
УТВЕРЖДЕНА

Решением Ученого совета
АНО ВО «Центральный университет»
«25» май 2026 г.
Протокол №2

**Рабочая программа дисциплины (модуля)
«Обработка естественного языка»**

Направление подготовки: 02.03.01 Математика и компьютерные науки

Направленность (профиль) подготовки: Математика и компьютерные науки

Квалификация (степень) выпускника: бакалавр

Форма обучения: очная

Срок освоения программы: 4 года

Год набора: 2026

**Москва
2026**

Содержание

1. Краткая характеристика дисциплины (модуля)	3
2. Перечень планируемых результатов обучения	5
3. Тематический план	7
4. Содержание дисциплины (модуля)	7
5. Учебно-методическое обеспечение	8
6. Материально-техническое обеспечение	8
7. Методические и оценочные материалы	10

1. Краткая характеристика дисциплины (модуля)

Рабочая программа дисциплины (модуля) «Обработка естественного языка» составлена в соответствии с федеральным государственным образовательным стандартом высшего образования – бакалавриат по направлению 02.03.01 «Математика и компьютерные науки», профиль «Математика и компьютерные науки», утвержденный приказом Министерства науки и высшего образования Российской Федерации № 807 от 23.08.2017 года.

Изучение дисциплины (модуля) «Обработка естественного языка» позволяет эффективно решать задачи автоматизации взаимодействия между человеком и машиной в реальных проектах. Обработка естественного языка является ключевой технологией в разработке интеллектуальных систем: чат-ботов, голосовых помощников, поисковых систем и аналитических платформ.

Место дисциплины (модуля) в структуре образовательной программы

Настоящая дисциплина (модуль) включена в учебный план по программе подготовки бакалавриата по направлению 02.03.01 «Математика и компьютерные науки», профиль «Математика и компьютерные науки» и входит в часть Блока 1, формируемую участниками образовательных отношений.

Дисциплина (модуль) изучается на 3 или 4 курсе в 5, 6, 7 или 8 семестре на выбор, доступна для прохождения при условии успешного завершения дисциплины (модуля) «Глубокое обучение».

Цель изучения дисциплины (модуля): формирование систематических знаний, практических умений и навыков в области анализа, обработки и генерации естественного языка с использованием современных методов машинного обучения и нейросетевых архитектур для решения прикладных задач в области искусственного интеллекта.

Задачи изучения дисциплины (модуля):

— формирование знаний принципов представления и предобработки текстовой информации в задачах обработки естественного языка;

— формирование знаний архитектур ключевых моделей обработки текста, включая RNN, LSTM, Transformer и современные языковые модели (BERT, GPT и др.);

— формирование знаний методов решения стандартных задач NLP: классификация текста, извлечение сущностей, машинный перевод, суммаризация, вопросно-ответные системы;

— формирование умений и навыков обучения, настройки и оценки качества моделей обработки естественного языка с использованием современных библиотек и фреймворков;

— формирование умений интегрировать языковые модели в сложные пайплайны и многомодальные системы, включая взаимодействие с визуальной информацией.

В результате освоения дисциплины (модуля) обучающийся должен:

знать:

— основные задачи области NLP и типы текстовых данных, включая однок доку mentные и многодокументные задачи;

— принципы токенизации, векторных представлений текста и языкового моделирования;

— архитектуру Трансформера, механизм внимания и различия между энкодерными, декодерными и encoder-decoder моделями;

— подходы к использованию промптинга, обучения с учителем и адаптации моделей под домен;

— принципы построения систем с дополненной генерацией (RAG), метрики качества и основные риски NLP-систем.

уметь:

- формулировать NLP-задачу, выбирать подходящий бейзлайн и корректные метрики оценки;
- строить и оценивать системы текстовой классификации и семантического поиска на основе эмбедингов;
- извлекать структурированную информацию из текстов по заданной схеме с использованием современных моделей;
- дообучать энкодерные модели с учителем для решения прикладных задач;
- проектировать пайплайн с дополненной генерацией, анализировать ошибки и обосновывать выбор архитектуры.

владеть:

- стеком Python и библиотеками: pandas, scikit-learn, Hugging Face Transformers/Datasets, sentence-transformers, PyTorch;
- методами построения TF-IDF и эмбединговых бейзлайнов для поиска и классификации;
- практиками воспроизводимых экспериментов и автопроверяемых систем оценивания;
- техниками структурированного извлечения данных и проектирования прототипов RAG-систем;
- навыками анализа компромиссов между качеством, латентностью, стоимостью и безопасностью NLP-решений.

2. Перечень планируемых результатов обучения

Компетенции, формируемые в результате освоения дисциплины (модуля) при проведении учебных занятий в форме контактной работы обучающихся с педагогическими работниками Университета и в форме самостоятельной работы обучающихся:

Компетенция	Содержание компетенции	Индикатор компетенции	Перечень планируемых результатов обучения по дисциплине (модулю)
УК-1.	Способен осуществлять поиск, критический анализ и синтез информации, применять системный подход для решения поставленных задач	УК-1.1.	Знает методы поиска и анализа информации в области разработки, основные принципы критической оценки источников информации и их релевантности.
		УК-1.2.	Умеет критически оценивать источники информации и синтезировать данные из различных источников для решения задач, применять системный подход к анализу и решению комплексных проблем
		УК-1.3.	Имеет практический опыт работы с современными инструментами и технологиями для обработки информации, формулировании и структурировании задач на основе полученной информации
УК-2.	Способен определять круг задач в рамках поставленной цели и выбирать оптимальные способы их решения, исходя из действующих правовых норм, имеющихся ресурсов и ограничений	УК-2.1.	Знает действующие правовые нормы, регулирующие деятельность в области решения задач, основные методы и подходы к определению круга задач
		УК-2.2.	Умеет определять круг задач в рамках поставленной цели, выбирать оптимальные способы решения задач, учитывая имеющиеся ресурсы и ограничения
		УК-2.3.	Имеет практический опыт применения знаний о правовых нормах и ресурсах в реальных ситуациях, разработки и реализации решений в соответствии с установленными ограничениями
ОПК-1.	Способен находить, формулировать и решать актуальные и значимые проблемы прикладной и компьютерной математики	ОПК-1.1.	Знает основные методы и подходы к решению задач прикладной и компьютерной математики, включая алгоритмы, математическое моделирование и теорию оптимизации, а также современные инструменты и технологии, используемые в этой области
		ОПК-1.2.	Умеет анализировать и формулировать математические задачи, применять

			соответствующие методы и алгоритмы для их решения, а также интерпретировать и представлять результаты в понятной и доступной форме
		ОПК-1.3.	Имеет практический опыт работы над проектами или исследованиями в области прикладной и компьютерной математики, включая участие в конкурсах, олимпиадах или научных публикациях, где были решены актуальные и значимые задачи
ПК-1.	Способен формулировать задачи с математической точностью, обосновывать утверждения строго и анализировать полученные результаты в области математики и компьютерных наук	ПК-1.1.	Знает методы и подходы к формулированию задач, а также основные принципы математического доказательства и анализа результатов.
		ПК-1.2.	Умеет корректно ставить и формулировать математические задачи, применять строгие методы доказательства и анализировать полученные результаты.
		ПК-1.3.	Имеет опыт работы с задачами в области математики и компьютерных наук, включая применение математических методов для решения практических задач
ПК-2.	Способен решать типовые задачи профессиональной деятельности в области разработки, опираясь на информационную и библиографическую культуру, используя информационно-коммуникационные технологии и учитывая основные требования информационной безопасности	ПК-2.1.	Знает основы информационной и библиографической культуры, а также принципы информационной безопасности и применения информационно-коммуникационных технологий в профессиональной деятельности
		ПК-2.2.	Умеет эффективно использовать информационно-коммуникационные технологии для решения стандартных задач профессиональной деятельности, учитывая требования информационной безопасности
		ПК-2.3.	Имеет опыт работы с информационными ресурсами и технологиями в области разработки, включая соблюдение норм информационной безопасности

3. Тематический план

№п/ п	Наименование раздела дисциплины (модуля)	Трудоемкость, академические часы				ТКУ (текущий контроль успеваемости)
		Очная форма				
		Аудиторная работа		Контроль	Самостояте льная работа	
		Лекции	Семинары (практические занятия)			
1	Основы NLP	10	10		40	Домашние задания, Тесты
2	Трансформеры и LLM	8	8	2	34	Домашние задания, Тесты
3	Прикладной NLP	12	12	2	48	Домашние задания, Тесты
	Экзамен			4		
Итого:		30	30	8	122	
Объем дисциплины (модуля) (в ак. ч.)		190				
Объем дисциплины (модуля) (в зач. ед.)		5				

4. Содержание дисциплины (модуля)

№п/п	Наименование раздела дисциплины (модуля)	Содержание дисциплины (модуля) по темам
1	Основы NLP	Введение в область NLP. Основы обработки текста. Текстовые представления и семантическая близость. Извлечение структурированной информации из текста. Нейросетевые подходы в области NLP
2	Трансформеры и LLM	Архитектура трансформера. Трансформеры в дискриминативных и генеративных задачах. Адаптация и пост-обучение больших языковых моделей
3	Прикладной NLP	Поиск и ранжирование. Основы методов дополненной генерации (RAG). Оценка качества в области NLP. Оптимизация больших языковых моделях NLP-системы.

5. Учебно-методическое обеспечение

Университет располагает полным набором лицензионного и свободно распространяемого программного обеспечения, включая продукты отечественного производства.

Каждый студент в течение всего периода обучения получает индивидуальный неограниченный доступ к электронно-библиотечной системе и электронной информационно-образовательной среде университета. Эти системы предоставляют возможность доступа к ресурсам из любой точки, где есть подключение к сети Интернет, как на территории университета, так и за его пределами.

Студентам обеспечен удаленный доступ к современным профессиональным базам данных и информационным справочным системам.

Основная литература:

1. Бессмертный, И. А. Интеллектуальные системы : учебник и практикум для среднего профессионального образования / И. А. Бессмертный, А. Б. Нугуманова, А. В. Платонов. — 2-е изд. — Москва : Издательство Юрайт, 2026. — 250 с. — (Профессиональное образование). — ISBN 978-5-534-20730-9. — Текст : электронный // Образовательная платформа Юрайт [сайт]. — URL: <https://urait.ru/bcode/586775>.

2. Кревецкий, А. В. Основы технологий искусственного интеллекта : учебное пособие / А. В. Кревецкий, Н. И. Роженцова, Ю. А. Ипатов ; под общ. ред. А. В. Кревцового. - Йошкар-Ола : Поволжский государственный технологический университет, 2023. - 272 с. - ISBN 978-5-8158-2358-7. - Текст : электронный. - URL: <https://znanium.ru/catalog/product/2133953>.

Дополнительная литература:

1. Платонов, А. В. Машинное обучение : учебник для вузов / А. В. Платонов. — 2-е изд. — Москва : Издательство Юрайт, 2026. — 78 с. — (Высшее образование). — ISBN 978-5-534-22200-5. — Текст : электронный // Образовательная платформа Юрайт [сайт]. — URL: <https://urait.ru/bcode/600893>.

2. Гасанов, Э. Э. Интеллектуальные системы. Теория хранения и поиска информации : учебник для вузов / Э. Э. Гасанов, В. Б. Кудрявцев. — 2-е изд., испр. и доп. — Москва : Издательство Юрайт, 2026. — 271 с. — (Высшее образование). — ISBN 978-5-534-08684-3. — Текст : электронный // Образовательная платформа Юрайт [сайт]. — URL: <https://urait.ru/bcode/584574>.

6. Материально-техническое обеспечение

Университет располагает материально-технической базой, соответствующей действующим противопожарным правилам и нормам и обеспечивающей проведение всех видов дисциплинарной и междисциплинарной подготовки, практической и научно-исследовательской работ обучающихся, предусмотренных учебным планом.

Помещения, которые представляют собой учебные аудитории для проведения занятий лекционного типа, занятий семинарского (практического) типа, групповых и индивидуальных консультаций, текущего контроля и промежуточной аттестации, а также помещения для самостоятельной работы и помещения для хранения и профилактического обслуживания учебного оборудования. Помещения укомплектованы специализированной мебелью и техническими средствами обучения, служащими для представления учебной информации большой аудитории.

Изучение дисциплины (модуля) обеспечивается в учебных аудиториях, оснащенных:

- столами и стульями;
- компьютерной техникой;

- механическими калькуляторами;
- специализированным оборудованием, включая демонстрационное оборудование.

Помещения для самостоятельной работы обучающихся, в том числе приспособленные для использования инвалидами и лицами с ограниченными возможностями здоровья, оснащены компьютерной техникой с возможностью подключения к сети «Интернет» и обеспечением доступа в электронную информационно-образовательную среду Университета.

Обучающимся предоставляется доступ (в том числе удаленный) к ресурсам информационно-телекоммуникационной сети «Интернет», электронным ресурсам (в том числе электронным библиотечным системам, современным профессиональным базам данных и информационным справочным системам):

№	Наименование портала (издания, курса, документа)	Ссылка
1.	Научная электронная библиотека elibrary.ru библиотека	https://elibrary.ru/defaultx.asp
2.	База данных для IT-специалистов	https://habr.com
3.	База данных ScienceDirect	https://www.sciencedirect.com
4.	Официальный сайт Министерства науки и высшего образования Российской Федерации	https://minobrnauki.gov.ru/
5.	Федеральный портал «Российское образование»	https://www.edu.ru/
6.	Информационная система "Единое окно доступа к образовательным ресурсам"	http://window.edu.ru/
7.	Единая коллекция цифровых образовательных ресурсов	http://school-collection.edu.ru/
8.	Федеральный центр информационно - образовательных ресурсов	http://fcior.edu.ru/

Перечень информационных технологий, используемых при осуществлении образовательного процесса по дисциплине (модулю), в том числе комплект лицензионного программного обеспечения, современные профессиональные базы данных и информационные справочные системы:

Наименование ПО	Производство	Лицензионное / свободно распространяемое
Операционные системы:		
Microsoft Imagine (Windows Client, Server)	зарубежное	лицензионное
Браузеры:		
Яндекс.Браузер	отечественное	свободно распространяемое
Google Chrome	зарубежное	свободно распространяемое
Офисные приложения:		
Microsoft Imagine (Visio, OneNote)	зарубежное	лицензионное
TeXstudio	зарубежное	свободно распространяемое
Adobe Acrobat Reader	зарубежное	свободно распространяемое
Программное обеспечение для планирования и учета времени:		
Toggle app	зарубежное	свободно распространяемое
Системы управления проектами:		
Microsoft Imagine (Project)	зарубежное	лицензионное
Системы управления базами данных:		
Microsoft Imagine (SQL Server)	зарубежное	лицензионное
Системы резервного копирования (backup):		
Acronis Backup Advanced for HyperV	зарубежное	лицензионное
Справочно-правовые системы:		

КонсультантПлюс: справочно-правовая система	отечественное	лицензионное
Средства антивирусной защиты:		
Kaspersky Endpoint Security для бизнеса Стандартный Russian Edition	отечественное	лицензионное
Среды разработки:		
Visual Studio Code	зарубежное	свободно распространяемое
Bash (Unix shell)	зарубежное	свободно распространяемое
Anaconda	зарубежное	свободно распространяемое
Robotic Operating System	зарубежное	свободно распространяемое
CopelliaSim	зарубежное	свободно распространяемое
Google Colaboratory	зарубежное	свободно распространяемое
Пакеты программных средств и библиотек:		
AutoPsy	зарубежное	свободно распространяемое
Interactive Disassembler (IDA)	зарубежное	свободно распространяемое
Системы управления библиографической информацией:		
Zotero	зарубежное	свободно распространяемое
Сервисы и службы:		
Bind	зарубежное	свободно распространяемое
Docker	зарубежное	свободно распространяемое

7. Методические и оценочные материалы

Методические указания для обучающихся по освоению дисциплины (модуля)

В процессе изучения дисциплины (модуля) «Обработка естественного языка» в рамках текущего контроля успеваемости используются такие виды учебной работы, как лекции, семинары и домашние задания, тесты, а также различные виды самостоятельной работы обучающихся по заданию преподавателя, направленные на развитие навыков профессиональной лексики, закрепление практических профессиональных компетенций, поощрение инициатив.

Лекция – систематическое, последовательное, монологическое изложение преподавателем учебного материала, как правило, теоретического характера.

В процессе лекций рекомендуется вести конспект лекций: кратко и схематично фиксировать основные идеи, выводы и обобщения лекции; выделять важные мысли, ключевые слова и термины. Необходимо отметить вопросы или материалы, которые вызывают затруднения, и попытаться найти ответы в рекомендованной литературе. Если разобраться в материале не удастся, следует сформулировать вопрос и задать его преподавателю на консультации или во время семинарского (практического) занятия.

Семинар – это форма учебной деятельности, проводимая в учебном заведении под руководством преподавателя, где студенты активно участвуют в обсуждениях, практических заданиях и других формах взаимодействия.

Для успешной подготовки к семинару рекомендуется заранее ознакомиться с темой занятия и основными материалами, чтобы иметь возможность активно участвовать в обсуждении. Также полезно подготовить вопросы и идеи для обсуждения, что поможет глубже понять материал и продемонстрировать заинтересованность.

Домашнее задание – набор задач по темам недели.

При работе над домашними заданиями важно внимательно ознакомиться с требованиями и сроками выполнения. Рекомендуется разбивать задания на этапы, чтобы избежать перегрузки и лучше усвоить материал. Использовать различные источники информации, включая учебники и онлайн-ресурсы, для более глубокого понимания темы.

Тест – особая форма проверки знаний. Проводится после освоения одной или нескольких тем и свидетельствует о качестве понимания основных понятий изучаемого материала. Тестовые задания составлены к ключевым понятиям, основным разделам, важным терминологическим категориям изучаемой дисциплины (модуля).

Для подготовки к тесту необходимо знать терминологический аппарат дисциплины (модуля), понимать смысл научных категорий и уметь их использовать в профессиональной лексике. Владение понятийным аппаратом, включённым в тестовые задания, позволяет преподавателю быстро проверить уровень понимания студентами важных методологических категорий.

Соревнование – организованное мероприятие, в рамках которого участники соперничают друг с другом для достижения определенной цели, демонстрируя свои навыки, знания или способности в заданной области.

Бонусные баллы – это оценки, которые студенты могут получить за выполнение дополнительных заданий.

Формат бонусных баллов позволяет студентам улучшить общую оценку по дисциплине (модулю) и стимулирует углубленное изучение материала.

Самостоятельная работа – работа студентов, направленная на углубленное изучение отдельных тем и вопросов учебной дисциплины (модуля).

В процессе самостоятельной работы студенты взаимодействуют с рекомендованными материалами при минимальном участии преподавателя. Задачи студента включают работу с конспектами лекций (обработка текста), повторное изучение учебных материалов планов и тезисов ответов, изучение дополнительных тем, выполнение учебно-исследовательских заданий и другое.

Система оценивания результатов обучения по дисциплине (модулю)

Критерии получения уровня и оценивания сформированности компетенций по дисциплине (модулю) «Обработка естественного языка»

Оценивание уровня учебных достижений, обучающихся по дисциплине (модулю), осуществляется в виде текущего контроля успеваемости и промежуточной аттестации.

Промежуточная аттестация по дисциплине (модулю) осуществляется в форме *экзамена*, при этом проводится оценка компетенций, сформированных по дисциплине.

Для оценивания текущего контроля успеваемости и промежуточной аттестации используется десятибалльная шкала оценивания, которая соотносится с традиционной пятибалльной шкалой следующим образом, если иное не указано в силлабусе дисциплины:

Десятибалльная оценка	Пятибалльная оценка	Общая характеристика результата обучения по дисциплине (модулю)
10	Отлично	Студент полностью владеет знаниями, изложенными в рабочей программе, и глубоко осмысляет дисциплину. Он самостоятельно и логически последовательно отвечает на все вопросы, акцентируя внимание на наиболее важном. Умеет анализировать, сравнивать, классифицировать, обобщать, конкретизировать и систематизировать изученный материал, выделяя ключевые моменты и устанавливая причинно-следственные связи. Четко формулирует ответы, уверенно интерпретирует результаты анализов и других исследований, а также решает сложные
9	Отлично	
8	Отлично	

Десятибалльная оценка	Пятибалльная оценка	Общая характеристика результата обучения по дисциплине (модулю)
		задачи. Студент хорошо знаком с методами исследования, необходимыми для практической деятельности, и умеет связывать теоретические аспекты дисциплины (модуля) с практическими задачами.
7	Хорошо	Студент обладает знаниями предмета почти в полном объеме рабочей программы и самостоятельно, логически последовательно и всесторонне отвечает на все вопросы, акцентируя внимание на наиболее значимых моментах. Он умеет анализировать, сравнивать, классифицировать, обобщать, конкретизировать и систематизировать изученный материал, выделяя его ключевые аспекты и устанавливая причинно-следственные связи. Формулирует свои ответы, уверенно интерпретирует результаты анализов и других исследований, а также решает сложные ситуационные задачи. Студент хорошо знаком с методами исследования, необходимыми для практической деятельности, и умеет связывать теоретические аспекты предмета с практическими задачами.
6	Хорошо	
5	Удовлетворительно	Студент обладает базовыми знаниями по дисциплине (модулю), но испытывает трудности при самостоятельных ответах и использует неточные формулировки. В ходе ответов он допускает ошибки, касающиеся сути вопросов. Студент способен решать только самые простые задачи и владеет лишь минимальным набором методов исследования.
4	Удовлетворительно	
3	Не сдан	Студент не овладел обязательным минимумом знаний по предмету и не может ответить на вопросы, даже если преподаватель задает дополнительные наводящие вопросы.
2	Не сдан	
1	Не сдан	

Дисциплина (модуль) «Обработка естественного языка» оценивается следующим образом:

Активность	Вес	Количество	Описание
Домашние задания	40%	5	Набор задач по темам недели
Тест	30%	15	Форма проверки знаний студентов через ответы на вопросы с выбором из нескольких вариантов ответов
Экзамен	30%	1	Письменная или устная работа над заданием, направленным на проверку полученных знаний и навыков по дисциплине (модулю)

В рамках изучения дисциплины (модуля) возможно получение бонусных баллов.

Формула расчёта итоговой оценки по дисциплине (модулю) «Обработка естественного языка»: $0,4 \times \text{среднее за домашние задания} + 0,3 \times \text{среднее за тесты} + 0,3 \times \text{Экзамен}$.

Текущий контроль успеваемости обучающихся по дисциплине (модулю)

Примерные домашние задания

Домашнее задание 1.

Задание 1.

1. Объясните, что такое цифровой текст и опишите основные этапы его предобработки: токенизация, нормализация, удаление стоп-слов.
2. Реализуйте на Python пайплайн предобработки текста для набора коротких отзывов (например, из IMDb или Yelp) с использованием библиотек nltk или spaCy.
3. Проведите анализ: сравните количество токенов до и после предобработки, визуализируйте самые частотные слова.

Задание 2.

1. Опишите, как текст может быть представлен в виде векторов: методы Bag-of-Words, TF-IDF, эмбединги (Word2Vec, GloVe).
2. Реализуйте вычисление сходства между текстами с помощью TF-IDF и косинусной меры. Протестируйте на парах предложений (похожие/разные).
3. Проведите эксперимент: сравните результаты семантического поиска с использованием TF-IDF и предобученных эмбедингов (например, sentence-transformers). Прокомментируйте различия.

Задание 3.

1. Опишите задачу извлечения структурированной информации из текста (например, извлечение имён, дат, организаций).
2. Реализуйте извлечение именованных сущностей (NER) с использованием модели spaCy или transformers на наборе новостных текстов.
3. Оцените точность извлечения вручную на 10 примерах, проанализируйте типичные ошибки.

Домашнее задание 2.

Задание 1.

1. Объясните архитектуру Трансформера: механизм внимания, multi-head attention, позиционные кодировки.
2. Сравните энкодерные (BERT), декодерные (GPT) и encoder-decoder (T5) архитектуры: в каких задачах каждая из них применяется?
3. Визуализируйте веса внимания в предобученной модели (например, BERT) с помощью библиотеки BertViz на примере простого предложения.

Задание 2.

1. Изучите подходы к адаптации больших языковых моделей: fine-tuning, prompt tuning, LoRA.
2. Выберите модель (например, distilbert-base-uncased или bloomz) и дообучите её на задаче классификации текстов (например, SST-2) с использованием Hugging Face Transformers.
3. Сравните качество до и после дообучения, опишите используемый пайплайн и гиперпараметры.

Задание 3.

1. Реализуйте генерацию текста с помощью предобученной LLM (например, gpt2, Llama-3-8b через Hugging Face).
2. Проведите эксперимент с разными стратегиями генерации: greedy, beam search, sampling (с разными temperature, top_k, top_p).

3. Проанализируйте, как параметры влияют на разнообразие и качество генерации.

Домашнее задание 3.

Задание 1.

1. Опишите принцип работы систем семантического поиска: индексация, эмбединги, поиск по векторам.
2. Реализуйте простой поисковый движок на основе эмбедингов (sentence-transformers) для набора документов (например, абстракты научных статей).
3. Оцените качество поиска: проверьте, насколько релевантны топ-3 результата для нескольких запросов.

Задание 2.

1. Объясните концепцию дополненной генерации (RAG): как внешние данные используются для улучшения генерации.
2. Реализуйте простую RAG-систему: используйте векторный поиск для извлечения контекста и LLM (например, gpt-3.5-turbo или Llama-3) для генерации ответа.
3. Протестируйте на вопросах, требующих знаний вне модели (например, "Какие меры были приняты на G7 в 2023 году?"). Сравните ответы с и без контекста.

Задание 3.

1. Опишите ключевые метрики оценки NLP-моделей: точность, F1, BLEU, ROUGE, perplexity, а также современные подходы (LLM-as-a-Judge).
2. Выберите задачу (например, суммаризация) и оцените два варианта выхода модели по нескольким метрикам.
3. Проведите анализ: сравните автоматические метрики с субъективной оценкой (по шкале 1–5). Сделайте вывод о надёжности метрик.

Примерные задания для теста

Тест 1.

Вопрос 1.

Что из перечисленного является основной целью токенизации?

- A. Уменьшение размера текста
- B. Преобразование текста в последовательность числовых векторов
- C. Разбиение текста на слова, подслова или символы
- D. Удаление стоп-слов и пунктуации

Ответ: C.

Вопрос 2.

Какой метод представления текста учитывает частоту слова в документе и его редкость в корпусе?

- A. Bag-of-Words
- B. One-Hot Encoding
- C. TF-IDF
- D. Word2Vec

Ответ: C.

Вопрос 3.

Что такое эмбединг слова?

- A. Словарная статья из википедии
- B. Числовой вектор, представляющий семантику слова
- C. Индекс слова в словаре
- D. Частота слова в тексте

Ответ: В.

Вопрос 4.

Какой из следующих подходов позволяет определить, что слова "автомобиль" и "машина" близки по смыслу?

- A. TF-IDF
- B. Эмбединги (например, Word2Vec или Sentence-BERT)
- C. One-Hot Encoding
- D. Подсчёт символов

Ответ: В.

Вопрос 5.

Какая задача заключается в извлечении имен, дат и организаций из текста?

- A. Суммаризация
- B. Классификация текста
- C. Извлечение именованных сущностей (NER)
- D. Машинный перевод

Ответ: С.

Тест 2.

Вопрос 1.

Что является ключевой идеей механизма внимания в архитектуре Трансформера?

- A. Учёт всех слов в последовательности при вычислении представления каждого слова
- B. Использование рекуррентных связей между токенами
- C. Классификация слов по частям речи
- D. Преобразование текста в изображение

Ответ: А.

Вопрос 2.

Какая архитектура используется в моделях типа BERT?

- A. Декодерная (decoder-only)
- B. Энкодерная (encoder-only)
- C. Encoder-decoder
- D. CNN + RNN

Ответ: В.

Вопрос 3.

Какая модель является примером генеративной архитектуры с декодерной структурой?

- A. T5
- B. BERT
- C. RoBERTa
- D. GPT-3

Ответ: D.

Вопрос 4.

Что такое fine-tuning языковой модели?

- A. Генерация текста с использованием промптов
- B. Обучение модели с нуля на новом корпусе
- C. Дообучение предобученной модели на задаче с размеченными данными
- D. Извлечение эмбедингов без обучения

Ответ: С.

Вопрос 5.

Какой метод позволяет адаптировать LLM с меньшим количеством параметров для обновления?

- A. LoRA (Low-Rank Adaptation)
- B. TF-IDF

C. PCA
D. Bag-of-Words
Ответ: А.

Задания для промежуточной аттестации по дисциплине (модулю)

№ п/п	Задание	Ответ	Компетенция
1	Как называется процесс разбиения текста на отдельные слова или подслова?	токенизация	УК-1
2	Как называется метод представления текста, при котором учитывается частота слова в документе и его редкость в корпусе?	TF-IDF	УК-1
3	Как называется задача извлечения имён, дат и организаций из текста?	NER / извлечение именованных сущностей	УК-1
4	Как называется подход, при котором модель обучается на одной задаче, а затем адаптируется под другую?	transfer learning / трансферное обучение	УК-1
5	Какой тип архитектуры используют модели BERT и RoBERTa?	энкодерная / encoder-only	УК-2
6	Какой метод адаптации LLM позволяет обновлять только небольшую часть параметров?	LoRA / Low-Rank Adaptation	УК-2
7	Какой компонент в RAG-системе отвечает за поиск релевантного контекста?	векторный поисковик / retriever	УК-2
8	Какой параметр генерации контролирует разнообразие выходного текста?	температура / temperature	УК-2
9	Как называется числовой вектор, представляющий смысл слова или предложения?	эмбединг / векторное представление	ОПК-1
10	Как называется метрика, измеряющая близость сгенерированного и эталонного текста на основе n-грамм?	BLEU	ОПК-1
11	Как называется механизм в трансформере, позволяющий каждому токenu учитывать все остальные?	внимание / self-attention / механизм внимания	ОПК-1
12	Как называется задача, при которой модель предсказывает следующее слово в последовательности?	языковое моделирование	ОПК-1
13	Как называется архитектура, лежащая в основе GPT?	декодерная / decoder-only	ПК-1
14	Как называется процесс дообучения предобученной модели на размеченных данных?	fine-tuning / дообучение	ПК-1
15	Как называется метрика, измеряющая качество суммаризации через пересечение n-грамм?	ROUGE	ПК-1
16	Как называется подход, при котором контекст извлекается из внешней базы перед генерацией?	RAG / дополненная генерация / retrieval-augmented generation	ПК-1
17	Как называется метод уменьшения размерности весов модели для ускорения инференса?	квантование	ПК-2
18	Какой формат позволяет запускать модели в разных фреймворках без переписывания кода?	ONNX	ПК-2
19	Как называется подход к оценке качества генерации с помощью другой языковой модели?	LLM-as-a-Judge	ПК-2

20	Какой инструмент используется для векторного поиска в системах RAG?	FAISS / Weaviate / Pinecone / Chroma	ПК-2
----	---	--------------------------------------	------