

МОДЕЛЬ НЕЙРОННОЙ СЕТИ ДЛЯ РАСПОЗНАВАНИЯ АГРОПРОДУКТОВ

Бурибаев Ж.А., Елеусинов А.И., Джолдасбаев С.К.

Институт информационных и вычислительных технологий, Алматы

Аннотация. В данной статье рассмотрены модели и алгоритмы сверточных нейронных сетей для распознавания агропродуктов. Усовершенствована модель VGG16 для корректной классификации. Своевременная уборка агропродуктов и доставка до потребителей в свежем виде является проблемой в сельскохозяйственном секторе. Более быстрая и качественная уборка агропродуктов могло бы помочь решить данную проблему, в то же время существенно снижая экономические потери. Использование сверточных нейронных сетей позволило агророботам повысить точность обнаружения и распознавания объектов. Современные модели сверточных нейронных сетей обучаются по очень крупным задачам классификации изображений. При использовании данных моделей для идентификации агропродуктов (томат, арбуз, тыква и т.д.) возникает проблемы с классификацией, потому что эти агропродукты не были изучены моделями. В статье предлагается модель нейронных сетей, которая идентифицирует агропродукты. Нашей задачей является разработать эффективную модель нейронных сетей для распознавания агропродуктов. В работе рассматривается четыре основных моделей распознавания. А также предлагается метод для увеличения точности распознавания агропродуктов, описываются полученные результаты.

Ключевые слова: распознавания объектов, сверточные нейронные сети, классификация изображений, VGG16.

Введение. Распознавание объектов было движущей мотивацией для исследований в области компьютерного зрения на протяжении многих лет. Недавний прогресс в этой области позволил распознать масштабирование с нескольких экземпляров объектов в контролируемых настройках до сотен категорий объектов в произвольных средах.

В этой статье применяются модели, обученные на больших наборах данных, таких как ImageNet [1] и его применение для нашей задачи.

Обучать только одну модель сверточных нейронных сетей (CNN) для разных объектов является сложной задачей и нуждаются производительных мощностей, когда существует много классов, и объекты различаются по размеру, форме, внешнему виду и другим качествам. Поскольку модель не обладает сложностью, необходимой для моделирования таких больших вариаций в данных.

Несмотря на то, что теоретически можно моделировать любую функцию, используя только один скрытый слой, но количество нейронов, необходимых для этого, было бы очень большим, что затрудняло бы обучение сети. Таким образом, мы используем глубокие сети со многими скрытыми слоями, которые пытаются изучить разные функции на разных уровнях.

Глубокие сети имеют большое количество неизвестных параметров в очень больших количествах [2]. Задачей обучения сети является поиск оптимальных параметров с использованием данных обучения. Для точного нахождения всех

неизвестных параметров нам понадобится много данных. Если у нас очень мало данных, мы получим только приблизительные значения для большинства параметров, которые нам не нужны. Проблема в том, что трудно получить такие огромные помеченные наборы данных для обучения сети.

Другая проблема, связанная с глубокими сетями, заключается в том, что даже если вы получаете данные для обучения сети, может потребоваться много времени, усилий и других затрат для получения удовлетворительных результатов.

Можно использовать уже подготовленные модели на очень больших объемах данных для сложных задач с тысячами классов. Многие исследовательские группы разделяют модели, которые они подготовили для таких наборов данных, как ImageNet. Модели прошли обучение на миллионах изображений и сотни часов на мощных графических процессорах. Чаще всего мы используем эти модели в качестве отправной точки для нашего обучения, чтобы не обучать нашу собственную модель с нуля.

Существует множество моделей, таких как AlexNet, VGGNet, Inception, ResNet, Xception и многие другие, которые мы можем выбрать, для нашей задачи. Многие исследовательские группы также делят свои модели, которые они подготовили для подобных задач, например, MobileNet, SqueezeNet и т. д. [3]. Эти сети обучаются для классификации изображений в одной из 1000 категорий или классов.

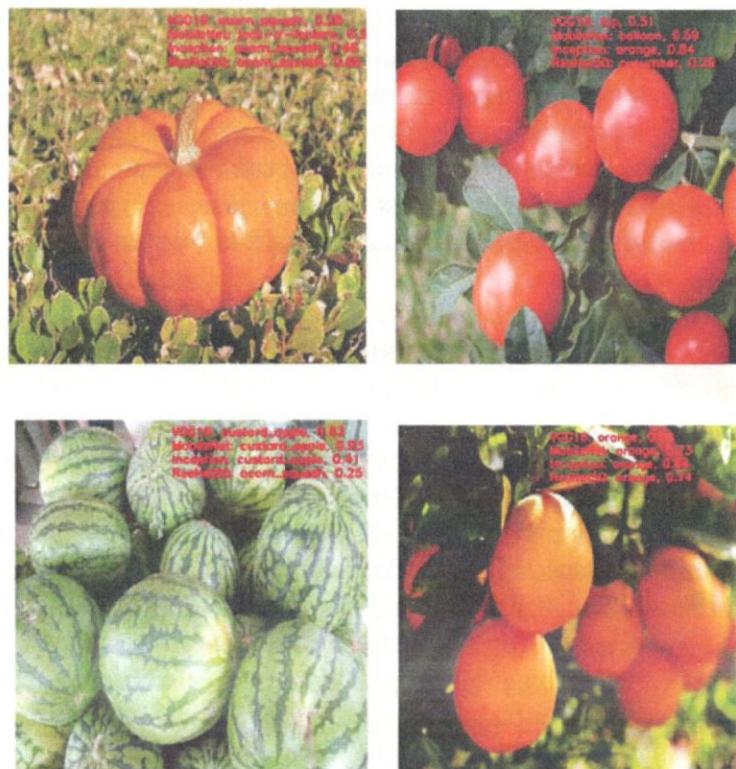
При работе использовалась библиотека Keras, которая поставляется в комплекте со многими моделями. Обученная модель состоит из двух частей: модельной архитектуры и весов моделей. Весы – это большие файлы, и поэтому они не связаны с Keras. Тем не менее, файл весов автоматически загружается один раз, если указывается, что следует загрузить веса, прошедшие обучение по данным ImageNet. Он имеет следующие модели:

- VGG16
- InceptionV3
- RESNET
- MobileNet

Для тестирования были применены данные модели нейронных сетей, получены результаты, указанные в таблице-1.

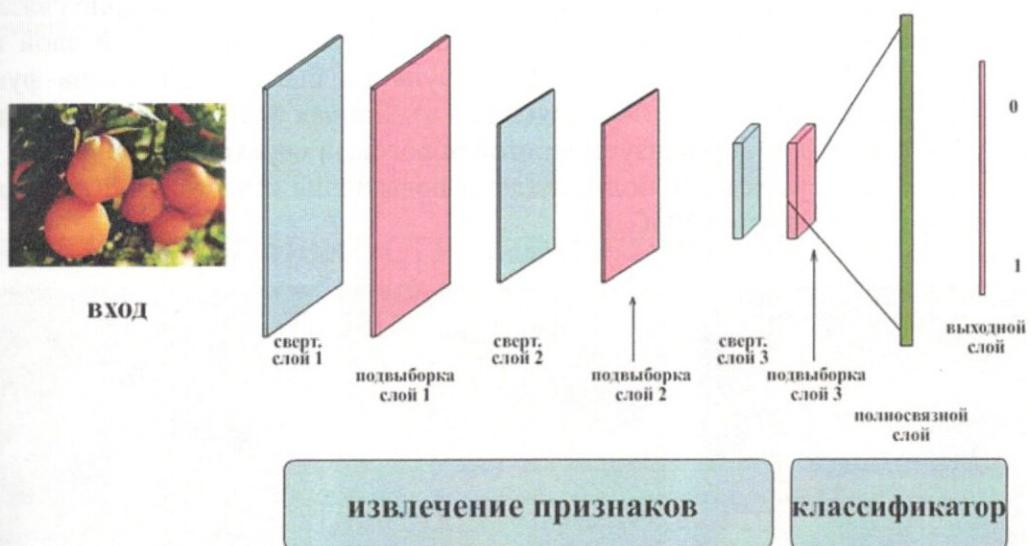
Таблица-1 – Применение моделей для распознавания агропродуктов

	Апельсин	Томат	Арбуз	Тыква
VGG16	0.89	0.51	0.63	0.28
InceptionV3	0.84	0.84	0.41	0.46
RESNET	0.74	0.29	0.25	0.59
MobileNet	0.73	0.59	0.93	0.5



1-рис. – Результаты различных моделей

При сравнении итоговых данных видно то, что не были достигнуты желаемые результаты, так как вышеуказанные модели нейронных сетей смогли распознать только апельсин, остальные агропродукты не были распознаны. Для решения данной проблемы будет использована методика Transfer Learning и применена к нейронной сети модели VGG16.



2-рис. – Структура модели нейронной сети

Обучение модели изначально задается по очень крупным задачам классификации изображений. Сверточные слои действуют как экстрактор признаков, в то время как полностью связанные слои являются классификаторами (2-рис.). Так как модели объемные и работали с огромным количеством данных (изображений) как правило они изучают значимые дискриминационные функции. В данном случае сверточные слои могут быть использованы как экстрактор признаков или подготовленные сверточные слои могут быть настроены в соответствии нашей задачей, как тонкая настройка.

Как правило, если есть небольшой набор тренировок и проблема аналогична задаче, на которой обучены подготовленные модели, то можно использовать передачу обучения. Имея достаточное количество данных, есть возможность настройки сверточных слоев, для определения более надежных функций, которые относятся к нашей проблеме. Далее постараемся дать подробный обзор тонкой настройки и передачи обучения в Keras. ImageNet основан на WordNet, задача которой группировать слова в наборы синонимов (synsets). Каждому synset присваивается определенный «wnid» – идентификатор Wordnet. Например, три разных синтезатора:

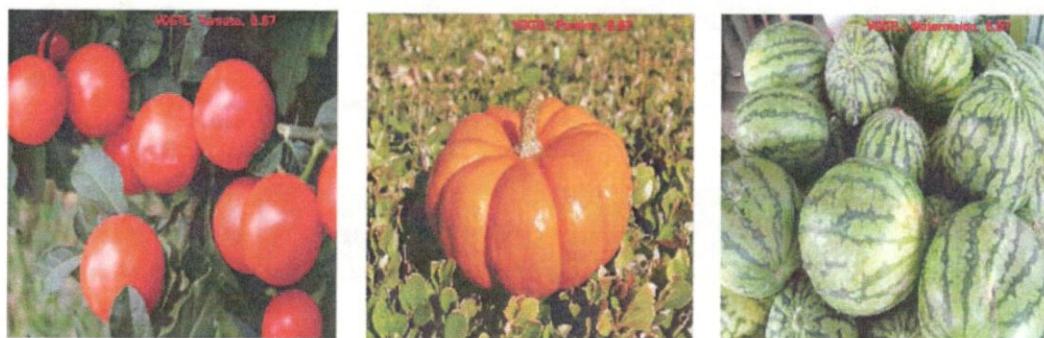
- Red Tomato (synset = n02103406),
- Yellow Tomato (synset = n02109150),
- Green Tomato (synset = n02106854).

Далее перечислены wnid из 3 классов объектов, которые рассматриваются ниже.

- n07734017 -> Tomato
- n07735510 -> Pumpkin
- n07756951 -> WaterMelon

Есть вероятность того, что данные будут очень шумные, т.е. много беспорядка, объекты закрыты и т.д. В работе использовалось около 250 изображений для каждого класса. Были созданы две директории: «поезд» и «валидация», чтобы использовать функции Keras для загрузки изображений. В работе были загружены предварительно подготовленные данные – модель VGG вместе с весами ImageNet. Следует отметить, что были загружены только сверточные слои. А последние два полностью связанных слоя, работающие как классификатор, не были загружены. Последний слой имеет форму 7x7x512. В качестве активационных функций была использована функция ReLU ((rectified linear unit, русс. «выпрямитель»). Данная функция активации имеет формулу $f(x) = \max(0, x)$ и реализует простой пороговый переход в нуле [9].

Результаты эксперимента подтверждают повышения качества распознавания, а также улучшения алгоритма VGG16.



3-рис. – Результаты проведенной работы по распознаванию агропродуктов

Nhcmuyym cuclmam ahspesmuu CO PAH

Tyron E.B., Spokane B.M.

AHAJNIS EFFEKTNHOCTN EHEPTEHNECERNX UJATHAUNN

YUK 330.4

1. Maxime Oquab, Leon Bottou, Ivan Laptev, Josef Sivic. Learning and Transferring Mid-Level Image Representations Using Convolutional Neural Networks, 2014 IEEE Conference on Computer Vision and Pattern Recognition, 1718-1724 C.

2. Anh Nguyen, Jason Yosinski, Jeff Clune. Deep Neural Networks are Easily Fooled: High Confidence Predictions for Unrecognizable Images, In Computer Vision and Pattern Recognition (CVPR '15), IEEE, 2015.

3. M. Norouzi, M. Ranzbari and G. Mori, "Stacks of convolutional Restricted Boltzmann Machines for shift-invariant feature learning", 2009 IEEE Conference on Computer Vision and Pattern Recognition, Miami, FL, 2009, pp. 2735-2742.

4. Harvey Jake e., opena, John paul t. yusioing. Automated tomato maturity grading using abc-trained artificial neural networks. *Malaysian Journal of Computer Science*, 2017.

5. Huang Y., Lee F. An automatic machine vision-guided grasping system for harvesting phalenopsis tissue culture plants, *Computers and Electronics in Agriculture*, 42-51C.

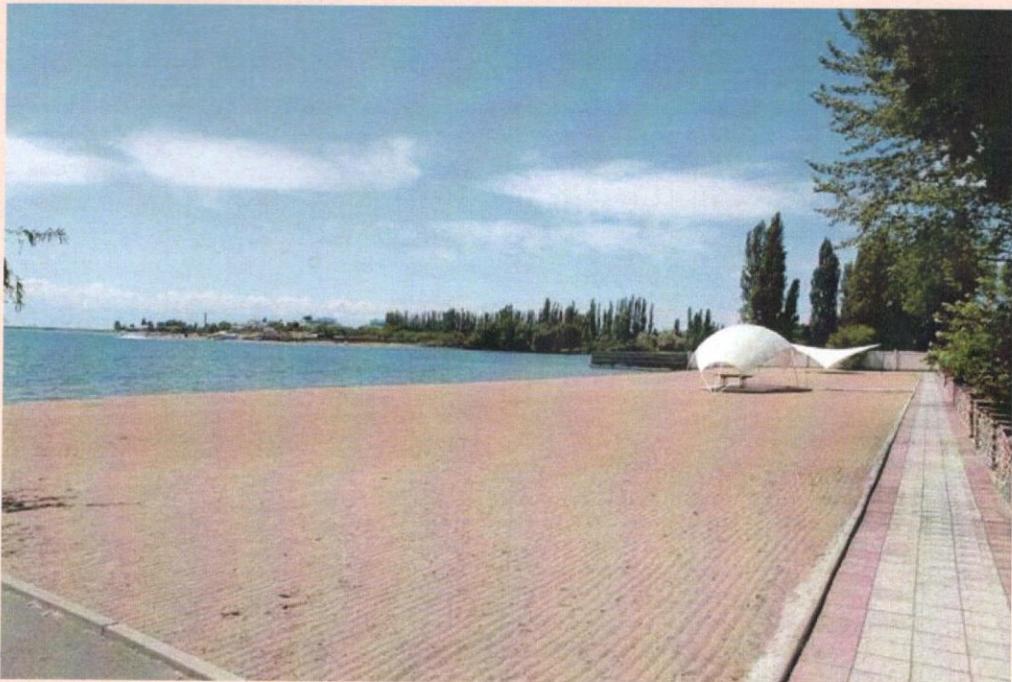
6. Harrell R., Slaugher D., Asstt P. A fruit-tracking system for robotic harvesting, *Machine Vision and Applications*, 2, 69-80 C.

7. Liu Y., Chen B., Qiao J. Development of a machine vision algorithm for recognition of peach fruit in a natural scene, *Transactions of the ASABE*, 54, 695-702 C.

8. Jiang H., Peng Y., Ying Y. Measurement of 3-d locations of ripe tomato by binocular stereo vision for tomato harvesting, *ASABE Annual International Meeting*, 2018.

9. Yongjie C., Maslenn N., Feng G., Kenji H., Osamu K., Masafumi, M. An automatic machine vision-guided grasping system for phalenopsis tissue culture plants, *Computers and Electronics in Agriculture*, 2010, 42-51 C.

Зарюхе. Типнебеңе һенпophиx certain B үпкىзажиx 3ауаx сиbориx
бce 60жe артаязбiм һатпаражиxенем B қобремехон мiнe ھayкa n үnyciпn. Coint
ometint, Aтpo үpомпiнiтiхочтa тaккe арнiретa нctoнiкoм ee aktayiбiхocht. B
jaхон пaгoтe pacmaтиpbaзiac 3aуaha pacmo3ahabaзiн aрpoпpoуkyta c үpимеhенem
heпpophиx ceгen, Bpli tipеjiokeh metoJ no yjyиmeheno aзiopntma. B җaзihеnem
muahnpophиx paзpaгoтaз Bpincиhеne koopjnhat pacmo3oкehia aрpoпpoуkytob c
nejpho co3jahna tipopamhoro komtireca juia y6opophix aрpо-pogotob.



МАТЕРИАЛЫ
XIV Международной Азиатской
школы-семинара
«ПРОБЛЕМЫ ОПТИМИЗАЦИИ
СЛОЖНЫХ СИСТЕМ»
20 - 31 июля 2018 года

ЧАСТЬ 1

**Кыргызская Республика
оз. Иссык-Куль
пансионат «Отель Евразия»**

Алматы 2018

УДК 51
ББК 22.1
П78

Главный редактор:

Калимолдаев М.Н. - генеральный директор ИИВТ, академик НАН РК, доктор физико-математических наук, профессор (Республика Казахстан, Алматы)

Ответственные редакторы:

Мамырбаев О.Ж. - заместитель генерального директора ИИВТ, доктор PhD (Республика Казахстан, Алматы)

Магзом М.М. - заместитель генерального директора ИИВТ, доктор PhD (Республика Казахстан, Алматы)

Токтошов Г.Ы. – научный сотрудник Института вычислительной математики и математической геофизики СО РАН (Россия, Новосибирск)

П78 Проблемы оптимизации сложных систем: Мат. XIV межд. азиат. школы-семинара (20-31 июля 2018 г.). Часть 1. – Алматы, 2018, – 355 с.

ISBN 978-601-332-127-1

В сборнике представлены материалы XIV Международной Азиатской школы-семинара «Проблемы оптимизации сложных систем».

В сборнике опубликованы доклады, представленные учеными от Республики Казахстан, Российской Федерации, Кыргызской Республики, Республики Узбекистан и других.

Рассмотрены актуальные вопросы в области математики, информатики и управления: математического моделирования сложных систем и бизнес-процессов, исследования и разработки защищенных и интеллектуальных информационных и телекоммуникационных технологий, математической теории управления, технологий искусственного интеллекта.

Материалы сборника предназначены для научных работников, докторантов и магистрантов, а также студентов старших курсов.

УДК 51
ББК 22.1

ISBN 978-601-332-127-1

© Институт информационных и
вычислительных технологий
МОН РК, 2018

Ахмед-Заки Д.Ж., Лебедев Д.В., Айдосова Ж.К., Маульшариф М.М., Толенбеков Е.К.	ПСИХОЛОГИЧЕСКИЕ ОСОБЕННОСТИ ЛИЧНОСТИ СТУДЕНТОВ И ИЗУЧЕНИЕ ИХ ВЗАИМОСВЯЗИ С ПОЛУЧЕННЫМ ПРОФИЛЕМ ИЗ СОЦИАЛЬНОЙ СЕТИ ДЛЯ ПОВЫШЕНИЯ КАЧЕСТВА ОБРАЗОВАНИЯ НА ОСНОВЕ АНАЛИЗА ПРОФИЛЯ	134
Байшемиров Ж.Д., Адиль Н., Баймурзаев Д.Д.	УСРЕДНЕННЫЕ МОДЕЛИ РАВНОВЕСНОГО ДВУХФАЗНОГО ПОТОКА СЖИМАЕМЫХ ФЛЮИДОВ	141
Бакирова Э.А., Кадирбаева Ж.М.	ОБ ОДНОЙ ЧИСЛЕННОЙ РЕАЛИЗАЦИИ МЕТОДА ПАРАМЕТРИЗАЦИИ РЕШЕНИЯ ЗАДАЧИ УПРАВЛЕНИЯ ДЛЯ ДИФФЕРЕНЦИАЛЬНОГО УРАВНЕНИЯ	146
Бегалиева К.Б., Аршидинова М.Т., Кудайкулов А.К., Ташев А.А.	ЭНЕРГЕТИЧЕСКИЙ МЕТОД РЕШЕНИЯ НЕЛИНЕЙНОЙ ЗАДАЧИ ТЕРМОУПРУГОСТИ ДЛЯ СТЕРЖНЯ ПЕРЕМЕННОГО СЕЧЕНИЯ	156
Бегимбаева Е.Е.	РАЗРАБОТКА МОДЕЛИ СИСТЕМЫ ЗАЩИЩЕННОГО ТРАНСГРАНИЧНОГО ОБМЕНА	162
Бекмуратов Т.Ф., Мухамедиева Д.Т.	МОДЕЛЬ НЕЧЕТКОЙ БАЗЫ ЗНАНИЙ ДЛЯ ЗАДАЧИ ПРОГНОЗИРОВАНИЯ УРОЖАЙНОСТИ	166
Бердышев А.С., Рыскан А.	РЕШЕНИЕ СИСТЕМЫ ДИФФЕРЕНЦИАЛЬНЫХ УРАВНЕНИЙ В ЧАСТНЫХ ПРОИЗВОДНЫХ ВТОРОГО ПОРЯДКА ДЛЯ ГИПЕРГЕОМЕТРИЧЕСКОЙ ФУНКЦИИ ОТ ЧЕТЫРЕХ ПЕРЕМЕННЫХ $F_{10}^{(4)}$	171
Блейхер Г.А., Кривобоков В.П., Байдикова Н.В.	ИССЛЕДОВАНИЕ ПРОЦЕССОВ ТЕПЛОМАССОПЕРЕНОСА ПРИ ЭЛЕКТРОННО-ЛУЧЕВОЙ СВАРКЕ	176
Бурибаев Ж.А., Елеусинов А.И., Джолдасбаев С.К.	МОДЕЛЬ НЕЙРОННОЙ СЕТИ ДЛЯ РАСПОЗНАВАНИЯ АГРОПРОДУКТОВ	181
Губий Е.В., Зоркальцев В.И.	АНАЛИЗ ЭФФЕКТИВНОСТИ ЭНЕРГЕТИЧЕСКИХ ПЛАНТАЦИЙ	185