
УТВЕРЖДЕНА

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

**Рабочая программа дисциплины (модуля)
«Безопасность систем ИИ»**

Направление подготовки: 02.04.01 Математика и компьютерные науки

Направленность (профиль) подготовки: Продуктовая аналитика

Квалификация (степень) выпускника: магистр

Форма обучения: очная

Срок освоения программы: 2 года

Год набора: 2026

**Москва
2026**

Содержание

1. Краткая характеристика дисциплины (модуля)	3
2. Перечень планируемых результатов обучения.....	5
3. Тематический план.....	8
4. Содержание дисциплины (модуля).....	8
5. Учебно-методическое обеспечение	9
6. Материально-техническое обеспечение	9
7. Методические и оценочные материалы	11

1. Краткая характеристика дисциплины (модуля)

Рабочая программа дисциплины (модуля) «Безопасность систем ИИ» составлена в соответствии с федеральным государственным образовательным стандартом высшего образования – магистратура по направлению 02.04.01 Математика и компьютерные науки, профиль Продуктовая аналитика, утвержденный приказом Министерства науки и высшего образования Российской Федерации № 810 от 23.08.2017 года.

Изучение дисциплины (модуля) «Безопасность систем ИИ» позволяет сформировать целостное понимание угроз и защитных механизмов в системах искусственного интеллекта, а также практические навыки анализа, тестирования и проектирования безопасных ИИ-решений в условиях современных кибератак.

Место дисциплины (модуля) в структуре образовательной программы

Настоящая дисциплина (модуль) включена в учебный план по программе подготовки магистратуры по направлению 02.04.01 Математика и компьютерные науки, профиль Продуктовая аналитика и входит в вариативную часть Блока 1, формируемую участниками образовательных отношений как дисциплина по выбору.

Дисциплина (модуль) доступна к изучению на 2 курсе в 3 семестре. Доступна для прохождения при условии параллельного изучения дисциплины (модуля) «Обработка естественного языка (Natural Language Processing)».

Цель изучения дисциплины (модуля): подготовить специалистов к выявлению, анализу и предотвращению киберугроз, направленных на модели и данные машинного обучения, а также к разработке защищённых архитектур ИИ-систем, устойчивых к атакам на разных уровнях — от данных до интеллектуальной собственности.

Задачи изучения дисциплины (модуля):

- изучить архитектуры ИИ-систем как в контексте их использования в кибербезопасности, так и в качестве целей атак;
- освоить классификацию и механизмы атак на модели машинного обучения: отравление данных, уклонение, кража моделей, атаки с использованием генеративных моделей;
- научиться оценивать безопасность наборов данных и моделей с точки зрения уязвимостей;
- приобрести навыки тестирования ИИ-систем с применением современных фреймворков;
- развить способность обоснованно выбирать архитектуры, алгоритмы и методы защиты в зависимости от рисков и требований безопасности.

В результате освоения дисциплины (модуля) обучающийся должен:

знать:

- основные области использования систем искусственного интеллекта в кибербезопасности;
- архитектуру и модели систем искусственного интеллекта, используемых при организации кибератак;
- архитектуру и модели систем искусственного интеллекта, используемых при защите от кибератак;
- схемы организации атак на модели машинного обучения;
- классификацию атак на модели машинного обучения (искусственного интеллекта);
- схемы атак отравления данных и методы борьбы с ними;
- схемы атак отравления моделей машинного обучения;
- схемы атак уклонением и методы борьбы с ними;
- схемы атак на интеллектуальную собственность и методы борьбы с ними;
- схемы использования порождающих моделей в атаках на системы машинного обучения (искусственного интеллекта).

уметь:

- строить модели систем искусственного интеллекта для использования в кибербезопасности;
- организовывать тестирование систем искусственного интеллекта для оценки их безопасности;
- оценивать наборы данных, используемые в моделях искусственного интеллекта с точки зрения безопасности;
- формировать обоснованную оценку организации и функционирования тех или иных компонентов систем искусственного интеллекта, как в контексте их базовых функций, так и с точки зрения рисков кибербезопасности;
- использовать современные открытые фреймворки для задач кибербезопасности систем искусственного интеллекта.

владеть:

- навыками выбора архитектурных решений для систем искусственного интеллекта, используемых в кибербезопасности;
- навыками анализа моделей машинного обучения (искусственного интеллекта) с точки зрения кибербезопасности (защиты от атак);
- умением выбора моделей и алгоритмов для систем искусственного интеллекта, используемых в кибербезопасности;
- навыком оценки рисков безопасности систем искусственного интеллекта.

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-6.	Способен определять и реализовывать приоритеты собственной деятельности и способы ее совершенствования на основе самооценки	УК-6.1.	Знает основные методы самооценки и анализа своей деятельности, а также принципы управления временем и целеполагания
		УК-6.2.	Умеет ставить реалистичные и достижимые цели, определять приоритеты в своей деятельности, а также разрабатывать и внедрять планы по совершенствованию своих навыков и компетенций на основе полученной самооценки
		УК-6.3.	Имеет практический опыт применения методов самооценки в своей профессиональной деятельности, включая участие в тренингах, семинарах и проектах, направленных на развитие личной эффективности и профессионального роста
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 определять общие формы и закономерности в данных продуктовой аналитики	ПК-1.1.	Знает основные теоретические концепции и принципы, относящиеся к области продуктовой аналитики, а также ключевые закономерности и модели, которые помогают в анализе и интерпретации данных
		ПК-1.2.	Умеет проводить систематический анализ продуктовой аналитики, выявлять и формулировать общие закономерности и тенденции, а также применять методы исследования для получения новых знаний и понимания
		ПК-1.3.	Имеет практический опыт работы в области продуктовой аналитики, включая участие в научных проектах, исследованиях или практических заданиях, где были выявлены и описаны общие формы и закономерности
ПК-3.	Способен решать задачи профессиональной деятельности в области продуктовой аналитики, формулировать результаты анализа и выявлять последствия полученных данных для принятия обоснованных решений и оптимизации продуктов	ПК-3.1.	Знает методы и инструменты продуктовой аналитики
		ПК-3.2.	Умеет применять аналитические инструменты и программное обеспечение для обработки и визуализации данных, а также формулировать выводы на основе проведенного анализа
		ПК-3.3.	Имеет опыт работы над реальными проектами в области продуктовой аналитики, включая анализ пользовательского поведения и оптимизацию продуктов на основе полученных данных
ПК-6.	Способен разрабатывать программное обеспечение для решения прикладных задач в сфере продуктовой аналитики	ПК-6.1.	Знает основные языки программирования, методы разработки программного обеспечения, а также принципы проектирования и архитектуры программных систем, применяемых в продуктовой аналитике
		ПК-6.2.	Умеет анализировать прикладные задачи, разрабатывать алгоритмы и реализовывать их в виде

			программного обеспечения, используя современные инструменты и технологии, а также проводить тестирование и отладку созданных решений
		ПК-6.3.	Имеет практический опыт разработки программного обеспечения в рамках реальных проектов, включая участие в командах, где были успешно реализованы решения для конкретных прикладных задач

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 (практичес кие занятия)			
1	Атаки на системы ИИ	20	20	2	50	Домашние задания Коллоквиум
2	Защита систем ИИ	6	6	2	34	Домашние задания Коллоквиум
3	Современные вызовы и автоматизация в безопасности ИИ	4	4	4	34	Контрольная работа
	Экзамен			4		
Итого:		30	30	12	118	
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	Атаки на системы ИИ	Наступательный ИИ (атаки) Защита с помощью ИИ Зловредные воздействия Введение в атаки на системы ИИ. Коллоквиум Схемы атак на системы ИИ Атаки отравления данных и моделей Атаки отравления – бэкдоры Атаки уклонения – белый ящик. Коллоквиум Атаки уклонения – черный ящик
2	Защита систем ИИ	Атаки уклонения – защита Атаки на приватные данные. Коллоквиум
3	Современные вызовы и автоматизация в безопасности ИИ	Атаки с порождающими элементами Автоматизация атак (фреймворки) Атаки на большие языковые и мультимодальные модели

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. Козырь, Н. С. Информационные технологии в кибербезопасности : учебник для вузов / Н. С. Козырь, А. М. Левченко. — Москва : Издательство Юрайт, 2026. — 217 с. — (Высшее образование). — ISBN 978-5-534-22095-7. — Текст : электронный // Образовательная платформа Юрайт [сайт]. — URL: <https://urait.ru/bcode/600794>.

2. Платонов, В. В. Технологии машинного обучения в кибербезопасности : учебное пособие / В. В. Платонов. - Москва ; Вологда : Инфра-Инженерия, 2024. - 140 с. - ISBN 978-5-9729-2048-8. - Текст : электронный. - URL: <https://znanium.ru/catalog/product/2170891>.

Дополнительная литература:

1. Партыка, Т. Л. Информационная безопасность : учебное пособие / Т.Л. Партыка, И.И. Попов. — 5-е изд., перераб. и доп. — Москва : ФОРУМ : ИНФРА-М, 2021. — 432 с. — (Среднее профессиональное образование). - ISBN 978-5-00091-473-1. - Текст : электронный. - URL: <https://znanium.ru/catalog/product/1189328>.

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) «Безопасность систем ИИ» в рамках текущего контроля успеваемости используются такие виды учебной работы, как лекции, семинары, домашние задания, коллоквиумы, контрольная работа, 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.

Коллоквиум – устные ответы на вопросы, список которых известен студенту заранее.

В процессе подготовки к коллоквиуму необходимо проанализировать учебные материалы, ознакомившись с лекциями, учебниками и дополнительными источниками, акцентируя внимание на ключевых темах. Рекомендуется создать структурированные конспекты, выделяя основные идеи, термины и формулы.

Контрольная работа – письменная работа с набором задач, которые нужно решить за ограниченное время.

Цель контрольной работы – получить специальные знания по одной или нескольким темам дисциплины и продемонстрировать навыки их практического применения.

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) «Безопасность систем ИИ»

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 задачи. Студент хорошо знаком с методами исследования, необходимыми для практической деятельности, и умеет связывать теоретические аспекты дисциплины (модуля) с практическими задачами.
9	Отлично	
8	Отлично	
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
6	Хорошо	

Десятибалльная оценка	Пятибалльная оценка	Общая характеристика результата обучения по дисциплине (модулю)
		задачами.
5	Удовлетворительно	Студент обладает базовыми знаниями по дисциплине, 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.

Дисциплина (модуль) «Безопасность систем ИИ» оценивается следующим образом:

Активность	Вес	Количество	Описание
Домашние задания	30%	12	Набор задач по темам недели
Коллоквиумы	30%	3	Устные ответы на вопросы, список которых известен студенту заранее
Контрольная работа	20%	1	Письменная работа с набором задач, которые нужно решить за ограниченное время
Экзамен	20%	1	Письменная или устная работа над заданием, направленным на проверку полученных знаний и навыков по дисциплине (модулю)

Формула расчёта итоговой оценки по дисциплине (модулю) «Безопасность систем ИИ»: $0,3 \times \text{Среднее за домашние задания} + 0,3 \times \text{Среднее за коллоквиумы} + 0,2 \times \text{контрольная работа} + 0,2 \times \text{экзамен}$.

Текущий контроль успеваемости обучающихся по дисциплине (модулю)

Примерные домашние задания

Домашнее задание 1. Анализ и моделирование атаки отравления данных

Задание:

- Используя открытый датасет (например, CIFAR-10 или IMDB), добавьте в обучающую выборку 5% зашумлённых или поддельных образцов (например, с неправильными метками).
- Обучите модель классификации (например, логистическую регрессию или небольшую нейросеть).
- Оцените изменение качества модели на чистом тестовом наборе.
- Проведите анализ: как атака повлияла на метрики (accuracy, precision, recall)?
- Предложите и реализуйте метод защиты (например, фильтрация аномалий, регуляризация).
- Сравните результаты до и после защиты.

Требования:

- Код на Python (scikit-learn, PyTorch)
- Отчёт с графиками и выводами
- Обоснование выбранного метода защиты

Домашнее задание 2. Построение и тестирование атаки уклонения (evasion attack)

Задание:

1. Выберите предобученную модель (например, из torchvision или Hugging Face).
2. Сгенерируйте атакующие примеры с помощью метода FGSM (Fast Gradient Sign Method) в белом или чёрном ящике.
3. Проверьте, насколько успешно модель ошибается на атакованных данных.
4. Визуализируйте исходное и изменённое изображение/текст.
5. Оцените устойчивость модели к атаке.
6. Примените простейший метод защиты (например, сглаживание, нормализация) и проверьте его эффективность.

Требования:

- Использование библиотеки ART (Adversarial Robustness Toolbox) или аналога
- Примеры атак и визуализация
- Выводы по уязвимости модели

Домашнее задание 3. Анализ угроз для больших языковых моделей**Задание:**

1. Выберите сценарий использования LLM (например, чат-бот поддержки или генератор контента).
2. Смоделируйте три типа атак:
 - Prompt-инжиниринг (обход фильтров)
 - Data leakage (попытка извлечь обучающие данные)
 - Генерация вредоносного контента (через jailbreak)
3. Протестируйте модель (локальную или через API).
4. Зафиксируйте случаи успешных атак.
5. Предложите меры защиты: фильтрацию промптов, ограничение контекста, мониторинг.
6. Оформите отчёт с рекомендациями.

Требования:

- Описание сценариев атак
- Примеры запросов и ответов
- Меры по защите и их обоснование

Примерные вопросы к коллоквиуму**Коллоквиум 1. Атаки на системы ИИ**

1. Что такое наступательный ИИ?
2. Какие цели преследуют атаки на ИИ-системы?
3. В чём суть атаки отравления данных?
4. Чем атака отравления модели отличается от отравления данных?
5. Что такое бэкдор-атака? Приведите пример.
6. Как работает атака уклонения (evasion)?
7. В чём разница между атаками белого и чёрного ящика?
8. Какие типы данных чаще всего подвергаются атакам отравления?
9. Какие признаки могут указывать на наличие бэкдора?
10. Какие сферы наиболее уязвимы к атакам на ИИ?

Коллоквиум 2. Защита систем ИИ

1. Какие методы защиты используются против атак уклонения?
2. Что такое робастная оптимизация?
3. Как работает защита через добавление шума (adversarial training)?
4. Что такое дифференциальная приватность?
5. Какие атаки направлены на извлечение приватных данных из модели?
6. Как можно обнаружить утечку обучающих данных?

7. Что такое модель-клон (model extraction)?
8. Как защититься от атак на интеллектуальную собственность?
9. Какие метрики используются для оценки робастности модели?
10. Что такое сертифицированная защита (certified robustness)?

Коллоквиум 3. Современные вызовы и автоматизация

1. Как порождающие модели (например, GAN, LLM) используются в атаках?
2. Что такое deepfake и как он угрожает безопасности?
3. Какие фреймворки используются для автоматизации атак на ИИ?
4. Что включает фреймворк MITRE ATLAS?
5. Какие уязвимости есть у мультимодальных моделей?
6. Что такое jailbreak в контексте LLM?
7. Какие методы используются для автоматического поиска уязвимостей?
8. Как атаки на ИИ масштабируются с помощью автоматизации?
9. Какие вызовы возникают при защите больших языковых моделей?
10. Какие принципы лежат в основе "secure-by-design" подхода к ИИ?

Примерные задания для контрольной работы

Контрольная работа 1

1. Определите тип атаки: в обучающую выборку добавлены изображения с неправильными метками.
2. Объясните, как это может повлиять на работу модели.
3. Приведите пример бэкдор-атаки.
4. Какие меры можно предпринять для обнаружения отравления?
5. Нарисуйте схему взаимодействия при атаке отравления данных.

Контрольная работа 2

1. Опишите принцип работы FGSM.
2. В чём разница между белым и чёрным ящиком в атаках уклонения?
3. Приведите пример атаки на приватность (например, атака по членству).
4. Как дифференциальная приватность помогает защититься от таких атак?
5. Какие ограничения есть у методов защиты от атак уклонения?

Контрольная работа 3

1. Что такое prompt-инжиниринг в атаках на LLM?
2. Приведите пример jailbreak-промпта.
3. Как автоматизация (например, через AutoPrompt) усиливает атаки?
4. Какие риски несёт использование генеративных моделей в фишинге?
5. Какие меры защиты можно применить к мультимодальной модели?

Задания для промежуточной аттестации по дисциплине (модулю)

№ п/п	Задание	Ответ	Компетенция
1.	Какой этический риск возникает при использовании состязательных примеров?	Манипуляция решениями ИИ	УК-6
2.	Как записывается возмущение в методе FGSM?	$\Delta = \epsilon \cdot \text{sign}(\nabla_x L)$	ОПК-1
3.	Какая библиотека популярна для тестирования устойчивости моделей?	IBM ART или Foolbox	ПК-1

4.	В чем разница между атакой уклонения и отравления?	Время воздействия (инференс vs обучение)	ПК-3
5.	Как интегрируется проверка безопасности в MLOps пайплайн?	Security Gates в CI/CD	ПК-6
6.	Кто несет ответственность за утечку данных через модель?	Владелец модели	УК-6
7.	Какова цель минимаксной оптимизации в adversarial training?	Минимизация потерь при максимизации ошибки атаки	ОПК-1
8.	Какой метод защищает от Membership Inference Attacks?	Дифференциальная приватность	ПК-1
9.	Как оценивается робастность модели к атакам?	Точность на состязательных примерах	ПК-3
10.	Что включает стратегия защиты от генеративных атак?	Фильтрация контента и водяные знаки	ПК-6
11.	Какой принцип нарушается при атаке на приватность?	Конфиденциальность данных	УК-6
12.	Что характеризует чувствительность модели к входным данным?	Градиент функции потерь	ОПК-1
13.	Как обнаруживается бэкдор в нейронной сети?	Анализ активаций нейронов	ПК-1
14.	Что такое Prompt Injection в контексте LLM?	Внедрение вредоносных инструкций	ПК-3
15.	Как управляется риск supply chain атак на модели?	Верификация источников артефактов	ПК-6
16.	Что требует регуляторика при внедрении защищенных систем?	Оценка рисков безопасности	УК-6
17.	Как определяется граница решения в линейном классификаторе?	$w^T x + b = 0$	ОПК-1
18.	Какой протокол защищает передачу моделей?	TLS/SSL шифрование	ПК-1
19.	Как влияет отравление данных на сходимость модели?	Смещение весов или расходимость	ПК-3
20.	Какой документ регламентирует требования к безопасности ИИ в ЕС?	EU AI Act	ПК-6