

**Федеральное государственное автономное образовательное  
учреждение высшего образования  
«Московский физико-технический институт  
(национальный исследовательский университет)»**

**УТВЕРЖДЕНО**

**Директор физтех-школы  
прикладной математики и  
информатики**

**А.М. Райгородский**

	<b>Рабочая программа дисциплины (модуля)</b>
<b>по дисциплине:</b>	Автоматическая обработка естественного языка
<b>по направлению:</b>	Информатика и вычислительная техника
<b>профиль подготовки:</b>	Прикладная математика и информатика Физтех-школа Прикладной Математики и Информатики кафедра алгоритмов и технологий программирования
<b>курс:</b>	1
<b>квалификация:</b>	магистр

Семестр, формы промежуточной аттестации: 2 (весенний) - Дифференцированный зачет

Аудиторных часов: 60 всего, в том числе:

лекции: 30 час.

семинары: 30 час.

лабораторные занятия: 0 час.

Самостоятельная работа: 30 час.

Всего часов: 90, всего зач. ед.: 2

Количество контрольных работ, заданий: 1

Программу составил: Е.Л. Артемова, канд. техн. наук, доцент

Программа обсуждена на заседании кафедры алгоритмов и технологий программирования 20.02.2025

## Аннотация

Курс «Автоматическая обработка естественного языка» является вводным в проблематику компьютерной лингвистики и построения программных систем для обработки текстов на естественном языке. Изучаются основные методы автоматической обработки текста (АОТ), а также виды необходимых для этого лингвистических ресурсов. Обзорно рассматриваются современные приложения в области АОТ и принципы их построения. Теоретический материал курса, дополняется практическими занятиями по изучению соответствующих интернет-ресурсов и прикладного программного обеспечения, а также домашними заданиями по их применению.

### 1. Цели и задачи

#### Цель дисциплины

- изучение современных алгоритмов интеллектуального анализа и обработки изображений.

#### Задачи дисциплины

- изучение моделей формирования, представления и искажения изображений;
- освоение математического аппарата обработки изображений;
- освоение основных алгоритмов цифровой обработки, восстановления, анализа, классификации и распознавания изображений.

### 2. Перечень формируемых компетенций

Освоение дисциплины направлено на формирование следующих компетенций:

Код и наименование компетенции	Индикаторы достижения компетенции
УК-3 Способен организовывать и руководить работой команды, вырабатывая командную стратегию для достижения поставленной цели	УК-3.1 Организует и координирует работу участников проекта, способствует конструктивному преодолению возникающих разногласий и конфликтов
	УК-3.2 Учитывает в своей социальной и профессиональной деятельности интересы, особенности поведения и мнения (включая критические) людей, с которыми работает/взаимодействует, в том числе посредством корректировки своих действий
	УК-3.3 Способен предвидеть результаты (последствия) как личных, так и коллективных действий
	УК-3.4 Способен планировать командную работу, распределять поручения членам команды, организовывать обсуждение разных идей и мнений
ОПК-2 Имеет представление об актуальных проблемах науки и техники в области информатики и вычислительной техники, способен на научном языке формулировать профессиональные задачи	ОПК-2.1 Имеет представление о современном состоянии исследований в рамках тематической области своей профессиональной деятельности
	ОПК-2.2 Способен оценивать актуальность исследований в области информатики и вычислительной техники и их практическую значимость
	ОПК-2.3 Владеет профессиональной терминологией, используемой в современной научно-технической литературе, обладает навыками устного и письменного изложения результатов научной деятельности в рамках профессиональной коммуникации
	ОПК-3.1 Способен анализировать задачу, планировать пути решения, предлагать и комбинировать способы решения
	ОПК-3.2 Способен разрабатывать и модернизировать программное и аппаратное обеспечение информационных и автоматизированных систем
	ОПК-3.3 Способен использовать исследовательские методы при решении новых задач, применяя знания из различных областей науки (техники)

ОПК-3 Способен выбирать и (или) разрабатывать подходы к решению типовых и новых задач в области информатики и вычислительной техники, учитывая особенности и ограничения различных методов решения	ОПК-3.4 Владеет аналитическими и вычислительными методами решения, понимает и учитывает на практике границы применимости получаемых решений
	ОПК-3.5 Способен адаптировать зарубежные комплексы обработки информации и автоматизированного проектирования к нуждам отечественных предприятий
	ОПК-3.6 Способен самостоятельно приобретать, развивать и применять математические, естественнонаучные, социально-экономические и профессиональные знания для решения нестандартных задач, в том числе в новой или незнакомой среде и в междисциплинарном контексте
	ОПК-3.7 Способен разрабатывать оригинальные алгоритмы и программные средства, в том числе с использованием современных интеллектуальных технологий, для решения профессиональных задач
ПК-2 Понимает и способен применить в научно-исследовательской и прикладной деятельности основные законы естествознания, современный математический аппарат и алгоритмы, современные информационно-коммуникационные технологии	ПК-2.1 Знает основы научно-исследовательской деятельности в области информационных технологий, владеет знанием основ философии и методологии науки; знанием методов научных исследований и навыками их проведения
	ПК-2.2 Умеет применять полученные знания в области фундаментальных научных основ теории информации и решать стандартные задачи в собственной научно-исследовательской деятельности
	ПК-2.3 Имеет практический опыт научно-исследовательской деятельности в области информационно-коммуникационных технологий
	ПК-2.4 Владеет методами и алгоритмами решения задач цифровой обработки сигналов, использования сети Интернет, аннотирования, реферирования, библиографического поиска, опыт работы с научными источниками

### 3. Перечень планируемых результатов обучения по дисциплине (модулю)

В результате освоения дисциплины обучающиеся должны

знать:

- постановку задач морфологического, синтаксического анализа;
- методы решения этих задач.

уметь:

- формулировать задачи классификации текстов, предложений или их элементов для выделения структурированной информации;
- реализовывать подходящий алгоритм классификации текстов;
- решать задачи выделения ключевых слов и определения тональности.

владеть:

- основными программными системами для выделения скрытых тем и снижения размерности векторных моделей.

### 4. Содержание дисциплины (модуля), структурированное по темам (разделам) с указанием отведенного на них количества академических часов и видов учебных занятий

#### 4.1. Разделы дисциплины (модуля) и трудоемкости по видам учебных занятий

№	Тема (раздел) дисциплины	Трудоемкость по видам учебных занятий, включая самостоятельную работу, час.			
		Лекции	Семинары	Лабораторные работы	Самост.

		лекции	семинары	лаборат. работы	работа
1	Вводное занятие	2	2		2
2	Основы машинного обучения и классификация текстов	2	2		2
3	Частотный анализ текстов	2	2		2
4	Морфологический анализ и разрешение неоднозначности	2	2		2
5	Recurrent Neural Networks	2	2		2
6	Выделение ключевых слов и словосочетаний	2	2		2
7	Векторная модель текста и слова, методы снижения размерности	2	2		2
8	Классификация текстов	2	2		2
9	Языковые модели	2	2		2
10	Консультация по проектам	2	2		2
11	Суммаризация текстов, вопросно-ответные системы	2	2		2
12	Исправление опечаток	2	2		2
13	Обработка речи, речевые технологии	2	2		2
14	Информационный поиск	2	2		2
15	Мультимодальная обработка текстов	2	2		2
Итого часов		30	30		30
Подготовка к экзамену		0 час.			
Общая трудоёмкость		90 час., 2 зач.ед.			

#### 4.2. Содержание дисциплины (модуля), структурированное по темам (разделам)

##### Семестр: 2 (Весенний)

###### 1. Вводное занятие

Программирование на Python, NumPy и Jupyter  
NLTK

Основные задачи обработки и анализа текстов. Актуальность обработки и анализа текстов. Краткий исторический экскурс по обработке и анализу текстов. Обзор существующих систем обработки и анализа текстов. Классификация систем обработки и анализа текстов.

###### 2. Основы машинного обучения и классификация текстов

Описание принципов обработки естественного языка и методов работы больших языковых моделей, а также основы когнитивной, корпусной и компьютерной лингвистики  
Форматы данных, способы хранения, принципы работы интернета. Краулинг. Regexp. Unicode.

###### 3. Частотный анализ текстов

Модель мешка слов. Закон Ципфа. Закон Хипса. Векторное представление текстов. Релевантность в векторной модели. Расширения модели мешка слов. Реализация модели мешка слов в библиотеках Gensim и NLTK.

###### 4. Морфологический анализ и разрешение неоднозначности

Задача морфологического анализа. Типы языков. Алгоритмы морфологического разбора. Морфологическая разметка. Омонимия и неоднозначность. Алгоритм разрешения омонимии. Скрытые Марковские модели. Декодирование в скрытых Марковских моделях.

## 5. Recurrent Neural Networks

Задача синтаксического разбора предложений. Модель составляющих. Вероятностные контекстно-свободные грамматики. Модель зависимостей. Универсальные зависимости. Парсинг зависимостей. Архитектура SyntaxNet.

## 6. Выделение ключевых слов и словосочетаний

Лексический анализ. Словари и тезаурусы. Поиск синонимов. Частотные методы выделения ключевых слов и словосочетаний. Метрики совместной встречаемости. Выделение ключевых словосочетаний по морфологическим шаблонам. Выделение ключевых словосочетаний по синтаксическим шаблонам. Алгоритмы RAKE и TextRank. Программные средства для выделения ключевых слов: NLTK, Томита-парсер.

## 7. Векторная модель текста и слова, методы снижения размерности

Векторная модель документа, векторная модель слова. Поиск похожих текстов. Косинусная мера близости. Методы снижения размерности в векторной модели документа: сингулярное разложение, латентный семантический анализ. Связь с моделями скрытых тем. Латентное размещение Дирихле (LDA). Параметры модели. Выбор числа скрытых тем. Расширения модели LDA. Дистрибутивная семантика, векторная модель слова. Построение матрицы PPMI. Поиск близких слов по значению. Снижение размерности и факторизация матрицы PPMI. Эмбединги: word2vec, GloVe, AdaGram. Обучение моделей word2vec. Отрицательное сэмплирование.

## 8. Классификация текстов

Задачи классификации текстов и предложений по теме, тональности и жанру. Метод наивного Байеса, метод максимальной энтропии. Сверточные нейронные сети. Архитектура FastText.

## 9. Языковые модели

Счетные языковые модели. Проблема нулевых вероятностей. Преобразование Лапласа, преобразование Гуд-Тьюринга. Вероятностные нейронные языковые модели. Генерация текстов. Рекуррентные нейронные сети.

## 10. Консультация по проектам

BiLSTM + CRF for Named Entity Recognition (NER)

## 11. Суммаризация текстов, вопросно-ответные системы

Абстрактивная и генеративная суммаризация текстов. Алгоритм TextRank. Вопросно-ответные системы. Архитектура энкодера-декодера для вопросно-ответных систем и чат-ботов.

## 12. Исправление опечаток

Модель зашумленного канала. Исправление опечаток по правилам. Редакционное расстояние.

## 13. Обработка речи, речевые технологии

Распознавание речи. Генерация речи.

#### 14. Информационный поиск

Понятие релевантности. Использование векторной модели в задаче поиска. Косинусная мера релевантности. Использование языковой модели в задаче поиска. Обучение ранжированию. A|B - тестирование.

#### 15. Мультимодальная обработка текстов

Связь обработки текстов с обработкой изображений. Генерация изображения по тексту. Поиск изображения по описанию.

### **5. Описание материально-технической базы, необходимой для осуществления образовательного процесса по дисциплине (модулю)**

Учебная аудитория, оснащенная мультимедийным оборудованием (проектор или плазменная панель), доской.

### **6. Перечень рекомендуемой литературы**

#### Основная литература

1. Python для сложных задач: наука о данных и машинное обучение [Текст] / Дж. Вандер Плас ; [пер. с англ. И. Пальти], СПб., Питер, 2018

Литература кафедры:

Плас Дж. Python для сложных задач. Наука о данных и машинное обучение. СПб.: Питер, 2017. 576 с.

Николаев И.С., Митренина О.В., Ландо Т.М. Прикладная и компьютерная лингвистика. М.: URSS, 2017. 320 с.

Маннинг К., Рагхаван П., Шютце Х. Введение в информационный поиск. М.: Вильямс, 2014. 528 с.

#### Дополнительная литература

### **7. Перечень ресурсов информационно-телекоммуникационной сети "Интернет", необходимых для освоения дисциплины (модуля)**

Не используются

### **8. Перечень информационных технологий, используемых при осуществлении образовательного процесса по дисциплине (модулю), включая перечень необходимого программного обеспечения и информационных справочных систем (при необходимости)**

На занятиях используются мультимедийные технологии, включая демонстрацию презентаций.

### **9. Методические указания для обучающихся по освоению дисциплины (модуля)**

Методические рекомендации позволяют студенту оптимальным образом организовать процесс обучения. В рабочей программе приведено примерное распределение часов аудиторной и внеаудиторной нагрузки по различным темам данной дисциплины.

полученные знания для решения различных задач.

Успешное освоение курса требует напряжённой самостоятельной работы студента. В программе курса приведено минимально необходимое время для работы студента над темой. Самостоятельная работа включает в себя:

- чтение и конспектирование рекомендованной литературы,
- проработку учебного материала (учебной и научной литературе), подготовку ответов на вопросы, предназначенных для самостоятельного изучения, доказательство отдельных утверждений, свойств;
- подготовку к дифференцированному зачету:

Руководство и контроль за самостоятельной работой студента осуществляется в форме индивидуальных консультаций.

Показателем владения материалом служит умение решать задачи. Для формирования умения применять теоретические знания на практике студенту необходимо решать, как можно больше задач. При решении задач каждое действие необходимо аргументировать, ссылаясь на известные теоретические сведения. При подготовке к практическим занятиям необходимо повторять ранее изученные основные определения, формулировки теорем. Важно добиться понимания изучаемого материала, а не механического его запоминания. При затруднении изучения отдельных тем, вопросов, следует обращаться за консультациями к преподавателю, ведущему практические занятия.

**ОЦЕНОЧНЫЕ МАТЕРИАЛЫ ПО ДИСЦИПЛИНЕ (МОДУЛЮ)**

<b>по направлению:</b>	Информатика и вычислительная техника
<b>профиль подготовки:</b>	Прикладная математика и информатика Физтех-школа Прикладной Математики и Информатики кафедра алгоритмов и технологий программирования
<b>курс:</b>	<u>1</u>
<b>квалификация:</b>	магистр

Семестр, формы промежуточной аттестации: 2 (весенний) - Дифференцированный зачет

**Разработчик:** Е.Л. Артемова, канд. техн. наук, доцент



## 1. Компетенции, формируемые в процессе изучения дисциплины

Код и наименование компетенции	Индикаторы достижения компетенции
УК-3 Способен организовывать и руководить работой команды, вырабатывая командную стратегию для достижения поставленной цели	УК-3.1 Организует и координирует работу участников проекта, способствует конструктивному преодолению возникающих разногласий и конфликтов
	УК-3.2 Учитывает в своей социальной и профессиональной деятельности интересы, особенности поведения и мнения (включая критические) людей, с которыми работает/взаимодействует, в том числе посредством корректировки своих действий
	УК-3.3 Способен предвидеть результаты (последствия) как личных, так и коллективных действий
	УК-3.4 Способен планировать командную работу, распределять поручения членам команды, организовывать обсуждение разных идей и мнений
ОПК-2 Имеет представление об актуальных проблемах науки и техники в области информатики и вычислительной техники, способен на научном языке формулировать профессиональные задачи	ОПК-2.1 Имеет представление о современном состоянии исследований в рамках тематической области своей профессиональной деятельности
	ОПК-2.2 Способен оценивать актуальность исследований в области информатики и вычислительной техники и их практическую значимость
	ОПК-2.3 Владеет профессиональной терминологией, используемой в современной научно-технической литературе, обладает навыками устного и письменного изложения результатов научной деятельности в рамках профессиональной коммуникации
ОПК-3 Способен выбирать и (или) разрабатывать подходы к решению типовых и новых задач в области информатики и вычислительной техники, учитывая особенности и ограничения различных методов решения	ОПК-3.1 Способен анализировать задачу, планировать пути решения, предлагать и комбинировать способы решения
	ОПК-3.2 Способен разрабатывать и модернизировать программное и аппаратное обеспечение информационных и автоматизированных систем
	ОПК-3.3 Способен использовать исследовательские методы при решении новых задач, применяя знания из различных областей науки (техники)
	ОПК-3.4 Владеет аналитическими и вычислительными методами решения, понимает и учитывает на практике границы применимости получаемых решений
	ОПК-3.5 Способен адаптировать зарубежные комплексы обработки информации и автоматизированного проектирования к нуждам отечественных предприятий
	ОПК-3.6 Способен самостоятельно приобретать, развивать и применять математические, естественнонаучные, социально-экономические и профессиональные знания для решения нестандартных задач, в том числе в новой или незнакомой среде и в междисциплинарном контексте
	ОПК-3.7 Способен разрабатывать оригинальные алгоритмы и программные средства, в том числе с использованием современных интеллектуальных технологий, для решения профессиональных задач
	ПК-2.1 Знает основы научно-исследовательской деятельности в области информационных технологий, владеет знанием основ философии и методологии науки; знанием методов научных исследований и навыками их проведения

ПК-2 Понимает и способен применить в научно-исследовательской и прикладной деятельности основные законы естествознания, современный математический аппарат и алгоритмы, современные информационно-коммуникационные технологии	ПК-2.2 Умеет применять полученные знания в области фундаментальных научных основ теории информации и решать стандартные задачи в собственной научно-исследовательской деятельности
	ПК-2.3 Имеет практический опыт научно-исследовательской деятельности в области информационно-коммуникационных технологий
	ПК-2.4 Владеет методами и алгоритмами решения задач цифровой обработки сигналов, использования сети Интернет, аннотирования, реферирования, библиографического поиска, опыт работы с научными источниками

## 2. Показатели оценивания компетенций

В результате изучения дисциплины «Автоматическая обработка естественного языка» обучающийся должен:

### знать:

- постановку задач морфологического, синтаксического анализа;
- методы решения этих задач.

### уметь:

- формулировать задачи классификации текстов, предложений или их элементов для выделения структурированной информации;
- реализовывать подходящий алгоритм классификации текстов;
- решать задачи выделения ключевых слов и определения тональности.

### владеть:

- основными программными системами для выделения скрытых тем и снижения размерности векторных моделей.

## 3. Перечень типовых (примерных) вопросов, заданий, тем для подготовки к текущему контролю

1. Методы распознавания именованных сущностей в текстах
2. Автоматическое выявление терминов и терминологических связей в тексте
3. Исследование современных языковых моделей для задач семантической классификации
4. Исследование методов создания вопросно-ответных систем: IR based QA vs KB based QA
5. Что такое токенизация в обработке естественного языка и какие методы токенизации существуют?
6. Объясните, что такое стемминг и лемматизация. В чем их различия?
7. Что такое частеречная разметка (POS-тегирование) и какие задачи она решает?
8. Что такое морфологический анализ текста и какие инструменты используются для его выполнения?
9. Объясните, что такое синтаксический анализ текста. Какие методы синтаксического анализа существуют?
10. Что представляет собой модель Word2Vec и какие задачи она решает в обработке естественного языка?
11. Что такое машинный перевод и какие методы используются для его реализации?
12. Объясните, что такое анализ тональности текста и какие подходы применяются для определения тональности.
13. В чем заключается задача исследования информационного извлечения из текста (Information Extraction)?
14. Какие методы машинного обучения применяются в задачах обработки естественного языка?

## 4. Перечень типовых (примерных) вопросов и тем для проведения промежуточной аттестации обучающихся

1. Приведите примеры использования технологий обработки текстов, с которыми вы сталкиваетесь в повседневной жизни
2. Напишите регулярное выражение для извлечения дат
3. Сформулируйте законы Хипса и Ципфа
4. Дайте определение скрытой Марковской цепи и покажите, как она может быть использована для разрешения морфологической омонимии
5. Перечислите несколько коэффициентов считаемости биграмм
6. Почему возникает необходимость в снижении размерности в векторной модели
7. Как устроен алгоритм обучения word2vec?
8. Что такое латентное размещение Дирихле?
9. Методы классификации текстов
10. Как формулируется задача классификации последовательности?
11. Как сгенерировать текст с помощью счетной языковой модели?
12. Как сгенерировать текст с помощью нейронной вероятностной языковой модели?
13. Как формулируется задача заполнения слотов для чат-ботов?
14. Связь модели зашумленного канала и языковой модели
15. Назовите несколько мер релевантности в задаче поиска

Пример билета:

Билет 1:

1. Приведите примеры использования технологий обработки текстов, с которыми вы сталкиваетесь в повседневной жизни.
2. Назовите несколько мер релевантности в задаче поиска

#### Критерии оценивания

оценка «отлично (10)» выставляется студенту, показавшему всесторонние, систематизированные, глубокие знания учебной программы дисциплины и умение уверенно применять их на практике при решении конкретных задач, свободное и правильное обоснование принятых решений;

- оценка «отлично (9)» выставляется студенту, показавшему всесторонние, систематизированные, глубокие знания учебной программы дисциплины и умение применять их на практике при решении конкретных задач, свободное и правильное обоснование принятых решений;

- оценка «отлично (8)» выставляется студенту, показавшему всесторонние систематизированные, глубокие знания учебной программы дисциплины и умение применять их на практике при решении конкретных задач, и правильное обоснование принятых решений;

- оценка «хорошо (7)» выставляется студенту, если он твердо знает материал, грамотно и по существу излагает его, умеет применять полученные знания на практике, но допускает в ответе или в решении задач некоторые неточности;

- оценка «хорошо (6)» выставляется студенту, если он знает материал, грамотно и по существу излагает его, умеет применять полученные знания на практике, но допускает в ответе или в решении задач некоторые неточности;

- оценка «хорошо (5)» выставляется студенту, если он знает материал, и по существу излагает его, умеет применять полученные знания на практике, но допускает в ответе или в решении задач некоторые неточности;

- оценка «удовлетворительно (4)» выставляется студенту, показавшему фрагментарный, разрозненный характер знаний, недостаточно правильные формулировки базовых понятий, нарушения логической последовательности в изложении программного материала, но при этом он владеет основными разделами учебной программы, необходимыми для дальнейшего обучения и может применять полученные знания по образцу в стандартной ситуации;

- оценка «удовлетворительно (3)» выставляется студенту, показавшему фрагментарный, разрозненный характер знаний, недостаточно правильные формулировки базовых понятий, нарушения логической последовательности в изложении программного материала, но при этом он владеет фрагментарно основными разделами учебной программы, необходимыми для дальнейшего обучения и может применять полученные знания по образцу в стандартной ситуации;

- оценка «неудовлетворительно (2)» выставляется студенту, который не знает большей части основного содержания учебной программы дисциплины, допускает грубые ошибки в формулировках основных понятий дисциплины и не умеет использовать полученные знания при решении типовых практических задач;
- оценка «неудовлетворительно (1)» выставляется студенту, который не знает формулировок основных понятий дисциплины.

## **5. Методические материалы, определяющие процедуры оценивания знаний, умений, навыков и (или) опыта деятельности**

Дифференцированный зачет проводится в устной форме.

При проведении экзамена обучающемуся предоставляется 30 минут на подготовку.

Результатирующая оценка рассчитывается по формуле:

$$O_{\text{итоговая}} = 0.8 * O_{\text{накопл}} + 0.2 * O_{\text{экз}}$$

Накопленная оценка рассчитывается как среднее значение оценок за все выданные домашние задания и самостоятельные работы. В конце семестра разрешается переписать все самостоятельные работы, пропущенные по уважительной причине.

Накопленная и итоговая оценки округляются арифметически.