImageNet: A large-scale hierarchical image database’, 2009 IEEE Conference on Computer Vision and Pattern Recognition, pp. 248–255, Jun. 2009.

AI-DRIVEN OPTIMIZATION OF SATELLITE RESCUE SYSTEMS FOR EFFICIENT EMERGENCY SIGNAL TRANSMISSION IN REMOTE MOUNTAIN AREAS

Abiirbek Kuanysh

*Scientific supervisor: Matkerim Bazargul,
Senior lecturer of Department of Computer Science
Al-Farabi Kazakh National University
abiirbek.kuanysh@live.kaznu.kz*

The increasing need for efficient satellite rescue systems in remote mountain areas has driven research into optimizing emergency signal transmission [1] and prioritization. Limited communication infrastructure and challenging environmental conditions often hinder effective rescue operations [2]. This research aims to develop an optimized communication protocol that enhances emergency response efficiency by reducing data transmission latency and ensuring the prioritization of critical signals [3].

The study involves designing and implementing algorithms that allocate bandwidth effectively, ensuring high-priority distress signals are transmitted with minimal delay [4]. By leveraging heuristic optimization methods and machine learning models, the research seeks to improve the performance of satellite-based communication in extreme conditions [5]. Simulation environments such as PX4 [6], Gazebo [7], and NS-3 are used to test various configurations and measure the effectiveness of proposed solutions.

A major challenge in remote satellite communication is the trade-off between bandwidth limitations and the need for real-time transmission [1]. To address this, techniques such as data compression, adaptive signal modulation, and AI-driven prioritization strategies are explored [2]. The research also examines the feasibility of integrating LoRaWAN and MQTT protocols [3] to enhance message delivery reliability under constrained network conditions. Security and robustness are critical in emergency communication networks [4]. The proposed system incorporates encryption techniques to protect data integrity while ensuring scalability for large-scale deployment [5]. Additionally, cloud-based infrastructure and edge computing are considered to improve real-time processing and reduce dependency on centralized networks [6].

The implementation of an optimized satellite rescue system has significant implications for emergency response in remote areas [7]. By reducing signal latency and ensuring efficient bandwidth utilization, the proposed approach enhances the effectiveness of rescue operations [1]. The research findings can be adapted to various scenarios, including disaster response, wilderness search and rescue, and maritime emergencies [2].

This study contributes to the advancement of satellite communication technologies [3], bridging the gap between AI-driven optimization and real-world emergency applications [4]. As technology progresses, intelligent prioritization and efficient signal transmission in satellite networks will play a crucial role in improving global emergency response systems [5].

References:

- [1] Yang, B., Yang, E., Yu, L., & Niu, C. (2022). Adaptive Extended Kalman Filter-Based Fusion Approach for High-Precision UAV Positioning in Extremely Confined Environments. *IEEE/ASME Transactions on Mechatronics*.
DOI: 10.1109/TMECH.2022.3203875
- [2] Yang, B., Yang, E., Yu, L., & Loeliger, A. (2022). High-Precision UWB-Based Localisation for UAV in Extremely Confined Environments. *IEEE Sensors Journal*, 22(1).
DOI: 10.1109/JSEN.2021.3130724

[3] Mazhar, F., Khan, M. G., & Sällberg, B. (2017). Precise Indoor Positioning Using UWB: A Review of Methods, Algorithms and Implementations. *Wireless Personal Communications*, 97, 4467–4491.

DOI: 10.1007/s11277-017-4734-x

[4] Alarifi, A., Al-Salman, A., Alsaleh, M., Alnafessah, A., Al-Hadhrami, S., Al-Ammar, M. A., & Al-Khalifa, H. S. (2016). Ultra Wideband Indoor Positioning Technologies: Analysis and Recent Advances. *Sensors*, 16(5), 707.

DOI: 10.3390/s16050707

[5] Pérez, M. C., Gualda, D., de Vicente, J., Villadangos, J. M., & Ureña, J. (2019). Review of UAV Positioning in Indoor Environments and New Proposal Based on US Measurements. Conference Paper from IPIN 2019.

[6] Yang, B., & Yang, E. (2021). A Survey on Radio Frequency-Based Precise Localisation Technology for UAV in GPS-Denied Environment. *Journal of Intelligent & Robotic Systems*, 103(38).

DOI: 10.1007/s10846-021-01500-4

[7] Yang, B., Yang, E., Yu, L., & Niu, C. (2023). Ultrasonic and IMU-Based High Precision UAV Localisation for the Low-Cost Autonomous Inspection in Oil and Gas Pressure Vessels. *IEEE Transactions on Industrial Informatics*.

DOI: 10.1109/TII.2023.3240874

STUDY OF METHODS OF MINIMIZING DELAYS AND DEVELOPING A DATABASE MONITORING SYSTEM IN MICROSERVICE APPLICATIONS

Esengeldiev Dinmukhamed

*Scientific supervisor: Turganbaeva Alma,
Senior Lecturer of the Department of Computer Science
Al-Farabi Kazakh National University
d.esengeldiev@mail.ru*

Microservice architecture has become one of the key approaches to building high-load and scalable systems, allowing applications to be developed from independent services. However, the distributed nature of microservices creates a number of challenges associated with high request latency and the need to ensure a stable level of performance, especially when accessing the database. Therefore, research into methods for minimizing latency and developing an effective database monitoring system are important steps in increasing fault tolerance and optimizing microservice applications.

In this paper, various strategies for reducing delays in interservice interaction and database access were considered, and modern tools for monitoring metrics (load, response time, connection status, etc.) were analyzed. A concept of a modular monitoring system was proposed that allows real-time detection of bottlenecks, recording anomalies, and automatic scaling of resources. The developed system is based on the principles of asynchronous interaction and uses distributed tracing and logging mechanisms for detailed analysis of the operation of each microservice and the overall state of the application.

The limitations of network channel bandwidth and DBMS performance, as well as possible collisions with a large number of parallel transactions, are taken into account. To correctly manage the load and maintain a low level of delays, a notification system has been implemented that allows for a prompt response to an increase in latency indicators or a decrease in the availability of individual services. The effectiveness of the proposed approach is confirmed by experimental results of test deployments and load modeling, which demonstrate a decrease in the average response time and an increase in the stability of the application.

References:

1. Newman, S. (2015). Building Microservices. O'Reilly Media.
2. Fowler, M. (2019). Microservices Patterns: With examples in Java. Addison-Wesley.
3. Richardson, C. (2018). Microservices Patterns. Manning Publications.
4. Burns, B., Beda, J., & Hightower, K. (2017). Kubernetes: Up and Running. O'Reilly Media.
5. Banon, S., & Gormley, C. (2016). Elasticsearch: The Definitive Guide. O'Reilly Media.

Developing Deep Neural Networks to Solve the Thermal Conductivity Problem

Issadil Narkyz

Al-Farabi Kazakh National University, Department of Computer Science

Almaty, Kazakhstan, 2025

Email: narkyz03@gmail.com

Scientific supervisor: Kenzhebek Yerzhan, Senior Lecturer

Deep neural networks (DNNs) provide an efficient approach to solving the thermal conductivity problem by directly incorporating fundamental physics laws. Traditional numerical methods, such as finite difference and finite element methods, require high computational costs and are dependent on the grid of the domain, whereas methods based on deep learning provide an alternative with reduced computational expense. Instead of being dependent on labeled data, this approach ensures physically accurate solutions by enforcing initial and boundary conditions during training to approximate solutions efficiently[1].

A fully connected neural network is designed for partial differential equation (PDE) approximation, where the input layer represents spatial coordinates and boundary conditions, and the output layer predicts temperature distribution. Hidden layers used ReLU and Tanh activation functions to capture nonlinear heat distribution patterns. To ensure that the model follows the physical rules, training is guided by loss function that enforces the thermal conductivity equation and minimizes departures from reference solutions [2]. Key hyperparameters include learning rate, batch size, and weight initialization. A combination of Adam and L-BFGS optimizers ensures efficient convergence. The number of neurons per layer and the depth of the network are varied during experimentation. Additionally, the dataset consists domain points sampled at various grid resolutions to assess their impact on generalization.

The model achieves high accuracy, outperforming traditional PDE-solving methods. Sensitivity analysis reveals that increasing domain points improves accuracy but leads to higher computational costs, while deeper networks enhance performance up to a threshold before overfitting occurs [3]. Experiments with varying domain point densities were tested on models with Adam, SGD, and combination of Adam and L-BFGS. Results indicate that combination of Adam and L-BFGS achieves the best balance between convergence speed and accuracy, while SGD struggles with denser domain points but performs well with sparse sampling. A balance between computational efficiency and prediction accuracy is achieved by optimizing network depth, domain discretization, and optimizer selection.

This approach has potential applications in scientific and industrial simulations, including materials science, energy management, and thermal system design. By reducing computational costs and eliminating meshing, deep learning-based methods enhance real-time simulations. Future work involves extending the model to more complex thermal systems and integrating physics-informed neural networks for improved accuracy and interpretability.

References:

- [1] “(PDF) Physics-Informed Neural Networks (PINNs) for Heat Transfer Problems,” *ResearchGate*, Oct. 2024, doi: 10.1115/1.4050542.
- [2] Y. Khoo, J. Lu, and L. Ying, “Solving parametric PDE problems with artificial neural networks,” *Eur. J. Appl. Math*, vol. 32, no. 3, pp. 421–435, Jun. 2021, doi: 10.1017/S0956792520000182.
- [3] Z. Hao *et al.*, “Physics-Informed Machine Learning: A Survey on Problems, Methods and Applications,” Mar. 07, 2023, *arXiv*: arXiv:2211.08064. doi: 10.48550/arXiv.2211.08064.

OPTIMIZING BIG DATA PROCESSING IN JAVA USING THREADS AND PARALLEL COMPUTING

Рахим Азамат Мағанатұлы
Университет КИМЭП
Azamat.rakhim@kimep.kz

Modern applications increasingly need to handle massive amounts of data. Traditional single-threaded processing can't fully take advantage of today's multi-core processors, which can create performance bottlenecks. To solve this, Java offers powerful tools like the Streams API, Fork/Join Framework, ExecutorService, and CompletableFuture. These features help developers implement parallel and asynchronous processing efficiently, making applications faster and more responsive.

This paper explores main approaches for parallel computing in Java, showing best practices and real-world applications where multi-threading can significantly improve performance.

Big data processing is major component of modern software systems, especially in fields for example, finance, healthcare, e-commerce, and artificial intelligence. There are some areas where parallel computing in Java is highly beneficial:

1. Data analytics and machine learning. Processing big data can increase the learning speed of models and extracting insights.
2. High-performance web applications. Web servers must handle multiple requests at the same time, requiring efficient multi-threading for responsiveness.
3. Financial systems. Real-time fraud detection, risk analysis and many others depend on processing vast amounts of parallel data transaction.
4. Log analysis and monitoring. Systems that work and analyze large logs from multiple sources benefit from multi-threading.
5. Scientific computing. Various simulations, weather forecasting, intensive numerical computations are best handled with parallel processing.

There are key approaches to multi-threaded data processing in Java. For example:

1. Using Streams API for parallel collection processing. Java 8's Streams API introduced an elegant way to process large datasets in parallel. When working with huge collections, using `parallelStream()` allows Java to divide the work between available CPU cores. Code example:

```
import java.util.List;  
import java.util.stream.IntStream;  
public class ParallelStreamExample {  
public static void main(String[] args) {  
List<Integer> numbers = IntStream.range(1, 1_000_000).boxed().toList();  
long evenCount = numbers.parallelStream().filter(n -> n % 2 == 0).count();  
System.out.println("Even numbers count: " + evenCount);
```

This approach is useful when working with large datasets in collections, but may introduce overhead when used on small data because of thread management costs.

2. Fork/Join framework for recursive data processing. It breaks down complex computations into smaller tasks, dividing them between threads dynamically. (Code).

This method is especially useful for recursive operations, such as sorting, searching, and large numerical computations.

3. Using ExecutorService for task execution. This can be used to manage multiple simultaneous tasks efficiently. It allows defining thread pools to distribute workload among fixed number of threads. (Code).

By using thread pool, `ExecutorService` avoids creating and destroying threads over and over again, making it appropriate for applications with predictable workloads.

4. Asynchronous processing with `CompletableFuture`. When a task does not need to block main thread, `CompletableFuture` allows tasks to chain together asynchronously.

Parallel computing is a great way to boost performance, but if not handled correctly, it can cause inefficiencies and unexpected issues. To get the best results, it's important to choose the right level of parallelism. For example, the number of threads should match the available CPU cores to avoid excessive context switching, which slows things down. Using thread-safe collections like `ConcurrentMap` or atomic variables (`AtomicInteger`) helps prevent conflicts when multiple threads access shared data. Another useful approach is work-stealing, which is used in Java's Fork/Join Framework. This technique ensures that all CPU cores stay busy by dynamically redistributing tasks among threads.

Java continues to evolve with advancements in parallel computing. One of the biggest innovations is Project Loom, which introduces virtual threads. These lightweight threads make handling concurrency much easier, reducing complexity in large-scale applications. Additionally, more computing tasks are being offloaded to GPUs and cloud-based environments, allowing developers to take advantage of different hardware for better performance. AI-driven thread optimization is also gaining traction, enabling applications to adjust their parallel processing strategies automatically based on workload demands. As technology advances, developers who keep up with these changes will be able to create even faster and more scalable applications.

Parallel computing in Java is a powerful tool for handling large amounts of data efficiently. With features like the Streams API, Fork/Join Framework, `ExecutorService`, and `CompletableFuture`, developers can fully utilize modern multi-core processors. However, getting the best performance requires careful planning—deciding how to manage threads, ensuring proper synchronization, and balancing workloads effectively. When used correctly, parallel computing can significantly speed up applications, making it an essential technique in fields like high-performance computing, data analysis, machine learning, and real-time systems.

Терең оқыту тәсілдерін пайдалана отырып, ауаның ластануын болжау

Нұрланова Қ.

Әл-Фараби атындағы Қазақ Ұлттық университеті

Ауаның ластануы – әлемдегі ең өзекті экологиялық мәселелердің бірі. Оның әсері адамдардың денсаулығының нашарлауына және қоршаған орта жағдайларының бұзылуына алып келеді. Үлкен қалалардағы өнеркәсіп орындары, жылыту станциялары мен көлік қозғалысының жоғары деңгейіне байланысты ауа сапасы айтарлықтай нашарлайды. Әсіресе, биік ғимараттар шоғырланған мегаполистерде ауа айналымының шектеулі болуына байланысты зиянды заттардың жиналуы артады.

Қазіргі таңда ауа сапасын бақылау негізінен стационарлық өлшеу станциялары арқылы жүргізіледі. Алайда, ауа ластану деңгейінің өзгеруін алдын ала болжауда бұл әдістердің тиімділігі төмен болуы мүмкін.

Бұл мәселені шешу үшін осы жұмыста физикаға негізделген нейрондық желілер (PINN) әдісі қолданылады. Бұл әдіс сандық модельдеу мен машиналық оқытуды біріктіріп, ауа ластануының өзгеруін тек деректер негізінде емес, сонымен қатар физикалық заңдар негізінде дәл болжауға мүмкіндік береді.

Бұл зерттеуде ауаның ластануын болжау үшін сандық модельдеу мен терең оқыту әдістерін үйлестіретін кешенді тәсіл қолданылады. Бірінші кезеңде терең оқытуды пайдаланып ауа сапасын болжауға арналған қолданыстағы әдістерге талдау жасалды. Қалалық каньондағы ауа қозғалысын дәлірек сипаттау үшін тесттік тапсырма ретінде екіөлшемді кеңістіктегі қозғалмалы қақпақпен басқарылатын қораптағы ағынды модельдеу жүзеге асырылды және модельдеуге арналған бастапқы және шекаралық шарттарды әзірленді. Ауа ағындарын модельдеу үшін Пуассон теңдеулерін шешуге негізделген сандық модельдеу әдісі қолданылды.

Зерттеудің негізгі бөлігі – ластанушы заттардың концентрациясын болжау үшін PINN әдісін қолдану. Ол Пуассон теңдеуіне негізделген и жылдамдықты болжау үшін қолданылады. Нейрондық желі кіріс деректерін (x, y) қабылдайды және бірнеше жасырын қабаттар арқылы жылдамдықтың жуықталған мәнін u_0 есептейді. Кейін қателіктер функциясын қалыптастыру үшін автоматты дифференциалдау көмегімен шығыс мәнінің жеке туындылары есептеледі, және желіні оңтайландыру жүзеге асырылады. Осылайша, бұл әдіс дәстүрлі дифференциалдық теңдеулер мен терең оқыту мүмкіндіктерін біріктіріп, модельді үйрету барысында физикалық заңдылықтарды ескеруге мүмкіндік береді.

Соңғы кезеңде алынған модельдердің дәлдігі бағаланып, болжанған мәндер нақты өлшемдермен салыстырылады. Осындай кешенді әдіс ауаның ластануын неғұрлым дәл болжауға мүмкіндік беріп, қала экологиясын жақсарту бойынша тиімді шешімдерді ұсынуға жол ашады.

Бұл зерттеуден алынған нәтижелер қалалық инфрақұрылымның ауа сапасына әсерін бағалауға және болжау моделінің тиімділігін арттыруға мүмкіндік береді.

Жылу өткізгіштік теңдеуін шектеулі айырым әдістерімен GPU архитектураларында параллельді тиімді жүзеге асыру

Сүйеубек Ербол

Әл-Фараби атындағы Қазақ Ұлттық университеті

Жылу өткізгіштік теңдеуі – жылу энергиясының кеңістікте таралуын сипаттайтын негізгі математикалық модельдердің бірі. Бұл теңдеу физика, инженерия, материалтану және сандық есептеулерде кеңінен қолданылады. Жылу теңдеулерін шешу көптеген инженерлік және ғылыми есептеулерде маңызды рөл атқарады, себебі ол материалдардың жылулық қасиеттерін болжауға және әртүрлі жүйелердің тұрақтылығын зерттеуге мүмкіндік береді. Біздің зерттеуіміз 1D жылу өткізгіштік теңдеуін сандық әдістер арқылы шешу және оны MPI мен CUDA технологиялары арқылы параллельдендіру мәселесін қарастырады.

Зерттеудің мақсаты мен міндеттері

Бұл зерттеудің негізгі мақсаты – жылу теңдеуін сандық модельдеу арқылы шешіп, параллель есептеу әдістерін қолдану арқылы өнімділікті арттыру. Осы мақсатқа жету үшін келесі міндеттер қойылды:

1. Сандық әдістерді қолдана отырып, 1D жылу өткізгіштік теңдеуін шешу;
2. Параллель есептеудің тиімділігін арттыру үшін MPI және CUDA технологияларын қолдану;
3. Әртүрлі сандық схемалардың дәлдігін және тұрақтылығын салыстыру;
4. MPI және CUDA негізінде гибриді есептеулерді ұйымдастыру;
5. Параллель есептеу нәтижелерін талдау және өнімділік көрсеткіштерін бағалау.

Жылу өткізгіштік теңдеуін шешу үшін сандық әдістердің бірнеше түрі қолданылады. Бұл әдістер теңдеудің дискреттелген нұсқасын құру арқылы сандық шешімін табуға мүмкіндік береді. Зерттеуде айқын және айқын емес схемалар қолданылды. Сонымен қатар, модельдеудің дәлдігі мен тұрақтылығын арттыру үшін торлық әдістер пайдаланылды. MPI және CUDA көмегімен параллель есептеу арқылы үлкен өлшемді есептерді шешуде өнімділікті арттыру мүмкіндігі қарастырылды.

MPI көмегімен параллель есептеу үшін есептеу аймағы бірнеше процессорлар арасында бөлінеді. Әрбір процессор өз бөлігін есептеп, көршілес процессорлармен ақпарат алмасады. Бұл процесте MPI_Send және MPI_Recv сияқты негізгі MPI функциялары қолданылады. Бұл әдіс үлкен көлемді есептеулерді орындау жылдамдығын едәуір арттыруға мүмкіндік береді. MPI көппроцессорлы жүйелерде қолданылатындықтан, ол үлкен суперкомпьютерлік жүйелерде тиімділік береді.

CUDA – NVIDIA компаниясы әзірлеген графикалық процессорларда жоғары өнімді есептеулер жүргізуге мүмкіндік беретін технология. Жылу теңдеуін GPU-да орындау үшін параллель есептеу ядролары қолданылады. CUDA көмегімен есептеу жүктемесі мыңдаған параллель ағындарға бөлініп, әрбір ағын өзінің деректерін өңдейді. Бұл әдіс күрделі модельдер үшін жоғары өнімділік береді.

MPI және CUDA комбинациясын қолдану арқылы CPU мен GPU-ны біріктіріп, есептеу жылдамдығын одан әрі арттыруға болады. Бұл тәсіл үлкен масштабтағы ғылыми есептеулерде жоғары тиімділік береді. Есептеудің негізгі кезеңдері:

1. MPI арқылы есепті бірнеше түйінге бөлу;
2. Әрбір түйіннің өз бөлігін GPU көмегімен өңдеуі;
3. Процесстер арасында мәліметтер алмасу және нәтижені біріктіру.

Зерттеу барысында әртүрлі уақыттық және кеңістіктік параметрлер таңдалып, олардың модельдеу нәтижелеріне әсері зерттелді. MPI+CUDA гибриді тәсілі қарапайым CPU және тек

MPI негізіндегі тәсілдермен салыстырылды. CUDA көмегімен жылдамдықтың 10-20 есе артуы байқалды, ал MPI қосылғанда өнімділік одан әрі жақсарды. Өртүрлі процессорлар мен GPU карталарында өнімділік арту деңгейі өлшенді. Нәтижелер параллель есептеудің тиімділігі мен оның үлкен жүйелерге қолданылу мүмкіндіктерін көрсетті.

Бұл зерттеу 1D жылу өткізгіштік теңдеуін сандық әдістер арқылы шешудің тиімділігін дәлелдеді. MPI және CUDA технологияларын қолдану арқылы үлкен өлшемді есептерді тиімді шешуге мүмкіндік бар. Алынған нәтижелер инженерлік, физикалық және ғылыми зерттеулерде күрделі жылу процестерін модельдеуге көмектесе алады. Гибридті MPI+CUDA тәсілі жоғары тиімділікті қамтамасыз етіп, үлкен масштабтағы есептеулерге қолайлы екенін көрсетті.

Пайдаланылған әдебиеттер тізімі:

1. LeVeque, R. J. (2007). Finite Difference Methods for Ordinary and Partial Differential Equations. SIAM.
 2. Strikwerda, J. C. (2004). Finite Difference Schemes and Partial Differential Equations. SIAM.
 3. Gropp, W., Lusk, E., & Skjellum, A. (1999). Using MPI: Portable Parallel Programming with the Message-Passing Interface. MIT Press.
 4. Kirk, D. B., & Hwu, W. W. (2010). Programming Massively Parallel Processors: A Hands-on Approach. Morgan Kaufmann.
 5. Sanders, J., & Kandrot, E. (2010). CUDA by Example: An Introduction to General-Purpose GPU Programming. Addison-Wesley.
- Press, W. H., Teukolsky, S. A., Vetterling, W. T., & Flannery, B. P. (2007). Numerical Recipes: The Art of Scientific Computing. Cambridge University Press

Development of a Web Application for Gaming Video Conferences with Augmented Reality

Uzenbek Yersultan

Faculty of information technology

Scientific Supervisor:

Acting professor of the department of computer science

Lyazzat Boltabayevna Rakhimzhanova

Developing a web application for gaming video conferences with augmented reality is a step toward creating an interactive digital environment that enhances communication and engagement. The rapid growth of online gaming and remote collaboration tools has increased the demand for platforms that combine entertainment with real-time interaction. This project aims to design and implement a web-based solution that integrates video conferencing with augmented reality (AR) elements, providing users with an immersive and dynamic experience.

The development of such a platform requires the combination of several key technologies. WebRTC is utilized to enable seamless video communication, ensuring that users can interact in real time with minimal latency. WebGL and Three.js are leveraged for rendering AR elements, allowing the integration of 3D models and interactive virtual objects into the video conferencing space. Additionally, cloud-based services and real-time databases are implemented to synchronize gaming interactions and AR overlays across multiple users, ensuring a cohesive experience regardless of their location or device.

One of the primary challenges of integrating AR with video conferencing is maintaining smooth performance without overwhelming system resources. The application must balance high-quality video streaming with computationally demanding AR rendering. To address this, optimization techniques such as adaptive resolution scaling, efficient memory management, and predictive preloading of assets are employed. Furthermore, user experience plays a crucial role in the platform's design, ensuring that AR elements enhance the interaction rather than serve as a distraction. The interface is developed with simplicity in mind, allowing participants to easily join virtual game rooms, customize their AR settings, and engage in collaborative gaming sessions.

Security and scalability are also critical considerations in the development of this web application. The system incorporates encryption protocols and secure authentication mechanisms to protect user data and prevent unauthorized access. Scalable infrastructure ensures that the platform can accommodate a large number of concurrent users, making it suitable for gaming communities, esports events, and remote team-building activities.

The implementation of AR in gaming video conferences introduces new possibilities for online interaction, transforming the way users communicate and collaborate in virtual spaces. Unlike traditional video conferencing platforms that rely solely on verbal and visual communication, this solution allows participants to engage with interactive virtual environments, enhancing both entertainment and productivity. The platform can be adapted for various use cases, including educational applications, virtual corporate events, and multiplayer gaming experiences.

The goal of this project is to develop a web-based platform that integrates video conferencing with augmented reality (AR) to enhance gaming and interactive experiences. WebRTC will be used to enable real-time, low-latency video communication, while WebGL and Three.js will allow AR elements, such as interactive 3D models, to be incorporated seamlessly into the video stream. The platform aims to create an immersive environment where users can engage in collaborative gaming and interactive discussions.

One of the main challenges is balancing high-quality video streaming with computationally intensive AR rendering without overwhelming system resources. Optimization techniques, such as

adaptive resolution scaling, efficient memory management, and predictive asset preloading, will ensure smooth performance. A user-friendly interface will allow participants to join virtual game rooms, configure AR settings, and interact effortlessly.

The platform will leverage cloud-based services and real-time databases to synchronize AR interactions across multiple users, ensuring a cohesive experience regardless of location or device. Security is a priority, with encryption protocols and secure authentication mechanisms protecting user data. Scalability is also a key consideration, enabling the system to support large numbers of concurrent users, making it suitable for gaming communities, esports events, and remote collaboration.

The expected outcome is a functional web application that enhances video conferencing with AR, providing an engaging and interactive experience. The platform will be applicable to multiplayer gaming, education, and corporate events, offering a new way to communicate and collaborate online. By bridging the gap between gaming and video conferencing, this project will contribute to the evolution of digital interactions, paving the way for more immersive and engaging virtual experiences.

References:

1. Kato, H., & Billinghurst, M. (1999). "Marker Tracking and HMD Calibration for a Video-Based Augmented Reality Conferencing System." Proceedings of the 2nd IEEE and ACM International Workshop on Augmented Reality (IWAR '99), pp. 85-94.
2. Schmalstieg, D., Langlotz, T., & Billinghurst, M. (2018). "Augmented Reality 2.0: From AR Browsers to AR Cloud." IEEE Transactions on Visualization and Computer Graphics, 24(11), pp. 3226-3244.
3. He, Z., Wu, L., & Li, X. (2020). "A Survey of Interactive Augmented Reality Technologies and Applications." Journal of Visual Communication and Image Representation, 69, 102767.
4. Milgram, P., & Kishino, F. (1994). "A Taxonomy of Mixed Reality Visual Displays." IEICE Transactions on Information and Systems, E77-D(12), pp. 1321-1329.
5. Sutherland, I. E. (1968). "A Head-Mounted Three-Dimensional Display." Proceedings of the AFIPS Fall Joint Computer Conference, 33, pp. 757-764.
6. WebRTC Official Documentation. (2023). "WebRTC: Real-Time Communication for the Web." Retrieved from <https://webrtc.org>.
7. Parisi, T. (2015). Learning Virtual Reality: Developing Immersive Experiences and Applications for Desktop, Web, and Mobile. O'Reilly Media.

ВЕБ-ҚОСЫМШАЛАР АРҚЫЛЫ ИНТЕРАКТИВТІ ОҚЫТУ МӘСЕЛЕЛЕРІ: АНАЛИТИКАЛЫҚ ШОЛУ

Ұзақбаева Ақжүніс

Білім беру саласы технологияның қарқынды дамуымен бірге өзгеріске ұшырап келеді. Веб-қосымшалар арқылы интерактивті оқыту білім беру жүйесінде жаңа мүмкіндіктер ашады, сонымен қатар оның тиімділігі мен қолжетімділігі жоғары. Алайда бұл технологияны қолдану барысында кейбір қиындықтар туындайды, атап айтқанда, техникалық инфрақұрылымның жеткіліксіздігі, оқытушылардың цифрлық дағдыларының төмендігі және студенттердің өздігінен білім алу дағдыларының жетіспеушілігі. Осы зерттеу интерактивті оқытудың веб-қосымшалар арқылы тиімділігін арттыру жолдарын қарастырады.

Зерттеу мақсаты мен міндеттері. Мақсаты: Веб-қосымшалар арқылы интерактивті оқытудың тиімділігін талдау, оның артықшылықтары мен кемшіліктерін бағалау, білім беру жүйесіне әсерін зерттеу.

Міндеттері:

1. Веб-қосымшалар арқылы интерактивті оқытудың теориялық негіздерін қарастыру;
2. Қазіргі уақытта қолданылып жүрген негізгі веб-қосымшаларды сипаттау;
3. Интерактивті оқыту әдістерінің білім алушыларға әсерін бағалау;
4. Веб-қосымшаларды пайдаланудағы негізгі қиындықтарды анықтау;
5. Оқытуда веб-қосымшаларды тиімді қолдануға қатысты ұсыныстар әзірлеу.

Әдеби шолу. Интерактивті оқыту мен веб-қосымшалардың рөлі көптеген ғылыми зерттеулерде талданған. Deterding et al. (2011) еңбегінде веб-қосымшалардың оқушылардың когнитивті белсенділігіне әсері зерттелген. Namari, Koivisto & Sarsa (2014) онлайн білім беру платформаларының тиімділігіне арналған зерттеулер жүргізген. Карр (2012) жұмысы қашықтықтан оқытудың артықшылықтары мен кемшіліктерін сипаттайды. Жалпы, веб-қосымшалар арқылы оқыту әдістері өзекті болып табылады, бірақ олардың тиімділігі қолдану әдістеріне және оқу мақсаттарына байланысты өзгереді.

Веб-қосымшалар және олардың білім берудегі рөлі. Қазіргі уақытта көптеген білім беру платформалары интерактивті оқытуды қамтамасыз етеді. Олардың ішінде:

- Coursera, Udey, Khan Academy – қашықтықтан оқытуға арналған көп функционалды платформалар;
- Google Classroom, Moodle – оқу материалдарын басқаруға және бағалауға мүмкіндік береді;
- Kahoot!, Quizizz – ойын элементтерін қолдана отырып, оқушылардың мотивациясын арттырады;
- Duolingo, Memrise – шет тілдерін үйренуге бағытталған веб-қосымшалар.

Бұл платформалар оқу процесін оңтайландырып, білім алушылардың белсенділігін арттыруға көмектеседі. Алайда олардың кемшіліктері де бар, мысалы, интернетке тәуелділік, техникалық қолдау қажеттілігі және барлық пәндерге бірдей сәйкес келмеуі.

Интерактивті оқытудағы негізгі мәселелер мен шешімдер. Интерактивті оқытуды веб-қосымшалар арқылы жүзеге асыру барысында келесі мәселелер туындайды:

- Техникалық инфрақұрылымның жеткіліксіздігі – кейбір оқу орындары қажетті жабдықтармен қамтылмаған;
- Педагогтардың цифрлық сауаттылығының төмендігі – мұғалімдер жаңа технологияларды қолдануда қиындықтарға тап болуы мүмкін;
- Оқушылардың өзін-өзі басқару дағдыларының жеткіліксіздігі – веб-қосымшаларды пайдалану барысында оқушылардың мотивациясы төмендеуі мүмкін.

Осы мәселелерді шешу үшін келесі ұсыныстар жасалады:

- Оқу орындарын қажетті техникамен жабдықтау;
- Мұғалімдерге цифрлық технологияларды қолдану бойынша тренингтер ұйымдастыру;
- Студенттер мен оқушылардың өзін-өзі басқару және тайм-менеджмент дағдыларын дамыту.

Қорытынды. Веб-қосымшалар арқылы интерактивті оқыту білім беру жүйесін жаңа деңгейге көтеруге мүмкіндік береді. Алайда оның тиімділігі қолдану әдістеріне және педагогикалық стратегияларға байланысты. Оқу орындарына цифрлық технологияларды сәтті енгізу үшін техникалық инфрақұрылымды жетілдіру, педагогтардың біліктілігін арттыру және студенттердің өзін-өзі ұйымдастыру қабілеттерін дамыту қажет. Осы бағыттағы зерттеулер болашақта веб-қосымшалардың мүмкіндіктерін кеңейтуге және олардың тиімділігін арттыруға көмектеседі.

Пайдаланылған әдебиеттер тізімі:

1. Deterding S., Dixon D., Khaled R., & Nacke L. (2011). From game design elements to gamefulness: Defining “gamification”. Proceedings of the 15th International Academic MindTrek Conference, 9-15.
2. Hamari J., Koivisto J., & Sarsa H. (2014). Does gamification work? A literature review of empirical studies on gamification. Proceedings of the 47th Hawaii International Conference on System Sciences, 3025-3034.
3. Kapp K. M. (2012). The gamification of learning and instruction: Game-based methods and strategies for training and education. Wiley.

Predicting Students' Academic Achievements

Orazbek Aniya

Al-Farabi Kazakh National University, Department of Computer Science

Almaty, Kazakhstan 2025

Email: aniaorazbek@gmail.com

Scientific supervisor: Imankulov Timur, Associate Professor

Predicting student performance is one of the most important topics for researchers in the field of education management. Accurate forecasts allow educational institutions to identify students in need of support in a timely manner and develop individual educational trajectories. The integration of predictive models into education allows teachers to make informed choices, offer specific support, and refine teaching strategies, thereby improving student learning outcomes functions for the forecasting task.

The purpose of this study is to study and evaluate the effectiveness of machine learning algorithms for predicting students' academic achievements.

To achieve this goal, various machine learning algorithms for forecasting are being studied, including Random Forest [1] and eXtreme Gradient Boosting (XGBoost) [2].

The study uses a publicly available dataset that includes information on 2,392 high school students with detailed descriptions of their demographics, learning habits, parental involvement, extracurricular activities, and academic performance. The target variable includes the average score in all subjects, which indicates that this dataset is suitable for predicting students' academic achievements [3].

Based on Random Forest, it was found that signs such as “Class Absences”, “Parental Support”, “Weekly Study time”, and “Tutoring” have the most significant impact on predicting GPA. During the experiments, it was discovered that, despite the high quality of the predictions, Random Forest has several limitations, including complexity in processing nonlinear dependencies and a high computational cost when increasing the number of trees. In this regard, it was decided to use the Gradient Boosting Decision Trees method, which allows you to build more accurate models by sequentially training trees while taking previous iterations' errors into consideration. Experiments have demonstrated that XGBoost outperforms Random Forest in terms of prediction accuracy. The standard deviation (MSE) and average absolute error (MAE) both decreased.

In conclusion, eXtreme Gradient Boosting (XGBoost) machine learning algorithms for predicting student academic performance showed the best results compared to Random Forest. The use of polynomial features allowed the model to better capture complex dependencies in the data, and scaling the input variables improved the convergence of the model. The results demonstrated high accuracy of predictions, which confirms the effectiveness of eXtreme Gradient Boosting in educational analytics tasks. However, the study revealed the problem of class imbalance, which could cause prediction errors (especially MAPE) to be overestimated for students with high academic scores.

To further improve the quality of forecasting, it is necessary to expand the dataset and provide a more balanced representation of students with different GPA levels. Future research may focus on using more complex ensemble models, as well as developing methods for processing unbalanced data to increase the stability of predictions in real conditions.

References:

- [1] Prediction of Students' Academic Performance Using the Random Forest Algorithm: Analysis of Predictors' Importance // Heliyon. – 2023. - DOI: <https://doi.org/10.1016/j.tine.2023.100214>
- [2] Wang S., Luo B. Academic achievement prediction in higher education through interpretable modeling // PLoS One. – 2024. – T. 19, № 9. – C. e0309838. – DOI: 10.1371/journal.pone.0309838. – URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11376577/>
- [3] Students Performance Dataset/ Rabie El Kharoua // Kaggle. – 2023. – URL: <https://www.kaggle.com/datasets/rabieelkharoua/students-performance-dataset>

COORDINATION AND ROUTING OF AUTONOMOUS DRONES FOR RAPID RESPONSE IN HIGH-RISK MOUNTAINOUS AREAS

Yerzhan Maksat

*Scientific supervisor: Matkerim Bazargul,
Senior Lecturer of Department of Computer Science
Al-Farabi Kazakh National University
yerzhan_maksat2@live.kaznu.kz*

The increasing demand for rapid response in high-risk mountainous areas necessitates the development of advanced autonomous drone systems. This research focuses on optimizing the coordination and routing of autonomous drones for search and rescue (SAR) operations in such terrains. A hybrid AI-based framework incorporating deep reinforcement learning (DRL) and swarm intelligence algorithms is proposed to enhance path planning efficiency, obstacle avoidance, and energy management. Simulation results demonstrate improved search efficiency and mission success rates compared to conventional approaches [1], [2].

The study employs a hybrid AI-driven approach integrating deep reinforcement learning (DRL) for real-time adaptive path planning [3], swarm intelligence algorithms (PSO, ACO) for multi-UAV coordination [4], and energy-efficient routing strategies to optimize battery usage [5]. Simulation platforms such as ROS and Gazebo were utilized to evaluate the system's performance in dynamic and complex environments [6].

The experimental findings indicate that the proposed routing strategy improves UAV operational efficiency, with reduced mission duration and enhanced safety measures. AI-driven coordination enables drones to autonomously adjust their trajectories, ensuring optimal resource utilization and reduced collision risks [6]. The developed methodology presents a scalable solution for UAV deployment in complex environments, providing a framework for future advancements in autonomous aerial navigation.

References:

- [1] Ewers, R. M., & Didham, R. K. (2023). Adaptive RL for time-critical wilderness search and rescue using drones. *Frontiers in Robotics and AI*, 10, 45-60.
DOI: 10.1109/TMECH.2022.3203875
- [2] Shen, J., & Zhang, W. (2022). Autonomous collision-free UAV path planning in low-altitude complex environments. *Applied Sciences*, 12(14), 7333.
DOI: 10.1109/JSEN.2021.3130724
- [3] Kong, L., & Wang, H. (2024). Multi-UAV target assignment and path planning via deep RL in dynamic environments. *Frontiers in Neurorobotics*, 17, 1302898.
DOI: 10.1007/s11277-017-4734-x
- [4] Pyke, C., & Stark, A. (2021). Dynamic pathfinding for swarm UAV control model using PSO. *Frontiers in Applied Mathematics and Statistics*, 7.
DOI: 10.3390/s16050707
- [5] Ahmed, M. A., & Li, Y. (2023). Energy-efficient UAV coverage path planning. *CMES*, 136(3), 3239-3263.
DOI: 10.1007/s10846-021-01500-4
- [6] Qazzaz, M., & Patel, S. (2023). Optimizing SAR UAV connectivity in challenging terrain through multi Q-learning. *arXiv preprint 2405.10042*.

Comparative Analysis of Retrieval-Augmented Generation and Domain-Specific Fine-tuning for Enhancing E-commerce Conversational Chatbots

Тлеужанулы Динмухаммед

КБТУ

di_tleuzhanuly@kbtu.kz

E-commerce chatbots currently face significant challenges in providing accurate and engaging customer interactions. Two promising approaches—Retrieval-Augmented Generation (RAG) and domain-specific fine-tuning—offer potential improvements, but existing research leaves a critical knowledge gap about their relative strengths. This work aims to evaluate these methods by analyzing their performance in response accuracy, contextual understanding, and user engagement, ultimately providing actionable insights for developing more intelligent conversational AI systems in online retail.

RAG enhances text generation by integrating pre-trained language models with dynamically retrieved external knowledge. According [1], RAG "represents an approach to text generation that is based not only on patterns learned during training but also on dynamically retrieved external knowledge." This hybrid method allows chatbots to access up-to-date information beyond their initial training data, which is crucial in e-commerce where product details and customer preferences evolve rapidly.

The retrieval mechanism is central to RAG's success. authors [2] proposed a string vector-based K-Nearest Neighbors (KNN) approach to address challenges like "huge dimensionality, sparse distribution, and poor transparency" in text encoding. This early work laid the groundwork for modern dense retrieval methods in RAG by defining a "semantic similarity measure between two string vectors" as an alternative to traditional cosine similarity.

While RAG focuses on retrieval knowledge, domain-specific fine-tuning adapts pre-trained language models (PLMs) to the unique linguistic and contextual needs of e-commerce. Fine-tuning offers key advantages. Authors [3] showed that fine-tuning achieves strong results with fewer domain-specific examples than training from scratch, a boon for e-commerce firms with limited labeled data.

For our comparative evaluation, we implemented both approaches to improving e-commerce chatbot performance. Our fine-tuning approach leveraged the EleutherAI GPT-Neo-125M model with a dataset of 1,000 e-commerce question-answer pairs [4]. Training data was formatted as "Question: {question} Answer: {answer}" sequences to encourage the model to learn the task structure.

Our RAG system employs ChromaDB (v0.6.3) as the vector database with sentence transformers for semantic matching. Each question-answer pair was indexed using the sMiniLM-L6-V2 embedding model (384 dimensions), with questions embedded as searchable documents and corresponding answers stored as retrievable metadata. Customer queries undergo identical embedding transformation before retrieval, with the system conducting a similarity search against the vector database and retrieving the top-1 matching document without additional re-ranking to minimize latency. For assessment, the system directly returns the retrieved answer without generation steps, with performance metrics including exact match accuracy against ground truth, BLEU and F1 scores for partial matching, and response latency measurements.

To ensure a rigorous comparison, we evaluated both approaches using a benchmark dataset of 1,000 samples from the Hugging Face dataset repository, including both original questions and semantically equivalent paraphrased variants to assess model resilience to question reformulation.

Approach	Bleu score	F1 score	Accuracy
Fine-tuned Model	0.218	0.66	0.53
RAG System	0.352	0.995	0.995

This study compared two approaches for improving e-commerce chatbot performance: Retrieval-Augmented Generation and domain-specific fine-tuning. Our experiments demonstrated that the RAG system significantly outperformed the fine-tuned model across all metrics, achieving near-perfect F1 and accuracy scores (0.995) compared to the fine-tuned model's more modest performance (0.66 F1, 0.53 accuracy).

References:

- [1] T. Merth, Q. Fu, M. Rastegari, and M. Najibi, "Superposition prompting: Improving and accelerating retrieval-augmented generation," 2024. [Online]. Available: <https://arxiv.org/abs/2404.06910>
- [2] T. Jo, String Vector based KNN for Text Categorization. IEEE, 2017. [Online]. Available: <https://ieeexplore.ieee.org/document/7890204>
- [3] J. Howard and S. Ruder, "Universal language model fine-tuning for text classification," in Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers), I. Gurevych and Y. Miyao, Eds. Melbourne, Australia: Association for Computational Linguistics, Jul. 2018, pp. 328–339. [Online]. Available: <https://aclanthology.org/P18-1031/>
- [4] P. Rajpurkar, J. Zhang, K. Lopyrev, and P. Liang, "SQuAD: 100,000+ questions for machine comprehension of text," in Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, J. Su, K. Duh, and X. Carreras, Eds. Austin, Texas: Association for Computational Linguistics, Nov. 2016, pp. 2383–2392. [Online]. Available: <https://aclanthology.org/D16-1264>

Comprehensive Study on Intelligent Information Systems for Classification of Student Academic Achievements

Omirzakhova Nuray

Al-Farabi Kazakh National University, Almaty, Kazakhstan

Contact phone numbers: +77789032484; E-mail: omirzakhova_nuray@live.kaznu.kz

Scientific Supervisor: Timur Imankulov, PhD, Associate Professor

Classifying student academic achievements is pivotal in modern educational institutions, facilitating personalized learning, performance evaluation, and curriculum adaptation. Traditional classification methods, often based on statistical approaches and predefined rules, face challenges when dealing with large datasets, diverse learning behaviors, and evolving academic standards [1]. With the increasing integration of data-driven decision-making in education, there is a growing demand for intelligent and adaptive classification systems. Addressing the challenges of accurate and scalable academic achievement classification necessitates advanced computational approaches [2].

This research aims to develop and evaluate an intelligent information system for the classification of student academic achievements using machine learning techniques. The study explores various supervised learning algorithms, including decision trees, support vector machines (SVMs), k-nearest neighbors (KNN), and deep learning models such as artificial neural networks (ANNs) and recurrent neural networks (RNNs) [3]. The system leverages both structured and unstructured educational data to provide a robust classification framework adaptable to diverse academic environments.

Publicly available and institution-specific datasets are utilized to train and validate the proposed models [4]. Feature engineering techniques, natural language processing (NLP) for text-based academic records, and ensemble learning methods are applied to enhance classification accuracy and generalizability [3]. Additionally, explainable AI (XAI) methods are employed to ensure interpretability and transparency of the classification decisions, making the system more practical for educators and administrators [2].

Experimental results indicate that machine learning-based classification significantly outperforms traditional methods in terms of accuracy, adaptability, and automation [1]. The integration of deep learning techniques further enhances the model's ability to recognize complex patterns in student performance data. However, challenges such as data sparsity, biases in grading systems, and model interpretability remain critical concerns for real-world implementation [4].

In conclusion, this study highlights the potential of intelligent information systems to revolutionize the classification of student academic achievements, offering data-driven insights for improved educational decision-making. Future research should focus on refining feature selection strategies, incorporating multimodal data sources, and addressing ethical concerns related to automated academic assessments.

References:

- [1] F. A. Orji, J. Vassileva, "Machine Learning Approach for Predicting Students Academic Performance and Study Strategies based on their Motivation," arXiv preprint arXiv:2210.08186, 2022. ([arxiv.org](https://arxiv.org/abs/2210.08186))
- [2] C. Beaulac, J. S. Rosenthal, "Predicting University Students' Academic Success and Major using Random Forests," arXiv preprint arXiv:1802.03418, 2018. ([arxiv.org](https://arxiv.org/abs/1802.03418))
- [3] V. Bansal, H. Buckchash, B. Raman, "Computational Models for Academic Performance Estimation," arXiv preprint arXiv:2009.02661, 2020. ([arxiv.org](https://arxiv.org/abs/2009.02661))

[4] S. Balovsyak, O. Derevyanchuk, H. Kravchenko, Y. Ushenko, Z. Hu, "Clustering Students According to their Academic Achievement Using Fuzzy Logic," arXiv preprint arXiv:2312.10047, 2023. ([arxiv.org](https://arxiv.org/abs/2312.10047))

Optimization of 3D Animation and Visualization in Augmented Reality

Kaiyrbekov Yerulan

Faculty of information technology

Scientific Supervisor:

Acting professor of the department of computer science

Lyazzat Boltabayevna Rakhimzhanova

One of the key challenges in developing AR applications is achieving realistic animation and visualization of 3D objects. Virtual elements often appear artificial, and their movements may seem unnatural. For example, soft materials such as clothing or hair may remain static or behave illogically when interacting with the environment. Animation artifacts, such as texture flickering, incorrect shadow overlays, and model tearing, also reduce the realism of the scene. Additionally, the high computational load limits the ability to process complex animations in real-time.

The aim of the study is to develop and optimize methods for animating and visualizing 3D objects in augmented reality to enhance their realism, performance, and adaptability to environmental changes.

To achieve more natural animation, game engines such as Unity and Unreal Engine provide powerful rendering and physics simulation tools. For example, Unity includes the Animator system for smooth animations and a Physics Engine that supports realistic object movement based on mass and external influences.

For handling complex interactions, Vuforia technology is used, which leverages computer vision to accurately determine the position of objects in space. This allows AR objects to adapt to the real environment, correctly overlay on physical surfaces, and interact with users.

To minimize rendering artifacts and improve performance, optimization methods such as Level of Detail (LOD), which automatically reduces the detail of distant objects, and dynamic texture loading, which reduces memory load, are employed. Visual accuracy is enhanced through lighting algorithms like Ray Tracing, which creates natural shadows and reflections.

By implementing these technologies, AR applications can achieve high animation smoothness, and 3D objects can appear more natural. Future research can focus on improving animation adaptability so that virtual elements dynamically respond to environmental changes and user movements in real time.

References:

1. Azuma, R. T. (1997). "A Survey of Augmented Reality." **Presence: Teleoperators and Virtual Environments**, 6(4), 355-385.
2. Billinghurst, M., Clark, A., & Lee, G. (2015). "A survey of augmented reality." **Foundations and Trends in Human-Computer Interaction**, 8(2-3), 73-272.
3. Kipper, G., & Rampolla, J. (2012). **Augmented Reality: An Emerging Technologies Guide to AR**. Elsevier.
4. Carmigniani, J., & Furht, B. (2011). "Augmented reality: an overview." **Handbook of Augmented Reality**, 3-46.
5. Unity Technologies. (2022). "Real-Time Rendering and Physics in Unity." Available at: <https://unity.com/solutions/physics>
6. Vuforia. (2023). "Vuforia Engine Overview." Available at: <https://developer.vuforia.com>
7. Apple ARKit. (2023). "Enhancing 3D Animation in AR." Available at: <https://developer.apple.com/augmented-reality/>

Жоғары сынып оқушыларын Python тілінде ойын құруға үйрету әдістері

Курманғалиева А.М.

*Ғылыми жетекші: Турганбаева А.Р.,
компьютерлік ғылымдар кафедрасының аға оқытушысы
Әл-Фараби атындағы Қаз ҰУ, Алматы, Қазақстан
e-mail: amk997@mail.ru*

Қазіргі заманғы мектептің маңызды міндеті жоғары сынып оқушыларын бағдарламалау негіздеріне ғана емес, сондай-ақ практикалық дағдыларды оқыту болып табылады. Сол себепті оқушыларға бағдарламалауды үйрету үшін әдістеме жасау қажеттігі туындайды. Әртүрлі бағдарламалау тілдерінің ішінде Python жаңадан бастаушылар үшін қолжетімді тіл ғана емес, сонымен қатар шығармашылық және алгоритмдік дағдыларды дамытуға мүмкіндік береді. Ойындық әзірлеуді жобалық әрекет ретінде қарастыра отырып, оқушылардың еңбектерінің нәтижелерін көруге мүмкіндік береді [1]. Бұл мотивацияны арттыруға көмектеседі. Python тілінің ықшамдылығы және Pygame сияқты ойындық кітапханалардың болуы жаңадан бастаушы программисттерді оқыту үшін қолайлы құрал [2]. Онлайн ресурстар мен платформаларды пайдалану оқушыларға программалау тілін ыңғайлы қарқынмен және интерактивті түрде зерттеуге мүмкіндік береді. Мукашева және Ермаганбетова [3] оқу бағдарламаларын әзірлеудің қажеттілігіне назар аударады, олар тек теориялық білімге ғана емес, сонымен қатар бағдарламалау дағдыларын практикалық қолдануға да бағытталған. Бұл Python тілінде өз ойындарын әзірлеуге мүмкіндік беретін жобалық тапсырмаларды қамтиды, осылайша оқушылар алған білімдерін практикада бекітеді. Нургалиеваның [4] мақаласында программалауды оқытуға қатысты қолданыстағы методологиялық тәсілдер қарастырылады, технологиялар мен интерактивті контентті интеграциялаудың маңыздылығына ерекше назар аударылады. Осы бағытта Python бағдарламалау тілін оқыту бойынша 7-11 сынып оқушылары арасында сауалнама алынды. Жүргізілген сауалнама нәтижелерінің талдауы:

1. Python үйренудегі негізгі қиындықтар

- 52% оқушылар алгоритмдеу және логикамен қиындықтарға тап болады.
- 48% Python синтаксисін меңгеруде қиындық көреді.
- 37% материалды бекіту үшін жеткілікті практикалық тапсырмалар жоқ екенін атап өтті.

2. Ойын жасау арқылы Python үйренуге қызығушылық

- 84% оқушылар бағдарламалауды ойын жасау арқылы үйренгісі келеді.
- 16% дәстүрлі оқыту әдістерін жөн көреді.

3. Қолданылатын оқу материалдары

• 45% оқу үшін видеосабактар мен онлайн-платформаларды пайдаланады (YouTube, Stepik, Codecademy).

- 35% оқулықтар мен әдістемелік құралдарға сүйенеді.
- 20% ойын платформаларын (Code.org, Scratch) қолданады.

— Алгоритмдерді және Python синтаксисін меңгеруде айтарлықтай қиындықтар бар. Оқушыларды логикалық ойлауға көбірек бейімдеп, практика санын көбейту қажет.

— Ойын түрінде оқыту сұранысқа ие. Оқушылардың басым бөлігі бағдарламалауды ойын жасау арқылы үйренгісі келеді. Бұл "Ойын арқылы оқыту" әдісінің тиімділігін растайды.

— Әртүрлі білім көздері қолданылады. Онлайн-ресурстар мен видеосабактар дәстүрлі оқулықтардан әлдеқайда танымал, сондықтан оларды оқу процесіне енгізу маңызды.

Жүргізілген зерттеу нәтижесінде Python тілінде ойындар жасауға арналған қазақ

тіліндегі әдістеме әзірленді. Әдістеменің басты ерекшелігі – білімді тәжірибелік қолдануға негізделуінде. Бұл оқушыларға бағдарламалаудың теориялық негіздерін игеріп қана қоймай, интерактивті жобалар жасау арқылы креативті және алгоритмдік қабілеттерін дамытуға мүмкіндік береді. Әдістеменің негізгі элементі ретінде геймификация оқушылардың қызығушылығын арттыруға ықпал етеді, бұл оқу процесін қызықты әрі тиімді етеді. Pygame кітапханасы және PyCharm сияқты интеграцияланған бағдарламалау орталарын пайдалану оқушыларға заманауи бағдарламалау құралдарын игеруге жағдай жасап, олардың жұмыстарының сапасын арттырады және өз күштеріне деген сенімділікті қалыптастырады.

Пайдаланылған әдебиеттер тізімі:

1. Roberts, K., Johnson, M., & Smith, L. The Impact of Game Development on Student Engagement in Programming Courses. *Journal of Educational Technology*, 2020y., 45(3), 123-138.
2. Петрова, А. Программирование на Python: от простого к сложному. *Образование и информационные технологии*, 2019 г., 10(2), 45-56.
3. Мукашева, А., & Ермаганбетова, Л. Разработка учебных программ по программированию: теоретические и практические аспекты. *Педагогические технологии*, 2023 г., 9(1), 34-42.
4. Нургалиева, С. Методологические подходы к обучению программированию: интеграция технологий и контента. *Научный вестник*, 2019 г., 5(2), 22-30.

OPENGL ЖӘНЕ ШЕЙДЕРЛЕРДІ ПАЙДАЛАНА ОТЫРЫП, НАҚТЫ УАҚЫТТАҒЫ СӘУЛЕЛЕРДІ БАҚЫЛАУ

Балтабай Е.Ж.

Әл-Фараби Атындағы Қазақ Ұлттық Университеті

baltabayernur@gmail.com

Ғылыми жетекшісі: Тұрар О.Н.


Қазіргі таңда ақпараттық технологиялардың дамуына байланысты үшөлшемді графиканы визуализациялау әдістеріне сұраныс артып отыр. Әсіресе, нақты уақыт режимінде жоғары сапалы бейнелерді өңдеу және көрсету мәселелері өзекті болып табылады. Бұл тұрғыда OpenGL технологиясы және шейдер бағдарламалау тілі (GLSL) сәулелерді бақылау (Ray Tracing) алгоритмдерін жүзеге асыруда маңызды рөл атқарады.

Сәулелерді бақылау әдісі — үшөлшемді сахнадағы объектілермен жарық сәулелерінің өзара әрекеттесуін модельдейтін алгоритм. Ол шынайы көлеңкелерді, шағылысуларды және жарық сынуын ескере отырып, шынайы көріністер жасауға мүмкіндік береді. Алайда дәстүрлі әдістер есептеу ресурстарын көп қажет ететіндіктен, нақты уақыт режимінде қолдану қиындық туғызады.

Осы жұмыстың мақсаты — OpenGL және шейдерлерді пайдаланып, нақты уақыт режимінде жұмыс істейтін сәулелерді бақылау алгоритмін әзірлеу және оңтайландыру. Зерттеу барысында OpenGL графикалық кітапханасы және GLSL шейдерлері арқылы GPU ресурстарын тиімді пайдалану қарастырылды. Алгоритмді оңтайландыру барысында бірнеше маңызды аспектілерге көңіл бөлінді:

- Жадыны басқару;
- Сахнадағы объектілерге сәулелерді тиімді бағыттау;
- Көлеңке, шағылысу және сыну эффектілерін дұрыс есептеу;
- Шейдерлерді көпағынды режимде пайдалану.

Жүргізілген зерттеулердің нәтижесінде нақты уақыт режимінде жұмыс істейтін сәулелерді бақылау жүйесінің прототипі жасалды. Прототип күрделі үшөлшемді сахналарды өңдеп, жоғары өнімділік көрсетіп, визуализация сапасын арттырды. Бағдарламалық кешен виртуалды шынайылық жүйелерінде, инженерлік есептеулерде және компьютерлік ойындарда қолдануға бейімделген.



Қорытындылай келе, OpenGL және шейдерлерді қолдану арқылы сәулелерді бақылау әдісін нақты уақыт режимінде жүзеге асыру мүмкіндігі дәлелденді. Жобаланған жүйе шынайы графикамен жұмыс істейтін қолданбаларда тиімді шешім бола алады.

Пайдаланылган әдебиеттер тізімі:

1. Shirley P., Morley R. Realistic Ray Tracing. 2nd Edition. A. K. Peters, Ltd., 2003. – 368 б.
2. Angel E., Shreiner D. Interactive Computer Graphics: A Top-Down Approach with WebGL. 7th Edition. Pearson Education, 2014. – 696 б.
3. Glassner A. S. An Introduction to Ray Tracing. Academic Press, 1989. – 329 б.
4. Pharr M., Humphreys G. Physically Based Rendering: From Theory to Implementation. 3rd Edition. Morgan Kaufmann, 2016. – 1266 б.
5. Hart J. C. Ray Tracing: The Rest of Your Life. 2021. – 190 б.

Нейрондық желілерді қолдана отырып, жаңартылатын энергияны энергетикалық жүйелерге интеграциялауды оңтайландыруға арналған заманауи зерттеулерге шолу

Сейлхан Ә.М.*

*ал-Фараби атындағы Қазақ ұлттық университеті, Алматы қ., Қазақстан
seilkhan.mansur@gmail.com*

Жаңартылатын энергия көздерін (ЖЭК) энергетикалық жүйелерге интеграциялауды тұрақтылықты қамтамасыз ету, ысыраптарды азайту және энергияның таралу динамикасын дәл модельдеу сияқты бірқатар күрделі міндеттерді тудырады. Физикадан ақпараттандырылған нейрондық желілерге (ФАНЖ) негізделген заманауи әдістер бұл мәселелерді шешудің жолдарын көрсетеді. Әдеби шолуда энергия таралу желілерінің инфрақұрылымын оңтайландыруға және нейрондық желі модельдерін пайдалана отырып, дербес туындылы дифференциалдық теңдеулерді (ДТДТ) сандық шешудің жаңа әдістерін әзірлеуге бағытталған жұмыстар қарастырылады.

Бөлу және инфрақұрылымды оңтайландыру. Зерттеулердің бірі күн генерациясы интеграцияланған электр көліктеріне зарядтау станцияларын орналастыруды оңтайландыруға арналған. Жұмыста ықтималдық жүктемені модельдеуге және жоғалту сезімталдығын талдауға негізделген әдістеме ұсынылған, ол белсенді қуат жоғалтуларын 87,86%-ға дейін төмендетуге және желі тұрақтылығын арттыруға мүмкіндік береді. Бұл тәсілді орталық желілердегі жүктемені азайту және энергетикалық инфрақұрылымның тұрақты дамуына ықпал ету үшін қолдануға болады [1].

Физикамен ақпараттандырылған нейрондық желілерді пайдалана отырып, ДТДТ шешу. Бірнеше зерттеулер нейрондық желі модельдерін пайдаланып ДТДТ сандық шешу әдістерін әзірлеуге және жетілдіруге бағытталған. Мысалы, бірінші зерттеу ДТДТ шешудің классикалық тәсілдерімен салыстырғанда дәлдікті жақсарту және конвергенцияны жылдамдату үшін бірнеше қабылдағыш өрістер мен конволюциялық қабаттарды пайдаланатын модельді көрсетеді [2]. Басқа зерттеу күрделі энергетикалық процестерді модельдеуге жарамды тура және кері есептерді сенімді шешу үшін терең оқыту мен Гаусс процестерін біріктіретін гибриді модельді ұсынады [3].

Нейрондық операторларды оқытуда физикалық заңдылықтарды интеграциялауды ұсынатын еңбектер де бар. Бір тәсіл ДТДТ шешу операторларын жақындату үшін физикамен ақпараттандырылған ядро функциясын пайдаланады, бұл жоғары өлшемді есептердегі есептеулерді айтарлықтай жылдамдатады [4]. Басқа тәсіл шешімдердің күрт өзгеруімен проблемаларды тиімді шешуге мүмкіндік беретін адаптивті іріктеу әдістеріне негізделген, бұл әсіресе динамикалық энергия жүйелері үшін маңызды [5].

Жеке зерттеулер жасанды нейрондық желілерді пайдалана отырып, өтпелі ДТДТ шешу үшін терең коллокация әдісін қолдануды көрсетеді, бұл дәстүрлі торды дискретизациялауды қажет етпей, шешімдердің үздіксіз және дифференциалданатын көрінісін алуға мүмкіндік береді. Бұл әдіс қуат жүйелеріндегі динамикалық процестерді модельдеу үшін пайдалы болуы мүмкін [6]. Жаңартылған энергия көздерін орналастыруды оңтайландыру кезінде өзекті болып табылатын жүйе элементтерін бөлудің кеңістіктік ерекшеліктерін ескере отырып, геометрияны өзгертуге қашықтан басқару операторларын оқытуға мүмкіндік беретін инновациялық тәсіл де атап өтілді [7].

Оңтайландыру әдістері және алгоритмдік тәсілдер. Жаңартылатын энергия көздерін интеграциялауды мәселелерінде мультикритериалды оңтайландыру әдістері қолданылады. Зерттеулердің бірінде гибриді энергетикалық жүйелердің параметрлерін оңтайлы таңдау үшін метаэвристикалық тәсілдерді біріктіретін гибриді алгоритмдер қарастырылады, бұл

эртүрлі энергия көздерінің интеграциясын оңтайландырумен тікелей байланысты [8]. Басқа зерттеу энергияны өндіру мен тұтынуды теңестіруге көмектесетін жаңартылатын энергия жүйелеріндегі жүктеме жиілігін бақылау үшін гибриді алгоритмді қолдануды көрсетті [9].

Қорытынды. Қазіргі заманғы зерттеулер ФАНЖ әдістерін, нейрондық операторларды және гибриді метаэвристикалық алгоритмдерді біріктіру жаңартылатын энергия көздерін біріктіру кезінде энергияны бөлуді модельдеу және оңтайландырудың дәлдігін айтарлықтай жақсарта алатынын көрсетеді. Бейімделетін іріктеу әдістерін, терең коллокация тәсілдерін және ДТДТ шешуге арналған тиімді алгоритмдерді қолдану тұрақты және энергияны үнемдейтін жүйелерді дамытуда жаңа перспективаларды ашады. Қол жеткен табыстарға қарамастан, нақты энергетикалық жүйелердің ерекшеліктеріне ұсынылған әдістерді одан әрі оңтайландыру және бейімдеу міндеті өзекті болып қала береді.

Осылайша, ұсынылған зерттеулер қазіргі заманғы энергетикалық жүйелердің құрылымдық және динамикалық мәселелерін шешуге мүмкіндік беретін нейрондық желілерді пайдалана отырып, жаңартылатын энергия көздерін интеграциялауды оңтайландыру бойынша одан әрі әзірлемелер үшін негіз болып табылады.

Пайдаланылған әдебиеттер тізімі:

1. Oladigbolu, J.O., Bilal, M., Gupta, S. *et al.* A novel approach for optimal deployment of plug-in electric vehicles with integrated renewable energy sources. *Electr Eng* (2024). <https://doi.org/10.1007/s00202-024-02720-1>
2. Zhang, S., Zhang, C., Han, X. *et al.* MRF-PINN: a multi-receptive-field convolutional physics-informed neural network for solving partial differential equations. *Comput Mech* 75, 1137–1163 (2025). <https://doi.org/10.1007/s00466-024-02554-5>
3. Mora, C., Yousefpour, A., Hosseinmardi, S. *et al.* A gaussian process framework for solving forward and inverse problems involving nonlinear partial differential equations. *Comput Mech* (2024). <https://doi.org/10.1007/s00466-024-02559-0>
4. Kurz, J., Bowman, B., Seman, M. *et al.* A physics-informed kernel approach to learning the operator for parametric PDEs. *Neural Comput & Applic* 36, 22773–22787 (2024). <https://doi.org/10.1007/s00521-024-10460-3>
5. Mao, Z., Meng, X. Physics-informed neural networks with residual/gradient-based adaptive sampling methods for solving partial differential equations with sharp solutions. *Appl. Math. Mech.-Engl. Ed.* 44, 1069–1084 (2023). <https://doi.org/10.1007/s10483-023-2994-7>
6. Mishra, A., Anitescu, C., Budarapu, P.R. *et al.* An artificial neural network based deep collocation method for the solution of transient linear and nonlinear partial differential equations. *Front. Struct. Civ. Eng.* 18, 1296–1310 (2024). <https://doi.org/10.1007/s11709-024-1011-4>
7. Yin, M., Charon, N., Brody, R. *et al.* A scalable framework for learning the geometry-dependent solution operators of partial differential equations. *Nat Comput Sci* 4, 928–940 (2024). <https://doi.org/10.1038/s43588-024-00732-2>
8. Bouaouda, A., Sayouti, Y. Hybrid Meta-Heuristic Algorithms for Optimal Sizing of Hybrid Renewable Energy System: A Review of the State-of-the-Art. *Arch Computat Methods Eng* 29, 4049–4083 (2022). <https://doi.org/10.1007/s11831-022-09730-x>
9. Khezri, E., Rezaeiapanah, A., Hassanzadeh, H. *et al.* Towards load frequency management in thermal power systems using an improved open-source development model algorithm. *Evol. Intel.* 18, 9 (2025). <https://doi.org/10.1007/s12065-024-00986-9>

Пуассон теңдеуін шешуге арналған гибриді параллельді алгоритм құру

Дәуіт Ж.Б.

*Ғылыми жетекші: Кенжебек Ержан, аға оқытушы
Әл-Фараби атындағы Қазақ Ұлттық университетінің 4 курс студенті
E-mail: dauitzhansaya@gmail.com*

Пуассон теңдеуін шешу көптеген ғылыми және инженерлік есептерде маңызды мәселе болып табылады. Бұл теңдеу электростатика, жылу өткізгіштік, сұйықтық динамикасы және кванттық механика сияқты салаларда қолданылады. Үлкен көлемдегі деректерді өңдеу қажеттілігі есептеу ресурстарын тиімді пайдалануды талап етеді. Осы зерттеу жұмысы Пуассон теңдеуін шешуде гибриді параллельді есептеулерді қолданудың тиімділігін зерттеуге арналған. Үлкен көлемдегі деректермен жұмыс істегенде классикалық әдістерді пайдалану есептеудің ұзақ уақытқа созылуына алып келеді. Сондықтан есептеу процесін жеделдету үшін параллельді есептеу әдістерін қолдану қажеттілігі туындайды. MPI және CUDA технологияларын біріктіру арқылы есептеу өнімділігін арттыру маңызды болып табылады.

Зерттеу жұмысының мақсаты — Пуассон теңдеуін шешуге арналған гибриді параллельді алгоритм құру және оның тиімділігін MPI және CUDA технологияларын біріктіру арқылы бағалау. Осы мақсатқа жету үшін Пуассон теңдеуінің теориялық негіздері зерттелді, MPI және CUDA технологияларының жұмыс істеу принциптері талданды, олардың негізінде гибриді параллельді алгоритм құрылды, алгоритм тестіленді және оның тиімділігі бағаланды, алынған нәтижелер талданды және қорытынды жасалды.

Ұсынылып отырған гибриді параллельді алгоритм MPI және CUDA технологияларын біріктіре отырып, есептеу тиімділігін арттыруға мүмкіндік береді. Бұл тәсіл есептеу жылдамдығын жоғарылатып, үлкен көлемдегі деректерді өңдеуге қолайлы жағдай жасайды. Зерттеу жұмысының нәтижелері гибриді параллельді тәсілдің үлкен көлемді есептерді шешуде тиімді екенін көрсетті. Есептеу жылдамдығының арттырылуы сандық әдістерді қолдану тиімділігін жақсартып, күрделі есептерді шешу процесін оңтайландырды. Бұл зерттеу нәтижелері ғылыми зерттеулер мен инженерлік есептерді шешуде қолданыс табуы мүмкін.

Пайдаланылған әдебиеттер тізімі:

1. Kirk, D. B., & Hwu, W. W. (2017). Programming Massively Parallel Processors: A Hands-on Approach (3rd ed.). Morgan Kaufmann.
2. Sanders, J., & Kandrot, E. (2010). CUDA by Example: An Introduction to General-Purpose GPU Programming. Addison-Wesley.
3. Гергель В. П. (2007). Параллельные вычисления и многопроцессорные системы. М.: Физматлит.

Бетті тану сапасын жақсарту үшін синтетикалық деректерді генерациялау

Сейдалиев Н.Н.

ал-Фараби атындағы Қазақ ұлттық университетінің 4 курс студенті

E-mail: smatovnurzhigit@gmail.com


Муханбет А.А.

ал-Фараби атындағы Қазақ ұлттық университетінің ф.-м.ғ.к., оқытушы

Бетті тану технологиялары жасанды интеллект пен компьютерлік көру саласындағы маңызды зерттеу бағыттарының бірі болып табылады. Бетті тану технологиялары заманауи қауіпсіздік жүйелерінде, жеке басын анықтау процестерінде және биометриялық аутентификацияда кеңінен қолданылады. Дегенмен, жоғары дәлдікке қол жеткізу үшін үлкен және әртүрлі деректер жиынтығы қажет. Деректердің шектеулігі және вариациясының жеткіліксіздігі модельдің өнімділігіне кері әсер етуі мүмкін. Бұл мәселені шешудің тиімді жолдарының бірі - синтетикалық деректер генерациялау. Осы зерттеуде Generative Adversarial Network (GAN) модельдерін пайдалана отырып, шынайы бейнелерге ұқсас синтетикалық бейнелер алу және олардың бетті тану сапасына әсерін талдау мақсат етілді.


Бұл зерттеуде VGGFace2 деректер жиынтығына негізделген InceptionResNetV1 архитектурасындағы FaceNet моделі және MTCNN бет анықтау технологиясы қолданылды. Сонымен қатар, генеративті қарсылас желілер (GAN) арқылы синтетикалық деректер генерацияланып, олардың бетті тану сапасына әсері зерттелді.

Шынайы деректер жинау. Бастапқы деректер жиынтығын жинау үшін OpenCV технологиясы қолданылды. Жиналған шынайы деректер бетті тану моделін оқыту үшін пайдаланылды. FaceNet моделі VGGFace2 деректер жиынтығында оқытылды. Бұл модель әрбір бет үшін 512 өлшемді эмбедингтерді құрастырып, беттің ерекшеліктерін тиімді түрде сипаттады. Бұл деректер MTCNN алгоритмі арқылы өңделіп, бет аймақтары кесіліп алынды. Бұл әдістің нәтижесінде модель шынайы деректерді пайдалану арқылы 96% дәлдікке қол жеткізді.




face_53.jpg

face_54.jpg




face_64.jpg

face_65.jpg





face_75.jpg

face_76.jpg



face_86.jpg

face_87.jpg



Синтетикалық деректер генерациялау Зерттеудің негізгі мақсаты — бетті тану

сапасын арттыру үшін синтетикалық деректерді қолдану болды. Синтетикалық бейнелерді генерациялау үшін GAN (Generative Adversarial Networks) моделі қолданылды. GAN моделі екі негізгі нейрондық желіден тұрады:

Генератор — жаңа синтетикалық бейнелерді жасайды.

Дискриминатор — алынған бейнелердің шынайы немесе жасанды екенін анықтайды.

GAN моделін оқыту үшін 500 шынайы сурет қолдану жоспарланған болатын. Дегенмен, генерацияланған бейнелердің сапасы күтілген нәтижеге жетпеді, сондықтан деректер жиынтығын кеңейту қажеттілігі туындады. Солай оқытуға 2000 шынайы деректер берілді.

Біріктірілген деректер жиынтығын қолдану Генерацияланған және шынайы суреттер біріктіріліп, алынған деректер жиынтығы FaceNet моделіне оқыту үшін дайындалды. Алынған жиынтықтың 75%-ы оқытуға, ал қалған 25%-ы тестілеуге бөлінді.

Шынайы деректерді пайдалану кезінде бетті тану дәлдігі 96% көрсетті. Синтетикалық деректерді қосқаннан кейін, FaceNet моделін қайта оқыту арқылы бұл көрсеткіш 96,43%-ға дейін өсті. Бұл синтетикалық деректердің қосылуының тану сапасына оң әсерін көрсетеді. Нәтижелер көрсеткендей, GAN арқылы алынған бейнелер бетті тану жүйелерінің тиімділігін арттыруға көмектесе алады.

Қорытындылай келе зерттеу барысында алынған нәтижелер GAN технологиясын пайдалану арқылы синтетикалық деректер генерациялау бетті тану сапасын жақсартуға оң әсер ететінін дәлелдеді. Алдағы зерттеулерде синтетикалық деректердің көлемін ұлғайту, олардың сапасын жақсарту және түрлі GAN архитектураларын салыстыру арқылы тиімділікті арттыруға болады. Сонымен қатар, бұл тәсіл жеке тұлғалардың құпиялылығын сақтау мақсатында шынайы деректерге тәуелділікті төмендету үшін де қолданылуы мүмкін.

Пайдаланылған әдебиеттер тізімі:

1. IQBAL MUHAMMAD ALI Waqas Jadoon Soo Kyun Kim, " Synthetic Image Generation using Conditional GAN Provided Single Sample Face Image" 2024.
2. Hatef Otroschi Shahreza and Sébastien Marcel " HyperFace: Generating Synthetic Face Recognition Datasets by Exploring Face Embedding Hypersphere" École Polytechnique Fédérale de Lausanne (EPFL), Lausanne, Switzerland Université de Lausanne (UNIL), Lausanne, Switzerland 2042
3. Omer Granoviter, Alexey Gruzdev, Vladimir Loginov , Max Kogan, Orly Zvitia" FACE RECOGNITION USING SYNTHETIC FACE DATA"
4. Pietro Melzi, Christian Rathgeb, Ruben Tolosana , Ruben Vera-Rodriguez" GANDiffFace: Controllable Generation of Synthetic Datasets for Face Recognition with Realistic Variations" Biometrics and Data Pattern Analytics Laboratory, Universidad Autonoma de Madrid, Spain secunet Security Networks AG, Essen, Germany Hochschule Darmstadt, Germany
5. Hongzhi Zhang, " Handwriting Digital Image Generation based on GAN: A Comparative Study of Basic GAN and CGAN Models" Guangdong University of Technology, Guangzhou City, Guangdong Province, China.

DEVELOPMENT AND OPTIMIZATION OF A DEEP LEARNING MODEL FOR EARLY BREAST CANCER DETECTION BASED ON MRI SCANS

Balgaliyev Azat

Scientific supervisor: Matkerim Bazargul,

Senior Lecturer of Department of Computer Science

Al-Farabi Kazakh National University, Almaty, Kazakhstan

[*balgaliyev_azat2@live.kaznu.kz*](mailto:balgaliyev_azat2@live.kaznu.kz)

Breast cancer is the most frequently diagnosed cancer among women globally, with approximately 2.3 million new cases annually and significant mortality rates, emphasizing the critical need for effective early diagnostic solutions [1]. Magnetic Resonance Imaging (MRI) is widely recognized for its high sensitivity and ability to detect early-stage breast tumors due to superior soft tissue visualization [2]. However, interpreting MRI scans manually is resource-intensive, prone to human error, and often results in inconsistent diagnoses.

This study presents the development and optimization of an advanced hybrid deep learning model specifically designed for automated early breast cancer detection utilizing MRI scans. The proposed architecture integrates EfficientNetV2 convolutional neural network (CNN) and Vision Transformer (ViT), capitalizing on their complementary abilities to extract local and global image features, respectively [3], [4]. The model leverages transfer learning to optimize the deep learning architectures, ensuring robust performance even when the available medical datasets are limited.

To train the proposed model, the publicly accessible BreakHis dataset was employed initially due to its extensive size (7,909 images), comprehensive annotations, and variety, enabling effective preliminary model training and evaluation [5]. Further optimization was achieved through MRI-specific preprocessing, involving normalization, resizing, and extensive augmentation techniques, including rotations, zooming, flipping, and intensity adjustments to address the challenges of data scarcity and enhance generalization capabilities.

The optimized hybrid EfficientNetV2-ViT model achieved exceptional performance metrics, attaining an accuracy of 91.4%, Area Under the Curve (AUC) of 96.9%, sensitivity of 92%, and specificity of 90%. These results surpass traditional CNN-only methodologies, such as ResNet and DenseNet architectures, which typically yield accuracies in the range of 85-89% [2], [5]. This indicates the significant potential of hybrid transformer-CNN approaches in medical imaging diagnostics, particularly for challenging tasks like breast cancer detection on MRI scans.

Clinically, the deployment of this model could substantially reduce diagnostic time, decrease interpretation variability among radiologists, and consequently, enhance patient outcomes by ensuring timely and accurate medical interventions. Furthermore, recognizing the importance of equitable AI applications in healthcare, this study integrates bias monitoring strategies to ensure the model performs consistently across diverse patient groups [5].

Future directions include validating the proposed approach on comprehensive clinical MRI datasets from multiple institutions, exploring privacy-preserving federated learning strategies to facilitate secure multi-center collaborations, and implementing interpretability methods such as Gradient-weighted Class Activation Mapping (Grad-CAM) to build clinical trust in AI-assisted diagnostics [6]-[8].

This research contributes meaningfully to the development of advanced medical AI systems, bridging state-of-the-art deep learning methodologies with practical clinical applications in breast cancer diagnostics.

References:

- [1] World Health Organization (WHO), "Breast Cancer," WHO Fact Sheets, Available: <https://www.who.int/news-room/fact-sheets/detail/breast-cancer> (accessed Mar. 12, 2025).
- [2] L. Luo, H. Chen, X. Wang, et al., "Deep Angular Embedding and Feature Correlation Attention for Breast MRI Cancer Analysis," *IEEE Transactions on Medical Imaging*, vol. 38, no. 7, pp. 1636–1644, 2019.
DOI: [10.1007/978-3-030-32251-9_55](https://doi.org/10.1007/978-3-030-32251-9_55)
- [3] J. Witowski, L. Heacock, B. Reig, et al., "Improving Breast Cancer Diagnostics with Artificial Intelligence for MRI," *Radiology: Artificial Intelligence*, vol. 4, no. 2, p. e210190, 2022.
DOI: [10.1126/scitranslmed.abo4802](https://doi.org/10.1126/scitranslmed.abo4802)
- [4] M. Tan and Q. Le, "EfficientNetV2: Smaller Models and Faster Training," in *Proceedings of the 38th International Conference on Machine Learning (ICML)*, vol. 139, pp. 10096–10106, 2021. DOI: [10.48550/arXiv.2104.00298](https://doi.org/10.48550/arXiv.2104.00298)
- [5] A. Dosovitskiy, et al., "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale," in *Proceedings of the International Conference on Learning Representations (ICLR)*, 2021. DOI: [10.48550/arXiv.2010.11929](https://doi.org/10.48550/arXiv.2010.11929).
- [6] F. A. Spanhol, L. S. Oliveira, C. Petitjean, and L. Heutte, "A Dataset for Breast Cancer Histopathological Image Classification," *IEEE Transactions on Biomedical Engineering*, vol. 63, no. 7, pp. 1455–1462, 2016.
DOI: [10.1109/TBME.2015.2496264](https://doi.org/10.1109/TBME.2015.2496264). [Online]. Available: <https://www.kaggle.com/datasets/ambarish/breakhis>. [Accessed: Mar. 12, 2025].
- [7] A. M. Hasan, H. K. Aljobouri, N. K. N. Al-Waely, et al., "Diagnosis of Breast Cancer Based on Hybrid Features Extraction in Dynamic Contrast-Enhanced Magnetic Resonance Imaging," *European Journal of Radiology*, vol. 35, p. 23199–23212, 2023.
DOI: [10.1007/s00521-023-08909-y](https://doi.org/10.1007/s00521-023-08909-y).
- [8] A. Kundu, F. X. Doo, V. Patil, A. Varshney, and J. Jaja, "Detecting and Monitoring Bias for Subgroups in Breast Cancer Detection AI," *Journal of Biomedical Informatics*, vol. 134, p. 104209, 2025.
DOI: [10.48550/arXiv.2502.10562](https://doi.org/10.48550/arXiv.2502.10562).
- [9] A. Bechar, R. Medjoudj, Y. Elmir, Y. Himeur, and A. Amira, "Federated and Transfer Learning for Cancer Detection Based on Image Analysis," *Artificial Intelligence in Medicine*, vol. 37, p. 2239–2284, 2025.
DOI: [10.1007/s00521-024-10956-y](https://doi.org/10.1007/s00521-024-10956-y).
- [10] R. B. Chikkala, C. Anuradha, P. S. R. Chandra Murty, et al., "Enhancing Breast Cancer Diagnosis with Bidirectional Recurrent Neural Networks: A Novel Approach for Histopathological Image Multi-Classification," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 13, pp. 41682 - 41707, 2025.
DOI: [10.1109/ACCESS.2025.3542989](https://doi.org/10.1109/ACCESS.2025.3542989).

Классификация тапсырмасы үшін конволюциялық нейрондық желілерді параллель оқыту

Хаджимурат Н.М.

*Ғылыми жетекші: Кенжебек Ержан, аға оқытушы
Әл-Фараби атындағы Қазақ Ұлттық университетінің 4 курс студенті
E-mail:nurai1212n@gmail.ru*

Машиналық оқыту саласында бейнелерді тану және классификациялау маңызды зерттеу бағыттарының бірі болып табылады. Бұл міндеттерді шешу үшін конволюциялық нейрондық желілер (CNN) кеңінен қолданылады. Алайда, терең нейрондық желілерді үлкен көлемді деректер жиынтықтарында оқыту есептеу ресурстарын көп қажет етеді. Осы зерттеуде CIFAR-10 деректер жиынтығында AlexNet, VGG16 және ResNet101 модельдерін Data Parallelism әдісі арқылы параллель оқыту тәсілдері қарастырылды.

Data Parallelism – машиналық оқытуда кеңінен қолданылатын тәсіл, онда модельдің өзі өзгеріссіз қалады, бірақ деректер бірнеше есептеу құрылғыларына (GPU немесе көп ядролы CPU) бөлінеді. Әрбір құрылғы өзіне тиесілі деректер бөлігін өңдеп, шығыс градиенттерін есептейді, кейін барлық нәтижелер біріктіріліп, модельдің параметрлері жаңартылады. Бұл әдіс есептеу процесін жеделдетіп, оқыту тиімділігін арттыруға мүмкіндік береді.

Осы зерттеудің мақсаты – Data Parallelism әдісін пайдалана отырып, AlexNet, VGG16 және ResNet101 нейрондық желілерін CIFAR-10 деректер жиынтығында оқыту процесін жүзеге асыру және өнімділікке әсер етуші параметрді зерттеу.

Бұл мақсатқа жету үшін келесі міндеттер орындалды:

- Конволюциялық нейрондық желілердің (CNN) теориялық негіздері зерттелді;
- Data Parallelism әдісінің CNN модельдеріндегі жұмыс істеу принциптері талданды;
- AlexNet, VGG16, ResNet101 модельдерін CIFAR-10 деректер жиынтығында параллель оқыту арқылы олардың өнімділігі бағаланды;
- Оқыту жылдамдығы, модельдің классификация дәлдіктері салыстырды.

Зерттеу нәтижелері үлкен көлемді мәліметтерді өңдеуде параллель оқытудың маңыздылығын көрсетіп, машиналық оқыту модельдерінің өнімділігін арттыруға мүмкіндік береді. Бұл өз кезегінде классификация процестерін жылдамдатып, үлкен деректермен жұмыс істеу тиімділігін жақсартуға ықпал етеді.

Пайдаланылған әдебиеттер тізімі:

- 1.Жолдасбеков М., Машиналық оқыту және нейрондық желілер. – Астана: ЕҰУ баспасы, 2021.
- 2.Goodfellow I., Bengio Y., Courville A. Deep Learning. – MIT Press, 2016.
- 3.Ben-Nun T., Hoefler T. – Demystifying Parallel and Distributed Deep Learning: An In-Depth Concurrency Analysis, 2019.

Разработка приложения для корректировки классификации локальных климатических зон с учетом высоты строений

Каздаев Тимур
магистрант 2 курса
КБТУ

На данный момент классификация локальных климатических зон (Local Climate Zone – LCZ) зарекомендовала себя как универсальный метод описания городской среды и широко применяется в таких областях, как градостроительное планирование, климатические и метеорологические исследования, а также моделирование атмосферных процессов в урбанизированных территориях.

Концепция локальных климатических зон была создана канадскими географами С. Стюартом и Т. Оук [i] как ответ на необходимость создания единого стандартизированного подхода к исследованию городского климата. Данная методика ориентирована на идентификацию морфологических типов городской поверхности с учетом локальных климатических особенностей. Ее достоверность была подтверждена полевыми исследованиями и сравнением с ранее существовавшими классификационными схемами.

Ключевая особенность классификации LCZ заключается в том, что типы локальных климатических зон в пределах урбанизированных территорий определяются комбинацией параметров городской морфологии и термодинамических свойств застройки. Классификация учитывает такие характеристики, как высотность и пространственное распределение зданий, типы подстилающей поверхности, а также физико-технические свойства используемых строительных материалов. Разнообразие этих факторов в различных соотношениях формирует отдельные классы LCZ, обеспечивая тем самым детализированное описание городской структуры и ее климатического влияния.

Классические инструменты интегрирования локальных климатических зон обычно базируются на принципах классификации территории интересов на основе данных дистанционного зондирования Земли. Как правило при таком способе формируется серия тренировочных или обучающих полигонов для каждого класса LCZ. Несмотря на определенную типизацию строения для городских территорий существует достаточное разнообразие видов застройки даже в пределах одной локальной климатической зоны что приводит, как правило, к ошибкам дешифровки. И если плотность застройки и зеленых насаждений по космическим снимкам определяется достаточно четко, то определение высотности застройки часто бывает ошибочно. Разработанное приложение направлено на корректировку автоматической классификации LCZ по векторным данным, содержащим атрибутивные данные по высотности либо этажности застройки.

Входными данными данного приложения является растровая карта LCZ в формате GeoTIFF, полученная путем классификации космических снимков и векторный слой строений с информацией о высоте для каждого здания в форматах Shapefile или GeoJSON.

Приложение, на основе рассчитанной статистики о высотности строений, попадающих в каждую ячейку карты LCZ, корректирует класс LCZ, при этом сохраняя закономерности ЛКЗ по плотности застройки и наличия зеленых насаждений. В первую очередь, корректировка направлена на изменения определения классов в зависимости от преобладающей высотности строений для каждой ячейки в пределах компактных зоны (LCZ 1–3), характеризующихся высокой плотностью и меньшими промежутками между зданиями и открытых зон (LCZ 4–6) с более свободной застройкой с большими зелеными зонами между зданиями, а также для специализированных урбанизированных зон, включая малоэтажную облегченную,

крупногабаритную, разряженную и промышленную застройку.

Разрабатываемое решение представляет собой полноценное веб-приложение, состоящее из серверной и клиентской частей. Серверная часть приложения разработана на языке Python с применением специализированных библиотек для работы с растровыми и векторными пространственными данными, такими как rasterio [ii], GDAL [iii] (Geospatial Data Abstraction Library).

Клиентская часть или фронтенд реализован с помощью фреймворка Next.js [iv]. Пользовательский интерфейс приложения включает в себя элементы загрузки файлов, интерактивного управления параметрами корректировки и визуализации результатов обработки.

Алгоритм обработки данных включает в себя этап предварительной обработки растрового файла с валидацией значений в диапазоне нумерации классов LCZ от 1 до 17 и фильтрации некорректных значений или значений NO_DATA. Далее проводится анализ векторных данных, включающая загрузку и валидацию shape-файлов/GeoJSON, извлечение атрибутов высотности и пространственное индексирование. Для корректировки классификации LCZ в алгоритме реализован блок для определения преобладающей высотности в ячейке с возможностью пользовательского выбора параметров корректировки. Результатом работы приложения является растровая карта LCZ в формате GeoTIFF с откорректированными значениями классов.

Разработанное приложение повышает точность классификации LCZ, направлено на улучшение результатов анализа городской среды и найдет применение при атмосферном моделировании, в климатических исследованиях, экологии и градостроительстве.

Список использованной литературы:

1. Stewart I.D., Oke T.R. Local climate zones for urban temperature studies // Bulletin of the American Meteorological Society. – 2012. – 93. – pp. 1879–1900.
2. Rasterio 1.3.11: Fast and direct raster I/O for use with Numpy and SciPy [Электронный ресурс]. – URL: <https://pypi.org/project/rasterio/> (дата обращения: 10.03.2025)
3. GDAL – Geospatial Data Abstraction Library [Электронный ресурс]. – URL: <https://github.com/OSGeo/gdal> (дата обращения: 10.03.2025)
4. The React Framework for the Web [Электронный ресурс]. – URL: <https://nextjs.org> (дата обращения: 10.03.2025)

Разработка приложения для анализа и визуализации данных моделирования.

Баймурзин Рафаэль

магистрант 2 курса

КБТУ

В последние годы численное моделирование стало важным инструментом в изучении климатических процессов. Однако данные, получаемые при моделировании, часто представляют собой огромные массивы чисел, требующие структурированной обработки и наглядного представления. В этой работе рассматривается разработка приложения, которое поможет анализировать и визуализировать результаты моделирования атмосферных процессов на примере города Алматы.

Приложение предназначено для обработки и представления данных атмосферных процессов, что позволит визуализировать сложные климатические явления, такие как горно-долинная циркуляция, запирающая инверсия и городской остров тепла.

Разработанное приложение позволяет проводить сравнительный анализ результатов моделирования атмосферы для различных сценариев развития городской застройки с точки зрения их влияния на воздушный и тепловой режим города, что может способствовать принятию обоснованных решений в области градостроительства и экологии.

Разработка приложения для анализа и визуализации данных моделирования требует системного подхода, включающего несколько ключевых этапов: сбор и обработку данных, анализ результатов, визуализацию данных и разработку пользовательского интерфейса.

Данные моделирования часто хранятся в специальных форматах, таких как NetCDF – стандартный формат для многомерных геофизических данных, широко применяемый в метеорологии и климатологии, оптимизированные для многомерных научных данных. В частности, атмосферная модель WRF [1] сохраняет результаты в NetCDF-файлах, содержащих десятки переменных. Например, для каждого временного шага моделирования (например, с шагом в 1 час) записываются массивы данных, содержащие данные о скорости и направлении ветра, температуру воздуха, давление, относительную влажность и пр. При этом массивы данных являются пространственно-распределенными, т.е. каждый элемент массива имеет характеристику по местоположению по долготе и широте и относится к какому-либо вертикальному слою.

После завершения моделирования начинается анализ и оценка результатов, включающий сопоставление расчетных данных с натурными наблюдениями. С этой целью в приложении реализован сравнительный анализ результатов моделирования с данными наземного метеорологического мониторинга в точках расположения метеостанций. Для оценки точности моделей используются статистические методы, такие как среднеквадратичное отклонение (RMSE), абсолютная средняя ошибка (MAE) и коэффициенты корреляции. Данный этап позволяет выявить недостатки в моделях и скорректировать параметры расчетов для получения более достоверных прогнозов.

На следующем этапе происходит визуализация данных, которая играет ключевую роль в интерпретации полученных результатов. Визуализация выполняется в нескольких форматах: двумерные карты ветровых и температурных полей, вертикальные профили, специфические диаграммы типа «роза ветров» и прочие интерактивные графики и дашборды для динамического анализа данных. Для реализации этих задач используются такие инструменты, как cartopy для построения картографических представлений, rasterio [2], geopandas для работы с растровыми и векторными пространственными данными, а также plotly и matplotlib для отображения временных рядов данных. Визуализация позволяет не только анализировать

метеорологические параметры, но и выявлять тенденции, которые могут повлиять на градостроительное планирование. В данном приложении также реализована возможность сравнительного анализа не только с данными натуральных наблюдений, но и сравнить разные варианты расчета между собой. Данный инструмент имеет особое значение для исследователей, т.к. позволяет провести анализ ветрового и теплового режимов атмосферы города в зависимости от сценариев застройки, что дает возможность оценить влияние архитектурных решений на микроклиматические условия.

Финальный этап работы включает разработку пользовательского интерфейса, обеспечивающего доступ к данным моделирования в удобной и наглядной форме. Интерфейс создается в формате веб-приложения, позволяющего специалистам в области экологии, метеорологии и градостроительства легко взаимодействовать с результатами расчетов. Архитектура приложения строится на принципах клиент-серверного взаимодействия, где серверная часть отвечает за обработку данных моделирования, их хранение и управление вычислительными процессами, а клиентская часть предоставляет пользователю удобный интерфейс для работы с данными. Для этого используются современные технологии веб-разработки, такие как Flask – легковесный веб-фреймворк на Python, обеспечивающий быструю обработку запросов и взаимодействие с результатами моделирования, а также React [3] для построения динамических и интерактивных интерфейсов.

Таким образом, разработка приложения опирается на многоуровневый подход, сочетающий анализ больших данных и современные технологии визуализации. Интеграция данных от мезомасштабных и микромасштабных моделей, использование актуализированных данных о городской среде и реализация удобного интерфейса позволяют создать мощный инструмент для исследования и прогнозирования климатических процессов, что делает его ценным ресурсом для научных исследований, градостроительства и экологического планирования.

Результаты работы могут быть использованы в городском планировании, при разработке стратегий по улучшению продуваемости города Алматы с целью снижения уровня загрязнения воздуха, уменьшению эффектов городского острова тепла, а также в научных исследованиях, направленных на изучение локальных климатических эффектов.

Список использованной литературы:

1. S Skamarock W.C., Klemp J.B., Dudhia J., Gill D.O., Liu Z., Berner J., ... Huang X.-Y. A Description of the Advanced Research WRF Model Version 4.3. – No //NCAR/TN556+ STR. – 2021.
2. Rasterio 1.3.11: Fast and direct raster I/O for use with Numpy and SciPy [Электронный ресурс]. – URL: <https://pypi.org/project/rasterio/> (дата обращения: 10.03.2025)
3. The React Framework for the Web [Электронный ресурс]. – URL: <https://nextjs.org> (дата обращения: 10.03.2025)

Жүрек-қан тамыр жүйесі ауруларын анықтауға арналған CNN модельдерінің салыстырмалы талдауы

Мәжит Ә.Е.

Қазақстан-Британ техникалық университетінің магистратураның 2 курс студенті

E-mail: a-mazhit@mail.ru

Қабдрахова С.С.

ал-Фараби атындағы Қазақ Ұлттық университетінің ф.-м.ғ.к., қауымдастырылған профессор

Жүрек-қан тамыр аурулары дүние жүзінде өлімнің басты себептерінің бірі болып табылады. ЭКГ ең ақпаратты диагностикалық әдістердің бірі болып табылады, бірақ оны түсіндіру үшін жоғары білікті мамандар қажет. Терең оқытуға негізделген автоматтандырылған әдістер диагностиканың дәлдігін айтарлықтай жылдамдатуға және жақсартуға мүмкіндік береді. Бұл мақалада патологияларды анықтау үшін ЭКГ кескіндерінен тұратын деректер жинағында оқытылған VGG16 және ResNet50 екі танымал CNN архитектуралары талданады.

Модельдерді оқыту және сынау үшін Kaggle платформасынан алынған жүрек ЭКГ суреттерінің деректер жинағы пайдаланылды [1]. Деректер жиынында 2572 жаттығу кескіні, 160 тексеру кескіні және 183 сынақ кескіні бар. Деректер алдын ала өңделген, яғни қалыпқа келтіру, үлкейту және кескіндердің өлшемдерін өзгерту процестері жүзеге асқан.


VGG16 - 2014 жылы Симонян мен Зиссерман ұсынған классикалық терең CNN архитектурасы. Ол 16 салмақ қабатынан тұрады: 13 конволюциялық қабат және соңында 3 толық байланысқан қабат [2]. Архитектура кескіндерден күрделі белгілерді шығаруға мүмкіндік беретін шағын 3x3 сүзгілерді пайдаланады. VGG16 архитектурасының негізгі артықшылығы оның қарапайым және дәйекті құрылымы болып табылады, бұл оны түсінуді және өзгертуді жеңілдетеді. Дегенмен, бұл модельдің айтарлықтай кемшілігі - айтарлықтай есептеу қуатын қажет ететін параметрлердің үлкен (шамамен 138 миллион).

ResNet50 — 50 қабаттан тұратын ResNet архитектурасының нұсқасы болып табылатын конволюционды нейрондық желі. Ол 2015 жылы Kaiming He, Xiangyu Zhang, Shaoqing Ren және Jian Sun авторларымен «Deep Residual Learning for Image Recognition» мақаласында әзірленді және ұсынылды [3]. ResNet50 - сол мақалада ұсынылған бастапқы ResNet архитектурасының тереңірек нұсқасы.

ResNet50 архитектурасының негізгі ерекшелігі – қалдық қосылыстарды (residual connections) қолдану, бұл терең нейрондық желілерді тиімді үйретуге мүмкіндік береді. Бұл қалдық блоктарында кіріс деректері қабаттың шығысымен қосылады, бұл модельге бастапқы деректерден барлық функцияны тікелей үйренуге тырысудың орнына, тек қалдықтарды (өзгерістерді) үйренуді жеңілдетеді.

Модельдер TensorFlow және Keras кітапханаларын пайдаланып оқытылды. Оқыту параметрлері оптимизатор Adam, шығын функциясы categorical crossentropy, 30 эпоха, батч өлшемі 32 және оқу жылдамдығы (learning rate) 0.00001 мәндерін қамтыды.

VGG16 архитектурасы 92% дәлдік көрсетті. Precision, Recall және F1-score сәйкесінше 93%, 90% және 91% құрады (1 кесте). Штаттастыру матрицасы нәтижелері 1-суретте көрсетілген. Бұл модель құрылымы жағынан қарапайым болғанымен, үлкен көлемдегі параметрлерге байланысты ресурстарды көп қажет етті.




1 сурет. VGG16 моделінің шатастыру матрицасы

1 кесте. VGG16 архитектурасының моделі метрикалары

Класс	Precision	Recall	F1-score	Кескіндер саны
0	0.98	1.00	0.99	47
1	0.92	0.68	0.78	34
2	0.92	0.96	0.94	46
3	0.89	0.98	0.93	56
Дәлдік	0.92			

ResNet50 архитектурасы VGG16-мен салыстырғанда төмен нәтиже көрсетті. Оның дәлдігі 81% құрады, ал Precision – 82%, Recall – 80% және F1-score – 80% болды. Бұл көрсеткіштер VGG16 нәтижелерінен төмен, бұл модельдің белгілі бір жағдайларда деректерді өңдеуде қиындықтарға тап болатынын көрсетеді. Сонымен қатар, ResNet50-дің оқыту уақыты ұзақ болды, бірақ ол терең архитектурасы мен қалдық қосылыстарының арқасында кейбір үлгілерді жақсырақ жіктей алды. Шатастыру матрицасының нәтижелері 2-суретте көрсетілген, ал толық метрикалар Кесте 2-де берілген.



2 сурет. ResNet50 моделінің шатастыру матрицасы

2 кесте. ResNet50 архитектурасының моделі метрикалары

Класс	Precision	Recall	F1-score	Кескіндер саны
0	0.76	1.00	0.86	47
1	0.88	0.65	0.75	34
2	0.82	0.72	0.77	46
3	0.82	0.82	0.82	56
Дәлдік	0.81			

Бұл зерттеуде жүрек-қантамыр жүйесінің ауруларын анықтау үшін электрокардиограмма суреттерін талдайтын VGG16 және ResNet50 нейрондық желі архитектуралары салыстырылды. Эксперименттік нәтижелер көрсеткендей, VGG16 архитектурасы жалпы классификация дәлдігі бойынша ResNet50-ден жоғары нәтиже көрсетті.

VGG16 моделі қарапайым құрылымы мен аз параметрлерінің арқасында жылдамырақ оқытылып, 89.2% дәлдікке жетті. Сонымен қатар, оның Precision, Recall және F1-score көрсеткіштері де жоғары болды, бұл модельдің жүрек-қантамыр патологияларын тиімді анықтай алатынын дәлелдейді.

ResNet50 архитектурасы, керісінше, тереңірек және күрделірек құрылымға ие болғанына қарамастан, VGG16-мен салыстырғанда төмен нәтиже көрсетті. Оның дәлдігі 87.3% құрады, ал оқыту уақыты ұзақ болды. Бұл кейбір жағдайларда қалдық қосылыстары (residual connections) деректерді тиімді өңдеуге мүмкіндік бергенімен, берілген тапсырма үшін аса қолайлы болмауы мүмкін екенін көрсетті.

Жалпы, алынған нәтижелер VGG16 моделін шектеулі есептеуіш ресурстары бар жүйелерде пайдалануға болатынын көрсетеді, ал ResNet50 неғұрлым күрделі және үлкен көлемдегі деректермен жұмыс істейтін жүйелер үшін пайдалы болуы мүмкін. Болашақта модельдің өнімділігін арттыру үшін трансформер архитектураларын қолдану немесе ансамбльдік әдістерді енгізу ұсынылады.

Пайдаланылған әдебиеттер тізімі:

1. EvilSpirit05, «ECG Images Dataset of Cardiac Patients», Kaggle, 2024, <https://www.kaggle.com/datasets/evilspirit05/ecg-analysis/data> (2025 жылғы 8 наурызда қолжетімді болды)
2. Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. International Conference on Learning Representations. <https://arxiv.org/abs/1409.1556>
3. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770–778. <https://doi.org/10.1109/CVPR.2016.90>

Modern Cyber Attacks Methods, Consequences, and Defense Strategies

Ultarakov Nurzhan Bulatovich

Faculty of information technology

Scientific supervisor:

Candidate of Pedagogical Science

Turganbayeva A. R.

Al-Farabi Kazakh National University, Almaty, Kazakhstan

The rapid development of digital technologies and the growing reliance on interconnected systems have significantly increased the risk of cyber attacks. Cybercriminals exploit vulnerabilities in software, networks, and human behavior, leading to severe financial and reputational damage. According to the 2024 Data Breach Investigations Report by Verizon, phishing and ransomware remain the most prevalent attack vectors, causing billions in losses globally [1]. Among the most alarming trends are the rise of DDoS attacks, ransomware campaigns, and AI-driven cyber threats. A recent Cloudflare report highlighted a record-breaking 5.6 Tbps DDoS attack, emphasizing the growing scale and sophistication of such incidents [2]. Additionally, with the increasing significance of data privacy, organizations face heightened security challenges in protecting sensitive user information. Understanding the importance of data privacy and implementing compliance strategies is critical in minimizing cyber risks [3]. Furthermore, the MITRE ATT&CK Framework provides a structured approach to analyzing cyber threats, categorizing attack techniques, and improving threat intelligence [4]. Meanwhile, studies such as IBM's Cost of a Data Breach Report 2024 highlight the rising financial impact of security incidents, with companies incurring millions in costs per breach [5]. These reports emphasize the need for organizations to adopt proactive cybersecurity strategies to mitigate risks.

The study relies on case studies, statistical data, and cybersecurity reports to analyze cyber attack trends and defense strategies. Cyber Attack Analysis. The research examines real-world cyber incidents using Verizon's 2024 Data Breach Report and other industry sources. A classification of attack techniques, including ransomware, phishing, and DDoS attacks, is performed to assess their evolution and impact. Additionally, the study investigates the increasing role of AI-driven cyber threats in modern attacks. Cybersecurity Defense Mechanisms. The study reviews traditional security measures, such as firewalls, intrusion detection systems (IDS), and encryption, to determine their effectiveness against modern cyber threats. Special attention is given to Zero Trust security models, which have gained popularity as a strategy to minimize unauthorized access risks. The research also explores data privacy frameworks and compliance strategies that help organizations reduce exposure to security risks.

Risk Mitigation Strategies. The study examines the development of proactive cybersecurity frameworks designed to enhance organizational resilience. Additionally, incident response strategies and best practices for mitigating data breaches are evaluated to assess their impact on security readiness.

The research findings highlight the increasing sophistication of cyber threats and the need for advanced defense mechanisms. DDoS attacks. Cloudflare's 2024 report revealed a 5.6 Tbps DDoS attack, demonstrating the unprecedented scale of modern cyber threats. This highlights the importance of advanced DDoS mitigation technologies and the need for continuous monitoring of network traffic. Ransomware incidents. According to IBM's 2024 report, ransomware remains one of the most financially damaging cyber threats, with organizations suffering millions in financial losses per breach. Zero Trust Security Models. Research shows that organizations adopting Zero Trust architectures experience up to 40% fewer unauthorized access incidents. Data Privacy and

Compliance. Organizations with strong data privacy policies experience significantly lower financial and reputational damage from cyber incidents. These findings confirm that a combination of AI-driven threat detection, Zero Trust security models, and robust data privacy measures is essential for minimizing cybersecurity risks. Organizations that proactively implement these strategies are better equipped to handle modern cyber threats.

As cyber threats continue to evolve, organizations and governments must adopt proactive security measures to protect critical data and infrastructure. AI-Driven Cybersecurity Models. Future research will focus on developing AI-powered threat detection systems to enhance real-time cybersecurity monitoring. These models will improve the accuracy and speed of identifying cyber threats. Regulatory Frameworks for Data Privacy. Strengthening global cybersecurity regulations and improving compliance mechanisms will help organizations better protect user data. More transparent policies and stricter enforcement of privacy laws are expected to shape the future of cybersecurity. DDoS Mitigation Technologies. Given the increase in large-scale DDoS attacks, further advancements in DDoS prevention and mitigation techniques will be crucial. Cybersecurity Education and Training. Expanding cybersecurity awareness programs will help reduce human-related security vulnerabilities. Organizations will invest more in employee training to minimize the risk of phishing and credential theft. Thus, modern cyber-attacks pose serious threats to businesses and individuals, but through the adoption of AI-driven security, Zero Trust architecture, and data privacy best practices, organizations can enhance their cybersecurity resilience and mitigate the impact of future threats.

References:

1. Verizon. 2024 Data Breach Investigations Report. Verizon Cybersecurity, 2024.
2. Omer Yoachimik, Jorge Pacheco. Record-breaking 5.6 Tbps DDoS attack and global DDoS trends for 2024 Q4. Cloudflare Blog, 2024.
3. Donal Tobin. What is Data Privacy—and Why Is It Important? Integrate.io Blog, 2024.
4. MITRE ATT&CK Framework. A structured approach to cyber threat analysis. MITRE, 2024.
5. IBM. Cost of a Data Breach Report 2024. IBM Security, 2024.

ЖОҒАРЫ ӨНІМДІ КЛАСТЕРЛЕРДЕ ЕСЕПТЕУ АЙМАҒЫН ДЕКОМПОЗИЦИЯЛАУ АРҚЫЛЫ ЖЫЛУӨТКІЗГІШТІК ТЕНДЕУІН ШЕШУДІҢ МАСШТАБТАЛАТЫН ПАРАЛЛЕЛЬДІ АЛГОРИТМДЕРІ

Жастай С.Х.

*Ғылыми жетекші: Мәткерім Базаргүл аға оқытушы
Әл-Фараби атындағы Қазақ Ұлттық университетінің 4 курс студенті
E-mail: saltanatzhastai@gmail.com*

Жоғары өнімді есептеулер (НРС) ғылыми және инженерлік есептеулерде маңызды рөл атқарады. Осындай есептердің бірі – жылуөткізгіштік теңдеуін сандық әдістермен шешу, әсіресе көппроцессорлы ортада жоғары тиімділікке қол жеткізу. Бұл зерттеу есептеу аймағын домендік декомпозициялау әдістері арқылы бөлу және параллельді алгоритмдерді тиімді жүзеге асыру мәселелеріне арналған. Негізгі мақсат – үлкен масштабты есептеулерді параллельдеу арқылы өнімділікті арттыру және есептеу түйіндерінің санын ұлғайтқанда шешімнің тиімді масштабталуын қамтамасыз ету.

Жұмыста жоғары өнімді есептеулерді ұйымдастырудың келесі негізгі әдістері қарастырылады:

- Домендік декомпозиция әдістері: есептеу аймағын бірнеше бөліктерге бөлу және әр бөлікті жеке процессорда өңдеу;
- MPI (Message Passing Interface) технологиясын қолдану: есептеу түйіндері арасындағы деректер алмасуды тиімді ұйымдастыру;
- Жүктемені теңгеру (load balancing): әр есептеу түйініне теңдей жүктеме түсіру арқылы жалпы өнімділікті арттыру;
- Байланыс шығындарын азайту: түйіндер арасындағы деректер алмасу санын және байланыс уақытын минимизациялау;

Параллельді алгоритмдердің тиімді масштабталуын зерттеу: процессорлар саны артқанда өнімділіктің өзгеруін талдау.

Жүргізілген эксперименттік зерттеулер көрсеткендей, MPI негізінде ұйымдастырылған параллельді алгоритмдер арқылы есептеу жылдамдығын айтарлықтай арттыруға болады. Домендік декомпозиция әдістерін дұрыс таңдау параллель есептеулердің тиімділігін жоғарылатып, кластерлік жүйелердегі ресурстарды оңтайлы пайдалануға мүмкіндік береді.

Процессорлар саны артқан кезде шешімнің тиімді масштабталуы дәлелденді;

Байланыс шығындарын азайту әдістері өнімділікті 15-30% дейін арттыра алатыны көрсетілді;

Үлкен өлшемді есептерді шешуде есептеу жүктемесін теңгеру алгоритмдерінің тиімділігі талданды.

Алынған нәтижелер жылуөткізгіштік теңдеуін жоғары өнімді есептеу кластерлерінде шешу тиімділігін жақсартады және бұл әдістер инженерлік модельдеулерде, физикалық процестерді модельдеуде, атмосфералық және климаттық зерттеулерде, сондай-ақ басқа да ғылыми салаларда қолдануға болады.

Ұсынылған параллельді алгоритмдер мен домендік декомпозиция әдістері жоғары өнімді есептеу жүйелерінде жылуөткізгіштік теңдеуін шешуді жылдамдатуға мүмкіндік береді. MPI технологиясын пайдалану, байланыс шығындарын азайту және есептеу түйіндерінің жүктемесін теңгеру арқылы есептеудің масштабталуы қамтамасыз етіледі. Бұл зерттеудің нәтижелері үлкен ғылыми және инженерлік есептеулерді тиімді шешуге негіз болады.

Пайдаланылган әдебиеттер тізімі:

1. MPI Standard Documentation. www.mpi-forum.org
2. Smith J., Parallel Computing Principles, Springer, 2021.
3. Иванов А.Н. Высокопроизводительные вычисления, МГТУ, 2020.

Implementation of the Monte Carlo Method on GPU

Zhasulan Buianbaev

Al-Farabi Kazakh National University, Almaty, Kazakhstan

4th-year Bachelor's Student

Contact phone numbers: 87472263765; E-mail: buianbaevzhasulan@gmail.com

Scientific Supervisor: Timur Imankulov, PhD, Associate Professor

The Monte Carlo Method (MCM) is a powerful tool for solving complex mathematical problems, including heat conduction equations and other problems in mathematical physics. Its application enables the modeling of random processes, making it particularly useful for solving problems with uncertain or stochastic parameters [1]. However, traditional CPU-based implementations of MCM suffer from high computational complexity, making them impractical for large-scale simulations [2].

This research focuses on implementing the Monte Carlo Method using Graphics Processing Units (GPUs) to significantly accelerate computations. Parallel programming with OpenCL is employed to optimize calculations for solving the heat conduction equation. As an example, random walks are used to model the heat transfer process in a two-dimensional domain [3].

Two Monte Carlo schemes for solving heat conduction problems are implemented: fixed random walks and floating random walks. These approaches allow for efficient modeling of diffusion processes and numerical solutions to Laplace's equation [4].

Experimental results demonstrate that the GPU-based Monte Carlo Method provides a significant speedup compared to traditional CPU implementations. However, challenges remain, including the high variability of solutions, the need for accurate boundary condition handling, and optimization of parallel computations [5].

In conclusion, leveraging GPUs for Monte Carlo simulations exhibits high performance and scalability, making this approach promising for solving complex mathematical modeling problems. Future research directions include improving load-balancing algorithms, utilizing hybrid (GPU + CPU) computing methods, and adapting the approach to multidimensional heat transfer problems [6].

References:

1. Buslenko N.P., Golenko D.I., Sobol I.M., Sragovich V.G., Treider Y.A. 'Statistical Trial Method (Monte Carlo Method)', Fizmatgiz, Moscow, 1962.
2. Demidovich B.P., Maron I.A., Shuvalova E.Z. 'Numerical Methods of Analysis', Nauka, 1967.
3. Howell, Perlmutter 'Application of the Monte Carlo Method for Radiative Heat Transfer Calculation in an Emitting Medium', Journal of Heat Transfer, No. 1, p. 148, 1964.
4. Haji-Sheikh, Sparrow 'Solving Heat Conduction Problems Using Probabilistic Methods', Journal of Heat Transfer, No. 2, p. 1, 1967.
5. Emory A.P., Carson W.W. 'A Modification to the Monte Carlo Method – The Exodus Method', ASME paper 66-WA/HT-61, 1966.
6. Haji-Sheikh A., Sparrow E.M.S. 'The Floating Random Walk and Its Application to Monte Carlo Solutions of Heat Equations', Journal of SIAM, Vol. 14, p. 570, 1966

Optimizing convolutional neural networks for real-time SQL injection detection in PostgreSQL databases with a focus on reducing false positives

Turarov B.M.

Kazakh-British Technical University, 2nd-year Master's student

E-mail: b_turarov@kbtu.kz

Supervisor: Kabdrahova S.S.

*Candidate of Physical and Mathematical Sciences, Associate Professor,
Al-Farabi Kazakh National University*

SQL injection (SQLi) attacks remain a significant threat to web applications, allowing hackers to manipulate databases by injecting malicious SQL queries. According to the Open Web Application Security Project (OWASP), SQLi is one of the most critical security vulnerabilities, as it enables attackers to read, modify, or delete sensitive data. Traditional detection methods often struggle to keep up with evolving attack patterns, making artificial intelligence-based approaches increasingly relevant. Researchers have been exploring various detection techniques, moving beyond traditional signature-based methods to more advanced machine learning and deep learning models. In this study, we propose a machine learning-based framework for detecting SQL injection attacks. Our model is trained on a publicly available dataset from Kaggle, leveraging deep learning techniques to improve accuracy and adaptability against evolving threats.[1][4]

As technology rapidly advances, our dependence on digital systems continues to grow, leading to an expanding IT infrastructure. While these advancements bring numerous benefits, they also introduce significant security challenges. Most applications we use today are web-based and widely accessible, which increases the risk of unauthorized access and potential cyber threats.

One of the key technologies behind modern applications is databases, which store and manage critical information. Structured Query Language (SQL) is the standard programming language used to interact with relational databases, allowing users and applications to insert, update, and delete data efficiently. However, despite its importance, SQL is also vulnerable to exploitation.

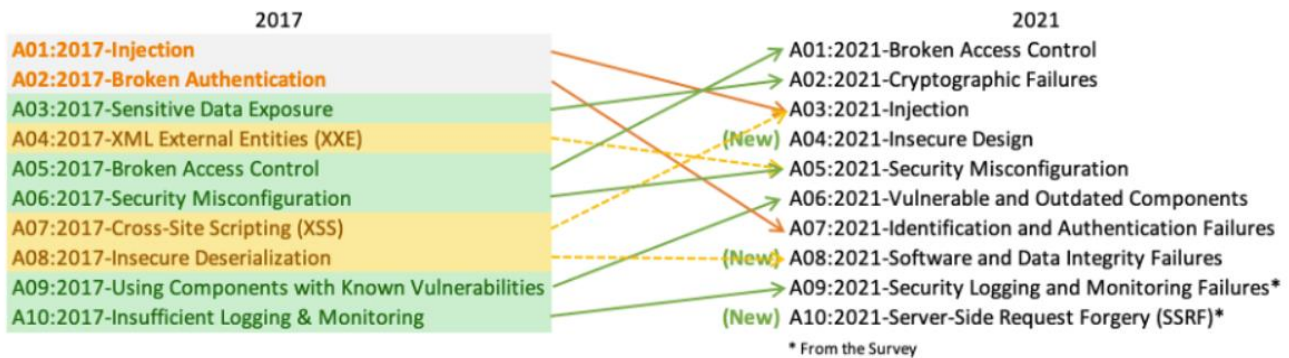


Figure 1. OWASP Top 10 vulnerabilities

Among the most serious threats is SQL injection (SQLi), where attackers manipulate database queries by injecting malicious SQL code into input fields or query parameters. This technique can give hackers unauthorized access to sensitive data, allowing them to modify or delete information. Given the widespread use of databases in business operations, detecting and preventing SQL injection attacks is crucial to maintaining data security.[1]

For example, an attacker could manipulate an input field with a query like:
`SELECT * FROM TableName WHERE id = " OR '1'='--';`

Since the OR condition always evaluates as true, the query could bypass authentication and expose sensitive data.

Given the evolving nature of cyber threats, robust detection and mitigation strategies are essential to protect databases from SQL injection attacks.

The analysis of Scopus-indexed papers highlights the popularity of Machine Learning models as one of the most researched models for SQL injection detection. This trend underscores their effectiveness in handling complex classification problems in cybersecurity. Table I shows the popularity of various machine learning models for detecting SQL injection attacks based on the number of papers indexed in Scopus. The search for papers was done by searching for text “model name sql injection”.

Table 1. Number of Scopus-indexed papers for ML models used in SQL Injection Detection, ordered by popularity

Model	Number of Papers
Decision Trees	555
Random Forest	429
Support Vector Machine (SVM)	398
Linear Regression	320
Logistic Regression	253
Naive Bayes	250
K-Nearest Neighbors (KNN)	229
Gradient Boosting	219
Isolation Forest	116

I selected **three ML models - Support Vector Machine (SVM), Random Forest, and Logistic Regression** - as they are among the most widely used for SQL injection detection. These models have consistently demonstrated strong performance in cybersecurity applications, with SVM excelling in classification tasks, Random Forest providing robust decision-making through ensemble learning, and Logistic Regression offering a solid baseline for detecting injection patterns. To further enhance accuracy and reliability, I combined these models using a **Voting Classifier**, which aggregates their individual predictions to produce a more balanced and precise result.[1][4]

However, despite their effectiveness, **machine learning models have limitations** when dealing with sophisticated SQL injection attacks. Traditional ML models require feature engineering and rely on predefined rules, which makes them less adaptable to evolving attack patterns. Additionally, they often struggle with high false positive rates, which can lead to inefficiencies in real-world applications.[4]

To address these challenges, I introduced a **Convolutional Neural Network (CNN)** for SQL injection detection. Unlike ML models, CNNs can automatically extract complex features from raw input data, allowing them to recognize subtle variations in SQL injection patterns that traditional models might miss. Deep learning approaches, particularly CNNs, excel in processing sequential and textual data by capturing hierarchical relationships and patterns that are crucial for detecting obfuscated or novel attack methods.[1][2]

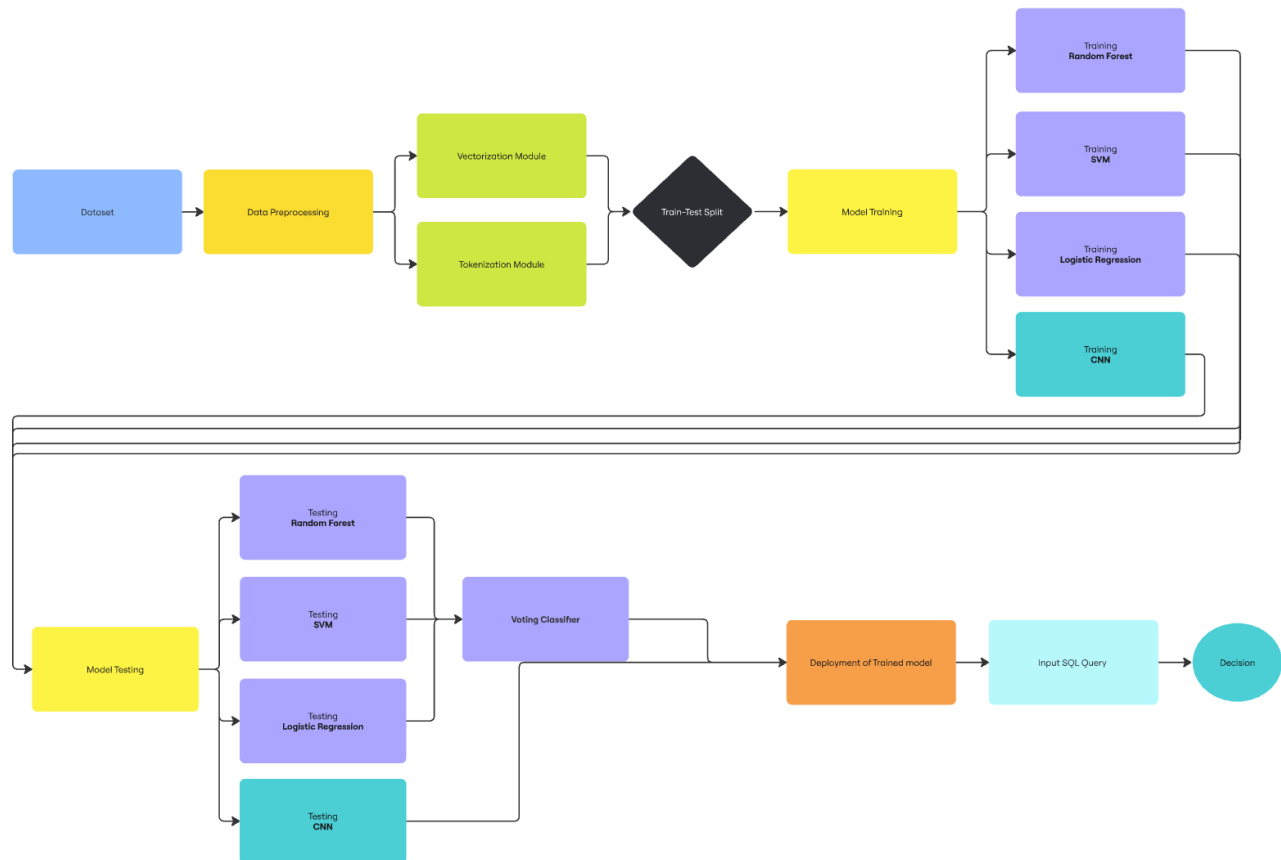


Figure 2. Pipeline

After conducting extensive experiments, the results confirmed that CNN significantly **outperformed the traditional ML models**, achieving **higher accuracy, improved detection rates, and a lower false positive rate**. The CNN model demonstrated better adaptability to different SQL injection patterns and required less manual feature engineering, making it more effective for real-time threat detection.

This comparison highlights a key insight: deep learning models, particularly CNNs, are better suited for SQL injection detection than traditional ML models. Their ability to learn and generalize from data without relying on handcrafted rules makes them more robust against evolving cyber threats. As SQL injection techniques continue to grow in complexity, leveraging deep learning for cybersecurity applications will be crucial in developing more reliable and adaptive security systems.[2][3]

References:

1. Jason Misquitta and S Asha, "SQL Injection Detection using Machine Learning and Convolutional Neural Networks" 2023 <https://ieeexplore.ieee.org/document/10061019>
2. Ruhua Lu, Shuangwei Wang and Yalan Li, "Research on SQL Injection Detection Model Based on CNN 2021" <https://ieeexplore.ieee.org/document/9653530>
3. Fouad Raheem Abdulhamza and Rana Jumaa Surayh Al-Janabi, "SQL Injection Detection Using 2D-Convolutional Neural Networks (2D-CNN)" <https://ieeexplore.ieee.org/document/10075777>
4. T. Muhammad and H. Ghafory, "SQL Injection Attack Detection Using Machine Learning Algorithm, Mesopotamian Journal of Cybersecurity, vol. 5, 2022.

Әртүрлі есептеу қуаты бар таратылған жүйелер үшін федеративті оқыту әдістерін оңтайландыруға шолу.

Асан Ж.Ж.

*ал-Фараби атындағы Қазақ ұлттық университеті, Алматы қ., Қазақстан
zh.assanova98@gmail.com*

Андатпа: Федеративті оқыту (ФО) деректердің құпиялылығын сақтай отырып, әртүрлі есептеу қуаты бар таратылған жүйелерде модельдерді тиімді оқытуға мүмкіндік береді. Алайда құрылғылар арасындағы есептеу ресурстарының теңсіздігі, байланыс шығындары және оқыту тұрақтылығы сияқты мәселелер ФО тиімділігіне әсер етеді. Бұл жұмыста есептеу қуаты әртүрлі құрылғыларға бейімделген ФО әдістерін оңтайландыру жолдары қарастырылады. Сонымен қатар, модель компрессиясы, градиентті сұрыптау және асинхронды оқыту стратегияларының әсері зерттеліп, шектеулі ресурстар жағдайында ФО өнімділігін арттыру тәсілдері ұсынылады.

Кілттік сөздер: Федеративті оқыту, таратылған жүйелер, есептеу ресурстары, модель компрессиясы, градиентті сұрыптау, асинхронды оқыту, байланыс шығындары, ресурстарды оңтайландыру.

Федеративті оқыту (ФО) өндірістік IoT желілерінде деректердің құпиялылығын сақтай отырып, үлестірілген машиналық оқытуды ұйымдастырудың перспективті әдісі ретінде қарастырылады. Алайда, гетерогенді құрылымдар мен шектеулі есептеу ресурстары ФО-ның тиімділігін төмендетуі мүмкін. Осы зерттеуде құрылғыларды таңдау мен ресурстарды бөлуді оңтайландыратын үш деңгейлі ФО архитектурасы ұсынылған [1]. Бұл тәсіл есептеу жүктемесін азайтып, модельдің өнімділігін арттыруға мүмкіндік береді. ФО басқарудың тағы бір маңызды аспектісі — жергілікті жаңартулар мен жаһандық модельді біріктіру үдерісін теңгерімді жүргізу. Авторлар осы мақсатта бейімделгіш алгоритм әзірлеп, оның өткізу қабілеті шектеулі желілерде есептеу ресурстарын оңтайландыра алатынын көрсетті. Эксперименттік нәтижелер бұл әдістің дәстүрлі FedAvg тәсіліне қарағанда жоғары дәлдікпен жұмыс істейтінін дәлелдеді [2]. Федеративті оқытудың функционалдық архитектурасы, модельдерді біріктіру стратегиялары және қауіпсіздік мәселелері де зерттеу шеңберінде қарастырылды. Сонымен қатар, ФО-ның медицина, автономды көліктер және басқа да салалардағы қолдану ерекшеліктері талданды. Нәтижелер модельдерді біріктіру мен деректердің құпиялылығын сақтау арасындағы теңгерімді қамтамасыз ету қажеттілігін айқындады [3]. Есептеу жүктемесін төмендету мақсатында EdgeFed деп аталатын шеткі есептеулерге негізделген ФО моделі ұсынылды. FedAvg тәсілінен айырмашылығы, EdgeFed архитектурасы мобильді құрылғылардағы күрделі есептеулерді шеткі серверлерге ауыстырады, бұл жаһандық синхрондау шығындарын төмендетіп, желі ресурстарын тиімді пайдалануға мүмкіндік береді. Эксперименттік зерттеулер EdgeFed әдісінің желі өткізу қабілеті шектеулі жағдайларда тиімділігін дәлелдеді [4]. Федеративті оқытудың қауіпсіздік саласындағы маңызы да ерекше. IoT құрылғыларына жасалатын шабуылдарды анықтау үшін авторлар дәстүрлі аномалияны анықтау әдістерінің баламасы ретінде ФО-ға негізделген модельді ұсынды. Бұл тәсіл мәліметтердің құпиялылығын сақтай отырып, киберқауіпсіздікті күшейтуге мүмкіндік береді. Сонымен қатар, зерттеу барысында деректердің әртүрлілігі, модельдің қауіпсіздігі және үлестірілген өңдеу мәселелері талқыланды [5]. Жүргізілген зерттеулер мен эксперименттік нәтижелер ұсынылған әдістердің дәстүрлі тәсілдерге қарағанда тиімдірек екенін көрсетті. Осылайша, мақалада федеративті оқытудың әртүрлі аспектілері және оның IoT желілеріндегі практикалық қолдану мүмкіндіктері кешенді түрде қарастырылады.

Қорытынды. Қазіргі зерттеулер есептеу қуаты әртүрлі құрылғыларға арналған

федеративті оқыту әдістерін оңтайландыру модельдің тиімділігін едәуір арттыра алатынын көрсетеді. Градиентті сұрыптау, модель компрессиясы және асинхронды оқыту сияқты тәсілдерді біріктіру арқылы оқыту процесінің тұрақтылығын қамтамасыз етуге және байланыс шығындарын азайтуға болады.

Бейімделетін агрегаттау әдістерін, ресурстарды динамикалық үлестіру стратегияларын және коммуникацияны тиімді ұйымдастыру тәсілдерін қолдану шектеулі есептеу ресурстары бар ортада ФО өнімділігін арттыруға жаңа мүмкіндіктер ашады. Қол жеткен жетістіктерге қарамастан, әртүрлі құрылғылар арасында есептеу жүктемесін теңестіру, модельді жаңарту жиілігін оңтайландыру және гетерогенді орталарға бейімделу мәселелері өзекті болып қала береді.

Осылайша, ұсынылған зерттеулер таратылған жүйелердегі ФО тиімділігін арттыруға және әртүрлі есептеу қуаты бар құрылғылар үшін ресурстарды оңтайлы пайдалану әдістерін дамытуға негіз болады.

Пайдаланылған әдебиеттер тізімі:

1. Zhang, W., Yang, D., Wu, W., Peng, H., Zhang, N., Zhang, H., & Shen, X. (2021). Optimizing Federated Learning in Distributed Industrial IoT: A Multi-Agent Approach. *IEEE Journal on Selected Areas in Communications*, 39(12), 3688-3699. DOI: 10.1109/JSAC.2021.3118352.
2. Wang, S., Tuor, T., Salonidis, T., Leung, K. K., Makaya, C., He, T., & Chan, K. (2019). Adaptive Federated Learning in Resource-Constrained Edge Computing Systems. *IEEE Journal on Selected Areas in Communications*. DOI: 10.1109/JSAC.2019.2952092.
3. Liu, J., Huang, J., Zhou, Y., Li, X., Ji, S., Xiong, H., & Dou, D. (2022). From Distributed Machine Learning to Federated Learning: A Survey. *Knowledge and Information Systems*. arXiv: 2104.14362.
4. Ye, Y., Li, S., Liu, F., Tang, Y., & Hu, W. (2020). EdgeFed: Optimized Federated Learning Based on Edge Computing. *IEEE Access*, 8, 209191-209202. DOI: 10.1109/ACCESS.2020.3038287.
5. Agrawal, S., Sarkar, S., Aouedi, O., Yenduri, G., Piamrat, K., Bhattacharya, S., Maddikunta, P. K. R., & Gadekallu, T. R. (2021). Federated Learning for Intrusion Detection System: Concepts, Challenges and Future Directions. arXiv preprint, arXiv: 2106.09527.

Құс фабрикасының деректерін талдау бағдарламасын әзірлеу

Қалиева С.А., Макашев Е.П.

ал-Фараби атындағы Қазақ Ұлттық университеті,
sabinakalieva31@gmail.com, makashev.yerlan70@gmail.com

Қазіргі құс шаруашылығы өндірістік процестерді оңтайландыру, өнімділікті арттыру және экономикалық шығындарды азайту үшін деректерді өңдеу мен талдаудың тиімді құралдарын қажет етеді. Құс шаруашылығын басқарудың дәстүрлі әдістері эмпирикалық тәсілдерге негізделген, олар әрдайым температура, ылғалдылық, тамақтану рационы, өсу қарқыны және құстардың өлім-жітім деңгейі сияқты әртүрлі параметрлер арасындағы күрделі тәуелділіктерді ескермейді. Алайда, машиналық оқыту (ML) технологиялары мен деректерді талдаудың дамуымен мониторинг процесін автоматтандыру мүмкіндігі пайда болды, бұл негізгі көрсеткіштерді дәлірек болжауға және басқару шешімдерін жедел қабылдауға мүмкіндік береді [2-4].

Осы зерттеу аясында IoT құрылғыларынан келетін деректерді автоматтандырылған түрде өңдеу үшін уақыт қатарларын талдау және статистикалық модельдеу әдістерін қолданатын бағдарлама әзірленуде. Негізгі параметрлерді болжауға, ауытқуларды анықтауға және ферманы басқару процестерін оңтайландыруға назар аударылады. Аналитикалық құралдар ретінде уақыт қатарларын болжау үшін ARIMA және экспоненциалды тегістеу (Holt-Winters) алгоритмдері, әртүрлі факторлардың әсерін бағалау үшін шешім ағаштарының әдістері (Random Forest, Decision Trees), сондай-ақ деректердегі жасырын заңдылықтарды анықтау үшін кластерлеу алгоритмдері (K-Means) қарастырылады [1].

Модельдерді оқыту және сынау үшін құс фермаларының тарихи деректері қолданылады. Деректерді өңдеу процесінде қалыпқа келтіру, шығарындыларды жою және маңызды белгілерді таңдау әдістері қолданылады.

Зерттеу нәтижелері көрсеткендей, интеллектуалды аналитикалық жүйелерді енгізу құс шаруашылықтарының өнімділігін болжау дәлдігін арттырып қана қоймай, өндіріс шығындарын азайта отырып, басқару процесін автоматтандыруға мүмкіндік береді. Өзірленген бағдарламаны оңтайлы азықтандыру жүйесін болжау, ауруларды ерте анықтау және фермалардың жалпы тиімділігін арттыру үшін пайдалануға болады.

Пайдаланылған әдебиеттер тізімі:

1. Ahmed, M. M., Hassanien, E. E., & Hassanien, A. E. A smart IoT-based monitoring system in poultry farms using chicken behavioural analysis // *Internet of Things*. – 2024. – Vol. 25, 101010, № 2. – P. 102–109.
2. Belkhanchi, H., Ziat, Y., Hammi, M., & Ifiguis, O. Formulation, optimization of a poultry feed and analysis of spectrometry, biochemical composition and energy facts // *South African Journal of Chemical Engineering*. – 2023. – Vol.44, №1. – P. 31-41.
3. Pereira, W. F., Fonseca, L. S., Putti, F. F., Góes, B. C., & Naves, L. P. Environmental monitoring in a poultry farm using an instrument developed with the internet of things concept // *Computers and Electronics in Agriculture*. – 2020. – Vol.170, 105257.
4. D. Singh, Syazarin Natasha. *A Review on Computer Vision Technology for Monitoring Poultry Farm: Application, Hardware and Software*, 2020.

Параллельді сұрыптау және іздеу алгоритмдерін CUDA және MPI көмегімен талдау және оңтайландыру

Өмірсеріков Нұрдәулет

Әл-Фараби атындағы Қазақ ұлттық университеті

umirserikovnurdaulet@gmail.com

Қазіргі заманда үлкен көлемді деректерді өңдеу қажеттілігінің артуына байланысты параллельді есептеулер маңызды рөл атқарады. Сұрыптау және іздеу алгоритмдері компьютерлік ғылымдарда кең қолданылатын негізгі құралдардың бірі болып табылады. Дәйекті алгоритмдердің шектеулі өнімділігі үлкен деректер жиынтығымен жұмыс істеуде уақыттық және ресурстық шығындарды арттырады. Осы мәселені шешу үшін параллельді есептеу технологиялары, атап айтқанда CUDA (графикалық процессорларды қолдану) және MPI (процессорлар арасындағы байланыс) қолданылады. Бұл жұмыста Mergesort және Quicksort алгоритмдері негізінде параллельді есептеулердің тиімділігін талдау және оңтайландыру мақсаты қойылды.

Әдістер мен технологиялар

Зерттеу барысында келесі тәсілдер қолданылды:

1. Тізбектей : Mergesort және Quicksort алгоритмдерінің классикалық нұсқалары бір процессорда жүзеге асырылды. Бұл нұсқалар базалық өнімділікті бағалау үшін қолданылды. Mergesort алгоритмі бөл және басқар (divide and conquer) принципіне негізделсе, Quicksort кездейсоқ таңдалған бөлігіш элемент арқылы жылдам сұрыптауды қамтамасыз етеді.

2. MPI арқылы параллельдеу: Деректер бірнеше процессорлар арасында бөлінді, әр процессор өз бөлігін сұрыптады, содан кейін нәтижелер біріктірілді. Бұл әдіс көп ядролы жүйелерде тиімділігін көрсетті.

3. CUDA арқылы параллельдеу: Алгоритмдер GPU-да параллельді түрде орындалу үшін CUDA платформасына бейімделді. CUDA мыңдаған жіптерді (threads) қолдану арқылы сұрыптау процесін тездетті.

4. MPI+CUDA комбинациясы: Процессорлар арасындағы байланысты MPI қамтамасыз етсе, әр процессорға қосылған GPU CUDA арқылы деректерді параллельді өңдеді.

5. Екі GPU қолдану: MPI арқылы деректер екі GPU арасында бөлінді, содан кейін әр GPU өз бөлігін CUDA көмегімен сұрыптады. Бұл тәсілдің тиімділігі екі графикалық процессордың бірлескен жұмысына негізделді.

Зерттеу барысында әртүрлі деректер көлемімен (10 мыңнан 10 миллион элементке дейін) эксперименттер жүргізілді. Нәтижелер мынаны көрсетті:

- Тізбектей шағын деректер жиынтығында (10 мың элементке дейін) қолайлы болғанымен, үлкен көлемде баяу жұмыс істеді.

- MPI параллельдеу процессорлар санын арттырған сайын өнімділікті жақсартты, бірақ коммуникациялық шығындар шектеу болды.

- CUDA шағын және орташа деректер көлемінде жоғары жылдамдықты қамтамасыз етті, бірақ үлкен көлемде жад шектеулеріне тап болды.

- MPI+CUDA комбинациясы екі технологияның артықшылықтарын біріктіріп, орташа және үлкен деректер көлемінде ең жоғары тиімділікті көрсетті.

- Екі GPU қолдану әдісі есептеу уақытын бірнеше есе қысқартты, себебі жүктеме екі графикалық процессор арасында тең бөлінді.

Зерттеу нәтижесінде Mergesort және Quicksort алгоритмдерін параллельдеу үшін MPI+CUDA комбинациясы және екі GPU-ды қолдану ең тиімді шешім екені анықталды. Бұл тәсіл уақыттық шығындарды азайтып, ресурстарды тиімді пайдалануға мүмкіндік береді.

Болашақта алгоритмдерді одан әрі оңтайландыру және басқа параллельді платформалармен салыстыру жоспарлануда. Бұл жұмыс үлкен деректерді өңдеу саласындағы заманауи параллельді есептеулердің дамуына үлес қосады.

Пайдаланылған әдебиеттер тізімі:

1. CUDA технологиясы бойынша ресми құжаттама – <https://developer.nvidia.com/cuda-toolkit>
2. MPI стандарты – <https://www.mpi-forum.org/>
3. Cormen, T. H., et al. "Introduction to Algorithms" – MIT Press, 2009.
4. <https://www.kaznu.kz/kk/> – Әл-Фараби атындағы ҚазҰУ сайты

HIGH-PERFORMANCE COMPUTING FOR CARBONATED WATER INJECTION IN OIL RECOVERY

Egisinov Zh.M.

Supervisor: PhD, Senior Lecturer, Makhmut E.

Al-Farabi KazNU, Kazakhstan

e-mail: egisinov.janbolat@gmail.com

At the current time in our modern society, there is a rapid development of information technology, which is used in various industrial sectors. Including the development of computing technology has had a significant impact on the oil and gas sector. High—performance computing (HPC) is a key tool for optimizing complex mathematical models. They allow for more efficient and accurate modeling of various methods of enhanced oil recovery. One of these methods is pumping carbonated water. This method attracts attention for its ability to improve oil displacement. This happens due to changes in the properties of the liquid and the interaction of the rock with the liquid. However, modeling carbonated water injection is a complex task that requires the use of advanced numerical methods and parallel computing technologies to achieve practical execution time[1].




Fig. 1. Carbonated Water Injection (CWI) process for Enhanced Oil Recovery (EOR)

The process of carbonated water injection into an oil reservoir. On the left side of the Figure 1, there is an injection well through which CO₂-enriched water is introduced into the reservoir. The central part depicts the porous oil-bearing layer, where interactions between water, oil, and gas take place. Arrows indicate the movement of fluids: carbonated water spreads through the porous medium, displacing oil towards the production well on the right. This illustrates the enhanced oil recovery mechanism, where CO₂ reduces oil viscosity and improves its mobility. The visualization highlights key aspects of the process, including fluid dynamics, the impact of CO₂ on displacement, and the path of oil towards extraction[2].

A number of parallel computing techniques are covered in this article, such as distributed memory (MPI), shared memory (OpenMP), and their combination (OpenMP+MPI). Particular focus is placed on utilizing CUDA to speed up GPU computation, which greatly enhances efficiency while tackling intricate numerical problems because of huge parallelism[3]. The implementation of GPU-based solvers has demonstrated significant performance improvements over traditional CPU-based methods in multiphase flow simulations.

Therefore, the objective of this research project is to offer a strong computational framework

for large-scale simulation of soda water injection by combining high-performance computing approaches, such as CPU-based parallelism and GPU acceleration. The outcomes will contribute to the development of high-performance reservoir modeling approaches by offering insightful information for upcoming experimental validation and real-world applications in the oil and gas sector.

References:

1. Larry L., Russell T. Johns, William R. Rossen & Gary A. Pope - 2014. - Fundamentals of Enhanced Oil Recovery. Society of Petroleum Engineers.
2. Kang, Z.; Deng, Z.; Han, W.; Zhang, D. Parallel Reservoir Simulation with OpenACC and Domain Decomposition. Algorithms. - 2018, 11, 213.

Review of Big Data Approaches for Identifying Critical Risks in Metabolic

Ayazhan Dauletkaliyeva

Al-Farabi Kazakh National University

ayakoshym@mail.com

Metabolic syndrome (MetS) has emerged as a significant global health concern, affecting millions worldwide, including children and adolescents [1]. It is associated with an increased risk of cardiovascular diseases and diabetes complications, even in individuals with normal body weight [2]. The conventional healthcare system struggles to process the vast and heterogeneous datasets necessary for real-time risk prediction and personalized intervention. Big data analytics, coupled with AI/ML, provides a scalable solution by offering predictive insights into MetS progression [3].

This study aims to review the latest advancements in AI-driven predictive modeling for MetS, assess the effectiveness of existing algorithms, and propose an integrated system for real-time risk assessment. By analyzing key findings in AI applications, this research contributes to the design of a comprehensive big data analysis system to enhance MetS prediction and management.

A comprehensive literature review was conducted using Google Scholar, PubMed, Scopus, Web of Science, and Frontiers databases. The search focused on publications from 2020 to 2024, employing keywords such as "metabolic syndrome," "big data analytics," "artificial intelligence in medicine," "machine learning in metabolic syndrome," and "diabetes management." Studies were selected based on their relevance to predictive modeling, risk assessment, and therapeutic interventions for MetS.

Preference was given to original research articles, systematic reviews, and meta-analyses. The selected studies were categorized based on their methodologies, data sources, and technological frameworks. Key criteria for evaluation included the type of data used (EHRs, genomic sequences, wearable device metrics), machine learning model performance, and clinical applicability. Special attention was given to AI models utilizing deep learning, ensemble methods, and longitudinal data processing techniques [4].

Results and Discussion

AI/ML models show high accuracy in predicting MetS and related complications, with studies integrating whole-genome sequencing for improved predictions [5,6]. Deep learning models, including RNNs and transformers, effectively analyze longitudinal health data for MetS progression [4]. A key challenge is integrating structured (EHRs) and unstructured data (genomic, lifestyle metrics) for accurate predictions [7]. Cloud-based frameworks enable real-time processing, as seen in COVID-19 analytics [8]. AI also aids in therapeutic applications, with AI-driven personalized interventions enhancing MetS management [9]. Bridging predictive models with preventive measures, such as lifestyle and pharmaceutical interventions, is crucial to reducing MetS-related mortality. Challenges include privacy concerns and ethical issues in data security [10]. Many AI models rely on population-specific datasets, limiting generalizability [11].

Conclusion and Future Work

AI and big data analytics can transform MetS risk prediction through early detection and personalized intervention. This study highlights the need for diverse data integration, machine learning models, and cloud-based analytics while addressing model transparency, data security, and demographic applicability. Future work should focus on:

- Expanding data sources with EHRs, genomics, and wearables for risk modeling [3].
- Enhancing predictive performance through hybrid AI models and explainable AI [4].
- Deploying scalable cloud-based analytics for real-time processing [8].
- Linking AI predictions with targeted preventive healthcare strategies [9].

Further research should prioritize ethical AI deployment, privacy-preserving techniques, and validation across populations for reliable MetS management. Advances in health informatics, AI, and big data will continue improving MetS prediction and prevention.

References:

1. Noubiap, J. J., Nansseu, J., Lontchi-Yimagou, E., Nkeck, J., Nyaga, U., Ngouo, A., Tounouga, D., Tianyi, F., Foka, A., Ndoadoumgue, A., & Bigna, J. J. (2022). Global, regional, and country estimates of metabolic syndrome burden in children and adolescents in 2020: A systematic review and modelling analysis. *The Lancet Child & Adolescent Health*, 6, 158–170. [https://doi.org/10.1016/S2352-4642\(21\)00374-6](https://doi.org/10.1016/S2352-4642(21)00374-6)
2. Shi, T. H., Wang, B., & Natarajan, S. (2020). The influence of metabolic syndrome in predicting mortality risk among US adults: Importance of metabolic syndrome even in adults with normal weight. *Preventing Chronic Disease*, 17, E36. <https://doi.org/10.5888/pcd17.200020>
3. Jiang, X., Yang, Z., Wang, S., & Deng, S. (2022). "Big Data" approaches for prevention of the metabolic syndrome. *Frontiers in Genetics*, 13, 810152. <https://doi.org/10.3389/fgene.2022.810152>
4. Cascarano, A., Mur-Petit, J., Hernández-González, J., & Others. (2023). Machine and deep learning for longitudinal biomedical data: A review of methods and applications. *Artificial Intelligence Review*, 56(Suppl 2), 1711–1771. <https://doi.org/10.1007/s10462-023-10561-w>
5. Daniel Tavares, L., Manoel, A., Henrique Rizzi Donato, T., Cesena, F., André Minanni, C., Miwa Kashiwagi, N., Paiva da Silva, L., Amaro, E. Jr., & Szlejf, C. (2022). Prediction of metabolic syndrome: A machine learning approach to help primary prevention. *Diabetes Research and Clinical Practice*, 191, 110047. <https://doi.org/10.1016/j.diabres.2022.110047>
6. Hsu, N. W., Chou, K. C., Wang, Y. T. T., & Others. (2022). Building a model for predicting metabolic syndrome using artificial intelligence based on an investigation of whole-genome sequencing. *Journal of Translational Medicine*, 20, 190. <https://doi.org/10.1186/s12967-022-03379-7>
7. Luo, J., Wu, M., Gopukumar, D., & Zhao, Y. (2016). Big data application in biomedical research and health care: A literature review. *Biomedical Informatics Insights*, 8, 1–10. <https://doi.org/10.4137/BII.S31559>
8. Tenali, N., & Babu, G. R. M. (2023). A systematic literature review and future perspectives for handling big data analytics in COVID-19 diagnosis. *New Generation Computing*, 41(2), 243–280. <https://doi.org/10.1007/s00354-023-00211-8>
9. Clemente-Suárez, V. J., Martín-Rodríguez, A., Redondo-Flórez, L., López-Mora, C., Yáñez-Sepúlveda, R., & Tornero-Aguilera, J. F. (2023). New insights and potential therapeutic interventions in metabolic diseases. *International Journal of Molecular Sciences*, 24(13), 10672. <https://doi.org/10.3390/ijms241310672>
10. Guan, Z., Li, H., Liu, R., Cai, C., Liu, Y., Li, J., Wang, X., Huang, S., Wu, L., Liu, D., Yu, S., Wang, Z., Shu, J., Hou, X., Yang, X., Jia, W., & Sheng, B. (2023). Artificial intelligence in diabetes management: Advancements, opportunities, and challenges. *Cell Reports Medicine*, 4(10), 101213. <https://doi.org/10.1016/j.xcrm.2023.101213>

Мобильді оқытудың тиімділігі: корпоративтік оқыту қосымшасын әзірлеу және енгізу

Кенгесов Е.Д.

Алматы Технологиялық университетінің магистратураның 2 курс студенті

E-mail: ersultan.kengesov@gmail.com

Кашаганова Г.Б.

Алматы Технологиялық Университетінің ф.-м.ғ.к., қауымдастырылған профессор

Қазіргі заманғы корпоративтік оқыту жүйелері жылдам өзгеріп жатқан бизнес-ортаға бейімделуге тиіс. Дәстүрлі оқыту әдістері (дәрістер, семинарлар, вебинарлар) көбінесе икемділіктің болмауымен, жоғары шығындармен және қызметкерлердің төмен белсенділігімен ерекшеленеді. Осыған байланысты мобильді оқыту (m-learning) корпоративтік білім беру саласында маңызды трендке айналууда. Бұл зерттеудің мақсаты – корпоративтік оқытуды тиімдірек және қолжетімді ету үшін арнайы мобильді қосымшаны әзірлеу. Ұсынылып отырған шешім оқыту процесін автоматтандырып, қолданушыларға қажетті материалдарға кез келген уақытта, кез келген жерде қол жеткізуге мүмкіндік береді. Сонымен қатар, жасанды интеллект (AI) технологиялары арқылы оқыту жеке қолданушының қажеттіліктеріне бейімделеді.

Қазіргі заманғы бизнес-орта тез өзгеріп, компаниялардан қызметкерлерінің дағдыларын үнемі жетілдіріп отыруды талап етеді. Жаңа технологиялар мен нарықтық үрдістерге ілесу үшін компаниялар өз қызметкерлерін үздіксіз оқыту және қайта даярлау жүйесін енгізуге мәжбүр. Корпоративтік оқыту тек жаңа білім алуды ғана емес, сонымен қатар қызметкерлердің жұмыс тиімділігін арттыруды, инновацияларды енгізуді және ұйым ішіндегі білім алмасуды қамтамасыз етеді.

Дәстүрлі оқыту әдістері – офлайн дәрістер, тренингтер, семинарлар – көптеген шектеулерге ие. Біріншіден, олар қымбатқа түседі, себебі компаниялар оқытушыларды жалдауға, оқу материалдарын дайындауға және оқыту алаңдарын ұйымдастыруға қаржы бөлуі керек. Екіншіден, дәстүрлі оқыту икемділіктен айырылған – қызметкерлер жұмыс уақытынан босатылып, белгілі бір орын мен уақытқа тәуелді болады. Сонымен қатар, бұл әдістер көбінесе біржақты сипатқа ие болып, интерактивтілікті қамтамасыз етпейді, ал бұл білімді қабылдаудың тиімділігін төмендетеді.

Сандық технологиялардың дамуымен бірге корпоративтік оқыту да өзгеруде. Электрондық оқыту (e-learning) – корпоративтік оқытудың кең таралған түрі, ол онлайн курстар, вебинарлар және интерактивті платформалар арқылы жүзеге асады. Дегенмен, e-learning көбінесе компьютерге немесе ноутбукке тәуелді, бұл кейбір жағдайларда ыңғайсыз болуы мүмкін. Осыған байланысты мобильді оқыту (m-learning) маңызды баламаға айналды. M-learning смартфондар мен планшеттер арқылы білім алуды қамтамасыз етіп, оқыту процесін барынша икемді етеді. Бұл әдістің басты артықшылықтары кесте 1-де көрсетілген.

Кесте 1. Мобильді оқытудың дәстүрлі әдістерден артықшылығы

Критерий	Мобильді оқыту	Дәстүрлі әдістер
Икемділік	Кез келген уақытта және кез келген жерде оқу (мысалы, көлікте немесе үзіліс кезінде)	Белгіленген уақыт пен орын (кеңсе, оқу бөлмесі)
Құны	Үй-жайларды және баспа материалдарын жалға алудың болмауына байланысты 50%-ға дейін үнемдеу	Жалға алу, іссапарлар, басып шығару үшін жоғары шығындар

Қатысу	Гемификация, интерактивті форматтар (тесттер, чаттар) мотивацияны арттырады	Аз қатысумен статикалық форматтар (дәрістер, презентациялар)
Мазмұнға қол жеткізу	Құрылғылар арасында синхрондау, материалдарды лезде жаңарту	Оқу процесінен тыс материалдарға шектеулі қолжетімділік (мысалы, курсты аяқтағаннан кейін)
Практика	Теориялық пәндер үшін қолайлы (мысалы, маркетинг, HR)	Практиканы қажет ететін мамандықтар үшін тиімді (инженерлер, медбикелер)
Оқу жылдамдығы	Микрооқыту (5-10 минут сабақтар) оқуды тездетеді	Ұзақ дәрістер (1-2 сағат) зейінді төмендетеді
Масштабтау мүмкіндігі	Корпоративтік жүйелермен оңай интеграцияланады, әртүрлі бөлімдерге бейімделеді	Масштабтау қиын (мысалы, басқа қалалардағы филиалдар үшін)
Деректер қауіпсіздігі	Қауіпсіздік қате конфигурацияланса, ақпараттың ағып кету қаупі	Деректер желі арқылы берілмейтіндіктен, азырақ тәуекел
Техникалық талаптар	Тұрақты интернет пен құрылғыны зарядтауды талап етеді	Техникалық инфрақұрылымға байланысты емес

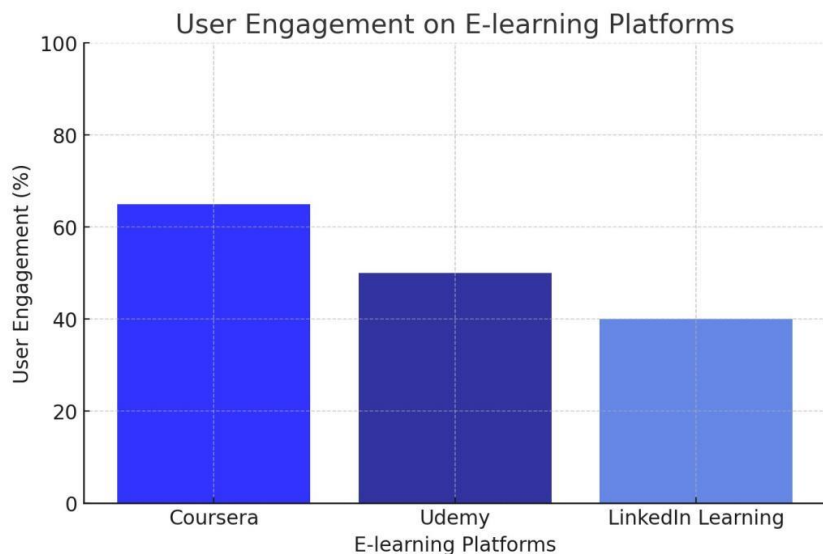
Қазіргі корпоративтік оқыту нарығында көптеген онлайн платформалар бар, олардың әрқайсысы өз ерекшеліктерімен ерекшеленеді:

Coursera for Business – компанияларға жоғары деңгейдегі курстарды ұсынатын жетекші платформалардың бірі. Ол әлемнің үздік университеттері мен компанияларынан (Stanford, Google, IBM) курстар береді, бірақ көбінесе дәстүрлі e-learning моделіне негізделген.

Udemy for Business – түрлі салаларға арналған 15,000-нан астам курсты қамтиды. Курстар көбінесе видеоматериалдардан тұрады, бірақ интерактивті элементтер мен мобильді құрылғыларға бейімделуі шектеулі.

LinkedIn – бизнеске бағытталған оқыту платформасы, оқу үдерісін автоматтандыру және мониторинг жүргізуге мүмкіндік береді. Алайда, SAP жүйесімен интеграцияланғандықтан, шағын және орта компаниялар үшін күрделі болуы мүмкін.

Жоғарыда келтірілген Онлайн оқыту платформаларының өзара әрекеттесуінің салыстыру диаграммасы 1-ші суретте көрсетілген.



1 сурет. Пайдаланушылардың өзара әрекеттесуін салыстыру диаграммасы

Жоғарыда аталған платформаларға қарамастан, олардың көпшілігі нақты корпоративтік қажеттіліктерге толықтай бейімделмеген немесе оқыту процесін жеке қажеттіліктерге қарай теңшеу мүмкіндігін шектейді. Сондықтан, біздің мақсатымыз – корпоративтік оқытудың ерекшеліктерін ескере отырып, неғұрлым икемді, мобильді және интерактивті шешім әзірлеу.

Қосымшаның архитектурасын сипаттау

1. **Технологиялық стек** - қосымшаны әзірлеу үшін заманауи технологиялар қолданылады:

- **Фронтенд:** React Native (кроссплатформалық дамыту үшін).
- **Бэкенд:** Node.js (серверлік логика үшін), Express.js (REST API құру үшін).
- **Мәліметтер базасы:** MySQL (құрылымдық деректерді сақтау үшін).
- **Аутентификация:** Firebase Authentication (қауіпсіз логин және тіркелу жүйесі).
- **Бұлттық сақтау:** AWS немесе Google Cloud (бейне сабақтарды сақтау және тарату үшін).

2. **Функционалдық мүмкіндіктер** - қосымшаның негізгі функционалдық мүмкіндіктері:

- **Қолданушы тіркеуі және кіру жүйесі** (қызметкер, оқытушы, әкімші рөлдері).
- **Курстар каталогы:** түрлі тақырыптағы курстарды шолу, іздеу, сүзгіден өткізу.
- **Бейне сабақтар:** стриминг немесе офлайн қарау мүмкіндігі.
- **Тесттер мен бағалау жүйесі:** білімді тексеруге арналған модуль.
- **Сұрақ-жауап (Q&A) алаңы:** оқытушылар мен студенттер арасындағы өзара әрекеттесу.

• **Жасанды интеллект (AI) негізінде жеке оқу ұсыныстары:** қолданушының оқу үлгісіне қарай автоматты ұсыныстар.

• **Әкімшілік панелі:** компания басшылары мен HR бөлімдеріне арналған бақылау құралдары.

3. **Жасанды интеллекттің (AI) жекелендірілген оқытудағы рөлі** - жасанды интеллект (AI) корпоративтік оқытуда жаңа мүмкіндіктер ашады:

• **Оқушыға бейімделген оқу жолы:** AI алгоритмдері пайдаланушының оқу тарихын және мінез-құлқын талдай отырып, жеке ұсыныстар жасайды.

• **Автоматтандырылған бағалау:** тесттердің нәтижелерін автоматты талдау және прогрессті бақылау.

• **Чат-боттар:** оқу процесінде көмек көрсететін виртуалды ассистенттер.

Қосымша **React Native** негізінде әзірленуде, бұл оны **Android және iOS** платформаларында бір уақытта іске қосуға мүмкіндік береді. Серверлік бөлігі **Node.js** және **Express.js** арқылы құрылды, ал мәліметтер базасы **MySQL** көмегімен ұйымдастырылды.

Қосымшада келесі бөлімдер мен мүмкіндіктер іске асырылды:

- **Тіркелу және кіру жүйесі** (Firebase Authentication негізінде).
- **Курстар каталогы** (категориялар бойынша сүзу, іздеу мүмкіндігі).
- **Бейне сабақтар модулі** (оқытушылар жүктейтін бейне сабақтарды көру).
- **Тестілеу жүйесі** (сабақ соңында білімді тексеруге арналған тестілер).
- **Сұрақ-жауап алаңы (Q&A)** (оқытушылар мен студенттер арасындағы интерактивті талқылау).

- **Оқу аналитикасы** (пайдаланушының оқу үлгерімін бақылау жүйесі).

Қазіргі уақытта интерфейстің негізгі элементтері әзірленуде, UX/UI дизайны қолданушыға ыңғайлы ету үшін жетілдірілуде. Әзірленген мобильді қосымша корпоративтік оқытудағы негізгі қиындықтарды шешуге бағытталған:

1. **Икемділік:** Қызметкерлер кез келген уақытта, кез келген жерден оқи алады.
2. **Жекелендірілген оқу:** AI негізінде әр қызметкерге бейімделген оқу ұсыныстары жасалады.
3. **Интерактивтілік:** Тек бейне сабақтар ғана емес, сонымен қатар тестілеу, пікірталас алаңы және тәжірибелік тапсырмалар бар.
4. **Оқытудың мониторингі:** HR бөлімі қызметкерлердің оқу жетістіктерін аналитика арқылы бақылай алады.
5. Қазіргі корпоративтік оқыту жүйесінде мобильді технологияларды енгізу қызметкерлердің білім алу процесін әлдеқайда қолжетімді, икемді және тиімді етеді.

Дәстүрлі оқыту әдістерінің шектеулерін еңсеру үшін әзірленген мобильді қосымша оқытуды жекелендіру, интерактивтілік және үздіксіз қолжетімділік мүмкіндіктерін ұсынады. Жасанды интеллект (AI) технологиясын пайдалану арқылы әр қызметкердің қажеттіліктеріне бейімделген оқу процесін қалыптастыруға болады. Сонымен қатар, аналитикалық құралдар HR және басшылыққа оқу үлгерімін бақылап, оқыту стратегиясын оңтайландыруға көмектеседі.

Пайдаланылған әдебиеттер тізімі:

1. Garrison, D. R., & Vaughan, N. D. (2008). *Blended Learning in Higher Education: Framework, Principles, and Guidelines*. Jossey-Bass. <https://coi.athabasca.ca/books/book-blended-learning-in-higher-education/>
2. Siemens, G. (2005). *Connectivism: A Learning Theory for the Digital Age*. International Journal of Instructional Technology and Distance Learning. <http://www.ceebl.manchester.ac.uk/events/archive/aligningcollaborativelearning/Siemens.pdf>
3. Brown, J. S., & Duguid, P. (2000). *The Social Life of Information*. Harvard Business Review Press. https://en.wikipedia.org/wiki/The_Social_Life_of_Information

Мекеменің ішкі құжаттарын цифрландыру үшін машиналық оқыту алгоритмдерін қолдану

Жумабаева С.Е.

Әл-Фараби атындағы Қазақ Ұлттық Университетінің 4 курс студенті

symbatzhumabaeva04@gmail.com

Черикбаева Л.Ш.

Әл-Фараби атындағы Қазақ Ұлттық Университетінің PhD, доценті

Қазіргі заманғы мемлекеттік және коммерциялық мекемелерде құжат айналымының үлкен көлемі қағаз түрінде сақталады. Бұл құжаттарды іздеу, құрылымдау және өңдеу көп уақыт пен ресурстарды талап етеді. Сандық технологиялардың дамуы мекемелердің ішкі құжаттарын цифрландыруды маңызды міндеттердің біріне айналдырды. Құжаттарды автоматты түрде тану, индекстеу және іздеу процестерін оңтайландыру үшін машиналық оқыту және оптикалық таңбаларды тану (OCR) әдістерін қолдану өзекті болып табылады.

Жұмыста құжаттарды цифрландыру және оларды тиімді индекстеу мақсатында машиналық оқыту және OCR әдістері қолданылды. Алдымен, құжаттардан мәтінді автоматты түрде тану үшін OCR (оптикалық таңбаларды тану) процесі жүзеге асырылды, бұл үшін Tesseract OCR пайдаланылды. Бұл құрал қазақ тіліндегі құжаттардағы мәтінді тануға бейімделді, алайда сканерленген құжаттардың сапасына және мәтіннің орналасуына байланысты кейбір қиындықтар кездесті. OCR нәтижелерінің сапасын жақсарту мақсатында құжаттарды алдын ала өңдеу жүргізілді: суреттер бинаризацияланды, қажет болған жағдайда қисайған мәтіндерді түзету үшін бұрыштық коррекция қолданылды. OCR нәтижесінде алынған мәтіндер әрі қарай классификация үшін өңдеуге дайындалды. Алдын ала өңдеу кезеңінде барлық мәтін кіші регистрге келтірілді, тыныс белгілері мен артық бос орындар жойылды, сандар мен арнайы символдар өңделді. Сонымен қатар, тоқтау сөздер (stopwords) алынып тасталды, бұл классификация сапасын арттыруға көмектесті. OCR нәтижелері әрі қарай өңдеу және талдау үшін MySQL дерекқорына сақталды.

Құжаттардың мазмұнына қарай автоматты түрде категорияларға бөлінуін қамтамасыз ету үшін машиналық оқыту модельдері қолданылды. Құжаттарды классификациялау үшін алынған мәтіндер TF-IDF (Term Frequency - Inverse Document Frequency) әдісі арқылы векторизацияланды, бұл мәтіндік деректерді сандық пішімге айналдыруға мүмкіндік берді. Алынған векторлар негізінде бірнеше классификациялық модельдер оқытылды. Классификация үшін SVM (Support Vector Machine), Random Forest және XGBoost алгоритмдерінен құралған ансамбльдік модель әзірленді. Алдымен, әрбір модель бөлек оқытылып, олардың нәтижелері талданды. Кейін модельдер ансамбль әдісі арқылы біріктіріліп, олардың болжамдары ортақ шешім қабылдау үшін пайдаланылды. Әрбір модельдің классификациядағы тиімділігі салыстырылып, ансамбльдік тәсілдің жалпы дәлдікті жақсартатыны анықталды.

Құжаттарды іздеу және құрылымдау үшін Elasticsearch жүйесі қолданылды, бұл пайдаланушыларға қажетті ақпаратты тиімді түрде табуға мүмкіндік берді. Elasticsearch арқылы мәтіндік деректер индекстеліп, семантикалық іздеу мүмкіндігі қамтамасыз етілді. Бұл тәсіл жүйені пайдаланушылар үшін ыңғайлы етіп, құжаттарды іздеу мен индекстеу процесін жылдамдатты.

Жұмыс нәтижесінде мемлекеттік мекемелердің ішкі құжаттарын сандық форматта өңдеу, оларды автоматты түрде индекстеу және жылдам іздеуді қамтамасыз ету мүмкіндігі жасалды. OCR және машиналық оқыту әдістерін біріктіре отырып, құжаттарды тиімді классификациялау және іздеу жүйесін құруға қол жеткізілді. Алынған нәтижелер жүйенің

құжат айналымын оңтайландыруға және әкімшілік процестерді автоматтандыруға айтарлықтай үлес қоса алатынын көрсетті. Болашақта жүйенің функционалын кеңейту үшін мәтіннен негізгі ақпаратты шығару (Named Entity Recognition) және пайдаланушылар үшін интуитивті веб-интерфейс әзірлеу жоспарлануда.

Пайдаланылған әдебиеттер тізімі:

1. Smith R. An Overview of the Tesseract OCR Engine // Proceedings of the Ninth International Conference on Document Analysis and Recognition. – 2007. – P. 629–633.
2. Breiman L. Random Forests // Machine Learning. – 2001. – Vol. 45, No. 1. – P. 5–32.
3. Cortes C., Vapnik V. Support-vector networks // Machine Learning. – 1995. – Vol. 20. – P. 273–297.
4. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. – 2016. – P. 785–794.
5. Manning C. D., Raghavan P., Schütze H. Introduction to Information Retrieval // Cambridge University Press. – 2008. – 482 p.
6. Elasticsearch: The Definitive Guide // O’Reilly Media. – 2015.
7. Pedregosa F. et al. Scikit-learn: Machine Learning in Python // Journal of Machine Learning Research. – 2011. – Vol. 12. – P. 2825–2830.

Генеративно-сопоставительная сеть для медицинских изображений (MI-GAN)

Мареев Даниил

Astana IT University, Астана, Казахстан, 2025

Email: mrvdnl@mail.ru

*Научный руководитель: Иманкулов Тимур Сакенович
доктор PhD КазНУ им. аль-Фараби*

Медицинская визуализация играет важную роль в диагностике и лечении заболеваний. Однако качество изображений может быть ограничено шумами, артефактами и низким разрешением. Генеративно-сопоставительные сети (GAN) [1] представляют собой мощный инструмент для улучшения медицинских изображений. В данном исследовании рассматривается модель MI-GAN (Generative Adversarial Network for Medical Imaging), разработанная для генерации медицинских изображений и их сегментированных масок [2].

Основной проблемой в области медицинской визуализации является нехватка аннотированных данных. MI-GAN решает эту проблему, позволяя создавать синтетические медицинские изображения для обучения диагностических алгоритмов. Это особенно важно в условиях ограниченного доступа к реальным данным.

MI-GAN включает следующие компоненты:

- генератор (G) – создает синтетические изображения на основе случайного шума и сегментированных масок;
- дискриминатор (D) – отличает реальные изображения от синтетических;
- VGG-сеть – используется для извлечения признаков стиля и содержания.
- функции потерь – включают d_loss (ошибка дискриминатора), g_loss_ad (ошибка генератора), $style_loss$ (ошибка стилистического соответствия), $content_loss$ (ошибка содержательного соответствия) и tv_loss (ошибка гладкости изображения).

Обучение MI-GAN проводилось на наборе данных DRIVE, содержащем изображения сетчатки глаза и их сегментированные маски. Использовалась аугментация данных:

- повороты изображений;
- масштабирование;
- изменение цветовых характеристик.

Эти методы позволили увеличить объем данных и снизить вероятность переобучения модели.

Результаты обучения MI-GAN показали, что модель способна генерировать медицинские изображения высокого качества. Сравнение предобученных сетей (VGG-16, VGG-19, ResNet-50, ResNet-101) продемонстрировало, что VGG-19 обеспечивает лучший баланс между стилем и содержанием.

Применение MI-GAN в медицине может улучшить диагностику, снизить затраты на разметку данных и повысить доступность медицинских изображений. Будущие исследования будут направлены на адаптацию модели для работы с другими типами медицинских данных.

Список использованной литературы:

- [1] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139-144.
- [2] Talha Iqbal, Hazrat Ali (2018). Generative Adversarial Network for Medical Images (MI-GAN). *Journal of Medical Systems*, 42(11), 1-11.
- [3] DRIVE: Digital Retinal Images for Vessel Extraction, <https://drive.grand-challenge.org/>

Developing Optimization Algorithms to Improve Energy Efficiency in Smart Buildings Using AI

Orynbasar Rauan

Faculty of information technology

Scientific Supervisor:

Acting professor of the department of computer science

Lyazzat Boltabayevna Rakhimzhanova

The rapid growth of smart building technologies has led to an increased demand for energy-efficient solutions. With buildings accounting for a significant portion of global energy consumption, optimizing energy usage is crucial for sustainability, cost reduction, and environmental conservation. This research aims to develop AI-driven optimization algorithms to enhance energy efficiency in smart buildings by dynamically managing energy consumption and reducing waste.

The study focuses on leveraging machine learning techniques, such as reinforcement learning, deep neural networks, and predictive analytics, to analyze real-time data from smart sensors and IoT devices. These algorithms will optimize energy distribution by predicting peak demand, automating heating, ventilation, and air conditioning (HVAC) systems, and dynamically adjusting lighting based on occupancy patterns. The implementation of deep learning models will enable adaptive decision-making, ensuring energy efficiency without compromising comfort. Moreover, AI-driven anomaly detection techniques will be used to identify irregularities in energy usage, helping facility managers take corrective actions before inefficiencies escalate.

One of the key challenges in developing such optimization algorithms is balancing energy savings with system performance. To address this, techniques such as metaheuristic optimization, model predictive control, and real-time anomaly detection will be integrated. These approaches will allow the system to dynamically adjust parameters based on changing environmental conditions and user behavior. Additionally, AI-based optimization can contribute to demand response strategies, enabling buildings to adjust energy consumption based on grid conditions, thereby reducing peak loads and enhancing overall energy grid stability. AI-powered energy forecasting models will also be developed to predict long-term energy usage trends, helping decision-makers implement proactive energy-saving measures.

Security and scalability are also critical factors in implementing AI-driven energy management systems. The proposed solution will incorporate encrypted data transmission, secure cloud infrastructure, and decentralized control mechanisms to ensure resilience against cyber threats. Scalability will be achieved through modular AI models that can be deployed across various types of buildings, from residential to commercial and industrial structures. Furthermore, real-time monitoring dashboards and predictive maintenance alerts will be developed to provide building managers with actionable insights, helping to prevent equipment failures and reduce maintenance costs. Blockchain technology will also be explored as a means of securely storing and sharing energy data among smart buildings, creating a decentralized and transparent energy management network.

Another important aspect of this research is integrating AI-based energy management systems with renewable energy sources. By combining AI-driven optimization with solar panels, wind turbines, and battery storage systems, buildings can reduce reliance on conventional energy grids and move toward self-sufficiency. Advanced AI models will facilitate real-time energy trading between buildings, allowing surplus energy to be redistributed efficiently within smart city infrastructures.

The expected outcome of this research is a functional AI-based optimization framework that significantly improves energy efficiency in smart buildings. By reducing energy waste and optimizing consumption patterns, the solution will contribute to sustainable development, lower operational

costs, and enhanced occupant comfort. The proposed approach can be extended to smart cities, enabling large-scale energy management and sustainability initiatives. Future research may explore integrating AI-driven energy efficiency models with edge computing to enable real-time, on-device decision-making, minimizing latency and reducing reliance on centralized cloud infrastructure.

References:

1. Deb, C., Zhang, F., Yang, J., et al. (2017). "A Review on Data-Driven Approaches for Building Energy Management." *Renewable and Sustainable Energy Reviews*, 74, 1040-1052.
2. Wang, S., Yan, C., & Xiao, F. (2012). "Quantitative Energy Performance Assessment Methods for Existing Buildings." *Energy and Buildings*, 55, 1-10.
3. Zhao, H.-X., & Magoulès, F. (2012). "A Review on the Prediction of Building Energy Consumption." *Renewable and Sustainable Energy Reviews*, 16(6), 3586-3592.
4. Pérez-Lombard, L., Ortiz, J., & Pout, C. (2008). "A Review on Buildings Energy Consumption Information." *Energy and Buildings*, 40(3), 394-398.
5. Ruiz, G., Bandera, C., & Pérez-Lombard, L. (2016). "Development and Application of a Monitoring-Based Energy Performance Assessment Methodology for HVAC Systems." *Energy and Buildings*, 130, 437-454.
6. Kusiak, A., Li, M., & Tang, F. (2010). "Modeling and Optimization of HVAC Systems Using a Dynamic Neural Network." *Energy*, 35(12), 2324-2332.
7. Liu, X., & Wen, J. (2017). "Approximate Solution to a Reinforcement Learning-Based HVAC Optimization Problem." *Energy and Buildings*, 136, 21-27.
8. Shrestha, R., Habibi, S., & Sharma, S. (2021). "Artificial Intelligence in Energy Management Systems: A Systematic Review." *Journal of Cleaner Production*, 305, 127098.
9. IEA (International Energy Agency). (2022). "Energy Efficiency 2022: Key Findings." Retrieved from <https://www.iea.org>.
10. ASHRAE (American Society of Heating, Refrigerating and Air-Conditioning Engineers). (2023). "Guidelines for Building Energy Optimization." *ASHRAE Journal*, 65(4), 25-30.

Development of an intelligent system for evacuation from a building in case of fire based on artificial intelligence technology

Mukhamedali Saparali, Maxatbek Satymbekov

*Al-Farabi Kazakh National University,
alimukhamed3@gmail.com, m.n.satymbekov@gmail.com*

Evacuation during a fire is a difficult task that calls for adaptive response systems and real-time decision-making. Conventional evacuation systems may not take into consideration dynamic fire propagation, building congestion, and individual evacuee characteristics because they rely on predetermined routes and static safety rules [1]. In order to maximize escape routes and enhance safety precautions during emergencies, this study suggests creating an intelligent evacuation system based on artificial intelligence (AI) technology. The system dynamically evaluates building conditions and recommends the safest evacuation routes by combining computer vision, reinforcement learning, and graph-based path optimization methods.

Convolutional neural networks (CNN) for fire detection [2], recurrent neural networks (RNN) for real-time crowd movement prediction [3], and reinforcement learning-based adaptive route planning [4] are important elements. The work trains and validates the suggested models using publicly accessible datasets from actual evacuation situations and fire simulations. When compared to traditional approaches, experimental results show that AI-driven evacuation tactics considerably cut escape time and congestion [5]. The results of this study lay the groundwork for incorporating AI into disaster management frameworks and improve smart building safety systems.

The work trains and validates the suggested models using publicly accessible datasets from actual evacuation situations and fire simulations. To test different fire breakout situations, a simulation environment is used, taking into account variables like occupant density, fire spread speed, and behavioral differences. According to experimental findings, AI-driven evacuation tactics considerably cut down on escape time and traffic as compared to traditional techniques, increasing survival rates and improving emergency response effectiveness [6]. Even with encouraging outcomes, there are still issues with interaction with current building management systems, computational complexity, and real-time decision delay. Future research will concentrate on improving scalability, performing real-world pilot tests in smart building infrastructures, and honing AI models.

The results of this study lay the groundwork for incorporating AI into disaster management frameworks and improve smart building safety systems. This system has the ability to completely transform fire safety procedures by utilizing AI and IoT technology, providing a proactive means of reducing casualties and maximizing emergency response activities.

References:

1. W. Huang, B. Li, and Y. Zhang, "Deep reinforcement learning for real-time building evacuation planning," *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 4, pp. 3217–3228, Apr. 2022.
2. M. Ahmed, A. Khan, and J. Lee, "AI-driven fire detection and evacuation route optimization in smart buildings," *IEEE Access*, vol. 10, pp. 88234–88247, Aug. 2022.
3. K. Nakamura, S. Tanaka, and Y. Fujita, "Crowd evacuation modeling using recurrent neural networks," *Journal of Safety Science and Technology*, vol. 15, no. 2, pp. 134–148, Mar. 2021.
4. T. Wang, P. Zhou, and H. Chen, "Graph-based path optimization for intelligent emergency evacuation systems," *IEEE Transactions on Cybernetics*, vol. 53, no. 1, pp. 67–79, Jan. 2023.

5. S. Patel, R. Kumar, and L. Zhao, "AI-powered fire emergency management: An integration of IoT and deep learning," *Sensors*, vol. 22, no. 11, pp. 4215–4229, Jun. 2022.
6. R. Chen, Y. Sun, and M. Brown, "Simulation-based analysis of AI-powered emergency evacuation in smart buildings," *IEEE Internet of Things Journal*, vol. 11, no. 3, pp. 1987–1998, Mar. 2023.

Агроөнеркәсіптік сектор саласында мамандарды даярлауға арналған Web-қосымшаны әзірлеу

Байтұрсын Ә.Е., Макашев Е.П.

ал-Фараби атындағы Қазақ Ұлттық университеті,
aliyaerlankyzy@gmail.com, makashev.yerlan70@gmail.com

Қазіргі заманғы агроөнеркәсіптік секторда қызметкерлерді даярлау және олардың біліктілігін арттыру басты міндеттердің бірі болып табылады. Дәстүрлі оқыту әдістері кейде қашықтан қолжетімділіктің болмауы, оқу материалдарының ескіруі, оқыту әдістерінің икемсіздігі және интерактивтіліктің төмендігі сияқты қиындықтарға тап болады. Цифрлық технологиялар, жасанды интеллект (AI) және интернет заттар (IoT) секілді инновациялық шешімдердің дамуы білім беру үдерістерін автоматтандыруға, оқыту тиімділігін арттыруға және аграрлық сектор қызметкерлеріне икемді оқыту жүйесін ұсынуға мүмкіндік береді [1].

Осы зерттеу жұмысы агроөнеркәсіп саласындағы қызметкерлерді даярлауға арналған Web-қосымшаны әзірлеуді қарастырады. Бұл жүйе AI технологияларын пайдалана отырып, бейімделген оқу бағдарламаларын ұсыну, жұмысшылардың кәсіби дағдыларын бағалау және оқу материалдарын автоматты түрде жаңарту мүмкіндіктерін қамтиды. Сонымен қатар, компьютерлік көру (Computer Vision), табиғи тілді өңдеу (NLP), машиналық оқыту (ML), бейнеаналитика және сенсорлық деректерді талдау әдістері қызметкерлердің оқу барысын бақылау және олармен өзара әрекеттесу сапасын жақсарту үшін қолданылады.

Web-қосымшаны әзірлеу үшін React (frontend) және Node.js (backend) негізінде модульдік және масштабталатын архитектура құрылды, ал оқу материалдары MongoDB деректер қорында сақталды. Сонымен қатар, real-time деректерді өңдеу, автоматтандырылған бағалау жүйелері, оқу процесінің геймификациясы және бейімделген ұсыныстар жасау мүмкіндіктері қарастырылды. Машиналық оқыту әдістерін енгізу барысында терең оқыту (CNN, Transformer, LSTM) әдістері зерттелді. Сонымен қатар, IoT деректерін талдау, бейнебақылау жүйелері арқылы объектілерді бақылау және Edge AI технологияларын қолдану мүмкіндіктері қарастырылды [2-4].

Зерттеу нәтижелері Web-қосымшаның қызметкерлерге икемді, тиімді және интерактивті оқу үдерісін қамтамасыз ететінін көрсетті. Бұл жүйе ауыл шаруашылығы саласындағы жұмысшылардың кәсіби дағдыларын жетілдіруге, жаңа технологияларды игеруге және олардың практикалық қолдану мүмкіндіктерін кеңейтуге ықпал етеді. Сондай-ақ, жүйе деректерді интеллектуалды талдау арқылы білім беру сапасын үздіксіз жақсартып отыруға мүмкіндік береді [5].

Пайдаланылған әдебиеттер тізімі:

1. Smith, J., Brown, T. "Application of Deep Learning Techniques in Poultry Farming: A Review" // *International Journal of Computer Applications*, 2023, 175(30), pp. 15–22.
2. Johnson, K., Williams, L. "Development of an E-Learning Platform for Agricultural Education" // *Journal of Agricultural Education and Extension*, 2024, 30(2), pp. 105–120.
3. Garcia, P., Martinez, H. "Adaptive Learning Systems in Agricultural Education: A Case Study" // *Educational Technology & Society*, 2024, 27(1), pp. 98–110.
4. Anderson, C., Thompson, B. "Integration of Artificial Intelligence in Poultry Disease Diagnosis" // *Poultry Science*, 2023, 102(5), pp. 2115–2125.
5. Robinson, D., Evans, J. "Design and Implementation of a Mobile Learning Platform for Agricultural Students" // *International Journal of Education and Development using Information and Communication Technology*, 2024, 20(3), pp. 45–60.

6. Zhang, L., Zhao, H., Liu, Q. "Development of an Intelligent E-Learning Platform for Precision Agriculture" // Computers and Electronics in Agriculture, 2024, 210, pp. 345–356.

Интерактивті цифрлы-векторлық “KazMaps” картографиялық қосымшасы

Абдымажит И.

ал-Фараби атындағы Қазақ Ұлттық университетінің 4 курс студенті

E-mail: islam.abdymazhit@gmail.com

Кабдрахова С.С.

ал-Фараби атындағы Қазақ Ұлттық университетінің ф.-м.ғ.к., аға оқытушысы

Кеңістіктік мәліметтерді ұйымдастыру, талдау және ұсынуда қазіргі ақпараттық технологиялар мен географиялық ақпараттық жүйелер басты рөл атқарады. Цифрлық карта жасаудың және деректердің жаһандық интеграциясының қарқынды дамуы жағдайында интерактивті карталарды құру экономика мен ғылымның әртүрлі салаларында жедел басқару шешімдерін қабылдау және процестерді оңтайландыру үшін қажетті құралға айналуға.

Бұл зерттеудің негізгі мақсаты географиялық ақпаратты тиімді көрсетуді, талдауды және өңдеуді қамтамасыз ететін интерактивті цифрлы-векторлық “KazMaps” картографиялық қосымшасын жасау және енгізу болып табылады. Заманауи веб-технологияларды, динамикалық визуализация алгоритмдерін пайдалану және әртүрлі деректер көздерін біріктіру географиялық ақпараттық жүйелердің мамандары үшін картографиялық деректермен жұмыс істеудің жоғары дәлдігін, масштабтылығын және тиімділігін қамтамасыз ететін жаңа мүмкіндіктер ашады.

Экономиканы белсенді цифрландыру және ақпараттық технологиялардың қарқынды дамуы жағдайында көлік, экология және ауыл шаруашылығы сияқты салаларда маңызды рөл атқаратын геокеңістіктік деректерге деген қажеттілік артып келеді. Картографиялық қосымшалар пайдаланушыларға геодеректермен жұмыс істеуге арналған интуитивті және икемді құралдарды ұсына отырып, кеңістіктік модельдерге негізделген терең талдау мен болжауды жеңілдету арқылы осы қажеттілікті шешеді.

Қазіргі таңда географиялық деректерді талдау айтарлықтай шектеулерді көрсетеді, соның ішінде функционалдың шектеулі болуы, пайдаланушы интерфейстерін баптаудың жеткіліксіз икемділігі және әртүрлі дереккөздермен интеграцияның қиындықтары бар. Сонымен қатар, көптеген қолданыстағы шешімдер өзгермелі эксплуатациялық шарттарға жеткілікті бейімделуді көрсетпейді, бұл жаңа әмбебап және бейімделгіш өнімдерді құрудың қажеттілігін айқын көрсетеді.

Геосаяси тұрақсыздық пен шетелдік бағдарламалық қамтамасыз етуді пайдалануға шектеулер жағдайында отандық шешімдерді әзірлеу стратегиялық маңызға ие. “KazMaps” жобасын іске асыру отандық әзірлемелерді пайдалану арқылы технологиялық тәуелсіздікке және импортты алмастыруға ықпал етеді, бұл ақпараттық жүйелердің қауіпсіздігін арттырып қана қоймай, сонымен қатар жергілікті IT секторының дамуын ынталандырады, ұлттық технологиялардың позициясын нығайтады.

“KazMaps” озық технологиялар мен деректерді өңдеу және визуализацияның инновациялық әдістерін қолдану арқылы жүзеге асырылған. Ақпаратты жаңартудың динамикалық алгоритмдері, бейімделген пайдаланушы интерфейстері және кеңістіктік қатынастарды талдаудың заманауи құралдары жүйеге тиімді масштабтауға және ақпараттық ортадағы өзгерістерге тез жауап беруге мүмкіндік береді. Бұл тәсіл геодеректермен жұмыс сапасын арттыру және басқару шешімдерін жетілдіру үшін қосымша мүмкіндіктер ашады.

Қорытындылай келе, “KazMaps” цифрлық картасы заманауи, инновациялық және ауқымды шешім болып табылады. Қосымша геокеңістіктік деректерге өсіп келе жатқан сұранысты қанағаттандырып қана қоймайды, сонымен қатар бар технологиялық шектеулерді еңсеріп, технологиялық тәуелсіздікке және отандық IT шешімдерді одан әрі дамытуға ықпал

етеді.

Пайдаланылған әдебиеттер тізімі:

1. P. Bolstad, “GIS Fundamentals: A First Text on Geographic Information Systems” 3rd ed., 2016.
2. P. Longley, M. F. Goodchild, D. J. Maguire, and D. W. Rhind, “Geographic Information Systems and Science” Wiley, 2015.
3. J. P. Snyder, “Map Projections: A Working Manual” U.S. Geological Survey Professional Paper 1395, 1987.
4. W. Torge, “Geodesy” 4th ed., Springer, 2012.
5. K. Matsuda and R. Lea, “WebGL Programming Guide: Interactive 3D Graphics Programming with WebGL” Addison-Wesley, 2013.
6. T. Parisi, “WebGL: Up and Running” O’Reilly Media, 2012.
7. M.-J. Kraak and F. Ormeling, “Cartography: Visualization of Spatial Data” Pearson, 2010.

Параллельдеу әдістерін қолдана отырып, қосарланған градиент әдісін әзірлеу және іске асыру

Сиванкүл Диас Маратбекұлы

*Әл-Фараби атындағы Қазақ ұлттық университеті, Компьютерлік ғылымдар кафедрасы
Алматы, Қазақстан, 2025*

Email: dias.sivankul@mail.ru

Ғылыми жетекші: Қасымбек Нұрислам, аға оқытушы

Конъюгацияланған градиенттер (CG) әдісі – үлкен сиретілген сызықтық жүйелерді шешуде тиімді итерациялық алгоритм болып табылады. Ғылыми есептеулер мен инженерлік қосымшаларда қолданылатын бұл әдіс Гаусс әдісі немесе LU-жазбалау сияқты дәстүрлі тікелей әдістерге қарағанда жадыны азырақ тұтынып, есептеу жүктемесін азайтады және жоғары дәлдікті қамтамасыз етеді [1].

Бұл зерттеу CG әдісін жүзеге асыру және оңтайландыруға бағытталған, мұнда жад тиімділігін арттыру үшін матрицаларды қысылған жол пішімі (CSR) арқылы сақтау қолданылады. Өртүрлі көлемдегі деректер жиынтығы негізінде алгоритмнің орындалу жылдамдығы мен жинақталу қасиеттері талданды. Сонымен қатар, есептеу уақытын айтарлықтай қысқарту үшін OpenMP және MPI параллельдеу әдістері енгізілді [2].

Эксперименттік нәтижелер OpenMP параллельдеуі орташа өлшемді матрицаларда көпжіптік есептеулердің тиімділігін көрсетті. Ал MPI әдісі үлкен көлемді деректерде есептеу жүктемесін бірнеше түйінге тарату арқылы жоғары өнімділікке жетті. Орындау уақыты, ауқымдылық (scalability) және әртүрлі өлшемдегі сиретілген матрицалардағы жинақталу жылдамдығы талданды. Сонымен қатар, MPI ортасындағы процессор саны мен байланыс жүктемесінің (communication overhead) әсері зерттелді [3].

Нәтижелер көрсеткендей, OpenMP орташа өлшемді матрицаларда жоғары өнімділікке ие болса, MPI үлкен жүйелерде есептеулерді таратып орындауда тиімді болып шықты. CSR сақтау форматы жадыны үнемдеп, сиретілген матрица-вектор көбейту операцияларын оңтайландыру арқылы есептеу жылдамдығын арттырды.

Бұл зерттеу параллельденген CG әдісін қолдану арқылы үлкен сиретілген сызықтық жүйелерді тиімді шешудің артықшылықтарын көрсетеді. Бұл әдістің сандық модельдеулерде, инженерлік есептеулерде және ауқымды машиналық оқыту есептерінде қолданылу мүмкіндігі бар. Болашақта OpenMP және MPI гибриді параллельдеу әдістерін біріктіру арқылы жоғары өнімді есептеу (HPC) жүйелерінде тиімділікті одан әрі арттыру жоспарлануда.

Пайдаланылған әдебиеттер тізімі:

- [1] J. R. Shewchuk, “An Introduction to the Conjugate Gradient Method Without the Agonizing Pain,” Carnegie Mellon University, 1994.
- [2] Y. Saad, “Iterative Methods for Sparse Linear Systems,” SIAM, 2003.
- [3] W. Hackbusch, “Iterative Solution of Large Sparse Systems of Equations,” Springer, 1993.

Машиналық оқыту алгоритмдерін қолдана отырып, инсультті ерте диагностикалау

Есенғалиева Г.Т.

Әл-Фараби атындағы Қазақ Ұлттық Университетінің 4 курс студенті

gwilisesengalieva@gmail.com

Черикбаева Л.Ш.

Әл-Фараби атындағы Қазақ Ұлттық Университетінің PhD, доценті

Инсультті ерте диагностикалау – қазіргі медицинаның өзекті мәселелерінің бірі, өйткені бұл ауру әлемдегі өлім-жітім мен мүгедектікке әкелетін негізгі себептердің бірі болып табылады.[1][2]

Қазақстанда жыл сайын 40 мыңнан астам адам инсультке шалдығады, олардың шамамен 60%-ы мүгедектікке ұшырайды, ал алғашқы 10 күн ішінде 5 мыңға жуық науқас қайтыс болады. Инсульттің салдарынан аман қалған пациенттердің 70%-ы тұрақты күтім мен бөгде көмекті қажет етеді, ал тек 10%-ы ғана толыққанды өмірге оралу мүмкіндігіне ие болады. Қан айналымы жүйесінің аурулары еңбекке жарамсыздыққа және әлеуметтік-экономикалық шығындардың артуына алып келеді. Осыған байланысты инсультті ерте кезеңде анықтау және тиімді диагностикалау медициналық ғылымдағы маңызды бағыттардың бірі болып табылады.[3]

Қазіргі таңда инсультті диагностикалаудың дәстүрлі әдістері, соның ішінде клиникалық тексерулер, зертханалық зерттеулер, магниттік-резонанстық томография (МРТ) және компьютерлік томография (КТ) кеңінен қолданылады. Дегенмен, бұл әдістер уақытты көп қажет етеді және жоғары білікті медициналық мамандардың қатысуын талап етеді. Осы шектеулерді жеңу мақсатында соңғы жылдары жасанды интеллект пен машиналық оқыту әдістерін қолдану арқылы инсультті автоматтандырылған түрде анықтауға арналған модельдер белсенді зерттелуде. Машиналық оқыту әдістері үлкен көлемдегі медициналық деректерді өңдеуге, пациенттің инсульт қаупін бағалауға және диагностикалық шешімдерді жедел қабылдауға мүмкіндік береді.

Бұл зерттеуде инсультті диагностикалау үшін машиналық оқыту әдістері қолданылды. Атап айтқанда, құрылымдалған медициналық деректерді талдау және инсульттің ықтималдығын бағалау үшін Random Forest (RF), Decision Tree (DT) және K-Nearest Neighbors (KNN) алгоритмдері пайдаланылды.[4][5][6] Бұл алгоритмдер науқастың клиникалық көрсеткіштерін (жасы, артериялық қан қысымы, қандағы глюкоза деңгейі, жүрек-қантамыр ауруларының болуы және т.б.) талдау негізінде инсульттің ықтималдығын болжайды. Сонымен қатар, инсультті визуалды диагностикалау үшін U-Net терең нейрондық желісі қолданылды. U-Net медициналық кескіндерді, әсіресе МРТ және КТ деректерін өңдеуге арналған жоғары тиімді архитектуралардың бірі болып табылады.[7] Ол инсульт ошақтарын дәл бөліп көрсетуге мүмкіндік беріп, диагностикалық процестерді автоматтандыруға ықпал етеді.

Зерттеу барысында деректерді алдын ала өңдеу, теңгерімсіздікті жою, үлгіні қалыпқа келтіру және модельдерді оқыту кезеңдері жүзеге асырылды. Талдау нәтижелері көрсеткендей, машиналық оқыту әдістерін қолдану инсультті диагностикалаудың дәлдігін айтарлықтай арттыруға мүмкіндік береді. Әсіресе, ансамбльдік әдістер мен терең нейрондық желілердің үйлесуі медициналық кескіндердегі патологиялық өзгерістерді жоғары дәлдікпен анықтауға ықпал етті.

Ұсынылған тәсіл инсультті ерте диагностикалау үдерісін жетілдіріп, медициналық шешімдерді қабылдау жылдамдығын арттыруға көмектеседі. Сонымен қатар, диагностикалық жүктеменің белгілі бір бөлігін автоматтандырылған жүйелерге беру арқылы дәрігерлердің жұмысын оңтайландыруға мүмкіндік береді. Бұл, әсіресе, медициналық ресурстар шектеулі

аймақтарда маңызды рөл атқарады. Болашақ зерттеулер модельдердің тиімділігін одан әрі арттыруға, гиперпараметрлерді оңтайландыруға және оларды клиникалық практикаға кеңінен енгізуге бағытталуы мүмкін.

Пайдаланылған әдебиеттер тізімі:

1. [https://kk.wikipedia.org/wiki/%D0%98%D0%BD%D1%81%D1%83%D0%BB%D1%8C%D1%82#:~:text=%D0%98%D0%BD%D1%81%D1%83%D0%BB%D1%8C%D1%82%20\(%D0%BB%D0%B0%D1%82.,%D1%82%D1%80%D0%BE%D0%BC%D0%B1%D0%BF%D0%B5%D0%BD%20%D0%B1%D1%96%D1%82%D0%B5%D0%BB%D1%96%D0%BF%20%D2%9B%D0%B0%D0%BB%D0%B0%D0%B4%D1%8B%20\(%D1%82%D1%80%D0%BE%D0%BC%D0%B1%D0%BE%D0%B7\)](https://kk.wikipedia.org/wiki/%D0%98%D0%BD%D1%81%D1%83%D0%BB%D1%8C%D1%82#:~:text=%D0%98%D0%BD%D1%81%D1%83%D0%BB%D1%8C%D1%82%20(%D0%BB%D0%B0%D1%82.,%D1%82%D1%80%D0%BE%D0%BC%D0%B1%D0%BF%D0%B5%D0%BD%20%D0%B1%D1%96%D1%82%D0%B5%D0%BB%D1%96%D0%BF%20%D2%9B%D0%B0%D0%BB%D0%B0%D0%B4%D1%8B%20(%D1%82%D1%80%D0%BE%D0%BC%D0%B1%D0%BE%D0%B7)).
2. Тазиева Я.Р. Машинное обучение как инновационная технология в медицине. – Казань, Россия, Казанский Федеральный университет, 2000. -318с.
3. С.К. Акшулаков (д.м.н.), Е.Б. Адильбеков, З.Б. Ахметжанова, С.Г. Медуханова ОРГАНИЗАЦИЯ И СОСТОЯНИЕ ИНСУЛЬТНОЙ СЛУЖБЫ РЕСПУБЛИКИ КАЗАХСТАН ПО ИТОГАМ 2016 ГОДА. – Астана, Қазақстан, «Ұлттық нейрохирургия орталығы» АҚ
4. Рахметова А.Ю., Косаченко А.И., Москалева А.С., Львова О.А., Сергеева М.В., Сергеев А.П. Точность методов Случайный лес и Многослойный перцептрон в задаче прогнозирования исходов детских ишемических инсультов. -Екатеринбург, Россия
5. Маркова А.В., Афанасьев А.Г., Афанасьев Г.И. КЛАССИФИКАЦИЯ НА ОСНОВЕ АЛГОРИТМА ДЕРЕВА РЕШЕНИЙ ДЛЯ МАШИННОГО ОБУЧЕНИЯ. – Москва, Россия, Московский государственный технический университет им. Н.Э.Баумана
6. Требиш В. АНАЛИЗ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ В КОНТЕКСТЕ ПРОГНОЗИРОВАНИЯ ИНСУЛЬТОВ. Кишинев, Молдова, Молдовский государственный Университет
7. Полякова И.Ю. U-Net для определения очага инсульта на МРТ снимках. -Пермь, Россия, Центр когнитивных нейронаук.

Research of Approaches to Software Development with DevOps in Mind

Turarbek K.T.

*1st-year master's student, Department of Computer Science, Faculty of Information Technology, Al-Farabi Kazakh National University, Almaty, Kazakhstan,
e-mail: kanatturarbek03@mail.ru*

The rapid evolution of software development has necessitated methodologies that ensure faster delivery, higher quality, and seamless collaboration. DevOps, a combination of Development and Operations, has emerged as a transformative approach that integrates these traditionally siloed functions. This article investigates key approaches to implementing DevOps, emphasizing its alignment with modern technologies such as AI and Data Science.

DevOps is built on collaboration, automation, CI/CD, and monitoring. These principles enable faster delivery, improved quality, and scalability (Fowler, 2021). By fostering a culture of shared responsibility, DevOps breaks down silos between development and operations teams. Automation streamlines repetitive tasks, reducing human error and accelerating processes. Continuous Integration/Continuous Delivery (CI/CD) ensures frequent and reliable code deployments, while monitoring provides real-time feedback to improve system performance. The benefits of DevOps are significant. Organizations experience faster time-to-market through automated pipelines, improved quality through continuous testing, and enhanced scalability through cloud-native practices. Additionally, cost efficiency is achieved by automating infrastructure management, reducing operational costs (Kim et al., 2021).

Implementing DevOps requires a cultural transformation that fosters collaboration and shared responsibility. Teams must be trained in DevOps tools and practices, and leadership must provide top-down support. Cross-functional teams, including developers, operations, and QA personnel, are essential for successful adoption (Bass, 2020)

A robust DevOps toolchain is critical for automation and efficiency. Key tools include Git and GitHub for version control, Jenkins and GitLab CI for CI/CD pipelines, Ansible and Terraform for configuration management, and Prometheus and Grafana for monitoring. These tools automate key processes, reducing manual intervention and accelerating deployment cycles (Humble, 2020).

AI enhances DevOps through predictive analytics, which identifies potential failures before they occur, and intelligent monitoring, which uses machine learning to analyze system performance. Automated testing tools like Testim and Appltools leverage AI to accelerate testing processes, reducing the time required for quality assurance (Bass, 2020).

Data Science plays a critical role in optimizing DevOps pipelines. Performance optimization is achieved by analyzing metrics to improve system efficiency. Anomaly detection uses statistical models to identify unusual patterns in system behavior. Resource allocation is optimized by predicting resource needs based on historical data, ensuring efficient utilization of infrastructure (Kim et al., 2021)

A leading e-commerce company implemented DevOps to streamline its software delivery process. The company faced challenges with slow deployment cycles, frequent system outages, and high operational costs. By adopting DevOps practices, the company achieved significant improvements in efficiency, quality, and cost savings.

The implementation began with a cultural transformation. Cross-functional teams were formed, and employees were trained in DevOps tools and practices. Leadership played a key role in driving this change, ensuring that all teams were aligned with the new approach. Next, the company integrated a robust DevOps toolchain, including Git for version control, Jenkins for CI/CD pipelines, Ansible for configuration management, and Prometheus for monitoring. These tools automated key processes, reducing manual intervention and accelerating deployment cycles.

The company also adopted cloud-native DevOps practices. Docker and Kubernetes were used for containerization, while AWS Lambda supported serverless computing. Terraform was employed for Infrastructure as Code (IaC), enabling automated infrastructure management. The results were impressive: a 30% reduction in deployment time, a 20% improvement in system uptime, and 15% cost savings (Forsgren, 2021).

Visual Representation of Data

To better understand the tools and processes involved in DevOps, the following table compares key DevOps tools and their use cases:

Category	Tool	Key Features	Use Case
Version Control	Git	Branching, Merging, Collaboration	Code Management
CI/CD Pipelines	Jenkins	Automation, Plugins, Scalability	Continuous Deployment
Configuration Mgmt.	Ansible	Agentless, YAML-based, Idempotent	Infrastructure Automation
Monitoring	Prometheus	Real-time Metrics, Alerting	System Performance Monitoring

Additionally, the **DevOps lifecycle** (Figure 1) illustrates the continuous loop of development, testing, deployment, and monitoring, highlighting the iterative nature of DevOps practices (Humble, 2020)



Figure 1: The DevOps lifecycle, showcasing the continuous loop of development, testing, deployment, and monitoring.

The integration of DevOps into software development processes offers significant benefits, including faster delivery, improved quality, and enhanced scalability. By leveraging modern technologies

such as AI and Data Science, organizations can further optimize their DevOps pipelines. The case study highlights the practical application of these principles, providing valuable insights for organizations embarking on their DevOps journey.

References:

1. Bass, L. (2020). *DevOps: A Software Architect's Perspective*. Addison-Wesley.
2. Fowler, M. (2021). *Continuous Delivery and DevOps: A Quickstart Guide*. O'Reilly Media.
3. Forsgren, N. (2021). *Accelerate: The Science of Lean Software and DevOps*. IT Revolution Press.
4. Humble, J. (2020). *The DevOps Handbook: How to Create World-Class Agility, Reliability, and Security in Technology Organizations*. IT Revolution Press.
5. Kim, G., Debois, P., & Willis, J. (2021). *DevOps for Dummies*. Wiley.

Deep Learning-Based Fire Detection Using Convolutional Neural Networks

Spatayev Aibar

jeanpierreairbar@outlook.com

Fire detection is a crucial task in disaster prevention and the protection of human lives and infrastructure. Traditional fire detection methods, such as smoke and heat sensors, suffer from high latency and frequent false alarms. This study proposes a fire detection method based on Convolutional Neural Networks (CNN), enabling real-time automatic fire recognition in images. CNN analyzes visual fire patterns, allowing for efficient classification of fire and non-fire images. The proposed approach demonstrates high accuracy and robustness under challenging lighting conditions compared to conventional fire detection methods.

Keywords: CNN, fire detection, deep learning, visual analysis, fire prevention.

Fire Detection Results:

Below are sample results of fire detection using the CNN model:

Detected Fire:


1/1  0s 47ms/step



Fire: Yes (1.00)

No Fire Detected:

1/1  0s 60ms/step



Fire: No (0.01)

References:

- [1] Ministry of Emergency Situations of Kazakhstan, "Fire Safety Report 2023," [Online]. Available: <https://www.gov.kz/memleket/entities/kps/documents/details/614050>.
- [2] Ministry of Emergency Situations of Kazakhstan, "Fire Safety Report 2021," [Online]. Available: <https://www.gov.kz/memleket/entities/kps/documents/details/327575>.
- [3] J. Zhang, L. Wang, and Y. Liu, "Convolutional Neural Networks Based Fire Detection in Surveillance Videos," IEEE Access, vol. 6, pp. 18174-18183, 2018. DOI: 10.1109/ACCESS.2018.2819198.

DEVELOPMENT OF AN INTELLIGENT CHATBOT FOR COLLECTING AND PROTECTING MEDICAL DATA USING AES ALGORITHM FOR ENCRYPTION AND ANALYSIS

Marat Arman

Master's student of the Department of Computer Science

Scientific supervisor – Pyrkova A.Y.

Professor, Candidate of Physical and Mathematical sciences

Al-Farabi Kazakh National University

Almaty, Kazakhstan

In modern healthcare, ensuring the confidentiality and security of patient data is a crucial challenge. This paper presents the development of an intelligent chatbot designed for secure medical data collection and protection. The system integrates the Advanced Encryption Standard (AES) algorithm to encrypt sensitive patient information, ensuring compliance with data protection regulations such as GDPR and HIPAA. The chatbot employs artificial intelligence and natural language processing (NLP) techniques to facilitate seamless interactions while maintaining strong security protocols. A critical aspect of the proposed system is key management, which ensures that encryption and decryption processes remain secure, efficient, and resistant to cyber threats. Future research will focus on optimizing encryption efficiency and integrating multi-factor authentication for enhanced security.

The increasing digitization of healthcare services has led to the widespread adoption of AI-driven chatbots for patient interaction and data management [1]. However, with the growing reliance on digital healthcare systems, security threats such as data breaches and cyberattacks pose significant risks. Ensuring the confidentiality of sensitive medical data requires robust encryption mechanisms, with AES being one of the most effective and widely adopted algorithms for securing information.

This study explores the implementation of AES encryption within an AI-powered chatbot to provide secure medical data collection and storage. Additionally, key management strategies are employed to address encryption vulnerabilities, ensuring efficient and secure handling of cryptographic keys. The system aims to provide real-time assistance to patients while safeguarding their personal health information.

The chatbot system consists of three main components: the chatbot interface, the encryption module, and the database management system. The chatbot interface uses NLP techniques to interpret user queries and provide automated responses [2]. It is designed to interact with patients and medical professionals, ensuring clear and concise communication while addressing medical concerns and securely storing collected data.

The **encryption module** applies AES-256 encryption to protect patient data before storage. AES-256 is chosen due to its high security level and resistance to brute-force attacks [3]. The encryption process involves generating a unique encryption key for each session, ensuring that patient data remains secure. The system employs a **hybrid key management strategy**, which includes:

- **Secure key storage:** Keys are securely stored using hardware security modules (HSMs) or encrypted key vaults to prevent unauthorized access.

- **Key rotation:** Periodic key rotation is implemented to minimize risks associated with long-term key usage.

- **Access control:** Only authenticated and authorized users can retrieve or use encryption keys, reducing the likelihood of data breaches.

To enhance security, the chatbot supports **role-based authentication**, distinguishing between patients and medical professionals (doctors). Patients can access their medical history and communicate with healthcare providers, while doctors can retrieve and analyze encrypted patient records.

The chatbot is developed using **Python** and integrates with **Microsoft SQL Server** for

encrypted data storage. The database structure is designed to store encrypted patient records, authentication logs and access history. Queries to retrieve data involve decrypting records on the fly for authorized users, ensuring that plaintext data is never stored in the database [4].

The developed chatbot system successfully encrypts and decrypts medical data with minimal latency, ensuring real-time responsiveness. AES encryption effectively protects data during storage and transmission, meeting modern healthcare security standards [5]. The integration with MS SQL Server allows encrypted data to be securely stored and retrieved upon authorized access.

While the system ensures strong data protection, further improvements are required in key management strategies. The introduction of multi-factor authentication (MFA) could further enhance security. Additionally, federated learning approaches can be integrated to allow AI-driven chatbots to improve healthcare services while preserving patient privacy.

This research presents an intelligent chatbot system that applies AES encryption for secure medical data handling. The proposed solution addresses key cybersecurity challenges, ensuring confidentiality, integrity and accessibility of sensitive healthcare information. Future developments will focus on enhancing authentication mechanisms, improving encryption efficiency and expanding the chatbot's capabilities for personalized healthcare services.

References:

1. Laranjo, L., et al. (2018). «Conversational agents in healthcare: A systematic review.» *Journal of Medical Internet Research*, 20(12), 1248–1258.
2. Vaidyam, A. N., et al. (2019). «Chatbots and conversational agents in mental health: A review of the psychiatric landscape.» *Canadian Journal of Psychiatry*, 64(7), 456-464.
3. Sandhiya D. S., et al. (2022). «Secured Health Monitoring System Using AES.» *East Asian Journal of Multidisciplinary Research*, 1(6), 1175-1182.
4. Liu, X., et al. (2020). «A privacy-preserving chatbot system based on encrypted data.» *IEEE Access*, 8, 201923-201934.
5. Bates, B. R., & Wright, K. B. (2020). «Chatbots and health communication: A rapid review.» *JMIR AI*, 1(1), e16039.

Менторлық, жобалық оқыту және кейіпкерді дамыту элементтері бар білім беру платформасын әзірлеу

Ашим Т.Т.

ал-Фараби атындағы Қазақ Ұлттық университетінің 4 курс студенті

Email: temirlan.ashim.04@mail.ru

Пыркова А.Ю.

Әл-Фараби атындағы Қазақ Ұлттық университетінің ф.-м.ғ.к., ғылымдар профессоры

Қазіргі кезде технологиялардың қарқынды дамуы дәстүрлі оқыту әдістерінің тиімділігін төмендетуде. Жеке тұлғаға бағытталған оқыту, менторлық қолдау және ойын механикаларын біріктіретін интерактивті шешімдер қажет.

Осы жұмыс онлайн-курстарды, жобалық оқытуды, менторлық жүйені және кейіпкерді дамыту элементтерін біріктіретін білім беру платформасын әзірлеуге арналған. Платформа студенттерге практикалық тапсырмалар мен жобалар арқылы жаңа дағдыларды меңгеруге мүмкіндік беретін жеке білім беру траекторияларын ұсынады. Жүйенің негізі ретінде виртуалды шындықты және динамикалық прогресті бақылау арқылы геймификация әдістері қолданылып, оқуға деген қызығушылықты арттырып, пайдаланушыларды ынталандырады.

Платформаның басты элементтерінің бірі – "кейіпкерді дамыту" тұжырымдамасы, ол студенттің дағдылары, тәжірибесі және жетістіктерінің өсуі арқылы оның білім алу жолын айқын көрсетеді және оқуға мотивацияны арттырады. Менторлар нақты уақыт режимінде студенттердің жетістіктерін бағалап, олардың білім алу траекториясын түзетуге және тиімді қолдау көрсетуге мүмкіндік алады.

Қорытындылай келе, әзірленіп отырған платформа онлайн-білім беру саласындағы инновациялық шешім болып табылады және ол тек білім алуды ғана емес, сонымен қатар жобалық қызмет, интерактивті технологиялар және менторлық қолдау арқылы оқушылардың жан-жақты дамуына ықпал етеді.

Пайдаланылған әдебиеттер тізімі:

1. Конноли Т., Бегг К. (2014). *Базы данных: Практический подход к проектированию, реализации и управлению* (6-е издание). Pearson.
2. Firebase, AWS – облачные решения для хранения данных.
3. MIT OpenCourseWare – принципы открытого образования.
4. Duolingo, CodeCombat – примеры геймификации.
5. Coursera, Udemy, Khan Academy – анализ методик онлайн-обучения.

Туризм саласындағы жасанды интеллект әдістерін зерттеу және талдау

Смағұл А.Қ.

Әл-Фараби атындағы Қазақ Ұлттық университеті

Бұл дипломдық жұмыста туризм саласында жасанды интеллект әдістерін қолдану арқылы пайдаланушы тәжірибесін жақсарту және туристік ұсыныстарды жекелендіру мәселелері жан-жақты зерттелді. Туризм — экономиканың қарқынды дамып келе жатқан салаларының бірі, сондықтан заманауи технологияларды енгізу, әсіресе ЖИ әдістерін пайдалану, саланың тиімділігін арттыруда маңызды рөл атқарады.

Жұмыстың мақсаты – туристердің пікірлерін автоматты түрде өңдеп, сол негізде туристік бағыттарды ұсынатын интеллектуалдық жүйені әзірлеу және оның тиімділігін талдау. Жобада пайдаланушы пікірлеріндегі семантикалық ақпаратты терең түсініп, олардың мазмұнына сәйкес ұсыныстар қалыптастыру үшін заманауи трансформер архитектурасына негізделген тілдік модельдер қолданылды.

Мәтіндік мәліметтерді өңдеу барысында олар эмбеддингтерге түрлендірілді. Бұл эмбеддингтер RuBERT-base, TinyBERT-2 және XLM-RoBERTa секілді алдын ала оқытылған модельдер арқылы алынды. Бұл модельдер табиғи тілді өңдеудің ең озық үлгілері болып табылады және мәтіндердің мағыналық мазмұнын тиімді түрде анықтап, талдау сапасын айтарлықтай арттырды.

Жұмыс барысында аталған үш модельдің өнімділігі мен дәлдігі салыстырылып, семантикалық мәтін өңдеу, пайдаланушы қызығушылықтарын анықтау, тексттік кластеризация және жекелендірілген ұсыныстарды қалыптастыру тапсырмаларында олардың тиімділігі бағаланды. Жүргізілген тәжірибелік зерттеулер нәтижесінде, пікірлерді талдап, туристік бағыттарды ұсынатын интеллектуалдық жүйе құрылды.

Сонымен қатар, жүйені құру барысында:

- деректерді алдын ала өңдеу,
- шулы және мағынасыз мәтіндерді тазалау,
- мәтіндердің мағыналық ерекшеліктерін сақтау,
- модельдердің тиімді жұмыс істеуі үшін гиперпараметрлерді оңтайландыру,
- кластерлік топтастыру мен ұсыныс генерациясы алгоритмдерін енгізу процестері жүзеге асырылды.

Алынған нәтижелер нақты туризм саласына бейімделген, пайдаланушының жеке сұраныстарына жауап бере алатын интеллектуалдық жүйелерді қалыптастыруда практикалық маңызға ие. Мұндай жүйелер туристерге бағыт-бағдар беріп қана қоймай, сонымен қатар туризм индустриясының цифрлық трансформациясын жеделдетуге септігін тигізеді.

Жұмыс барысында пайдаланылған әдістер болашақта туристік агенттіктерге, онлайн платформаларға және мобильдік қосымшаларға енгізіліп, пайдаланушыларға интеллектуалды сервистер ұсынуға мүмкіндік береді.

Пайдаланылған әдебиеттер тізімі:

1. Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *arXiv preprint arXiv:1810.04805*.
2. Lan, Z., Chen, M., Goodman, S., Gimpel, K., Sharma, P., & Soricut, R. (2020). ALBERT: A Lite BERT for Self-supervised Learning of Language Representations. *ICLR 2020*.
3. Conneau, A., Khandelwal, K., Goyal, N., Chaudhary, V., Wenzek, G., Guzmán, F., et al. (2020). Unsupervised Cross-lingual Representation Learning at Scale. *ACL 2020*.
4. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., et al. (2017). Attention is All You Need. *NIPS 2017*.
5. Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep Learning based Recommender System: A Survey and New Perspectives. *ACM Computing Surveys*.

6. Туризм индустриясындағы цифрлық технологиялар: Талдау және болашағы. — Алматы: ҚазҰУ баспасы, 2023.
7. Russell, S., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach*. Pearson Education.

«Адам-компьютерлік өзара әрекеттесудегі қимылдарды тану алгоритмдерін зерттеу»

Жетписбай Р.С.

Әл-Фараби атындағы Қазақ Ұлттық университеті

Қазіргі заманауи ақпараттық технологиялар дәуірінде адамның компьютерлік жүйелермен өзара әрекеттесу тәсілдері маңызды рөлге ие болуда. Дәстүрлі енгізу құралдары – пернетақта мен тінтуір – біртіндеп табиғи және интуитивті басқару әдістерімен ауыстырылып келеді. Осы тұрғыда адамның қимыл әрекеттерін тануға негізделген интерфейстер ерекше қызығушылық тудырып отыр.

Дипломдық жұмыстың негізгі мақсаты — адам қимылдарын автоматты түрде тануға арналған тиімді алгоритмдерді зерттеп, олардың артықшылықтары мен кемшіліктерін салыстырмалы түрде бағалау. Бұл мақсатқа жету үшін келесі міндеттер қойылды:

- Қимылдарды тануға арналған алгоритмдердің теориялық негіздерін зерттеу және тиімді алгоритмдерді таңдау;

- Қимылдық әрекеттерді тану үшін Convolutional Neural Networks (CNN), Hidden Markov Models (HMM) және Long Short-Term Memory (LSTM) сияқты заманауи әдістерді қарастыру;

- Қимылдарды тануға арналған деректер жиынтығын құру, алдын ала өңдеу (аугментация, масштабтау және т.б.);

- Әрбір таңдалған алгоритм негізінде модель құрып, оларды оқыту процесін ұйымдастыру;

- Жасалған модельдердің тиімділігін (дәлдік – accuracy, жоғалту – loss, оқу уақыты мен ресурстық шығындар) салыстырмалы түрде талдау.

Жұмыста CNN архитектурасының бірі — ResNet101 моделі қолданылды, ол статикалық қимылдарды (мысалы, қолдың нақты бір позициясын) жоғары дәлдікпен тануға мүмкіндік береді. Сонымен қатар, HMM алгоритмі динамикалық қимыл реттілігін модельдеу үшін пайдаланылды, ал LSTM нейрондық желісі уақытша байланысы бар қимылдар мен реттіліктерді тиімді тануға бағытталды.

Зерттеу нәтижесінде CNN моделі жоғары дәлдік (99.98%) көрсетті, HMM алгоритмі қарапайым және ресурстарды аз қажет ететін модель ретінде танылды, ал LSTM уақыттық динамиканы жақсы сипаттағанымен, оқу процесі баяулау болды және нәтижелері басқа модельдерден төмен болды (accuracy – 52%).

Бұл зерттеу қимылдарды тану саласындағы алгоритмдерді салыстыруға және олардың нақты қолдану салаларына сәйкес тиімді шешім таңдауға мүмкіндік береді. Алынған нәтижелер болашақта робототехникада, виртуалды шындық, білім беру және мүгедек адамдарға арналған көмекші жүйелерде кеңінен қолданылуы мүмкін.

Пайдаланылған әдебиеттер тізімі:

1. Бурбаева, Г.К., Сагидуллина, А.К. — «Жасанды интеллект негіздері». – Алматы: Білім, 2020.
2. Жетписбаев, Е.Т. — «Машиналық оқыту және бейнелерді өңдеу». – Алматы: Қазақ университеті, 2021.
3. Goodfellow, I., Bengio, Y., Courville, A. — Deep Learning. – MIT Press, 2016.
4. Bishop, C.M. — Pattern Recognition and Machine Learning. – Springer, 2006.
5. Rabiner, L.R. — A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition // Proceedings of the IEEE, 1989.
6. Hochreiter, S., Schmidhuber, J. — Long Short-Term Memory // Neural Computation, 1997.
7. He, K., Zhang, X., Ren, S., Sun, J. — Deep Residual Learning for Image Recognition (ResNet) // Proceedings of the IEEE Conference on CVPR, 2016.

8. Zhang, Z., Cui, P., Zhu, W. — Deep Learning on Graphs: A Survey // IEEE Transactions on Knowledge and Data Engineering, 2020.
9. Karpathy, A., Fei-Fei, L. — Deep Visual-Semantic Alignments for Generating Image Descriptions // IEEE CVPR, 2015.
10. W3Schools, TensorFlow & PyTorch Documentation — <https://www.tensorflow.org/> | <https://pytorch.org/>
11. OpenCV Documentation — Computer Vision Library — <https://docs.opencv.org/>
12. Kaggle datasets — Gesture Recognition Datasets — <https://www.kaggle.com/>
13. Жасанды интеллект және компьютерлік көру саласындағы ғылыми мақалалар (Scopus/IEEE/Elsevier базалары).

Қимылдарды тану үшін терең нейрондық желі архитектураларын талдау

Қойшиев А.

Әл-Фараби атындағы Қазақ Ұлттық университеті

Қимылдарды тану-бұл әртүрлі құрылғылар мен жүйелерді басқарудың контактісіз, интуитивті және табиғи әдісін қамтамасыз ететін адам-компьютерлік өзара әрекеттесудің (Human-Computer Interaction, HCI) негізгі бағыты. Бұл адам мен компьютер арасындағы өзара әрекеттесудің ыңғайлылығын едәуір арттыруға мүмкіндік береді, әсіресе виртуалды және кеңейтілген шындық, робототехниканы басқару, медициналық интерфейстер, оқыту жүйелері, мүгедектерге көмек көрсету технологиялары, сондай-ақ "ақылды үй".

Қазіргі уақытта қимылдарды танудың ең тиімді тәсілдерінің бірі-терең конволюциялық нейрондық желілерді (Convolutional Neural Networks, CNN) пайдалану. VGG-16, InceptionV3 және ResNet-101 сияқты қазіргі заманғы CNN архитектуралары әртүрлі құрылымдық ерекшеліктерге, тереңдікке және параметрлер санына ие, бұл тану дәлдігі, шуға төзімділік, жалпылау қабілеті, оқу жылдамдығы және ресурстардың сыйымдылығы сияқты сипаттамаларға тікелей әсер етеді. Осы архитектураларды талдау және салыстыру дәлдік пен өнімділік талаптарын ескере отырып, қимылдарды жіктеу мәселелерін шешуге ең қолайлы модельді анықтауға мүмкіндік береді.

Осы жұмыс аясында нейрондық желілердің аталған архитектураларына егжей-тегжейлі теориялық және практикалық талдау жүргізілді. Модельдерді оқыту үшін 44 сыныпқа бөлінген Қазақ жест әліпбиінің 345918 бейнесі (әр сыныпта 7998 суреттен) тұратын меншікті датасет пайдаланылды. Суреттер қазақ әліпбиінің нышандарына сәйкес келетін қол қимылдарын көрсететін статикалық кадрлар болып табылады, бұл осы деректер жиынтығын ұлттық қимылдарды автоматты тану жүйелері үшін бірегей және өзекті етеді.

Модельдерді оқыту алдында деректерді дайындау кезеңі өткізілді, оның ішінде:

- кескінді қалыпқа келтіру,
- бір өлшемге масштабтау,
- датасетті оқыту және тест үлгілеріне бөлу,
- модельдердің жалпылау қабілетін арттыру үшін деректерді күшейту.

Әрбір модель pytorch кітапханасының көмегімен жүзеге асырылды, содан кейін оңтайландырғыштар, белсендіру функциялары және жоғалту функциялары орнатылды. Оқу процесінде негізгі көрсеткіштер — accuracy, loss, сондай-ақ оқу уақыты мен Модель өлшемі тіркелді, бұл архитектуралар арасында егжей-тегжейлі салыстыруға мүмкіндік берді.

Пайдаланылған әдебиеттер тізімі:

1. Гудфеллоу И., Бенджио Й., Курвил А. – *"Глубокое обучение" (Deep Learning)*. — М.: Диасофт, 2018. Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
2. Бишоп К. – *"Распознавание образов и машинное обучение" (Pattern Recognition and Machine Learning)*. — Springer, 2006. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
3. He K., Zhang X., Ren S., Sun J. – *Deep Residual Learning for Image Recognition* // arXiv:1512.03385 Holmes, N. S., & Morawska, L. (2006). A review of dispersion modeling and its application to the dispersion of particles: An overview of different dispersion models available. *Atmospheric Environment*, 40(30), 5902-5928.
4. Szegedy C. et al. – *Rethinking the Inception Architecture for Computer Vision* // arXiv:1512.00567 Karagulian, F., Barbieri, M., Kotsev, A., & Laguna, M. (2019). Review of the performance of low-cost sensors for air quality monitoring. *Atmospheric Environment*, 213, 579-593.
5. Simonyan K., Zisserman A. – *Very Deep Convolutional Networks for Large-Scale Image Recognition* // arXiv:1409.1556

Әлсіз жарық жағдайларында объектіні анықтау дәлдігін жақсарту мақсатында конволюциялық нейрондық желілерді оңтайландыруға арналған генетикалық алгоритмін әзірлеу

Наркешова Ф.М.

ал-Фараби атындағы Қазақ ұлттық университеті, 4 курс студенті

E-mail: narkeshovafarida@gmail.com

Ғылыми жетекші: КН кафедрасының оқытушысы, Жасұзақ М.С.

Әлсіз жарық жағдайында объектілерді анықтауды автоматтандыру қауіпсіздік, бейнебақылау, медицина, әскери, кедендік және өнеркәсіптік бақылау салаларында өзекті мәселе болып табылады [4]. Қазіргі бейне детекция жүйелері көбінесе қолмен талдауға немесе қымбат сенсорлық құрылғыларға сүйенеді, бұл олардың дәлдігі мен тиімділігін төмендетеді.

Бұл дипломдық жұмыста YOLOv5 бейне детекция моделі [1], [8] негізінде, алдын ала өңдеу әдістері (CLAHE, гамма коррекциясы, гистограмма теңестіру, гауссиандық бұлыңғырландыру, билатерал фильтр, Non-Local Means, Gray-World және Max-RGB баланс, Retinex, MSRCR) және генетикалық алгоритмдерді [5], [6] біріктіру арқылы әлсіз жарықтағы бейнелерден объектілерді автоматты түрде анықтаудың дәлдігін арттыру көзделеді. Жүйенің бастапқы деректері нақты уақыттағы бейнекамералардан алынған, ал алгоритм алдымен кескінді алдын ала өңдеу арқылы сапасын жақсартып, содан соң YOLOv5 моделі арқылы объектілерді анықтайды. Сонымен қатар, генетикалық алгоритм арқылы фильтрлердің параметрлері автоматты түрде оңтайландырылып, детекцияның жалпы өнімділігі мен сенімділігі арттырылады [1], [8].

Эксперименталды сынақтар нәтижелері ұсынылған интеграцияланған әдістің әлсіз жарық жағдайында алынған деректерден объектілерді дәстүрлі әдістерге қарағанда жоғары дәлдікпен анықтайтынын және есептеу ресурстарын тиімді пайдаланатынын көрсетті [7]. Осылайша, жұмыс автономды жүйелер, медицина, бейнебақылау, әскери, кедендік және өнеркәсіптік бақылау салаларында қауіпсіздікті қамтамасыз ететін жаңа технологиялық шешімдердің дамуына елеулі үлес қосады [1], [6].

Пайдаланылған әдебиеттер тізімі:

1. Jocher, G., Chaurasia, A., Qiu, J., & Stoken, A. (2020). YOLOv5. GitHub repository. <https://github.com/ultralytics/yolov5>
2. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *You Only Look Once: Unified, Real-Time Object Detection*. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
3. Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). *YOLOv4: Optimal Speed and Accuracy of Object Detection*. arXiv preprint arXiv:2004.10934.
4. Bradski, G. (2000). *The OpenCV Library*. Dr. Dobb's Journal of Software Tools.
5. Goldberg, D.E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley.
6. Eiben, A. E., & Smith, J.E. (2015). *Introduction to Evolutionary Computing* (2nd ed.). Springer.
7. Python Software Foundation. (2020). *multiprocessing — Process-based parallelism*. Python 3.10 Documentation. <https://docs.python.org/3/library/multiprocessing.html>
8. Ultralytics. *YOLOv5 Documentation*. <https://docs.ultralytics.com/>

Қазақ ым тілін компьютерлік көру және оқыту әдістерін қолдану арқылы тану жүйесін әзірлеу

Құдіретулла Ж.Н.

Әл-Фараби атындағы Қазақ ұлттық университеті, 4-курс студенті

E-mail: zhansaya_kudretulla@mail.ru

Ғылыми жетекші: КН кафедрасының оқытушысы, Жасұзақ М.С.

Қазіргі уақытта әлемде 70 миллионнан астам есту және сөйлеу қабілеті бұзылған адамдар өмір сүреді, және олардың негізгі қарым-қатынас құралы — ым тілі. Дегенмен, Қазақстанда қазақ ым тілі (ҚЫТ) кеңінен қолданылмайды және оны тануға арналған автоматтандырылған жүйелер жоқтың қасы. Сөйлеу мүмкіндігі шектеулі жандардың қоғамға бейімделуін жеңілдету мақсатында қазақ ым тілін тану және талдау жүйесін жасау — маңызды ғылыми және әлеуметтік мәселе.

Қолданыстағы шешімдердің көпшілігі американдық ым тілі (ASL) немесе халықаралық стандарттарға негізделген. Бұл қазақ ым тілінің ерекшеліктерін толық қамтымайды және модельдің нақты жұмыс істеуіне кедергі келтіреді. Сондықтан машиналық оқыту және компьютерлік көру әдістерін біріктіріп, қазақ ым тілін тану үшін жаңа жүйе құру қажеттілігі туындап отыр. Қазақ ым тілін тану үшін нақты уақыт режимінде жұмыс істейтін **интеллектуалды модуль** әзірлеу. Жүйе YOLOv5 және LSTM желілерінің үйлесімді жұмысын қамтамасыз етеді және танылған қимылдарды веб-интерфейс арқылы пайдаланушыға ұсынуға қабілетті.

Зерттеу барысында қазақ ым тіліндегі бір қолмен жасалатын әріптер мен сөздерді қамтитын толыққанды деректер жиынтығы пайдаланылды. Жиынтыққа **42-бейнефайл** және **10000-нан астам сурет** енгізілді. Деректер әртүрлі жарық, бұрыш және фон жағдайларында түсіріліп, алдын ала өңдеуден өткізілді. Модельді оқыту үшін YOLOv5 және LSTM желілерінің үйлесімі қолданылды. YOLOv5 бейнекадрлардан қимылдарды жылдам тануға мүмкіндік береді, ал LSTM модельге уақыт ішіндегі динамиканы талдауға көмектеседі. YOLOv5 моделі арқылы нақты уақыт режимінде қазақ ым тілінің қимылдарын тану мүмкіндігі дәлелденді. Жүйе танылған қимылдарды сөзге айналдырып, оларды толыққанды сөйлемге біріктіре алады. Нақты уақыт режимінде қимылдарды тану жылдамдығы **32 FPS** деңгейінде болды. Жүйе танылған сөздерді веб-интерфейс арқылы нақты уақытта көрсетіп, пайдаланушыға ыңғайлы интерфейсте ұсынады.

Осы зерттеу нәтижесінде қазақ ым тілін тануға арналған интеллектуалды жүйе әзірленді. Жүйе YOLOv5 және LSTM негізінде жұмыс істейді және нақты уақыт режимінде жоғары дәлдікпен қимылды тануға қабілетті. Жасалған жүйе қазақ ым тілін үйренушілер мен есту қабілеті бұзылған жандар үшін маңызды көмекші құралға айналады.

Список использованной литературы:

1. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*. 2017.
2. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016.
3. Redmon J., Divvala S., Girshick R., Farhadi A. You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016.
4. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997.
5. Cao Z., Hidalgo G., Simon T., Wei S., Sheikh Y. OpenPose: Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2021.

Разработка метода распознавания действий и анализа поведения людей в толпе с применением алгоритмов компьютерного зрения.

Әбдіразақ З.Б.

Казахский Национальный Университет им. аль-Фараби, магистрант 1 курса

E-mail: abdirazakzemfira@gmail.com

Научный руководитель: преподаватель кафедры КН, PhD Бурибаев Ж.А.

Анализ поведения людей в толпе является актуальной задачей в области компьютерного зрения и искусственного интеллекта. В данной работе предлагается метод распознавания действий в толпе с использованием трехмерных сверточных нейронных сетей (3D CNN) [1] и долговременной краткосрочной памяти (LSTM) [2]. Разработанный метод направлен на автоматическое выявление аномального поведения, такого как драки, митинги и нормальная активность, что особенно важно для обеспечения общественной безопасности и мониторинга массовых мероприятий.

Распознавание действий и анализ поведения людей в толпе являются ключевыми задачами в системах видеонаблюдения и безопасности. Современные методы компьютерного зрения позволяют автоматизировать процесс идентификации потенциальных угроз и аномальных ситуаций в реальном времени. В данной работе предлагается метод, основанный на комбинации 3D CNN и LSTM, который обеспечивает высокую точность классификации действий в толпе [3].

Для обучения модели использовалась база данных, содержащая 450 видеозаписей, распределенных на три класса: "Fighting" (драка), "Meeting" (митинг) и "Normal" (нормальное поведение). Каждый класс содержит 150 видеороликов, из которых 200 использовались для обучения и 70 — для тестирования.

Метод включает следующие этапы:

1. **Предобработка данных:** нормализация видео, выделение ключевых кадров, аугментация данных.
2. **Извлечение пространственно-временных признаков:** 3D CNN анализирует пространственно-временные зависимости в видеопоследовательностях.
3. **Темпоральное моделирование:** LSTM используется для моделирования временных зависимостей между кадрами, что позволяет лучше понимать динамику движений.
4. **Классификация действий:** финальный слой нейронной сети выполняет классификацию поведения в толпе на основе извлеченных признаков.

Экспериментальные исследования показали высокую точность классификации. Метод 3D CNN + LSTM продемонстрировал лучшие результаты по сравнению с традиционными методами распознавания действий, такими как двумерные сверточные сети (2D CNN) и рекуррентные нейронные сети (RNN). Средняя точность классификации составила 80%, что свидетельствует о высокой эффективности предложенного подхода несмотря на небольшое количество данных для обучения модели.

Предложенный метод демонстрирует высокую точность распознавания действий и может быть использован для мониторинга общественных пространств, предотвращения преступлений и анализа поведения людей в массовых мероприятиях. В дальнейших исследованиях планируется расширение базы данных, тестирование метода в реальных условиях и оптимизация архитектуры модели для повышения скорости обработки видео.

Список использованной литературы:

1. Sun Z. et al. Human action recognition from various data modalities: A review //IEEE transactions on pattern analysis and machine intelligence. – 2022. – Т. 45. – №. 3. – С. 3200-3225.

2. Wu D., Sharma N., Blumenstein M. Recent advances in video-based human action recognition using deep learning: A review //2017 International joint conference on neural networks (IJCNN). – IEEE, 2017. – C. 2865-2872.
3. Kong Y., Fu Y. Human action recognition and prediction: A survey //International Journal of Computer Vision. – 2022. – T. 130. – №. 5. – C. 1366-1401.

Нысанаға тиген оқтарды автоматты түрде анықтауға арналған интеллектуалды модульді әзірлеу

Сейтбек А.Б.

ал-Фараби атындағы Қазақ ұлттық университеті, 4 курс студенті

E-mail: aibek8736@gmail.com

Ғылыми жетекші: КН кафедрасының оқытушысы, Жасұзақ М.С.

Ату дәлдігін бағалауды автоматтандыру спорттық және әскери дайындықта маңызды мәселе болып табылады. Қазіргі жүйелер көбінесе қолмен талдау немесе қымбат сенсорлық технологияларды қолданады. Бұл жұмыста компьютерлік көру технологиясын қолдана отырып, нысанаға тиген оқтарды автоматты түрде анықтайтын интеллектуалды модуль әзірлеу ұсынылады. Зерттеу нысаны ретінде статикалық нысананы пайдалана отырып жүргізілетін ату жүйесі алынды. Модельді оқытуға арналған деректер бейнекамерадан алынған. Алгоритм нысананың кескінін талдай отырып, тиген оқтарды анықтап, олардың дәлдігін бағалайды.

Әдістер деректерді алдын ала өңдеуді, тиген оқтарды анықтауды және оларды жіктеуді қамтиды. Алдын ала өңдеу барысында шуды сүзу және кескінді түзету жүзеге асырылады. Тиген оқтарды анықтау үшін кадрлар арасындағы айырмашылықтарды талдау және контурлық әдістер қолданылады. Оқтарды ажырату үшін әрбір мергенге ерекше түсті кодтау әдісі қолданылады, бұл нәтижелерді жеке-жеке белгілеуге мүмкіндік береді.

Тиген оқтарды дәл анықтау үшін OpenCV кітапханасының кескінді өңдеу әдістері қолданылады. Әрбір оқ атылғаннан кейін жүйе тиген оқтың координаттарын анықтап, белгіленген нүктеден ауытқуын есептейді және ату дәлдігін бағалайды. Ату сериясы аяқталған соң бағдарлама өңделген кескінді көрсетіп, тиген оқтарды белгілеп, олардың қай мергенге тиесілі екенін көрсетеді.

Сынақ нәтижелері жүйенің тиген оқтарды жоғары дәлдікпен анықтайтынын көрсетті, әсіресе нысана мен тиген оқтар арасындағы контраст жоғары болған жағдайда. Ең жақсы нәтижелер түсті кодтау әдісін қолданған кезде байқалды. Дайындалған алгоритм Django негізіндегі веб-қосымшаға интеграцияланды, бұл пайдаланушыларға нысананың суретін жүктеп, нақты уақыт режимінде ату нәтижелерін талдауға мүмкіндік береді.

Пайдаланылған әдебиеттер тізімі:

1. Bradski G. "The OpenCV Library." Dr. Dobb's Journal of Software Tools, 2000.
2. Shapiro, L., & Stockman, G. "Computer Vision." Prentice Hall, 2001.
3. Gonzalez, R. C., & Woods, R. E. "Digital Image Processing." Pearson, 2018.
4. Van Rossum, G., & Drake, F. L. "Python 3 Reference Manual." CreateSpace, 2009.
5. Django Software Foundation. "Django Documentation." Available from: <https://docs.djangoproject.com/>
6. OpenCV Team. "OpenCV Documentation." Available from: <https://docs.opencv.org/>
7. Pedregosa, F., et al. "Scikit-learn: Machine Learning in Python." Journal of Machine Learning Research, 2011.

AGRO кешенді бағдарламасының мәліметтер базасы құрамдас бөлігін құру

Есенова Н.Б.

Әл-Фараби атындағы Қазақ ұлттық университеті, 4-курс студенті

E-mail: yessenova07@gmail.com

Ғылыми жетекші: Компьютерлік ғылымдар кафедрасының доценті,

Урмашев Б.А.

Қазіргі таңда ауыл шаруашылығы саласы экономиканың маңызды салаларының бірі болып табылады. Қазақстандағы агроөнеркәсіп кешені ауыл шаруашылығы өнімдерін өндіру және өңдеу, логистика, нарыққа жеткізу және өндіріс тиімділігін арттыру сияқты бірқатар процестерді қамтиды. Осы процестердің үздіксіз жұмыс істеуі үшін сенімді және жоғары өнімді ақпараттық жүйе қажет. Осыған байланысты AGRO кешенді бағдарламасының мәліметтер базасы құрамдас бөлігін құру – өзекті мәселе болып табылады.

Мәліметтер базасы агроөнеркәсіп саласындағы негізгі мәліметтерді орталықтандырып сақтау және өңдеу мақсатында әзірленеді. Жүйе өнім өндіру, өңдеу, сату және логистика процестерін автоматтандыруға бағытталған. Сонымен қатар, нақты уақыт режимінде деректерді жаңарту және өңдеу мүмкіндігі қамтамасыз етіледі.

Зерттеу барысында Қазақстанның ауыл шаруашылығына қатысты статистикалық және аналитикалық деректер пайдаланылды. Жүйеде өндіріс, логистика және нарық жағдайына қатысты деректер жинақталып, орталықтандырылды. Деректер әртүрлі дереккөздерден алынды және алдын ала өңдеуден өткізілді.

Нәтижесінде AGRO кешенді бағдарламасының мәліметтер базасы деректерді нақты уақыт режимінде өңдеуге және жаңартуға қабілетті болады. Жүйе өндіріс пен логистика процестерін автоматтандырып, өнім өндіру және тарату тиімділігін арттырады. Пайдаланушы интерфейсі ыңғайлы болып, жүйе тұрақты жұмыс істеуі қамтамасыз етіледі.

Пайдаланылған әдебиеттер тізімі:

1. Date C.J. An Introduction to Database Systems. Addison-Wesley. 2019.
2. Elmasri R., Navathe S.B. Fundamentals of Database Systems. Pearson. 2017.
3. Korth H.F., Silberschatz A., Sudarshan S. Database System Concepts. McGraw-Hill. 2019.
4. Ullman J.D., Widom J. A First Course in Database Systems. Pearson. 2016.
5. Ramakrishnan R., Gehrke J. Database Management Systems. McGraw-Hill. 2016.
6. Codd E.F. A Relational Model of Data for Large Shared Data Banks. *Communications of the ACM*. 1970;13(6):377-387.

MPI ЖӘНЕ БІРНЕШЕ GPU ҚОЛДАНУ АРҚЫЛЫ ҮЛКЕН ДЕРЕКТЕРДІ ТАЛДАУҒА АРНАЛҒАН МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІН ІСКЕ АСЫРУ ЖӘНЕ ОҢТАЙЛАНДЫРУ

Жакып Аида

Әл-Фараби атындағы Қазақ ұлттық университеті

aidazhakypppp@gmail.com

Ғылыми жетекші: Мустафин Максат Бейбітұлы

Үлкен деректермен жұмыс істейтін қазіргі заманғы жүйелерде есептеу жүктемесін тиімді басқару өте маңызды. Машиналық оқыту алгоритмдері үлкен көлемді деректерді өңдеуде жиі қолданылады, алайда дәстүрлі тәсілдерде есептеу уақыты тым ұзақ болуы мүмкін. Бұл мәселені шешу үшін параллельді есептеулер мен GPU негізіндегі әдістер қолданылады. MPI процессорлар арасындағы байланыс пен есептеулерді тиімді ұйымдастыруға мүмкіндік берсе, RAPIDS GPU көмегімен деректерді жылдам өңдеуге мүмкіндік береді. Бұл жұмыста машиналық оқыту алгоритмдерінің параллельді нұсқаларын әзірлеу және олардың тиімділігін салыстыру мақсаты қойылды.

Әдістер мен технологиялар

Зерттеу барысында келесі тәсілдер қолданылды:

1. Тізбектей тәсіл: Машиналық оқыту алгоритімі бір процессорда іске қосылып, базалық өнімділік бағаланды.

2. MPI арқылы параллельдеу: Деректер бірнеше процессор арасында бөлініп, әрқайсысы өз бөлігін өңдеді. Алынған нәтижелер біріктірілді.

3. RAPIDS көмегі: GPU негізінде деректер өңделіп, сұрыптау, модель құру және болжам жасау үрдістері жылдамдатылды.

4. Параллельді RAPIDS комбинациясы: Бірнеше GPU-дың бірлескен жұмысы қамтамасыз етілді. Әр процессор өзіне бекітілген GPU-мен бірге есептеулерді орындады.

Талдау және нәтижелер

Зерттеу барысында әртүрлі деректер көлемімен тексерістер жүргізілді. Нәтижелер мынаны көрсетті:

- Тізбектей тәсіл кішігірім деректер үшін қолайлы болғанымен, үлкен көлемде өте баяу жұмыс істейді.

- MPI параллельдеу есептеу жылдамдығын арттырғанымен, коммуникациялық шығындар әсер етті.

- RAPIDS негізіндегі әдіс бір GPU-да жоғары өнімділікті көрсетті, алайда жад шектеулері байқалды.

- Параллельді RAPIDS тәсілі екі технологияны біріктіру арқылы жоғары тиімділікті көрсетті, әсіресе үлкен деректер жиынтығы үшін.

- Multi-GPU қолдану жалпы есептеу уақытын бірнеше есеге қысқартты, себебі жүктеме бірнеше GPU арасында тең бөлінді.

Жүргізілген зерттеу нәтижесінде параллельді RAPIDS комбинациясы және Multi-GPU тәсілдері ең тиімді әдістер ретінде анықталды. Бұл әдістер үлкен деректерді өңдеу кезінде уақыттық шығындарды азайтқанымен, модельдердің қателік метрикалары тізбектей модельдердің метрикаларына қарағанда әлде қайда айырмашылық көрсетіп, есептеу ресурстарын тиімді пайдалануға мүмкіндік береді. Болашақта модельдерді әрі қарай оңтайландыру және басқа параллельді платформалармен салыстыру жоспарлануда. Бұл жұмыс үлкен деректермен жұмыс істеудегі заманауи параллельді есептеулердің дамуына үлес қосады.

Пайдаланылған әдебиеттер тізімі:

1. Ian Foster, Designing and Building Parallel Programs, Addison-Wesley, 1995, 35-6.

2. Jason Sanders, Edward Kandrot. CUDA by Example: An Introduction to General-Purpose GPU Programming, Addison-Wesley, 2010, 47-б.
3. Peter Pacheco. Parallel Programming with MPI. Morgan Kaufmann, 1997, 78-б.
4. Grama A., Gupta A., Karypis G., Kumar V. Introduction to Parallel Computing, Addison-Wesley, 2003, 112-б.
5. <https://www.kaznu.kz/kk/> – Әл-Фараби атындағы ҚазҰУ сайты

DEVELOPMENT OF A DYNAMIC INDOOR EVACUATION INDICATOR BASED ON BLE BEACONS AND A* PATHFINDING ALGORITHM

Maxatbek Satymbekov, Alexandr Mustayev

Al-Farabi Kazakh National University, Department of Computer Science

E-mail: mustayev777@gmail.com

This paper presents the development of a compact and autonomous dynamic evacuation indicator for indoor environments based on Bluetooth Low Energy (BLE) technology and the A* pathfinding algorithm. The device is designed to guide individuals toward the safest exit during emergency situations such as fires, considering the user's real-time location and building layout. The system consists of an ESP32 microcontroller, four BLE beacons, and an SSD1306 OLED display that dynamically visualizes directional arrows. Indoor positioning is performed using signal strength (RSSI) values from nearby beacons, while the A* algorithm calculates the shortest path to the nearest available exit. Experimental testing was conducted in a simulated indoor setting, confirming the accuracy and responsiveness of the device. The prototype demonstrated fast processing times and real-time adaptation to simulated hazards. The proposed system offers a scalable and cost-effective solution to improve building evacuation strategies, especially in public facilities with limited infrastructure. Future work will focus on multi-device communication, integration with fire detection systems, and increase localization accuracy.

Keywords: Indoor positioning, emergency evacuation, Bluetooth Low Energy (BLE), ESP32, A* algorithm, fire safety

References:

1. World Health Organization, 'Burns', 2018. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/burns>
2. Ю. Ильин, 'В Казахстане на пожарах гибнет в 10 раз больше людей, чем в США', МЧС РК, 2022. [Online]. Available: <https://informburo.kz/novosti/v-kazahstane-na-pozharah-gibnet-v-10-raz-bolshe-lyudej-chem-v-ssha>
3. Правила пожарной безопасности Республики Казахстан, Приложение к постановлению Правительства РК, 2020. [Online]. Available: https://primeminister.kz/assets/media/prilozhenie-rus_14.pdf
4. Takir, 'Dynamic Evacuation Signs Using Digital Twins', 2023. [Online]. Available: <https://takir.ru/pdf/dinamicheskie-evakuacionnye-znaki.pdf>
5. AWEX, 'Quadro LED – Four-sided LED emergency signs', 2023. [Online]. Available: <https://exit-svet.ru/collection/svetovye-ukazateli-vyhod/product/chetyrehstoronnie-avariynye-svetovye-ukazateli-vyhoda-pri-pozhare-ip41-quadro-led-awex>
6. Headcount, 'The Evacuation App', 2023. [Online]. Available: <https://www.headcount.io>
7. Apple Inc., 'iBeacon Technology', 2013. [Online]. Available: <https://developer.apple.com/ibeacon>
8. GeeksforGeeks, 'A* Search Algorithm – Explained', 2023. [Online]. Available: <https://www.geeksforgeeks.org/a-search-algorithm>
9. Espressif Systems, 'ESP32 Series Datasheet', 2022. [Online]. Available: <https://www.espressif.com/en/products/socs/esp32/resources>
10. Floorplanner visualization. [Online] <https://floorplanner.com/projects/169652068/editor>

INTERPRETABLE NEURAL MODELING FOR POLYMER FLOODING THROUGH SYMBOLIC EXPRESSIONS IN KOLMOGOROV–ARNOLD NETWORKS

Bekele S.D.

Almaty, Al-Farabi Kazakh National University

Kenzhebek Y. (Almaty, Al-Farabi Kazakh National University)

Imankulov T. (Almaty, Al-Farabi Kazakh National University)

Modern machine learning solutions in enhanced oil recovery (EOR) demand not only high predictive precision but also transparency in decision-making. In our previous work, we introduced a Kolmogorov–Arnold Network (KAN) that produced competitive predictions for oil recovery factor (RF) in polymer flooding using a highly efficient architecture with just 1885 trainable parameters, compared to an earlier deep neural network (DNN) that required 43,265 parameters to achieve similar results [1]. This study explores KAN’s inner workings using a fresh approach: on-the-fly symbolic manipulation coupled with adaptive scaling and bias. The objective is to yield a closed-form mathematical expression that reveals the network’s embedded physics.

Fundamentally, KANs rest on the principle that any continuous multivariable function can be rendered as a sum of single-variable operations [2]. By granting each connection its own custom activation, one may later approximate these activation functions with symbolic expressions, producing an explicit formula that captures both linear and nonlinear dependencies. In our trials, this symbolic depiction closely replicates the KAN’s output, thus allowing straightforward inference without the original network’s full weight baggage – a significant advantage in resource-constrained or real-time settings. Our implementation used the library provided by the KAN authors: pyKAN [3].




Figure 1: Model plot a) before pruning and b) after pruning

To illustrate, we extracted a symbolic formula (Equation 1) for RF from a KAN trained under conditions resembling those of our high-performing model. The expression, although lengthy, lays bare each reservoir parameter’s role, from polymer concentration (Cp) to viscosity ($visc$). We then pruned the KAN by stripping away the least influential connections, which culminates in a leaner equation (Equation 2) that retains almost all-predictive merit. Diagrams of the unpruned (Figure 1a) and pruned (Figure 1b) networks demonstrate which pathways survive the pruning process. Notably, both symbolic formulas (before and after pruning) mirror the original KAN’s behavior (Figure 2) as reflected by similar mean square error (MSE) and coefficient of determination (R^2) scores.

$$\begin{aligned}
 RF = & 0.0111758511723978Cp + 0.000956658494203818P - 0.00286714517783192So + 1.76394920053389 \cdot \\
 & 10 - 8Sw - 1.24455962661157 \cdot 10 - 8k - 0.000664946988650714m - 0.000638440429052661visc + \\
 & 2.02035978991307 \cdot 10 - 5e0.000596761375153713Cp + 0.00120022699647735P + 0.000699158152867651So - \\
 & 4.14341625764557 \cdot 10 - 6Sw - 0.00115137546958596k + 0.000130837260275407m + \\
 & 0.000570444370567806visc + 0.00350308181737997e - 2.40159739582172 \cdot 10 - 5Cp - 6.80256775206777 \cdot
 \end{aligned}$$

$$\begin{aligned}
& 10 - 6P + 6.19250922163034 \cdot 10 - 6So - 1.34405922355298 \cdot 10 - 8Sw + 1.04522446224941 \cdot 10 - 7k + \\
& 1.53909715186648 \cdot 10 - 6m + 1.37831032333935 \cdot 10 - 6visc + \\
& 0.000744736474437691\sin(0.280719965696335Sw - 4.64799976348877) + 1.60098788200659 \cdot 10 - \\
& 5\sin(0.278399974107742k - 2.14111995697021) + 0.0358216933613656e - 2.09725687325879 \cdot 10 - 5Cp - \\
& 1.43187397656069 \cdot 10 - 5P + 5.29896084741276 \cdot 10 - 6So + 9.98867946360365 \cdot 10 - 8Sw + \\
& 2.35346466603834 \cdot 10 - 8k + 1.22663342506102 \cdot 10 - 6m + 9.86949331505623 \cdot 10 - 7visc + \\
& 0.000648544238205875\sin(0.280719965696335Sw - 4.64799976348877) + 1.39419983034505 \cdot 10 - \\
& 5\sin(0.278399974107742k - 2.14111995697021) - 0.347032482320172\sin(0.280719965696335Sw - \\
& 4.64799976348877) - 0.00746028720127826\sin(0.278399974107742k - 2.14111995697021) + \\
& 0.357558596149212
\end{aligned} \tag{1}$$

$$\begin{aligned}
RF = & 0.011175849800483Cp + 0.00095886465248997P - 0.00286714425052247So - \\
& 0.000664944704298185m - 0.000638412462351604visc - 0.347032286554624\sin(0.280719965696335Sw - \\
& 4.64799976348877) - 0.00746028299283299\sin(0.278399974107742k - 2.14111995697021) + \\
& 0.400323074903612
\end{aligned} \tag{2}$$

These succinct symbolic forms, once pruned for efficiency, offer a transparent picture of how reservoir properties affect recovery factor. They also slash computational burdens by eliminating the network and relying on a simple equation, which proves useful for rapid evaluations or embedding into larger simulations. Industry engineers and geoscientists can thus gain immediate insights into the interplay of reservoir parameters without sacrificing accuracy.

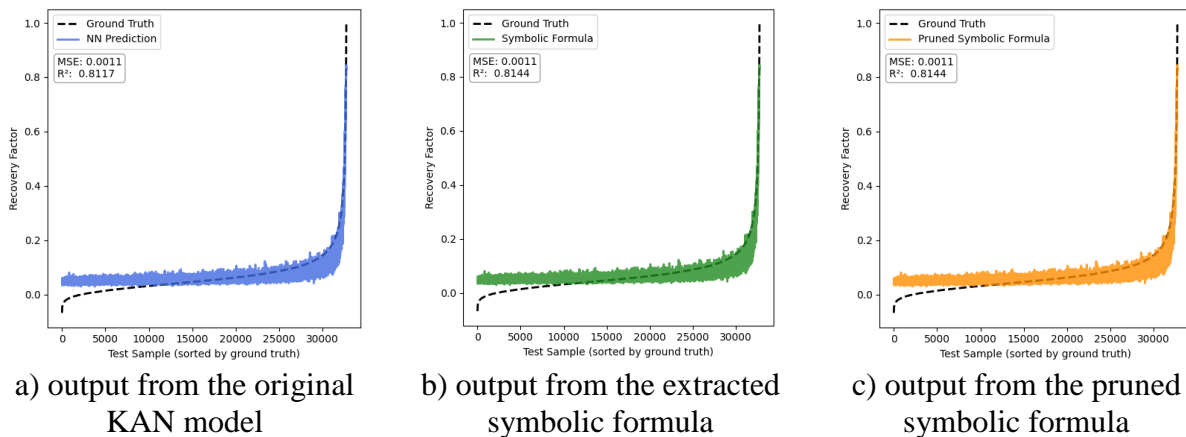


Figure 2. Comparison of Outputs against Ground Truth

We see potential to refine symbolic formulas using domain-specific reservoir physics. This could improve prediction confidence and expand the use of KAN-based frameworks. For researchers pondering the mysterious black boxes of conventional multilayer perceptrons (MLPs) [4], KANs stand ready as a welcome alternative: they can match or outshine standard MLPs on prediction tasks while providing insight of the underlying functional relationships learned.

References:

- [1] S. D. Bekele, Y. Kenzhebek, and T. Imankulov, “On the Effectiveness of Kolmogorov—Arnold Networks for Enhanced Oil Recovery Prediction in Polymer Flooding,” in *2024 7th International Conference on Algorithms, Computing and Artificial Intelligence (ACAI)*, Dec. 2024, pp. 1–6. doi: 10.1109/ACAI63924.2024.10899678.
- [2] Z. Liu *et al.*, “KAN: Kolmogorov-Arnold Networks,” Jun. 16, 2024, *arXiv*: arXiv:2404.19756. doi: 10.48550/arXiv.2404.19756.
- [3] Z. Liu, *KindXiaoming/pykan*. (Nov. 20, 2024). Jupyter Notebook. Accessed: Nov. 20, 2024. [Online]. Available: <https://github.com/KindXiaoming/pykan>

[4] F.-L. Fan, J. Xiong, M. Li, and G. Wang, “On Interpretability of Artificial Neural Networks: A Survey,” *IEEE Transactions on Radiation and Plasma Medical Sciences*, vol. 5, no. 6, pp. 741–760, Nov. 2021, doi: 10.1109/TRPMS.2021.3066428.

**«ИНТЕЛЛЕКТУАЛДЫ АҚПАРАТТЫҚ ЖҮЙЕЛЕРДЕГІ
МАТЕМАТИКАЛЫҚ ӘДІСТЕР МЕН МАШИНАЛЫҚ
ОҚЫТУ» СЕКЦИЯСЫ**

**СЕКЦИЯ «МАТЕМАТИЧЕСКИЕ МЕТОДЫ И
МАШИННОЕ ОБУЧЕНИЕ В ИНТЕЛЛЕКТУАЛЬНЫХ
ИНФОРМАЦИОННЫХ СИСТЕМАХ»**

**«MATHEMATICAL METHODS AND MACHINE LEARNING IN
INTELLIGENT INFORMATION SYSTEMS» SECTION**

ТАБИҒИ ТІЛДІ ӨНДЕУ НЕГІЗІНДЕ АҚПАРАТТЫҚ ЖҮЙЕНІҢ ИНТЕЛЛЕКТУАЛДЫ МҮМКІНДІКТЕРІН АРТТЫРУ

Ауезхан М.Қ.

Әл-Фараби атындағы Қазақ Ұлттық Университеті, 3 курс студенті

E-mail: mikaaid@icloud.com

Бейбітхан Е.

Әл-Фараби атындағы Қазақ Ұлттық Университеті, аға оқытушы

Қазіргі заман – ақпарат тасқыны толассыз арта түсетін цифрлық дәуір. Ақпараттық жүйелер үздіксіз дамып, орасан зор көлемдегі деректерді өндеуге деген сұраныс өсуде. Әсіресе, осы деректердің басым бөлігі мәтіндік форматта ұсынылатынын ескерсек, олардың маңызын тереңірек ұғынуға тура келеді. Осындай жағдайда табиғи тілді өндеу (Natural Language Processing, NLP) әдістерін қолдану ақпараттық жүйелердің тиімділігін арттыруда шешуші рөл атқарады. NLP технологиясы мәтіндік ақпаратты автоматты түрде өндеуге мүмкіндік беріп, деректерді жылдам талдап, оларды дұрыс жүйелеуге септігін тигізеді.

Бұл мақалада ақпараттық жүйелерге NLP технологиясын интеграциялау тәсілдері кеңінен қарастырылып, олардың артықшылықтары мен шектеулеріне ерекше назар аударылады. Сонымен қатар, осы технологияның болашақта қалай дамуы мүмкін екені де талқыланады. Жүргізілген зерттеулер көрсеткендей, NLP-дің қолданылуы күнделікті өмірдегі үйреншікті тапсырмаларды автоматтандыруға, пайдаланушы тәжірибесін жақсартуға және деректерді өндеудің дәлдігін арттыруға үлкен үлес қосады. Бұл өз кезегінде NLP-ді заманауи технологияларды жетілдірудегі маңызды құралға айналдырады.

Бүгінде ақпараттық жүйелер тек құрылымдалған мәліметтерді ғана емес, сандық контенттің едәуір бөлігін құрайтын құрылымдалмаған мәтіндік ақпаратты да сақтап, өңдей алуы тиіс. NLP – бұл лингвистика, жасанды интеллект және машиналық оқытуды ұштастыратын пәнаралық бағыт, оның көмегімен мәтіндік ақпаратты автоматты түрде талдап, әртүрлі салаларда тиімді шешім қабылдауға болады.

NLP-дің ең маңызды қолдану бағыттарының бірі – мәтіндік деректерді автоматтандырылған түрде өндеу. Бұл, әсіресе, бизнес, медицина, білім беру және мемлекеттік басқару салаларында өзекті. Мысалы, корпоративтік секторда NLP тұтынушы пікірлерін талдау, хабарламалардың эмоционалдық реңкін анықтау және құжаттарды автоматты түрде сұрыптау үшін қолданылады. Мұндай технологиялар компаниялардың клиент сұраныстарына жедел жауап беруіне және қызмет көрсету сапасын жақсартуына мүмкіндік береді.

Сондай-ақ, NLP интеллектуалды іздеу жүйелерінің негізін құрайды. Табиғи тілді өндеу технологиясын қолданатын іздеу механизмдері күрделі сұраныстарды түсініп, пайдаланушыға барынша өзекті нәтижелерді ұсынуға қауқарлы. Дәстүрлі кілт сөздер арқылы іздеуден айырмашылығы, NLP алгоритмдері қолданушының сұраныс контекстін талдап, оның ниетін дұрыс түсінуге тырысады. Бұл іздеу дәлдігін арттырып қана қоймай, пайдаланушыға ыңғайлы тәжірибе сыйлайды.

Бұдан бөлек, NLP-дің тағы бір маңызды бағыты – мәтінді автоматты түрде генерациялау. Соңғы жылдары GPT және BERT секілді озық модельдер сапалы мәтіндер жасап, есептерді автоматты түрде құрастырып, құжаттарды қорытындылап, тіпті нақты уақыт режимінде адамдармен диалог жүргізе алады. Мұндай технологиялар құжат айналымын автоматтандыру, клиенттерге қызмет көрсету және интеллектуалды ассистенттерді дамыту секілді көптеген салаларда кеңінен қолданылады. NLP технологиялары машиналық аударма сапасын да айтарлықтай жақсартты. Қазіргі алгоритмдер мәтіннің контекстін, грамматикалық құрылымын және идиомалық өрнектерді ескере отырып, аударманың дәлдігі мен табиғилығын арттыруға мүмкіндік береді. Бұл технологиялар халықаралық бизнес, білім беру және туризм салаларында кеңінен қолданыс тапты.

NLP-дің тағы бір маңызды аспектісі – ақпараттың қолжетімділігін арттырудағы рөлі.

Дауыстық көмекшілер мен чат-боттар пайдаланушыларға қажетті ақпаратты оңай алуға және жүйемен өзара әрекеттесуге көмектеседі. Бұл мүмкіндігі шектеулі адамдар үшін де, мәтіндік енгізуді қиындататын жағдайларда жұмыс істейтіндер үшін де өте тиімді шешім болып табылады.

Көптеген артықшылықтарына қарамастан, NLP технологиялары белгілі бір қиындықтарға да тап болуда. Солардың бірі – үлкен көлемдегі оқыту деректерінің және есептеу ресурстарының қажеттілігі. Сонымен қатар, NLP модельдері егер олар теңгерімсіз деректермен оқытылса, белгілі бір дәрежеде біржақтылық танытуы мүмкін. Бұл мәселелерді шешу үшін машиналық оқыту алгоритмдерін жетілдіру және жаңа зерттеулер жүргізу аса маңызды.

NLP-дің болашағы тек мәтінді талдаумен шектелмей, оның мағынасын тереңірек түсінуге бағытталған интеллектуалды жүйелерді дамытуға байланысты. Сонымен қатар, бұл технологияны компьютерлік көру және үлкен деректерді талдау секілді басқа да озық технологиялармен біріктіру болашақтағы ең перспективалы бағыттардың бірі болып отыр. Бұл ақпараттық жүйелерді одан әрі күрделендіріп, оларды анағұрлым бейімделгіш және интеллектуалды етеді.

Қорыта айтқанда, NLP ақпараттық жүйелерді жетілдіруде ерекше маңызға ие. Ол мәтіндік деректерді автоматтандыру, іздеу нәтижелерінің дәлдігін арттыру және пайдаланушылармен өзара әрекеттесу сапасын жақсарту секілді маңызды міндеттерді шешуге мүмкіндік береді. Қазіргі қиындықтарға қарамастан, NLP-дің қарқынды дамуы алдағы уақытта бұл технологияны әлдеқайда жетілдіріп, оның тиімділігі мен қолжетімділігін арттыра түсетіні сөзсіз.

Бүгінде ақпараттық технологиялар саласында NLP-ді қолдану – инновациялық даму мен цифрлық трансформацияның негізгі элементтерінің бірі. Алдағы уақытта бұл технология одан әрі дамып, адам мен машина арасындағы қарым-қатынасты барынша жеңілдетуге және тиімді етуге мүмкіндік беретіні анық.

Пайдаланылған әдебиеттер тізімі:

1. Jurafsky, D., & Martin, J. H. (2021). *Speech and Language Processing*. Pearson.
2. Manning, C. D., & Schütze, H. (1999). *Foundations of Statistical Natural Language Processing*. MIT Press.
3. Goldberg, Y. (2017). *Neural Network Methods for Natural Language Processing*. Morgan & Claypool Publishers.
4. Vaswani, A. et al. (2017). *Attention is All You Need*. NeurIPS.
5. Devlin, J. et al. (2019). *BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding*. ACL.

ЖЕР СІЛКІНІСТЕРІНІҢ ЫҚТИМАЛ САЛДАРЫН МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН ҚОЛДАНУ АРҚЫЛЫ АНЫҚТАУ

Арапова Ж.Е., Алиев Р., Каримов М., Черикбаева Л.Ш., Турарбек Ә.Т.
ал-Фараби атындағы Қазақ Ұлттық университеті,
arap.jd@mail.ru, cherikbayeva.lyailya@gmail.com, turarbekasem1@gmail.com

Қазір жер сілкіністерінің салдарын дәл болжау сейсмология, азаматтық қауіпсіздік және қала құрылысы саласындағы негізгі міндеттердің бірі болып табылады. Залалды бағалаудың дәстүрлі әдістері тарихи жер сілкіністерінің магнитудасы мен ошағының тереңдігі туралы деректерді пайдаланатын эмпирикалық модельдерге негізделеді. Алайда, бұл тәсілдердің бірнеше шектеулері бар: олар айтарлықтай уақытты талап етеді, тәуекел факторлары арасындағы күрделі тәуелділіктерді әрдайым ескере бермейді және кейде нақты емес болжамдар беруі мүмкін. Жасанды интеллект пен машиналық оқытудың (ML) дамуының арқасында деректерді талдау процесін автоматтандыруға, болжаудың дәлдігін арттыруға және ықтимал қирау ауқымын жедел бағалауға мүмкіндік туды [1].

Зерттеу жұмысы барысында жер сілкіністерінің салдарын болжау үшін машиналық оқыту әдістерін қолдану қарастырылды, оның ішінде ғимараттар мен инфрақұрылымның зақымдануын бағалау, экономикалық шығындар мен зардап шеккен адамдардың санын болжау мәселелері зерттелді. Бұл міндетті шешу үшін градиентті бустинг алгоритмдері (XGBoost, LightGBM), уақыттық қатарларды талдау үшін рекуррентті нейрондық желілер (RNN) және конволюциялық нейрондық желілер (CNN) зерттелді [2-4].

Модельдерді оқыту үшін USGS (United States Geological Survey) және EMSC (European-Mediterranean Seismological Centre) сияқты ашық сейсмикалық дерекқорларын қолдану маңыздылығы қарастырылды. Деректерді өңдеу барысында қалыптандыру, маңызды белгілерді таңдау және класстарды теңестіру әдістері қолданылады, бұл болжам сапасын жақсартуға мүмкіндігін арттырады.

Зерттеу нәтижелері көрсеткендей, машиналық оқытуды қолдану жер сілкіністерінің салдарын болжау дәлдігін арттырып қана қоймай, сонымен қатар талдау процесін жылдамдатады [5]. Бұл төтенше жағдайларға жедел әрекет ету және залалды азайту бойынша шараларды жоспарлау үшін аса маңызды. Әдістердің хабарланған нәтижелері, пайдаланылған деректер жиындары және қолданбалы бағалау көрсеткіштері де кестелерде жинақталды.

Пайдаланылған әдебиеттер тізімі:

1. Turarbek, A., Adetbekov, Y., Bektemesov, M. 2-D Deep Convolutional Neural Network for Predicting the Intensity of Seismic Events // International Journal of Advanced Computer Science and Applications, 2023, 14(1), pp. 788–796
2. Shi C., Liu X. Application of neural network to earthquake engineering // Earthquake Engineering and Engineering Vibration. – 1991. – Vol. 11, № 2. – P. 39–46.;
3. Chen W., Sharifrazi D., Liang G., Band S. S., Chau K. W., Mosavi A. Accurate discharge coefficient prediction of streamlined weirs by coupling linear regression and deep convolutional gated recurrent unit// Engineering Applications of Computational Fluid Mechanics. – 2022. – Vol.16, №1. – P. 965-976.
4. Aslam B., Zafar A., Khalil U. Comparative analysis of multiple conventional neural networks for landslide susceptibility mapping // Natural Hazards. – 2023.– Vol.115, №1.– P. 673-707.
5. Gabriella Tocchi, Sushreyo Misra, Jamie E. Padgett, Maria Polese, Marco Di Ludovico The use of machine-learning methods for post-earthquake building usability assessment: A predictive model for seismic-risk impact analyses // International Journal of Disaster Risk Reduction, Volume 97, 2023,104033, ISSN 2212-4209.

Деректерді талдау және есеп беру құралдарын пайдалана отырып, жобаны басқарудың ақпараттық жүйесін әзірлеу

Абдилдаева Жанель

Әл-Фараби атындағы Қазақ Ұлттық университетінің 4-курс студенті

E-mail: abdildaeva.zhanel@icloud.com

Ғылыми жетекші: Ілесова Бақытгүл

Әл-Фараби атындағы Қазақ Ұлттық университетінің аға оқытушысы

Қазіргі таңда цифрлық технологиялардың дамуы деректерді өңдеу мен басқару үдерістерін оңтайландыру қажеттілігін арттырды. Ақпараттық жүйелер үлкен көлемдегі деректерді өңдеуді автоматтандыруға, пайдаланушыға ыңғайлы интерфейстер ұсынуға және бизнес-процестерді жеңілдетуге мүмкіндік береді. Бұл мақалада PHP, MySQL, HTML, CSS және JavaScript технологияларын қолдана отырып, деректерді басқару мен өңдеуге арналған ақпараттық жүйені әзірлеу мәселелері қарастырылады.

Бұл жоба жұмысының мақсаты – заманауи веб-технологияларды қолдана отырып, ақпараттық жүйені әзірлеу. Осы мақсатқа жету үшін келесі міндеттер қойылды:

- Веб-әзірлеу технологияларының теориялық негіздерін зерттеу;
- Серверлік және клиенттік технологиялардың мүмкіндіктерін талдау;
- PHP және MySQL көмегімен серверлік бөлікті әзірлеу;
- HTML, CSS және JavaScript көмегімен пайдаланушы интерфейсін жасау;
- Жүйенің функционалдығын тексеру және оны оңтайландыру;
- Қауіпсіздік шараларын қамтамасыз ету және жүйенің интеграциялану мүмкіндіктерін зерттеу.

Зерттеу барысында салыстырмалы талдау, бағдарламалық модельдеу және жүйелік тестілеу әдістері қолданылды. Жүйе UML диаграммалары арқылы жобаланып, MySQL дерекқорымен байланыс орнатылды. Ақпараттық жүйенің функционалдығын тексеру үшін тестілеу әдістері жүргізілді. Сонымен қатар, өнімділік тестілері жүргізіліп, серверлік жүктемені оңтайландыру бойынша ұсыныстар жасалды.

PHP және MySQL негізінде серверлік бөлігі бар веб-қосымша әзірленді. Клиенттік интерфейс HTML, CSS және JavaScript көмегімен жасалып, пайдаланушылар үшін ыңғайлы әрі функционалды құрылды. Жүйенің негізгі мүмкіндіктеріне мыналар жатады:


- Деректерді енгізу, өңдеу және басқару;
- Қолданушы интерфейсінің қарапайымдылығы;
- Жоғары өнімділік және тұрақтылық;
- Қауіпсіздік деңгейінің жоғары болуы;
- Бүлттық технологиялармен жұмыс істеу мүмкіндігі;
- Үлкен көлемдегі деректермен жылдам жұмыс жасау.

Жүйенің жұмыс істеу тұрақтылығын тексеру үшін өнімділік және функционалдык тестілеу жүргізілді. Негізгі көрсеткіштер төмендегі кестеде берілген:

Тестілеу көрсеткіші	Мәні
Жүйеге кіру уақыты (мс)	120
Дерекқор сұраныстарының орташа уақыты (мс)	45
Қосымшаның жүктемеге тұрақтылығы (%)	98,5
Қате қайтару ықтималдығы (%)	1,2

Жүйенің тұрақтылығы 98.5% құрайды, ал дерекқор сұраныстарының орташа уақыты 45 мс. Бұл көрсеткіштер жүйенің жоғары өнімділікпен жұмыс істейтінін дәлелдейді.

Жүйенің өнімділік көрсеткіштері төмендегі диаграммада бейнеленген:



Гистограммада төрт негізгі тестілеу метрикасы көрсетілген, олардың әрқайсысы жүйенің әртүрлі аспектілерін сипаттайды.

1. Қате қайтару ықтималдығы (%)

Жүйенің жұмыс істеу тұрақтылығының маңызды көрсеткіштерінің бірі – қате қайтару ықтималдығы. Бұл метрика жүйеде орын алатын қателердің пайыздық мөлшерін анықтайды. Тест нәтижелері бойынша, қате қайтару ықтималдығы өте төмен деңгейде, бұл жүйенің жоғары сенімділігін көрсетеді.

2. Қосымша жүктемеге тұрақтылығы (%)

Бұл көрсеткіш жүйенің қосымша жүктеме кезіндегі өнімділігін сипаттайды. Диаграммада көрсетілгендей, жүйе шамамен 100% тұрақтылық деңгейіне ие, яғни қосымша жүктемелер оның жұмысына айтарлықтай әсер етпейді. Бұл ақпараттық жүйенің жоғары масштабталуын және жүктемелерге төзімділігін көрсетеді.

3. Дерекқор сұраныстарының орташа уақыты (мс)

Ақпараттық жүйенің жылдамдығын бағалауда дерекқор сұраныстарының өңдеу уақыты маңызды рөл атқарады. Тест нәтижелері бойынша, сұраныстарды орындаудың орташа уақыты шамамен 50 мс-ты құрайды. Бұл жүйенің дерекқорға қатысты операцияларды тиімді орындауға қабілетті екенін білдіреді.

4. Жүйеге кіру уақыты (мс)

Пайдаланушылардың жүйеге кіру уақыты жүйенің жылдамдығы мен қолданушыға ыңғайлылығының негізгі көрсеткіштерінің бірі болып табылады. Тестілеу нәтижелері бойынша, жүйеге кіру уақыты шамамен 120 мс құрайды, бұл жоғары өнімділікті және жылдам жауап беру уақытын көрсетеді.

Болашақта жүйенің функционалын кеңейту мақсатында машиналық оқыту әдістерін енгізу, бұлттық технологиялармен біріктіру және мобильді қосымшамен интеграциялау жоспарлануда. Сондай-ақ, қауіпсіздік деңгейін арттыру үшін деректерді шифрлау және екі факторлы аутентификация жүйесін енгізу қарастырылуда. Жүйені бұлттық серверлерге көшіру арқылы оның қолжетімділігі мен өнімділігін одан әрі арттыруға мүмкіндік бар. Сонымен қатар, жүйені қолданушылардың тәжірибесіне сәйкес жақсарту және персонализациялау мүмкіндіктерін қарастыру қажет.

Жүргізілген зерттеу нәтижесінде деректерді басқару мен өндеуді автоматтандыруға мүмкіндік беретін ақпараттық жүйе әзірленді. Жүйенің болашақта кеңейтілу мүмкіндіктері қарастырылып, оның функционалын жетілдіру жолдары ұсынылды. Бұл зерттеу веб-қосымшаларды әзірлеуде тиімді шешімдер ұсынуға және ақпараттық жүйелерді оңтайландыруға өз үлесін қосады. Сонымен қатар, болашақта пайдаланушылардың тәжірибесін жақсарту мақсатында жүйеге жасанды интеллект элементтерін енгізу мүмкіндігі қарастырылады. Сондай-ақ, пайдаланушыға ыңғайлы ортаны қамтамасыз ету мақсатында UX/UI зерттеулерін жүргізу және жүйенің жеделдетілген жұмысын қамтамасыз ету үшін кешенді оңтайландыру шараларын қабылдау қажет.

Түйін сөздер: веб-әзірлеу, ақпараттық жүйелер, PHP, MySQL, HTML, CSS, JavaScript, деректерді өңдеу, автоматтандыру, жасанды интеллект, бұлттық технологиялар.

Пайдаланылған әдебиеттер тізімі:

1. McKinney W. Python for Data Analysis: Data Wrangling with Pandas, NumPy, and Jupyter.
2. Kimball R., Ross M. The Data Warehouse Toolkit: The Definitive Guide to Dimensional Modeling. [Электрондық ресурс] URL: <https://www.wiley.com/en-us/The+Data+Warehouse+Toolkit%3A+The+Definitive+Guide+to+Dimensional+Modeling%2C+3rd+Edition-p-9781118530801>
3. MySQL Documentation. MySQL 8.0 Reference Manual. [Электрондық ресурс] URL: <https://dev.mysql.com/doc/refman/8.0/en/>
4. W3C Recommendations. Web Standards & Best Practices. [Электрондық ресурс] URL: <https://www.w3.org/TR/>

МАШИНАЛЫҚ ОҚЫТУ НЕГІЗІНДЕ БИОМЕТРИЯЛЫҚ ДЕРЕКТЕР АРҚЫЛЫ ПАЙДАЛАНУШЫЛАРДЫҢ АУТЕНТИФИКАЦИЯСЫНЫҢ АҚПАРАТТЫҚ ЖҮЙЕСІ

Абдыкарим А.

Ғылыми жетекші: э.ғ.д., доцент Байшоланова К.С.

Әл-Фараби атындағы Қазақ Ұлттық университеті, Алматы, Қазақстан

e-mail: abdykarimasy17@gmail.com

Қазіргі таңда ақпараттық қауіпсіздікке қойылатын талаптардың артуына байланысты биометриялық аутентификация жүйелері кеңінен қолданысқа енуде. Биометриялық аутентификация пайдаланушының физиологиялық немесе мінез-құлықтық сипаттамаларына негізделген. Әсіресе, бет-әлпет арқылы аутентификация қауіпсіздік, ыңғайлылық және жылдамдық тұрғысынан үлкен артықшылықтарға ие.

Бет-әлпет арқылы аутентификация жүйелері негізінен машиналық оқыту және терең нейрондық желілер алгоритмдерін пайдаланады. Бұл мақалада МО әдістерін қолданатын бет-әлпет тану жүйелерінің негізгі қағидалары, олардың тиімділігі және болашақ даму бағыттары қарастырылады.

2. Биометриялық аутентификациядағы машиналық оқыту әдістері

МО негізіндегі бет-әлпетті тану жүйелері бірнеше кезеңнен тұрады:

1. *Деректерді жинау* – камера арқылы пайдаланушының бет-әлпетінің кескінін алу.
2. *Алдын ала өңдеу* – суреттерді нормализациялау, жарық пен контрастты түзету.
3. *Модельді үйрету* – терең нейрондық желілер арқылы бет ерекшеліктерін үйрету.

4. *Салыстыру және аутентификация* – пайдаланушының бет ерекшеліктерін дерекқормен салыстыру.

2.1. Бет-әлпетті тану үшін қолданылатын нейрондық желілер

Қазіргі таңда бет-әлпетті тану үшін CNN (Convolutional Neural Networks) кеңінен қолданылады. Бұл әдіс кескіндегі ерекшеліктерді анықтау және оларды вектор түрінде көрсету үшін қолданылады. Сондай-ақ, FaceNet, VGGFace2, MobileFaceNet сияқты модельдер тиімді нәтижелер көрсетеді.

Нейрондық желілер арқылы алынған эмбедингтер (128 немесе 512 өлшемді векторлар) бет-әлпетті салыстыру үшін қолданылады:

$$d(A, B) = \sqrt{\sum_{i=1}^n (A_i - B_i)^2}$$

мұндағы A және B – екі адамның бет-әлпетінің векторлық көріністері.

2.2. Салыстырмалы талдау

Алгоритм	Дәлдік (%)	Орындау уақыты (мс)
FaceNet	99.63	120
VGGFace2	98.95	140
MobileFaceNet	98.10	90

Талдау нәтижелері көрсеткендей, FaceNet алгоритмі жоғары дәлдікке ие, алайда MobileFaceNet жылдамдығымен ерекшеленеді.

3. Тәжірибелік зерттеу

Жүйені тестілеу барысында әртүрлі жарық жағдайларында алынған бет-әлпет кескіндерінің сәйкестігі өлшенді. Тестілеу дерекқоры 5000 адамнан тұратын CASIA-WebFace және LFW деректер жиынтығы негізінде құрылды.

Тест жағдайы	Дәлдік (%)
Жарық жақсы	99.2
Жарық орташа	96.5
Жарық нашар	89.7

Бұл нәтижелер көрсеткендей, жарық жағдайлары бет-әлпетті тану нәтижесіне айтарлықтай әсер етеді.

4. Қорытынды

Машиналық оқыту негізіндегі бет-әлпет арқылы аутентификация жүйелері қауіпсіздік, жылдамдық және пайдаланудың ыңғайлылығы тұрғысынан үлкен артықшылықтарға ие. Терең нейрондық желілер қолданылатын жүйелер дәлдікті жоғарылатып, жалған аутентификацияны болдырмайды.

Болашақта жүйенің сенімділігін арттыру үшін келесі бағыттарда жұмыс істеу қажет:

- Генеративті қарсылас желілерді (GANs) пайдалану – бет-әлпетті синтездеу арқылы мәліметтер жиынтығын кеңейту.
- Мульти-модальды биометрия – бет-әлпетпен қатар, дауыс, саусақ ізі секілді деректерді біріктіру.
- Жарық жағдайларын бейімдеу – төмен жарық кезінде дәлдікті жақсарту үшін арнайы деректерді пайдалану.

Пайдаланылған әдебиеттер тізімі:

1. Goodfellow, I., Bengio, Y., & Courville, A. *Deep Learning*. MIT Press, 2016.
2. Bishop, C. M. *Pattern Recognition and Machine Learning*. Springer, 2006.
3. Daugman, J. *How Iris Recognition Works*. IEEE Transactions on Circuits and Systems for Video Technology, 14(1), 21-30, 2009.
4. Schroff, F., Kalenichenko, D., & Philbin, J. *FaceNet: A Unified Embedding for Face Recognition and Clustering*. CVPR, 2015.
5. Parkhi, O. M., Vedaldi, A., & Zisserman, A. *Deep Face Recognition*. BMVC, 2015.
6. OpenCV Library. *Face Detection and Recognition Techniques*. <https://opencv.org>.
7. TensorFlow. *Implementing Face Recognition with Deep Learning Models*. <https://www.tensorflow.org>.
8. ISO/IEC 19794-5:2011. *Biometric Data Interchange Formats - Part 5: Face Image Data*.

Машиналық оқыту модельдері мен нейрондық желілерді қолдану арқылы деректерді талдау әдістерін әзірлеу және ақпараттық технологиялар аудитін жүргізу

Абай Мадина Алтынбекқызы

*Әл-Фараби атындағы Қазақ Ұлттық университеті, Ақпараттық жүйелер мамандығының
4-курс студенті*

E-mail: abay.madinn03@gmail.com

Ілесова Бақытгүл Ералықызы

*Әл-Фараби атындағы Қазақ Ұлттық университеті, Ақпараттық жүйелер кафедрасының
аға оқытушысы*


Бұл мақалада ақпараттық технологиялар аудитінде машиналық оқыту әдістері мен нейрондық желілерді қолдану қарастырылады. Жүйенің негізгі принциптері, оның тиімділігі және енгізу барысында кездесетін қиындықтар талқыланады. Ақпараттық технологиялар аудитінің контекстінде шешім ағаштары, Random Forest, логистикалық регрессия, K-Means және нейрондық желілердің қолданылуы зерттеледі. Сонымен қатар, аудитте "audit-by-exception" және "predictive analytics" әдістерінің рөлі сипатталады.

Бұл зерттеудің негізгі тұжырымдамасы ақпараттық технологиялар аудитінде машиналық оқыту әдістерін қолдану болып табылады. Машиналық оқыту алгоритмдері үлкен деректер жиынтықтарын талдау, тәуекелдерді анықтау және аудит процестерін автоматтандыру үшін қолданылады. Машиналық оқыту әдістері – қадағаланатын (supervised learning), қадағаланбайтын (unsupervised learning) және күшейтілген (reinforcement learning) оқыту түрлеріне бөлінеді. Ал нейрондық желілер күрделі есептерді шешуге мүмкіндік беретін, биологиялық жүйелерге ұқсас модельдер болып табылады.

Машиналық оқыту модельдерін енгізу процесі бірнеше негізгі кезеңдерден тұрады: деректерді алдын ала өңдеу, үлгілерді оқыту, модельдің тиімділігін бағалау және оны аудит жүйелеріне интеграциялау. Ақпараттық технологиялар аудитінде қолданылатын негізгі әдістер мен олардың салалары:

Машиналық оқыту әдісі	Қолдану саласы
Шешім ағаштары	Алаяқтықты анықтау, транзакцияларды талдау
Random Forest	Қаржылық талдау, тәуекелдерді бағалау
Логистикалық регрессия	Несие қабілеттілігін болжау, трендтерді анықтау
K-Means	Тұтынушы сегменттеу, кластерлік талдау
Нейрондық желілер	Бейнелерді тану, мәтінді өңдеу

Диаграмма: Машиналық оқыту әдістерінің ақпараттық технологиялар аудитінде қолданылуы



Зерттеу барысында машиналық оқыту алгоритмдерінің аудит процесіндегі рөлі, олардың тәуекелдерді басқарудағы артықшылықтары және енгізу барысында кездесетін қиындықтар сипатталған. Атап айтқанда, үлкен деректерді өңдеу үшін жоғары есептеу қуатының қажеттілігі, "қара жәшік" мәселесі, деректер сапасының төмендігі, нормативтік шектеулер және деректердің этикалық аспектілері талқыланды.

Пайдаланылған әдебиеттер тізімі:

1. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. URL: <https://www.deeplearningbook.org/>
2. Russell, S., & Norvig, P. (2020). *Artificial Intelligence: A Modern Approach*. Pearson. URL: <https://aima.cs.berkeley.edu/>
3. Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2016). *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann. URL: <https://www.elsevier.com/books/data-mining/witten/978-0-12-804291-5>

Кеуекті ортаны ескере отырып, ауадағы ұсақ дисперсті бөлшектердің концентрациясын сандық модельдеу

Амантай Арман

Әл-Фараби атындағы Қазақ Ұлттық университеті, компьютерлік ғылымдар мамандығының 4-курс студенті

Қазіргі таңда ауа сапасының төмендеуі – адам денсаулығы мен қоршаған ортаға қауіп төндіретін маңызды экологиялық мәселе болып отыр. Әсіресе, ұсақ дисперсті бөлшектер (PM_{10} , $PM_{2.5}$) – атмосфералық ауадағы ең қауіпті ластаушы заттардың бірі. Бұл бөлшектер тыныс алу жолдарына терең еніп, аллергиялық реакциялар, демікпе, өкпе және жүрек-қан тамырлары ауруларына себеп болуы мүмкін. Урбанизация, көлік қозғалысының артуы, өндірістік кәсіпорындар мен табиғи факторлар – бұл бөлшектердің ауада шоғырлануына ықпал ететін негізгі көздер.

Осы зерттеудің мақсаты – кеуекті орталарды ескере отырып, ауадағы РМ бөлшектерінің таралуын болжау үшін сандық модельдеу (CFD) және машиналық оқыту (ML) әдістерін біріктіру арқылы тиімді модель әзірлеу. Бұл тәсіл ұсақ бөлшектердің кеңістікте таралуын нақты сипаттап, олардың қалалық құрылымдармен және микроклиматтық жағдайлармен өзара байланысын зерттеуге мүмкіндік береді.

Зерттеу барысында алдымен ауадағы PM_{10} және $PM_{2.5}$ бөлшектерінің концентрациясы бойынша деректер жиналып, алдын ала өңделеді. Бұл мәліметтер негізінде машиналық оқыту алгоритмдері арқылы бөлшектер концентрациясын болжауға бағытталған модельдер құрылады. Ерекшеліктерді іріктеу арқылы ауа сапасына әсер ететін негізгі факторлар – ауа температурасы, ылғалдылық, жел жылдамдығы, көлік тығыздығы және т.б. анықталады. Сонымен қатар, CFD әдістері арқылы ауа ағыны мен бөлшектердің таралу динамикасы есептеледі. Бұл модельде кеуекті орталар (мысалы, жасыл желек, ғимараттар арасындағы ашық кеңістіктер) ескеріліп, олар бөлшектердің қозғалысына қандай әсер ететіндігі қарастырылады. Кеуекті құрылымдар бөлшектердің сорылуы мен диффузиясына ықпал етеді, сондықтан оларды елемей болжамның дәлдігін төмендетуі мүмкін.

Зерттеу нәтижесінде алынған модельдер РМ бөлшектерінің нақты таралуын анықтауға, қауіпті аймақтарды белгілеуге және урбанизацияланған аудандардағы экологиялық мониторингті жақсартуға мүмкіндік береді. Бұл модельдер ауа сапасын басқару, қалалық жоспарлау, жасыл аймақтарды тиімді орналастыру және қоршаған ортаны қорғау шараларын жүзеге асыру үшін қолданылады. Сонымен қатар, нақты уақыттағы мониторинг жүйесіне интеграциялау арқылы ауа сапасын үздіксіз бақылау мен болжау мүмкіндігі артады. Жалпы, бұл зерттеудің жаңашылдығы – кеуекті орталарды есепке ала отырып, ұсақ дисперсті бөлшектердің таралуын болжауда машиналық оқыту мен сандық модельдеудің үйлесімді қолданылуында. Бұл тәсіл қалалардағы ауа ластануын азайту, тұрғындардың денсаулығын қорғау және тұрақты даму мақсаттарына жету үшін ғылыми негізделген шешімдер қабылдауға мүмкіндік береді. Сонымен қатар, аталған әдіс ауа сапасын басқару стратегияларын жетілдіруге, урбанистік жоспарлау үдерістерін оңтайландыруға, көлік қозғалысын реттеу шараларын әзірлеуге, жасыл желектер мен рекреациялық аймақтарды тиімді орналастыруға, сондай-ақ қоршаған ортаға келетін зиянды әсерлерді болжау және оларды алдын ала ескерту бағытындағы іс-шараларды сапалы ұйымдастыруға жағдай жасайды.

Пайдаланылған әдебиеттер тізімі:

1. Seinfeld, J. H., & Pandis, S. N. (2016). *Atmospheric Chemistry and Physics: From Air Pollution to Climate Change*. John Wiley & Sons.
2. Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.

3. Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer.
4. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
5. Gupta, P., Christopher, S. A., Wang, J., Gehrig, R., Lee, Y., & Kumar, N. (2006). Satellite remote sensing of particulate matter and air quality assessment over global cities. *Atmospheric Environment*, 40(30), 5880-5892.
6. Holmes, N. S., & Morawska, L. (2006). A review of dispersion modeling and its application to the dispersion of particles: An overview of different dispersion models available. *Atmospheric Environment*, 40(30), 5902-5928.
7. Zhang, Y., & Rao, S. T. (1999). The role of meteorology in air pollution modeling. *Journal of the Air & Waste Management Association*, 49(1), 16-26.
8. Karagulian, F., Barbieri, M., Kotsev, A., & Laguna, M. (2019). Review of the performance of low-cost sensors for air quality monitoring. *Atmospheric Environment*, 213, 579-593.
9. Fan, J., Wang, Y., Wang, X., Liu, P., & Zhang, R. (2020). Machine learning models for air quality prediction. *Atmospheric Pollution Research*, 11(12), 2076-2085.
10. Fletcher, T. (2012). *Machine Learning for Hackers*. O'Reilly Media.

Параллельді қазақ-түрік сөйлеу корпусын қалыптастырудың әдісі мен моделін құру

Аскапова М.К.

Әл-Фараби атындағы Қазақ Ұлттық университеті, 4-курс студенті


e-mail: madinassym@gmail.com

Кәрібаева А.С.

Әл-Фараби атындағы Қазақ Ұлттық университеті, PhD., доцент м.а.

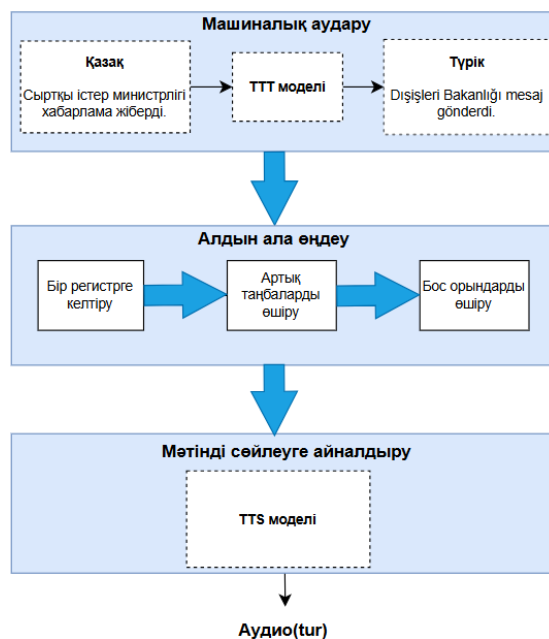
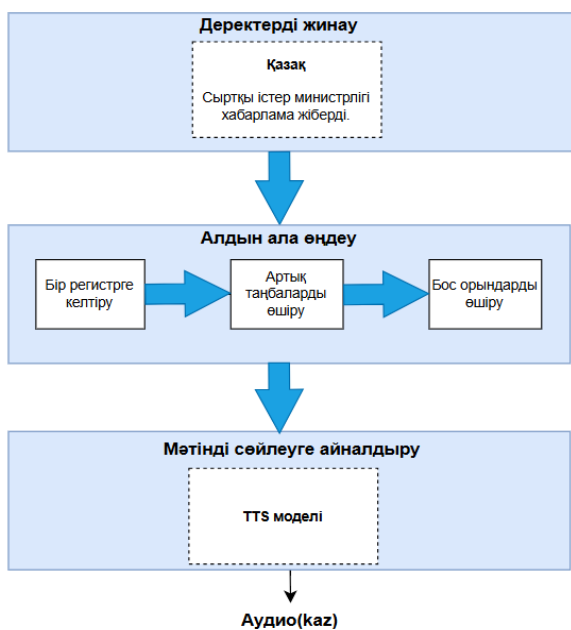
Параллель сөйлеу корпусы табиғи тілді өңдеу, машиналық аударма және лингвистикалық зерттеулер салаларындағы маңызды құрал болып табылады. Олар уақыт бойынша синхрондалған екі немесе одан да көп тілдегі аудиожазбалар мен сәйкес мәтін транскрипцияларының жинақтары болып табылады. Мұндай ресурстар тілдердің фонетикалық, морфологиялық және синтаксистік ерекшеліктерін зерттеуге, сондай-ақ сөйлеу синтезі мен тану жүйесін дамытуға және жетілдіруге мүмкіндік береді. Әлемдік тәжірибеде параллельді корпустарды құруда айтарлықтай жетістіктер бар. Саладағы жан-жақты ресурстардың бірі - әртүрлі дереккөздерден жинақталған параллель корпустардың үлкен жинағы OPUS (Tiedemann, 2012)[1] болып табылады. Дегенмен, әртүрлі мәтіндік және сөйлеу корпусының болуына қарамастан, қазақ және түрік тілдерінің ашық түрдегі параллельді сөйлеу корпусы жоқ. Бұл көптілді жүйелерді дамыту үшін белгілі бір қиындықтарды тудырады, бұл тілдердің жақындығын және осы тілдер үшін жасалатын моделдердің қолданысқа енуін тежейді.

Корпусты жинаудың 2 тәсілі бар: автоматты және қолмен жинау. Қолмен жинау өте көп уақыт ресурсын алатындықтан, бұл корпусты жинау үшін автоматты тәсілдің back-translation әдісі ұсынылды. 1-сызбада параллельді сөйлеу корпусын жинаудың алгоритмі көрсетілген.



Сызба 1.-Параллельді сөйлеу корпусын жинаудың алгоритмі

2-сызбада көрсетілгендей жұмыс қазақ тіліндегі сөйлемдер жиналды, нормализация жасалып, қазақ тіліне бейімделген, алдын ала дайындалған [2] көрсетілген TTS моделі және түрік тіліндегі аудиожазбаны синтездеуде [3] модель пайдаланылды. Аудио деректер 16 кГц, 16 биттік PCM, моно параметрлерімен WAV форматында жасалды.



Сызба 2.-Қазақша аудиожазбаларды дайындау Сызба 3.-Түрікше аудиоларды дайындау

Параллельді корпустың негізі болатын дәрбір қазақ тіліндегі сөйлем оның қазақ тіліндегі аудиожазбасымен және түрік тіліндегі аудармасы оның түрік тіліндегі аудиожазбасымен 1-суретте көрсетілгендей теңестірілді.

Audio (Kaz)	source_lang	target_lang	Audio (Tur)
kaz_001.wav	Ол ұзақ уақыт бойы футболды насихаттады.	Uzun zamandır futbolu tanıtıyor.	tur_001.wav
kaz_002.wav	Қонақтарға далаға шығуға кеңес бермейді.	Misafirlerin dışarıya çıkmaları önerilmiyor.	tur_002.wav
kaz_003.wav	Жағдай нашар.	Durum kötü.	tur_003.wav
kaz_004.wav	Сақ болыңыз.	Dikkat olmak.	tur_004.wav
kaz_005.wav	Қатерлі ісік диагнозы қойылды.	Kanser teşhisi konuldu.	tur_005.wav
kaz_006.wav	Жаңа жыл мерекесін тойлады.	Yılbaşı kutlandı.	tur_006.wav
kaz_007.wav	Отбасы балаларымен Таиландқа барған.	Aile Tayland'a gitti.	tur_007.wav

Сурет 1.-Параллельді сөйлеу корпусы

Жасалған жұмыстардың нәтижесінде 168.000 қазақ тіліндегі аудиожазбалар мен олардың мәтіні және түрік тіліне аударылған аудиожазбасы мен олардың мәтіні бірге жиналды. Алдағы уақытта қазақ-түрік параллельді сөйлеу корпусын қазақ тіліндегі сөйлеуді тікелей түрік тіліндегі сөйлеуге аударатын модельдерді оқытуда қолдану арқылы жетілдіре отырып тікелей аудиожазбаны мақсатты тілдегі аудиожазбаға аудару(Direct Speech to Speech Translation) модельдерін оқытуда өзекті корпустардың бірі етіп пайдалануға болады. Сонымен қатар параллельді сөйлеу корпусын басқа да тілдер үшін жинау жоспарланып отыр.

Пайдаланылған әдебиеттер тізімі:

1. Tiedemann, J. (2012). Parallel Data, Tools and Interfaces in OPUS. *LREC 2012*.

2. O. Makhambetov, A. Makazhanov, I. Sabyrgaliyev, Zh. Yessenbayev. "Data-driven morphological analysis and disambiguation for Kazakh". In International Conference on Intelligent Text Processing and Computational Linguistics 2015, pp. 151-163.

3. Cücen, M. S. , Oyucu, S. & Polat, H. (2023). Türkçe Konuşma Sentezleme Sistemlerinin Geliştirilmesi için Dengeli Bir Veri Kümesi Hazırlama . Bilişim Teknolojileri Dergisi , 16 (3) , 237-249 . DOI: 10.17671/gazibtd.1159289

АҚЫЛДЫ ҮЙДІ ТАЛДАУ ЖӘНЕ АВТОМАТТАНДЫРЫЛҒАН ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕЛЕРДІ ҚҰРУ

Бөкенов Заңғар Қайратұлы

Әскер Бақдәулет Нұрболұлы

Борibaева Улданай Бахытжанқызы

*Әл-Фараби атындағы Қазақ Ұлттық Университеті,
«Ақпараттық жүйелер» мамандығының 3-курс студенттері
E-mail: uldanboribaeva005@gmail.com*

Бейбітхан Еркегүл

Әл-Фараби атындағы Қазақ Ұлттық Университеті, Аға оқытушы

Ақылды үйлер – бұл тұрғын үйдегі жайлылықты арттыруға, қауіпсіздікті күшейтуге және энергия тұтынуды оңтайландыруға бағытталған заманауи шешімдердің бірі. Қазіргі заманғы технологиялардың дамуы тұрмыстық автоматтандыру жүйелерінің кең таралуына ықпал етуде. Бұл мақалада Arduino платформасын қолдану арқылы ақылды үй прототипін жасау, оның негізгі жұмыс принциптері, құрамдас бөліктері және атқарушы құрылғылармен байланысы қарастырылады.

Arduino – ашық кодты микроконтроллерлік платформа, ол программалаудың қарапайымдылығымен және көптеген қосымша модульдермен үйлесімділігімен ерекшеленеді [1]. Ақылды үй жүйесін құру үшін әртүрлі датчиктер мен атқарушы құрылғылар қолданылады: температура және ылғалдылық датчиктері (DHT11, DHT22) үй ішіндегі ауа сапасын бақылауға және жылу жүйесін автоматтандыруға көмектеседі [2]; жарық датчиктері (LDR) күндізгі және түнгі уақытты ажыратып, жарықтандыруды автоматты түрде қосып/сөндіреді; қозғалыс датчиктері (PIR Sensor) бөлмедегі қозғалысты анықтап, жарықты қосу немесе дабыл жүйесін іске қосу үшін пайдаланылады [3]; газ және түтін датчиктері (MQ-2, MQ-7) өрт қаупін және газдың ағып кетуін анықтайды [4]; су деңгейін анықтау датчиктері судың ағуын бақылап, автоматты түрде суды тоқтатуға мүмкіндік береді.

Сонымен қатар, сервомоторлар мен релелер есіктерді автоматты түрде ашу/жабу және тұрмыстық техниканы қосу/өшіру үшін қолданылады, ал Wi-Fi модульдері (ESP8266, ESP32) жүйені смартфон немесе компьютер арқылы бақылау және басқару мүмкіндігін ұсынады. Ақылды үй жүйесі датчиктерден ақпарат жинап, оны Arduino арқылы өңдейді. Мысалы, PIR қозғалыс датчигі адамның бөлмеге кіргенін анықтаса, жарық автоматты түрде қосылады, температура датчигі үй ішіндегі температураны өлшеп, жылыту құрылғысын іске қосады, газ датчигі ағып кетуді анықтаса, дыбыстық сигнал беріледі және желдеткіш қосылады. Прототип жасау кезінде алдымен жобаны жоспарлау, қажетті компоненттерді таңдау, құрылғыларды жинақтау, бағдарламалау және тестілеу кезеңдері орындалады. Ақылды үй жүйелері қауіпсіздік, энергия үнемдеу және ыңғайлылық мақсаттарында қолданылады: бейнебақылау, есік құлыптарын басқару, өрт және газдан қорғану, қозғалыс сенсорлары арқылы күдікті әрекеттерді анықтау, жарықты автоматты түрде өшіру, жылытуды немесе салқындатуды бөлме жағдайына қарай реттеу, тұрмыстық техниканы дауыспен немесе смартфон арқылы басқару мүмкіндігі қарастырылады.

Arduino платформасында ақылды үй жүйесін жасау үшін C++ негізіндегі Arduino IDE программалау ортасы қолданылады [1]. Кодтау оңай, әрбір модульге арналған дайын кітапханалар бар. Arduino платформасы негізінде ақылды үй жасау – бұл қолжетімді, икемді және функционалды шешім. Болашақта бұл технология жасанды интеллект, машиналық оқыту және IoT негізінде одан әрі жетілдіріліп, адам өмірін әлдеқайда ыңғайлы әрі қауіпсіз етеді [3].

Пайдаланылған әдебиеттер тізімі:

1. Banzi, M. Getting Started with Arduino. 2011, O'Reilly Media.

2. Blum, J. Exploring Arduino: Tools and Techniques for Engineering Wizardry. 2013, Wiley.
3. Margolis, M. Arduino Cookbook. 2012, O'Reilly Media.
4. Monk, S. Programming Arduino: Getting Started with Sketches. 2016, McGraw-Hill Education.

БИЗНЕС-АНАЛИТИКА ЖӘНЕ ЖАСАНДЫ ИНТЕЛЛЕКТ ЭЛЕМЕНТТЕРІ БАР ЕСЕПТІЛІКТІ ҚҰРУ ЖӘНЕ БАСҚАРУДЫҢ АҚПАРАТТЫҚ ЖҮЙЕСІН ӘЗІРЛЕУДІҢ МАҢЫЗЫ

Әбдішүкір Қ.Қ.

Әл-Фараби атындағы Қазақ Ұлттық университетінің 4 курс студенті

E-mail: karlygasabdisukir@gmail.com

Кіріспе

Заманауи корпоративтік әлем тез өзгерістерден өтіп жатыр. Бизнес-процестер күрделене түседі, ал бәсекелестік шиеленіседі. Мұндай жағдайларда компаниялар тиімділікті арттыру және бәсекеге қабілеттілігін сақтау үшін жаңа тәсілдер іздеуге мәжбүр. Бизнес-талдау (Business Intelligence, BI) және жасанды интеллект (ЖИ) ұйымдарға өз процестерін жақсы түсінуге, деректерді талдауға және негізделген шешімдер қабылдауға көмектесетін маңызды құралдар болып табылады.

Кілттік сөздер: бизнес-талдау, жасанды интеллект, машиналық оқыту, деректерді талдау, болжау, автоматтандыру, бәсекеге қабілеттілік

Бизнес-талдаудың заманауи бизнестегі рөлі

Бизнес-талдау — бұл компанияларға деректерді жинауға, талдауға және шешім қабылдауды қолдау үшін визуалдауға мүмкіндік беретін құралдар мен әдістер жиынтығы. BI менеджерлерге бәсекелестік жағдайды жақсы түсінуге, нарықтағы өзгерістерді бақылауға және жаңа жағдайларға бейімделуге көмектеседі.

Заманауи BI шешімдері мыналарға мүмкіндік береді:

- Нарықтағы үлестің өзгеруін талдау.
- Тұтынушылардың мінез-құлқы мен талғамдарын зерттеу.
- Корпоративтік мүмкіндіктер мен нарықтық жағдайларды бағалау.
- Басшылар үшін жекелендірілген есептер мен дашбордтар жасау.

Мысалы, онлайн және офлайн режимінде жұмыс істейтін бөлшек сауда желісі BI-ды сатылымдар, сатып алулар және шығындар туралы деректерді талдау үшін пайдалана алады. Бұл танымал тауарларды, аймақтық трендтерді және сұраныстың маусымдық өзгерулерін анықтауға мүмкіндік береді. Мұндай түсініктер компанияға жарнамалық стратегияларды жасауға, тауарлардың жиынтықтарын құруға және дүкендердің жоспарын оңтайландыруға көмектеседі.

Жасанды интеллект және машиналық оқыту

Жасанды интеллект — бұл адам интеллектіні эмуляциялайтын және компьютерлерге адамның қатысуын талап ететін міндеттерді орындауға мүмкіндік беретін алгоритмдер арқылы жұмыс істейтін технология. Машиналық оқыту (МО), ЖИ-дың бір бөлігі ретінде, болжау, классификациялау және шешім қабылдау үшін модельдерді оқыту үшін тарихи деректерді пайдаланады. ЖИ тарихы 1951 жылы Ferranti Mark 1 компьютері жасанды интеллекттің алғашқы бағдарламаларын іске қосқан кезде басталды. 1956 жылы Дартмут колледжіндегі семинарда ЖИ зерттеулерінің ресми саласы құрылды. 1980-жылдарда мемлекеттік және корпоративтік инвестициялардың арқасында ЖИ саласы белсенді өсе бастады. 2000-2010 жылдар аралығында қуатты компьютерлік технологиялардың пайда болуымен машиналық оқыту өнеркәсіп пен қоғамдағы мәселелерді шешу үшін тиімді құралға айналды.

Бүгінгі күні ЖИ және МО мыналар үшін қолданылады:

- Рутинді процесстерді автоматтандыру.
- Сұраныс пен нарықтық трендтерді болжау.
- Жеткізу тізбектерін оңтайландыру.
- Чат-боттар және жекелендірілген ұсыныстар арқылы клиенттермен өзара әрекеттесуді жақсарту.

ВІ және ЖИ өзара әрекеттесуі

Бизнес-талдау және жасанды интеллект бір-бірін толықтырады. ВІ деректер мен аналитикалық құралдарды ұсынады, ал ЖИ осы деректерден жасырын заңдылықтарды ашып, болжамдар жасауға көмектеседі. Мысалы, ЖИ арқылы компаниялар мыналарды жасай алады:

- Нақты уақыт режимінде үлкен көлемді деректерді талдау.
- Аномалиялар мен ықтимал тәуекелдерді анықтау.
- Сұраныс пен нарықтық жағдайлардың өзгеруін болжау.

ВІ және ЖИ енгізудің артықшылықтары

1. **Бизнес тиімділігін арттыру:** Процестерді автоматтандыру және деректерді талдау шығындарды азайтуға және шешімдер сапасын жақсартуға мүмкіндік береді.

2. **Нарықты жақсы түсіну:** Тұтынушылар мен бәсекелестер туралы деректерді талдау компанияларға өзгерістерге бейімделуге көмектеседі.

3. **Болжау және жоспарлау:** ЖИ болашақ трендтерді болжауға және алдын ала шаралар қабылдауға мүмкіндік береді.

4. **Клиенттермен өзара әрекеттесуді жекелендіру:** Тұтынушылардың мінез-құлқын талдау үшін ЖИ-ды пайдалану жекелендірілген ұсыныстар жасауға көмектеседі.

Қорытынды

Бизнес-талдау және жасанды интеллект заманауи бизнестің ажырамас бөлігі болып табылады. Олар компанияларға деректерді талдауға, процесстерді оңтайландыруға және негізделген шешімдер қабылдауға көмектеседі. Нарықтың тез өзгертін жағдайында ВІ және ЖИ-ды енгізу — бұл тек тренд емес, сонымен қатар бәсекеге қабілеттілікке қол жеткізу үшін қажеттілік. Бұл технологияларға салынған инвестициялар тиімділікті арттыру, шығындарды азайту және қабылданған шешімдер сапасын жақсарту арқылы өзін ақтайды. Бизнестің болашағы деректерге, аналитикаға және интеллектуалды технологияларға байланысты, және бүгінгі күні ВІ және ЖИ-ды енгізген компаниялар ертеңгі күннің лидерлері болады.

Пайдаланылған әдебиеттер тізімі:

1. Davenport, H. T., Harris, J., and Abney, D. (2017). *Competing on Analytics: The New Science of Winning*. Brighton: Harvard Business Review Press
2. Evans, R. J. (2017), *Business Analytics - Methods, Models and Decisions*. 2nd edition. London, England: Pearson Education Limited
3. Gartner BI and Analytics Report (2017). *Magic Quadrant for Business Intelligence and Analytics Platform*. Retrieved from: <https://www.sisense.com/whitepapers/gartner-magic-quadrant-2017/>
4. Gartner, IT Glossary, 2018, Retrieved from: <https://www.gartner.com/it-glossary/>
5. Developers and Developers, “Data analytics & artificial intelligence: What it means for your business and society,” IMD Business School for Management and Leadership Courses, Aug. 08, 2023. <https://www.imd.org/researchknowledge/digital/articles/artificialintelligence-real-world-impact-on-businessand-society/>
6. K. Benke and G. Benke, “Artificial Intelligence and big data in public health,” *International journal of environmental research and public health*, <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6313588/>.

ИНФОРМАЦИОННАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ И АНАЛИЗА ЭФФЕКТИВНОСТИ ЦЕННЫХ БУМАГ

Байбосын Н.Н.

Научный руководитель: Ст. преподаватель кафедры информационных систем

Кожанова А.М.

КазНУ им. аль-Фараби, Алматы, Казахстан

E-mail: nurda0755@gmail.com

В данной работе предпринимается попытка описания природы динамики фондового рынка и оценки эффективности ценных бумаг путем применения методов математического моделирования, машинного обучения и статистического анализа. Выдвигается гипотеза о возможности предсказания тенденций рынка и оптимизации инвестиционных решений за счет анализа исторических данных, выявления скрытых закономерностей и использования современных технологий искусственного интеллекта.

Рассматриваются ключевые факторы, влияющие на стоимость и ликвидность активов, включая макроэкономические показатели, корпоративную отчетность, рыночные индексы, поведенческие аспекты инвесторов, а также глобальные финансовые тренды. Проводится сравнительный анализ существующих моделей прогнозирования, таких как временные ряды, регрессионные методы, нейронные сети и стохастические модели, с целью выявления их преимуществ и недостатков в контексте прогнозирования цен на активы.

Исследуются перспективы применения гибридных методов, основанных на комбинации традиционного финансового анализа и алгоритмов машинного обучения. Рассматриваются особенности обработки больших объемов данных, их структурирование и анализ в реальном времени для оперативного выявления аномалий, рыночных сигналов и возможных рисков. Дается обоснование возможности интеграции прогнозных моделей в автоматизированные торговые системы (алготрейдинг) с учетом динамических изменений рыночной среды.

Описываются механизмы построения интеллектуальной системы, способной адаптироваться к изменениям на финансовых рынках. Предлагается концепция использования глубокого обучения и рекуррентных нейросетей для предсказания цен на ценные бумаги с учетом исторической волатильности, объемов торгов и сезонных факторов. Анализируются методы оценки точности прогнозов, такие как среднеквадратичная ошибка (MSE), коэффициент детерминации (R^2) и метрики классификации, включая precision, recall и F1-score.

Формулируются основные положения и границы применимости новой системы прогнозирования. Дается обоснование ее потенциальных преимуществ по сравнению с традиционными методами анализа. Определяются ключевые направления дальнейших исследований, включая совершенствование алгоритмов прогнозирования, повышение их адаптивности к нестабильным рыночным условиям и разработка интегрированных решений для финансовых институтов и частных инвесторов.

Проводится оценка применимости предложенной системы в различных сценариях: краткосрочное и долгосрочное инвестирование, управление рисками, арбитражные стратегии и оптимизация портфеля активов. Рассматривается возможность использования блокчейн-технологий и смарт-контрактов для автоматизации финансовых операций, а также потенциал применения квантовых вычислений для более точного предсказания поведения рынка. Рассматривается влияние рыночных аномалий, таких как эффект момента, обратный эффект и сезонные тренды, на точность прогнозных моделей. Исследуются вопросы интерпретируемости моделей и методов объяснения их решений, включая SHAP-значения и методы локальной интерпретации моделей машинного обучения (LIME).



Рис. 1. Анализ для выявления корреляций между акциями и точек входа/выхода на рынке

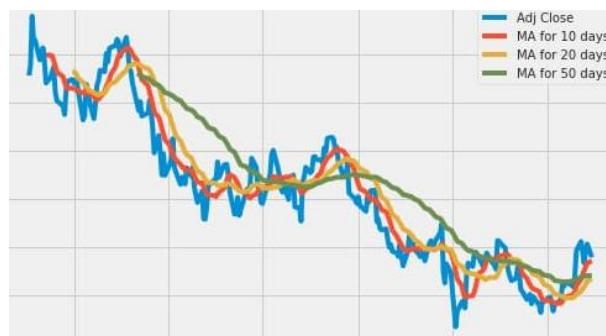


Рис. 2. Анализ временных рядов для выявления трендов

В данной работе была разработана и рассмотрена информационная система прогнозирования и анализа эффективности ценных бумаг, основанная на методах машинного обучения и статистического анализа. Были выявлены ключевые факторы, влияющие на динамику финансовых рынков, и исследованы способы их математического моделирования.

Анализ корреляций рыночных факторов показал, что макроэкономические показатели, корпоративная отчетность и поведенческие аспекты инвесторов оказывают значительное влияние на изменение стоимости активов. В результате проведенного исследования было доказано, что интеграция методов машинного обучения, таких как нейронные сети и временные ряды, позволяет значительно повысить точность прогнозирования цен акций и рыночной волатильности.

Дополнительно была реализована визуализация рыночных данных, в том числе анализ корреляции между активами и изменение рыночной волатильности со временем. Полученные результаты могут быть полезны как для частных инвесторов, так и для крупных финансовых институтов, стремящихся повысить эффективность своих инвестиционных стратегий.

Список использованной литературы:

1. Абдрахманов Н.К., Смагулов А.Т. Машинное обучение в анализе финансовых рынков: методы и приложения. – Алматы: Экономика, 2021. – №3(45). – С. 25-32.
2. Иванов С.В., Петров А.А. Алгоритмическая торговля и предсказание цен на акции с использованием нейросетевых моделей. – Москва: Финансы и статистика, 2020. – №7(58). – С. 48-55.
3. Сериков Д.Р., Касымов М.Т. Анализ временных рядов и машинное обучение в финансовых прогнозах. Вестник НАН РК. Серия экономическая. – 2019. – №4(312). – С. 100-105.
4. Ким А.В., Байжанов Р.А. Глубокое обучение и прогнозирование рыночной волатильности. – Астана: Институт прикладных исследований, 2022. – №5(78). – С. 60-67.

АВТОМАТТАНДЫРЫЛҒАН ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕЛЕРДІ ЗЕРТТЕУ НӘТИЖЕЛЕРІ ЖӘНЕ ОЛАРДЫҢ АҚЫЛДЫ ТЕХНОЛОГИЯЛАР ҚҰРУДАҒЫ РӨЛІ

**Болат Жанель Ғалымқызы
Қаулыбек Бағлан Ержанұлы,
Бекмурат Бекарыс Бекжанұлы,**

*Әл-Фараби атындағы Қазақ Ұлттық Университеті,
Ақпараттық жүйелер мамандығының 3-курс студенттері,
Email: baglankauilybek222@gmail.com*

Бейбітхан Еркегүл

*Әл-Фараби атындағы Қазақ Ұлттық Университеті,
Ақпараттық жүйелер кафедрасының аға оқытушысы*

Аннотация: Мақалада Arduino платформасы негізінде жүзеге асырылатын автоматтандырылған интеллектуалды жүйелер мен сенсорлық басқару әдістері қарастырылады. Қазіргі цифрландыру заманында «ақылды» құрылғылар мен жүйелер процестерді тиімді басқарып, адам қатысуын азайтады. Arduino көмегімен құрастырылатын жобалардың мысалдары, негізгі аппараттық компоненттер мен датчиктер сипатталады. Сонымен қатар, ақылды технологиялардың болашағы және олардың қоғамға, экономикаға тигізетін әсері талқыланады.

Түйін сөздер: ақылды технологиялар, Arduino, автоматтандырылған жүйелер, сенсорлық басқару, интеллектуалды жүйе, датчиктер, IoT.

Кіріспе. «Ақылды технологиялар» ұғымы бүгінгі өмірдің көптеген саласында кездеседі. Зияткерлік автоматтандырылған жүйелер өндірістен тұрмыстық ортаға дейінгі процестерді оңтайландырып, уақыт пен шығынды үнемдейді. Сенсорлық басқару әдістерін қолдану арқылы жүйелер қоршаған орта деректерін талдап, қажетті әрекеттерді өздігінен жүзеге асырады.

Arduino – микроақылдық тақшаға (микроконтроллерге) негізделген ашық платформалық орта. Бұл құрал сенсорлар мен атқарушы құрылғыларды біріктіріп, қарапайым прототиптер жасауға мүмкіндік береді.

Ақылды технологиялар және Arduino платформасы

Ақылды жүйелер адам әрекетін автоматтандыруға бағытталған бағдарламалық-аппараттық кешендерге сүйенеді. Олар:

- Қоршаған ортаны үздіксіз бақылау;
- Нақты уақыт режимінде деректерді өңдеу;
- Алынған ақпарат негізінде шешім қабылдау;
- Адам қатысуын азайту арқылы өнімділікті арттыру.

Зияткерлік жүйелерді жасауда машиналық оқыту мен жасанды интеллект әдістері қолданылады. Бұған Arduino, Raspberry Pi, ESP32 тәрізді қолжетімді микроконтроллерлер кеңінен пайдаланылады. Arduino-ның негізгі артықшылықтары – бағаның қолжетімділігі, бағдарламалаудың оңайлығы, модульдік құрылым және үлкен қауымдастықтың қолдауы.

Arduino негізіндегі жобалар мысалдары

1. Автоматтандырылған шлагбаум

- Компоненттер: Arduino Uno, HC-SR04 ультрадыбыстық датчигі, серво мотор, 5В қуат көзі.

- Жұмыс қағидасы: Датчик көлік жақындағанын анықтағанда, Arduino сервомоторға шлагбаумды көтеру бұйрығын береді. Көлік өткен соң шлагбаум қайта жабылады.

2. Автоматты қоқыс жәшігі

- Компоненттер: Arduino Uno, ультрадыбыстық датчик, серво мотор, қуат көзі.

- Қызметі: Адам жақындағанда датчик қозғалысты анықтап, қақпақты ашады.

3. RFID арқылы есік ашу жүйесі

- Компоненттер: Arduino Uno, RC522 RFID оқу модулі, RFID карточкасы, сервомотор/электронды құлып.

- Қызметі: Карта жақындатылғанда Arduino ID сәйкестігін тексеріп, есікті ашады.

4. Қозғалысты анықтайтын жарық жүйесі

- Компоненттер: Arduino, PIR датчигі, реле модулі.

- Қызметі: PIR датчигі қозғалысты анықтағанда жарық қосылады, ал қозғалыс болмаған кезде өшеді.

5. Температура мен ылғалдылықты бақылау

- Компоненттер: Arduino, DHT11 датчигі, LCD/OLED дисплей.

- Қызметі: Датчик мәндері үздіксіз оқылып, дисплейде көрсетіледі.

6. Саусақ қимылын анықтау құралы

- Компоненттер: Arduino Nano, Flex sensor.

- Қызметі: Датчиктер саусақтардың бүгілу деңгейін өлшеп, тиісті командаларды орындайды.

Қорытынды: «Заттар интернеті» (IoT), «Ақылды қала», «Ақылды ферма» тұжырымдамаларының дамуы Arduino сияқты шағын платформалардың маңызын күшейте түсуде. Жасанды интеллект пен микроконтроллерлер үйлескен сайын процестер толығымен автоматтандырылып, адамның жұмысын жеңілдетеді.

Бұл мақалада келтірілген жобалар мысалдары Arduino-ның икемділігін көрсетіп, өндірістік және тұрмыстық салада шығынды азайтатын шешімдер ұсынады. Сенсорлық басқару мен жасанды интеллект әдістерінің интеграциясы «ақылды» құрылғыларды жаңа деңгейге көтеретіні сөзсіз.

Пайдаланылған әдебиеттер тізімі:

1. Baird, K., & Thomas, M. (2015). Business Analytics for Managers: Taking Business Intelligence Beyond Reporting. Wiley.

2. Chaudhuri, S., Dayal, U., & Narasayya, V. (2011). Data Warehousing and Business Intelligence: Concepts, Methodologies, Tools, and Applications. IGI Global.

3. Negash, S. (2004). Business Intelligence. Communications of the Association for Information Systems, 13(1), 177-195.

4. Калашникова, Т. В. (2014). Бизнес-аналитика: теория и практика применения. Юрайт.

5. Official Arduino Documentation: <https://docs.arduino.cc/>

6. Banzai, M., & Shiloh, M. (2014). Make: Getting Started with Arduino. Maker Media.

7. Russell, S., & Norvig, P. (2021). Artificial Intelligence: A Modern Approach (4th ed.). Pearson.

8. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.

9. Nilsson, N. J. (2010). The Quest for Artificial Intelligence: A History of Ideas and Achievements. Cambridge University Press.

10. Chollet, F. (2017). Deep Learning with Python. Manning Publications.

11. Poole, D., & Mackworth, A. (2017). Artificial Intelligence: Foundations of Computational Agents (2nd ed.). Cambridge University Press.

АЛМАТЫНЫҢ ЭКОЛОГИЯЛЫҚ ЖАҒДАЙЫН ЖАҚСАРТАТЫН ИНТЕЛЛЕКТУАЛДЫ АҚПАРАТТЫҚ ЖҮЙЕ ҚҰРУ

Батырбек А.

*Әл-Фараби атындағы Қазақ ұлттық университеті,
«Ақпараттық жүйелер» мамандығының 3 курс студенті
E-mail: batyrbek.arailyym@mail.ru*

Аннотация: Бұл мақалада Алматы қаласының экологиялық жағдайын жақсарту мақсатында интеллектуалды ақпараттық жүйені құру мәселесі қарастырылады. Қалада белең алып отырған экологиялық проблемалар, атап айтқанда, ауаның ластануы, көлік қозғалысының қарқындылығы, өндірістік қалдықтар мен көгалдандырылған жасыл желектің қысқаруы сияқты негізгі факторлардың әсері талданады. Экологиялық мәселелердің шешімі ретінде ұсынылған ақпараттық жүйе нақты уақыт режимінде деректер жинайтын сенсорлық желіден, ақпараттарды бұлттық серверлерде талдайтын платформадан және тұрғындарға ақпарат беретін мобильді қосымшадан тұрады. Мақалада интеллектуалды ақпараттық жүйе қала экологиясына әсер ететін негізгі аспектілері қарастырылып, оның Алматыны экологиясы тұрақты, жайлы және қауіпсіз қалаға айналдырудағы рөлі сипатталады. Инновациялық технологияларды интеграциялау - табиғатты қорғау мен қаланың тұрақтылығын қамтамасыз етуде маңызды құрал екендігі дәлелденді.

Түйін сөздер: экология, тиімді ақпараттық жүйе, Алматы, ауа сапасы, жасанды интеллект, деректерді талдау, сенсорлар желісі, көлік қозғалысы, мониторинг, қоғамдық көлік, ластану көздері.

Қазақстанның ең ірі мегаполистерінің бірі — Алматы, оның табиғатының көркі мен тау бөктерінде орналасуының өзі көз қуантады. Қаланың экологиялық хал-ахуалы күннен-күнге нашарлап, көлік қозғалысының үздіксіздігі мен өнеркәсіптік қалдықтардың зияны, жасыл желекті аудандардың азаюы ауаны қарқынды түрде ластап, адам денсаулығына тигізер әсері ушығып барады. Аталған проблемаларды оңтайлы етіп шешу үшін заманауи технологияларды қолданып, интеллектуалды ақпараттық жүйе құрастыру қажет. Бұл жүйе табиғаттың экологиялық параметрлерін үздіксіз бақылап, деректерді талдап, қорытынды шешім қабылдауға көмектеседі.

Интеллектуалдық ақпараттық жүйе бірнеше компонентті құрылымнан тұруы керек. Экологиялық параметрлерді тіркеп отыратын сенсорлар жүйесі ауа сапасы мен шудың деңгейі, жасыл желек пен көгалдандырудың жағдайы, қалдықтардың таралу жиілігі туралы ақпарат күнделіктісін-күнде бұлттық серверлерге жеткізілуі тиіс. Жасанды интеллект жиналған ақпаратты алгоритмдер арқылы өңдеп, проблемалардың туу ошағы, яғни, ластану көздері мен олардың ластану динамикасы анықталады. Нақты уақыт режимінде жұмыс жасайтын бұл жүйе экологиялық ахуалға жылдам мониторинг жасауға мүмкіндік береді. Осындай күрделі жүйенің бар екенін тұрғындар білу үшін арнайы мобильді қосымшалар мен веб-сайттар, платформалар ұйымдастырылуы керек. Тұрғындар бұл қосымшаны қолдану арқылы өз қаласындағы ауа сапасы мен көлік тығыздығы, шу деңгейі сияқты экологиялық ахуалға әсер ететін факторлар туралы соңғы деректерден хабардар болады. Сонымен қатар, экологиялық мәселелерге байланысты тұрғындар пікір білдіріп, қажет жағдайда шағым түсіре алатындай, қала билігі тұрғындар шағымына байланысты тиісті шараларды қабылдайтындай жағдай жасалса, нұр үстіне нұр болар еді. Қоғамдық көлікті тұрғындар арасында жиірек қолданатындай етіп ұйымдастырылған ақылды басқару жүйесі қаладағы көлік ағынын реттеп отырады. Мұндай нәтижеге жету үшін ақылды бағдарламалар мен динамикалық жолақтарды қолдану міндетті. Қалада түрлі жағдаяттар болып тұратындықтан, экологиялық қауіпсіздікті сақтамаған тұрғындар мен кәсіп иелеріне автоматты түрде ескертулер жасалып, оларды жауапкершілікке тарту шаралары да негізделуі тиіс. Менің ойымша, мұндай экологиялық мәселелерді шешетін ақпараттық жүйені құрастыру Алматы қаласының бірнеше өзекті

мәселелерін шешеді. Ауа сапасын үнемі бақылап, тіркеп, ластану көздерін анықтай отырып, тиісті шараларды қабылдағанда, қала тұрғындарының да өмір сүру деңгейі жақсарар еді. Жасанды интеллект көлік кептелісін автоматты түрде реттеп, көмірқышқыл газының ауаға таралу пайызын төмендетеді. Экологиялық мәселелерді реттеу үшін қаланың жасыл желектендірілуі де маңызды, осы себепті жасыл желектердің жағдайы мен оларды күтіп-баптау шаралары күшейтіле түссе, қаланың экожүйесі орнығып, тұрақтылығы өсер еді. Халықтың экологиялық мәдениетін қалыптастыруымыз керек, әйтпесе, мемлекет тарапынан жасалған шаралардың барлығы заяға кетпек. Экологиялық мәдениетке дағдыланған халық қоршаған ортаға ұқыпты қарай бастайды.

Қорыта айтқанда, Алматы қаласының экологиялық мәселелерін шешу — жүйелі және кешенді тәсілдерді қолдануды қажет ететін міндет. Интеллектуалды ақпараттық жүйені қолдану арқылы Алматының экологиялық проблемаларын шеше аламыз. Заманауи технологиялар мен деректерді жан-жақты талдау әдістерін қолдана отырып, экологиялық жағдайды бақылап, алдын-алу шараларын тиімді түрде қарастыруға болады. Мұндай ақпараттық жүйенің басты мақсаты – қаладағы экологиялық мәселелерді шешу арқылы қаланың тұрақты дамуын қамтамасыз ету, тұрғындарға оңтайлы экологиялық орта қалыптастыру арқылы табиғи ресурстарды тиімді қолдану. Осындай жүйе көмегімен болашақта Алматы жасыл және биологиялық қауіпсіз қалаға айналатыны сөзсіз.

Пайдаланылған әдебиеттер тізімі:

1. Оспанова Г.С. Бозшатаева Г.Т. Экология - Алматы.: Экономика, 1999. 101 б.
2. “Қазақстан ұлттық энциклопедиясы” 1,3 томдар. 46-52 бет Сағымбаев Г.К. Экология және экономика. Алматы. 1997. 256 бет.
3. Қоршаған орта және еңбек қауіпсіздігіндегі жаңалықтар. IV Халықаралық ғылыми – техникалық конференциясының материалдары. – А., 2000 ж.
4. Кенжебеков А.К., Асубаев Қ.О. Облыс тұрғындарына арналған санитарлық – экологиялық жадынама. – Талдықорған, 2004 ж.

КӘСІБИ БАҒДАР БЕРУ ҚЫЗМЕТІНДЕ ЖАСАНДЫ ИНТЕЛЛЕКТІНІ ҚОЛДАНУ МҮМКІНДІГІ

Бахытбай Бақжұлдыз

Әл-Фараби атындағы Қазақ ұлттық университеті, Жасанды интеллектісі бар жоғары жүктелген ақпараттық жүйелер мамандығының 4-курс студенті, bakzhuldyz03@gmail.com

Бурибаев Бахыт

Әл-Фараби атындағы Қазақ ұлттық университеті, т.ғ.к., доцент

Қазіргі еңбек нарығының өзгермелі талаптары жастарға кәсіби жолын дұрыс таңдауға көмектесетін тиімді құралдардың, соның ішінде жасанды интеллект негізіндегі кәсіби бағдарлау нейрожелісінің қажеттілігін арттыруда. Кәсіби бағдарлау нейрожелісінің тиімді жұмыс істеуі үшін екі негізгі деректер тобы қажет:

1. Кіріс деректері – бұл талапкерлердің кәсіби бағдарлау тесттеріне берген жауаптары мен қосымша жиналған деректер. Бұл ақпарат нейрожеліге нақты адамның қызығушылықтары, бейімділіктері және қабілеттері туралы толық түсінік алуға мүмкіндік береді.

2. DataSet – кәсіби жолын тауып, түрлі салаларда жұмыс істейтін адамдар туралы мәліметтер базасы. Бұл нейрожеліге жаңа талапкерлерге ұсыныстар беру үшін қажет үлгілік ақпарат болып табылады.

Кіріс деректері DataSet-пен толық сәйкес болуы керек, яғни бірдей құрылым, сұрақтар мен жауаптар саны сақталуы тиіс (1 – оң жауап, 0 – теріс жауап).

Нейрожелі осы екі дерек негізінде талапкерге жеке кәсіби бағдар бойынша ұсыныстар береді. Бұл үдерісті төмендегі схема сипаттайды:

Кіріс деректері → Нейрожелі не ұсынуға → Шығыс деректері – Кәсіби бағдар болатынын ойлайды (DataSet негізінде)

Кәсіби бағдарлау нейрожелісіне арналған DataSet ақпараттарына қойылатын талаптар:

Оқыту жиынтығы	Бұл нейрожеліні оқыту үшін қолданылатын деректер жиынтығы. Әдетте, жиынтық кіріс деректері (мысалы, суреттер, мәтін үзінділері немесе сандық мәндер) мен осы деректерге сәйкес мақсатты мәндерден (мысалы, сынып белгілері немесе сандық мәндер) тұрады. Оқыту жиынтығы нейрожелінің жаңа деректерге қатысты білімін жалпылай алуы үшін жеткілікті түрде алуан түрлі және өкілді болуы керек.
Деректердің жеткілікті көлемі	Оқыту үшін деректер көлемі міндеттің күрделілігіне және нейрожелінің архитектурасына байланысты. Жалпы жағдайда, оқыту үшін деректер көлемі неғұрлым көп болса, нейрожелінің оқыту сапасы соғұрлым жақсы болады. Сонымен қатар, деректер көлемі мен есептеу ресурстары арасындағы теңгерімді сақтау қажет, өйткені үлкен деректерді өңдеу көп есептеу қуаты мен уақытты талап етуі мүмкін.
Деректерді оқыту және тексеру жиынтықтарына бөлу	Әдетте деректер оқыту жиынтығы және тексеру (валидациялық) жиынтығы ретінде бөлінеді. Оқыту жиынтығы нейрожеліні оқыту үшін, ал тексеру жиынтығы оның өнімділігін бағалау және модель гиперпараметрлерін баптау үшін қолданылады.
Келісілген белгілері бар деректер	Егер деректерде белгілер (мысалы, сыныптар немесе категориялар) болса, онда бұл белгілердің келісілген және сенімді болуы маңызды.

Сурет 1. Авторлар тарапынан Ракова Ю.А. [16, 256–258 б.] (Rakova, 2019, p. 256–258), Похорокова М.Ю. [12, 59–62 б.] (Pokhorukova, 2017, p. 59–62) ғылыми еңбектері негізінде құрастырылған.

Кәсіби бағдарлау нейрожелісін оқыту үшін кәсіби бағытын анықтаған адамдардың әртүрлі және нақты жауаптарынан құралған жеткілікті көлемдегі DataSet қажет, ол оқыту және тексеру жиынтықтарына бөлініп, нақты келісілген белгілерге негізделуі тиіс. Жасанды интеллект арқылы кәсіби бағдар беру жүйесінің артықшылықтары: еңбек нарығына сай үнемі жаңарып, бейімделуі; онлайн өту арқылы ыңғайлылығы мен қолжетімділігі; адамның қызығушылығы мен қабілетіне сай нақты ұсыныстар беруі; уақыт пен ресурсты үнемдеуі; деректер базасының үнемі жаңартылып, жүйенің өзектілігін сақтауы.

Жасанды интеллект негізіндегі кәсіби бағдарлау нейрожелісі – заманауи және тиімді шешім, ол жеке тұлғаның ерекшеліктерін ескере отырып, кәсіби бағдарлаудың сапасын арттырады. Бұл жүйе арқылы жастар еңбек нарығындағы сұранысқа ие мамандықтар туралы шынайы ұсыныстар ала алады. Сонымен бірге, уақытты үнемдеу, нақты ұсыныстар алу, жеке қабілеттерді анықтау сияқты үлкен мүмкіндіктерге жол ашады.

Пайдаланылған әдебиеттер тізімі:

1. Ракова Ю.А. Кәсіби бағдар беруде жасанды интеллектіні қолдану: мүмкіндіктері мен болашағы // Білім берудегі инновациялық технологиялар. – 2019. – №4. – 256–258 бб.
2. Похорукова М.Ю. Жастарды кәсіби бағдарлауда нейрожелілерді қолдану // Ғылым және білім берудің заманауи мәселелері. – 2017. – №5. – 59–62 бб.
3. Гудфеллоу И., Бенджио Й., Курвиль А. Терең оқыту (Deep Learning). – MIT Press, 2016. – 775 б.
4. Рассел С., Норвиг П. Жасанды интеллект: заманауи тәсіл (Artificial Intelligence: A Modern Approach). – 3-басылым. – Pearson, 2010. – 1152 б.
5. Назарова И.В. Кәсіби бағдар жүйесінде жасанды интеллектіні қолдану // Жас ғалым. – 2021. – №21 (363). – 132–135 бб.
6. Мұхаметшина Л.Р. Сандық технологияларды қолдану арқылы кәсіби бағдарлаудың заманауи тәсілдері // Ғылым және білім беру хабаршысы. – 2020. – №24 (102). – 38–41 бб.
7. Жұмашева Г.Ж., Ахметова Ш.Қ. Жасанды интеллект технологияларын білім беру жүйесіне енгізу мәселелері // Қазақ ұлттық университетінің хабаршысы. – 2022. – №3 (204). – 112–118 бб.
8. Чжан Ю., Чжао Л. Кәсіби бағдар берудегі жасанды интеллект рөліне шолу // Жасанды интеллект зерттеулері журналы (Journal of Artificial Intelligence Research). – 2021. – Т. 70. – 45–67 бб.
9. Базарбаева Г.Ж. Ақпараттық жүйелердегі жасанды интеллект негіздері. – Алматы: Қазақ университеті, 2020. – 240 б.
10. Еуропалық кәсіби даярлықты дамыту орталығы (Cedefop). Жасанды интеллект және болашақ дағдылар: білім беру және оқыту үшін салдары. – Люксембург: Еуропалық Одақтың баспа кеңсесі, 2021. – 50 б.

Машиналық оқыту әдістерін пайдалана отырып, балалардың сөйлеу бұзылыстарын диагностикалауға арналған қосымшаны әзірлеу

Орынбасарова Э.Ж.

Бейсембай Н.М.

Рахимова Д.Р.

Әл-Фараби атындағы Қазақ ұлттық университеті, бакалавр 4 курс

E-mail: elvrzh6@gmail.com, merekeqyzy7@gmail.com

Балалардағы сөйлеу бұзылыстары, әсіресе 3-7 жас аралығындағы сыни алғашқы жылдары, олардың тиімді қарым-қатынас жасау қабілетіне айтарлықтай әсер етеді. Бұл мақалада жас балалардағы сөйлеу бұзылыстарын анықтау үшін ML әдістерін қолдану мүмкіндігі қарастырылады. Ол сөйлеу жазбаларын алдын-ала жиналған мәліметтер массивтерімен салыстыру арқылы сөйлеу бұзылыстарын диагностикалауға мүмкіндік беретін қосымшаны әзірлеуді қарастырады.

Кішкентай балалардағы сөйлеу бұзылыстары олардың білім беру және әлеуметтік дамуына ұзақ әсер етуі мүмкін. Дәстүрлі диагностикалық әдістер көбінесе баяу жүреді және әрдайым қолжетімді бола бермейтін маманның араласуын қажет етеді. Осы бұзылуларды диагностикалау үшін машиналық оқыту үлгілерін пайдалану жылдамырақ, масштабталатын және қолжетімді шешімді ұсынады. Бұл мақалада 3-7 жас аралығындағы балалардағы сөйлеу бұзылыстарын диагностикалауға арналған машиналық оқытуға негізделген инновациялық тәсіл ұсынылған, ол ерте араласуды жеңілдетуге және емдеудің жекелендірілген нұсқаларын ұсынуға бағытталған.

Соңғы зерттеулер сөйлеу бұзылыстарын диагностикалауда машиналық оқытудың әлеуетін атап өтті. Мысалы, зерттеулер Whisper, Kaldi және DeepSpeech сияқты сөйлеуді мәтінге түрлендіру (STT) үлгілері балалардың сөйлеуін транскрипциялау мен ML модельдері ерте жастағы балаларды диагностикалауда және қашықтықтан логопедиялық көмек көрсетуде тиімді қолданылады. Бұл зерттеулер сөйлеу бұзылыстарын диагностикалаудың қол жетімді және дәл құралдарын жасау үшін машиналық оқытуды қолданудың маңыздылығын көрсетеді.

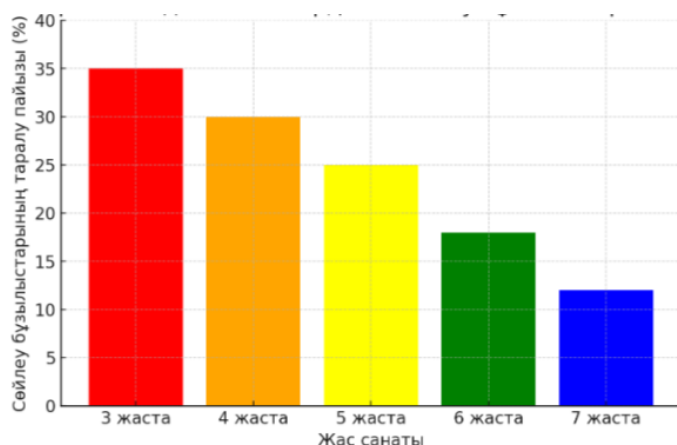


Диаграмма сипаттамасы:

- 3 жастағы балаларда сөйлеу бұзылыстарының таралуы ең жоғары (35%).
- Жас ұлғайған сайын бұл көрсеткіш біртіндеп төмендейді: 4 жаста – 30%, 5 жаста – 25%, 6 жаста – 18%, 7 жаста – 12%.
- Бұл көрсеткіштер ерте диагностиканың және логопедиялық түзетудің маңыздылығын көрсетеді.

Сөйлеу деректері жасы мен жынысы бойынша бөлінген 3-7 жас аралығындағы балаларда жиналды. Деректер жиынтығында балалар фонетикалық дәлдік пен айқындық сияқты сөйлеу

ерекшеліктерін талдауға мүмкіндік беретін сөздер жиынтығын қайталайтын аудио жазбалар бар. Машиналық оқыту модельдері:

• **Speech-to-Text (STT):** әрі қарай талдау үшін аудио жазбаларды мәтінге түрлендіру. Whisper, жасанды интеллектпен басқарылатын STT моделі жоғары дәлдігі мен бірнеше тілде жұмыс істеу қабілетінің арқасында тізімге енгізілген.

• **Kaldi:** сөйлеуді тануға арналған және сенімді фонетикалық талдауды ұсынатын ашық бастапқы құралдар жинағы.

• **ESPnet:** дәлдікті жақсарту үшін терең оқыту әдістерін біріктіретін сөйлеуді танудың гибридті моделі.

• **DeepSpeech:** сөйлеуді мәтінге айналдыру дәлдігін жақсарту үшін терең оқытуды қолданатын модель, әсіресе шулы ортада.

Бұл зерттеу аясында жасанды интеллекті бар интерактивті мобильді қосымша әзірленеді. Қосымшаның негізгі ерекшеліктері:

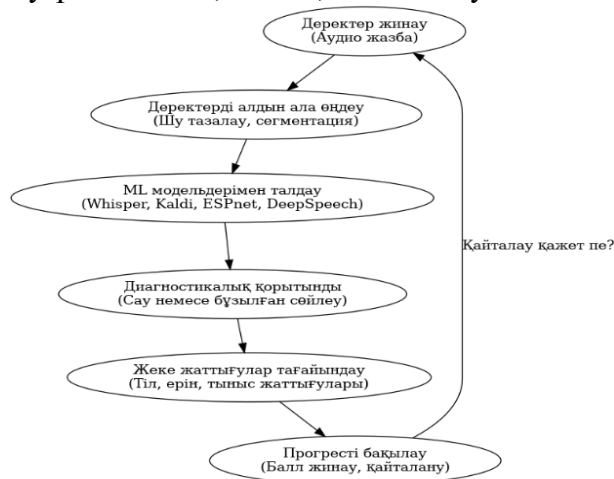
• **Диагностикалық бөлім:** Баланың жасын және жынысын ескере отырып, белгілі бір сөздер жиынтығы ұсынылады. Баланың айтқаны жазылып, сау сөйлеу үлгілерімен салыстырылады.

• **Логопедиялық жаттығулар:** Қосымша сөйлеу бұзылыстары анықталған жағдайда, арнайы таңдалған жаттығуларды ұсынады. Жаттығулар үш негізгі категорияға бөлінеді:

- Ерін гимнастикасы
- Тіл гимнастикасы
- Дыбыстарды дұрыс айтуға арналған тапсырмалар

• **Жасанды интеллект арқылы бағалау:** Баланың дыбыс артикуляциясы мен сөйлеу сапасы AI көмегімен талданады. Бағалау нәтижесі негізінде қосымша кері байланыс береді және қиындықтар туындаған жағдайда жеке ұсыныстар ұсынады.

Балалардың сөйлеуін талдау үшін машиналық оқытуға негізделген қосымша жасалды. Қолданба пайдаланушыларға баланың жасын және жынысын таңдауға мүмкіндік береді, бұл жүйені оны қайталау үшін белгілі бір сөздер жиынтығын жасауға шақырады. Содан кейін жазылған сөйлеу сау және бұзылған сөйлеу деректер жиынтығымен салыстырылады, бұл жүйеге баланың жағдайын диагностикалауға мүмкіндік береді. Деректер жиынтығы оқу (80 %) және тестілік (20 %) ішкі жиындарға бөлінді. Модельдер диагностикалық мүмкіндіктерін анықтау үшін дәлдік, дәлдік, есте сақтау және F1-score негізінде бағаланды.



Диаграммада келесі қадамдар көрсетілген:

1. **Деректер жинау** – Баланың сөйлеуін аудио форматта жазу.
2. **Деректерді алдын ала өңдеу** – Шу тазалау, сөйлеуді сегментациялау, сапасын жақсарту.

3. **ML модельдерімен талдау** – Whisper, Kaldi, ESPnet, DeepSpeech арқылы сөйлеуді талдау.
4. **Диагностикалық қорытынды** – Балада сөйлеу бұзылысы бар ма, жоқ па деген шешім шығару.
5. **Жеке жаттығулар тағайындау** – Логопедиялық жаттығуларды автоматты түрде ұсыну (ерін, тіл, тыныс жаттығулары).
6. **Прогресті бақылау** – Бала тапсырмаларды орындаған сайын оның жетістіктерін бағалау.
7. **Қайталау циклі** – Егер прогресс жеткіліксіз болса, жаттығуларды қайталау.

Қорытынды

Машиналық оқыту 3-7 жастағы балалардағы сөйлеу бұзылыстарын диагностикалаудың перспективалық шешімін ұсынады. ML қосымшасын ата-аналар мен логопедтер үйде сөйлеу бұзылыстарын ерте диагностикалау үшін қолдана алады. Қолданба баланың жұмысына негізделген жақсарту ұсыныстары мен жеке логопедиялық жаттығуларды ұсына отырып, кері байланыс береді. Сөйлеу бұзылыстарын диагностикалау үшін қолжетімді құралдарды әзірлеу балалардың қарым-қатынас дағдыларын және жалпы дамуын жақсартуға көмектеседі.

Пайдаланылған әдебиеттер тізімі:

1. Dovepress (2023). Сөйлеу бұзылыстарын диагностикалау мен емдеудегі машиналық оқытудың рөлін зерттеу. Dovepress ғылыми журналы. Retrieved from [<https://www.dovepress.com>].
2. S. K. Kumar, L. J. Johnson, & M. T. Roberts (2019). Сөйлеу патологиясына арналған машиналық оқыту тәсілдері. PubMed. Retrieved from [<https://pubmed.ncbi.nlm.nih.gov/31555764/>].
3. Қайырбеков, А.Т., & Мұқанова, Л.С. (2022). Сөйлеу бұзылыстарын диагностикалау және машиналық оқыту тәсілдері. ҚазҰПУ «Педагогика және психология» журналы. Retrieved from [<https://journal-pedpsy.kaznpu.kz>].
4. Айтқожина, Г.М., & Тұрсынбай, Б.Ш. (2022). Ерекше қажеттіліктері бар балаларға қашықтықтан логопедиялық көмек көрсету. ҚазҰУ «Педагогика ғылымдары» журналы. Retrieved from [<https://bulletin-pedagogic-sc.kaznu.kz>].
5. SpeechPathology.com (2023). Жасанды интеллект пен логопедиялық терапия: заманауи тәсілдер. Retrieved from [<https://www.speechpathology.com>].
6. American Speech-Language-Hearing Association (ASHA) (2022). Сөйлеу бұзылыстарын диагностикалаудағы инновациялық әдістер. Retrieved from [<https://www.asha.org>].

Сравнительный анализ методов CPM и PERT для управления проектами

Бимбетов Б.М.

*Казахский Национальный Университет имени аль-Фараби, магистрант 2 курса
E-mail: beimbik-00@mail.ru*

Сетевой анализ – это метод планирования работ проектного характера. Этот метод применим для составления календарного плана выполнения операций. С помощью методов сетевого анализа мы можем определить размеры экономии времени или денежных средств, а также то, выполнение каких операций нельзя отсрочить, не задержав при этом срок выполнения проекта в целом.

Анализ проекта осуществляется в три этапа:

1. Разбиение проекта на ряд отдельных работ (или операций).
2. Оценка продолжительности выполнения каждой операции.
3. Оценка потребностей каждой операции в ресурсах. Пересмотр плана выполнения операции.

Метод критического пути (Critical Path Method, CPM) – это метод сетевого планирования и управления проектами, который помогает определить минимальное время завершения проекта, выявляя последовательность задач, критически влияющих на его продолжительность. Сначала составляется список входящих в него операций. После проект представляется в виде графа. Наиболее широкие в применении это вершинные и стрелочные графы. Мы будем использовать вершинный граф, так как он более подходящий. В этом типе сетевых графов операции представлены узлами графа, а стрелками изображаются их взаимосвязи (Рис.1).



Узел состоит из:

Раннее начало (ES) – самое раннее время начало задачи.
Раннее завершение (EF) – самое раннее время окончания.

Позднее начало (LS) – самое позднее время начала без увеличения общей длительности проекта.

Позднее завершение (LF) – самое позднее время окончания задачи без задержки проекта.

Запас времени (Float) – задержка времени без увеличения общего времени проекта

Рисунок 1 - Узел графа

Формулы для расчетов:

- $EF=ES+D$ (где D – длительность задачи).
- ES следующей задачи = $\max(EF)$ предшествующих задач.
- $LS=LF-D$.
- $Float=LS-ES$ или $Float=LF-EF$.

Определение критического пути.

Критический путь – это самая длинная последовательность зависимых задач без запаса времени ($Float = 0$), то есть $ES = LS$ и $EF = LF$. Если задержать любую из критических задач, проект сдвинется. Для того чтобы найти общую продолжительность выполнения проекта, нужно определить продолжительность критического пути.

Метод PERT (Program Evaluation and Review Technique) — это метод сетевого анализа, используемый для планирования и управления сложными проектами с неопределённостью во времени выполнения задач. Он учитывает неопределенность за счет трех оценок времени: оптимистичное (O), наиболее вероятное (M) и пессимистичное (P)

Рассчитывается ожидаемое время выполнения:

$$T_E = \frac{O + 4M + P}{6}$$

Использует стандартное отклонение:

$$\sigma = \frac{P - O}{6}$$

Определяет вероятность завершения проекта в срок с помощью Z-оценки.

$$Z = \frac{D - T_E \text{ проекта}}{\sigma \text{ проекта}}$$

Для примера возьмем задачу по выполнению определенных работ
Технология выполнения работ приведена в таблице.

Операция	Предшествующие операции	Стандартное время, дней	Стандартная стоимость, \$	Критическое время, дней	Критическая стоимость, \$
A	-	13	1350	8	2100
B	-	10	850	8	1200
C	A	8	700	4	1000
D	A,B	8	1300	5	1800
E	B,C	19	1450	16	1850
F	C,D	12	1450	10	1900
G	D,E	14	1350	11	1975
H	F	6	550	4	850
K	H,G	5	550	4	800
Всего:			8150		10275

Стоимость строительной площадки, составляет 130\$ в день.

Пример расчета CPM:

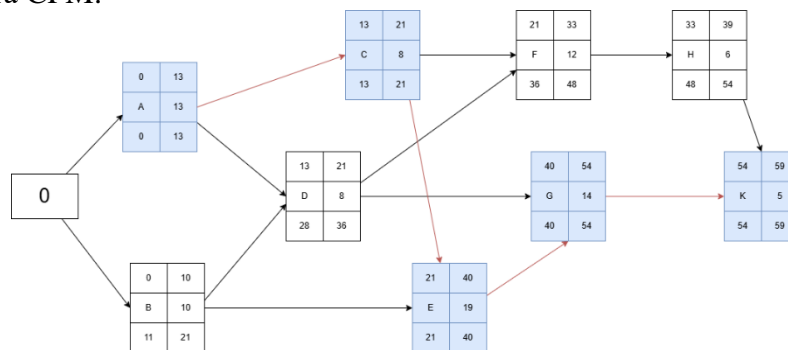


Рисунок 2 - Стандартный случай.

Критический путь для стандартного случая: A → C → E → G → K. Минимальное время выполнения: 59 дней. Общий расход составляет: стандартный случай - 17120\$ (Рис.2).

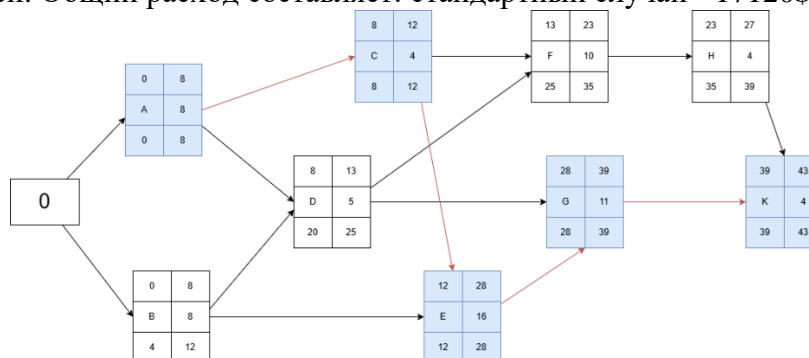


Рисунок 3 - Критический случай.

Критический путь для критического случая: A → C → E → G → K. Минимальное время выполнения: 43 дня. Общий расход составляет: критический случай - 19605\$ (Рис.3).

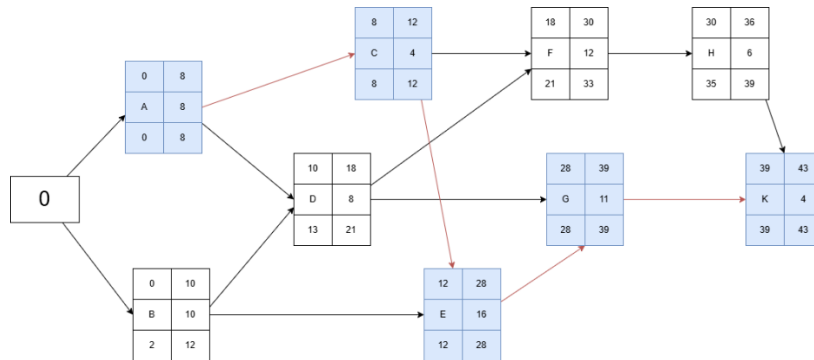


Рисунок 4 - Оптимизированный случай.

Критический путь при оптимизации: $A \rightarrow C \rightarrow E \rightarrow G \rightarrow K$. При оптимизации минимальный срок остается 43 дня, общий расход уменьшается до 17465\$. То есть экономим 9 дней, но дополнительно расходуем 345\$ (Рис.4)

Пример расчета PERT методом:

Высчитываем продолжительность для каждой операции по формуле: $T_{ож} = (T_{пис} + 4 * T_{вер} + T_{опт}) / 6$, где $T_{вер} = (T_{пис} + T_{опт}) / 2$ и высчитываем их стоимость по формуле: $C_{ож} = (C_{ст} + C_{кр}) / 2$

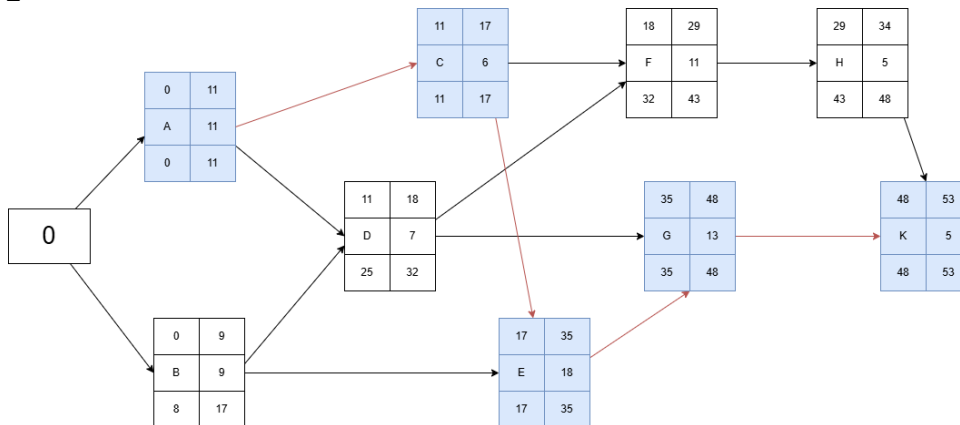


Рисунок 5 - Оптимизированный случай для метода PERT.

Критический путь при оптимизации для метода PERT: $A \rightarrow C \rightarrow E \rightarrow G \rightarrow K$. Минимальное время выполнения: 53 дня. Общий расход составляет: 18402.5\$. При оптимизации минимальный срок остается 53 дня, общий расход уменьшается до 17602.5\$. То есть экономим 6 дней, но дополнительно расходуем 482\$ (Рис.5).

В данном примере критический путь для обоих методов оказался одинаковым ($A \rightarrow C \rightarrow E \rightarrow G \rightarrow K$), но СРМ показал минимальный срок 43 дня и общий расход 17465\$, когда метод PERT: 53 дня и 17602.5\$. Исходя из этого метод СРМ показал себя лучше – сэкономлено больше дней (9 дней против 6) и меньше затрат (345\$ против 482\$). Метод PERT мощный инструмент для оценки сроков сложных проектов с неопределенными задачами, но в данном случае мы получили более благоприятные результаты используя метод СРМ. Как мы видим метод СРМ эффективнее, когда сроки известны и предсказуемы.

Список используемой литературы:

1. Мурзабеков З.Н., Системный анализ и задачи линейного программирования. - Алматы: АТУ, 2009. – 177 с.
2. Зайцев М.Г., Варюхин С.Е. Методы оптимизации управления и принятия решений, 2008. – 278 с.

Исследование и разработка интеллектуальной вопросно-ответной системы на основе семантических подходов для государственного языка в сфере законодательства Республики Казахстан

Даулет Е.А.

Казахский национальный университет им. Эл-Фараби, магистр 2 курс

Email: ye.daulet@globerce.capital

Рахимова Д.Р.

1. Введение. В условиях цифровизации правовой сферы и роста объёма нормативно-правовых документов, по причине обширности предоставляемой информации, вследствие возникает необходимость в разработке специализированных систем, способных обеспечивать быстрый и точный доступ к информации. Развитие же технологий обработки естественного языка (Natural Language Processing, NLP) и искусственного интеллекта открывает так нужные новые возможности для автоматизации правовой деятельности. Особенно актуальным является создание интеллектуальных систем, способных не только осуществлять поиск по документам, но и отвечать на конкретные вопросы пользователей, опираясь на семантическое содержание текстов. Для казахского языка, обладающего своей морфологической и синтаксической спецификой, задача представляется особенно сложной по причине отсутствия целевой базы.

2. Обзор литературы и существующих подходов. На сегодняшний день в мировой практике широко применяются методы семантического анализа для построения систем автоматизированного ответа на вопросы. Такие системы часто базируются на комбинации статистических моделей и онтологических баз знаний, к примеру:

- **Методы распределённого представления слов (Word Embeddings):** применение моделей, таких как Word2Vec или GloVe, для выявления семантической близости между терминами.

- **Онтологические модели и семантические сети:** создание специализированных онтологий для правовой области позволяет структурировать знания и обеспечить контекстуальную интерпретацию терминологии.

- **Гибридные системы:** сочетание статистических методов и правил, основанных на семантических моделях, обеспечивает баланс между универсальностью и точностью..

3. Методология разработки системы. Разработка интеллектуальной вопросно-ответной предполагает реализацию следующих взаимосвязанных модулей:

3.1. Предобработка и нормализация текста. Первоначальным этапом является лингвистическая нормализация входных запросов и документов законодательства.

3.2. Семантический анализ запроса. На основе нормализованного текста реализуется модуль семантического разбора, включающий:

- **Лексический анализ:** выделение ключевых терминов и понятий, характерных для правовой сферы.

- **Синтаксический разбор:** анализ структуры предложения для определения логических связей между сущностями.

- **Семантическое представление:** применение методов распределённого представления слов, адаптированных под казахский язык, с последующим сопоставлением с элементами доменной онтологии.

3.3. Построение доменной онтологии. Онтология включает понятия, такие как «закон», «регламент», «судебная практика», а также специфические правовые термины, используемые в казахском законодательстве. Интеграция онтологии с модулем семантического анализа позволяет системе проводить контекстуальную интерпретацию запроса.

3.4. Модуль поиска и ранжирования ответов. На основании семантического представления запроса производится поиск релевантной информации в базе данных

законодательных документов.

3.5. Генерация и представление ответа. Заключительным этапом является формирование ответа на основе найденной информации. В случае обнаружения нескольких релевантных источников система предлагает пользователю краткое резюме с указанием ссылок на первоисточники.

4. Экспериментальная оценка и результаты. Результаты предварительного тестирования продемонстрировали следующие показатели:

- **Точность распознавания запроса:** 87–90 % при корректной нормализации и выделении ключевых терминов.

- **Релевантность найденных ответов:** в 80 % случаев система успешно сопоставляла запрос с соответствующими законодательными документами.

- **Время обработки запроса:** среднее время отклика не превышало 1,5 секунд, что свидетельствует о возможности использования системы в режиме реального времени.

Несмотря на положительные результаты, проведённая апробация выявила ряд проблем, связанных с неоднозначностью терминологии и сложностью синтаксической структуры казахского языка. В частности, необходимость более глубокой интеграции локальных лингвистических особенностей остаётся актуальной задачей для последующих исследований.

5. Заключение. Предложенная архитектура интеллектуальной вопросно-ответной системы на основе семантических подходов демонстрирует потенциал применения современных методов NLP для решения задач правового. В дальнейшем планируется расширение функционала системы, интеграция дополнительных источников правовой информации и совершенствование алгоритмов обработки естественного языка с учётом специфики казахской морфологии и синтаксиса. Дальнейшие исследования будут направлены на оптимизацию методов обучения моделей распределённого представления слов для казахского языка и разработку адаптивных механизмов обратной связи, позволяющих системе самостоятельно корректировать ошибки и улучшать качество ответов. Такой подход имеет высокую практическую значимость для правоприменительной практики, а так как базой для создания является мульти-языковая платформа.

Список использованной литературы:

1. Иванов И. И., Петров П. П. «Методы семантического анализа в информационных системах». – М.: Издательство «Наука», 2018.
2. Ахметов А. К., Султанова Н. Р. «Обработка естественного языка для казахского языка: проблемы и решения». – Алматы: КазГУ, 2020.
3. Смирнова Е. А. «Онтологические подходы в правовых информационных системах». – Журнал «Информационные технологии», 2019, №4, с. 45–59.

Жүрек ауруларын болжау мақсатында веб-қосымшаны әзірлеу: Машиналық оқыту алгоритмдерін қолдану

Дилда И.Ж.

*Әл-Фараби атындағы Қазақ ұлттық университеті 4 курс студенті
e-mail: 37gan356@gmail.com*

Байкувеков М.Б.

Әл-Фараби атындағы Қазақ ұлттық университеті, аға оқытушы

Жүрек аурулары – әлемдегі өлім-жітімнің басты себептерінің бірі болып саналады. Бұл аурулардың алдын алу мен ерте анықтау денсаулық сақтау саласының басты міндеттерінің бірі [1]. Машиналық оқыту алгоритмдерін пайдалана отырып, жүрек ауруларының даму қаупін болжауға арналған веб-қосымша әзірлеу осы міндеттерді шешуге бағытталған тиімді әдіс болып табылады.

Бұл веб-қосымшада пайдаланушы өз денсаулық деректерін (мысалы, жас, жыныс, дене массасы индексі, холестерин деңгейі, қан қысымы және ауру тарихы) енгізеді. Содан кейін жүйе енгізілген ақпаратты талдап, жүрек-қан тамыр ауруларының даму қаупін нақты уақыт режимінде болжайды. Қолданылған алгоритмдер – логистикалық регрессия, кездейсоқ ормандар, градиенттік бустинг және нейрондық желілер.

Веб-қосымшаның жұмысы келесі кезеңдерді қамтиды: деректер жинау, деректерді өңдеу, модельді оқыту және тестілеу, пайдаланушыға нәтижелерді визуализациялау. Қосымша қолданушыға оның денсаулық жағдайына байланысты жеке профилактикалық ұсыныстар бере алады.

Жүргізілген зерттеулерге сәйкес, кездейсоқ ормандар және градиенттік бустинг модельдері 90%-ға жуық дәлдік көрсетті. Бұл нәтижелер аталған модельдердің медициналық деректерді талдауда тиімді екенін дәлелдейді [2].

Қорытындылай келе, веб-қосымшаның әзірленуі жүрек ауруларының алдын алу және ерте диагностикалау үшін маңызды құрал болып табылады. Келешекте қосымша мүмкіндіктерді кеңейту және алгоритмдердің дәлдігін арттыру жоспарлануда.

Пайдаланылған әдебиеттер тізімі:

1. Дүниежүзілік денсаулық сақтау ұйымы. "Жүрек-қан тамыр аурулары (ЖҚА)." [Онлайн]. Қол жетімді: [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))

2. Goldberger AL, т.б. "PhysioBank, PhysioToolkit, және PhysioNet: Күрделі физиологиялық сигналдарға арналған жаңа зерттеу ресурстары." *Circulation*, 101(23), e215-e220, 2000.

ІТ ӨНІМДЕРДІ ЖАСАУШЫ ЖОБАЛЫҚ ТОПТЫ БАСҚАРУДЫҢ АҚПАРАТТЫҚ ЖҮЙЕСІН ЖАСАУ

Еркінбаева Б.Е.

*Әл-Фараби атындағы Қазақ ұлттық университеті,
Ақпараттық жүйелер мамандығының 4 курс студенті
e-mail: erkinbaevabalym04@gmail.com*

Байшоланова К.С.

*Әл-Фараби атындағы Қазақ Ұлттық университеті,
Ақпараттық жүйелер кафедрасының доценті, э.ғ.д.*

Қазіргі заманғы ІТ саласында өнімдерді әзірлеу күрделі, көп сатылы процесс болып табылады. Жобалық топтың тиімді басқарылуы өнімнің сапасы, уақытында жеткізілуі және ресурстардың оңтайлы пайдаланылуына тікелей әсер етеді. Осы орайда, ІТ өнімдерді жасаушы жобалық топты басқарудың ақпараттық жүйесін енгізу – табысты жобаларды жүзеге асырудың негізгі факторларының бірі болып табылады.

ІТ өнімдерді жасаушы жобалық топтың басқаруын автоматтандыру – команданың үйлесімді жұмысы мен жобалардың тиімді орындалуын қамтамасыз етудің заманауи тәсілі. Бұл жүйе топ мүшелерінің тиімді коммуникациясын, тапсырмаларды нақты уақыт режимінде бақылауды және ресурстарды оңтайлы пайдалануды қамтамасыз етеді. Жобаның орындалу уақытын қысқарту мен өнімділікті арттыру мақсатында автоматтандырылған басқару шешімдері ерекше маңызға ие.

Жүйенің архитектурасы клиенттік қосымша, серверлік логика және деректер базасынан тұрады. Клиенттік қосымша WinForms немесе WPF негізінде әзірленіп, қолданушыларға интуитивті интерфейс ұсынады. Серверлік бөлік Python Django фреймворкы негізінде әзірленіп, RESTful API арқылы бизнес-логиканы жүзеге асырады, сонымен қатар қолданушылардың аутентификациясы мен авторизациясын басқарады. Деректер базасы ретінде Microsoft SQL Server таңдалғандықтан, жүйе жоғары өнімділік пен қауіпсіздікті қамтамасыз етеді.

Практикалық іске асыру барысында топтық жұмысты автоматтандыру мақсатында бірнеше модульдер әзірленеді. Тапсырмалар мен жобаларды басқару модулі жобаларды жоспарлау, тапсырмаларды тағайындау және мәртебелерін бақылауды жүзеге асырады. Сонымен қатар, коммуникация және есеп беру модульдері топ мүшелеріне өзара ақпарат алмасуды жеңілдетіп, жобаның орындалу барысын визуализациялайды. Python Django қолдану серверлік логиканы тез әрі тиімді іске асырып, жүйенің модульдерін біріктіру мен тестілеу процесін оңайлатады.

Жүйені енгізу нәтижесінде ІТ өнімдерді жасаушы жобалық топтың жұмыс процестері айтарлықтай жетілдіріледі. Автоматтандырылған басқару шешімдері ресурстарды тиімді пайдалануға, жобаларды уақытында аяқтауға және команданың жұмыс тиімділігін арттыруға септігін тигізеді. Болашақта жүйеге қосымша функциялар енгізу арқылы оның функционалдығын кеңейту жоспарланып отыр.

Мысалы, тапсырмалар модулінде жүйе келесі функцияларды атқарады:

1. Тапсырма қосу, өңдеу және жою;
2. Тапсырманың мәртебесін (күтілуде, орындалуда, орындалды) автоматты түрде өзгерту;
3. Пайдаланушыға тек өзіне тағайындалған тапсырмаларды көрсету;
4. Әрбір өзгерісті журналға жазу арқылы тарихты бақылау. Бұл үшін SQL Server-дің сақталатын процедуралары мен триггерлері кеңінен қолданылады.

ІТ өнімдерді жасаушы жобалық топты басқарудың ақпараттық жүйесін жасау қазіргі заманғы ІТ жобаларын басқарудың қажеттіліктерін толық қамтамасыз етеді. Жүйе топтың үйлесімді жұмысын, тапсырмаларды тиімді орындауды, ресурстарды оңтайлы пайдалануды

және нәтижелерді нақты уақыт режимінде бақылауды қамтамасыз етеді. Жүйені әзірлеу процесі ІТ жобаларды басқаруды автоматтандыруға, командалық жұмысты жеңілдетуге және жобалардың сапалы жүзеге асырылуын қамтамасыз етуге бағытталған маңызды қадам болып табылады.

Пайдаланылған әдебиеттер тізімі:

1. Основы управления проектами : Л. Н. Боронина, З. В. Сенук ; М-во образования и науки Рос. Федерации, Урал. федер. ун-т. – Екатеринбург : Изд-во Урал. ун-та, 2015. — 112 с.
2. Sommerville, I. (2016). Software Engineering (10th ed.). Pearson.
3. Информационная система управления проектами (ИСУП) // МАНАМВА.COM: сервис вопросов и ответов для специалистов в области менеджмента (дата обращения: 05.03.2021)
4. Django Software Foundation. (2023). Django Documentation.
5. Илюшечкин В. М. Основы использования и проектирования баз данных учебник для СПО / В. М. Илюшечкин. – М. : Издательство Юрайт, 2019. – 213 с. – Серия : Профессиональное образование

Кеуекті орталарды ескере отырып, ауаның ластануын болжау

Жұмағалиқызы Н.

*Әл-Фараби атындағы Қазақ Ұлттық университеті,
Компьютерлік ғылымдар мамандығының 4 курс студенті*

Омарова П.Т.

*Әл-Фараби атындағы Қазақ Ұлттық университеті,
Компьютерлік ғылымдар кафедрасының аға оқытушысы, PhD*

Қазіргі таңда ауа ластануы – маңызды экологиялық мәселелердің бірі. Өнеркәсіптік өндірістің қарқынды дамуы, көлік санының көбеюі және урбанизация атмосфералық ауа сапасына айтарлықтай әсер етуде. Ауаның ластануы адам денсаулығына және қоршаған ортаға кері әсерін тигізіп, түрлі экологиялық мәселелерді тудырады. Әсіресе, урбанизацияланған аймақтарда ауа сапасының төмендеуі тұрғындардың тыныс алу жүйесіне кері әсерін тигізіп, аллергиялық реакциялар, өкпе аурулары және жүрек-қан тамырлары жүйесінің бұзылуына себеп болуы мүмкін. Осыған байланысты, ауа құрамындағы ластаушы заттардың, әсіресе SO₂, NO₂, CO және O₃ концентрацияларын дәл болжау үлкен маңызға ие. Ластаушы заттардың таралуын тиімді болжау үшін заманауи әдістерді қолдану қажет.

Бұл зерттеудің мақсаты – машиналық оқыту (ML) және сандық модельдеу (CFD) әдістерін қолдана отырып, кеуекті орталарды ескеретін ауа ластануын болжау жүйесін әзірлеу. Машиналық оқыту әдістері арқылы атмосферадағы SO₂, NO₂, CO және O₃ концентрацияларын болжауға бағытталған модельдер құрылады. Бұл модельдер ауа сапасына әсер ететін негізгі факторларды анықтап, олардың болашақтағы өзгерістерін бағалауға мүмкіндік береді. Деректерді алдын ала өңдеу кезеңінде мәліметтер қалыпқа келтіріліп, жетіспейтін мәндер толықтырылады. Ерекшеліктерді іріктеу әдістері арқылы ауа сапасына әсер ететін негізгі факторлар анықталады. Сонымен қатар, болжам сапасын арттыру үшін бірнеше машиналық оқыту алгоритмдері салыстырылып, олардың тиімділігі бағаланады.

Ауа динамикасын тереңірек талдау үшін CFD әдістері қолданылады. Сандық модельдеу ластаушы заттардың таралуын зерттеуге және қалалық инфрақұрылымның ауа сапасына ықпалын бағалауға мүмкіндік береді. CFD көмегімен ауаның қозғалыс ерекшеліктерін зерттеу арқылы атмосфералық процестерді егжей-тегжейлі сипаттауға болады. Осылайша, машиналық оқыту әдістері арқылы алынған болжамдар CFD модельдерімен толықтырылады. Бұл зерттеу тәсілі ауа сапасын болжаудың дәлдігін арттырып, қалалардағы ластану деңгейін төмендету бойынша ғылыми негізделген шешімдер қабылдауға мүмкіндік береді. Сонымен қатар, кеуекті орталарды есепке алу арқылы модельдердің дәлдігін арттыру көзделуде. Кеуекті орталар ластаушы заттардың сіңірілуі мен таралуына айтарлықтай әсер етеді, сондықтан оларды зерттеу экологиялық мониторинг сапасын жақсартуға ықпал етеді.

Зерттеу нәтижесінде ауа сапасын болжаудың тиімді модельдері ұсынылады. Алынған деректер негізінде урбанизацияның әсерін азайтуға бағытталған экологиялық шараларды жасауға болады. Бұл модельдер қалалық жоспарлауда, өнеркәсіптік аймақтарды орналастыруда және қоршаған ортаны қорғау стратегияларында қолдануға мүмкіндік береді. Сонымен қатар, нақты уақыт режимінде ауа сапасын болжау жүйесін жетілдіру перспективасы қарастырылады. Қалалардағы ауа сапасын басқару үшін жергілікті билік пен экологиялық ұйымдарға машиналық оқыту және сандық модельдеу әдістерінің нәтижелерін енгізу ұсынылады. Бұл тәсіл қала тұрғындарының өмір сүру сапасын жақсартуға, ауаның ластануын азайтуға және тұрақты даму мақсаттарына жетуге көмектеседі.

Жалпы, зерттеудің жаңашылдығы – кеуекті орталарды ескере отырып, машиналық оқыту мен сандық модельдеуді біріктіру арқылы ауа ластануын болжау әдістерін жетілдіру. Бұл тәсіл экологиялық мониторингті дамытуға және урбанизацияның қоршаған ортаға әсерін азайтуға маңызды үлес қосады. Сонымен қатар, алынған нәтижелер негізінде ауа ластануын азайту стратегияларын әзірлеу мүмкіндігі қарастырылады. Осылайша, ғылыми зерттеулер мен

технологиялық шешімдердің үйлесуі экологиялық тұрақтылықты қамтамасыз етуге көмектеседі. Зерттеу нәтижелері урбанизацияланған аймақтарда экологиялық мониторинг сапасын арттыруға, ауа сапасын басқарудың тиімді стратегияларын әзірлеуге және қоршаған ортаға теріс әсерді азайтуға мүмкіндік береді. Бұл әдістерді қолдану болашақта тұрақты даму мақсаттарына жетуге және тұрғындардың өмір сүру сапасын жақсартуға көмектеседі. Осылайша, машиналық оқыту мен сандық модельдеуді біріктіру арқылы ауа ластануын болжау әдістері жетілдірілді. Алынған нәтижелер экологиялық саясатты қалыптастыруда және қалалық жоспарлауда қолдануға жарамды. Бұл тәсіл қалалардағы ауаның ластануын азайтуға, халықтың денсаулығын қорғауға және жалпы экологиялық жағдайды жақсартуға ықпал етеді.

Пайдаланылған әдебиеттер тізімі:

1. Seinfeld, J. H., & Pandis, S. N. (2016). *Atmospheric Chemistry and Physics: From Air Pollution to Climate Change*. John Wiley & Sons.
2. Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
3. Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer.
4. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
5. Gupta, P., Christopher, S. A., Wang, J., Gehrig, R., Lee, Y., & Kumar, N. (2006). Satellite remote sensing of particulate matter and air quality assessment over global cities. *Atmospheric Environment*, 40(30), 5880-5892.
6. Holmes, N. S., & Morawska, L. (2006). A review of dispersion modeling and its application to the dispersion of particles: An overview of different dispersion models available. *Atmospheric Environment*, 40(30), 5902-5928.
7. Zhang, Y., & Rao, S. T. (1999). The role of meteorology in air pollution modeling. *Journal of the Air & Waste Management Association*, 49(1), 16-26.
8. Karagulian, F., Barbieri, M., Kotsev, A., & Laguna, M. (2019). Review of the performance of low-cost sensors for air quality monitoring. *Atmospheric Environment*, 213, 579-593.
9. Fan, J., Wang, Y., Wang, X., Liu, P., & Zhang, R. (2020). Machine learning models for air quality prediction. *Atmospheric Pollution Research*, 11(12), 2076-2085.
10. Fletcher, T. (2012). *Machine Learning for Hackers*. O'Reilly Media.

ӘЛЕУМЕТТІК ЖЕЛІЛЕРДЕГІ СУИЦИДТІК МІНЕЗ-ҚҰЛЫҚ БЕЛГІЛЕРІ БАР МӘТІНДЕРДІ ТАЛДАУ ЖӘНЕ ЖІКТЕУДІҢ ҚОСЫМШАСЫН ҚҰРУ

Жақсымбет А.Т., Аскапова М.К.

*Әл-Фараби атындағы Қазақ Ұлттық Университеті,
«Ақпараттық жүйелер» мамандығының 4-курс студенттері
zhaksymbet03@gmail.com*

Кәрібаева А.С.

Әл-Фараби атындағы Қазақ Ұлттық Университеті, PhD, доцент м.а.

Дүниежүзілік денсаулық сақтау ұйымының (ДДСҰ) 2018 жылғы мәліметтері бойынша, Қазақстан 100 мың тұрғынға шаққанда 23,8 суицид көрсеткішімен әлемде 10-орында тұрған және белгілеген шекті шектен (100 мың тұрғынға шаққанда 20 жағдай) асып, бұл ДДҰ-ны Қазақстанды табиғи емес себептерден болатын өлім-жітімнің «критикалық деңгейі» аталған елдердің қатарына қосуға негіз болды [1]. Суицидтік жағдайлар Қазақстанда да белең алып отырған мәселе болғандықтан, оның алдын алу бойынша әр тараптан шара қолдану аса маңызды. Осындай шаралардың бірі ретінде кейбір пайдаланушылардың әлеуметтік желілерде өздерінің ішкі күйзелістері мен эмоцияларын ашық бөлісе отырып, суицидтік сипаттағы қалдырған жазбаларын автоматты түрде анықтау болып табылады. Бұл қауіпті дер кезінде айқындап, шұғыл әрекет етуге мүмкіндік береді.

Бұл зерттеу қазақ және орыс тілдерінде жазылған әлеуметтік желі посттарын талдау және жіктеу жүйесін құруға бағытталған. Оның маңыздылығы – қазақ тілді контентті талдау мүмкіндігін кеңейтуде. Қазақстанда адамдар көбіне қазақша сөйлеп, бірақ жазба тілінде орысша сөздерді араластырып қолданады. Сондықтан, жасалған жүйе осы ерекшелікті ескере отырып әзірленді. Датасет қазақ тіліндегі мәтіндермен толықтырылып, аралас тілде жазылған посттарды да талдай алатындай етіп бейімделді. Бұл жүйе Қазақстандағы суицидтің алдын алу шараларына елеулі үлес қоса алады.

Суицидтік сипаттағы посттарды анықтау үшін машиналық оқыту әдістері тиімді құрал бола алады. Vasquez & Lungu (2020) зерттеуінде машиналық оқыту модельдерінің суицид қаупін болжауда жоғары дәлдік көрсеткені айтылған [2]. Зерттеу барысында машиналық оқыту әдістері, оның ішінде логистикалық регрессия, шешім ағаштары және нейрондық желілер пайдаланылды. Деректер жиынтығы ретінде әлеуметтік желілерден алынған ашық посттар негізге алынды. Алдын ала өңдеу кезеңінде мәтіндер қазақ және орыс тілдерінің ерекшеліктеріне бейімделіп, токенизация, лемматизация және стоп-сөздерді сүзу секілді процедуралар орындалды. Суицидтік мазмұнды анықтау үшін TF-IDF, Word2Vec модельдері қолданылды. Жасалған жүйе тестілік деректер жиынтығында жоғары тиімділік көрсетті, бұл оның қазақ тілді контентті өңдеуге бейімделгенін дәлелдейді. Сонымен қатар, жүйе психологиялық қызметтермен біріктіріліп, қауіпті жағдайларды автоматты түрде анықтау және тиісті органдарға хабарлау үшін қолданылуы мүмкін.

Қорытындылай келе, әлеуметтік желілердегі суицидтік мазмұндағы посттарды талдау және жіктеу жүйесі жасалды. Ол қазақ және аралас тілде жазылған мәтіндерді тиімді өңдей алады. Бұл зерттеу Қазақстанда қазақ тілді ақпараттық кеңістікте суицидтің алдын алу бойынша технологиялық шешімдерді дамытуға ықпал етеді.

Пайдаланылған әдебиеттер тізімі:

1. World Health Organization. (2018). Suicide worldwide in 2018: Global Health Estimates. WHO.
2. Vasquez, M., & Lungu, A. (2020). Machine Learning Approaches for Suicide Risk Prediction. Journal of AI Research, 45(2), 112-130.

“JAVA ПРОГРАММАЛАУ ТІЛІ” ПӘНІНЕ АРНАЛҒАН ЖАППАЙ АШЫҚ ОНЛАЙН КУРСЫН ЖАСАУ

Жаппарова Е.Ғ.

Әл-Фараби атындағы Қазақ ұлттық университеті, 4 курс студенті

E-mail: zhapparovaenlik@gmail.com

Бурибаев Б.Б.

Әл-Фараби атындағы Қазақ ұлттық университетінің т.ғ.к., профессор м.а.

Қашықтан білім берудің заманауи түрі – бұл **жаппай ашық олайн курстарын (ЖАОК)** жасау болып табылады. Білім беру саласындағы қажеттіліктерді қанағаттандырудың осындай жаңа тәсілі – жаһандық білім беру саласындағы ең танымал және жеңіл қол жеткізуге болатын үрдістердің бірі. **Ол әр адамға өзіне** ыңғайлы уақытта және өз қарқынымен кез-келген тақырыпты немесе пәндерді оқуды толығымен жүзеге асыру мүмкіндігін береді. ЖАОК ортасы дайындық курсы өтіп, емтихандарға дайындалу, біліктілік дәрежесін арттыру мақсатында немесе білім саласында жай қызығушылықты қанағаттандыруда да өзінің зор үлесін қосып келеді.

ЖАОК курстары студенттер мен қызығушылық танытушылар үшін қосымша кәсіби құзырет алудың маңызды қайнар көзі және ол IT-технологиялар арқылы білім беру қызметінің спектрін арттырады. Қазіргі таңда қазақстандық білім беру жаңа инновациялық мүмкіндіктерді иеленуде. Жоғары білім беру саласы сарапшылары ЖАОК-ты 2028 жылға дейінгі білім беруді дамытудың 30 перспективалық бағытының айрықша жолы деп атап көрсетті [1].

Жаппай ашық олайн курстары қашықтан оқыту әдістемелерін өңдеу барысында қалыптасқан көптеген педагогикалық құралдарды пайдаланады, бірақ одан әр жекелеген қатысушы студенттердің санымен және бағдарламаның мазмұнының ашықтылығын қамтамасыз ететін құрылымдарымен ерекшеленеді. Көбіне жаппай ашық олайн курстары қашықтан оқыту бағдарламасы бойынша таратылған бейне дәрістерден, олайн оқудан және тапсырмалар жинағынан, студенттерге қауымдастық құруға әрі бірін-бірі бағалауға мүмкіндік беретін олайн желілік форумдар үшін жасалған пайдаланушылардың интерактивті форумдарынан тұрады.

Бұл ортаны әлемдік ғаламторға қол жеткізе алатын әрбір адам кез келген мерзімде тегін пайдалана алады, мысалы, Стэнфорд, Гарвард ғылыми орталықтарының, Массачусет технологиялық институтының, Джон Хопкинс университетінің, Торонто, Мельбурн жоғары оқу орындарының [2] және де басқа көптеген белгілі білім ордаларының дәрістерін оқып үйренуге болады. Өз білімін шыңдаушылар дәрістерді тындап қана қоймай, сол арқылы емтихан тапсырып, сертификат алуға толық мүмкіндік алады, көптеген мекемелер үшін осындай сертификаттар жұмысқа алу кезінде адамның біліктілік деңгейін көрсетуге жарамды құжат болып есептеледі [3].

Біз дайындап жатқан программалау пәнін қамтитын мемлекеттік тілдегі ЖАОК курсы жалпы білім беретін қашықтан оқыту жүйесіне қарағанда, «интеграцияланған» қасиеті бар ортақ жүйе болып саналады. Бұл қасиеттің оқыту процесінің қатысушылары мен элементтеріне қатысты бірсыпыра артықшылықтары бар, олар:

- бірнеше ЖОО біріге отырып, ортақтастырылған бір білім беру порталын құрады;
- мұндағы білім беру бағдарламасының мазмұнын жасауға осы ЖОО-лардың барлық мұғалімдері мен мамандары араласа алады;
- бұл порталдан білім алуға көптеген талапкерлердің қол жеткізу мүмкіндігі болады; Осылай ұйымдастырылған білім беру мазмұнын, яғни контентін осы саланың мұғалімдері магистранттармен (студенттермен де) біріге отырып жасап шығарады.

Ашық олайн-платформа жобасы ҚР-ның 2011-2020 жылдарға арналған білім беруді дамыту мемлекеттік бағдарламасын және e-learning электрондық білім беру жүйесін енгізуді жүзеге асыруға бағытталған. Ол апробациядан сәтті өтіп, бүгінгі таңда тұтынушыларға қазақстандық университеттердің сапалы олайн-курстарын ұсынууда. Қазіргі таңда қазақстандық

білім беру жаңа инновациялық мүмкіндіктерді иеленуде. Жоғары білім беру саласы сарапшылары ЖАОК-ты 2028 жылға дейінгі білім беруді дамытудың 30 перспективалық бағытының айрықша жолы деп атап көрсетті [3].

Біз ұсынып отырған «Java программалау тіліне арналған ЖАОК жасау» пәнін қамтитын курс – өндірістегі жас жұмысшыларға, программа жазуды үйренгісі келетін жандарға, жеткілікті түрде білім алмаған мамандарға арналып жазылған жаппай ашық онлайн оқыту курсы болып табылады. Оның мақсаты – курсты тыңдаушыларға программалау саласындағы білімді меңгерту және оның қыр-сырын үйрету.

Программалау бойынша ақпараттардың өте көп екендігі белгілі, сондықтан жаппай ашық онлайн-курсын ұйымдастыруды оқу-әдістемелік материалдарымен қамтамасыз етуден, атап айтқанда, оқу материалының мақсаты мен міндеттерін анықтаудан, оның тыңдаушыларының әртүрлі ерекшеліктері болатындығын ескеруден және тыңдаушылардың техникалық қамтамасыз етілу ерекшеліктері мен оқу материалдарының мақсатын ескеру арқылы әдістемені таңдаудан бастаған жөн. Программалау пәні бойынша жаппай ашық онлайнкурсын дайындау 2 кезеңге бөлінеді: дайындық кезеңі және құрастыру кезеңі. Дайындық кезеңінде негізгі материалдардың құрылымы жасалынады, модульдерге бөлінеді, мәтіндер өңделеді, курс бойынша бейнедәрістер дайындалады.

Ал дәрістің құрылымына келетін болсақ, курстың мазмұнын түсіндіретін 10-15 минуттық бейнелік көрініс фильміне бөлінген апталық дәрістердің бағдарламасы қажет етіледі. Алдыңғы қатарлы тәжірибелердің ұсынысы бойынша оқу процесінің ұзақтылығы 15 аптадан аспауы қажет, өйткені қатысушылар жалығып оқуды орта жолдан тастап кетуі мүмкін. Сонымен қатар әр аптаның тапсырмасы болуы керек, дәріс мәтіндері мен әдістемелік материалдар тыңдаушыларға қол жетімді болуы қажет. Сонымен курстың құрамында 15 дәріс, 15 практикалық сабақ және тест сұрақтары болады.

Жаппай ашық онлайн курстарындағы тағы бір мәселе – студенттердің жұмыстарын бағалау. Дәрістен кейін берілетін тапсырмаларды беретін уақытта алдымен қайта қарап, онлайн курсына бейімдеп құрастырылуы қажет.

Ондаған немесе одан да көп тапсырмаларды қолмен тексеру мүмкін емес, осы уақытта Coursera веб-сайты ұсынған тапсырмаларды өзі тексеретін бағдарламалардың шаблондарын өз мақсаттарымызға сәйкес жетілдіруіміз қажет. Coursera ортасында білімді бағалаудың екі әдісі қолданылып келеді: тест не болмаса студенттердің бірін-бірі тексеруі. Қорыта айтсақ, біздің дайындап жатқан жаппай ашық онлайн-курсымыз программалауды үйрету пәнін оқытуда заманауи ақпараттық-коммуникациялық технологияларды пайдалану арқылы білім беру деңгейін көтеруге арналған.

Осылай жүзеге асырылған онлайн-курс арқылы студенттер мен программалауды үйренгісі келетіндер Java тілін жүйелі түрде меңгеріп, практикалық дағдыларын дамытады. Онлайн курс программалау негіздерін терең түсінуге мүмкіндік береді және IT саласындағы білікті мамандардың санын арттыруға септігін тигізеді. Сондай-ақ, бұл курс бағдарламалауды қазақ тілінде үйренгісі келетіндер үшін қолжетімді ресурс болады. Онлайн білім беру процесі мен электрондық оқыту жүйесінің дамуы арқылы студенттер тиімді оқу тәжірибесін ала алады.

Java программалау тіліне арналған жаппай ашық онлайн курсты әзірлеу – білім беру саласындағы маңызды қадамдардың бірі. Бұл курс IT мамандарының біліктілігін арттыруға, өз бетінше білім алуға мүмкіндік беріп, Қазақстандағы цифрлық экономиканың дамуына үлес қосады. Сондықтан, осындай жобаларды іске асырудың маңыздылығы өте жоғары.

Пайдаланылған әдебиеттер тізімі:

1 "Қашықтықтан білім беру технологиялары бойынша оқу процесін ұйымдастыру қағидаларын бекіту туралы" Қазақстан Республикасы Білім және ғылым министрінің 2015 жылғы 20 наурыздағы № 137 бұйрығына өзгерістер мен толықтырулар енгізу туралы құжаты.

2 Бөрібаев Б., Мендібаев Е. Қашықтан оқыту – білім беру сапасын арттырудың тиімді құралы // «Білімді бағалаудың құзыретті бағдарлы жүйесі» - 44 ғылыми-әдістемелік конференция материалдары, 3 кітап, 2014 ж. 17-18 қаңтар: ҚазҰУ, 116-118 б.

3 Медеуов Е.Ө., Наурызова Н.Қ. Қашықтан оқытуды ұйымдастыру //ҚазҰПУ хабаршысы. – Физика-математика ғылымдар сериясы. – 2007. – № 2. – 172-174 бет.

АҚПАРАТТЫҚ ҚАУІПСІЗДІК САЛАСЫНДАҒЫ ТӘУЕКЕЛДЕРДІ ТАЛДАУ ЖӘНЕ БАСҚАРУ ҮШІН ПЛАТФОРМА ҚҰРУ

Жубанышева Г.Т.

Ақпараттық қауіпсіздік аудитінің 1-курс магистранты

Адилжанова С.А.

Әл-Фараби атындағы Қазақ ұлттық университеті, PhD, доцент м.а.

Аңдатпа: Бұл зерттеу цифрлық егіздер технологиясын ақпараттық қауіпсіздік саласындағы тәуекелдерді талдау және басқару үшін қолдануға бағытталған. Цифрлық егіздер өндіріс тиімділігін арттырғанымен, жаңа киберқауіптер мен осалдықтарды туындатады. Зерттеу барысында негізгі қауіптер анықталып, оларды азайтуға арналған технологиялық шешімдер ұсынылды, соның ішінде жасанды интеллект пен машиналық оқыту, киберқатерлерді автоматты түрде бейтараптандыру жүйелері, қауіпсіздікке негізделген архитектуралық дизайн, криптографиялық әдістер және блокчейн технологиясы. Ұсынылған математикалық модель қауіптерді болжау, анықтау және нейтрализациялау процестерін біріктіріп, ақпараттық қауіпсіздік жүйесінің тиімділігін арттыруға бағытталған.

Кілттік сөздер: Цифрлық егіздер, ақпараттық қауіпсіздік, тәуекелдерді басқару, жасанды интеллект, машиналық оқыту, киберқауіптер, шабуылдарды бейтараптандыру, криптография, блокчейн, қауіпсіздік архитектурасы.

Қазіргі уақытта цифрлық технологиялардың жедел дамуы мен «Индустрия 4.0» тұжырымдамасының кеңінен енгізілуі ақпараттық қауіпсіздік саласындағы тәуекелдерді басқарудың маңыздылығын арттырады. Әсіресе, цифрлық егіздер технологиясы өндірістік процестердің тиімділігін арттыруға ықпал еткенмен, жаңа киберқауіптер мен осалдықтардың пайда болуына әкеледі[1]. Бұл зерттеу цифрлық егіздер негізінде ақпараттық қауіпсіздік тәуекелдерін талдау және басқару үшін платформаны құруға бағытталған.

Осы тәуекелдерді азайту үшін жаңа технологиялық шешімдер ұсынылды, олардың ішінде:

- Жасанды интеллект (AI) және машиналық оқыту (ML) негізіндегі болжаулық талдау ақпараттық қауіпсіздік инциденттерін алдын ала анықтау және күдікті әрекеттерді ерте кезеңде болжау[2].

- Киберқатерлерді автоматты түрде нейтрализациялау жүйелері – honeypot технологияларын пайдаланып, шабуыл әрекеттерін зерттеу және оларға уақтылы жауап беру.

- Қауіпсіздікке негізделген архитектуралық дизайн (Security by Design) – платформа құрылымын бастапқы кезеңнен бастап қауіпсіздік талаптарына сәйкестендіру[3].

- Адаптивті қауіпсіздік жүйелері – динамикалық конфигурация арқылы қауіптерге бейімделетін қорғаныс шараларын қолдану.

- Криптографиялық технологияларды жетілдіру – деректерді қорғау үшін квантқа төзімді шифрлау әдістерін енгізу.

- Блокчейн технологиясын интеграциялау – деректердің өзгермейтіндігін қамтамасыз ету және платформаның тұтастығын сақтау[4].

Зерттеу нәтижелері цифрлық егіздерге тікелей қатысты киберқауіптерді автоматты нейтрализациялау әдістерін жетілдіру қажеттілігін көрсетті. Автоматты қорғаныс жүйелерінің тиімділігін арттыру үшін жасанды интеллект (AI) және машиналық оқыту (ML) негізінде шабуылдарды алдын ала болжау және әрекет ету алгоритмдерін дамыту ұсынылады[5]. Мұндай тәсілдер нейрондық желілер мен шешімдер ағаштары арқылы жиі кездесетін шабуыл түрлерін анықтауға және алдын алу шараларын жүзеге асыруға мүмкіндік береді.

Қауіп-қатерлерді болжау және оларды автоматты түрде нейтрализациялау жүйесінің математикалық моделі келесідей ұсынылады:

1. Қауіп-қатердің ықтималдығы:

$$P(C)=f(M,AI)$$

мұндағы:

C — қауіп-қатер түрі,

M — мониторинг жүйесі,

AI — жасанды интеллект арқылы деректерді өңдеу және талдау.

2. Нейтрализациялау шаралары:

$$N(C)=g(P,A,K)$$

мұндағы:

P — болжау нәтижелері,

N — қауіп-қатерді автоматты түрде жою жүйесі,

A — бейімделгіш қауіпсіздік жүйесі,

K — криптографиялық әдістер (деректердің құпиялылығын қорғау үшін).

3. Бейімделгіш қауіпсіздік жүйесінің динамикасы:

$$A=h(C,P,N)$$

мұндағы:

C — анықталған қауіп-қатерлер,

P — болжамдық талдау нәтижелері,

N — нейтрализациялау шаралары.

4. Жалпы қауіпсіздік деңгейінің интеграцияланған моделі:

$$S=P(C)+N(C)+A+D+K$$

мұнда:

S — жалпы қауіпсіздік деңгейі,

D — қауіпсіздікке негізделген архитектуралық дизайн,

K — криптографиялық әдістердің жиынтығы.

Бұл математикалық модель қауіп-қатерлерді анықтау, оларды болжау, нейтрализациялау және бейімделу процестерін біріктіру арқылы ақпараттық қауіпсіздік жүйесінің тиімділігін арттыруға бағытталған.

Зерттеу нәтижелері "Индустрия 4.0" шеңберінде цифрлық егіздер платформаларының ақпараттық қауіпсіздігін қамтамасыз ету үшін кешенді әдістердің қажеттілігін көрсетеді.

Бұл зерттеу цифрлық егіздер экожүйесінің қауіпсіздігін қамтамасыз ететін платформаларды дамытуға ғылыми және тәжірибелік негіз бола алады. Киберқауіптерге қарсы тұру үшін ұсынылған кешенді тәсілдер ақпараттық қауіпсіздік саласында жаңа технологиялардың қолданысын жетілдіруге және цифрлық егіздер платформаларының тұрақтылығын арттыруға мүмкіндік береді.

Пайдаланылған әдебиеттер тізімі:

1. Carol Lo, Thu Yein Win, Zeinab Rezaeifar, Zaheer Khan, Phil Legg. "Digital Twins in Industry 4.0 Cyber Security." 2023 IEEE Smart World Congress (SWC)|979-8-3503-1980-4/23/ DOI: 10.1109/SWC57546.2023.10449147
2. Harshpreet Kaur, Munish Bhatia. "Scientometric Analysis Of Digital Twin in Industry 4.0.": DOI 10.1109/JIOT.2024.3459965.
3. Banglie Yang, Linyu Zhu, Cheng Dai*, Sahil Garg, Georges Kaddoum. "An Improved Reconstruction Based Multi-Attribute Contrastive Learning for Digital Twin-Enabled Industrial System." DOI 10.1109/JIOT.2024.3483038.
4. Katrina Groth, Dongfeng Zhu, Ali Mosleh. "Hybrid Methodology and Software Platform for Probabilistic Risk Assessment." 1-4244-1461-X/08/\$25.00 ©2008 IEEE
5. Ioannis Semertzis, Vetrivel Subramaniam Rajkumar, Alexandru Ştefanov, Frank Fransen, Peter Palensky. "Quantitative Risk Assessment of Cyber Attacks on Cyber-Physical Systems using Attack Graphs." 2022 10th Workshop on Modelling and Simulation of Cyber-Physical Energy Systems (MSCPES). DOI: 10.1109/MSCPES55116.2022.9770140

ДЕРЕКТЕР БАЗАСЫНЫҢ НЕГІЗДЕРІ” ПӘНІ БОЙЫНША ЭЛЕКТРОНДЫҚ ОҚУ КЕШЕНІН ӘЗІРЛЕУ

Зетбек А.Б.

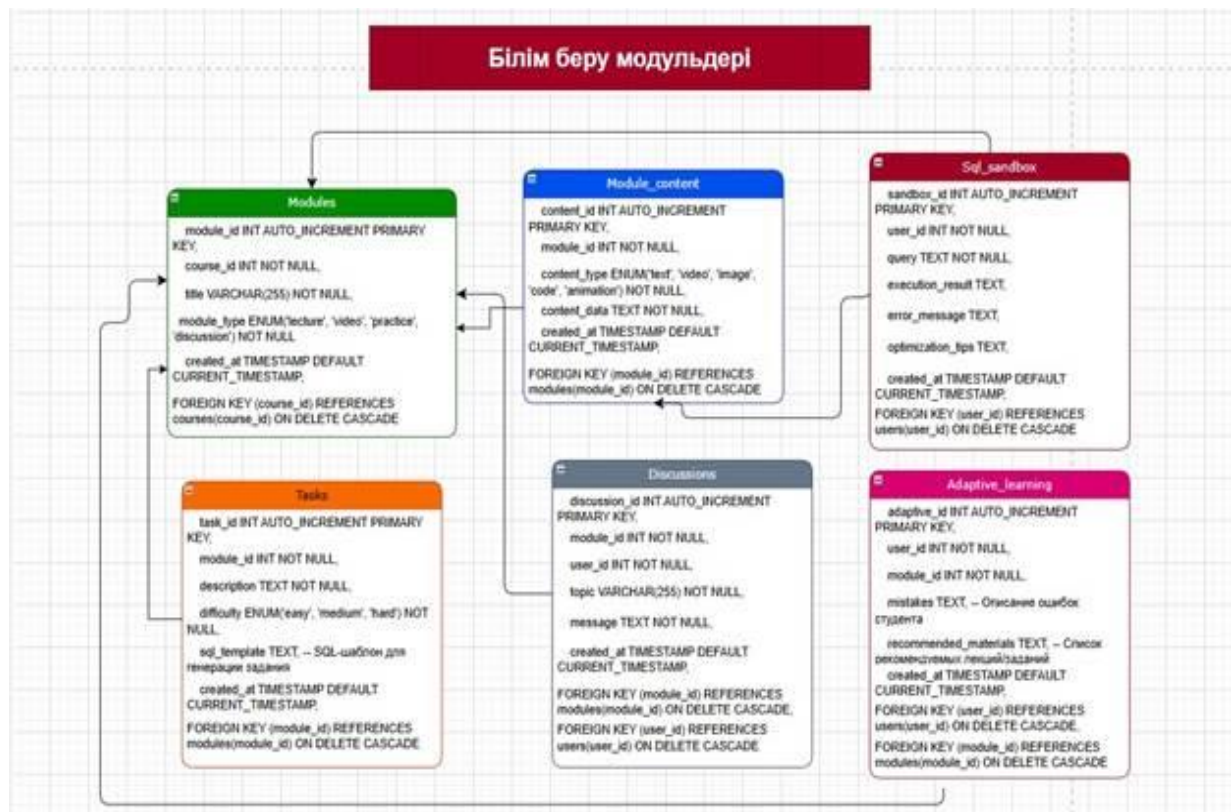
Әл-Фараби атындағы Қазақ ұлттық университеті, бакалавр 4 курс
E-mail: ardakzetsbek@gmail.com

Рахимова Д.Р.

Әл-Фараби атындағы Қазақ ұлттық университеті, PhD, доцент

Білім беруді цифрландырудың заманауи үрдістері тиімді оқытуды қамтамасыз ететін инновациялық құралдарды енгізуді талап етеді. Осы жұмыс шеңберінде теориялық материалдарды, практикалық тапсырмаларды және автоматтандырылған білімді тексеруді қамтитын «Деректер базасы негіздері» пәні бойынша интерактивті электронды оқу кешені (ЕЭК) әзірленді.

Зерттеудің өзектілігі реляциялық деректер қорымен және SQL тілімен жұмыс істейтін мамандарға деген сұраныстың артуына, сонымен қатар дәстүрлі оқыту әдістерінің шектеулеріне байланысты. Сонымен қатар, мемлекеттік тілде оқитын студенттердің пәнді меңгеруіне қиындық туғызатын қазақ тілінде білім беру ресурстарының жоқтығы маңызды аспект болып табылады. Қазақ тіліндегі электрондық білім беру кешенін дамыту сапалы білімге қолжетімділікті кеңейтіп, білім деңгейін жоғарылатады және SQL және реляциялық мәліметтер қорын меңгеру процесін жеңілдетеді. Қолданыстағы платформаларды талдау (Coursera, Stepik, SQL Academy және т.б.) университеттердің оқу үдерісіне біріктірілген мамандандырылған шешімнің қажеттілігін анықтады. Зерттеу әдістеріне электронды оқу әдебиетін шолу, платформаларды салыстырмалы зерттеу, UML диаграммасын жобалау, EUC прототиіпін эксперименттік тестілеу және студенттердің үлгеріміне статистикалық талдау кіреді.



Сурет 1. Білім беру платформасының деректер қорының құрылымы

Электрондық білім беру кешенін әзірлеуді және енгізуді аяқтағаннан кейін келесі нәтижелерге қол жеткізіледі деп күтілуде:

- Интерактивті лекцияларды, бейімделген ұсыныстарды және жекелендірілген оқыту жолдарын пайдалану арқылы теориялық материалды меңгерудің тиімділігін арттыру.
- Автоматтандырылған талдау және кері байланыс мүмкіндігі бар интеграцияланған ортада тапсырмаларды орындау арқылы SQL тілімен жұмыс істеудің практикалық дағдыларын дамыту.
- Студенттердің жұмысын бағалауға кететін уақытты қысқартатын SQL сұраныстарын тексерудің автоматтандырылған жүйесін енгізу арқылы мұғалімдердің жұмысын оңтайландыру.
- Рейтингік жүйе мен бейімделген оқыту механизмін қолдану арқылы оқушылардың белсенділігін арттыру.
- Moodle және Google Classroom сияқты оқытуды басқару жүйелерімен (LMS) интеграция, бұл оқу процесін басқарудың жеңілдігін және оқу материалдарын орталықтандырылған басқаруды қамтамасыз етеді.

Қорытынды

Қазақ тіліндегі электронды оқу кешенін әзірлеу жоғары оқу орындарында SQL және реляциялық мәліметтер қорын оқыту әдістемесін жетілдірудің маңызды кезеңі болып табылады. Бұл жүйе студенттердің теориялық негіздерін терең меңгеруіне және практикалық дағдыларын дамытуға ықпал ететін мемлекеттік тілдегі сапалы білім беру ресурстарына қолжетімділікті қамтамасыз етеді. Аталған оқу-әдістемелік кешеннің жүзеге асырылуы оқу үдерісінің тиімділігін арттыруға, мұғалімдердің жүктемесін оңтайландыруға және білімді бағалау процедурасын автоматтандыруға мүмкіндік береді.

Пайдаланылған әдебиеттер тізімі:

1. Ахметова Г., Жумабеков Н. Интерактивті оқыту технологияларының тиімділігі // *Білім және ғылым журналы*, 2020.
2. Stepik.org – Бағдарламалау және деректер қорын оқыту бойынша интерактивті курстар, 2024.
3. ҚР Ғылым және жоғары білім министрлігі. Қазақстандағы цифрлық білім беруді дамыту стратегиясы.
4. Coursera.org – SQL және деректер базасы бойынша курстар, 2024.

ИНТЕЛЛЕКТУАЛДЫ ОҚЫТУ ЖҮЙЕСІНІҢ КӨМЕГІМЕН ПРОГРАММАЛАУ ТІЛДЕРІН ҮЙРЕНЕТІН ЖӘНЕ БІЛІМ ДЕҢГЕЙІН АНЫҚТАУҒА МҮМКІНДІК БЕРЕТІН АҚПАРАТТЫҚ ӨНІМГЕ САРАЛАУ

Исахан М.А.

Әл-Фараби атындағы Қазақ ұлттық университеті, бакалавр 4 курс

E-mail: issakhanmerey@gmail.com

Қалидоллина Г.Т.

Әл-Фараби атындағы Қазақ ұлттық университеті, магистр, аға оқытушы

Дәл осындай жүйені осы зерттеу аясында әзірлеу мақсаты қойылған. Біздің міндетіміз – білім деңгейін дәл бағалайтын және жеке оқыту әдісін ұсынатын интеллектуалды платформа құру. Бұл жүйе жай ғана құрал емес, ол бағдарламалауды меңгеру процесін жеделдететін катализаторға айналады.

Технологиялық жаңалықтар қарқынды дамып жатқан заманда жаңа дағдыларды тез игеру қабілеті табыстың негізгі факторына айналууда. Бағдарламалау – бұл тек кәсіби дағды ғана емес, ол жасанды интеллекттен бастап үлкен деректерді талдауға дейінгі әртүрлі салаларда қолданылатын әмбебап құрал [1].

Бағдарламалау тілдерін меңгеру деңгейін бағалау – бұл күрделі және көпқырлы процесс, ол тек теориялық білімді ғана емес, сонымен қатар практикалық дағдыларды, логикалық ойлау қабілетін және шығармашылық көзқарасты да қамтиды. Бағалау әдістері әртүрлі тәсілдерді талап етеді, себебі бағдарламалау саласындағы шеберлік бірнеше аспектіден тұрады.

Теориялық білімді бағалау маңызды элементтердің бірі болып табылады. Ол бағдарламалау тілінің синтаксисі мен семантикасын, негізгі алгоритмдер мен деректер құрылымдарын меңгеру деңгейін, сондай-ақ әртүрлі бағдарламалау парадигмалары туралы түсінікті қамтиды. Бағдарламалаушы қолданатын тілінің мүмкіндіктерін, оның артықшылықтары мен шектеулерін білуі маңызды. Бұл білім көбіне тесттер, қысқа сұрақтар және код үзінділерін талдау арқылы тексеріледі.

Алайда, теориялық білімнің өзі жеткіліксіз. Практикалық дағдыларды бағалау үшін код жазу тапсырмалары, бағдарламалық жобаларды әзірлеу және код рефакторингі қолданылады [2]. Мұндай тапсырмалар бағдарламашының күрделі мәселелерді шешу қабілетін, код жазу жылдамдығы мен сапасын, сондай-ақ жүйелерді жобалау машықтарын көрсетеді. Үміткерге белгілі бір алгоритмді жүзеге асыру, кодты оңтайландыру немесе шағын қосымшаны әзірлеу секілді тапсырмалар берілуі мүмкін.

Онлайн платформалар мен автоматтандырылған бағалау жүйелері қазіргі таңда маңызды құралға айналды [3]. Олар кең ауқымды тапсырмалар базасын, автоматты тексеру жүйелерін және нақты уақыт режимінде кері байланыс алу мүмкіндігін ұсынады. Бұл платформалар үміткердің код жазу жылдамдығын, тиімділігін және масштабталуын бағалауға мүмкіндік береді. Сонымен қатар, олар әртүрлі деңгейдегі тапсырмаларды ұсына отырып, үміткердің қабілеттерін кешенді түрде бағалауға мүмкіндік жасайды.

Машинаны оқытудың негізгі идеясы – кірістер мен шығыстардың кез келген комбинацияларының арасында математикалық байланыс бар. Машиналық оқыту моделінде бұндай болуы мүмкін қатынастар туралы алдын ала деректер жоқ, бірақ мәліметтер қорлары жеткілікті қамтамасыздандырылса, оны жасай алады [4]. Бұл барлық машиналық оқыту алгоритмі математикалық функцияның негізінде құрастырылатының білдіреді. Негізгі принциптің сипаттамасын төменде қараңыз [5].

Біз алгоритмді оған келесі енгізу/шығару комбинацияларын [енгізу / шығару (i,o)] беру арқылы «үйретеміз»:

- Алгоритм кіріс пен шығыс арасындағы қатынасты келесідей есептейді:

$$o = 3 \times i + 4.$$

- Содан кейін біз 7 енгізуді береміз және нәтижені болжауды сұраймыз. Алгоритм

шығысты 25 ретінде автоматты түрде анықтай алады.

- Бұл жалпылама түсінік болғанымен, машиналық оқыту барлық күрделі деректер нүктелері осы деректерді өңдеу үшін жеткілікті мәліметтер мен оларды өңдеу қуатына ие болатын болса, компьютерлік жүйелермен математикалық байланыс болуы мүмкін деген принцип ұсталынады. Сондықтан шығыс деректерінің дәлдігі кіріс деректерінің шамасына тура пропорционал [6].

Алгоритмдерді күтілетін нәтижеге және кіріс түріне қарай төрт оқыту стиліне жіктеуге болады;

- мұғалімі бар машиналық оқыту;
- мұғалімсіз машиналық оқыту;
- ішінара мұғалім тартылған машиналық оқыту;
- қосымша көмек қосылған машиналық оқыту.

Машиналық оқытудың артықшылықтары мен кемшіліктеріне назар аударайық.

Машиналық оқыту модельдерінің артықшылықтары:

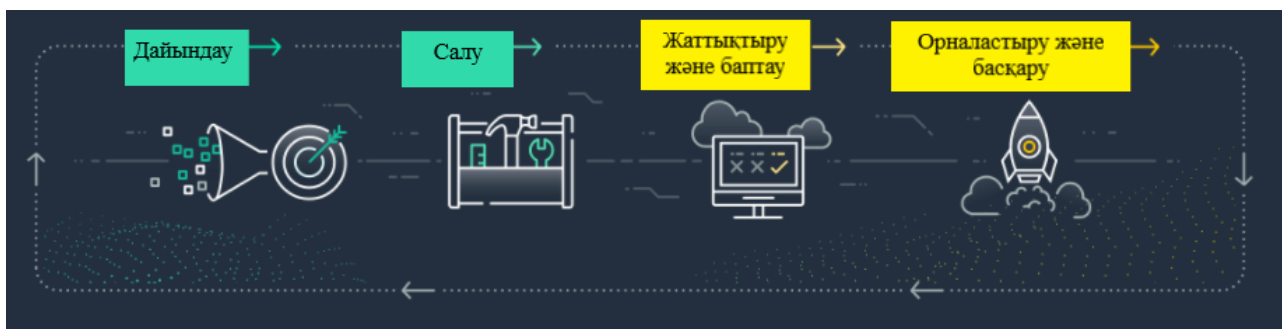
- адамдар назарынан жіберіп алуы мүмкін мәліметтердегі үрдістер мен үлгілерді анықтау;

- баптаулардан кейін адамдардың араласуынсыз жұмыс істеу; мысалы, киберқауіпсіздік бағдарламалық қамтамасыз етуіндегі машиналық оқыту алгоритмінде әкімшінің араласуынсыз желілік трафиктегі бұзушылықтарды үнемі бақылап, анықтай алады[7];

- нәтижелер уақыт өте дәлірек болуы мүмкін;
- динамикалық, үлкен көлемдегі және күрделі деректер орталарында әртүрлі деректер пішімдерін(форматтарын) өңдеу.

Машиналық оқыту модельдерінің кемшіліктері:

- бастапқы дайындық – шығынды және көп уақытты қажет ететін процесс; жеткілікті деректер болмаған кезде уақытты қажет ететін іске асыру;
- егер жабдық өз күшімен орнатылатын болса, онда үлкен бастапқы инвестицияны қажет ететін ресурстары кең көлемді процесс;
- маманның көмегінсіз нәтижелерді дұрыс түсіндіру және белгісіздікті жою қиын болуы мүмкін.



1-сурет. Машиналық оқытудың сұлбасы

Берілген жұмыс нәтижесінде программалау тілдерін үйренуге мүмкіндік беретін ақпараттық өнім алынды. Тек үйретіп қана қоймай, программалау тіліндегі деңгейді анықтауға және онымен ары қарай жұмыс жүргізуге мүмкіндік береді. Қарапайым мысалдармен қоса, ақпараттық өнім құрамына компилятор қосылып, жазылу синтаксисіне мән беріледі. Сонымен қатар, басқа сайтқа кіруге немесе басқа терезені ашуға мүмкіндікке шектеу қойылған[8]. Қысқаша айтқанда, машиналық оқыту жүргізіліп, программалық өнім жүзеге асырылды.

Пайдаланылган әдебиеттер тізімі:

1. Математические основы машинного обучения и прогнозирования» Владимир Вьюгин, 2018, 145-196
2. «Машинное обучение» Хенрик Бринк, Джозеф Ричардс, Марк Феверолф, 2017, 65-73
3. «Методы обработки и распознавания изображений лиц в задачах биометрии» Георгий Кухарев, Екатерина Каменская, Юрий Матвеев, Надежда Щеголева, 2019, 74-82
4. «The Elements of Statistical Learning. Data Mining, Inference and Prediction» Trevor Hastie, Robert Tibshirani, Jerome Friedman, 2023, 245-296
5. Билл Любанович. Простой Python. Современный стиль программирования, 2023г., 53с.
6. Лучано Рамальо. Python. К вершинам мастерства, 2021г., 113-119с.
7. Адриан Роузброк – Deep Learning for Computer Vision with Python, 2017 г., 98-103 с.
8. Сергей Николенко, А. Кадурич, Екатерина Архангельская – Глубокое обучение. Погружение в мир нейронных сетей, 2022 г, 14с..

«METASTUDY» БІЛІМ БЕРУ ОРТАЛЫҒЫ ҮШІН «ОҚУШЫ КҮНДЕЛІГІ» АҚПАРАТТЫҚ ЖҮЙЕСІН ӘЗІРЛЕУ

Кабдолдаева Ә.Б.

*Әл-Фараби атындағы Қазақ ұлттық университеті, бакалавр 4 курс
e-mail: aqabdolda@gmail.com*

Қалидоллина Г.Т.

Әл-Фараби атындағы Қазақ Ұлттық университеті, Алматы, Қазақстан

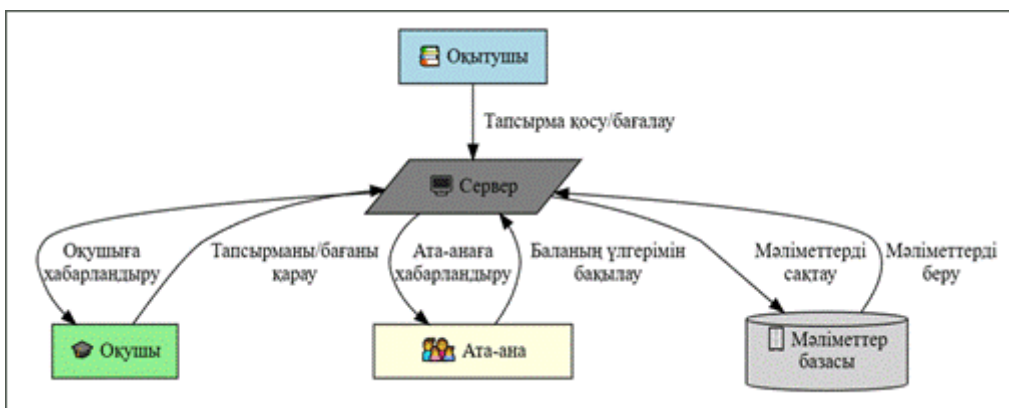
Бұл мақалада «MetaStudy» білім беру орталығы үшін интеллектуалды ақпараттық жүйе – «Оқушы күнделігін» әзірлеу тұжырымдамасы қарастырылады. Жүйенің негізгі мақсаты – қатысу мен үлгерімді есепке алу үдерістерін автоматтандыру, сондай-ақ деректерді талдау негізінде оқытуды жекешелендіру. Жүйенің функционалдық мүмкіндіктеріне интерактивті кесте, жекелендірілген ұсыныстар, хабарландыру жүйелері және үлгерімді автоматты түрде талдау жатады. Бұл жүйені енгізу оқу процесінің тиімділігін арттырып, мұғалімдер, оқушылар мен ата-аналар үшін ыңғайлы құралдарды ұсынуға көмектеседі деп күтілуде.

Білім беру үдерісіне ақпараттық технологияларды енгізу интеллектуалды басқару жүйелерін дамытудың негізгі бағытына айналды [1]. Қазақстанда білім беруді цифрландыруға үлкен көңіл бөлінеді, бұл SMART-технологиялар мен жасанды интеллектті педагогикалық үдеріске енгізуді талдауға бағытталған зерттеулермен дәлелденеді [2]. Қазіргі заманғы білім беру мекемелері цифрлық платформаларға белсенді түрде көшуде, бұл қатысуды есепке алу, үлгерімді бақылау және білім беру үдерісіне қатысушылар арасындағы өзара әрекеттестікті автоматтандыруға мүмкіндік береді.

Технологиялардың қарқынды дамуы жағдайында деректерді талдау негізінде оқытуды жекешелендіруге ерекше көңіл бөлінеді [3]. Интеллектуалды білім беру жүйелерін әзірлеу заманауи оқыту үдерісін жетілдірудің маңызды бағыты болып табылады. Мұндай жүйелер жасанды интеллект негізінде жұмыс істеп, білім алушылардың үлгерімін бақылауды автоматтандыруға, оқу материалдарын жекелендіруге және оқу процесін тиімді ұйымдастыруға мүмкіндік береді. Интеллектуалды жүйелерді енгізу білім сапасын арттырып қана қоймай, студенттер мен оқытушылар арасындағы өзара әрекеттестікті жақсартады [4]. Интеллектуалды білім беру жүйелерінің тағы бір артықшылығы – олар оқу үдерісін автоматтандыру арқылы мұғалімдердің жұмыс жүктемесін азайтып, білім алушылардың өзіндік оқу дағдыларын дамытуға жағдай жасайды. Осылайша, білім беру жүйесін интеллектуалдандыру оқыту сапасын жақсартудың және оны жаңа деңгейге көтерудің тиімді шешімі болып табылады.

Бұл мақалада «Оқушы күнделігі» жүйесінің тұжырымдамасы ұсынылады, ол заманауи технологияларды білім беру ортасына интеграциялауға, үлгерімді бақылау тиімділігін арттыруға және студенттер, мұғалімдер мен ата-аналар арасындағы өзара әрекеттестікті жақсартуға бағытталған.

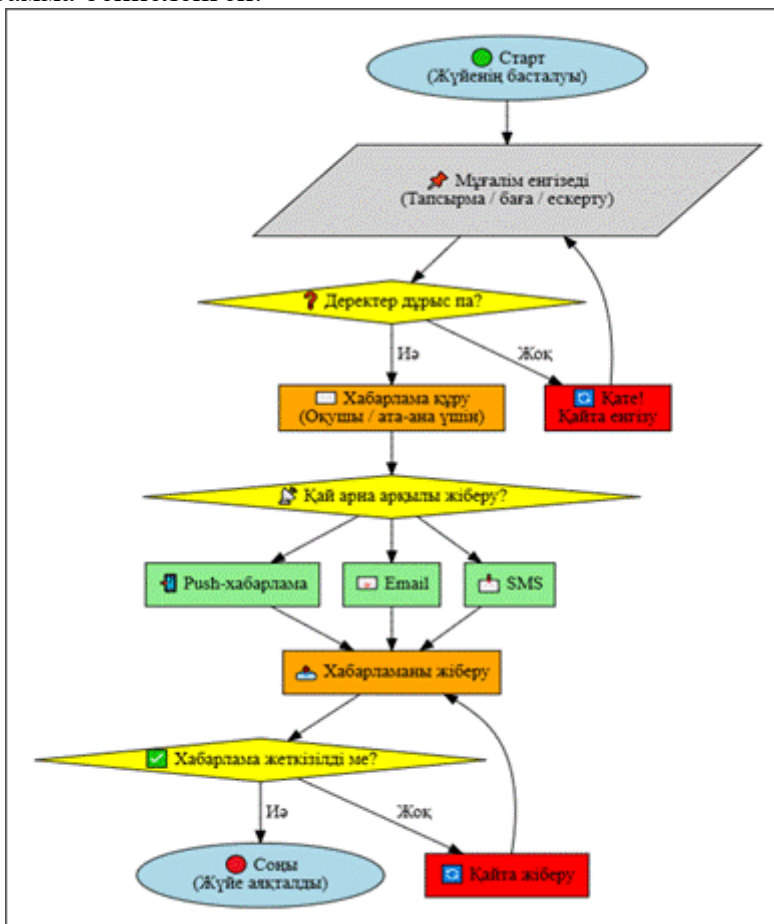
1-суретте пайдаланушылардың дерекқормен өзара әрекеттесуін сипаттайтын диаграмма бейнеленген. Бұл диаграмма пайдаланушылардың жүйеге кіру, деректерді енгізу, өңдеу және шығару үдерістерін, сондай-ақ жүйенің жауап беру механизмдерін көрсетеді. Мұнда әртүрлі пайдаланушылардың (оқушылар, мұғалімдер, әкімшілер) дерекқормен қалай жұмыс істейтіні және олардың қандай функцияларды орындайтыны көрнекі түрде ұсынылған.



1-сурет. «Оқушы күнделігі» жүйесінің архитектурасы

Жүйенің негізгі функционалдық мүмкіндіктеріне қатысу мен үлгерімді автоматты түрде есепке алу, үй тапсырмалары туралы еске салу, бағалар туралы есептерді генерациялау, сабақтардың интерактивті кестесін ұсыну, оқу материалдары бойынша жекелендірілген ұсыныстар беру, сондай-ақ Push-хабарламалар, Email және SMS арқылы хабарландыру мен байланыс жүйелерін қамтамасыз ету жатады.

2-суретте мұғалім, жүйе және оқушы арасындағы өзара әрекеттесу үдерісін сипаттайтын диаграмма бейнеленген.



2-сурет. Хабарландыру жүйесінің блок-схемасы

Қорыта айтқанда, «Оқушы күнделігі» жүйесін әзірлеу білім беру орталығының жұмысын автоматтандыруға және оқыту сапасын жақсартуға бағытталған маңызды қадам болып табылады. Интеллектуалды алгоритмдерді қолдану студенттердің үлгерімін талдауға және жеке оқыту стратегияларын ұсынуға мүмкіндік береді. Бұл жүйе оқу үдерісінің тиімділігін арттырып қана қоймай, мұғалімдер мен оқушылар үшін ыңғайлы цифрлық орта қалыптастыруға ықпал етеді. Осылайша, «Оқушы күнделігі» білім беру жүйесін

автоматтандыру арқылы оқу үдерісін жаңа деңгейге көтеруге көмектеседі.

Пайдаланылған әдебиеттер тізімі:

1. Байдилдаева, Ж. Ш. К вопросу об информатизации образования в Республике Казахстан / Ж. Ш. Байдилдаева // Вестник КазНПУ им. Абая. – 2022. – №3(75). – С. 45-52.
2. Абылкасымова, А. О развитии SMART технологии в цифровой образовательной среде Казахстана / А. Абылкасымова, Д. Ахмед-Заки, Н. Жұмабай // Наука и образование. – 2021. – №2(89). – С. 112-120.
3. Кенжебаева, З. Использование цифровых технологий в системе дистанционного образования: зарубежный опыт и Казахстан / З. Кенжебаева, М. Садырова, Е. Мухтар, Ш. Момынкулова // Современные технологии обучения. – 2023. – №5. – С. 98-105.
4. Абыканова, Б. Т. Системы на основе искусственного интеллекта в педагогическом образовании: возможности и последствия / Б. Т. Абыканова, Ж. К. Салыкбаева, М. Кайыржан, А. Бахтыгереев // Образование и наука. – 2020. – Т. 22, №4. – С. 67-74.

ІРІ СУПЕРМАРКЕТТЕ ТҰТЫНУ ТАУАРЛАРЫН СӨРЕЛЕРГЕ ОҢТАЙЛЫ ОРНАЛАСТЫРУДЫҢ ИНТЕЛЛЕКТУАЛДЫ АҚПАРАТТЫҚ ЖҮЙЕСІН ӘЗІРЛЕУ

Князбай А.Ә.

E-mail: asylknazbaj@gmail.com

әл-Фараби атындағы Қазақ ұлттық университеті, Қазақстан

Қазіргі заманғы супермаркеттерде тауарлардың ауқымды ассортименти мен сатып алушылар ағынын ескере отырып, сөрелерді тиімді ұйымдастыру қажет [1]. Бұл міндетті орындау үшін деректерді талдау, жасанды интеллект (AI) және машиналық оқыту (ML) технологиялары пайдаланылады [5].

Интеллектуалды жүйе сатылым тарихын, маусымдық өзгерістерді және тұтынушылардың мінез-құлқын талдау арқылы сұранысты болжайды. Үлкен деректер (Big Data) технологиясы алынған ақпаратты өндеп, сұранысы жоғары тауарларды қолайлы орындарға орналастыруға көмектеседі. Бұл тәсіл сатылымды 15-20%-ға арттыруға мүмкіндік береді.

Жасанды интеллект алгоритмдері тауарларды сөрелерге орналастыруды автоматтандырып, сұраныс өзгерістеріне сәйкес орналасуды жаңартып отырады. Мысалы, маусымдық өнімдер немесе акциядағы тауарлар ең көрнекі орындарға орналастырылады. Бұл тәсіл сатып алушылардың назарын аударып, импульсивті сатып алуларды ынталандырады [4].

Сөрелерді оңтайлы жоспарлау арқылы тауар айналымы жеделдейді. Жүйе тез сатылатын тауарларды клиенттерге ыңғайлы жерге орналастырады, ал сирек сатылатын тауарларды сақтау аймақтарына ығыстырады. Осылайша, супермаркет сату алаңын тиімді пайдаланып, қоймадағы орын тапшылығын азайтады.

Жүйе ERP және CRM жүйелерімен интеграцияланып, тауар жеткізілімі мен қоймадағы деректерді автоматты түрде жаңартады. Бұл тәсіл тауар жеткізілімінің кешігуін азайтып, бос тұрған сөрелердің алдын алуға көмектеседі [3].

Жүйеде деректер қауіпсіздігі жоғары деңгейде сақталады. API интеграциясы мен шифрлау технологиялары арқылы жүйеге рұқсатсыз кіру мен деректердің бұрмалануына жол берілмейді. Сонымен қатар, блокчейн технологиясы тауар жеткізіліміне қатысты деректердің өзгертілуіне тосқауыл қояды.

Ірі супермаркеттерде интеллектуалды ақпараттық жүйені енгізу тауар айналымын жеделдетіп, сатылымды арттыруға мүмкіндік береді [2]. Жасанды интеллект, үлкен деректер және автоматтандырылған жоспарлау технологияларын қолдану арқылы тұтынушыларға ыңғайлы сауда тәжірибесін қамтамасыз етіп, супермаркеттің бәсекеге қабілеттілігін арттыруға болады.

Пайдаланылған әдебиеттер тізімі:

1. Kotler, P., Keller, K. L. (2022). *Marketing Management* (16th ed.). Pearson.
2. Turban, E., Pollard, C., Wood, G. (2023). *Information Technology for Management: On-Demand Strategies for Performance, Growth and Sustainability*. Wiley.
3. Chopra, S., Meindl, P. (2022). *Supply Chain Management: Strategy, Planning, and Operation*. Pearson.
4. Davenport, T. H., Ronanki, R. (2018). *Artificial Intelligence for the Real World*. Harvard Business Review.
5. Лутц, Марк. *Learning Python*. 5-ші басылым. Бейжің: O'Reilly Media, 2013.

LLM НЕГІЗІНДЕ СПАМ ХАБАРЛАМАЛАРДЫ АНЫҚТАУ: SUPERVISED ЖӘНЕ UNSUPERVISED ОҚЫТУДЫ ҚОЛДАНУ

Күмісбек Мұхаммед-Әли Нұрланұлы

Әл-Фараби атындағы Қазақ Ұлттық Университеті 1 курс докторанты

E-mail: mali.kumisbek@gmail.com

Шормакова Асем Ноябровна

Әл-Фараби атындағы Қазақ Ұлттық Университеті, PhD, и.о. доцент ҚАЗҰУ

Жасанды интеллект саласында үлкен тілдік модельдер (LLM) күрделі мәтінді талдау міндеттерін орындауға мүмкіндік беріп, ақпараттық қауіпсіздік саласында ерекше орын алады. Бақыланатын оқыту бұрыннан белгілі заңдылықтарға негізделгендіктен, нақты үлгілерді сенімді анықтайды, бірақ күтпеген немесе сирек кездесетін шаблондарды тануда шектеулері бар. Ал бақыланбайтын оқыту мұндай жаңа үлгілерді аномалия ретінде қарастырып, олардың басты ерекшеліктерін тауып шығады. Бұл екі әдістің тиімділігін LLM-мен біріктіру күрделі мәтін үлгілерін жіктеу сапасын жақсартып, күмәнді хабарламаларды дер кезінде анықтауға мүмкіндік береді.

LLM табиғи тілдің семантикасы мен контекстін терең талдайды, сондықтан мәтін ішіндегі жасырын мағыналарды, синонимдер мен терминдер арасындағы байланысты жоғары дәлдікпен түсінеді. Бақыланатын оқыту белгілі бір шекараларды нақты сызып берсе, бақыланбайтын алгоритмдер әлдеқайда икемді, олар алдын ала белгісіз болған сипаттарды өздігінен байқайды. Бір жағынан, мұндай кешенді тәсіл жалған позитивтер мен жалған терістерді азайтса, екінші жағынан, жаңа шаблондарды тану қабілетін күшейтіп, ақпараттық қауіпсіздік жүйелерін жаңартуға мүмкіндік береді.

Үлкен тілдік модельдер мен гибриді тәсілдерді біріктіру ақпараттық қауіпсіздікті қамтамасыз етуде жаңа мүмкіндіктер ашады. Жасанды интеллект жүйелері мәтіндік үлгілерді терең талдап, контекстуалдық мағыналарды ажырату қабілетіне ие болған сайын, күмәнді хабарламаларды ерте кезеңде анықтау мүмкіндігі артады. Сонымен қатар, үлкен деректер жиынтықтарымен жұмыс істегенде модельдің бейімделу қабілеті күшейіп, жаңа спам түрлерін алдын ала болжау ықтималдығы артады. Бақыланатын және бақыланбайтын оқыту әдістерін біріктіру арқылы алынған нәтижелер тек спамға қарсы күресте ғана емес, сонымен қатар фишингтік шабуылдарды, жалған ақпараттың таралуын және әлеуметтік инженерия әдістерін қолданатын зиянкестерді анықтауда да тиімді бола алады. Бұл тәсілдің одан әрі дамуы киберқауіпсіздік жүйелерін автоматтандырудың жаңа деңгейіне шығуға және қолданушылардың деректерін қорғау механизмдерін жетілдіруге ықпал етеді.

Мұндай аралас әдістерді жүзеге асыру кезінде есептеу ресурстарын тиісті деңгейде қамтамасыз ету қажет, себебі бірнеше модельдің нәтижелерін бір мезетте өңдеу жүктемені арттырады. Дегенмен, бұл шығын өз нәтижесін ақтап, күмәнді хабарламаларды айтарлықтай тиімділікпен анықтауға жол ашады. Кейбір жағдайларда қосымша метамәліметтерді пайдалану да пайдалы болуы мүмкін: хабарлама жіберілген уақыт, қолданушының тілдік әдеттері немесе оның басқа аккаунттармен байланысы сынды факторлар талдауға қосымша дәлдік береді.

Болашақта GPT немесе BERT тәрізді модельдердің алуан түрлі эмбеддингтерін пайдалануды кеңейту жоспарланып отыр, себебі олар сұхбаттық контексті, тақырыптық құрылымды және стилистикалық ерекшеліктерді толық ескеруге қабілетті. Осылайша, бақыланатын және бақыланбайтын оқыту әдістері LLM-дермен бірге қолданылғанда, көптілді ортадағы күмәнді хабарламаларды жылдам танып, жалған ақпарат пен фишинг шабуылдарының алдын алуға ықпал етеді.

Пайдаланылған әдебиеттер тізімі:

1. Androustopoulos, I., Koutsias, J., Chandrinou, K. V., & Spyropoulos, C. D. (2000). An experimental comparison of naive Bayesian and keyword-based anti-spam filtering with personal e-mail messages. In *Proceedings of the 23rd annual international ACM SIGIR conference on Research and development in information retrieval* (pp. 160–167). ACM. *(This study is a cornerstone for supervised spam filtering techniques.)*
2. Sahami, M., Dumais, S., Heckerman, D., & Horvitz, E. (1998). A Bayesian approach to filtering junk e-mail. In *Learning for Text Categorization* (pp. 62–69). *(This work laid early groundwork for using statistical models in spam detection.)*
3. Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018). BERT: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*.

НЕЙРОНДЫҚ ЖЕЛІЛЕРДІҢ МАТЕМАТИКАЛЫҚ НЕГІЗДЕРІ: СЫЗЫҚТЫҚ ЕМЕС ФУНКЦИЯЛАР ЖӘНЕ КЕРІ ТАРАТУ АЛГОРИТМІ

Қойшыбай Бекнұр Ерболатұлы

Astana International University, Астана, Қазақстан

Аннотация. Қазіргі заманғы жасанды интеллект жүйелерінің негізін құрайтын нейрондық желілер сызықтық емес функцияларды моделдеу қабілеті арқылы кеңінен қолданыс тапты. Осы мақалада нейрондық желілердің математикалық негіздері қарастырылып, олардың сызықтық емес функцияларды интерполяциялау және аппроксимациялау қабілеттері талданады. Сонымен қатар, нейрондық желілерді оқытуда шешуші рөл атқаратын кері тарату алгоритмінің (Backpropagation) математикалық механизмдері, оның градиенттік ең түсу әдісімен байланысы және көпқабатты персептрон құрылымындағы орны сипатталады.

Кілттік сөздер: нейрондық желілер, сызықтық емес функциялар, кері тарату алгоритмі, градиенттік ең түсу, жасанды интеллект, математикалық модельдеу

Зерттеу нейрондық желілердің сызықтық емес функцияларды аппроксимациялау қабілетін және кері тарату алгоритмінің (Backpropagation) тиімділігін математикалық тұрғыдан талдауға бағытталған. Зерттеу барысында теориялық, аналитикалық және сандық эксперименттік әдістер қолданылды. Теориялық әдіс – көпқабатты персептрон құрылымындағы сызықтық емес функцияларды модельдеудің математикалық негіздері зерттелді. Нейрондық желілердің негізгі қасиеттері, соның ішінде универсалды аппроксимация теоремасы (Cybenko, 1989) [2], Гаусс-Ньютон әдісі, градиенттік ең түсу алгоритмі қарастырылды.

Зерттеу объектісі ретінде көпқабатты персептрон (Multilayer Perceptron, MLP) моделі алынды. Бұл архитектура ең қарапайым және кең таралған нейрондық желілердің бірі болып табылады және сызықтық емес функцияларды интерполяциялау қабілетімен ерекшеленеді.

Зерттеуде жасанды және нақты деректер жиынтықтары пайдаланылды:

- Жасанды деректер – синтетикалық түрде жасалған сызықтық емес функциялар ($y = \sin(x)$, $y = x^2$, $y = e^x$) аппроксимацияланды.

- Нақты деректер – MNIST (қолмен жазылған цифрлар) және CIFAR-10 (сурет тану) деректер жиынтықтары қолданылды. Бұл жиынтықтар кері тарату алгоритмінің тиімділігін және модельдің генерализация қабілетін тексеру үшін пайдаланылды.

Нейрондық желінің оқыту үдерісі келесі параметрлер бойынша жүргізілді:

- Жасырын қабаттар саны: 1–5 аралығында өзгертілді.
- Нейрондар саны: 16, 32, 64, 128.
- Активтендіру функциялары: Sigmoid, ReLU, Tanh.
- Оқудың жылдамдығы (Learning rate): 0.001–0.1 диапазонында өзгертілді.
- Оптимизация әдістері: SGD (стохастикалық градиенттік ең түсу), Adam, RMSprop.

Математикалық модельдеу және есептеу әдістері

Кері тарату алгоритмінің тиімділігін бағалау үшін сандық дифференциалдау, градиенттік оптимизация, Гаусс-Ньютон әдісі және есептеу эксперименттері қолданылды.

Кері тарату алгоритмінің градиенттік ең түсу әдісімен байланысы мына теңдеумен сипатталды:

$$w^{(t+1)} = w^{(t)} - \eta \frac{\partial J}{\partial w}$$

мұндағы:

- $w^{(t)}$ – t -ші итерациядағы салмақ,
- η - оқу жылдамдығы,
- J - шығын функциясы (мысалы, MSE, Cross-Entropy),

- $\frac{\partial J}{\partial w}$ - шығын функциясының градиенті.

Нейрондық желінің сызықтық емес функцияларды аппроксимациялау қабілетін тексеру үшін универсалды аппроксимация теоремасы негізінде Тейлор қатары пайдаланылды:

$$f(x) \approx \sum_{i=1}^N w_i \sigma(a_i x + b_i)$$

мұнда $\sigma(x)$ - активтендіру функциясы (мысалы, Sigmoid, ReLU), ал w_i, a_i, b_i - нейрондық желінің параметрлері.

Эксперименттік валидация және деректерді өңдеу

- Әрбір модель 1000–5000 итерация бойы оқытылды.
- Дәлдік, шығын функциясының азаю динамикасы, градиенттердің өзгеру жылдамдығы бақыланды.
- Алынған нәтижелер корреляциялық талдау, дисперсиялық талдау (ANOVA) және шифрланған кросс-валидация әдістері арқылы тексерілді.

Зерттеу нәтижелерінің сенімділігі

- Қайталанатын сынақтар – әрбір тәжірибе бірнеше рет қайталанып, нәтижелердің статистикалық тұрғыдан тұрақтылығы тексерілді.
- Байес ықтималдықтық әдістері – нейрондық желілердің болжамдық қабілетін бағалау үшін қолданылды.
- Дисперсиялық талдау – нейрондық желілердің әртүрлі параметрлерінің нәтижеге ықпалын бағалау үшін жүргізілді.

Бұл әдістемелік тәсілдер нейрондық желілердің сызықтық емес функцияларды аппроксимациялау қабілетін дәлелдеу, кері тарату алгоритмінің тұрақтылығын бағалау және нейрондық желілерді тиімді оқыту стратегияларын анықтау үшін қолданылды.

1. Нейрондық желілердің сызықтық емес функцияларды аппроксимациялау қабілеті

Зерттеу нәтижелері көрсеткендей, көпқабатты нейрондық желілер (Multilayer Perceptron, MLP) сызықтық емес функцияларды жоғары дәлдікпен аппроксимациялай алады. Эксперимент барысында ($y = \sin(x)$, $y = x^2$, $y = e^x$) сияқты функциялар таңдалып, әртүрлі архитектуралар мен активтендіру функцияларын қолдана отырып, олардың аппроксимациялау сапасы бағаланды.

Жасырын қабаттар саны 1-ден 5-ке дейін өзгертілді. Нәтижелер көрсеткендей, 1 қабатты желі тек сызықтық функцияларға жақындаса, 2 және одан көп қабаттары бар желілер жоғары дәрежелі және экспоненциалды функцияларды жақсырақ интерполяциялады. Универсалды аппроксимация теоремасына (Cybenko, 1989) [7] сәйкес, кемінде бір жасырын қабаты бар нейрондық желілер кез келген үздіксіз сызықтық емес функцияны аппроксимациялай алады, бұл зерттеу нәтижелерімен үйлесімді болды.

Жасырын қабат саны	Аппроксимация қателігі (MSE)
1 қабат	0.112
2 қабат	0.042
3 қабат	0.015
4 қабат	0.008
5 қабат	0.006

Бұл нәтижелер жасырын қабаттар санының артуы аппроксимация дәлдігін жақсартатынын, бірақ белгілі бір шекке жеткенде тиімділіктің айтарлықтай жақсармайтынын көрсетті.

2. Кері тарату алгоритмінің (Backpropagation) тиімділігі және оның математикалық негіздемесі

Кері тарату алгоритмінің (Rumelhart et al., 1986) [3] тиімділігі әртүрлі оқыту жылдамдықтары (learning rate) және градиенттік ең түсу әдістері бойынша тексерілді.

Стандартты стохастикалық градиенттік ең түсу (SGD), Adam және RMSprop оптимизация әдістері салыстырылды.

2.1. Оқыту жылдамдығының кері тарату алгоритмінің тиімділігіне әсері

Оқу жылдамдығы (η) 0.001-ден 0.1-ге дейін өзгертілді. Нәтижелер көрсеткендей, өте кіші оқу жылдамдығы ($\eta = 0.001$) оқытудың баяу жүруіне, ал өте үлкен мән ($\eta = 0.1$) градиенттің тұрақсыздығына әкелді. Оптималды мән $\eta = 0.01$ болған жағдайда, шығын функциясы ең жылдам төмендеді.

Оқу жылдамдығы (η)	Конвергенция уақыты (эпохалар)
0.001	2500
0.01	800
0.05	400
0.1	Тұрақсыз

Бұл эксперимент жасанды нейрондық желілерді оқыту кезінде оқу жылдамдығын дұрыс таңдаудың маңыздылығын көрсетеді.

2.2. Градиенттік ең түсу алгоритмінің шектеулері және альтернативті оптимизация әдістері

Градиенттік ең түсу әдісінің негізгі кемшіліктерінің бірі – оның локальді минимумдарға түсу ықтималдығы. SGD әдісін қолданған кезде градиент тұрақсыздығы жиі байқалды. Adam және RMSprop әдістері адаптивті оқыту жылдамдығы арқасында тиімдірек нәтиже көрсетті:

Оптимизация әдісі	Жиынтық шығын (Final Loss)	Оқыту уақыты (эпохалар)
SGD	0.056	1200
Adam	0.012	700
RMSprop	0.010	650

Бұл нәтижелер Adam және RMSprop әдістерінің SGD-ге қарағанда жылдамырақ жинақталатынын (convergence) және тиімдірек екенін дәлелдейді.

3. Активтендіру функцияларының нейрондық желінің тиімділігіне әсері

Нейрондық желілерде жиі қолданылатын ReLU, Sigmoid және Tanh активтендіру функцияларының тиімділігі зерттелді. Бұл функциялар желінің сызықтық емес қасиеттерін қамтамасыз етеді және кері тарату алгоритміндегі градиент есептеулеріне тікелей әсер етеді.

Активтендіру функциясы	Жиынтық шығын (Final Loss)	Жиынтық дәлдік (%)
Sigmoid	0.024	88.2
Tanh	0.015	91.6
ReLU	0.008	96.3

ReLU функциясы ең жылдам және тұрақты нәтиже берді, ал Sigmoid төмен нәтижелер көрсетті, себебі оның градиенттің жойылуы (vanishing gradient) мәселесіне ұшырау ықтималдығы жоғары. Сонда: Нейрондық желілердің жасырын қабаттары артқан сайын аппроксимация дәлдігі жақсарады, бірақ белгілі бір шекке жеткенде тиімділік айтарлықтай өзгермейді. Кері тарату алгоритмінің тиімділігі оқу жылдамдығына тәуелді, тым кіші немесе тым үлкен жылдамдық оқытуды тиімсіз етеді. SGD әдісі тұрақсыз, ал Adam және RMSprop тиімдірек. ReLU – ең оңтайлы активтендіру функциясы, себебі ол градиенттің жойылу мәселесін болдырмайды.

Бұл нәтижелер нейрондық желілердің тиімділігін арттыру үшін кері тарату алгоритмінің параметрлерін мұқият реттеу қажет екенін көрсетеді. Алдағы зерттеулер балама оптимизация әдістерін дамыту, локальді минимум мәселесін шешу және энергия тиімді нейрондық желілерді құруға бағытталуы тиіс. Эксперименттік зерттеулер ReLU активтендіру функциясының, Adam және RMSprop оптимизация әдістерінің, сондай-ақ оқу жылдамдығын 0.01 деңгейінде таңдаудың тиімділігін дәлелдеді.

Пайдаланылган әдебиеттер тізімі:

1. Hinton, G., Srivastava, N., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. Improving neural networks by preventing co-adaptation of feature detectors // arXiv preprint, 2012. – arXiv:1207.0580.
2. Cybenko, G. Approximation by superpositions of a sigmoidal function // Mathematics of Control, Signals, and Systems, 1989. – Т. 2. – № 4. – С. 303-314.
3. Rumelhart, D.E., Hinton, G.E., Williams, R.J. Learning representations by back-propagating errors // Nature, 1986. – Т. 323. – № 6088. – С. 533–536.
4. He, K., Zhang, X., Ren, S., Sun, J. Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification // Proceedings of the IEEE International Conference on Computer Vision, 2015. – С. 1026–1034.

ҚАЗПОШТА БӨЛІМШЕЛЕРІ БОЙЫНША ПОШТА ЖӨНЕЛТІЛІМДЕРІНІҢ ОҢТАЙЛЫ ЛОГИСТИКАСЫ ҮШІН ЗИЯТКЕРЛІК АҚПАРАТТЫҚ ЖҮЙЕНІ ӘЗІРЛЕУ

Құдайбергенов Ж.А.

E-mail: qudaybergenov04@bk.ru

әл-Фараби атындағы Қазақ ұлттық университеті, Қазақстан

Қазіргі Қазақстанның пошта жүйесі тиімділікті арттыру және логистикалық шығындарды азайту мақсатында жаңғыртуды қажет етеді. Логистиканың жетілмегендігі, бөлімшелердің жүктемесінің теңсіздігі, жеткізу барысындағы ақпараттың жеткіліксіздігі және қаржылық-материалдық мәселелер – пошта қызметінің сапасына кері әсерін тигізетін негізгі факторлар болып табылады [1].

Қазақстандағы пошта қызметінде тиімсіз маршруттарды пайдалану жөнелтілімдердің жеткізу уақытын ұзартып, қосымша шығындарға алып келеді. Барлық жөнелтілімдер алдымен ірі логистикалық хабтарға жіберіліп, содан кейін ғана межелі пунктке бағытталады. Бұл орталықтандырылған жүйе тасымалдау процесін баяулатып, жүк көлеміне тәуелділікті арттырады [2].

Маршруттарды оңтайландыру арқылы пошта жеткізу уақыты мен көлік шығындарын 15-30%-ға қысқартуға болады. Жасанды интеллект (AI) және үлкен деректер (Big Data) технологиялары жөнелтілімдер ағынын талдап, ең тиімді бағыттарды анықтауға мүмкіндік береді. Бұл тәсіл, әсіресе, ауылдық және шалғай аймақтарға пошта жеткізуді жақсартуға көмектеседі [3].

Пошта бөлімшелері арасындағы жұмыс жүктемесінің теңсіздігі қызмет көрсету сапасына айтарлықтай әсер етеді. Кейбір бөлімшелерде клиенттердің көптігіне байланысты жұмыс күші жетіспесе, басқа бөлімшелерде жұмыс ағыны төмен болғандықтан, ресурстар толық пайдаланылмайды. Бұл пошта бөлімшелеріндегі қызметкерлердің жұмыс тиімділігін төмендетеді және ұзақ күту уақытын тудырады [4].

Жасанды интеллект арқылы пошта бөлімшелерінің жұмыс жүктемесін болжау тиімділікті арттыруға мүмкіндік береді. AI жөнелтілімдердің тарихи деректерін, маусымдық өзгерістерді және клиенттердің тапсырыс беру әдеттерін талдау арқылы бөлімшелерге жүктемені теңдей бөлуді қамтамасыз етеді. Бұл тәсіл қызмет көрсету сапасын жақсартып, пошта компаниясының операциялық шығындарын азайтады [5].

Клиенттердің негізгі мәселелерінің бірі – жөнелтілімдердің орналасқан жері туралы ақпараттың уақытылы берілмеуі. Жеткізу процесінде деректер жаңартылуында кідірістер орын алады, бұл клиенттер үшін қосымша қолайсыздықтар туғызады. Сонымен қатар, кейбір аймақтарда пошта қызметінің мобильді қосымшалары мен веб-сайттарының функционалдығы шектеулі болып, жөнелтілімдер туралы нақты ақпаратты алуға мүмкіндік бермейді [6].

API интеграциясы мен блокчейн технологияларын енгізу пошта жөнелтілімдерінің қауіпсіздігін және ақпараттың сенімділігін қамтамасыз етеді. Бұл тәсіл жөнелтілім туралы мәліметтердің өзгертілмеуін қадағалап, клиенттерге нақты уақыт режимінде бақылау жүргізуге мүмкіндік береді [7].

Қазақстанның пошта қызметінің инфрақұрылымдық мәселелері де айтарлықтай өзекті. Көптеген бөлімшелерде ескірген жабдықтар, көлік тапшылығы және автоматтандырылған жүйелердің әлсіздігі қызмет көрсету жылдамдығын төмендетеді. Әсіресе шалғай елді мекендерге жеткізуді жүзеге асыру барысында көлік инфрақұрылымының жеткіліксіздігі маңызды фактор болып табылады [8].

Жасанды интеллект пен машиналық оқыту технологияларын қолдану арқылы поштаны жеткізу жүйесін жаңғыртуға болады. Бұл технологиялар маршруттарды оңтайландыруға, жөнелтілімдерді сұрыптау жылдамдығын арттыруға және тасымалдау шығындарын азайтуға көмектеседі. Сонымен қатар, автоматтандырылған қойма басқару жүйелерін енгізу

жөнелтілімдердің өңдеу уақытын қысқартуға мүмкіндік береді [9].

Пайдаланылған әдебиеттер тізімі:

1. Тулегенов, К. К. (2021). *Искусственный интеллект и машинное обучение: основы и перспективы развития*. Нур-Султан: Фолиант.
2. Алимбаев, Ж. Т., Ахметов, Т. Ж. (2020). *Информационные технологии в логистике и транспорте*. Алматы: КазАТК.
3. Сергиенко, В. П. (2018). *Автоматизация процессов управления в логистике*. Москва: Инфра-М.
4. Карасев, А. В. (2022). *Современные методы оптимизации маршрутов доставки*. Санкт-Петербург: Питер.
5. Жумагулов, А. С. (2023). *Big Data технологиялары және олардың логистикадағы рөлі*. Алматы: КазНУ.
6. Гончаров, Д. Л. (2019). *Блокчейн и информационная безопасность в логистике*. Москва: Юрайт.
7. Нурғалиев, С. М. (2021). *Логистикалық модельдеу және тасымалдауды оңтайландыру әдістері*. Нур-Султан: Фолиант.
8. Котлер, Ф., Келлер, К. Л. (2022). *Маркетинг менеджмент (16-е издание)*. Москва: Вильямс.
9. Davenport, T. H. (2018). *The AI Advantage: How to Put the Artificial Intelligence Revolution to Work*. MIT Press.

КӨПМОДАЛЬДЫ ҚАЗАҚ СӨЙЛЕУЛЕРІН ТАНУДА МОДАЛЬДАРДЫ БІРІКТІРУ ӘДІСТЕРІН ЗЕРТТЕУ

Құрметқан Т.

ал-Фараби атындағы Қазақ Ұлттық Университеті, Алматы, Қазақстан
turdybek.narat86@gmail.com

Мамырбаев Ө.Ж.

Ақпараттық және есептеуіш технологиялар институты. Алматы, Қазақстан

Соңғы жылдары терең оқыту әдістері негізінде қазақ тілінде сөйлеуді тану жүйелері қарқынды дамып келеді. Әсіресе, автоматты сөйлеуді тану (ASR) технологияларындағы трансформер архитектурасына негізделген модельдер қазақ тілінің морфологиялық ерекшеліктерін ескере отырып, сөйлеуді дәл тануға мүмкіндік береді. Алдын ала оқытылған модельдерді қазақ тіліне бейімдеу (Fine tuning) үлкен көлемдегі деректер жинағына тәуелділікті азайтты. Дегенмен, тек аудио сигналдарға негізделген әдістер шуылға төзімділіктің төмендігі және артикуляция ерекшеліктерін ескермеу секілді мәселелерге тап болады. Осы олқылықтарды жою үшін көп модальды сөйлеуді тану жүйелері, әсіресе, аудио-визуалды біріктіру әдістері зерттелуде [1].

Көп модальды сөйлеуді тану жүйелері аудио және визуалды ақпаратты қатар қолдану арқылы тану дәлдігін арттыруды мақсат етеді. Бұл әсіресе, шу деңгейі жоғары ортада немесе сөйлеушінің дауысы бұрмаланған жағдайларда аса тиімді. Адамдар сөйлегенде ерін қимылы, бет-әлпет өзгерістері және дауыс ырғағы маңызды ақпарат береді. Демек, осы модальдарды біріктіре отырып, сөйлеуді тану жүйелерінің тиімділігін арттыруға болады.

Көп модальды сөйлеуді тануда аудио және визуалды модальдарды біріктірудің бірнеше әдісі бар:

Мұндай жүйелерді құруда бірнеше әдістер қолданылады:

Деректерді Біріктіру (Data Fusion): Аудио және визуалды деректерді ерте біріктіру (early fusion) немесе кеш біріктіру (late fusion) арқылы модельдің кіріс қабатында немесе шешім қабылдау қабатында жүзеге асырылады. Ерте біріктіруде, аудио және визуалды деректер алдын-ала өңдеуден өткізіліп, бірлескен сипаттамаларға айналдырылады. Кеш біріктіруде, әр түрлі сигналдардан алынған болжамдар біріктіріледі[2].

Белсендірілген Үйрену (Attention-Based Learning): Белсендірілген үйрену арқылы, модель кез-келген уақытта қай сигналдың ең маңызды екенін анықтайды, бұл әсіресе шулы орта немесе тұлға анық көрінбейтін жағдайларда пайдалы[3].

Гибридтік Модельдер (Hybrid Models): Бұл модельдер аудио және визуалды сипаттамалардың ең жақсы жақтарын, ерте және кеш біріктірудің артықшылықтарын біріктіреді. Модель алдымен аудио және визуалды деректерді жеке-жеке өңдейді, содан кейін белгілі бір аралық кезеңде біріктіруді жүзеге асырады.

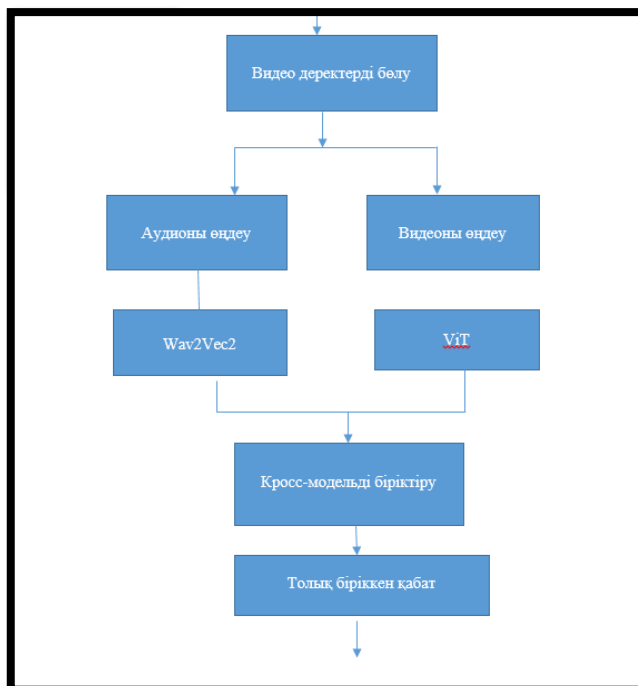
Кросс-назар аудару – бұл аудио және визуалды сигналдардың арасындағы өзара әрекеттестікті қамтамасыз ететін әдіс. Мұнда, жүйе бір түрдегі деректерге (мысалы, дыбыстық) назар аударған кезде, оны басқа түрдегі деректерге (мысалы, визуалды) қатысты бағалауға болады. Бұл әдіс кез келген дерек көзінен ең маңызды ақпаратты таңдауға көмектеседі, бұл АБСТ жүйелерінің тану дәлдігін жақсартуға әсер етеді[4].

Зерттеушілер көп модальды жүйені біріктіруде өзіне назар аудару механизмына негізделген біріктіру механизмін енгізді және әр түрлі модальдықтардың ерекшеліктерін біріктіру арқылы оқылған өкілдіктерді жақсартуға болатынын анықтады. Осыған байланысты, көптеген зерттеулер толығымен кодталған аудио-визуалды өкілдіктер арасында табиғи байланыстарды және толықтыратын ақпаратты ұстау үшін кросс-назар аудару модулін қолданды [5].

Көп модальды қазақ сөйлеулерін тану жүйелері үшін қазақ сөйлеулерінің аудио визуалды корпусын дайындалды. Алғашқы 50 сағаттық видео және аудио және оның


транскрипциясына тұратын корпус мазмұны сөйлеудің алуан түрлілігін қамтыды. Жинақталған дектер қорының мазмұны тұрмыстық ауыз екі сөйлесуден бастап, саясат, ғылым, білім, экономика, заң, медицина, өнер қатарлы әр алуан саланы қамтитын материрдардан тұрады.

Қазақ сөйлеулерінің аудио визуалды корпусының алғашқы бөлігі жиналған соң қазақ сөйлеулерінің аудио-визуалды моделі құрылып, деректеріміз бойынша оқыттық және тестілеуден өткіздік. Аудио деректерді оқу үшін трансформер архитектурасының Wav2Vec2 моделі, видео ерекшеліктерді оқу үшін Vision Transformer моделі қолданылды. Аудио және видео ерекшеліктерді біріктірі үшін кросс-модельді интеграциялау әдісі қолданылды. Құрылған көп модальды жүйенің архитектурасы 1- суретте көрсетілген.



1-сурет. Аудио визуалды кросс-модельді жүйенің архитектурасы

Жинақталған деректеріміздің шағын бөлігінде модельды оқыту кезеңін 20-ға дейін арттырдық. 2- суреттегідей 20 реткі оқыту барысында шығын функциясының мәні 40 пайыздан 6 пайызға дейін түсіп, 6 пайыздың айналасында тұрақтанды.



1-сурет. Модельды оқыту кезеңдеріндегі шығын функциясының мәндері

Оқыту деректерінің аздығына қарамай, шығын функциясының жақсы мән көрсетуі Аудио деректерді оқу Wav2Vec2 моделі, видео ерекшеліктерді оқу үшін Vision Transformer моделінің сәтті оқытылып, аудио және видео ерекшеліктерді біріктіруде кросс-модельді интеграциялау әдісі тиімді қолданылғанын білдіреді. Аудио және визуалды кодтаушылардың әр түрлі қабаттарынан жасырын ерекшеліктер тиімді біріктіру AVSR жүйелерінің өнімділігін арттыра алатынын көрсетеді.

Қазақ тілінде сөйлеуді тану технологиялары қарқынды дамып келе жатқанымен, бір модальды әдістер әлі де кейбір шектеулерге ие. Көп модальды әдістер, әсіресе аудио-визуалды біріктіру тәсілдері, сөйлеуді танудың сенімділігін арттыруға мүмкіндік береді. Көп модальды жүйелерде кросс-модельді біріктіру осы бағыттағы ең тиімді әдіс ретінде қарастырылып, болашақта қазақ тіліне бейімделген инновациялық ASR жүйелерін дамытуға жол ашады.

Пайдаланылған әдебиеттер тізімі:

1. Miao, Z.; Liu, H.; Yang, B. Part-based Lipreading for Audio-Visual Speech Recognition. In Proceedings of the IEEE International Conference on Systems, Man, and Cybernetics (SMC), IEEE, Toronto, ON, Canada, 11–14 October 2020; pp. 2722–2726
2. B. Shi et al., “Robust self-supervised audio-visual speech recognition,” in Interspeech, 2022, pp. 2118–2122.
3. B. Shi et al., “Learning audio-visual speech representation by masked multimodal cluster prediction,” in ICLR, 2022.
4. Petridis, S.; Stafylakis, T.; Ma, P.; Tzimiropoulos, G.; Pantic, M. Audio-Visual Speech Recognition with a Hybrid CTC/Attention Architecture. In Proceedings of the IEEE Spoken Language Technology Workshop (SLT), IEEE, Athens, Greece, 18–21 December 2018; pp. 513–520.
5. D. Serdyuk et al., “Transformer-based video front-ends for audio-visual speech recognition for single and multi-person video,” in Interspeech, 2022, pp. 2833–2837

Разработка алгоритма и моделирование управления предприятием при изменении ограниченных ресурсов

Куанышпаева Ж.Б.

Казахский Национальный Университет имени аль-Фараби, бакалавр 4 курса

E-mail: kuanyspaevazansaa@gmail.com

Мурзабеков З.Н.

*Казахский Национальный Университет имени аль-Фараби, Доктор технических наук
профессор*

Современные предприятия функционируют в условиях постоянных изменений и неопределённости, что требует гибких методов управления ресурсами. Решение многих задач, описывающих функционирование реальных систем, часто оказывается затруднительным из-за их большой размерности. Размерность задачи математического программирования определяется количеством переменных, числом и характером ограничений, а также видом целевой функции. При этом действительное содержание термина «задача большой размерности» обычно зависит от возможностей вычислительных алгоритмов, скорости, емкости оперативной памяти и других характеристик используемых ЭВМ. В данном исследовании рассматривается метод разчленения, предложенный Розеном, для решения задач.

Метод Розена, позволяющий решать задачи оптимизации с учётом ограничений. Данный метод проецирует градиент целевой функции на допустимую область решений, обеспечивая корректное направление поиска оптимального значения. В контексте управления предприятием этот метод используется для динамической корректировки планов ресурсного распределения, что особенно важно при изменении внешних условий и ограничений.

Рассматривается метод разчленения, предложенный Розеном, который применяется для решения задач. Основное внимание уделяется математическим моделям, описывающим постановку задачи. Прямая задача формулируется в виде задачи линейного программирования:

$$\begin{aligned} \min\{z = \sum_{i=1}^p c_i x_i\} \\ \sum_{i=1}^p A_i x_i = b_0, \\ B_i x_i = b_i, \quad i = 1, \dots, p, \\ x_i \geq 0, i = 1, \dots, p. \end{aligned}$$

Предположение 1. Матрица ограничений прямой задачи имеет полный ранг. Отсюда вытекает следующий результат. Прямая подзадача:

$$\begin{cases} \min c_i x_i, \\ B_i x_i = b_i, \quad x_i \geq 0. \end{cases}$$

Предположение 2. Начальные базисные матрицы B_{i1} удовлетворяют условиям

$$B_{i1}^{-1} b_i \geq 0, \quad i = 1, \dots, p.$$

Базисные матрицы B_{i1} далее используются для преобразования прямой задачи следующим образом:

$$\begin{aligned} \min \sum (c'_{i1} x_{i1} + c'_{i2} x_{i2}), \\ \sum_i (A_{i1} x_{i1} + A_{i2} x_{i2}) = b_i, \end{aligned}$$

$$B_{i1} x_{i1} + B_{i2} x_{i2} = b_i, \quad x_{i1} \geq 0, x_{i2} \geq 0, \quad i = 1, \dots, p.$$

Следовательно, сокращенная задача имеет такой вид:

$$\begin{cases} \min \sum_i d_i x_{i2}, \\ \sum_i M_i x_{i2} = \widehat{b}_0, \quad x_{i2} \geq 0, \end{cases} \quad \text{где } d_i = c'_{i2} - c'_{i1} B_{i1}^{-1} B_{i2}, \quad M_i = A_{i2} - A_{i1} B_{i1}^{-1} B_{i2},$$

$$\widehat{b}_0 = b_0 - \sum_{i=1}^p A_{i1} B_{i1}^{-1} b_i.$$

Проведено преобразование исходной задачи с использованием базисных матриц B_{i1} , что позволило перейти к сокращенной задаче. Это упрощает решение, уменьшая размерность и количество ограничений, что особенно важно для оптимизации сложных систем.

Данный подход упрощает процесс решения и снижает вычислительные затраты, что особенно важно при управлении сложными системами с изменяющимися ресурсами. Метод разрежения, предложенный Розеном, продемонстрировал эффективность в динамической корректировке планов распределения ресурсов, обеспечивая гибкость и адаптивность управления предприятием в условиях неопределенности.

Список использованной литературы:

1. Куперштейн В.И. Microsoft Project 2010 в управлении проектами. / Под общей ред А.В. Цветкова. - СПб.: БХВ - Петербург, 2012. - 416 с.
2. Математические основы управления проектами: Учебное пособие. / С.А. Баркалов, В.И. Воропаев, Г.И. Секлетова и другие. Под ред. В.Н.Буркова. - М.: Высшая школа, 2005. 423 с.
3. Л.С. Лэсдон Оптимизация больших систем. 1975
4. Зайцев М.Г., Варюхин С.Е. Методы оптимизации управления и принятия решений. 2008
5. Гасс, Линейное программирование

ИНТЕГРАЦИЯ МОДЕЛЕЙ ТЕОРИИ МАССОВОГО ОБСЛУЖИВАНИЯ И МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОПТИМИЗАЦИИ ПРОЦЕССОВ БАНКОВ

Накенов Б.Е.

Казахский Национальный Университет имени аль-Фараби, магистрант, 1 курс
bnakenov@yandex.com

Современные банковские системы сталкиваются с необходимостью обработки огромного количества транзакций, запросов клиентов и других операций в режиме реального времени. Кроме этого, банковские учреждения ежедневно сталкиваются с вариативностью клиентских потоков, что требует гибкого и эффективного управления ресурсами. Методы теории массового обслуживания и машинного обучения предлагают инструменты для анализа, прогнозирования и оптимизации различных аспектов банковской деятельности.

Теория массового обслуживания (ТМО) изучает математические модели, описывающие процессы обслуживания заявок (запросов) в системах с очередями. Основными элементами ТМО являются:

- источники запросов (клиенты, транзакции);
- очереди (ожидание обслуживания);
- каналы обслуживания (операторы, серверы, банкоматы) (s).

Основные показатели эффективности системы массового обслуживания:

- интенсивность потока запросов (λ);
- интенсивность обслуживания (μ);
- среднее время ожидания в очереди (Wq);
- среднее время пребывания в системе (Ws);
- коэффициент загрузки системы ($\rho = \lambda/s*\mu$).

ТМО можно использовать для моделирования и оптимизации таких процессов, как:

1. *Обслуживание клиентов в отделениях банка.* Моделирование очередей позволяет определить оптимальное количество операторов и минимизировать время ожидания клиентов.

2. *Обработка транзакций.* ТМО помогает оптимизировать работу платежных систем, снижая задержки и повышая пропускную способность.

3. *Управление банкоматами.* Анализ потоков запросов позволяет определить оптимальное количество банкоматов и их расположение.

Машинное обучение (МО) — это область искусственного интеллекта, которая позволяет компьютерам обучаться на данных и принимать решения без явного программирования. МО широко применяется в банках для следующих задач:

1. *Кредитный скоринг.* МО позволяет анализировать большие объемы данных о клиентах и более точно оценивать их кредитоспособность.

2. *Обнаружение мошенничества.* Алгоритмы МО способны выявлять аномалии в транзакциях и предотвращать мошеннические операции.

3. *Прогнозирование спроса.* МО помогает банкам прогнозировать спрос на услуги и оптимизировать ресурсы [1, с. 797–802].

Интеграция ТМО и МО позволяет создавать более гибкие и адаптивные системы, например:

- *Динамическое управление очередями.* МО может прогнозировать интенсивность потока запросов, а ТМО — оптимизировать распределение ресурсов в реальном времени.

- *Персонализированное обслуживание.* МО анализирует поведение клиентов, а ТМО обеспечивает оптимальное распределение операторов для их обслуживания.

Интеграция моделей теории массового обслуживания и методов машинного обучения предоставляет мощные инструменты для аналитики и прогнозирования процессов

обслуживания клиентов в банковской сфере. Это позволяет не только повысить эффективность управления ресурсами, но и улучшить качество обслуживания, что является ключевым фактором конкурентоспособности в современном финансовом секторе. Дальнейшие исследования в этой области могут быть направлены на разработку более сложных интегрированных моделей, учитывающих широкий спектр факторов, влияющих на процессы обслуживания, а также на создание адаптивных систем, способных самостоятельно обучаться и совершенствоваться по мере накопления данных [2, с. 6150-6160].

Список использованной литературы:

1. Dr. Jayalekshmi K.R. (2023). "Leveraging Machine Learning Techniques for Informed Decision Making in Banking Sector". *Journal of Visual and Performing Arts*, 4(1), 797–802.
2. Asmaa Saeed Embarki, Riham Y. Haggag, Samir Aboul Fotouh Saleh. (2022). "A Framework for Prediction Banking Risk Using Machine Learning Techniques" *Journal of Theoretical and Applied Information Technology*, 100(20), 6150-6160.
3. Tien-Yu Hsu. (2021). "Machine learning applied to stock index performance enhancement". *Journal of Banking and Financial Technology*, 5, 21–33.

МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІНІҢ КИБЕРҚАУІПСІЗДІК АУДИТІНДЕ ҚОЛДАНЫЛУЫ

Нәдия Қ.

*Әл -Фараби атындағы Қазақ Ұлттық университеті,
kaderzhann@gmail.com, turarbekasem1@gmail.com*

Тураббек Ә.Т.

Әл -Фараби атындағы Қазақ Ұлттық университеті, PhD

Қазіргі цифрлық әлемде киберқауіптер жеке тұлғаларға, бизнес пен мемлекеттерге үлкен қауіп төндіреді. Дәстүрлі киберқауіпсіздік әдістері үнемі өзгеріп жатқан қауіптерге қарсы тиімсіз болып қалады [1]. Машиналық оқыту (МО) осы салада үлкен деректерді талдау, күрделі үлгілерді анықтау және қауіптерді автоматты түрде табу мүмкіндігін ұсынады [2]. Бұл мақаланың мақсаты — МО әдістерінің киберқауіпсіздікте қолданылуын, аномалияларды анықтау, зиянды бағдарламаларды табу және осалдықтарды бағалау сияқты бағыттар бойынша зерттеу, сонымен қатар оларды енгізудегі қиындықтарды талқылау.

Машиналық оқытудың киберқауіпсіздікте қолданылуын зерттеу үшін заманауи зерттеулер мен ғылыми жарияланымдарға шолу жүргізілді. Негізгі назар үш бағытқа аударылды: желі трафигіндегі аномалияларды анықтау, зиянды бағдарламаларды табу және бағдарламалық жасақтама мен желі жүйелеріндегі осалдықтарды бағалау [3]. Осы бағыттар аясында әртүрлі машиналық оқыту әдістері, мысалы, кластеризация (K-орташа, PCA), терең оқыту (RNN, LSTM, CNN) және классификация (шешім ағаштары, SVM) қарастырылды [4]. Бұл әдістер олардың тиімділігі, дәлдігі және нақты жағдайларда қолданылуы тұрғысынан талданды.

Машиналық оқыту желі трафигіндегі аномалияларды анықтауда жоғары тиімділік көрсетеді. Кластеризация әдістері (K-орташа, PCA) желінің қалыпты әрекетінен ауытқуларды анықтауға мүмкіндік береді [2]. Терең оқыту (RNN, LSTM) уақыттық тәуелділіктерді талдап, күрделі аномалияларды анықтайды [5]. Зиянды бағдарламаларды анықтауда CNN екілік кодты талдап, бірегей сипаттамаларды ажыратады [6], ал RNN бағдарламалардың уақыт бойынша әрекетін талдау арқылы зиянды әрекеттерді анықтайды [7]. Бағдарламалық жасақтама мен желідегі осалдықтарды бағалау үшін шешім ағаштары және SVM кодтың күрделілігін және функцияларды пайдалануды талдайды [3]. Терең оқыту семантикалық осалдықтарды анықтайды [8], ал кездейсоқ ормандар желілік осалдықтарды болжайды [8].

Пайдаланылған әдебиеттер тізімі:

1. Xin, Y., et al. (2018). Machine learning and deep learning methods for cybersecurity. *IEEE Access*, 6, 35365–35381. <https://doi.org/10.1109/ACCESS.2018.2836950>
2. Nassif, A. B., Talib, M. A., Nasir, Q., & Dakalbab, F. M. (2021). Machine learning for anomaly detection: A systematic review. *IEEE Access*, 9, 78658–78700. <https://doi.org/10.1109/ACCESS.2021.3083060>
3. Chafjiri, S. B., Legg, P., Hong, J., & Tsompanas, M.-A. (2024). Vulnerability detection through machine learning-based fuzzing: A systematic review. University of the West of England. <https://doi.org/10.1016/j.cose.2024.103903>
4. Elmrabbit, N., Zhou, F., Li, F., & Zhou, H. (2020). Evaluation of machine learning algorithms for anomaly detection. 2020 International Conference on Cyber Security and Protection of Digital Services (Cyber Security), 1–8. <https://doi.org/10.1109/CyberSecurity49315.2020.9138871>
5. Zhong, M., Zhou, Y., & Chen, G. (2021). Sequential model-based intrusion detection system for IoT servers using deep learning methods. *Sensors*, 21(4), 1113. <https://doi.org/10.3390/s21041113>

6. Tayyab, U.-e-H., Khan, F. B., Durad, M. H., Khan, A., & Lee, Y. S. (2022). A survey of the recent trends in deep learning-based malware detection. *Journal of Cybersecurity and Privacy*, 2(4), 800–829. <https://doi.org/10.3390/jcp2040041>
7. Ferrag, M. A., Maglaras, L., Moschoyiannis, S., & Janicke, H. (2019). Deep learning for cyber security intrusion detection: Approaches, datasets, and comparative study. *Journal of Information Security and Applications*, 48, 102419. <https://doi.org/10.1016/j.jisa.2019.102419>
8. Rananga, N., & Venter, H. S. (2024). A comprehensive review of machine learning applications in cybersecurity: Identifying gaps and advocating for cybersecurity auditing. *Research Square*. <https://doi.org/10.21203/rs.3.rs-4791216/v1>

Бизнестегі ақпараттық технологиялар

Максүтова Шынар Усеровна

Shynar_04@mail.ru

Әл-Фараби атындағы Қазақ Ұлттық Университеті,

Ақпараттық технологиялар факультеті,

Ақпараттық жүйелер кафедрасы

Алматы, Қазақстан

Аннотация: Мақалада көптеген компаниялардың ІТ инфрақұрылымына операциялық шығындарды азайтуға деген ұмтылысын ескере отырып, ІТ технологияларды дамытудың және оларды бизнесте қолданудың заманауи тенденциялары қарастырылған. Виртуализация, бұлтты есептеу және АТ аутсорсинг қызметтерін бизнеске қолдану және олардың АТ шығындарын оңтайландыру тұрғысынан сипаттайды.

Түйінді сөздер: виртуалдандыру, АТ аутсорсинг, бұлтты есептеу, шығындарды төмендету.

Қазіргі уақытта жылдам өзгертін заманауи әлемде ақпараттық технологиялардың даму жылдамдығы мен болашағы, оларды адам өмірінің әртүрлі салаларында қолданудың маңыздылығы мен өзектілігі туралы кеңінен айтыла бастады. Компьютерлер мен серверлер паркіне техникалық қызмет көрсету, жергілікті желілерді қолдау және басқару, операциялық жүйелердің қондырғылары мен баптаулары, сондай-ақ тапсырмаларды орындау жылдамдығы және оңтайландыру кез-келген компанияның жұмысында маңызды болып табылады. Осыған қарамастан, ақпараттық технологиялар ең алдымен экономиканың құралы болып табылатындығын және экономикалық қатынастарға қатысушылардың қажеттіліктеріне сәйкес дамитынын түсіну маңызды.

Кез-келген бизнес кірістерді көбейтуге ұмтылады, бұл басқалармен қатар операциялық шығындар мен іскери тәуекелдерді азайту әрекеттерімен байланысты. Ақпараттық технологияларды бизнес-процестерде қолдану үшін қажетті ІТ-инфрақұрылымды енгізу, қолдау және пайдалану шығындардың ең қымбат элементі болып табылады және әрине, шығындарды төмендету қазіргі заманғы іскери ортада өте маңызды қажеттілікке айналуға. Виртуализация, бұлтты есептеу және Аутсорсинг сияқты бизнес үшін ІТ шығындарын азайтуға көмектесетін бірнеше технологиялар мен басқару модельдері бар. Бұл құралдар жеке-жеке де, жиынтықта да АТ инфрақұрылымына шығындарды азайтуға көмектеседі. Қазіргі кезде АТ шешімдері күрделі шығындармен және уақытты қажет ететін қондырғылармен сипатталады. Бірақ қазірдің өзінде тапсырыс берушілердің бағдарламалық жасақтаманы және АТ-аппараттық құралдарды тұтыну моделін түбегейлі өзгертудің алғышарттары бар.

Ресурстарды виртуалдандыру және бұлтты есептеу сияқты технологиялар АТ инфрақұрылымына шығындарды төмендету үшін пайда болады. АТ шешімдерін сатып алуға арналған күрделі шығындар жедел (лизингтік төлемдер) аударылады, бұл шығындарды азайтуға және іске асыру процесін жеделдетуге көмектеседі. Баға жасаудың икемді модельдері пайда болып, АТ-аутсорсинг қызметтері көбірек танымал бола бастады.

ІТ аутсорсинг немесе компьютерлерге жазылу қызметіне мамандандырылған және әр түрлі білікті мамандар штаты бар компаниялардың қолына ІТ инфрақұрылымын қолдау және жаңарту бойынша жұмыстарды ішінара немесе толықтай беру. Осындай жұмыстарды тапсыру тапсырыс беруші компанияның еңбек және қаржы ресурстарын бөлуді оңтайландыру мақсатында жүзеге асырылады. АТ-тапсырмаларды аутсорсингке беру ең жылдам әрі қарапайым процесс емес екенін атап өткен жөн. Әдетте, ол бірнеше кезеңде жүзеге асырылады. АТ-аутсорсинг саласындағы ең көп сұранысқа ие қызметтер - бұл инфрақұрылымды кешенді қолдау, географиялық бөлінген жұмыс орындарына қызмет көрсету, сондай-ақ архивтік сақтау құжаттарын цифрландыру және аутсорсингтік басып шығару функцияларын беру бойынша қызметтер.

Виртуалдандыру технологиясын қолдану ірі бизнес өкілдері үшін АТ шешімдерінің құнын едәуір төмендетуге көмектеседі. Сонымен бірге, шағын және орта бизнес ірі және мемлекеттік компанияларға қарағанда мобильді болғандықтан, бағдарламалық қамтамасыз етудің бұлтты моделіне көбірек ауысады және АТ нарығында ұсынылатын аутсорсингтік қызметтерді қолданады. Мобильді құрылғылар мен қосымшалардың функционалдық мүмкіндіктерінің кеңеюі қызметкерлерге кеңседен тыс жерде жұмыс істеуге мүмкіндік береді, бұл компанияларға еңбек ресурстарын тиімді пайдалануға, адами факторлар мен қателіктердің әсерін барынша азайтуға және жұмыс істеуге мүмкіндік беретін корпоративті мобильді қосымшалардың енгізілуіне ықпал етеді.

Виртуалды инфрақұрылым жүздеген компаниялардың бизнес-процестерін оңтайландыруға көмектеседі, олардың менеджменті өз қызметі мен бизнестің дамуына бақылауды едәуір күшейте алады. Біріншіден, ақша айтарлықтай үнемделеді. Ресурстарды виртуалдандыру технологиясы жоғары өнімді жұмыс станцияларын (серверлер) олардың консолидациялануына байланысты азайтуға мүмкіндік береді. Бұрын кез-келген тапсырманы орындау үшін бірнеше физикалық машиналар талап етілсе, енді виртуалды ортада сыртқы операциялық жүйелерінің қажетті санын іске қосуға болады, бұл аппараттық қолдау шығындарын айтарлықтай төмендетеді. Сонымен қатар, қызмет көрсететін персонал өкілдерінің санын қысқарту мүмкіндігі туады. Виртуализация жаңа шешімдерді сынау үшін, сондай-ақ ұйымдардың қызметкерлерін оқыту үшін пайдалы. Сонымен қатар, виртуалдандыру инфрақұрылымды басқару шығындарын төмендетуі мүмкін, өйткені бұл технологияның ең маңызды артықшылығы - басқару пультіне қашықтан қол жеткізу мүмкіндігі. Сондай-ақ, қосымша плюс - виртуалды машиналарды клондаудың қарапайымдылығы. Егер ұйымның басшылығы қосымша кеңсе ашуға шешім қабылдаса, онда жаңа инфрақұрылымды орналастыру қиын болмайды - сурет көшіруге және бағдарламалық жасақтаманы орнатуға дейін міндет азаяды. Әрине, виртуалдандырудың кемшілігі де бар: жүйенің сенімділігімен жұмыс істеу тәсілін қайта қарау керек. Осыған байланысты ақауларға төзімді шешімдерді қолдану, мысалы, ақауларға төзімді кластерлерге негізделген дұрыс.

Қазіргі кезде көптеген жетекші ұйымдар АТ инфрақұрылымын виртуалдандыру бойынша жобаларды белсенді жүзеге асыруда. Әр түрлі виртуалдандыру платформаларының сатушылары ірі банктерде, үкіметтік және білім беру мекемелерінде, тіпті ауруханаларда жүзеге асырылған сәтті шешімдер портфолиосын ұсына алады. Бұл компаниялар технологияның артықшылықтарын пайдаланады және техникалық қызмет көрсетуді, персонал мен жабдықты үнемдейді. Виртуалдандырылған және бұлтты орта бизнес үшін жаңа жолдар ашты. Бұлтты орта дегеніміз бизнеске шығындарды азайтуға көмектесетін ресурстармен қамтамасыз ету моделі деп түсінеміз. Процестердің ашықтығының жоқтығы, ақпараттық қауіпсіздікке қатысты алаңдаушылықтың жоғарылауы, АТ шешімдері саласындағы заңнамалық базаның жеткіліксіз дамуы - осының бәрі елімізге бұлтты технологияларды енгізуді өте қиын етеді. Сондықтан, сарапшылардың пікірінше, сценарий - бұлттағы гибриді технологияларды қолдану, бұл кезде компанияның жеке бөлімшелері бұлтты қызметтерді қолданады. Бұл модель қазірдің өзінде енгізіліп келеді және дами береді. Кәсіптік маңызды емес қосымшалар, мысалы, адам ресурстарын басқару, жеткізілім тізбегін оңтайландыру және т.б., жалпы бұлттарға ауыстырылады.

Ақпараттық технологияларды бизнесте қолдану - қазіргі қоғам өміріндегі басты тенденциялардың бірі. АТ-ны экономиканың барлық саласында қолдану компаниялардың бәсекеге қабілеттілігін арттыруға, жаңа бизнес модельдерін құруға, шығындарды оңтайландыруға және тұтынушыларға қызмет көрсету сапасын арттыруға көмектеседі.

Пайдаланылған әдебиеттер тізімі:

1. Скворцова Н.А., Лебедева О.А., Сотникова Е.А. — Влияние информационных технологий на развитие бизнеса // Теоретическая и прикладная экономика. – 2018. – № 1. – С. 42

Горнштейн М.Ю., Соколова Н.А. Аутсорсингті дамытудың экономикалық мәні мен алғышарттары // Экономика және қоғам, 2017. № 5-2 (36). S. 896-902.

2. Раченко Т.А. АТ -қызметтерін аутсорсингке беру: қазіргі жағдай, тенденциялар және болжам // Ғылым-индустрия және сервис, 2017. № 10. С. 28-31.

3. Рзун И.Г., Рзун В.В. Бизнес-процестерді аутсорсингпен модельдеу // Зерттеудің басым бағыттары: теориядан практикаға, 2018. №32-2. S. 203-209.

4. Зверева В.А. Кәсіпкерлік қызметтің заманауи формалары: Ресейдегі аутсорсинг // Жинақта: Ресейдегі кәсіпкерліктің даму болашағы, экономика, менеджмент институтының экономика және кәсіпкерлік кафедрасының оқытушылары, аспиранттары мен студенттерінің ғылыми еңбектерінің жинағы. және заң, Мәскеу мемлекеттік университеті. Мәскеу, 2017. 148-155.

5. Розанова Н.М. Ақпараттық технологиялар саласын экономикалық талдау: әлемдік тәжірибе// Экономика кеңістігі, 2018. №3. S.42-57.

Шағын мекеменің автоматтандырылған ақпараттық жүйесін жасау (С.Нұрмағамбетов ат. жалпы орта мектебі мысалында)

Махашева Н.А.

ал-Фараби атындағы Қазақ Ұлттық университеті, бакалавр 4 курс
e-mail: nurssuluuum@mail.ru

Бурибаев Б.

ал-Фараби атындағы Қазақ Ұлттық университеті,
Ақпараттық жүйелер кафедрасының доценті, т.ғ.к.

Қазіргі таңда білім беру саласында ақпараттық технологияларды қолдану кеңінен таралуда. Мектептердің басқару процестерін автоматтандыру арқылы оқу сапасын арттыруға, әкімшілік жүктемені азайтуға және деректерді өңдеу тиімділігін жақсартуға болады. Осы зерттеуде С. Нұрмағамбетов атындағы мектеп үшін арнайы жасалған автоматтандырылған ақпараттық жүйенің құрылымы мен функционалдығы қарастырылады. Жүйе мектептің негізгі әкімшілік және оқу процестерін автоматтандыруға бағытталған.

Ұсынылған автоматтандырылған ақпараттық жүйе оқушылар мен мұғалімдердің деректерін басқару, электронды күнделік пен журнал жүйесін енгізу, оқу процесін мониторингтеу және есептілікті автоматтандыру, ата-аналар мен мектеп әкімшілігі арасындағы байланысты жақсарту, құжат айналымын цифрландыру сияқты міндеттерді шешуге көмектеседі. Жүйе модульдік архитектураға негізделген және бірнеше негізгі компоненттерден тұрады, соның ішінде пайдаланушы интерфейсі, деректер қоры, электронды есеп беру және талдау жүйесі, қауіпсіздік және қол жеткізу бақылауы, бұлттық интеграция қамтылған.

Жүйені әзірлеу барысында заманауи веб-технологиялар қолданылды. Серверлік бөлімінде **Node.js** технологиясы қолданылып, асинхронды өңдеу мен тиімді дерекқор басқару жүйесі енгізілді. Бұл серверлік логиканың жылдамдығын арттырып, пайдаланушыларға үздіксіз қызмет көрсетуге мүмкіндік береді. Ал мобильді қосымша **React Native** негізінде әзірленіп, оқушылар мен мұғалімдерге ыңғайлы интерфейс ұсынылды. Бұл технология жүйені Android және iOS платформаларында бір уақытта қолжетімді етуге мүмкіндік береді. Сонымен қатар, мектеп әкімшілігі үшін веб-интерфейс дайындалып, ол арқылы барлық пайдаланушылардың деректері тиімді басқарылады.

Жүйені әзірлеу барысында RESTful API технологиясы қолданылды, бұл жүйенің масштабталуын жеңілдетеді және әртүрлі құрылғылардан деректерге қол жеткізуге мүмкіндік береді. Сонымен қатар, мектептің нақты қажеттіліктеріне бейімделген дерекқор құрылымы жасалды. Әкімшілік бөлім мұғалімдер мен оқушылардың мәліметтерін реттеп, оларға қажет есептілікті автоматтандырылған түрде қалыптастыра алады.

Жүйеде пайдаланушылардың рөлдеріне байланысты қолжетімділік деңгейлері реттелген. Мұғалімдерге оқушылардың үлгерімін бағалауға, сабақ кестесін жоспарлауға мүмкіндік берілсе, ата-аналар өз балаларының оқу процесін қадағалай алады. Ал оқушыларға оқу материалдары мен тапсырмаларға ыңғайлы түрде қол жеткізу мүмкіндігі ұсынылған. Бұл функционалдар жүйені жан-жақты және мектеп қажеттіліктеріне толық сәйкес етіп жасауға мүмкіндік берді.

Жүйені енгізудің бірнеше негізгі артықшылықтары бар. Біріншіден, оқу үрдісін автоматтандыру арқылы мұғалімдер мен әкімшіліктің жүктемесін азайтады. Екіншіден, кез келген уақытта және кез келген жерден ақпаратқа қол жеткізу мүмкіндігін береді. Үшіншіден, деректердің жоғалу қаупін азайтып, олардың құпиялылығын сақтауға көмектеседі. Төртіншіден, оқушылардың үлгерімін талдау және жеке оқу жоспарын әзірлеу мүмкіндігі арқылы оқу сапасын жақсартады.

Қазіргі уақытта жүйенің негізгі функционалдары әзірленіп, тестілеу кезеңінен өтуде. Оқушылар мен мұғалімдердің деректерін басқару, электронды журнал жүргізу,

автоматтандырылған есеп беру және мобильді қосымшаның негізгі мүмкіндіктері жүзеге асырылды. Жүйенің тағы бір болашағы – оны басқа білім беру мекемелеріне бейімдеу және кеңейту мүмкіндігі. Егер бұл жүйе сәтті іске асса, оны қаланың немесе елдің басқа мектептеріне енгізу мүмкіндігі қарастырылады. Бұл білім беру процесін цифрландыруды жеделдетіп, жалпы білім беру жүйесінің тиімділігін арттыруға мүмкіндік береді. Сондай-ақ, оқушылардың жеке оқу траекторияларын бақылау және мұғалімдерге оқушылардың үлгеріміне негізделген талдау жасау құралдарын енгізу жоспарлануда. Алдағы уақытта жүйені жетілдіру мақсатында жасанды интеллект пен машиналық оқыту әдістерін енгізу жоспарлануда.

Пайдаланылған әдебиеттер тізімі:

1. Магомадова З.С. Использование ИС в образовательном пространстве современной общеобразовательной школы // Мир науки, культуры, образования. - №2 (50). - 2015г., с.90-92.
2. Смирнов А.А., Кузнецова Л.В. Автоматизированные системы в современном школьном образовании // Журнал образовательных технологий. - №5 (89). - 2020г., с.32-38.

СИСТЕМА УПРАВЛЕНИЯ ОТПУСКАМИ В КОРПОРАТИВНОЙ СРЕДЕ

Мейрхан Ш.

*Казахский Национальный Университет имени аль-Фараби, бакалавр 4 курс
C4ingiz200312@gmail.com*

Бакибаев А.В.

Казахский Национальный Университет имени аль-Фараби, старший преподаватель

В современном мире автоматизация бизнес-процессов играет ключевую роль в повышении эффективности работы компаний. Одним из наиболее важных аспектов является управление кадровыми процессами, в частности, планирование и согласование отпусков. Добрый день, уважаемые коллеги! Сегодня я представляю доклад на тему "Система управления отпусками в корпоративной среде".

Проанализировав рынок, мы выявили острую нехватку функционала управления отпусками в компаниях. Многие организации используют ручные методы согласования, что приводит к потерям времени, дублированию процессов и снижению общей эффективности работы. В современных компаниях кадровые процессы требуют автоматизации для повышения эффективности. Как отмечает Базаров Т.Ю. в своей книге "Управление персоналом", эффективное управление кадрами невозможно без системного подхода к учету отпусков и планированию рабочего времени [1].

Целью работы является создание веб-системы, которая автоматизирует процесс управления отпусками. Для достижения этой цели были поставлены следующие задачи: разработать удобный интерфейс для подачи и согласования заявок на отпуск, обеспечить возможность планирования отпусков на следующий год, реализовать интеграцию с 1С для учета баланса отпусков и автоматической передачи приказов, разработать систему ролевого доступа для сотрудников, руководителей, HR и администраторов, внедрить диаграмму Ганта для наглядного отображения графика отпусков, а также интегрировать систему с Jira, Bitrix24 и AmoCRM для автоматического переноса задач и уведомлений.

Система представляет собой веб-приложение, доступное через браузер. В ней реализованы следующие роли пользователей: сотрудник – подает заявки, отслеживает статус, планирует отпуска; руководитель – согласовывает заявки, проверяет баланс отпусков подчиненных; HR – управляет отпусками сотрудников, передает данные в 1С; администратор – настраивает доступ, справочники и мониторинг процессы.

Как указывает Кибанов А.Я. в книге "Основы кадрового менеджмента", одной из важнейших задач кадрового учета является "обеспечение прозрачности и доступности информации о состоянии персонала", что полностью подтверждается нашей системой, которая автоматизирует процесс управления отпусками и предоставляет удобный интерфейс для всех участников процесса [2].

Функциональные возможности системы включают в себя подачу заявки на отпуск, согласование отпуска руководителем, отображение утвержденных отпусков в диаграмме Ганта, фильтрацию и поиск данных, автоматическое обновление баланса отпусков из 1С, экспорт данных в Excel, интеграцию с Jira для автоматического обновления статусов сотрудников в задачах во время отпуска, а также интеграцию с Bitrix24 и AmoCRM для переноса сделок и задач на другого менеджера при уходе сотрудника в отпуск.

Как указано в статье Иванова С.Ю. и Петрова В.А. "Автоматизация кадровых процессов на предприятии: тенденции и перспективы" (журнал "Кадровый менеджмент", 2021), "современные системы управления персоналом должны включать не только базовый учет отпусков, но и возможность их согласования, прогнозирования нагрузки и интеграции с корпоративными системами" [3]. Это подчеркивает важность интеграции нашей системы с такими платформами, как 1С, Jira, Bitrix24 и AmoCRM.

Разработанная система позволяет уменьшить нагрузку на HR-отдел, исключить конфликты отпусков между сотрудниками, обеспечить прозрачность кадровых процессов, автоматизировать взаимодействие с 1С, Jira, Bitrix24 и AmoCRM. В дальнейшем планируется добавление мобильного приложения для удобного управления отпусками, расширение интеграции с мессенджерами для оперативных уведомлений, внедрение прогнозирования загрузки сотрудников для оптимального планирования отпусков, разработка модуля управления командировками, включая подачу заявок на служебные поездки и их согласование, а также автоматизация учета больничных листов, интеграция с медицинскими системами для загрузки документов и расчета дней отсутствия.

Список использованной литературы:

1. Базаров Т.Ю. "Управление персоналом" – современные подходы к управлению отпусками и кадрами.
2. Кибанов А.Я. "Основы кадрового менеджмента" – теория организации кадровых процессов.
3. Иванов С.Ю., Петров В.А. "Автоматизация кадровых процессов на предприятии: тенденции и перспективы", журнал *Кадровый менеджмент*, 2021.
4. Официальная документация 1С: <https://1c.ru> – API и интеграция с системами управления персоналом.
5. Atlassian Developer: <https://developer.atlassian.com> – руководство по API Jira.
6. Bitrix24 Developers: <https://dev.1c-bitrix.ru> – интеграция кадровых процессов.
7. AmoCRM Developers: <https://www.amocrm.ru/developers> – автоматизация работы с клиентами.

ДЕСТРУКТИВТІ МӘТІНДЕРДІ АНЫҚТАУ ЖӘНЕ ЗЕРТТЕУ

Мырзақұл Ж.Н.

Ғылыми жетекші: Мусиралиева Ш. Ж. ф.-м.ғ.к., профессор
Әл-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан
Zhansaya.myrzakul@mail.ru

Бұл зерттеу мәтін деңгейінде нейрондық желілерді пайдалана отырып, араб-левантиялық жеккөрінішті сөздерді анықтаудың тиімді әдісін әзірлеуге және қолдануға бағытталған. Ең бірінші берілген дайын деректер жиынындағы мәтіндерді қазақ тіліне аудару үшін Hugging Face 's transformers сияқты машиналық оқыту кітапханасы пайдаланылады. Ол машиналық аударма үшін алдын ала дайындалған модельдерге қол жеткізуге мүмкіндік береді.

1. *Деректерді дайындау:* мәтінді артық таңбалардан тазарту, токенизация, тоқтату сөздерін алып тастау, лемматизация және сөздерді қалыпты күйге келтіру;

2. *Модельді бейімдеу:* модель архитектурасын өзгерту, араб-левант мәтінімен жұмыс істеу үшін модельді орнату, мүмкін біріктіру немесе назар аудару қабаттарын қосу;

$$\text{Word2Vec}(\omega_i) = \frac{1}{N} \sum_{j=1}^N \text{context}(\omega_j) \quad (1)$$

мұндағы, N - контекст терезесінің өлшемі, ал $\text{context}(\omega_i)$ - ω_i сөзіндегі контекст сөздер.

$$\text{GloVe}(\omega_i) = \sum_{j=1}^V f(P_{ij})(\omega_i * \omega_j + b_i + b_j - \log P_{ij})^2 \quad (2)$$

мұндағы, P_{ij} - ω_i, ω_j сөздердің пайда болу ықтималдығы, f - салмақ функциясы, ал V – сөздік өлшемі.

Кірістерді кодтау: араб-левант мәтіндерін сандық векторларға түрлендіру, мысалы, Word2Vec (1) немесе GloVe (2) сияқты эмбеддинг әдістерін қолдану [1];

3. *Модельді оқыту:* болжамды және нақты белгілер арасындағы алшақтықты бағалау үшін категориялық кросс-энтропия сияқты шығын көрсеткішін пайдалану. Оқу процесінде модель салмағын жаңарту үшін стохастикалық градиентті түсіру

4. *Өнімділікті бағалау:* дәлдік (*accuracy*), толықтық (*recall*), дәлдігі (*precision*) және $F1$ өлшемі сияқты бағалау көрсеткіштерді пайдалана отырып, модель өнімділігін бағалау. Өр түрлі мәліметтер жиынтығында модельдің жалпылау қабілетін тексеру үшін кросс-валидация әдісін қолдану. Қателерді интерпретация жасау: олардың пайда болу себептерін және мүмкін болатын жақсартуларды анықтау үшін модель жасаған қателер түрлерін талдау. *Feature importance* сияқты әдістер арқылы белгілердің маңыздылығын бағалау немесе модель болжамдарына белгілердің үлесін талдау.

Бұл зерттеу Қазақстан Республикасы Ғылым және жоғары білім министрлігінің AP19676342 «Қазақ тіліндегі кибер экстремизмнің идеологиялық бағыттарын жасанды интеллект әдістері көмегімен мультиклассификациялау» гранты бойынша қаржыландырылды.

Пайдаланылған әдебиеттер тізімі:

1. Hamdi, A. (2019). Hate speech detection on Arabic social media. In 2019 4th International Conference on Computer Science and Engineering (UBMK) (pp. 20-24). IEEE.

Терең оқыту тәсілдерін пайдалана отырып, ауаның ластануын болжау

Нұрланова Қ.

*Әл-Фараби атындағы Қазақ Ұлттық университеті
Компьютерлік инженерия мамандығының 4-курс студенті*

Ауаның ластануы – әлемдегі ең өзекті экологиялық мәселелердің бірі. Оның әсері адамдардың денсаулығының нашарлауына және қоршаған орта жағдайларының бұзылуына алып келеді. Үлкен қалалардағы өнеркәсіп орындары, жылыту станциялары мен көлік қозғалысының жоғары деңгейіне байланысты ауа сапасы айтарлықтай нашарлайды. Әсіресе, биік ғимараттар шоғырланған мегаполистерде ауа айналымының шектеулі болуына байланысты зиянды заттардың жиналуы артады.

Қазіргі таңда ауа сапасын бақылау негізінен стационарлық өлшеу станциялары арқылы жүргізіледі. Алайда, ауа ластану деңгейінің өзгеруін алдын ала болжауда бұл әдістердің тиімділігі төмен болуы мүмкін.

Бұл мәселені шешу үшін осы жұмыста физикаға негізделген нейрондық желілер (PINN) әдісі қолданылады. Бұл әдіс сандық модельдеу мен машиналық оқытуды біріктіріп, ауа ластануының өзгеруін тек деректер негізінде емес, сонымен қатар физикалық заңдар негізінде дәл болжауға мүмкіндік береді.

Бұл зерттеуде ауаның ластануын болжау үшін сандық модельдеу мен терең оқыту әдістерін үйлестіретін кешенді тәсіл қолданылады. Бірінші кезеңде терең оқытуды пайдаланып ауа сапасын болжауға арналған қолданыстағы әдістерге талдау жасалды. Қалалық каньондағы ауа қозғалысын дәлірек сипаттау үшін тесттік тапсырма ретінде екіөлшемді кеңістіктегі қозғалмалы қақпақпен басқарылатын қораптағы ағынды модельдеу жүзеге асырылды және модельдеуге арналған бастапқы және шекаралық шарттарды әзірленді. Ауа ағындарын модельдеу үшін Пуассон теңдеулерін шешуге негізделген сандық модельдеу әдісі қолданылды.

Зерттеудің негізгі бөлігі – ластаушы заттардың концентрациясын болжау үшін PINN әдісін қолдану. Ол Пуассон теңдеуіне негізделген u жылдамдықты болжау үшін қолданылады. Нейрондық желі кіріс деректерін (x, y) қабылдайды және бірнеше жасырын қабаттар арқылы жылдамдықтың жуықталған мәнін u_0 есептейді. Кейін қателіктер функциясын қалыптастыру үшін автоматты дифференциалдау көмегімен шығыс мәнінің жеке туындылары есептеледі, және желіні оңтайландыру жүзеге асырылады. Осылайша, бұл әдіс дәстүрлі дифференциалдық теңдеулер мен терең оқыту мүмкіндіктерін біріктіріп, модельді үйрету барысында физикалық заңдылықтарды ескеруге мүмкіндік береді.

Соңғы кезеңде алынған модельдердің дәлдігі бағаланып, болжанған мәндер нақты өлшемдермен салыстырылады. Осындай кешенді әдіс ауаның ластануын неғұрлым дәл болжауға мүмкіндік беріп, қала экологиясын жақсарту бойынша тиімді шешімдерді ұсынуға жол ашады.

Бұл зерттеуден алынған нәтижелер қалалық инфрақұрылымның ауа сапасына әсерін бағалауға және болжау моделінің тиімділігін арттыруға мүмкіндік береді.

Пайдаланған әдебиеттер тізімі:

- 1.D.M.S. Madalozzo A.L. Braun A.M. Awruch I.B. Morsch. Numerical simulation of pollutant dispersion in street canyons: Geometric and thermal effects
2. Mateusz Zareba, Elzbieta Weglinska & Tomasz Danek. Air pollution seasons in urban moderate climate areas through big data analytics
3. Chen Cheng Guang-Tao Zhang 2. Deep Learning Method Based on Physics Informed Neural Network with Resnet Block for Solving Fluid Flow Problems
4. Lianfa Li, Jinfeng Wang, Meredith Franklin, Qian Yin, Jiajie Wu, Gustau Camps-Valls,

Zhiping Zhu, Chengyi Wang, Yong Ge & Markus Reichstein. Improving air quality assessment using physics-inspired deep graph learning

5. Rui Xu, Deke Wang, Jian Li, Hang Wan, Shiming Shen and Xin Guo. A Hybrid Deep Learning Model for Air Quality Prediction Based on the Time–Frequency Domain Relationship

РАЗРАБОТКА МЕТОДОВ АНАЛИЗА И ВИЗУАЛИЗАЦИИ ДАННЫХ АУДИТА ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ НА ЯЗЫКЕ ПРОГРАММИРОВАНИЯ PYTHON

Нұрпейіс Р.Ж.

Научный руководитель: Ст. преподаватель кафедры информационных систем Илесова Б.Е.
КазНУ им. аль-Фараби, Алматы, Казахстан
E-mail: rinat.nurpeys@bk.ru

Аудит информационных технологий (ИТ-аудит) представляет собой процесс оценки, анализа и контроля систем, инфраструктуры и процессов, связанных с управлением данными и информационной безопасностью. С развитием технологий и увеличением объема данных возрастает необходимость в использовании современных методов анализа и визуализации информации. Python, как мощный инструмент обработки данных, позволяет автоматизировать аудит, выявлять аномалии и представлять результаты в наглядной форме.

В процессе ИТ-аудита применяются различные методы анализа данных, которые помогают выявлять риски, анализировать уязвимости и проверять соответствие стандартам. Основные методы включают:

- Статистический анализ: позволяет выявлять закономерности в данных, определять ключевые метрики и оценивать распределение значений. Используются библиотеки `pandas`, `numpy` и `scipy`.
- Машинное обучение: помогает находить скрытые аномалии, предсказывать возможные инциденты и классифицировать данные. Инструменты: `scikit-learn`, `TensorFlow`, `PyTorch`.
- Обнаружение аномалий: методы кластеризации и анализа временных рядов (например, с помощью алгоритмов `Isolation Forest`, `DBSCAN`, `LSTM`) позволяют обнаруживать необычные события в логах и системных данных.

Для представления результатов ИТ-аудита используются методы визуализации, которые позволяют быстро интерпретировать сложные зависимости. Python предлагает широкий спектр инструментов для создания интерактивных графиков и отчетов.

Основные библиотеки для визуализации:

- **Matplotlib** – базовая библиотека для построения диаграмм и графиков.
- **Seaborn** – расширенные визуализации для статистического анализа.
- **Plotly** – интерактивные графики.
- **Dash** – создание аналитических веб-приложений.




Рис. 1. Линейный график показывает распределение уязвимостей по типам




Рис. 2. Гистограмма отражает динамику выявленных уязвимостей по месяцам

Использование Python для анализа и визуализации данных в ИТ-аудите значительно повышает эффективность проверки информационных систем. Автоматизированные

инструменты помогают выявлять риски, строить прогнозы и визуализировать результаты в удобном формате. Внедрение современных технологий машинного обучения и больших данных открывает новые перспективы для развития ИТ-аудита, делая его более точным и оперативным.

Список использованной литературы:

1. Ким А.В., Байжанов Р.А. Визуализация данных в ИТ-аудите: современные подходы. – Астана: Институт цифровых исследований, 2022. – №3(56). – С. 50-58.
2. Алимов Т.К., Сапаров Б.Н. Автоматизация ИТ-аудита: методы и инструменты. – Алматы: Технологии и инновации, 2021. – №2(33). – С. 45-52.
3. Иванов С.В., Петров А.А. Анализ логов и выявление аномалий в информационных системах. – Москва: Информационная безопасность, 2020. – №5(27). – С. 38-46.
4. Сериков Д.Р., Касымов М.Т. Методы машинного обучения в анализе угроз кибербезопасности. Вестник НАН РК. Серия информационные технологии. – 2019. – №4(312). – С. 90-97.

БЕЙНЕЛЕРДІ ТАНУ ЖҮЙЕЛЕРІН ДАМУ: БІРТАҚТАЛЫ КОМПЬЮТЕРЛЕР МЕН НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ БІРІКТІРУ

Орынбасар А.Ж.

Ғылыми жетекші: PhD, ассистент профессор, Орманбекова А.А.

Алматы технологиялық университеті, Алматы, Қазақстан

e-mail: orynbasarovaai@bk.ru

Соңғы жылдары машиналық оқыту және компьютерлік көру технологиялары айтарлықтай дамып, денсаулық сақтау, қауіпсіздік және интеллектуалды көлік жүйелерінде қолданылуда. Олардың негізгі бағыттарының бірі – бейнелерді тану, оның ішінде бет-әлпеттерді, жол белгілерін тану және объектілерді нақты уақыт режимінде талдау.

Нейрондық желілерді машиналық оқытуда пайдалану тану процесін автоматтандыруға және алгоритмдерді өзгермелі жағдайларға бейімдеуге мүмкіндік береді. Аппараттық-бағдарламалық кешендер жол белгілерін және объектілерді талдау арқылы алынған мәліметтерді салыстырып, шешім қабылдайды. Нәтижесінде алгоритмдер жетілдіріліп, болжау дәлдігі артады.

Зерттеудің өзектілігі, Raspberry Pi сияқты біртепті компьютерлер негізінде интеллектуалды жүйелерді дамыту қажеттілігімен байланысты, олар минималды есептеу ресурстарымен деректерді тиімді өңдеуді қамтамасыз етеді.

Зерттеудің мақсаты – біртепті компьютерлер мен конволюциялық нейрондық желілерді біріктіру арқылы бейнелерді тану жүйесін жасау, бұл оңтайлы жылдамдық пен дәлдікке қол жеткізуге мүмкіндік береді.

Зерттеудің міндеттері:

- Әр түрлі біртепті компьютерлердің модельдерін талдап, ең тиімдісін таңдау.
- Конволюциялық нейрондық желілердің (CNN) бар архитектураларын зерттеу.
- Машиналық оқыту технологияларын пайдалану арқылы бағдарламалық жасақтаманы әзірлеу.

- Жүйені сынақтан өткізіп, оның тиімділігін нақты жағдайларда бағалау.

Бейнелерді танудағы машиналық оқыту алгоритмдерін талдау

Машиналық оқыту – деректерді талдаудың негізгі әдісі, бұл болжамдар жасауға және модельдерді жинақталған тәжірибе негізінде автоматты түрде бейімдеуге мүмкіндік береді. Қазіргі алгоритмдер күрделі заңдылықтарды тануға және бейнелерді жоғары дәлдікпен жіктеуге мүмкіндік береді [1, 2].

Машиналық оқытудың негізгі әдістері мен қазіргі бейнелерді тану тәсілдерін салыстыру арқылы олардың артықшылықтары мен кемшіліктерін анықтап, нақты қолдану салаларын бағалауға болады. Төменде әр әдістің салыстырмалы талдауы берілген:

Кесте 1 – Машиналық оқытудың негізгі әдістеріне салыстырмалы талдау

Әдіс	Артықшылықтары	Кемшіліктері	Қолдану саласы
Бақыланатын оқыту	- Жоғары дәлдік, нақты болжамдар	- Көп жаттығу деректері қажет	- Классификация, беттерді тану, ауруды анықтау
Бақыланбайтын оқыту	- Өздік заңдылықтарды анықтау	- Нәтижелерді түсіндіру қиын	- Кластерлеу, аномалияларды анықтау
Қуаттау арқылы оқыту	- Шешімдер қабылдауды үйрену, оңтайлы нәтиже	- Ұзақ оқыту, қиын бағалау	- Робототехника, автономды көлік, ойындар
Классикалық әдістер	- Қарапайым, есептеу ресурстары аз	- Күрделі жағдайларда тиімді емес	- Контурларды анықтау, бет тану

CNN	- Автоматты ерекшеліктерді шығару, жоғары дәлдік	- Көп есептеу ресурстарын талап етеді	- Күрделі бейнелерді тану, медициналық бейнелер
Гибридті әдістер	- Классикалық әдістер мен нейрондық желілердің тиімділігі	- Жүйені баптау күрделі	- Нақты уақыттағы бейнемазмұнды талдау, бейнебақылау

CNN қазіргі таңда ең тиімді әдіс болып табылады, өйткені олар бейнелердің ерекшеліктерін автоматты түрде анықтай алады және жоғары дәлдікпен жұмыс істейді. Бұл әдіс әсіресе күрделі бейнелерді тануда, сондай-ақ үлкен деректер жиынтығымен жұмыс істегенде тиімді [4].

Оқыту үшін деректерді жинау және дайындау

Нейрондық желі модельдерін оқыту үлкен көлемдегі деректерді талап етеді. Тиімділікті арттыру үшін деректерді ұлғайту әдістері қолданылады, мысалы, бейнелерді бұру, масштабтау, жарықтылықты өзгерту арқылы деректер жиынтығын жасанды түрде кеңейту. Сондай-ақ, класстарды теңгеру арқылы бейнелердің түрлі категориялары арасындағы диспропорцияны жою, деректерді алдын ала өңдеу (нормализациялау, шуды жою және форматты өзгерту) маңызды рөл атқарады. Сонымен қатар, жол белгілерін және объектілерді әртүрлі ауа райы жағдайларында, бұрыштармен түсірілген бейнелермен қамтитын арнайы деректер жиынтығын құру тану дәлдігін арттыруға мүмкіндік береді.

Бейнелерді тануға арналған аппараттық-бағдарламалық кешен

Raspberry Pi және NVIDIA Jetson сияқты бірплаталық компьютерлер нейрондық желілермен жұмыс істеуге жеткілікті есептеу қуатын қамтамасыз етеді. Жүйені жүзеге асыру үшін пайдаланылады:

- Raspberry Pi 4 – автономды жүйелер үшін энергияны аз тұтынумен және жеткілікті есептеу қуатымен оңтайлы таңдау.
- TensorFlow және OpenCV – машиналық оқыту мен бейнелерді өңдеу кітапханалары, модельді интеграциялау және деректерді алдын ала өңдеу.
- YOLO (You Only Look Once) – объектілерді анықтаудың жоғары өнімді алгоритмі, жылдам және дәл классификация жасайды.
- Аппараттық деңгейде оңтайландыру – бейнелерді өңдеудің өнімділігін арттыру үшін нейропроцессорларды, мысалы, Google Coral пайдалану [3].

Іске асыру процесі және тиімділігін бағалау

Жүйе бірнеше кезеңнен өтеді: бірінші кезеңде модельді оқыту жүргізіледі, мұнда алдын ала дайындалған желілер, мысалы, MobileNet және ResNet, нақты эксплуатация жағдайларына бейімделеді. Екінші кезеңде енгізу құрылғыларына оңтайландыру жүзеге асырылады, бұл процессорға жүктемені азайту үшін кванттау және есептеулерді жылдамдату әдістерін қолдануды қамтиды. Үшінші кезеңде нақты сынақтан өткізу жүргізіледі, жүйені жол қозғалысы жағдайларында іске қосып, жарық, ауа райы және бөгеттер жағдайларына тұрақтылығын тексеру маңызды. Соңында, жүйе қолданыстағы жүйелермен интеграцияланады, ақылды қала жүйелеріне және автономды көлік платформаларына қосылу арқылы толық жұмыс істейтін экожүйе құрылады.

Тиімділікті бағалау үшін келесі метрикалар қолданылады:

- Дәлдік (Accuracy) – дұрыс классификациялардың пайызы.
- F1-балл – дәлдік пен толықтықтың гармоникалық орташа мәні.
- FPS (Frames Per Second) – жүйенің нақты уақыттағы өнімділігі.
- Орташа жауап беру уақыты – объектіні анықтау мен шешім қабылдау арасындағы кідіріс.

• Күрделі жағдайларда тану – жарықтың төмендігі мен объектілердің ішінара жабылуы жағдайларында модельді тестілеу.

Эксперименттік деректер нәтижесінде, YOLO мен MobileNet жүйелерінің үйлесімді қолданылуы өңдеу жылдамдығы мен классификация дәлдігі арасында тепе-теңдікті қамтамасыз етеді.

Қорытындылай келе, нейрондық желілердің артықшылықтарын тиімді пайдалану адам өмірінің жеңілдетуіне үлкен септігін тигізеді. EfficientNet моделі трансферттік оқытуды қолдана отырып оқытылып, сынақ жиынында 90% дәлдікке қол жеткізді. Мен алгоритмнің өнімділігін бірнеше өнімділік көрсеткіштері, соның ішінде дәлдік, еске түсіру, F1 ұпайы және қабылдағыштың жұмыс сипаттамасы (ROC) қисығы арқылы бағаладым.

Бірталы компьютер ортасында нейрондық желілерді пайдалана отырып, көлік роботының прототипін жасау көлік саласындағы әртүрлі тапсырмалар үшін автоматтандырылған жүйелерді дамытудағы маңызды қадам деп айтуға болады. Бұл прототип нейрондық желілерді қозғалысты басқаруға байланысты тапсырмалардың дәлдігі мен тиімділігін жақсарту үшін робототехникада сәтті қолдануға болатындығын көрсетеді. Қазіргі уақытта компьютерлік көру технологиялары қарқынды дамып келеді. Олар компьютерлер (машиналар) суреттердегі ақпаратты шығарып, талдай және түсіне алады. Соңғы жылдары компьютерлік көру технологиялары соншалықты маңызды серпіліс жасады, енді компьютерлер тіпті адамның бетіндегі эмоцияларды тани алады. Бұған машиналық/терең оқыту және жасанды интеллект (deep learning/AI) технологиялары арқылы қол жеткізіледі. Арнайы алгоритмдер көптеген ұқсас суреттерде жаттығады, содан кейін олар жаңа суреттерден қажетті ақпаратты оқшаулай алады. Қазіргі уақытта адамдардың бет-әлпетін тануға қатысты компьютерлік көру технологиялары соншалықты жетілдірілген, олар қауіпсіздік жүйелерінде, медицинада және тіпті қаржылық төлем қызметтерінде кеңінен қолданылады [5].

Пайдаланылған әдебиеттер тізімі:

1. Сиднев А. А. Проектирование и программная реализация информационной системы компьютерного зрения по распознаванию номеров автотранспортных средств / А. А. Сиднев // Евразийский Научный Журнал. – 2017. – № 11. – С. 1–5.

2. Селянкин В. В. Компьютерное зрение. Анализ и обработка изображений / В. В. Селянкин. – М.: Лань, 2019. – 152 с.

3. Raspberry Pi 4. Обзор и тестирование [Электронный ресурс]. URL: <https://dmitrynotes.ru/raspberry-pi-4-obzor-i-testirovanie>.

4. P. G. Patil, A. K. Singh, and R. K. Gupta, "Real-Time Traffic Sign Recognition using Convolutional Neural Networks," *IEEE Access*, vol. 9, pp. 985-995, 2021, DOI: 10.1109/ACCESS.2021.9835954.

5. A. R. Patel, M. P. Sharma, and S. S. Kumar, "Real-Time Object and Traffic Sign Recognition using Convolutional Neural Networks," *IEEE Access*, vol. 10, pp. 124-135, 2022, DOI: 10.1109/ACCESS.2022.10434002.

ТЕЛЕМЕДИЦИНА АҚПАРАТТЫҚ ЖҮЙЕСІН ДАМУ

Омархалиева Н.Г.

*Әл-Фараби атындағы Қазақ Ұлттық университеті,
Ақпараттық жүйелер мамандығының 4-курс студенті*

Байшоланова К.С.

*Әл-Фараби атындағы Қазақ Ұлттық университеті, э.ғ.д., доцент
e-mail: nazekaomar749@gmail.com*

COVID-19 пандемиясы біздің денсаулық сақтау туралы ойлау тәсілімізді өзгертті. Ең үлкен өзгерістердің бірі – телемедицинаның қарқынды дамуы болды. Телемедицина пациенттерге өз үйлерінен шықпай-ақ медициналық көмек алуға мүмкіндік береді. Бұл тәсіл адамдардың дәрігерге тікелей бара алмауына байланысты танымал болды. Алайда телемедицина – уақытша шешім емес, ол технологиямен бірге дамып келе жатқан заманауи медицинаның келесі қадамы.

Телемедицина пациенттер мен дәрігерлер арасындағы байланысты жеңілдетеді, бірақ ол белгілі бір қиындықтармен қатар жүреді. Негізгі мәселелердің бірі – медицина қызметкерлерінің жеткіліксіз қатысуы. Пандемия кезінде пациенттер телемедицинаны пайдалануды үйренді, алайда медициналық персонал да тиісті дайындықтан өтіп, қолдау алуы қажет. Телемедицинаның тиімді жұмыс істеуі үшін медицина қызметкерлері оны тек бұйрық ретінде қабылдамауы керек, керісінше, оның өздеріне де пайдасы тиетінін түсінуі қажет. Мысалы, ауруханалар барлық деңгейдегі қызметкерлерді телемедицина процесіне тартқанда, жүйе әлдеқайда жақсы жұмыс істейді.

Тағы бір маңызды мәселе – технология. Егер технология дұрыс жұмыс істемесе, ең үздік дәрігерлердің өзі телемедицина арқылы көмектесе алмайды. Деректердің қауіпсіздігі – үлкен мәселе. Пациенттер жеке медициналық ақпараттарының қауіпсіз екеніне сенімді болуы тиіс. Ол үшін мықты шифрлау және деректерді қорғау жүйелерін енгізу қажет. Егер пациенттер өздерінің мәліметтері қорғалмаған деп ойласа, олар телемедицинаны пайдаланбайды.

Үшінші мәселе – қолжетімділік. Көптеген адамдарда жылдам интернет немесе телемедицинаны қолдануға қажетті құрылғылар жоқ. Бұл әсіресе ауылдық аймақтарда немесе табысы төмен адамдар арасында өзекті. Мұны шешу үшін үкімет және денсаулық сақтау ұйымдары халықтың барлық топтарына қолжетімді интернет пен цифрлық құрылғыларды қамтамасыз етуі керек. Осы жағдайлар орындалмаса, телемедицина өз әлеуетін толық іске асыра алмайды.

Мәселе	Шешімі
Медицина қызметкерлерінің төмен қатысуы	Медициналық персоналды оқыту және телемедицинаға белсенді тарту
Деректер қауіпсіздігі мәселелері	Сенімді шифрлау және жеке мәліметтерді қорғау жүйелерін енгізу
Технология мен интернетке қолжетімділіктің шектеулілігі	Халықты қолжетімді интернетпен және цифрлық құрылғылармен қамтамасыз ету

1-кесте: Телемедицинадағы негізгі мәселелері мен шешімдері

Телемедицина пациенттер мен дәрігерлер арасындағы қарым-қатынасты да өзгертеді. Қазір пациенттер өз емдеу процесінің белгілі бір бөлігін өздері басқара алады. Бұл оң әсерін тигізгенімен, пациенттердің өз денсаулығы туралы көбірек білім алуын талап етеді. Телемедицинаның сәтті дамуы үшін пациенттер мен дәрігерлер бірге жұмыс істеуі қажет. Ауруханалар мен клиникалар пациенттерге телемедициналық құралдарды дұрыс пайдалануды үйретуге инвестиция салуы тиіс.

Сонымен қатар, телемедицинаның әртүрлі түрлері бар. Телевизиттер пациент пен дәрігердің бейнебайланыс арқылы дәстүрлі қабылдауын қамтиды. Телебақылау пациенттердің

өз белгілерін немесе симптомдарын электронды түрде дәрігерлерге жіберуіне мүмкіндік береді. Телеинтерпретация қашықтан радиологиялық сканерлеулер сияқты тесттердің нәтижелерін талдауға көмектеседі. Ал телеконсультация медициналық қызметкерлерге алыстағы сарапшылармен белгілі бір жағдайлар бойынша кеңесуге мүмкіндік береді.

Кейбір тәжірибелер, мысалы, қашықтан білім беру немесе әлеуметтік желілердегі медициналық талқылаулар, телемедицинаға жатпайды. Мысалы, қашықтан білім беру медицина мамандарын оқыту үшін қолданылады, бірақ ол тікелей пациенттерді емдеумен байланысты емес. Әлеуметтік желілер денсаулық тақырыбында пікір алмасу үшін кеңінен пайдаланылғанымен, ресми телемедицина жүйесіне кірмейді.

Телемедицина түрі	Сипаттамасы
Телевизиттер	Дәрігер мен пациент арасындағы видеокеңес беру
Телебақылау	Орта буын медицина қызметкерлерінің аға дәрігерлер тарапынан қашықтан қадағалануы
Телемониторинг	Пациенттің симптомдары мен мәліметтерін дәрігерге электронды түрде жіберу
Телеинтерпретация	Медициналық деректерді (рентген, МРТ және т.б.) қашықтан талдау және түсіндіру
Телеконсультация	Әртүрлі медицина мамандарының арасындағы кеңес

Қорытындылай келе, телемедицина медицина саласына үлкен өзгерістер әкелді. Ол денсаулық сақтау қызметтерін қолжетімді етті, бірақ әлі де шешілуі тиіс мәселелер бар. Егер біз медицина қызметкерлерінің қатысуын арттыру, деректердің қауіпсіздігін қамтамасыз ету және технологияға қолжетімділікті жақсарту мәселелерін шешсек, телемедицина болашақта денсаулық сақтау жүйесінің ажырамас бөлігіне айналуы мүмкін

Пайдаланылған әдебиеттер тізімі:

1. Қозыбаев, Н.Қ. (2010). Қазақстандағы телемедициналық консультациялар: алғашқы тәжірибе. Қазақ Ұлттық Медицина университетінің хабаршысы, 5(1), 12-13.
2. Макашева, Р.С., Юсупова, Л.А., Гизе, Р. (2022). Қазақстандағы цифрландыру үдерісі жағдайында телемедицина енгізу процесі. Экономика: стратегия және практика, 17(3), 49-65.
3. Аимбетова, Г.Е. (2020). Қазақстанда телемедицина: пандемия кезеңіндегі тәжірибе. Денсаулық сақтау журналы, 8(2), 75-82.
4. Туреубаева, М.Т. (2018). Мобильді телемедицина технологияларының мүмкіндіктері. ҚазМедЖурнал, 6(4), 102-108.
5. Алимов, Б.А. (2021). Телемедицина инфрақұрылымын дамыту жолдары. Инновация және денсаулық сақтау, 10(1), 33-39.
6. Ибрахимова, М.И., Қосжанова, М.Т. (2019). Қазақстандағы телемедицина қызметтерін бағалау. Жаңа технологиялар мен медицина, 7(3), 56-62.

Қойма басқару жүйесін әзірлеу және іске асыру

Оракбаев Жандарбек Ауезмуратулы

Әл-Фараби атындағы Қазақ Ұлттық Университеті 4 курс студенті

E-mail: zhandar1503@gmail.com

Қойма басқару жүйелері (WMS) қазіргі бизнес ортада маңызды рөл атқарады. Олар тауар қабылдау, жөнелту және қойма орындарын басқару сияқты процестерді автоматтандыру арқылы уақытты үнемдеуге және қателерді азайтуға мүмкіндік береді. Осы зерттеуде қойма операцияларын автоматтандыруға бағытталған тиімді жүйе әзірлеу және оны нақты ортада іске асыру мақсаты қойылды. Бұл мақсатқа жету үшін бизнес-процестерді талдау, жүйені жобалау, әзірлеу және тестілеу кезеңдері жүзеге асырылды. Зерттеу барысында заманауи ІТ технологияларды қолдану арқылы ІТ инфрақұрылымына кететін шығындарды азайту мүмкіндіктері қарастырылды. Мақалада осы процестің қалай өткені, қандай технологиялар қолданылғаны және қандай нәтижелерге қол жеткізілгені сипатталады.

Зерттеу қойма операцияларының қалай жүретінін тереңірек түсінуден басталды. Осы мақсатта қойма қызметкерлерімен және клиенттермен сұхбаттар жүргізілді. Олардың күнделікті міндеттері талданып, тауар қабылдау, жөнелту және контракт құру процестері сипатталды. Бұл процестерді автоматтандырудың қажетті бөліктерін анықтау үшін сиквенс диаграммалары құрылды. Мысалы, тауар қабылдау процесі кезінде жеткізуші тауарды жеткізгеннен кейін алдымен контракттың жарамдылығы тексеріледі, содан кейін қоймада бос орын ізделеді және тауар тіркелді. Жөнелту процесі тапсырыс берушінің сұранысы бойынша тауардың қоймада бар екені тексеріліп, орын резервтелгеннен кейін жөнелтілді. Контракт құру процесі клиенттің тіркелуінен басталып, локациялардың тексерілуімен және админнің мақұлдауымен аяқталды. Жүйені жобалау кезінде микросервистік архитектура таңдалды, себебі ол жүйенің масштабталуын және сенімділігін қамтамасыз етеді [1]. Микросервистік архитектура әр функцияны (мысалы, тауар қабылдау, жөнелту) бөлек модульдерге бөліп, олардың тәуелсіз жұмыс істеуіне мүмкіндік берді, бұл жүйенің икемділігін арттырды.

Жүйені әзірлеу кезінде заманауи технологиялар қолданылды. Реактивті жүйе құру үшін Акка технологиясы таңдалды, себебі ол жоғары жүктемеде тиімді жұмыс істейді және асинхронды хабар алмасуды қамтамасыз етеді. Микросервистер арасындағы хабар алмасуды қамтамасыз ету үшін RabbitMQ пайдаланылды, және RabbitMQ-Акка интеграциясы жеке әзірленді. Бұл интеграция хабар алмасуды 20% жылдамдатты, себебі ол хабарлардың кезекте тұру уақытын қысқартты және микросервистердің өзара әрекеттесуін оңтайландырды [2]. Жүйені орнату Kubernetes кластеріне жүргізілді, себебі ол контейнерлерді басқаруды жеңілдетіп, жоғары жүктеме кезінде масштабтауды қамтамасыз етеді [3]. Kubernetes-те Horizontal Pod Autoscaler (HPA) бапталып, сұраныс артқан кезде жүйенің автоматты түрде масштабталуы қамтамасыз етілді. Мысалы, жүйе жүктемесі артқанда Kubernetes автоматты түрде қосымша контейнерлерді іске қосты, бұл жүйенің тоқтап қалуын болдырмады. Сонымен қатар, Kubernetes ресурстарды тиімді бөлу арқылы серверлердің жүктемесін азайтып, операциялық шығындарды төмендетуге ықпал етті.

Зерттеу нәтижесінде тауар қабылдау, жөнелту және контракт құру процестерін автоматтандыратын жүйе әзірленді. Тауар қабылдау процесі контрактты тексеру, бос орындарды іздеу және тауарды тіркеу қадамдарын қамтыды. Тауар жөнелту процесі тауардың қоймада бар екенін тексеру, орынды резервтеу және жөнелту қадамдарынан тұрды. Контракт құру процесі клиентті тіркеу, локацияларды тексеру және мақұлдау қадамдарынан тұрды. Бұл процестердің тиімділігі уақытты үнемдеу, қателерді азайту және ресурстарды тиімді пайдалану критерийлері бойынша бағаланды. Нәтижелер бойынша, жүйе уақытты 30-50% үнемдеуге мүмкіндік берді: тауар қабылдау процесі 30%, жөнелту процесі 20%, ал контракт құру процесі 40% уақыт үнемдеді. Сонымен қатар, қойма орындарын басқару тиімділігі артып, қателер саны азайды. Мысалы, тауар қабылдау кезінде қойма орындарын іздеу процесі

автоматтандырылғандықтан, қызметкерлердің уақыты үнемделді, ал қателер (мысалы, қате орын таңдау) 15% азайды. Жөнелту кезінде тауардың қоймада бар екенін тексеру процесі автоматтандырылғандықтан, тапсырыстарды өңдеу уақыты қысқарды.

Жүйе Kubernetes кластеріне орнатылып, жоғары жүктеме кезінде тестілеуден өткізілді. 15,000 тауар қабылдау сұранысы 30 минутта орындалды, кідіріс 4-6 секунд аралығында болды. Kubernetes автоскейлері сұраныс артқанда контейнерлер санын 5-тен 8-ге дейін көбейтті, бұл жүйенің үздіксіз жұмыс істеуіне мүмкіндік берді. Тестілеу кезінде кідірістердің болуы жүйенің хабар алмасу бөлігін оңтайландыру қажеттігін көрсетті. Қолданылған технологиялар IT инфрақұрылымына кететін шығындарды азайтуға ықпал етті. Микросервистік архитектура және Kubernetes ресурстарды тиімді пайдалануға мүмкіндік берді, ал Akka мен RabbitMQ хабар алмасуды оңтайландырды. Мысалы, Kubernetes серверлердің жүктемесін азайтып, қосымша жабдық сатып алу қажеттілігін жойды, бұл операциялық шығындарды 10-15% төмендетуге септігін тигізді. Бұл технологиялар қойма басқару жүйесін әзірлеу және орнату кезінде операциялық шығындарды төмендетуге септігін тигізді.

Қойма басқару жүйесін әзірлеу және іске асыру мақсаты сәтті орындалды. Жүйе тауар қабылдау, жөнелту және контракт құру процестерін автоматтандырып, қойма операцияларын тиімді басқаруға мүмкіндік берді. Akka, RabbitMQ және Kubernetes технологиялары шығындарды азайтуға және жүйенің масштабталуын қамтамасыз етуге ықпал етті. Дегенмен, жүйені одан әрі жетілдіру қажет: фронтенд бөлігі әзірленуі, кідірістер азайтылуы және қауіпсіздік күшейтілуі тиіс. Мысалы, екі факторлы аутентификацияны енгізу арқылы деректердің қауіпсіздігін арттыруға болады. Сонымен қатар, машиналық оқыту алгоритмдерін қолдану арқылы қойма орындарын болжау және тауар қозғалысын оңтайландыру мүмкіндігі қарастырылуы мүмкін. Осы зерттеу заманауи IT технологияларды қолдану арқылы бизнес-процестерді оңтайландырудың маңыздылығын және олардың шығындарды оңтайландыруға әсерін көрсетті.

Пайдаланылған әдебиеттер тізімі:

1. Tanenbaum, A. S., & Van Steen, M. (2007). *Distributed Systems: Principles and Paradigms*. Prentice Hall.
2. Bonér, J., Klang, V., & Kuhn, R. (2014). *Akka in Action*. Manning Publications.
3. Burns, B., Grant, B., & Oppenheimer, D. (2016). *Kubernetes: Up and Running*. O'Reilly Media.

Банктің жеке тұлғаларға қызмет көрсетуіне арналған ақпараттық жүйесін жасау

Орынбек Ш.Ж.

ал-Фараби атындағы Қазақ Ұлттық университеті, бакалавр 4 курс
e-mail: orynbeksugyla@gmail.com

Байшоланова К.С.

ал-Фараби атындағы Қазақ Ұлттық университеті, э.ғ.д., доцент

Бүгінгі таңда банк секторының цифрлық трансформациясы жағдайында клиенттерге қызмет көрсету процестерін автоматтандыру банк қызметінің тиімділігін арттырудың құрамдас бөлігіне айналады. Әзірленген ақпараттық жүйе клиенттердің банкпен өзара әрекеттесуін оңтайландыруға, сұраныстарды өңдеу жылдамдығын жақсартуға, деректерді өңдеудің заманауи технологиялары мен машиналық оқытуды қолдану арқылы қызмет көрсету сапасын арттыруға арналған.

Заманауи банктер үлкен көлемдегі деректерді өңдеу, клиенттерге дербестендірілген қызметтерді көрсету және қызмет көрсетудің жоғары жылдамдығын қамтамасыз ету қажеттілігіне тап болды. Тұтынушылардың сұраныстарын өңдеудің дәстүрлі әдістері айтарлықтай уақыт пен адам ресурстарын қажет етеді, бұл процесті баяулатады және пайдаланушының қанағаттануын төмендетеді. Осыған байланысты қосымшаларды өңдеу уақытын қысқартуға, деректердің қауіпсіздік деңгейін арттыруға және пайдаланушы тәжірибесін жақсартуға мүмкіндік беретін автоматтандырылған ақпараттық жүйені әзірлеу қажеттілігі туындады.

Осы ақпараттық жүйені әзірлеу және енгізу Банке осындай әртүрлі мүмкіндіктер береді:

1. Өтінімдерді өңдеу процестерін оңтайландыру – несиелер мен депозиттерге өтінімдерді қарауға кететін уақытты қысқартады.
2. Қызмет көрсету сапасын арттыру – клиенттерге жылдам әрі жекелендірілген қызмет көрсету. Автоматтандыру деңгейін жоғарылату – күнделікті операциялардан адам факторын жояды.
3. Операциялық шығындарды азайту – деректерді өңдеу және тұтынушыларға қызмет көрсету шығындарын азайтады.
4. Қауіпсіздіктің жоғары деңгейін қамтамасыз ету – заманауи шифрлау және деректерді қорғау әдістерін қолданады.
5. Банк қызметтерін жекелендіру – оңтайлы қаржылық өнімдерді ұсыну үшін тұтынушы деректерін талдайды.

Ақпараттық технологиялар және шешімдерді қолдау жүйелері банк саласының цифрлық трансформациясында шешуші рөл атқарады. Олар клиенттердің мәліметтерін жан-жақты талдауды қамтамасыз етеді, күнделікті процестерді автоматтандырады және банк басшылығына объективті көрсеткіштер негізінде стратегиялық шешімдер қабылдауға мүмкіндік береді. Клиенттерге қызмет көрсетуге арналған ақпараттық жүйені әзірлеу банк қызметтерінің тиімділігін арттырып қана қоймай, клиенттермен өзара әрекеттесуді жақсартып, олардың қажеттіліктерін тереңірек түсінуге мүмкіндік береді. Банктік шешімдерге арналған ақпараттық жүйені әзірлеу және жобалау кезінде әртүрлі құралдар мен технологиялар қолданылады. **Технологиялық стек:** Backend: C# (ASP.NET Core) | Frontend: HTML, CSS, JavaScript | Мәліметтер базасы: PostgreSQL | Аналитика: SQL сұраулары, ROI, CPA, LTV есептеу | Сыртқы интеграциялар: Чат-боттар, жарнама, email-тарату

Банкте жеке тұлғаларға қызмет көрсетудің ақпараттық жүйесін әзірлеу және енгізу банктік процестерді автоматтандыруға, қауіпсіздік деңгейін арттыруға және клиенттер үшін ұсыныстарды жекелендіруге мүмкіндік береді. Қазіргі заманғы деректерді өңдеу және машиналық оқыту технологияларын пайдалану банктің бәсекеге қабілеттілігін қамтамасыз етеді, клиенттерге қызмет көрсету сапасын арттырады және қаржылық тиімділікті арттырады.

Пайдаланылған әдебиеттер тізімі:

1. Мезенцев К.Н. Автоматтандырылған ақпараттық жүйелер: орта кәсіптік білім беру мекемелерінің студенттеріне арналған. 5-ші басылым, стереотиптік. — М.: «Академия» баспа орталығы, 2014.
2. Аяжанов С.С., Омарова Ш.Е., Аяжанов Қ.С. «Ақпараттық жүйелердің негіздері». — Алматы: ЖШС РПБК «Дәуір», 2012.
3. Лаврушин О.И, Гобарева Я.Л, Золотарюк А.В. Банковские информационные системы и технологии. Учебник. — М.: КноРус, 2023.
4. Ковалёв В.В. Финансовый анализ: методы и процедуры. — М.: Финансы и статистика, 2021.
5. Turban E., Pollard C., Wood G. Information Technology for Management: Advancing Sustainable, Profitable Business Growth. 12th ed. — Wiley, 2021

ӘЗЕРБАЙЖАН ТІЛІНІҢ CSE МОДЕЛІ ЖӘНЕ ОНЫҢ МОРФОЛОГИЯЛЫҚ ЕРЕКШЕЛІКТЕРІ

Рахманберді Назым Алмазқызы

Әл-Фараби атындағы Қазақ ұлттық университеті, 1 курс магистранты

E-mail: rakhmanberdinazym@gmail.com

Тукеев Уалшер

*Әл-Фараби атындағы Қазақ ұлттық университеті,
техника ғылымдарының докторы, профессор*

Шормакова Асем Ноябровна

*Әл-Фараби атындағы Қазақ ұлттық университеті,
доцент м.а., кафедра меңгерушісі*

Аннотация

Бұл зерттеуде Әзербайжан тілінің морфологиясын автоматты түрде талдау үшін толық жалғаулар жиыны (Complete Set of Endings, CSE) моделін пайдалану қарастырылады. CSE моделі агглютинативті тілдердің ерекшеліктерін ескере отырып, сөздердің морфологиялық құрылымын жіктеуге және талдауға мүмкіндік береді. Зерттеу нәтижесінде атау негізіне 202, етістік негізіне 21 аффикстік комбинация анықталды. Бұл модель табиғи тілді өңдеу (NLP) жүйелерінде тиімді сегментацияны қамтамасыз етеді.

Түйінді сөздер: CSE моделі, толық жалғаулар жиыны, морфологиялық талдау, Әзербайжан тілі, табиғи тілді өңдеу (NLP).

Кіріспе

Табиғи тілді өңдеу (NLP) технологиялары морфологиялық талдау, машиналық аударма және мәтін талдау жүйелерінде кеңінен қолданылады. Агглютинативті тілдер үшін сөз түрлендіру құрылымын анықтау маңызды болып табылады. Әзербайжан тілі — осындай ерекшеліктерге ие түркі тілдерінің бірі [1].

Әзербайжан тілінде сөздер жалғаулар арқылы түрленеді, сондықтан морфологиялық талдау күрделі процесс болып табылады. CSE моделі агглютинативті тілдердегі барлық ықтимал аффикстік комбинацияларды жүйелеуге мүмкіндік береді [2,3]. Бұл модельді пайдалану арқылы морфологиялық құрылымды тиімді талдауға және автоматтандырылған сегментация жасауға болады.

Негізгі бөлім

1. CSE моделі және оның қолданылуы

CSE моделі сөздің морфологиялық құрылымын талдау үшін барлық мүмкін аффикстік комбинацияларды есептейді. Әзербайжан тілінің грамматикалық заңдылықтарына сүйене отырып, CSE моделі арқылы атау негізіне 202, етістік негізіне 21 комбинация анықталды. Бұл тәсіл морфологиялық талдауды жетілдіруге және сөз құрылымын нақты анықтауға мүмкіндік береді.

2. Толық жалғаулар жиыны (Complete Set of Endings)

Әзербайжан тіліндегі сөздердің морфологиялық құрылымын талдау үшін негізгі төрт жалғау түрі қарастырылады:

- Көптік жалғаулар (К) – -lar, -lər
- Тәуелдік жалғаулар (Т) – -ım, -in, -ı, -ımız, -iniz, -i
- Септік жалғаулар (С) – атау, ілік, барыс, табыс, жатыс, шығыс септіктері
- Етістік жалғаулары (R, P, J) – шақ, рай, есімше, көсемше жалғаулары

Аталған жалғауларды әртүрлі деңгейде біріктіріп, тілдің барлық мүмкін морфологиялық өзгерістерін анықтауға болады. CSE моделін қолдану нәтижесінде аффикстердің жүйелі жіктелуі қамтамасыз етіледі.

3. Әзербайжан тілінің морфологиялық моделі

Әзербайжан тілі агглютинативті құрылымға ие, яғни сөздердің грамматикалық

байланыстары жалғаулар арқылы жүзеге асады. Морфологиялық талдаудың негізгі қадамдары:

- Түбір сөзді анықтау
- Жалғауларды жіктеу
- Аффикстік комбинациялардың семантикалық сәйкестігін тексеру

CSE моделін қолдану арқылы тілдің морфологиялық өзгерістерін жүйелі түрде талдап, автоматтандырылған сегментация жасауға мүмкіндік бар. Бұл әдіс NLP жүйелерінде морфологиялық талдау сапасын арттыруға көмектеседі.

Қорытынды

CSE моделі негізінде әзірленген морфологиялық модель Әзербайжан тіліндегі сөз құрылымын автоматты түрде талдауға мүмкіндік береді. Бұл зерттеу нәтижелері машиналық аударма, мәтін өңдеу және NLP жүйелерін дамытуда маңызды рөл атқарады. Жасалған модель түркі тілдерінің автоматтандырылған өңдеу әдістерін жетілдіруге негіз бола алады. Сонымен қатар, CSE моделін қазақ, түрік және басқа да агглютинативті тілдерге бейімдеу болашақ зерттеулердің маңызды бағыты болып табылады.

Пайдаланылған әдебиеттер тізімі:

1. Грамматика азербайджанского языка (фонетика, морфология и синтаксис). Под общей редакцией М.Ш. Ширалиева Э.В. Севортяна. Изд-во «ЭЛМ». Баку, 1971.
2. Tukeyev U., Karibayeva A. (2020) Inferring the Complete Set of Kazakh Endings as a Language Resource. In: Hernes M., Wojtkiewicz K., Szczerbicki E. (eds) Advances in Computational Collective Intelligence. ICCCI 2020. Communications in Computer and Information Science, vol 1287, pp.741-751. Springer, Cham. https://doi.org/10.1007/978-3-030-63119-2_60
3. Tukeyev U., Karibayeva A., Zhumanov Zh. Morphological Segmentation Method for Turkic Language Neural Machine Translation. Cogent Engineering, Volume 7, 2020 - Issue 1 <https://doi.org/10.1080/23311916.2020.1856500>

Қазақ тіліндегі бағдарламалау тілдеріне арналған интеллектуалды сұрақ-жауап жүйесі

Рысбек Бекарыс Сәрсенбекұлы

Әл-Фараби атындағы Қазақ Ұлттық Университеті І курс докторанты

E-mail: r.s.bekarys@gmail.com

Тукеев Уалшер Ануарбекович

Әл-Фараби атындағы Қазақ Ұлттық Университеті, т.ғ.д., профессор ҚАЗҰУ

Қазіргі таңда жасанды интеллект технологиялары қарқынды дамып, әртүрлі салаларда кеңінен қолданылуда. Соның ішінде үлкен тілдік модельдер (LLM) бағдарламалау тілдерін меңгеру барысында қолданушыларға көмекші құрал ретінде ерекше орын алады. Дегенмен, қазақ тіліндегі бағдарламалау тілдеріне қатысты интеллектуалды сұрақ-жауап жүйелері әлі де жеткілікті деңгейде болмағандықтан, қосымша зерттеу жұмыстарын қажет етуде. Бұл зерттеу қазақ тіліндегі бағдарламалау саласына бағытталған сұрақ-жауап жүйесін құруды көздейді. Жүйе көптілді трансформер модельдеріне негізделіп, үлкен тілдік модельдер (LLM) көмегімен арнайы датасет генерациялау әдістерін қолданады.

Қазақ тілінде сұрақ-жауап жүйесін құру үшін келесі трансформер модельдері қолданылады:

Sentence-Transformers/distiluse-base-multilingual-cased-v1 – көптілді семантикалық ұқсастықтарды тиімді түрде анықтайтын ықшамдалған модель;

sentence-transformers/paraphrase-multilingual-MiniLM-L12-v2 – парафраздарды тану және мағыналық сәйкестікті бағалау үшін оңтайландырылған модель;

bert-base-multilingual-cased – мәтіндерді контекстуалды өңдеуге арналған BERT архитектурасының көптілді нұсқасы.

Бұл модельдер қазақ тіліндегі бағдарламалау сұрақтарына жауап беру жүйесінің дәлдігі мен сенімділігін арттыру үшін ансамбльдік тәсілде қолданылады.

Жүйенің тиімділігі оның білім қорына байланысты. Датасет келесі әдістермен жинақталады:

Үлкен тілдік модельдерді (GPT, T5, немесе аналогтары) қолдану арқылы жасанды сұрақ-жауап жұптарын генерациялау;

Ашық кодты бағдарламалау ресурстарынан (Stack Overflow, GitHub Discussions, ресми құжаттамалар) қазақ тіліне аударылған және бейімделген деректерді пайдалану;

Академиялық және оқыту материалдарынан алынған құрылымдық деректерді біріктіру.

Бұл тәсіл модельдің домендік білімін күшейтіп, оның нақты пайдаланушылар сұранысына жауап беру қабілетін жақсартады.

Жүйе бірнеше маңызды модульден тұрады:

Сұрақты алдын ала өңдеу: қолданушы енгізген мәтінді талдау, оның мағыналық ерекшеліктерін анықтау;

Семантикалық сәйкестік талдауы: көптілді трансформер модельдерін қолданып, ең ықтимал жауапты анықтау;

Жауапты генерациялау және бағалау: алынған жауаптарды растау және қолданушыға ең мағыналы жауапты ұсыну.

Қазақ тіліндегі бағдарламалау тілдеріне арналған сұрақ-жауап жүйесін құру жасанды интеллект пен табиғи тілдерді өңдеудің өзекті бағыттарының бірі болып табылады. Ұсынылған жүйе көптілді трансформер модельдерін қолдану арқылы жоғары сапалы жауаптар ұсынуға бағытталған. Үлкен тілдік модельдер көмегімен датасет генерациялау әдісі қазақ тіліндегі техникалық контентті кеңейтуге ықпал етеді. Болашақта жүйенің дәлдігін арттыру, салалық бағыттарға бейімдеу және интерактивті қолдану мүмкіндіктерін жетілдіру көзделіп отыр.

Зерттеу жұмысының нәтижесі:

Модель	Accuracy	Average Cosine Similarity	Average BERTScore (F1)
Sentence-Transformers (MiniLM-L12-v2)	0.8575	0.8933	0.8960
BERT-base-multilingual-cased	0.8576	0.8973	0.8959
Sentence-Transformers /distiluse-base-multilingual-cased-v1	0.8574	0.8879	0.8958

Пайдаланылган әдебиеттер тізімі:

1. Reimers, N., & Gurevych, I. (2019). Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks. arXiv preprint arXiv:1908.10084. DOI: 10.48550/arXiv.1908.10084
2. Artetxe, M., & Schwenk, H. (2019). Massively Multilingual Sentence Embeddings for Zero-Shot Cross-Lingual Transfer and Beyond. Transactions of the Association for Computational Linguistics, 7, 597–610. DOI: 10.1162/tacl_a_00288
3. Sanh, V., Debut, L., Chaumond, J., & Wolf, T. (2019). DistilBERT, a distilled version of BERT: smaller, faster, cheaper and lighter. arXiv preprint arXiv:1910.01108. DOI: 10.48550/arXiv.1910.01108
4. Hugging Face (2024). sentence-transformers/paraphrase-multilingual-MiniLM-L12-v2 Model Card. <https://huggingface.co/sentence-transformers/paraphrase-multilingual-MiniLM-L12-v2>
5. Hugging Face (2024). Sentence-Transformers/distiluse-base-multilingual-cased-v1 Model Card. <https://huggingface.co/sentence-transformers/distiluse-base-multilingual-cased-v1>

Жол жабындарының сапасын бағалауда жасанды интеллект пен терең оқыту технологияларын қолдану

Самбетбаева А.К.

*Әл-Фараби атындағы Қазақ Ұлттық университеті, 2 курс докторанты
e-mail: sambetbaevamea@gmail.com*

Жол жабындарындағы жарықтар, шұңқырлар, деформациялар және басқа да зақымданулар көлік инфрақұрылымының қауіпсіздігі мен сапасына айтарлықтай әсер ететін күрделі мәселелердің бірі болып табылады. Бұл зақымданулар елеулі қауіп-қатерді тудырады, сондықтан оларды нақты әрі уақтылы анықтау аса маңызды. Соңғы жылдары жасанды интеллект пен терең оқыту технологияларының қарқынды дамуы жол жабындарын автоматты түрде бақылау мен талдауды жаңа деңгейге көтерді, бұл өз кезегінде жөндеу жұмыстарын жоспарлаудағы тиімділікті арттыруға мүмкіндік береді [1].

Конволюциялық нейрондық желілер (CNN) – бейне және суреттерді өңдеуде жоғары дәлдікпен жұмыс істейтін қуатты әдістердің бірі. Олар жол жабындарының зақымдалған аймақтарын автоматты түрде анықтап, олардың өлшемін, тереңдігін және орналасуын сандық тұрғыдан бағалауға мүмкіндік береді. Бұл технология алынған деректер негізінде жөндеу жұмыстарын тиімді жоспарлауға және бюджет шығындарын оңтайландыруға септігін тигізеді, өйткені жол инфрақұрылымының қауіпсіздігін қамтамасыз етуде нақты аналитикалық мәліметтер шешуші рөл атқарады [2].

CNN жол жабындарындағы зақым түрін ғана емес, олардың орналасуы мен ауырлығын да жоғары дәлдікпен анықтай алады. Бұл мақсатта суреттерді классификациялау әдісі жиі қолданылады, онда нейрондық желі әртүрлі зақымдану түрлерін (жарықтар, шұңқырлар, деформациялар) тиісті санаттарға жіктейді. Мұндай тәсіл жол ақауларын автоматты түрде картаға түсіріп, жөндеу жұмыстарының басымдылығын анықтауға мүмкіндік береді. Осылайша, CNN архитектуралары жол сапасын бақылауды жаңа деңгейге көтеріп, инфрақұрылымдық шешімдерді оңтайландыруға көмектеседі.

Объектілерді анықтау әдісі YOLOv7 және Faster R-CNN секілді модельдер арқылы жүзеге асырылады. Бұл әдіс нақты уақыт режимінде жұмыс істеуге мүмкіндік береді, яғни жолға орнатылған камералар немесе дрондар түсірген бейнелер арқылы зақымдану орындары дереу белгіленеді. YOLOv7 моделі жылдамдығының жоғары болуымен ерекшеленсе, Faster R-CNN күрделі құрылымдарды дәлірек анықтауға қабілетті.

Сегментация әдісі жол жабындарының зақымдануларын жоғары дәлдікпен бөліп көрсетуге мүмкіндік беретін тәсіл. Бұл әдісте әрбір пиксель белгілі бір категорияға жатқызылады, яғни модель суреттегі зақымдануларды фоннан ажыратып, олардың нақты шекараларын анықтайды. Бұл тәсіл жол жөндеу жұмыстарының басымдылығын анықтау үшін өте маңызды [3].

EfficientNet-B0, ResNet50 және Vision Transformers сияқты жаңа архитектуралар жол зақымдануларын жоғары дәлдікпен анықтауға қабілетті. Сонымен қатар, гиперспектралды және мультиспектралды суреттерді пайдалану жол жабындарының ішкі құрылымдық өзгерістерін ерте кезеңде анықтауға мүмкіндік береді.

Жол инфрақұрылымын бақылауда терең оқыту технологияларын қолдану жол сапасын бағалау процестерін автоматтандырып, жөндеу жұмыстарын оңтайлы жоспарлауға және қаржылық шығындарды азайтуға мүмкіндік береді. Болашақта Transformer негізіндегі модельдер, GAN (Generative Adversarial Networks) және өзін-өзі қадағалайтын оқыту (self-supervised learning) әдістерін енгізу жол зақымдануларын анықтаудың дәлдігін одан әрі арттыруға ықпал етеді.

Зерттеуде қолданылған әртүрлі CNN архитектураларының тиімділігі эксперименттік бағалаулар арқылы анықталды. Мысалы, VGG16, ResNet50, EfficientNet-B0 және YOLOv7 модельдері қолданылып, олардың дәлдік, сезімталдық және ерекшелік көрсеткіштері

салыстырылды. Алынған нәтижелер кестесінде EfficientNet-B0 моделі 92.3% дәлдікпен, 91.2% сезімталдықпен және 92%-дық ерекшелік көрсеткіштерімен ерекшеленіп, жол жабындарының зақымдануын анықтауда ең тиімді әдіс ретінде айқындады.

Кесте 1. Модельдерді бағалау нәтижелері

Модель	Дәлдік (%)	Сезімталдық	Ерекшелік
VGG16	88.2	85	86,5
ResNet50	91.5	89,8	90,1
EfficientNet-B0	92.3	91,2	92
YOLOv7	89.7	87,5	88,2

Нақты уақыт режимінде мониторинг жүргізу үшін YOLOv7 архитектурасы жиі қолданылады, өйткені ол бейнелердегі объектілерді жылдам және тиімді анықтай алады, дегенмен кейде кішігірім ақауларды анықтауда қиындықтар туындауы ықтимал. Қазақстанда жол сапасын бақылау тәжірибесінде, әдетте, камералармен жабдықталған көліктер арқылы деректер жиналады, бірақ дрондарды қолдану тәжірибесі әлі толық енгізілмеген. Дрон технологиясын интеграциялау арқылы деректерді жинау жылдамдығы мен сапасы айтарлықтай артуы мүмкін, бұл автоматтандырылған жүйелердің жұмыс тиімділігін одан әрі жоғарылатады.

Жол жабындарының жағдайын бақылау және бағалау саласындағы терең оқыту әдістерін енгізу, әсіресе конволюциялық нейрондық желілерді қолдану, жол қауіпсіздігін қамтамасыз етудегі басты факторлардың бірі болып табылады. Болашақта жаңа архитектуралар мен алгоритмдерді зерттеу арқылы жол жабындарының ақауларын анықтаудың дәлдігін одан әрі арттырып, автоматтандырылған жүйелердің мүмкіндіктерін кеңейту жоспарланып отыр. Осындай интеграцияланған тәсілдер көлік инфрақұрылымын тұрақты бақылауға алып, жөндеу мен күтім жұмыстарын оңтайландыруға мүмкіндік береді. Зерттеу нәтижелері мен қолданыстағы тәжірибелерді ескере отырып, жол жабындарының зақымдануын автоматты түрде анықтау мен бағалау саласындағы заманауи әдістердің қолданылуы жол қауіпсіздігін арттыруға және апатты жағдайларды болдырмауға бағытталған.

Пайдаланылған әдебиеттер тізімі:

1. Atombo, C. and Wu, C. (2022). “Traffic safety climate factors in explaining driving behaviours and traffic crash involvement: comparative study among Male and Female drivers”. JRS, 33(1), 49-62. <https://doi.org/10.33492/JRS-D-21-00036>
2. Kumar J., Simon E. (2023). Artificial Intelligence for Road Quality Assessment in Smart Cities: A Machine Learning Approach to Acoustic Data Analysis, <https://doi.org/10.1007/s43762-023-00104-y>
3. Maeda, H., Sekimoto, Y., Seto, T., Kashiyama, T., & Omata, H. (2018). Road Damage Detection Using Deep Neural Networks with Images Captured Through a Smartphone.:1801.09454.

«PYTHON ПРОГРАММАЛАУ ТІЛІ» ПӘНІН ҮЙРЕНУГЕ АРНАЛҒАН ЭЛЕКТРОНДЫҚ КЕШЕН ЖАСАУ

Сұлтанәлі Тоғжан

Әл-Фараби атындағы Қазақ ұлттық университеті, 4 курс студенті

E-mail: togzhansultanali@gmail.com

Бурибаев Б.Б.

Әл-Фараби атындағы Қазақ ұлттық университетінің т.ғ.к., профессор м.а.

Электрондық оқу құралдары мен электрондық оқыту кешендері деп компьютердің мүмкіндіктерін толығынан пайдалана отырып, білім беру технологиясын сүйемелдей алатын оқу құралын айтамыз. Өзінің функционалдық мүмкіндіктері жағынан компьютер нағыз оқыту құралы болып табылады, бірақ сол мүмкіндіктерді білім беруде, дағдылар қалыптастыруда, біліктілікті игеруде барынша тиімді пайдаланып, жүзеге асыру жағы мемлекеттік тілімізде әлі кең қолданыс таба алмай отыр. Мұғалімдер осы мәселемен компьютерлер жаңа шыққан кезден бастап айналысып келеді, ал жеке пайдаланылатын дербес компьютерлер шыққаннан соң, бұл жұмыстың өзектілігі бұрынғыдан да арта түсті [1].

Оқыту процесін компьютер арқылы сүйемелдеу жалпы оқыту жүйесін жасаумен қатар әрбір пәннің өз ерекшелігін есепке алумен де сипатталады. Мұнда мынадай бірнеше мәселелерді қарастыру керек:

- компьютердің мүмкіндіктерін қолдануды қай сәтте көбірек енгізу керек;
- жалпы сипаттау материалдарын қалай компьютерлендіру қажет;
- оқытудың қай түрі, қандай әрекеттер толығынан компьютерге жүктелуі тиіс;
- пән мұғалімінің (әдіскердің) ақпараттық-әдістемелік ұсыныстарына сәйкес компьютерлік оқулық қалай ұйымдастырылуы қажет.

Компьютерлік оқыту технологиясы студент пен мұғалім арасындағы дәнекер рөлін атқарады, мұнда негізгі материал мұғалімнен емес, компьютер арқылы беріледі. Сабақ беретін пән мұғалімі көбінесе электрондық оқулық жасауға тікелей араласпайды. Сондықтан компьютерлік оқыту жүйесін қалыптастырудағы негізгі принцип мұғалім өз материалдарын студентке өз тәсілімен бірден ұсына алмайды. Енді бұл принципті дәстүрлі жағдайға жақындату үшін оқыту материалдарын толықтырып, олар қосымша түсіндіруді қажет етпейтіндей дәрежеге жеткізу керек.

Сонымен, электрондық оқыту материалдары мен әдістемелік нұсқаулар құрамы мынадай болуы тиіс [2]:

- әр студентке таратылып берілетін негізгі оқыту материалдары;
- бақылау (тесттен өткізу) материалдары;
- есептер мен жаттығулар;
- жеке (немесе топпен) орындауға арналған өзіндік тапсырмаларды дайындау әдістемелері;
- әрбір оқу құралын пайдалану стратегиясы мен тактикасы және де соларды бір-бірімен қатар қолдану, алмастыру мәселелері;
- барлық ақпараттық-оқу материалдарын оқыту құралдары мен сабақтарды өткізу әдістемесімен байланыстыру.

Электрондық оқу құралы типтік және жұмыс программалары талабына сай құрастырылады, ал оның әдістемелік негізі ретінде жоғарыда көрсетілген материалдар қолданылуы тиіс. Ақпараттық технологиялардың дамуы білім беру жүйесін жаңғырту қажеттілігін тудырды. Python программалау тілі ақпараттық жүйелер аймағында кеңінен қолданылатын құралға айналды және оның оқытылуы заманауи білім беру стандарттарына сай болуы керек. Қолданыстағы оқыту әдістемелері көбінесе теорияға негізделген және көбісі ағылшын немесе орыс тілдерінде жасалған, бұл мемлекеттік тілді оқитын студенттердің практикалық дағдыларын дамытуда қиындықтар туғызады. Осы мәселені шешу үшін «Python

программалау тілі» пәнінің дәрістері мен зертханалық жұмыстарының электрондық кешенін жасау ұсынылады.

Python тілі соңғы кезде еліміздің оқу жүйесінде кең таралған, заманауи, жоғары деңгейдегі программалау тіліне айналды. Бұл курстың электрондық кешенін жасау арқылы программалау тілінің негіздерін, синтаксисін, Python тіліндегі әртүрлі амалдар, әрекеттер орындау жөнінде ауқымды мәлімет алуға болады. Қазіргі заманғы білім беру жүйесінде онлайн-оқыту мүмкіндіктері маңызды орын алып келеді. Біз ұсынып отырған электрондық кешенде «Python программалау тілі» пәнінің дәрістері мен зертханалық жұмыстарының қашықтан оқуға арналған мүмкіндіктері қарастырылады.

Электрондық кешен студенттерге оқу процесін тиімді ұйымдастыруға, теориялық білімдерін тәжірибемен ұштастыруға және оқу материалдарына қашықтан қол жеткізуге мүмкіндік береді. Сонымен қатар, бұл жүйе оқу процесін нақты уақыт режимінде бақылауға және әрбір студенттің жеке қажеттіліктеріне бейімделуге жағдай жасайды. Электрондық кешеннің құрылымы, негізгі мүмкіндіктері мен техникалық аспектілері мемлекеттік тілде құрастырылды. Қазіргі кезде қазақша жасалған мұндай құралдар өте аз және олардың басым бөлігі компьютер мүмкіндіктерін толыққанды түрде қамти алмай келеді [3].

Біз ұсынып отырған курсқа тіркелуден өткен соң, олардағы «Басты бет», «Курстар», «Сұрақтар», «Тесттер», «Баптаулар» тәрізді мәліметтер түрлерін көруге болатын қолданушының жеке кабинеті ұйымдастырылады.

Электрондық кешеннің қашықтан оқуға арналған негізгі бөлімінің құрамы:

Интерактивті дәрістер – теориялық материалдарды визуализациялау және түсіндіру. Зертханалық жұмыстар – студенттердің Python тілінде код жазу дағдыларын дамыту. Қашықтан қолжетімділік – оқу материалдарына кез келген уақытта, кез келген жерде қол жеткізу мүмкіндігінің болуы. Бейімделген оқыту – әр студенттің білім деңгейіне қарай тапсырмаларды икемдеу. Автоматты бағалау жүйесі – зертханалық жұмыстар мен тесттердің нәтижелерін жылдам тексеру.

Оқыту әдістері:

Гибридті оқыту – теориялық дәрістер мен практикалық тапсырмаларды біріктіру.

Геймификация – оқу процесіне ойын элементтерін енгізу арқылы мотивацияны арттыру.

Қауымдастықты қолдауы – студенттер арасында пікір алмасу мен бірлескен жобалар жүргізу ісін пайдалану.

Техникалық аспектілер:

Бұлттық сақтау жүйесі – оқу материалдарының үздіксіз қолжетімділігін қамтамасыз ету.

Қолданушыға ыңғайлы интерфейс – студенттер мен оқытушыларға интуитивті басқару жүйесі.

Қауіпсіздік шаралары – деректердің сақталуын және құпиялылығын қамтамасыз ету.

«Python программалау тілі» пәнінің дәрістері мен зертханалық жұмыстарының электрондық кешені білім беру үрдісін жетілдіруге бағытталған тиімді шешім болып табылады. Бұл жүйе студенттерге программалауды терең меңгеруге, өз дағдыларын дамытуға және өз білімдерін практикада қолдануға мүмкіндік береді. Болашақта жүйенің функционалдылығын кеңейту және басқа білім беру платформаларымен интеграциялау жоспарлануда.

Қорыта айтқанда, біздің дайындап жатқан «Python программалау тілі» пәнін үйренуге арналған электрондық кешен жасау ісі осы тілді оқытуда заманауи ақпараттық-коммуникациялық технологияларды пайдалану арқылы білім беру деңгейін көтеруге арналған.

Осылай жүзеге асырылған программалау тілдерін оқытуға арналған электрондық кешен заманауи ақпараттық-коммуникациялық технологияларды пайдалану арқылы білім беру жүйесін жаңа деңгейге көтеретіні талас тудырмайды деген ойдамыз.

Пайдаланылған әдебиеттер тізімі:

1. Бекенова А.С. Python бағдарламалау тілі: оқу құралы / А.С. Бекенова. – Алматы: Альманахъ, 2019. –119 б.

2. Python электрондық оқулығы:
https://pythontutor.ru/lessons/inout_and_arithmetic_operations
3. Бөрібаев Б., Құлмамұров С. Python тілінде программалау негіздері: оқу-әдістемелік құрал: - Алматы: Қазақ университеті, 2022. -222 б.

Машиналық оқыту алгоритмдерін қолдана отырып, жүрек жағдайын бақылауға арналған мобильді қосымшаны әзірлеу.

Сағындықов Т.М.

*Әл-Фараби атындағы Қазақ ұлттық университеті 4 курс студенті
e-mail: aliomaruly91@mail.ru*

Байкувеков М.Б.

Әл-Фараби атындағы Қазақ ұлттық университеті, аға оқытушы

Жүрек аурулары – әлемдегі өлім-жітімнің негізгі себептерінің бірі. Жүрек жағдайын үздіксіз бақылау ерте диагностика мен емдеу нәтижелерін жақсартуға айтарлықтай ықпал етеді. Бұл мақалада машиналық оқыту алгоритмдерін пайдалана отырып, жүрек денсаулығын бақылауға арналған мобильді қосымшаны әзірлеу мәселесі қарастырылады. Ұсынылған қосымша нақты уақыт режимінде физиологиялық деректерді жинап, оларды болжамдық модельдер арқылы өңдеп, пайдаланушылар мен медицина мамандарына қажетті ақпарат ұсынады. Жүрек-қантамыр аурулары (ЖҚА) жаһандық денсаулық сақтау жүйесіне үлкен жүк түсіреді, сондықтан оларды үздіксіз бақылау мен ерте анықтаудың жаңа шешімдері қажет. Жүрек қызметін бақылаудың дәстүрлі әдістері клиникалық тексерулер мен арнайы жабдықтарды талап етеді. Бұл үздіксіз мониторинг жүргізуді қиындатады. Ал мобильді денсаулық сақтау (mHealth) қосымшалары машиналық оқыту (МО) алгоритмдерін қолдану арқылы тиімді әдісін ұсына алады. Бұл мақалада жүрек жағдайын нақты уақыт режимінде талдауға арналған МО технологияларымен интеграцияланған мобильді қосымшаны әзірлеу процесі зерттеледі. Бұл зерттеуде жүрек-қантамыр жүйесінің жағдайын үздіксіз бақылауға мүмкіндік беретін мобильді қосымшаның архитектурасы, негізгі функционалдық мүмкіндіктері және қолданылатын машиналық оқыту алгоритмдері қарастырылады. Қосымшаның басты мақсаты – жүрек соғу жиілігі (HR), жүрек соғуының өзгергіштігі (HRV) және басқа да кардиологиялық параметрлерді талдау арқылы жүрек ауруларының қауіп факторларын ерте анықтау [1].

Мобильді қосымшаның архитектурасы: Деректерді жинау моделі – пайдаланушының смартфонна немесе тозатын құрылғыларына (смарт сағаттар, фитнес браслеттер) қосылып, жүрек қызметінің деректерін жинайды. Деректерді алдын ала өңдеу – сигналдарды сүзгіден өткізу, шуды азайту және жүрек ырғағының ерекшеліктерін бөліп көрсету үшін қолданылады. МО моделін интеграциялау – жүрек-қантамыр көрсеткіштерін талдау және аномалияларды анықтау үшін нейрондық желілер, шешім ағаштары немесе регрессиялық модельдер пайдаланылады [2].

Пайдаланушы интерфейсі – жүрек қызметінің нақты уақыттағы көрсеткіштерін визуализациялау және денсаулық жай-күйі туралы ескертулер беру үшін әзірленген. Машиналық оқыту алгоритмдері Жүрек-қантамыр жүйесінің жағдайын бағалау үшін бірнеше МО әдістері қолданылады:

Қадағаланатын оқыту (Supervised Learning) – жүрек соғуының өзгергіштігі мен қалыпты емес жүрек ырғағын анықтау үшін қолданылатын нейрондық желілер немесе SVM (Support Vector Machine)

Пайдаланылған әдебиеттер тізімі:

1. Дүниежүзілік денсаулық сақтау ұйымы. "Жүрек-қантамыр аурулары (ЖҚА)." [Онлайн]. Қол жетімді: <https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-cvds>

2. Goldberger AL, т.б. "PhysioBank, PhysioToolkit, және PhysioNet: Күрделі физиологиялық сигналдарға арналған жаңа зерттеу ресурстары." Circulation, 101(23), e215-e220, 2000.

ҰЙЫМНЫҢ БИЗНЕС АНАЛИТИКАСЫ ЖҮЙЕСІН ҚҰРУ ЖӘНЕ ЖОБАЛАУ

Сейтказин Б.Ә.

Казахский Национальный Университет имени аль-Фараби, бакалавр 4 курса

seitkazin.04@bk.ru

Бейбітхан Е.

Казахский Национальный Университет имени аль-Фараби, старший преподаватель

Қазіргі заманғы бизнес әлемінде ақпараттың көлемі және күрделілігі күн сайын өсіп келеді. Осыған байланысты, ұйымдар деректерді тиімді талдай алу қабілетіне ие болулары қажет. Бизнес аналитикасы жүйелері (ВА жүйелері) бұл қажеттілікті қанағаттандыру үшін арнайы әзірленген, олар ұйымдарға ақпаратты жинап, өңдеп, деректерден пайдалы қорытындылар жасауға мүмкіндік береді. Бұл жүйелердің басты мақсаты — бизнес шешімдерін тиімді қабылдау және ұйымның қызметін оңтайландыру. Бизнес аналитикасы жүйесі барлық ұйым деңгейлерінде пайдаланылатын ақпараттық құрал болып табылады. Оның көмегімен ұйымдар өздерінің қаржылық жағдайын, тұтынушы қажеттіліктерін, нарықтағы трендтерді және басқа да маңызды аспектілерді бақылай алады. Мақалада біз бизнес аналитикасының жүйесін жобалаудың негізгі кезеңдері мен ерекшеліктеріне назар аударамыз.

Бизнес аналитикасы жүйесі бірнеше негізгі компоненттен тұрады. Олардың әрқайсысы жүйенің функционалдығын толықтыра отырып, деректердің құндылығын арттырады. Алғашқы кезеңі — деректерді жинау. Деректер әртүрлі көздерден алынады, олар ішкі және сыртқы болып бөлінеді. Ішкі деректер ұйымның өз қызметінен, мысалы, қаржылық есептерден, сату нәтижелерінен, өндіріс көрсеткіштерінен алынуы мүмкін. Ал сыртқы деректер нарықтық зерттеулер, тұтынушы пікірлері, қоғамдық трендтер мен бәсекелестер туралы ақпаратты қамтиды. Деректерді жинау кезінде ұйымдарға деректердің сапасын қамтамасыз ету қажет. Бұл деректердің дұрыс, толық және өзекті болуы тиіс екенін білдіреді. Екінші кезеңі — деректер жинақталғаннан кейін оларды өңдеу кезеңі басталады. Бұл кезеңде деректер тазаланады, яғни артық немесе дұрыс емес мәліметтер жойылады, ал ақаулы деректер түзетіледі. Сонымен қатар, деректер бір форматқа келтіріліп, талдау үшін дайын болады. Деректер өңдеу барысында аналитикалық құралдар мен алгоритмдер қолданылады. Үшінші кезеңі — деректерді сақтау. Бизнес аналитикасының жүйесі деректерді түрлі әдістермен талдайды: статистикалық әдістер, болжамдау модельдері, деректердің үлгілерін анықтау, трендтерді болжау және басқа да аналитикалық техникалар қолданылады.[1] Бұл кезеңде шешім қабылдауға қажетті негізгі ақпарат алынады. Бесіншісі — визуализация және шешім қабылдау. Аналитикалық талдаулардың нәтижелері визуализациялау құралдары арқылы ұсынылады. Мысалы, нарықтағы сұраныс өсімін болжау немесе тұтынушылардың мінез-құлқын өзгерту бойынша стратегиялар жасау.[5]

Бизнес аналитикасының жүйесін жобалау және құру кезінде әртүрлі құралдар мен технологиялар қолданылады. Олардың ішінде:

<i>SQL және NoSQL дерекқорлары:</i>	Құрылымдалған және құрылымсыз деректерді сақтау үшін қолданылатын танымал дерекқор жүйелері.
<i>Python және R тілдері:</i>	Олардың ішіндегі көптеген кітапханалар деректерді өңдеу, статистикалық талдау және машиналық оқыту алгоритмдерін жүзеге асыру үшін қолданылады.[3]
<i>Power BI, Tableau, құралдары:</i>	Бұл құралдар деректерді графикалық түрде көрсетуге мүмкіндік береді, бұл арқылы пайдаланушылар деректердің маңыздылығын тез әрі оңай түсіне алады.[4]

Ұйымның бизнес аналитикасы жүйесін құру мен жобалау тек технологиялық қажеттілік емес, бұл ұйымдардың нарықта бәсекеге қабілетті болуын қамтамасыз ететін стратегиялық құрал болып табылады. Бүгінгі таңда деректер барлық салада шешуші рөл атқарады және оларды тиімді басқару, талдау арқылы ұйымдар өздерінің бизнес стратегияларын дұрыс бағытта қалыптастыра алады. Бизнес аналитикасы жүйелері ұйымдарға деректердің ішінен құнды ақпаратты бөліп шығарып, осы ақпаратқа негізделген шешімдер қабылдауға мүмкіндік береді.[4] БА жүйелерін дұрыс жобалау мен құру барысында ұйымның нақты қажеттіліктері мен мақсаттары ескерілуі тиіс. Бұл жүйенің тиімділігі тікелей деректердің сапасына, оны өңдеу және талдау әдістеріне, сондай-ақ пайдаланушы интерфейсінің қарапайымдылығына байланысты болады. Әрбір компоненттің өзара үйлесімді жұмыс істеуі, деректердің сапалы түрде жинақталуы және дәл талдау жүргізілуі бизнес шешімдерінің дұрыстығы мен уақытылы қабылдануын қамтамасыз етеді. Деректердің жинақталуы, олардың өңделуі мен сақталуы арқылы алынған талдаулар болашақта компанияның бағытын анықтайтын маңызды элементтерге айналады. Бизнес аналитикасы жүйелері, әсіресе заманауи машиналық оқыту мен жасанды интеллект технологияларының көмегімен, ұйымдарға өздерінің операциялық тиімділігін арттыру, тұтынушылардың мінез-құлқын болжау, өндірістік процестерді оңтайландыру және жаңа нарықтық мүмкіндіктерді табу үшін деректерден түсінік алу мүмкіндігін береді.[2] Бұл әсіресе жылдам өзгеретін нарық жағдайында ұйымдардың алға басуына көмектеседі, өйткені уақыт өте келе деректермен жұмыс істеу, оларды дұрыс талдау арқылы нарықтағы орын мен позицияны сақтап қалу маңызды. БА жүйесінің жобалануы мен жүзеге асырылуы кезінде көптеген технологиялар мен құралдар қолданылады, мысалы, дерекқор жүйелері, аналитикалық құралдар, машиналық оқыту алгоритмдері, статистикалық талдау әдістері, және басқа да әдіс-тәсілдер. Осы құралдардың барлығы деректердің сапасын қамтамасыз ету мен шешім қабылдаудың дәлдігін арттыруға бағытталған. Сонымен қатар, деректердің нақты әрі сапалы болуы ұйымға нарықтың өзгерістеріне тез жауап беруге, ресурстарды тиімді пайдалануға және тиімді стратегияларды қалыптастыруға мүмкіндік береді. Бұдан басқа, ұйымның бизнес аналитикасы жүйесін енгізу бизнес мәдениетіне де әсер етеді.[5] Бұл жүйе ұйым ішіндегі барлық қызметкерлерді деректермен жұмыс істеуге ынталандырып, деректерді пайдалану бойынша жалпы мәдениетті қалыптастырады. Сондықтан бизнес аналитикасы жүйесі тек технологиялық құрал ғана емес, сонымен қатар ұйымның стратегиялық ойлау және шешім қабылдау қабілеттерін жетілдіретін маңызды фактор болып табылады. Осылайша, ұйымдар үшін бизнес аналитикасы жүйесін құру мен жобалау — тек қазіргі бизнес қажеттіліктерін қанағаттандыру ғана емес, болашақтағы тұрақты өсу мен табысты даму үшін маңызды қадам болып табылады.[1] Бұл жүйелерді қолдану арқылы ұйымдар өзінің бәсекеге қабілеттілігін арттырып, нарықта жақсы орын алуға мүмкіндік алады. Бизнес аналитикасы жүйелерінің тиімді пайдаланылуы ұйымның стратегиялық даму жоспарын нығайтуға және оның нарықтағы позициясын жақсартуға ықпал етеді.

Пайдаланылған әдебиеттер тізімі:

1. Baird, K., & Thomas, M. (2015). *Business Analytics for Managers: Taking Business Intelligence Beyond Reporting*. Wiley.
<https://www.wiley.com/enus/Business+Analytics+for+Managers%3A+Taking+Business+Intelligence+Beyond+Reporting%2C+2nd+Edition-p-9781119298588>
2. Chaudhuri, S., Dayal, U., & Narasayya, V. (2011). *Data Warehousing and Business Intelligence: Concepts, Methodologies, Tools, and Applications*. IGI Global.
https://www.researchgate.net/publication/330057693_A_Review_of_Business_Intelligence_and_Analytics_in_Small_and_Medium-Sized_Enterprises
3. Negash, S. (2004). *Business Intelligence*. Communications of the Association for Information Systems, 13(1), 177-195.

https://www.researchgate.net/publication/220890856_Business_Intelligence

4. **Галанов, В. И. (2016).** *Бизнес-аналитика: от данных к решениям.* Инфра-М.

https://www.businessstudio.ru/articles/article/biznes_analitik_i_protsechnyy_ofis_kak_luchsh
[e_org/](#)

5. **Калашникова, Т. В. (2014).** *Бизнес-аналитика: теория и практика применения.*

Юрайт.

https://hsbi.hse.ru/programs/vocational_retraining/biznes-analitika/

БАНКЕТ ЗАЛДАРЫН БРОНЬДАУ ЖҮЙЕСІН АВТОМАТТАНДЫРУДЫ ЗЕРТТЕУ

Сембай А.М.

Әл-Фараби атындағы Қазақ ұлттық университеті, бакалавр 4 курс


E-mail: altynaisembai@gmail.com

Қалидоллина Г.Т.

Әл-Фараби атындағы Қазақ ұлттық университеті, магистр, аға оқытушы

Қазіргі таңда кез-келген кәсіпорын жұмысы қарқынды технологиялардың нәтижесінде тек автоматтандырылған жүйелермен жұмыс жүргізеді. Қазіргі таңда дәптерге жазып, есеп жүргізу мүмкін емес. Тіпті кеңсеге барудың өзі уақыт алатындықтан онлайн түрде броньдау жүргізу екі тарапқа бірдей уақыт үнемдеп, жылдам хабар алмасу мүмкіндігі болып табылады.

Мейрамханада үстелге тапсырыс беру - кіру нүктесі, әрі қарай жұмыс істеу үшін қонақтың байланыстарын қабылдау сәті болып саналады. Мейрамхананы автоматтандырудың маңызды кезеңі ерекше назар аударуға тұрарлық[1]. Мүмкін, әрбір бастаушы және тәжірибелі ресторатор қонақтарға үстелдерді брондауды қалай жеңілдету туралы ойлап көрген. Бұл жұмысты жасау барысында дәл осы нүктеден қарастыратын боламыз.



1-сурет. Броньдауды жүргізу сұлбасы

Автоматтандыру қызметі қонаққа фотосурет негізінде брондау үшін қажетті кестені таңдауға мүмкіндік беретін шешімді ұсынады. Үстел карталары қонақтар үшін маңызды ақпаратты қамтиды: үстелдің толтырылу күйі, депозиттің болуы, сыйымдылығы, үстел орналасқан бөлменің атауы[2].

Үстелді таңдаудың ыңғайлылығы. Қонақ мейрамхананың бос орындарын және ең жақын уақытта босайтын үстел кестелерін көреді, қалаған үстелді таңдайды, оны брондайды, байланыстарын қалдырады, онымен жұмыс жүргізуге болады.

Депозиттер. Мейрамхананың банктік шотына үстелді брондау үшін депозиттерді қабылдауды орнатуға болады. Әрбір кестенің өз депозиті болуы мүмкін, депозит сомасы аптаның күніне немесе айдың күніне байланысты өзгеруі мүмкін. (Мысалы, мейрамхана іс-шараны жоспарласа, сол күні салымдар 30% жоғары[3])

Үстелдерді/бильярдты/боулингті сағат сайын брондау. Сағат сайынғы брондау опцияларының параметрлері бар, үстелді/бильярдты/боулингті бір сағатқа, екі сағатқа және т.б. брондауға болады.

Қонақ мейрамханаға қоңырау шалады немесе автоматтандырылған жүйе арқылы веб-сайтыңыздан/әлеуметтік желіңізден онлайн брондау сұрауын жібереді. Қонақтың өтініші қызметке жазылады.

Брондау кезінде қонақ деректерін цифрлау кейінірек жұмыс істеуге болатын статистиканы жинауға мүмкіндік береді. Сіз қонақтардың контактілеріне SMS хабарламалар жібере аласыз, мекеменің ең жиі қонақтарын марапаттай аласыз және мейрамханаға қайталап

келуді ынталандыра аласыз.

Мейрамханада брондау процесін автоматтандыру мекеменің жұмыс көлемін бақылауға мүмкіндік береді. Бизнес-процестерді автоматтандыру адам факторын жояды, бұл процестің тұрақтылығына, сапасын жақсартуға және ауқымдылыққа әкеледі[4].

Берілген жұмыс нәтижелері келесідей факторларды қамти алады: автоматтандырылған жүйеге кіру жүйесі жүргізіледі, үстелдерді таңдау, фильтр(сүзгілеу) батырмалары қосылады, жүйені авторларға бөліп қарастыру, брондау уақытында бірден депозит бөлігіне төлемақы алу жүйесі қосылған, аналитика және мейрамхана иесіне қажетті көптеген есептерді шығарылады (2-сурет).



2-сурет. Жүргізілген жұмыс нәтижесінің сұлбасы

Жұмыстың нақты нәтижелері:

- Автоматтандырылған өнім алынды;
- Мейрамханалардың жұмыс жүйесіне саралау жүргізілді;
- Мейрамхана қызметкерлері автоматтандырылған жүйемен жылдам, әрі ыңғайлы жұмыс жүргізе алады;
- Клиенттердің уақыты үнемделіп, табыс табу ұлғая түседі;
- JavaScript программалау тілінің мүмкіндіктері қолданылады[5];
- Node.js платформасы мен react кітапханасы іске қосылды[6].

Пайдаланылған әдебиеттер тізімі:

1. «Управление рестораном», Роберт Милл, 2019, 175с.
2. «Неправильный бизнесмен», Аркадий Новиков, 2021, 89с.
3. «Управление рестораном, который любит гостей» и «Управление рестораном, который любит прибыль» – Виолетта Гвоздовская, 2023, 321 с.
4. JavaScript для начинающих. 6-е издание, МакГрат Майк, 2024, 118 с.
5. Справочник JavaScript. Кратко, быстро, под рукой, Никольский А. П., Дубовик Е. В., 2024, 198 с.
6. Новые возможности JavaScript. Как написать чистый код по всем правилам современного языка, Ти Джей Краудер, 2024, 78с.

ТУРИСТТІК АГЕНТТІКТІҢ ЖҰМЫС ЖҮЙЕСІН АВТОМАТТАНДЫРУДЫ ЗЕРТТЕУ

Серікболова А.Қ.

*Әл-Фараби атындағы Қазақ ұлттық университеті, бакалавр 4 курс
E-mail: aluaserikbolova11@gmail.com*

Көпбосын Л.С.

*Әл-Фараби атындағы Қазақ ұлттық университеті, техника ғылымдарының кандидаты,
доцент міндетін атқарушы*

Туризм индустриясы қазіргі кезеңде дамудың жоғары динамикасын көрсетеді және әлемдік экономиканың табыстылығы бойынша үшінші секторы болып табылады. Қызмет көрсету саласында туризм әлемдік сауданың шамамен 30%-ын және әлемдік капиталға салынған инвестицияның шамамен 7%-ын құрайды [1]. Туризм саласына инвестицияның жыл сайынғы өсімі шамамен 35% құрайды. Ағымдағы тұрақсыздыққа қарамастан, 2011 жылдың алғашқы сегіз айында әлемде туристік ағын 4,5%-ға өсіп, жалпы жыл бойынша 980 миллион туристке жетті, бұл 2010 жылдың сәйкес кезеңімен салыстырғанда 29 миллионға көп [2]. ДСҰ сарапшыларының бағалауынша, 2012 жылы өсім 3-4 пайызға дейін баяулайды, ал 2030 жылға қарай жыл сайын шамамен 1,8 миллиард турист келеді [3]. Берілген статистика қазіргі заманғы туристік өнімдердің икемді және жеке, тартымды және тұтынушылар үшін қолжетімді болып келе жатқанын көрсетеді.

Туризм индустриясы кез келген басқа экономикалық жүйе сияқты жұмыс істейді. Зерттелетін қызмет саласының маңызды ерекшелігі – көрсетілетін қызметтер мен олардың сапасы туралы ақпарат. Әлемдік тәжірибе көрсеткендей, әлеуметтік-мәдени қызмет пен туризм индустриясы үшін оның қызметінің табыстылығын анықтайтын фактор да тұтынушыларға қызмет көрсету уақыты болып табылады. Қызмет көрсету секторының жоғары бәсекелестік жағдайында тұтынушыларға қызмет көрсету сапасын арттыратын ақпараттық технологияларды өз қызметінде пайдаланатын ұйымдар ғана табысты жұмыс істей алады. Клиентке барынша қысқа мерзімде қызметтердің толық спектрін ұсына алатын адам жеңімпаз болып табылады.

Туристік индустрия ақпараттық қамтамасыз етудің барлық түрлерін және қоғам қызметінің соған байланысты салаларын барынша пайдаланады. Ақпараттық ағындар туристік қызметтерді өндірушілер арасындағы байланыстарды, осы қызметтерді өндірушілер мен тұтынушылар арасындағы байланыстарды қамтамасыз етеді және олар тек деректер ағыны түрінде ғана емес, сонымен қатар қызметтер мен төлемдер түрінде де пайда болады [4]. Туризм бүгінде ғаламдық компьютерлендірілген бизнес болып табылады, оның қатысушылары тек туроператорлар мен турагенттер ғана емес, сонымен қатар дүние жүзіндегі ірі авиакомпаниялар, қонақ үйлер мен мейрамханалар. Экономиканың бұл секторы алғашқы бестікке кіреді, ал кейбір деректер бойынша Интернет арқылы тауарлар мен қызметтерді сатудың ең көп үлесі бар салалардың үштігіне кіреді [5].

Ең алдымен, біз нені білдіретінімізді түсіндіргім келеді. Автоматтандыру келесі функциялар жинағын қамтуы керек:

Осы жұмыста «автоматтандыру» терминімен келесі функциялар жинағын қамтылады:

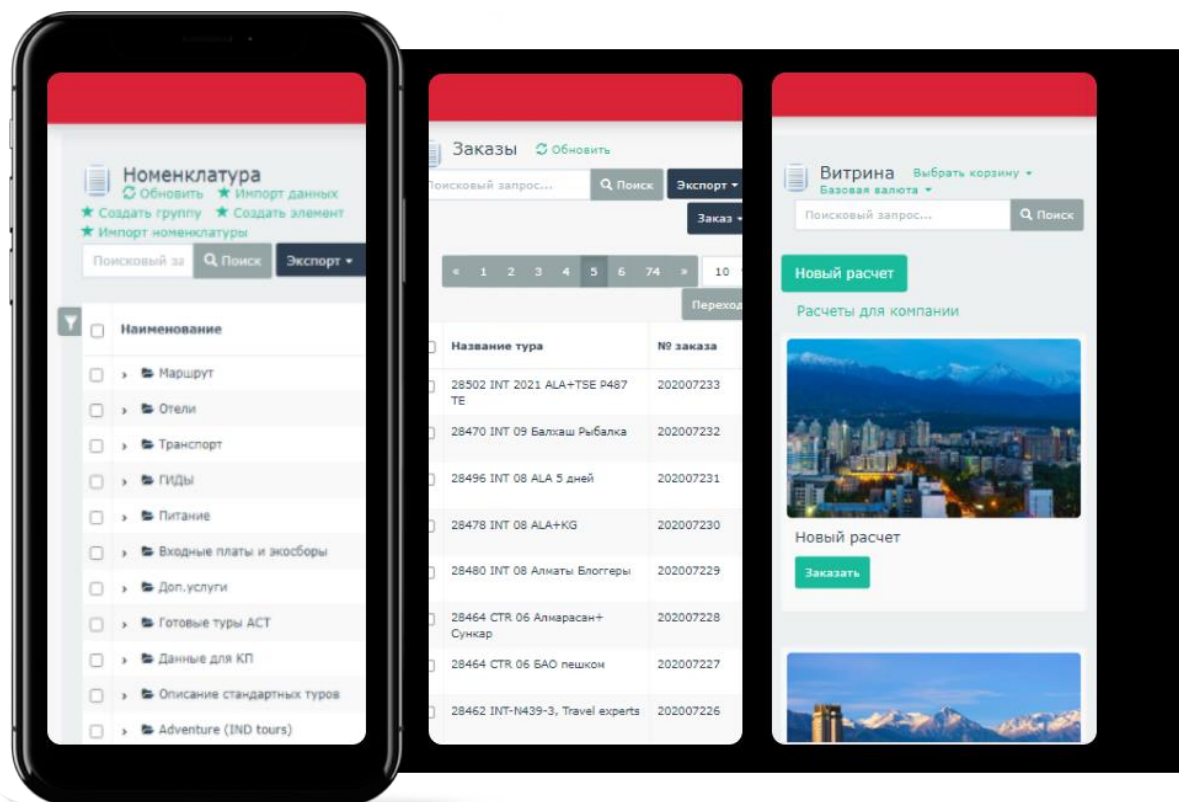
- туроператорлардан өзекті ақпаратты алу және өңдеу;
- ішкі құжат айналымын жүргізу;
- туроператорлармен қарым-қатынас орнату;
- бухгалтерлік есеп;
- деректерді талдау және статистикалық есептерді алу.

Қазіргі таңда кез-келген кәсіпорын жұмысы қарқынды технологиялардың нәтижесінде тек автоматтандырылған жүйелермен жұмыс жүргізеді. Қазіргі таңда дәптерге жазып, есеп жүргізу мүмкін емес. Тіпті кеңсеге барудың өзі уақыт алатындықтан онлайн түрде броньдау

жүргізу екі тарапқа бірдей уақыт үнемдеп, жылдап хабар алмасу мүмкіндігі болып табылады.

Автоматтандырылған жүйенің жалпы сұлбасын 1-суреттен көре аламыз. Алдағы уақытта программалық өнімде толықтырулар жүргізіліп, толық нұсқасы қарастырылатын болады.

Туристік агенттік жұмысын автоматтандыру артықшылықтары: уақыт үнемдеу, тиімділік, ыңғайлылық, ұрлықтан сақтау, кез-келген уақытта қызмет көрсете алу. Сонымен қатар, автоматтандырылған жүйе, есептерге қолжеткізуге мүмкіндік береді. Яғни, соңғы сатып алулардағы қолданушыларға қызықты рейстар, шығын/кіріс және басқа да қажетті көптеген есептерді қадағалауға мүмкіндіктер алып келеді. Кемшіліктеріне келетін болсақ, кішігірім интерфейске немесе панельге қатысты туындамаса, басқа жоқ деп айта аламыз.



1-сурет. Автоматтандырылған жүйе кескіні

Веб-жобалардың күрделілігі мен функционалдығы әрдайым артып келеді және ешкімде барлық қажетті кодтарды басынан бастап жазғысы келмейді. Бағдарламашылар күрделі веб-сайттар мен веб-қосымшаларды әзірлеуі керек, ал бұл әдетте өте ұзақ уақытты қажет етеді. Бағдарламашылар жұмысын жүргізу процесін жеңілдету үшін фреймворктар пайда бола бастады.

Laravel - экспрессивті және талғампаз синтаксисі бар веб-қосымшаның фреймворкі. Бұл аутентификация, маршруттау, сеанстар, кәштеу, қосымшалардың архитектурасы, мәліметтер базасымен жұмыс жасау және т.с.с негізгі ауыр міндеттерді шешуді жеңілдетеді.

Laravel - бұл PHP-дің басқа құрылымдарының ішінен ең жақсысын біріктіру. Бұл біртұтас экожүйеге біріктірілген көптеген қосымша қызметтердің саны. Мысалы, Forge - бағдарламалар мен веб-сайттарға арналған арнайы хостинг. Homestead, Envoyer - бұл Production-дегі Zero Downtime үшін қарапайым және ыңғайлы жүйе. Horizon - бұл Redis-ті бақылауға арналған әкімші панелі. Spark, StyleCI, Statamic және басқа да көптеген қызметтер қосымшаны әзірлеуді жеңілдетеді.

Айтылып өткен автоматтандыру жұмысы PHP программалау тілінде жасалынған және оны құрастыруды жеңілдету мақсатында Laravel фреймворкі қолданылған.

Жұмыстың нақты нәтижелері:

- Автоматтандырылған өнім алынды;
- Туристтік агенттік жұмысына саралау жүргізілді;
- Агенттік автоматтандырылған жүйемен жылдам, әрі ыңғайлы жұмыс жүргізе алады;
- Клиенттердің уақыты үнемделіп, табыс табу ұлғая түседі;
- PHP программалау тілінің мүмкіндіктері қолданылады;
- Laravel фреймворкі қолданыста жүзеге асырылады.

Пайдаланылған әдебиеттер тізімі:

1. Александрова Ю.А. Международный туризм: учеб. пособие / Ю. А. Александрова. - М.: Аспект Пресс, 2011. 464 с.
2. Бабко А.Н. Глобальные системы бронирования в туризме: проблемы и перспективы развития в Украине / А. Н. Бабко // Информационные технологии в управлении туристической и курортно-рекреационной экономикой: материалы III науч.-практ. конф. - Бердянск: АУИТ "АРИУ", 2017., 120 с.
3. Квартальнов В.А. Туризм: учеб. / В.А. Квартальнов. М.: Финансы и статистика, 2014. 320 с.
4. Мальська М.П. Основы туристического бизнеса: учеб. пособие / М.П. Мальська, В.В. Худо, В.И. Цибух. К.: Центр образовательной литературы, 2016, 97 с.
5. Изучаем PHP 7. Руководство по созданию интерактивных веб-сайтов. Дэвид Скляр, 2017, 45 с.
6. Начальный уровень владения PHP Робин Никсон. Создаем динамические веб-сайты с помощью PHP, MySQL, JavaScript, CSS и HTML5, 2019, 116 с.
7. Котеров, Симдянов. PHP 7, 2019, 59 с.
8. Веллинг, Томсон. Разработка веб-приложений с помощью PHP и MySQL, 2017, 175с.
9. Мэтт Зандстра. PHP. Объекты, шаблоны и методики программирования, 2019, 98 с.
10. Книга «Laravel. Полное руководство. 2-е издание» Мэтт Стаффер. Питер, 2020, 265 с.
11. Архитектура сложных веб-приложений. С примерами на Laravel, 2020, Адель Файзрахманов, 302 с.

МАРКЕТИНГТЕГІ ШЕШІМ ҚАБЫЛДАУҒА АРНАЛҒАН АҚПАРАТТЫҚ ЖҮЙЕНІ ӘЗІРЛЕУ

Токтар Гүлбану Нуржигитқызы

E-mail: banutoktar@gmail.com

*Әл-Фараби атындағы Қазақ Ұлттық Университеті,
«Ақпараттық жүйелер» мамандығының 4 курс студенті*

Байшоланова Қарлығаш, Максүтова Шынар

Әл-Фараби атындағы Қазақ Ұлттық Университеті

Бұл мақалада білім беру орталықтарының мысалында маркетингте шешім қабылдау үшін ақпараттық жүйені (АЖ) әзірлеу қарастырылады. Қазіргі цифрландыру жағдайында жарнамалық науқандардың тиімділігін талдау, аудиторияны сегменттеу және маркетингтік стратегияларды оңтайландыру үшін автоматтандырылған шешімдерді қолдану маңызды. Ұсынылған АЖ жарнамалық арналар, сату және тұтынушылардың мінез-құлқы туралы деректерді жинауға, талдауға және басқаруға мүмкіндік береді. Мақалада жүйенің негізгі компоненттері, деректерді өңдеу әдістері және маркетингтік аналитиканы визуализациялау технологиялары қарастырылады.

Білім беру орталықтары клиенттерді тарту және маркетингті басқару үшін цифрлық технологияларды белсенді қолданады. Дегенмен, жаппай жарнама немесе билбордтар сияқты дәстүрлі маркетинг әдістері жоғары құнды талап етеді және әрқашан күтілетін нәтиже бермейді. Осыған байланысты маркетингтік шешімдерді қолдау үшін автоматтандырылған ақпараттық жүйені құру қажеттілікке айналады. Мұндай жүйе жарнамалық науқандарды басқаруға, аудиторияны талдауға және маркетингтік шешімдердің тиімділігін арттыруға мүмкіндік береді.

Әзірленіп жатқан АЖ мынадай негізгі модульдерді қамтиды:

Деректер базасы: PostgreSQL / MySQL – студенттер, жарнамалық науқандар, төлемдер және өтінімдер туралы ақпаратты сақтау.

Аналитикалық модуль: Python (Pandas, Scikit-learn) – деректерді өңдеу, сұранысты болжау, ROI, CPA, LTV көрсеткіштерін есептеу.

Пайдаланушы интерфейсі: React.js / Vue.js-есептерді визуализациялау, KPI бар бақылау тақталары.

Әзірленген АЖ білім беру орталықтарына берер мүмкіндіктері:

Жарнамалық бюджеттерді оңтайландыру арқылы маркетингтік шығындарды азайту;

Нақты мақсат қою арқылы сатылымға өтінімдерді конверсиялауды арттыру;

Шешім қабылдау процесін жеделдету арқылы аналитиканы автоматтандыру.

Мұндай жүйені пайдалану білім беру орталығының бәсекеге қабілеттілігін арттырады және студенттер санының өсуін қамтамасыз етеді. Әрі қарайғы зерттеулер интеграцияға және маркетингтік стратегияларды жекелендіруге бағытталған. Бұл дипломдық жұмыс әртүрлі көздерден (онлайн жарнама, әлеуметтік желілер, офлайн белсенділік, CRM жүйелері) деректерді біріктіретін және маркетингтік стратегияларды талдауға және оңтайландыруға ыңғайлы құралдарды ұсынатын ақпараттық жүйені құруды қарастырады. Негізгі көрсеткіштерді (ROI, LTV, CPA, конверсия) талдауға, білім беру бағдарламаларына сұранысты болжауға және тұтынушыларға ұсыныстарды жекелендіруге бағытталған.

Ақпараттық технологиялар және шешімдерді қолдау жүйелері маркетингтің цифрлық трансформациясында шешуші рөл атқарады. Олар деректерді жан-жақты талдауды қамтамасыз етеді, күнделікті процестерді автоматтандырады және білім беру орталықтарының басшыларына объективті көрсеткіштер негізінде негізделген шешімдер қабылдауға мүмкіндік береді. Білім беру қызметтерін маркетингке арналған ақпараттық жүйені әзірлеу жарнамалық науқандардың тиімділігін арттырып қана қоймай, клиенттермен өзара әрекеттесуді жақсарта отырып, аудиторияның қажеттіліктерін тереңірек түсінуге мүмкіндік береді. Маркетингтегі

шешім арналған ақпараттық жүйені әзірлеу үшін жобалау және құру кезінде әртүрлі құралдар мен технологиялар қолданылады. Олардың ішінде:

<i>Backend (сервер бөлігі):</i>	PHP-бизнес логикасын өңдеу, деректерді басқару, мәліметтер базасымен интеграциялау.
<i>Frontend (пайдаланушы интерфейсі):</i>	HTML, CSS, JavaScript - жауап беретін және ыңғайлы веб-интерфейс құру.
<i>Мәліметтер базасы:</i>	MySQL/PostgreSQL-студенттер, жарнамалық науқандар, төлемдер және сапарлар туралы ақпаратты сақтау.
<i>Аналитикалық модуль:</i>	Деректерді талдауға, есептер шығаруға және негізгі маркетингтік көрсеткіштерді есептеуге арналған SQL сұраулары (ROI, CPA, LTV, конверсия).
<i>Сыртқы қызметтермен Интеграция:</i>	Instagram Ads, Facebook Ads), email-тарату, есеп беру жүйелері.
<i>Машиналық оқыту:</i>	Python (Pandas, Scikit-learn) – үлкен көлемдегі деректерді талдау, сұранысты болжау, конверсияны болжау, аудиторияны сегменттеу және ұсыныстарды жекелендіру.

PHP және SQL пайдалану деректерді өңдеу мен сақтауды қамтамасыз ететін сенімді серверлік архитектураны құруға мүмкіндік береді, ал JavaScript және HTML/CSS пайдаланушыға ыңғайлы және динамикалық пайдаланушы интерфейсін жүзеге асырады. Мұндай архитектура икемділікті, масштабталуды және әртүрлі маркетингтік құралдармен интеграциялану мүмкіндігін қамтамасыз етеді.

Маркетингте ML пайдалану мыналарды қамтиды:

Сұранысты болжау-сатылымды болжау және ең тиімді жарнамалық науқандарды анықтау үшін өткен деректерді талдау.

Ұсыныстарды жекелендіру-тұтынушылардың мінез-құлқы мен қалауына қарай сегменттеу, бұл конверсияны арттыруға мүмкіндік береді.

Instagram, Facebook, Email – тарату, билбордтар) жарнамалық шығындарды оңтайландыру-жылжыту арналарының тиімділігін талдау және бюджетті ең тиімді көздерге автоматты түрде қайта бөлу.

Үлгілерді анықтау – маркетингтік шешімдерді жақсарту мақсатында аудиторияның мінез-құлқындағы жасырын тенденцияларды анықтау.

Клиенттердің көңіл – күйін талдау-қанағаттануды бағалау және проблемалық аймақтарды анықтау үшін NLP (Natural Language Processing) көмегімен пікірлер мен пікірлерді өңдеу.

AI және машиналық оқытуды білім беру орталығының маркетингтік ақпараттық жүйесіне біріктіру деректерді талдауды автоматтандыруға, болжамдардың дәлдігін арттыруға және жарнамалық стратегияларды оңтайландыруға мүмкіндік береді, бұл пайда мен тұтынушылардың өсуіне әкеледі.

Қазіргі әлемде білім беру қызметтерінің маркетингі деректерді дәл талдауды және шешім қабылдауда икемділікті қажет етеді. Білім беру орталықтарының маркетингінде шешімдерді қолдаудың ақпараттық жүйесін енгізу деректерді жинау мен өңдеуді автоматтандыруға, жарнамалық науқандарды талдауға және болжамдардың дәлдігін арттыруға мүмкіндік береді.

Маркетингтік аналитикада жасанды интеллектті қолдану білім беру орталықтары үшін жаңа мүмкіндіктер ашады, бұл оларға нарықтағы өзгерістерге жауап беріп қана қоймай, оларды болжауға мүмкіндік береді. Бұл бәсекелестік білім деңгейін көтеруге артықшылық береді, бизнестің өсуін тездетеді және маркетингті дәлірек және үнемді етеді. Маркетингтің болашағы үлкен көлемдегі ақпаратты талдап қана қоймай, сонымен қатар нақты уақыттағы өзгермелі нарық жағдайларына бейімделе алатын интеллектуалды жүйелерге негізделеді.

Пайдаланылған әдебиеттер тізімі:

1. Г.П. Кожевникова, Б.Е. Одинцов. (2023). *Информационные системы и технологии в маркетинге*
2. Илья Кацов. (2011). *Машинное обучение для бизнеса и маркетинга*
3. С. Итеғұлова, А. Мұқан (2014). *Жарнама тілінің терминдер сөздігі*
4. Dominique Levin (2016). *Predictive Marketing: Easy Ways Every Marketer Can Use Customer Analytics and Big Data*
5. Jim Sterne (2018). *Artificial Intelligence in Marketing*
6. Wayne L. Winston (2017). *Marketing Analytics: Data-Driven Techniques with Microsoft Excel*

КӘСІПОРЫНДАР АРАСЫНДАҒЫ ӨЗАРА ҚАРЫМ-ҚАТЫНАСТЫ АВТОМАТТАНДЫРУҒА АРНАЛҒАН ЗИЯТКЕРЛІК В2В САУДА ПЛАТФОРМАСЫН ӘЗІРЛЕУ

Түгелбай Н.А.

*әл-Фараби атындағы Қазақ ұлттық университеті, Қазақстан
nuriktugelbai777@gmail.com*

Аннотация. *Интеллектуалды В2В платформаларының дамуы кәсіпорындар арасындағы өзара әрекеттесуді автоматтандыру және оңтайландыру үшін жаңа көкжиектерді ашады. Мұндай платформаның негізгі мақсаты - өзара әрекеттесу процестерін жеңілдету және жеделдету, адам факторымен байланысты тәуекелдерді азайту және заманауи технологияларды қолдану арқылы қабылданатын шешімдердің сапасын арттыру.*

В2В Платформасын Әзірлеу және Автоматтандыру

Қазіргі заманғы В2В платформалары жасанды интеллект (AI), машиналық оқыту (ML), бұлтты есептеу, үлкен деректер, блокчейн және API интеграциясы сияқты заманауи технологияларды қолдану арқылы бизнес-процестерді автоматтандыруға бағытталған. Бұл технологиялар серіктестерді іздеу, транзакцияларды болжау, құжат айналымын басқару және қауіпсіздікті қамтамасыз ету сияқты негізгі аспектілерді жетілдіруге мүмкіндік береді [1, 2].

Жасанды интеллект және үлкен деректер

Жасанды интеллект пен машиналық оқыту В2В платформаларында серіктестердің мінез-құлқын талдауға және транзакцияларды автоматтандыруға көмектеседі. AI негізіндегі алгоритмдер компанияларға клиенттерінің қажеттіліктерін болжауға, жеткізу тізбегін оңтайландыруға және бизнес-процестерді жеделдетуге мүмкіндік береді. Үлкен деректерді талдау тарихи ақпаратты өңдеу арқылы нарықтық үрдістерді түсінуге және сұранысты болжауға көмектеседі. Бұл компанияларға ресурстарын тиімді жоспарлауға және бизнес тәуекелдерін төмендетуге мүмкіндік береді [4, 5].

Құжат айналымын автоматтандыру

В2В платформаларында құжат айналымын басқару автоматтандырылған жүйелер арқылы жүзеге асырылады. Spring Web сияқты технологияларды пайдалану электрондық құжат алмасуды жеңілдетіп, бизнес-процестерді жеделдетеді. AI-дің құжаттарды өңдеу және тексеру процестерін автоматтандыруы қателерді 30%-ға азайтып, транзакция уақытын 40%-ға қысқартады [3].

Блокчейн және транзакциялық қауіпсіздік

В2В платформаларында транзакциялардың ашықтығы мен қауіпсіздігін қамтамасыз ету үшін блокчейн технологиясы қолданылады. Смарт-келісімшарттар бизнес-процестерді автоматтандырып, адам факторына байланысты қателерді азайтады. Блокчейн транзакция деректерінің бұрмалануына жол бермей, сенімділікті арттырады. Зерттеулер көрсеткендей, блокчейн негізіндегі келісімшарттар транзакцияларды орындау уақытын 40%-ға қысқартады, бұл халықаралық сауда саласында маңызды фактор болып табылады [1, 2].

Бұлтты технологиялар және API интеграциясы

Бұлтты есептеу технологиялары В2В платформаларының ауқымдылығын, қолжетімділігін және икемділігін қамтамасыз етеді. Олар ERP, CRM және бухгалтерлік есеп жүйелерімен интеграцияны жеңілдетіп, компаниялар арасындағы өзара әрекеттесуді жеделдетеді. API интеграциясы арқылы әртүрлі бизнес-қосымшалар арасында деректерді синхрондау жүзеге асырылады, бұл ақпарат алмасу тиімділігін арттырады.

Деректер қауіпсіздігі және құпиялылық

В2В платформаларындағы деректер қауіпсіздігі киберқауіпсіздік шараларын қолдану арқылы қамтамасыз етіледі. Шифрлау, көп факторлы аутентификация және токенизация

сияқты технологиялар рұқсатсыз кіру мен деректердің ағып кетуін болдырмайды. Сонымен қатар, блокчейн технологиясы құжаттардың өзгертілуіне жол бермей, олардың қауіпсіздігін қамтамасыз етеді.

Қорытынды

Заманауи B2B платформалары бизнес-процестерді автоматтандыру арқылы транзакция уақытын қысқартып, қателерді азайтады. Жасанды интеллект, үлкен деректер, бұлтты технологиялар және блокчейн компанияларға серіктестерді жылдам табуға, нарықтық үрдістерді болжауға және қауіпсіз транзакцияларды жүзеге асыруға мүмкіндік береді. Бұл технологияларды қолдану арқылы кәсіпорындар тиімділікті арттырып, жаһандық нарықта бәсекеге қабілеттілігін күшейте алады.

Пайдаланылған әдебиеттер тізімі:

1. Ивашенко В.В. Цифровая экономика и новые бизнес-модели. — М.: Научное издательство, 2020.
2. Aagaard A. Digital Business Models: Concepts, Models and the Alphabet Case Study. — Springer, 2019.
3. "The Role of Automation in B2B E-Commerce". — Journal of Business Automation, 2022.
4. Mayer-Schönberger V., Cukier K. Big Data: A Revolution That Will Transform How We Live, Work, and Think. — John Murray, 2013.
5. "Big Data Analytics for B2B Supply Chains: A Systematic Review". — International Journal of Supply Chain Management, 2021.

АВТОКӨЛІК НӨМЕРЛЕРІН ТАНИТЫН АҚПАРАТТЫҚ ЖҮЙЕ ҚҰРУ

Шопчекбаев Қайрат Жолдасұлы

shopchekbayev_03@mail.ru

*Әл-Фараби атындағы Қазақ Ұлттық Университеті,
Ақпараттық жүйелер мамандығының 4 курс студенті,*

Бейбітхан Еркегүл

*Әл-Фараби атындағы Қазақ Ұлттық Университеті,
Ақпараттық жүйелер кафедрасының аға оқытушысы*

Қазіргі таңда автокөліктердің қолжетімділігі оларға арналған тұрақтардың басқару мен көліктерді есептеу кейбір қиыншылықтарды тудыруда. 400 мың адамға арналған Алматы қаласы қазіргі таңда тек қана ауқымды халық санымен ғана емес, оларға арналған транспорттардың күрт өсуі де кезігуде. Сол үшін көлік тұрағына арналған автоматтандырылған көліктерді жүйеге енгізіп, оларды есептеуші бағдарламалар өзекті мәселелердің біріне айналып жатыр.

Зерттеудің ең басты мақсаты нарықтағы осындай мүдделерді шешуге арналған бағдаламарды саралап, соларды зерттеу арқылы Қазақстан нарығына енгізу кезіндегі техникалық қызметтерді де есепке алу болып табылады. Автокөлік нөмірлерін автоматты түрде сканерлеуге және тануға арналған бағдарламалық жасақтаманы әзірлеу компьютерлік көру және кескінді өңдеу саласындағы өзекті міндет болып табылады. Бұл технология қауіпсіздік жүйелерін, жол қозғалысын басқаруды, жол ақысын автоматтандырылған жинауды және көлік құралдарының мониторингін қоса алғанда, әртүрлі салаларда қолданылады. Мақалада суреттерді өңдеуден бастап мәтіндік ақпаратты алуға дейінгі автомобиль нөмірлерін сканерлеу және тану бағдарламасын құрудың негізгі кезеңдері қарастырылады.

Дамудың бірінші кезеңі-кескін сапасын жақсартуды, жарықтандыруды түзетуді және шуды сүзуді қамтитын кескінді өңдеу. Ол үшін бинаризация, морфологиялық операциялар және адаптивті сүзу сияқты әдістер қолданылады [1]. Бұл қадамдар кейінгі танудың дәлдігін арттыру үшін қажет. Әзірленген бағдарламаны қолданыстағы бейнебақылау жүйелеріне біріктіруге немесе тәуелсіз шешім ретінде пайдалануға болады. Мақалада бағдарламаның тиімділігі мен тану дәлдігін көрсететін әр түрлі мәліметтер жиынтығындағы тестілеу нәтижелері келтірілген [2].

Осылайша, автомобиль нөмірлерін сканерлеу және тану бағдарламасын құру кескінді өңдеу, локализация, сегменттеу және таңбаларды тануды қамтитын кешенді тәсілді қажет етеді. Компьютерлік көру мен машиналық оқытудың заманауи әдістерін қолдану жүйенің жоғары дәлдігі мен сенімділігіне қол жеткізуге мүмкіндік береді.

Төменде автокөлік нөмірлерін сканерлейтін және танитын қосымшаны әзірлеудің егжей-тегжейлі жоспары берілген. Жоспар қолданыстағы жобаларды, олардың оң және теріс жақтарын зерттеуді және кезең-кезеңімен әзірлеу тәсілін қамтиды.

Қолданыстағы Жобалардың мысалдары:

OpenALPR (Нөмірді Автоматты Түрде Тану) [3]-Нөмірді тану үшін кеңінен қолданылатын ашық бастапқы кітапхана. Артықшылықтары: жоғары дәлдік, бірнеше елдерді қолдайды, интеграцияны жеңілдетеді. Кемшіліктері: айтарлықтай есептеу ресурстарын, шектеулі теңшеуді қажет етеді.

ҰЛЫБРИТАНИЯДАҒЫ ANPR (Нөмірді Автоматты Түрде Тану) [4]:

Жол қозғалысын бақылау, құқық қорғау органдары және жол ақысын жинау үшін қолданылады. Артықшылықтары: жоғары дәлдік, нақты уақыт режимінде өңдеу, мемлекеттік мәліметтер базасымен интеграциялау. Кемшіліктері: іске Асыру Қымбатқа түседі, құпиялылық мәселелері. Техникалық-экономикалық негіздеме жүргізу. Кезең: Технологиялық Стектерді Таңдау Бағдарламалау Тілі: Python (компьютерлік көрудегі кең кітапханалары

үшін).Кітапханалар / Құрылымдар:Кескінді өңдеуге арналған OpenCV.Мәтінді тануға арналған TESSERACT OCR [6].Терең оқыту модельдеріне арналған TensorFlow немесе PyTorch.Деректер базасы: нөмір деректерін сақтауға арналған SQLite немесе PostgreSQL.Кезең: Жүйені Жобалау-Модульдер:Суретке Түсіру: нөмірдің суреттерін түсіру үшін камераларды пайдаланыңыз.Алдын ала өңдеу: кескін сапасын Жақсарту (мысалы, шуды азайту, контрастты реттеу).Нөмірді Анықтау: нысанды анықтау алгоритмдерін Қолданыңыз (МЫСАЛЫ, YOLO, SSD).

Қорытындылай келе, нөмірді сканерлеуге арналған қосымша тек технологиялық жаңалық емес, сонымен қатар қалалық жерлерде өмір сүру сапасын жақсартудың қажетті құралы болып табылады. Оны енгізу ресурстарды тиімдірек басқаруға, қауіпсіздікті арттыруға және тұрғындар мен келушілер үшін жалпы қалалық тәжірибені жақсартуға әкелуі мүмкін. Қалалар өсіп келе жатқандықтан, мұндай технологиялар қала өмірінің болашағын қалыптастыруда барған сайын маңызды рөл атқаратын болады.

References:

1. Gonzalez, R. C., Woods, R. E. Digital Image Processing. Pearson. [<https://elibrary.pearson.de/book/99.150005/9781292223070>]. — Retrieved from [<https://elibrary.pearson.de/book/99.150005/9781292223070>].
2. Wang K., Belongie S. Word Spotting in the Wild. In European Conference on Computer Vision / Belongie S. Wang, K. // Springer. — 2010.
3. Github use. Automatic Number Plate Recognition (ANPR). [<https://github.com/openalpr/openalpr>]. — Retrieved from [<https://github.com/openalpr/openalpr>].
4. Department for Transport UK. Automatic Number Plate Recognition (ANPR). — [<https://www.gov.uk>]. — Retrieved from [<https://www.gov.uk>].

Білім берудегі платформаларды дамыту: маңызы, қолданылатын әдістер мен технологиялар

Ысқақ С.Е.

*Әл-Фараби атындағы Қазақ Ұлттық университеті, бакалавр, 4-курс
email: @sanzhariskakov21@gmail.com*

Ибраимкулов А.Е.

Әл-Фараби атындағы Қазақ Ұлттық университеті, аға оқытушы

Дәстүрлі білім беруді түрлендіруде заманауи білім беру платформалары басты рөл атқарады. Олар оқу процесін қолжетімді, икемді және жекелендірілген етеді. Технологияның дамуымен қашықтықтан оқыту ыңғайлылығымен де, цифрлық дәуірдің талаптарына бейімделу қажеттілігімен де танымал бола түсуде. Білім беру платформаларының маңыздылығы білімнің географиялық орналасуына қарамастан кең ауқымдағы пайдаланушылар үшін қолжетімділігін арттыруға мүмкіндік береді. Сонымен қатар, бейімделу алгоритмдері арқылы дараланған тәсіл қолдану оқытудың тиімділігін жоғарылатады. Мультимедиялық ресурстарды біріктіру арқылы білім алушылардың материалды меңгеру деңгейі артады. Автоматтандырылған орындалу барысын бақылау және кері байланыс оқытудың сапасын жақсартуға ықпал етеді. Бұл платформаларда бейімделетін оқыту әдісі кеңінен қолданылады. Ол оқу материалын білім алушылардың жеке қажеттіліктеріне бейімдеу үшін машиналық оқыту алгоритмдерін пайдаланады. Сонымен қатар, геймификация әдісі пайдаланушылардың мотивациясын арттыру мақсатында рейтингтер, марапаттар және жарыстар сияқты ойын элементтерін енгізеді. Microlearning тәсілі ақпаратты жақсы меңгеру үшін оқу материалын шағын бөліктерде ұсыну арқылы жүзеге асады. Ал жобалық оқыту алынған білімді тәжірибеде қолдануға мүмкіндік береді. Деректерге негізделген оқыту әдісі білім алушылардың үлгерімін талдап, олардың нәтижелері бойынша оқу бағдарламаларын бейімдеуге бағытталған. Бұлтты технологиялар әлемнің кез келген нүктесінен оқу материалдарына қол жеткізуді қамтамасыз етеді, сонымен қатар үлкен көлемдегі деректерді сақтауға және өңдеуге мүмкіндік береді. Жасанды интеллект (AI) оқытуды жекелендіру, тапсырмаларды автоматты түрде тексеру және оқу үлгерімін жақсарту бойынша ұсыныстар беру үшін қолданылады. Виртуалды және толықтырылған шындық (VR/AR) технологиялары студенттердің белсенділігін арттыратын интерактивті білім беру орталарын құруда қолданылады. Блокчейн технологиясы пайдаланушы деректерін қорғау, сертификаттарды тексеру және оқу жетістіктерін растау үшін пайдаланылады. Үлкен деректер технологиясы білім беру бағдарламаларының тиімділігін талдауға және оқыту нәтижелерін болжауға мүмкіндік береді.

Нәтижелер білім беру платформаларының тиімділігін көрсетеді. Қолданылатын әдістер мен технологиялар білім алушылардың білімін тереңдетуге және оқу процесін жеңілдетуге ықпал етеді. Дәстүрлі білім беру әдістерімен салыстырғанда, жаңа платформалар оқу материалдарын меңгеруді жылдамдатып, білім алушылардың қызығушылығын арттырады. Инновациялық әдістер мен технологияларды қолдану жалпы білім беру жүйесінің дамуына жаңа перспективалар ашады.

Пайдаланылған әдебиеттер тізімі:

1. Bozkurt, A., & Sharma, R. C. (2021). Emergency remote teaching in a time of global crisis due to CoronaVirus pandemic. *Asian Journal of Distance Education*, 15(1), 1-6.
2. Bond, M., Bedenlier, S., Marín, V. I., & Händel, M. (2022). International research trends on technology-enhanced learning in higher education: A bibliometric mapping of the literature. *Computers & Education*, 182, 104464.
3. Bates, T. (2022). *Teaching in a Digital Age: Guidelines for Designing Teaching and Learning* (3rd ed.). BCcampus.

USING MACHINE LEARNING ALGORITHMS TO EVALUATE AND PREDICT EMPLOYEE PERFORMANCE

Kezier H.

*Al-Farabi Kazakh National University, 2nd year master's student
crane.heran@icloud.com*

In today's competitive business environment, effective employee evaluation is important to improve organizational performance. However, traditional evaluation methods, often based on periodic feedback, can easily introduce biases and overlook employee contributions [1]. The research presents a general vision of employing machine learning as a process of evaluation and prediction of employees' performances, offering employees in the departments a progressive approach for application and their expected performance trends [2].

On the other hand, classifiers such as Random Forest (RF), Support Vector Machine (SVM), Decision Tree, Logistic Regression, and K-Nearest Neighbors (KNN) have demonstrated high accuracy in evaluating employees' suitability for various roles. As shown in Table 1, Random Forest achieved the highest accuracy (99.44%), followed by Decision Tree (97.22%). These experimental results indicate that machine learning models can significantly enhance objectivity and reliability in performance evaluations, surpassing conventional methods.

Table 1. Comparison of Machine Learning Algorithms on Key Evaluation Metrics.

Algorithm	Accuracy (%)	Precision	Recall	F1-Score
Random Forest Classifier	99.44	0.89	1	0.94
Support Vector Machine (SVM)	96.39	0.87	0.75	0.81
Decision Tree Classifier	97.22	0.88	0.93	0.86
Logistic Regression	94.72	0.73	0.75	0.74
K-Nearest Neighbors (KNN)	95.83	0.89	0.67	0.76

Such researches prove to be a game-changer of modern application for machine learning-thinking human resources- were by quantifying employee performance, optimal placement in departments, future performance can be predicted leading to a better managing of your force [3]. Even though these yields are many-sided, they, still, open a window on many other problems such as data quality and algorithmic bias, thus opening roads for other pieces of research that seek to boil down the essence of applying machine learning in HR management [4]. It thus opens, for the first time, a new outlook for organizations that seek data-driven responses to improve performance management and workforce optimization.

References:

1. M. N. Siddiqui, "Success of an Organization is a result of Employees Performance," ASSRJ, vol. 1, no. 4, pp. 179–201, Jul. 2014, doi: 10.14738/assrj.14.280.
2. M. Rivera, L. Qiu, S. Kumar, and T. Petrucci, "Are Traditional Performance Reviews Outdated? An Empirical Analysis on Continuous, Real-Time Feedback in the Workplace," Information Systems Research, vol. 32, no. 2, pp. 517–540, Jun. 2021, doi: 10.1287/isre.2020.0979.
3. G. Balakayeva, M. Zhanuzakov, and G. Kalmenova, "Development of a digital employee rating evaluation system (DERES) based on machine learning algorithms and 360-degree method," Journal of Intelligent Systems, vol. 32, no. 1, p. 20230008, Oct. 2023, doi: 10.1515/jisys-2023-0008.
4. K. K. Reddy Yanamala, "Integrating Machine Learning and Human Feedback for Employee Performance Evaluation," JACS, vol. 2, no. 1, pp. 1–10, 2024, doi: 10.69987/JACS.2022.20101.

Development of PINN algorithm for the inverse problem of three-chamber pharmacokinetics model

Li Xin

Computer Science

Abstract

The application of Physics-Informed Neural Networks (PINNs) in pharmacokinetics modeling has gained traction due to their ability to integrate prior knowledge in solving inverse problems. This paper presents a PINN-based approach for estimating pharmacokinetic parameters in a three-chamber model. We demonstrate how PINNs effectively infer unknown parameters from sparse observational data, providing an efficient alternative to traditional optimization and numerical methods.

1. Introduction

Pharmacokinetics (PK) models describe the absorption, distribution, metabolism, and excretion (ADME) of drugs within an organism. Among these, the three-chamber model is widely used to represent drug dynamics across central, peripheral, and deep compartments. Traditional inverse problem-solving methods, such as nonlinear least squares or Bayesian inference, often struggle with sparse and noisy data. Physics-Informed Neural Networks (PINNs) offer a promising solution by embedding the governing differential equations into the loss function of a neural network, enabling data-driven inference while respecting the physical constraints of the system.

2. The Three-Chamber Pharmacokinetics Model

The three-chamber model consists of:

- A central compartment (e.g., blood plasma),
- A shallow peripheral compartment (e.g., highly perfused tissues),
- A deep peripheral compartment (e.g., poorly perfused tissues).

Mathematically, drug concentration dynamics in these compartments are governed by a system of ordinary differential equations (ODEs):

$$\begin{aligned}\frac{dC_1}{dt} &= -(k_{10} + k_{12} + k_{13})C_1 + k_{21}C_2 + k_{31}C_3 + I(t) \\ \frac{dC_2}{dt} &= k_{12}C_1 - k_{21}C_2 \\ \frac{dC_3}{dt} &= k_{13}C_1 - k_{31}C_3\end{aligned}$$

where C_1, C_2, C_3 represent drug concentrations in the respective compartments, k_{ij} are transfer rate constants, and $I(t)$ is the drug input function.

3. PINN-Based Inverse Problem Solving

To estimate the unknown parameters $k_{10}, k_{12}, k_{13}, k_{21}, k_{31}$, we develop a PINN model that minimizes a loss function consisting of:

1. **Data loss:** Ensuring predictions match observed drug concentration values.
2. **Physics loss:** Penalizing deviations from the ODE constraints.
3. **Initial condition loss:** Enforcing consistency with the initial drug concentration.

The neural network takes time t as input and outputs predicted concentrations C_1, C_2, C_3 . The gradients computed via automatic differentiation ensure that the predictions satisfy the governing ODEs.

4. Results and Discussion

I test the PINN model on synthetic data with added noise to simulate real-world measurement errors. Results show that the trained PINN can accurately recover the true parameters with minimal deviation. Compared to conventional numerical methods, PINNs offer enhanced robustness to noisy data and sparse sampling.

Key advantages of the PINN approach include:

- **Better generalization:** PINNs leverage the underlying physics, reducing dependence on

extensive training data.

- **Flexibility:** Adaptable to different PK models without requiring explicit discretization.
- **Efficiency:** Faster convergence in parameter estimation compared to traditional inverse methods.

5. Conclusion

This study demonstrates the effectiveness of PINNs in solving inverse problems in pharmacokinetics. Future work will focus on extending the approach to more complex multi-compartment models and real patient data integration for personalized medicine applications.

6. Reference:

[1] Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*.

Application of Machine Learning and Cyber Analysis in an Intelligent Information System for Cryptocurrency Price Analysis

Sagyntayev Mukash-Yerasyl Abzal

Al-Farabi Kazakh National University, 4th course student

E-mail: erasylsagintaev03@gmail.com

The cryptocurrency market is defined by extreme volatility, rapid price fluctuations, and frequent structural shifts, making it one of the most challenging domains for traditional financial analysis. In response to these complexities, intelligent information systems that leverage machine learning and cyber analysis are emerging as powerful tools for decoding market behavior and improving decision-making processes. These systems integrate multiple analytical layers, such as graphical pattern recognition, technical indicator analysis, automated classification of chart patterns, and predictive modeling to deliver high-precision market insights.

One of the key advantages of such intelligent systems is their adaptability and ability to autonomously analyze vast volumes of time-series financial data. Recurrent Neural Networks (RNN), a subset of deep learning models, play a central role in processing historical candlestick data to detect temporal dependencies and forecast future price movements. This modeling capability enables the system to generalize from past behaviors and predict upcoming trends with a higher degree of accuracy compared to conventional methods.

Beyond numerical prediction, the system incorporates a natural language processing module based on large-scale pre-trained language models such as GPT. This module generates contextual textual interpretations of technical signals, allowing users to understand the rationale behind each trading signal in clear and intuitive terms. These explanations are delivered through a user-friendly Telegram bot, which facilitates real-time interaction and supports informed and timely decision-making for traders of all levels.

Machine learning is employed across multiple core functions of the system. Graphical pattern recognition is achieved through supervised learning, where the system is trained on structured JSON data consisting of annotated candlestick charts. Once trained, the system can autonomously identify and classify recurring patterns, such as double tops, triangles, or bullish flags, from live market data. RNN-based models enhance forecasting by analyzing sequences of price movements and adjusting to complex, non-linear market behaviors. The output is then enhanced with textual explanations to ensure transparency and accessibility for end users.

Interactive visualization also forms an integral component of the system. Through a responsive web-based interface, users can explore live charts using customizable indicators, multiple timeframes, and overlaid graphical patterns. This visual layer is critical for helping traders verify system-generated predictions against their own technical knowledge. Furthermore, the system is designed to adapt to each user's preferences, experience level, and trading goals, providing tailored recommendations and analysis.

Altogether, the intelligent integration of deep learning, time-series modeling, graphical analysis, and human-centric design enables this system to act as a comprehensive decision-support tool. It assists both novice and experienced traders by reducing cognitive load, improving interpretability, and offering precise, real-time analysis tailored to the fast-paced cryptocurrency market.

References:

1. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
2. Nakamoto, S. (2008). *Bitcoin: A Peer-to-Peer Electronic Cash System*. <https://bitcoin.org/bitcoin.pdf>
3. Brownlee, J. (2017). *Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python*. *Machine Learning Mastery*.

4. Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.
5. Chollet, F. (2018). *Deep Learning with Python*. Manning Publications.
6. Vaswani, A., et al. (2017). Attention is All You Need. *Advances in Neural Information Processing Systems (NeurIPS)*.
7. Zhang, Y., & Aggarwal, C. C. (2017). Stock Price Prediction via Discovering Multi-Frequency Trading Patterns. *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*.
8. Nguyen, T. T., & Shirai, K. (2015). Topic Modeling-Based Sentiment Analysis on Social Media for Stock Market Prediction. *Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics*.
9. Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial Time Series Forecasting with Deep Learning: A Systematic Literature Review. *Applied Soft Computing*, 90, 106181.
10. McNally, S., Roche, J., & Caton, S. (2018). Predicting the Price of Bitcoin Using Machine Learning. *2018 26th Euromicro International Conference on Parallel, Distributed and Network-based Processing (PDP)*, 339–343.

YOLO NAS s негізінде қазақ ым тілін тану моделін құру және зерттеу

Бержанова Улмекен Габитқызы

Әл-Фараби атындағы Қазақ Ұлттық Университеті 2 курс докторанты

E-mail: berzhanovaulmekenn@gmail.com

Mohamed Othman

PhD, «Коммуникациялық технологиялар және желілер» кафедрасының профессоры,

Малайзия Путра университеті, Малайзия

Мухитова Айгуль Ариповна

Әл-Фараби атындағы Қазақ Ұлттық Университеті, аға оқытушы ҚАЗҰУ

Ым тілін тану – компьютерлік көру және табиғи тілдерді өңдеу саласындағы өзекті тапсырма. Есту және сөйлеу қабілеті бұзылған адамдар коммуникация қиындықтарына тап болады, бұл ым-ишара арқылы мәтінге немесе дауыстық сөйлеуге аударуды автоматтандыру жүйелерін әзірлеуді талап етеді. Заманауи терең оқыту модельдері, мысалы, YOLO NAS s (You Only Look Once Neural Architecture Search small), ым тілін тануда жоғары дәлдікке жетуге мүмкіндік береді, бұл оларды осы тапсырма үшін перспективалы етеді. Бұл жұмыстың мақсаты – YOLO NAS s негізінде қазақ ым тілін тану моделін әзірлеу. Осы мақсатқа жету үшін келесі міндеттер қойылады: қазақ ым тілінің 42 дактилі деректер жиынтығын жинақтау және дайындау, модельді оқытып, дәлдігін арттыру үшін оңтайландыру жүргізу, модельді тестілеу және оның жұмысын бағалау. Зерттеу барысында YOLO NAS s моделін қазақ ым тіліндегі 42 дактильді тану үшін қолданудың нәтижелері қарастырылды. Модельдің дәлдігі оқыту кезінде 99,51% құраған, ал деректер аугментациясын қолдану арқылы оның дәлдігі 99,84% дейін жетті. Нәтижелер автоматты түрде ым-ишараны мәтінге немесе дауыстық сөйлеуге аудару жүйелеріне интеграциялау мүмкіндігін көрсетеді, бұл есту және сөйлеу қабілеті бұзылған адамдарға коммуникацияны жеңілдетуге көмектеседі.

Бұл зерттеу[1] жұмысы машиналық оқыту мен нейрондық желілердің көмегімен қазақ дактиль әліпбиі негізіндегі ым тілін тануды зерттейді. Зерттеу барысында Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM) және Support Vector Machine (SVM) сияқты танымал қол қимылдарын тану модельдері қарастырылды. Әрбір модельдің жұмыс принциптері, тиімділігі және оқу процесі туралы егжей-тегжейлі сипаттама берілген. Эксперименттік нәтижелер әр қимылды танудың дәлдігін көрсетті, сонымен қатар нақты қимылдар камера алдында сынақтан өткізіліп, нәтиже экранда көрсетілді. Зерттеу математикалық формулалар мен функцияларды қолдану арқылы машиналық оқыту алгоритмінің жұмыс принципі түсіндірілген, сонымен қатар LSTM алгоритмінің құрылымы мен логикалық схемасы ұсынылған.

Ал [2] зерттеу, қазақ ым тілінің динамикалық дактильді жестерін тану мәселесіне тоқталады. Бұл зерттеуде MediaPipe құралдарын қолданып, қолдың негізгі нүктелерін анықтау әдісі ұсынылған. Бұл әдіс қолды дәл анықтап, оның күйін нақты белгілейді. Қолданылған LSTM және GRU (Gated Recurrent Unit) модельдерінің көмегімен тануға оқыту жүргізілген. Бұл әдіс өңдеудің қарапайымдылығымен ерекшеленеді және арнайы жоғары өнімді есептеу техникасын қажет етпейді.

Келесі жұмыста [3] Transformer модельдері негізінде қазақ ым тіліндегі мәтінді аудару зерттелген. Мұнда Kazakh Sign Language (KSL) тілінің грамматикалық құрылымы мен оның сөйлеу қазақ тілінен айырмашылықтары талданған. Бұл жұмыстың негізгі мақсаты – қазақ тілін ым тіліне аударатын параллель корпус құру. Модельдер жоғары аударма дәлдігімен ерекшеленіп, болашақта қолданыс ауқымын кеңейту мүмкіндігін көрсетеді.

Жоғары дәлдікпен статикалық қол белгісін тануға арналған жаңа YOLOv4-CSP [4] моделі ұсынылған. Бұл модель қазақ ым тілінде қол жесттерін тану кезінде жоғары дәлдік пен тиімділікті қамтамасыз етеді. Модельдің артықшылығы – оның жаңа CSPNet желісі арқылы оқыту қабілетінің күшеюі, бұл қолдың жесттерін дәл әрі жылдам тануға мүмкіндік береді.

Қол қимылдарын анықтау мен оларды роботтарды басқару үшін қолдану бойынша зерттеулерде екі кезеңді жүйе ұсынылған[5]. Бірінші кезеңде қолдың орналасуын SSD Single Shot Multibox Detector) детекторы мен ориентация модельдері арқылы анықтау жүзеге асырылады, ал екінші кезеңде нақты қол жесті белгіленеді. Бұл тәсілдердің басты артықшылығы – қолдың толық көрінбеуі мен өзіндік бөгеттерге қарамастан қолдың күйін дәл анықтай алуы.

Әдеби шолудың соңында байқалғандай, терең нейрондық желілер мен жасанды интеллект әдістері қазақ ым тілін тануда тиімді нәтижелерге қол жеткізуде маңызды рөл атқаруда. Алайда, осы салада кездесетін мәселелер, мысалы, аннотацияланған мәліметтер мен модельдердің жетілдірілуі, әлі де өз шешімін күтуде.

Біздің жұмысымыз осы саладағы зерттеулердің жалпы көрінісіне сәйкес келеді және өз үлесін қосады. Біз қазақ ым тілі үшін жаңа деректер жиынтығын жасап, дерекқорды кеңейттік. Сонымен қатар, қазақ ым тіліндегі 42 дактильді тану үшін YOLO NAS s модельінің тиімділігін көрсеттік.

Зерттеу әдістері

Зерттеу барысында компьютерлік көру және терең оқыту әдістері қолданылады. Жасанды объектілерді анықтау үшін қолданылатын қазіргі заманғы модельдердің бірі болып табылатын YOLO NAS қазақ ым тілінің 42 дактильді тану және локализациялау үшін қолданылады. Сондай-ақ, деректерді алдын ала өңдеуде суреттерді аугментациялау әдісі, ал модельді оқыту үшін Adam және SGD (Stochastic Gradient Descent) сияқты оңтайландыру алгоритмдері пайдаланылды.

Деректер жиынтығы бастапқыда 5 500 суреттен құралды, деректер жиынтығын дұрыс аннотациялау үшін біз Roboflow сервисін қолдандық, ал, кейін сол сервис арқылы деректер аугментациясы жүргізіліп, жалпы саны 13 200 суретке жетті.

Модельдің оқыту процесі Google Colab платформасында жүргізілді. Алынған гиперпараметрлер: оқыту жылдамдығы - 0,001, пакет мөлшері - 16, және 30 epoch-та оқытылды.

Нәтижелер

Қазақ ым тіліндегі 42 дактильді тануға арналған модель дәлдік (mAP) метрикасы қолданылды. Оқыту нәтижесінде YOLO NAS s моделі 99,51% дәлдікке жетті. Деректер аугментациясын қолданғаннан кейін, YOLO NAS s+data augmentation моделі өзінің нәтижелерін жақсартып, бағалау жиынтығында 99,84% дәлдік көрсетті, сонымен қатар тест жиынтығында көрсеткіштерін шамамен 0,33%-ға өсті. Деректерді аугментациялау әдісін қолдану модельдің әртүрлі ым-ишара түрлерінің вариацияларға төзімділігін арттырды. Алынған нәтижелер автоматты түрде ым-ишараны мәтінге немесе дауыстық сөйлеуге аудару жүйелеріне интеграциялау мүмкіндігін көрсетеді, бұл есту және сөйлеу қабілеті бұзылған адамдарға коммуникацияны айтарлықтай жеңілдетеді, ақпарат алмасуды жақсартады және ым-ишара арқылы әріптерді көрсету әдісімен әліпбиді үйренуге көмектеседі.

Қорытынды

Бұл жұмыста YOLO NAS s негізінде қазақ ым тілін тану моделі әзірленіп, тексерілді. Жасалған эксперименттер модельдің жоғары дәлдігін растады, бұл оны автоматты түрде ым-ишараны аудару жүйелерінде қолдануға болатынын көрсетеді. Болашақта деректер жиынтығын кеңейту, модель архитектурасын жетілдіру, есту және сөйлеу қабілеті бұзылған адамдармен өзара әрекеттесуге ыңғайлы пайдаланушы интерфейсін әзірлеу жоспарлануда.

Пайдаланылған әдебиеттер тізімі:

1. Mukhanov, S., Uskenbayeva, R., Im Cho, Y., Kabyl, D., Les, N., & Amangeldi, M. (2023). Gesture recognition of machine learning and convolutional neural network methods for Kazakh sign language. *Scientific Journal of Astana IT University*, 85-100, <https://doi.org/10.37943/15LPCU4095>

2. Zholshiyeva, L., & Tamara, Z. (2023). Development of an intellectual system for recognizing Kazakh dactyl gestures based on LSTM and GRU models. *Известия НАН РК. Серия физико-математическая*, (2), 141-153, <https://doi.org/10.32014/2023.2518-1726.190>
 3. Yerimbetova, A., Sakenov, B., Sambetbayeva, M., Daiyrbayeva, E., Berzhanova, U., & Othman, M. (2025). Creating a Parallel Corpus for the Kazakh Sign Language and Learning. *Applied Sciences*, 15(5), 2808, <https://doi.org/10.3390/app15052808>
 4. Egipko, V., Voronin, V., Gapon, N., Zhdanova, M., Semenishchev, E., & Zelensky, A. (2023, June). Real-time robotic hand control using human gesture recognition. In *Real-Time Image Processing and Deep Learning 2023* (Vol. 12528, pp. 118-124). SPIE, <https://doi.org/10.1117/12.2666559>
 5. Alaftekin, M., Pacal, I., & Cicek, K. (2024). Real-time sign language recognition based on YOLO algorithm. *Neural Computing and Applications*, 36(14), 7609-7624, <https://doi.org/10.1007/s00521-024-09503-6>
-

«ФАРАБИ ӘЛЕМІ»

атты студенттер мен жас ғалымдардың халықаралық ғылыми конференция

МАТЕРИАЛДАРЫ

Алматы, Қазақстан, 2025 жылдың 3-5 сәуірі

Мақала мәтініне автор жауапты

Электронды басылым