

Комитет науки Министерства образования и науки
Республики Казахстан
РГП «Институт информационных и вычислительных технологий»
КН МОН РК



25 лет
Независимости
Республики Казахстан



25 лет
Институту
информационных и
вычислительных
технологий

МАТЕРИАЛЫ

Международной научной конференции
«Информатика и прикладная математика»
(«Computer science and Applied Mathematics»),
посвященной 25-летию Независимости Республики Казахстан и
25-летию Института информационных и
вычислительных технологий

Часть I

г. Алматы, 21-24 сентября 2016 года

Алматы
2016

Содержание

Жанысбекова Г.А., Сембиеев О.З., Сулейменова Л.А., Ашим Ж.К., Тимабай Ж.Н.	Локализация на карте ГИС территорий военно-политических процессов Казахского ханства с использованием ИТ-технологии	111
8		
Исмаилов Б.И., Мамбеталиева С.М.	Снижение субъективности весовых коэффициентов при оценке эффективности работы университетов по множеству критериив	125
13		
Костылев А.О., Скопина Л.В.	Принятие инвестиционных решений в нефтегазовой отрасли в условиях неопределенности	134
21		
27		
Култешов Б.Ш.	Почти счетная категоричность в упорядоченных структурах	141
36		
Купчишин А.И., Купчишин А.А., Шмыгалева Т.А., Шмыгалев Е.В.	Основы каскадно-вероятностного метода	151
47		
54		
Мансурова М.Е., Койбагаров К.Ч., Барахнин В.Б., Солтангельдинова М., Бердибеков С.	Применение морфологического анализатора казахского языка для извлечения фактов из фактографических систем	156
66		
76		
Мурзабеков З.Н., Мурзабеков А.З.	Синтез пропорционально-интегральных регуляторов для систем автоматического управления при наличии ограниченных управляемых воздействий	166
85		
93		
105		
Мухарлямов Р.Г.	Построение уравнений динамики систем с линейными дифференциальными программными связями	174
Плесневич Г.С., Карабеков Б.С., Нгуен Тхи Минь Ву	Спецификация онтологий для потоков задач	182
Рысбайулы Б., Карашибаева Ж.О.	Задача продолжения для процесса переноса тепла и влаги в многослойной области	193
Тлеубергенов М.И., Ажымбаев Д.Т.	Итеративно-интервальный подход к расчету тепловых параметров в метастабильных горных системах при неточных исходных данных	201
Хисамиев Н.Г., Конырханова А.А.	О построении стохастических дифференциальных уравнений по заданному интегральному многообразию	210
	Вычислимые ретракты разрешимых групп	218

ПРИМЕНЕНИЕ МОРФОЛОГИЧЕСКОГО АНАЛИЗАТОРА КАЗАХСКОГО ЯЗЫКА ДЛЯ ИЗВЛЕЧЕНИЯ ФАКТОВ И ФАКТОГРАФИЧЕСКИХ СИСТЕМ

Мансурова М.Е.¹, Койбагаров К.Ч.², Барахнин В.Б.^{3,4},
Солтангельдинова М.¹, Бердабеков С.¹

¹Казахский национальный университет имени аль-Фараби, Казахстан

²Институт информационных и вычислительных технологий МОН РК

Казахстан,

³Институт вычислительных технологий СО РАН, Россия,

⁴Новосибирский государственный университет, Россия

Аннотация

В данной работе описывается применение лингвистического анализатора для казахского языка для автоматизированного наполнения онтологии фактографической поисковой системы. Для осуществления морфологической разметки используются лексический и морфологический модули анализатора. Задачей лексического модуля является определение границ слов, выражений, выделение слов, идентификаторов и пунктуационных маркеров. Морфологический модуль выполняет поиск слов в словаре казахского языка и определяет их морфологические параметры. Осуществляемая с помощью разработанного анализатора морфологическая разметка является этапом автоматизированного наполнения онтологии фактографической поисковой системы.

1 Введение

В тюркологии существует большое количество исследований по автоматизации морфологической разметки текстов для родственных казахскому языков, основанных на разных концептуальных подходах [1, 2, 3, 4, 5]. Анализ открытых публикаций в области технологий морфологического анализа словоформ казахского языка показывает, что данное направление исследований представляет большой теоретический и практический интерес.

С 1970-2000 года публикации в области морфологии казахского языка имели в основном теоретический характер. С 2006 годов появились публикации в зарубежных журналах ([6, 7, 8, 9]). В работах российских исследователей описаны принципы построения существительных казахского языка на флексивные классы и построение базового на этом разбиении алгоритма синтеза словоформ [10, 11]. Среди казахстанских ученых особо следует отметить работу Шарипбаева А.А. ([12]), посвященную проектированию интеллектуального морфологического анализатора, основанного на семантических сетях. Целый ряд работ исследовательской группы из Национального Университета посвящен методу морфологического анализа и устранения недостаточности для казахского языка, который учитывает как флексивную, так и деривативную морфологию [13, 14, 15]. Все перечисленные работы затрагивают различные аспекты области морфологии и синтаксиса казахского языка, при этом основное внимание уделяется методологии построения морфологического анализатора. В связи с этим актуальными являются вопросы проектирования, программной реализации и применения в открытом доступе морфологического анализатора для казахского языка. По методам морфологического анализа, использующихся в лингвистических проекциях можно выделить методы с декларативной и с процедурной ориентацией. Данная

и продолжением исследований авторов в этой области, в основе которых лежит новый подход, который использует преимущества как декларативного, так и программного методов [16, 17, 18].

Дальнейшее изложение работы выглядит таким образом. В разделе 2 приводится описание разработки анализатора для автоматизации морфологической разметки текста на казахском языке. Раздел 3 содержит сведения о технологии автоматизированного применения онтологии фактографической поисковой системы. В разделе 4 описываются результаты вычислительных экспериментов. В разделе 5 формулируются выводы и определяется план будущих исследований.

1 Разработка анализатора для автоматизации морфологической разметки текстов на казахском языке

1.1 Особенности казахской морфологии

Казахский язык относится к классу агглютинативных языков и вместе с узбекским, кыргызским, башкирским, татарским, азербайджанским, турецким и другими языками образует тюркскую семью. Для агглютинативных языков характерно последовательное присоединение различных формообразующих суффиксов или окончаний, неизменяющих грамматическое значение, к неизменяемому корню или основе, являющимся единицами лексического значения.

Порядок добавления аффиксов строго определен. Например, для имен существительных к основе слова вначале добавляется суффикс и далее окончание множественности числа, затем притяжательное окончание, далее следует падежное окончание и повторное окончание формы спряжения (добавляется только к одушевленным существительным) [19, 20].

Для казахского языка существует закон сингармонизма: гармония гласных и согласных звуков аффикса со звуками корня. Гармонируют гласные по принципу твердотвердости и согласные – конечный звук корня и первый звук аффикса. Помимо трех основных правил сингармонизма, необходимо учитывать следующие правила исключений:

1. Правило удаления глухой согласной в прибавляемом аффиксе, если в окончании присутствуют две глухие согласные. Например: **журналист+тер -> журналистер**.

2. Закон сингармонизма не соблюдается в следующих случаях следующих аффиксов:

a) для аффиксов **мен, пен, бен**: *қаламмен; нікі, дікі, тікі; баланікі;*

b) для заимственных слов с окончаниями: **рк, ик, кс, кт:- пукнте**

3. Правило выпадения гласной **і, ы** в корне слова при добавлении притяжательного аффикса **і, ы**. Например: *Әрін - әрпі, қаяин - қауні, қойын - қойны, Ерін - ерні, құлқы.*

1.2 Структура лингвистического анализатора

На рис. 2 представлен разрабатываемый нами лингвистический анализатор, который состоит из четырех анализаторов (лексический, морфологический, синтаксический, идентический) (рис 1). Анализаторы располагаются последовательно друг за другом, входной поток одного анализатора служит входом для следующего анализатора. Задача лексического анализатора является определение границ предложений, выделение идентификаторов и пунктуационных маркеров. Морфологический анализатор выполняет поиск слов в словаре (словарь представляет собой отдельную базу данных) и вычисляет их морфологические параметры (например, часть речи, число, падеж и т.д.). Синтаксический анализатор выполняет построение синтаксического графа

предложения. В данной работе мы используем два анализатора – лексический и морфологический анализатор.

Лексический анализатор – это программа начального анализа естественного языка, представленного в виде цепочки Unicode символов. Выходная информация необходима для дальнейшей обработки морфологическим и синтаксическим анализаторами. В задачу лексического анализатора входят:

1. Разделение входного текста на слова, числа, разделители и т.д.
2. Выделение устойчивых оборотов, не имеющих словоизменительных вариантов;
3. Выделение имен собственных, выделение ФИО (фамилия, имя, отчество), когда имя и отчество написаны инициалами;
4. Выделение электронных адресов и имен файлов;
5. Выделение предложений из входного текста;

Процедура выделения из текста слов, чисел и знаков препинания совершается в виду. После считывания очередного абзаца текста графематический анализатор выделяет токены и приписывает им соответствующие графематические характеристики. На этом этапе выделение токенов производится по пробелам и знакам препинания. Одной из наибольшей сложность составляет определение начала и конца предложения. Лексический анализатор содержит эвристический механизм определения границ предложения и результатами лексического анализа является не только массив лексем, но и указатели на начало и конец текущего предложения в тексте.

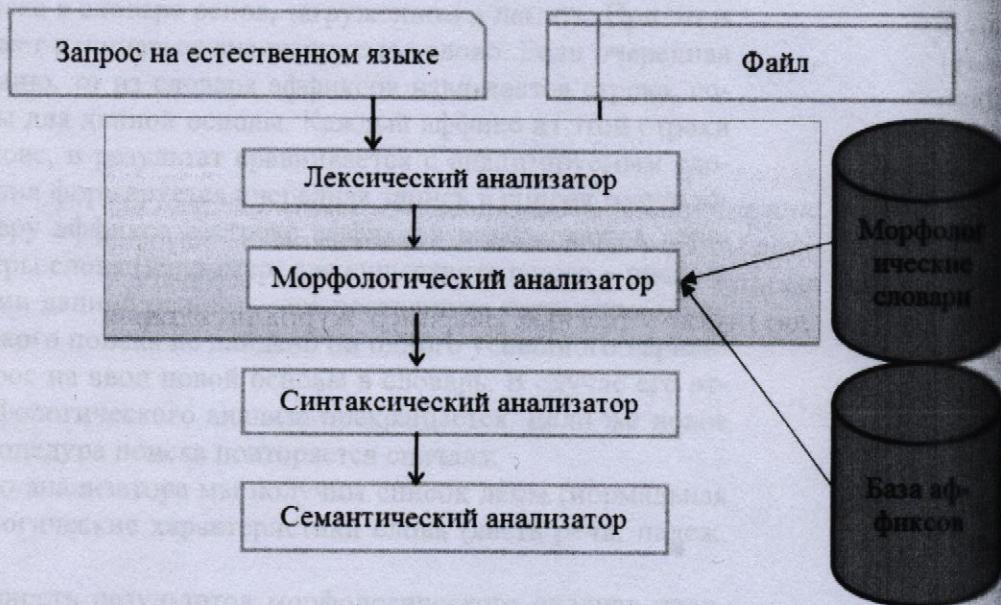


Рис. 1. Состав лингвистического анализатора

Найти конец предложения в тексте тоже не так просто, как может показаться. Восклицательный или вопросительный знак наверняка означают конец предложения, но вот точка может стоять и после сокращения, и в середине десятичной дроби. Следует также учитывать и сложные единицы измерения (кв.м, км/час), интернет-адреса (<http://yandex.ru>), записанные цифрами порядковые числительные (1917-ж.), выделенные фамилии (Касымов К.С.). Рассмотрим следующий фрагмент:

1917 ж. 21-26 шілдеде Покровский С.И. Орынборда болған «Букілқазақтық»

Несколько точка встречается четырежды, и только в четвертом случае она означает ко-
нцовка предложения. Поэтому в анализатор введены специальные блоки проверки. В част-
ности простейшая проверка: лексема, стоящая непосредственно перед точкой, должна
быть хотя бы одну гласную. Такой проверкой удается отобрать многие сокраще-
ния, потребляемые с точкой на конце:

и, т.г.к., тг., ф.-м.ф.д., к.

Разумеется, такая проверка не гарантирует правильность результата. С одной сто-
роны сокращение или число с точкой могут действительно стоять в конце предложения
не менее, опять работы с документами подтверждает эффективность такой
проверки. Только после анализа точек, не являющихся маркером предложения, выпол-
няется разбивка абзаца на предложения, и весь дальнейший анализ ведется уже только
в пределах одного предложения.

1.3 Описание алгоритма морфологического анализатора

Работает морфологический анализатор следующим образом. На его вход поступают
слова, знаков препинания и чисел, выделенных из входного текста на этапе
лексического анализа, с лексическими характеристиками [21]. Для каждого слова ана-
лизатор выполняет процедуру поиска в словаре основ, загруженном в память. При этом
находит все основы, с которых может начинаться анализируемое слово. Если очередная
основа удовлетворяет этому условию, то из словаря аффиксов извлекается строка, со-
дущая все возможные аффиксы для данной основы. Каждый аффикс из этой строки
присоединяется к основе, и результат сравнивается с анализируемым сло-
вом. В случае их точного совпадения формируется очередная запись в список результа-
та. По порядковому номеру аффикса в строке аффиксов определяются пере-
ходные морфологические параметры слова (например, для существительного – число и
положение в предложении, для глагола – время и модальность). По словарной информации данной основы – его постоянные параметры (сущ.,
прил...). Если в результате такого поиска не найдено ни одного успешного вариан-
та, пользователю выдается запрос на ввод новой основы в словарь. В случае его от-
рицательного ответа выполнение морфологического анализа прекращается. Если же новое
слово в словарь введенено, то вся процедура поиска повторяется сначала.

На выходе морфологического анализатора мы получим список лемм (нормальная
форма слова) + аффикс + морфологические характеристики слова (часть речи, падеж,

таким образом, вся совокупность результатов морфологического анализа пред-
ставлена в виде динамического массива. Число его элементов равно числу лексем в
тексте. Элементами массива являются другие массивы, каждый из которых хра-
нит возможные интерпретации своей лексемы омонимы. В качестве исходных лек-
сем материалов используются словарь основ слов, словарь географических названий,
словарь фамилий, словарь аффиксальных соединений.

Разработанный морфологический анализатор представлен в открытом доступе:
<http://mf.kaznu.kz/>. Наличие морфологической разметки текстов корпуса расширяет
возможности поиска по корпусу: в качестве поискового запроса пользователь будет
иметь возможность задать любое сочетание признаков слова, имеющихся в системе.
Разработанный анализатор позволяет решать различные задачи по обработке текстов на
национальном языке. В следующем разделе описывается применение морфологического
анализатора для автоматизированного наполнения онтологии фактографической поис-
ковой системы.

3 Алгоритм автоматизированного наполнения онтологии фактографической поисковой системы

В данном разделе описан алгоритм, позволяющий извлечь ключевые слова/словосочетания из корпуса текстов однородной тематики. Извлеченные слова в дальнейшем используются в качестве возможных значений атрибутов сущностей, описываемых в создаваемой онтологии предметной области, предназначенной для организации фактографического поиска. В качестве входных данных используется текст на казахском языке, предварительно размеченный с помощью морфологического анализатора, описанного в разделе 2. Для извлечения семантически связанных слов/словосочетаний в алгоритме применяется метод случайных блуждающих набору этих словосочетаний с целью отнесения конкретного словосочетания к определенному атрибуту описываемой в тексте сущности применяется обученная нейросеть со скрытым слоем.

3.1 Автоматизированное извлечение фактов в системах фактографической поиска

Важным этапом процесса функционирования фактографических систем является извлечение фактов, содержащихся в текстах документов. Как показано в [22], в этом понимается совокупность связей между сущностями, содержащейся в текстах различных документов. Практическая реализация такого подхода опирается на множество сущностей [23], отличительные особенности которой заключаются в том, что, во-первых, в ней всё трактуется как объекты, во-вторых, все связи в этой модели бинарные, причем связи между объектами также рассматриваются как объекты, связанные, в свою очередь, с объектами – атрибутами связей. Таким образом, в качестве атомарного факта можно рассматривать входящую в текст и в мотивацию документа характеристику сущности, описываемую в онтологии информационной системы. Такая характеристика представляется как единичное значение данной сущности. В работе под онтологией понимается модель с произвольным набором отношений.

Наиболее сложной проблемой, возникающей при создании фактографических систем, является разработка методик автоматизированного извлечения фактов из документов на естественном языке. Для достижения поставленной цели необходимы следующие задачи:

- 1) разметить текст, определяя, к какой части речи относится каждая входящая в текст;
- 2) извлечь из размеченного текста наборы семантически связанных слов;
- 3) создать нейросеть, обученную извлечению лингвистических конструкций, которые входят возможные значения атрибутов сущностей, описываемых в предметной области;
- 4) используя коллекцию лингвистических конструкций и наборы семантически связанных слов, наполнить онтологию предметной области.

Особенностью данного алгоритма является возможность использования результатов его применения для автоматизированного добавления вики-разметки в структурированные документы, предназначенные для помещения в Википедию.

3.2 Создание и обучение нейронной сети

Для выполнения этого этапа в качестве входных данных выбирается корпус текстов с википодобной разметкой. Данный корпус используется для обучения нейронной сети, извлекающей лингвистические конструкции, в которые входят возможные значения атрибутов сущностей.

бутов сущностей, описываемых в онтологии предметной области. Мы остановимся на выборе на нейронной сети со скрытым слоем [24].

Следующие входные данные – это лексические конструкции, например, для био- “родился x ”, “появился на свет x ” и т.п., где x – искомая характеристика (дата рождения). Процесс обучения сети осуществляется посредством предъявления каждого набора данных и последующего распространения ошибки. Стоит отметить, что решениях данной задачи весовые коэффициенты являются булевозначными, равно как и сама ошибка. В рассматриваемой задаче при распознавании синонимов сначала определяется синоним первой характеристики, синоним второй и так далее, затем определение повторяется. В итоге обученная сеть способна извлекать лингвистические конструкции, в которые входят возможные значения атрибутов сущностей, описываемых в онтологии предметной области. Отметим, что в текущей реализации скрытый слой реализован в виде коллекции в MongoDB.

Извлечение наборов семантически связанных слов

В данной работе на основе морфологического анализа текста с помощью метода случайных блужданий извлекаются семантически связанные слова. Предположим, что у нас имеется текст, включающий в себя n документов: $D = (d_1, d_2, \dots, d_n)$.

В данном случае, в качестве документа при анализе текста целесообразно рассматривать отдельно взятое предложение. Обозначим через: $W = (w_1, w_2, \dots, w_n)$ слова, входящие в каждое слово документа нам известны его морфологические характеристики (вид речи, род число, падеж и т.д.). Кроме того, для каждого документа мы можем вычислить вес слова в данном документе (TF-IDF).

Анализируемый текст можно представить в виде гиперграфа $H = (V, E)$, в котором V – это слова текста, гиперребра $e \in E$ – это документы нашего текста. Семантическую связь между вершинами (словами) нашего гиперграфа будем вычислять на основе модели случайных блужданий (random walk model) между вершинами гиперграфа. Предполагается, что случайный переход от вершины к вершине осуществляется в два этапа (на первом выбирается одно из гиперребер, смежных с нашей вершиной, на втором этапе случайным образом выбирается вершина данного гиперребра). Таким образом, процесс случайных блужданий будет представлять собой динамическую цепь Маркова с конечным множеством состояний. Как известно, основным результатом такого процесса является матрица вероятностей переходов между состояниями. Таким образом, на выходе получаем набор семантически связанных слов, из которых будет реализован алгоритм фактографического поиска.

Наполнение онтологии предметной области

Работа алгоритма была проверена на биографиях учёных, так как биографии природы и общества имеют сходную онтологию. В качестве обучающей выборки были взяты статьи из Википедии. В качестве примера полного цикла работы алгоритма рассмотрим биографию Фаризы Онгарсынкызы. На первом этапе текст биографии разбивается по частям речи. Затем с помощью метода случайных блужданий выделяются семантически связанные слова и словосочетания.

Вычислительные эксперименты

Предложенный алгоритм был опробован на биографиях выдающихся личностей. Для этого на нейронной сети со скрытым слоем было использовано 100 статей из Википедии и сайта Жарап [25] и извлеченные из соответствующих биографий наборы

ключевых слов. В качестве дескрипторов для извлечения онтологии были следующие характеристики: имя, род деятельности, дата рождения, дата смерти.

На первом этапе, текст биографии размечается по частям речи морфологический анализатор. При разметке тексты разделяются по предложению для каждого слова, входящего в предложение, по базе ищутся все основы которых может начинаться данное слово. И таким образом, идет анализ каждого определяются все характеристики и на выходе мы получаем список лемм + морфологические характеристики.

Ниже приведена часть размеченного текста:

Предложение: *Фариза Оңғарсынқызы Оңғарсынова - қазак ақыны, жазушысы, журналист. 1939 жылы 5 желтоқсанда Гурьев (қазіргі Атырау) қаласы, Новобогат ауданына қарасты Манаш ауылында туған.*

Разметка:

Фариза/фариза|| [fio]
қазак/қазак|| [zt]
акыны/акын[ы] [3T|ы/ТЖ-3+ØAC] // сущ + притяж.оконч
.|| [Comma]
халық/халық|| [zt]
жазушысы/жазушы[сы] [3T|сы/ТЖ-3+ØAC] сущ + суффикс + притяж.оконч
.|| [Comma]
журналист/журналист|| [zt]
.|| [Comma]

1939/1939|| [NUMCHAR]
<omonim>
жылы/жылы|| [sn]
жылы/жылы|| [et]
жылы/жыл[ы] [3T|ы/ТЖ-3+ØAC]
</omonim>
5/5|| [NUMCHAR]
желтоқсанда/желтоқсанда [3T|да/ЖС]
Гурьев/турьев|| [fio]
(/|| [LBracet]
қазіргі/қазіргі|| [sn]
<omonim>
Атырау/атырау|| [zt]
Атырау/атырау|| [geo]
</omonim>
)|| [RBracet]
облысы/облыс[ы] [3T|ы/ТЖ-3+ØAC]
.|| [Comma]
Новобогат/<Unknown>
ауданына/ауданына [3T|ы/ТЖ-3+на/БС]
<omonim>
қарасты/қарасты|| [yc]
қарасты/қарасты [3T|ты/TC]
қарасты/қарасты [ET|ты/ЖӨШI+АР+ЖЖ-3]

имени

жанн майаш|| [fio]

жаннда/ауылбында| [ЗТ]ы/ГЖ-3+ида/ЖС]

имени

жанн тұган|| [zt]

жанн тұған| [ЕС]тан/БС]

жанн тұған| [ЕТ]тан/Е+АР+ЖЖ-3]

имени

жанн тұнда

бюл штого с помощью метода случайных блужданий выделяются ключевые словосочетания, например:

жанн оңгарсының оңгарсынова, ақын, жазушы, 1939 жыл 5 желтоқсан,

жанн, Манаши ауылы и т.д.

на последнем этапе, нейронная сеть размещает данные по дескрипторам.

имя: "жанн оңгарсының оңгарсынова"

имя: "ақын", "жазушы"

имя: birth: "1939 жыл 5 желтоқсан"

имя: death: "2014 жылдың 23 қаңтар"

Бақылование

данной работе описывается применение морфологического анализатора для автоматизированного наполнения онтологии фактографической поисковой системы. Всемирная технология основана на применении морфологического анализатора для текста с последующим использованием метода случайных блужданий для извлечения семантически связанных ключевых слов (словосочетаний). К набору этих слований с целью отнесения конкретного словосочетания к определенному атрибуту, включаемому в тексте сущности применяется обученная нейронная сеть со скрытым слоем. В дальнейшем планируется продолжить исследования по разработке модуля лексического и семантического анализаторов, что расширит возможности для наполнения онтологии и функционирования фактографической поисковой системы.

Бақылование выполнено при финансовой поддержке МОН РК в рамках научного проекта № 5033 «Разработка интеллектуальной высокопроизводительной информационно-справочной поисковой системы обработки слабоструктурированных данных». В работе морфологического анализатора принимали участие сотрудники Института информационных и вычислительных технологий» МОН РК и сотрудники Института языка имени Ахмета Байтурсынова МОН РК.

Литература:

Махмудов М. Системы автоматической переработки тюркского текста на лексико-морфологическом уровне. – Баку: Элм, 1991. – 114 с.

Мигалкин В.В. Моделирование орфографии якутского языка и разработка компьютерных программ для проверки правописания якутских текстов в среде Windows; Автодиссертация к.т.н. Якутск, 2005.

Садыков Т. Проблемы моделирования тюркской морфологии: аспект порождения искаженной именной словоформы. – Изд-во Илим, 1987. – 119 с.

4. Сиразитдинов З.А. Моделирование грамматики башкирского языка. Словоизменительная система. – Уфа, 2006. – 160 с.
5. Сиразитдинов З.А. О моделировании словоизменительной системы агглютивных языков парными сочетаниями (на примере башкирского языка)/Актуальные проблемы современного монголоведения и алтайстики. Материалы Международной научной конференции. Элиста, 2014. С. 139-143.
6. Jonathan North Washington. A Novel Approach to Delineating Kazakh's Five Present Tenses: Lexical Aspect. (2006) <http://jnw.name/papers/2006wi-kzpres.pdf> (дата смотра: 01.06.2016)
7. Altenbek G. and WANG Xiao-long. Kazakh segmentation system of inflectional fixes. // In Joint Conference on Chinese Language Processing, CIPS- SIGHAN, – p. 183. 2010.
8. Zafer H.R., Tilki B., Kurt A., Kara M. Two-level description of Kazakh morphology // In: Proceedings of the 1st International Conference on Foreign Language teaching and Applied Linguistics, FLTAL 2011, Sarajevo (May 2011).
9. Kessikbayeva G., Cicekli I. A Rule Based Morphological Analyzer and a Morphological Disambiguator for Kazakh Language. Linguistics and Literature Studies, 4(1), 96. 2016.
10. Барахнин В.Б., Лукпанова Л.Х., Соловьев А.А. Алгоритм построения синтаксических форм с использованием флексивных классов для систем морфологического анализа казахского языка // Вестник Новосибирского государственного университета. Серия: Информационные технологии. – 2014. – Т. 12, № 2. – С. 25-32.
11. Барахнин В.Б., Лукпанова Л.Х., Соловьев А.А. Алгоритм синтеза словоформ казахского языка с использованием флексивных классов // Электронные библиотеки: перспективные методы и технологии, электронные коллекции: тр. 16 Всероссийской конф. (RCDL'2014) Дубна, 13-16 окт. 2014 г. – Дубна: ОИЯИ, 2014. – С. 108-112.
12. Шарипбаев А.А., Бекманова Г.Т., Ергеш Б.Ж., Бурибаева А.К., Карабаев М.Х. Интеллектуальный морфологический анализатор, основанный на семантических сетях // Открытые семантические технологии проектирования интеллектуальных систем (OSTIS-2012): материалы II Международной научно-технической конференции. Минск: БГУИР, 2012. – С. 397-400.
13. Makhambetov O., Makazhanov A., Yessenbayev Zh., Matkarimov B., Sabyrgaliyev I., Sharafudinov A. Assembling the Kazakh Language Corpus. // Proceedings of Conference on Empirical Methods in Natural Language Processing (EMNLP 2013). 2013 – P. 1022.
14. Makhambetov O., Makazhanov A., Yessenbayev Zh., Sabyrgaliyev I., Sharafudinov A. Towards a data-driven morphological analysis of Kazakh language // J. Türkiye Vakfi bilgisayar bilimleri ve mühendisliği dergisi. – Vol. 7, issue 1. – 2014.
15. Makhambetov O., Makazhanov A., Sabyrgaliyev, Yessenbayev Zh. Data-Driven Morphological Analysis and Disambiguation for Kazakh // International Conference on Intelligent Text Processing and Computational Linguistics Springer International Publishing – P. 151-163
16. Койбагаров К.Ч., Мусабаев Р.Р., Калимольдаев М.Н. Разработка лингвистического процессора текстов на казахском языке. / Проблемы информатики. 2014. – № 1. – С. 64-72.
17. Койбагаров К.Ч., Амиргалиев Е.Н., Мусабаев Т.Р. Программная реализация распознавания команд казахской речи на основе марковской модели. // Труды международной азиатской школы-семинара «Проблемы оптимизации сложных систем». 2013.

18. Койбагаров К.Ч., Мусабаев Р.Р. Разработка лексико-морфологического парсера казахского языка // Труды 10-й международной Азиатской школы-семинар "Проблемы минимизации сложных систем". Кыргызская Республика, Иссык-Кульская область, 2014 г.
19. Бекманова Г.Т. Некоторые подходы к проблемам автоматического словаизменения и морфологического анализа в казахском языке // Вестник Восточно-Казахстанского государственного технического университета им. Д. Серикбаева. – Усть-Каменогорск: 2009г. – № 4. – с. 192-197.
20. Жубанов А.Х. Основные принципы формализации содержания казахского языка. – Алматы, 2002. – 250 с.
21. Азарова И.В. Морфологическая разметка текстов на русском языке с использованием формальной грамматики AGFL. Кафедра математической лингвистики НГУ // <http://www.dialog-21.ru/Archive/2003/AzarovaAFGL.htm> (дата просмотра: 01.06.2016)
22. Барахнин В. Б., Федотов А. М. Построение модели фактографического поиска // Вестник НГУ. Серия: Информационные технологии. – 2013. – Том 11, Выпуск № 4. С. 16–27.
23. Chen P.P. The entity-relational model. Toward a unified view of data // ACM TODS. 1976. № 1. Р. 9-36. / Рус. пер. Чен П. П.-Ш. Модель «сущность-связь» – шаг к единому представлению данных // СУБД. 1995. № 3. С.137-158.
24. Хайкин С. Нейронные сети. Полный курс, 2-е изд., испр.: Пер. с англ. – М.: ООО «И. Д. Вильямс», 2006.