
УТВЕРЖДЕНА

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

**Рабочая программа дисциплины (модуля)
«Обработка данных и каузальный анализ в машинном обучении (Causal inference)»**

Направление подготовки: 02.04.01 Математика и компьютерные науки

Направленность (профиль) подготовки: Машинное обучение в
электронной коммерции

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.....	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 данных и каузальный анализ в машинном обучении (Causal inference)» составлена в соответствии с федеральным государственным образовательным стандартом высшего образования – магистратура по направлению 02.04.01 Математика и компьютерные науки, профиль Машинное обучение в электронной коммерции, утвержденный приказом Министерства науки и высшего образования Российской Федерации № 810 от 23.08.2017 года.

Изучение дисциплины (модуля) «Обработка данных и каузальный анализ в машинном обучении (Causal inference)» позволяет преодолеть ограничения традиционных моделей машинного обучения, которые часто путают корреляцию с причинностью, приводя к ошибочным выводам и предвзятостям в принятии решений. Освоение методов причинно-следственного анализа позволяет создавать более надежные, интерпретируемые и этичные системы ИИ, интегрирующие экспертные знания и физические принципы, что особенно актуально в областях, таких как здравоохранение, финансы и политика, где последствия ошибок могут быть значительными.

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 Машинное обучение в электронной коммерции и входит в вариативную часть Блока 1, формируемую участниками образовательных отношений как дисциплина по выбору.

Дисциплина (модуль) доступна к изучению на 1 и 2 курсе во 2 и 4 семестре. Доступна для прохождения при условии успешного завершения дисциплин (модулей) «Прикладная математика для машинного обучения» и «Машинное обучение (Machine Learning)».

Цель изучения дисциплины (модуля): развитие навыков применения причинно-следственного анализа для создания интерпретируемых и надежных моделей машинного обучения, учитывающих физические закономерности и минимизирующих предвзятости в данных.

Задачи изучения дисциплины (модуля):

- освоить различия между корреляцией и причинностью для корректного анализа зависимостей в данных машинного обучения;
- научиться применять каузационные графы для визуализации и моделирования причинных связей между переменными;
- развить навыки использования инструментов интерпретации моделей, таких как SHAP, SAGE и LIME, для объяснения предсказаний;
- приобрести умение выявлять и корректировать предвзятости в наборах данных для повышения качества моделей;
- освоить техники встраивания физических законов в архитектуру статистических моделей и нейронных сетей для улучшения их предсказательной способности.

В результате освоения дисциплины (модуля) обучающийся должен:

знать:

- понятия причинности, корреляции, интерпретируемости;
- подходы к интерпретируемости, каузационные графы, типа взаимодействия признаков;

- способы учёта физических законов внутри статистических моделей.

уметь:

- использовать каузационные графы, для построения моделей;
- интерпретировать результаты предсказания статистической модели различными способами (SHAP, SAGE, LIME);
- оценивать качество входящих данных, определять возможные предвзятости в данных;
- вводить физические законы в архитектуру нейронной сети.

владеть:

- методами построения причинной модели на основе статистического анализа;
- способами интерпретации статистических моделей;
- методами интеграции аналитических моделей в статистические.

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-2.	Способен создавать и исследовать новые математические модели в естественных науках, совершенствовать и разрабатывать концепции, теории и методы	ОПК-2.1.	Знает современные подходы к построению математических и статистических моделей, применяемых в электронной коммерции, включая модели поведения пользователей, системы рекомендаций, модели удержания клиентов, а также методы анализа неполных, зашумлённых и временных данных
		ОПК-2.2.	Умеет разрабатывать, адаптировать и проверять математические модели для решения прикладных задач, оценивать их точность и устойчивость,

			интерпретировать результаты с учетом экономических показателей деятельности организации
		ОПК-2.3.	Имеет практический опыт разработки и исследования математических моделей в рамках прикладных проектов, включая подготовку данных, настройку параметров моделей, проверку их качества на реальных данных и представление результатов в аналитических отчетах
ПК-3.	Способен осуществлять анализ, интерпретацию и оценку результатов применения методов машинного обучения в электронной коммерции	ПК-3.1.	Знает методы статистического анализа, принципы построения и оценки качества моделей, подходы к проведению экспериментальных исследований и проверке статистических гипотез
		ПК-3.2.	Умеет проводить анализ данных и результатов моделирования, интерпретировать полученные результаты с учетом целей и показателей эффективности деятельности организации
		ПК-3.3.	Имеет практический опыт проведения аналитических исследований и подготовки обоснованных выводов и рекомендаций для принятия управленческих решений

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	Введение и основы. Понятие каузации и базовый математический аппарат	7	7		22	Домашние задания
2	Разбор алгоритмов на примерах	7	7		22	Домашние задания
	Зачет с оценкой			2		Проект
Итого:		14	14	4	44	
Объем дисциплины (модуля) (в ак. ч.)		76				
Объем дисциплины (модуля) (в зач. ед.)		2				

4. Содержание дисциплины (модуля)

№п/п	Наименование раздела дисциплины (модуля)	Содержание дисциплины (модуля) по темам
1	Введение и основы. Понятие каузации и базовый математический аппарат	Введение, понятие причинности и связь с каузацией. Спутывание, парадокс Симпсона, направленный ациклический граф. Сопоставление по конфаундерам, оценка причинных эффектов.
2	Разбор алгоритмов на примерах	Метод "взвешивания обратной вероятности лечения" (IPTW). Метод инструментальных переменных. Каузационный лес (Causal Forest). Information Geometric Causal Inference.

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. Хантингтон-Клейн, Н. В поисках эффекта. Планирование экспериментов и причинный вывод в статистике : практическое руководство <https://znanium.ru/catalog/document?id=462757>.

2. Маунт, Д. Погружение в аналитику данных : практическое руководство / Д. Маунт. - Санкт-Петербург : БХВ-Петербург, 2023. - 224 с. - ISBN 978-5-9775-6866-1. - Текст : электронный. - URL: <https://znanium.com/catalog/product/2123377>.

3. Лесковец, Ю. Анализ больших наборов данных : практическое руководство / Д. Дж. Ульман, Ю. Лесковец, А. Раджараман ; пер. с англ. А. А. Слинкина. - 2-е изд. - Москва : ДМК Пресс, 2023. - 500 с. - ISBN 978-5-89818-304-2. - Текст : электронный. - URL: <https://znanium.ru/catalog/product/2102592>.

Дополнительная литература:

1. Робинсон, Я. Графовые базы данных. Новые возможности для работы со связанными данными : практическое руководство / Я. Робинсон, Дж. Вебер, Э. Эфрем ; пер. с англ. Р. Н. Рагимова. - 3-е изд. - Москва : ДМК Пресс, 2023. - 257 с. - ISBN 978-5-89818-566-4. - Текст : электронный. - URL: <https://znanium.com/catalog/product/2107921>.

2. Мыльников, Л. А. Статистические методы интеллектуального анализа данных / Л. А. Мыльников. - Санкт-Петербург : БХВ-Петербург, 2021. - 240 с. - ISBN 978-5-9775-6733-6. - Текст : электронный. - URL: <https://znanium.ru/catalog/product/2142845>.

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 данных и каузальный анализ в машинном обучении (Causal inference)» в рамках текущего контроля успеваемости используются такие виды учебной работы, как лекции, семинары, домашние задания, проект, 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.

Проект – исследовательская работа по дисциплине (модулю) и презентация результатов.

Для успешной подготовки к проекту рекомендуется: четко определить цели и задачи проекта; составить план работы, разбив проект на этапы с указанием сроков выполнения каждого из них; использовать разнообразные источники информации и инструменты для исследования темы; регулярно проверять прогресс и вносить коррективы в план, если это необходимо.

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 данных и каузальный анализ в машинном обучении (Causal inference)»

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 *зачета с оценкой*, 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 syllabus 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 (модуль). 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 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
4	Удовлетворительно	

Десятибалльная оценка	Пятибалльная оценка	Общая характеристика результата обучения по дисциплине (модулю)
		владеет лишь минимальным набором методов исследования.
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 данных и каузальный анализ в машинном обучении (Causal inference)» оценивается следующим образом:

Активность	Вес	Количество	Описание
Домашние задания	70%	5	Набор задач по темам недели
Зачет с оценкой	30%	1	Проект – Исследовательская работа по дисциплине (модулю) и презентация результатов

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

Формула расчёта итоговой оценки по дисциплине (модулю) «Обработка данных и каузальный анализ в машинном обучении (Causal inference)»: $\langle 0,7 \times \text{среднее за домашние задания} + 0,3 \times \text{зачет с оценкой} \rangle$.

Текущий контроль успеваемости обучающихся по дисциплине (модулю)

Примерные домашние задания

Домашнее задание 1.

1. Проанализируйте пример из реальной жизни (например, связь между курением и раком легких), где корреляция может быть принята за каузацию, и объясните, почему статистические модели без учета причинных связей могут привести к ошибочным выводам. Подготовьте краткий отчет с обоснованием.

2. Сравните статистическую модель (например, линейную регрессию) и аналитическую модель (например, модель с каузационными графами) на синтетическом наборе данных, созданном в Python с использованием библиотек вроде pandas и scikit-learn. Опишите различия в интерпретируемости результатов.

3. Опишите понятие интерпретируемости в контексте машинного обучения и приведите три примера, когда низкая интерпретируемость модели может привести к этическим проблемам в принятии решений (например, в кредитном скоринге).

4. Используя простой набор данных (например, Boston Housing), примените два способа интерпретации статистической модели (SHAP и LIME) и сравните их результаты, объяснив, как они помогают выявить каузационные связи.

5. Разработайте сценарий, где аналитическая модель интегрирует экспертные знания для решения проблемы каузации, и предложите шаги по ее реализации на основе изученных понятий.

Домашнее задание 2.

1. Постройте каузационный граф для сценария влияния образования на доход, включая типы связей (confounder, covariate, mediator). Используйте инструмент вроде DAGitty для визуализации и объясните, как каждая связь влияет на интерпретацию данных.
2. Проанализируйте пример с moderator-эффектом (например, влияние возраста на связь между упражнениями и здоровьем сердца) и нарисуйте соответствующий граф, выделив мультипликативный эффект признаков.
3. На основе реального кейса (например, влияние рекламы на продажи продукта с учетом confounder-факторов, таких как сезонность), создайте граф причинности и обсудите, как учет взаимного влияния признаков изменяет выводы модели.
4. Используя библиотеку networkx в Python, смоделируйте граф с mediator-связью (например, стресс как mediator между работой и здоровьем) и симулируйте данные, чтобы продемонстрировать, как игнорирование этого типа связи искажает результаты.
5. Сравните два графа причинности для одного и того же набора данных (например, влияние диеты на вес), один с учетом всех типов связей, другой упрощенный, и объясните преимущества полного графа для предсказательной модели.

Домашнее задание 3.

1. Рассчитайте доверительный интервал для среднего значения выборки из набора данных (например, оценки качества воздуха) и интерпретируйте его в контексте погрешности модели, объяснив, как это влияет на вывод о причинных связях.
2. На примере линейной регрессии на синтетических данных выведите соотношение числа исходов и анализируемых признаков, используя метрики вроде R-квадрат и MSE, и обсудите, как погрешность растет с увеличением числа признаков.
3. Проанализируйте способы расчета погрешности (стандартная ошибка, bootstrap) для оценки коэффициентов в каузационной модели и приведите пример, где высокая погрешность указывает на необходимость дополнительных данных или корректировки графа.
4. Используя реальный датасет (например, данные о зарплатах), постройте модель с доверительными интервалами для коэффициентов и объясните, как интерпретация погрешности помогает избежать переобучения в контексте причинного вывода.
5. Выведите типичное соотношение между числом исходов и признаков для модели с низкой погрешностью, используя теорему о размерности, и предложите стратегии по снижению погрешности в моделях с большим количеством переменных.

Домашнее задание 4.

1. Объясните необходимость интерпретации данных в модели машинного обучения на примере предсказания риска заболеваний, где неинтерпретируемые результаты могут привести к неверным медицинским решениям.
2. Примените два способа интерпретации (например, SHAP и permutation importance) к модели случайного леса на датасете Iris и сравните, как они раскрывают вклад признаков в предсказание.

3. Разработайте кейс, где интерпретация результатов модели (например, с использованием LIME) помогает выявить предвзятость в данных о найме персонала, и предложите корректирующие меры.

4. На основе набора данных о продажах, постройте интерпретируемую модель (например, линейную регрессию) и используйте глобальные методы интерпретации (PDP plots), чтобы объяснить влияние признаков на исход.

5. Обсудите сценарий, где отсутствие интерпретации результатов модели приводит к этическим дилеммам в автономных системах (например, в беспилотных автомобилях), и предложите шаги по интеграции интерпретируемости в процесс разработки.

Примерное описание задания и критерии оценивания к проекту

Цель проекта: Разработать комплексный анализ причинных связей в реальном наборе данных, интегрируя теоретические понятия каузации, графы причинности, интерпретируемость моделей и методы работы с данными. Студенты должны продемонстрировать умение применять статистические и аналитические модели, оценивать качество данных, снижать размерность и оценивать границы применимости моделей. Проект способствует развитию навыков интерпретации результатов, избежания переобучения и этического использования ИИ в критических областях, таких как здравоохранение.

Формат: Индивидуальный или групповой (2–3 человека). Срок выполнения: 4–6 недель.

Инструменты: Python (библиотеки: pandas, scikit-learn, networkx, causalmml, SHAP, LIME, statsmodels, torch для PINNs), Jupyter Notebook, DAGitty или аналогичные для визуализации графов.

Датасет: Рекомендуется использовать открытый датасет, такой как Diabetes Dataset (из sklearn) или Framingham Heart Study (с Kaggle), или синтетический набор данных, созданный самостоятельно. Датасет должен содержать переменные для анализа причинных связей (например, факторы риска, исходы здоровья).

Структура проекта и интеграция тем

Проект разделен на этапы, каждый из которых соответствует одной из тем дисциплины. Студенты должны последовательно выполнять шаги, документируя процесс в отчете (в формате Jupyter Notebook с кодом, визуализациями и объяснениями). Итоговый отчет должен включать: введение, анализ, результаты, обсуждение проблем и выводы.

1. Каузация и интерпретируемость

- **Задача:** Определите проблему каузации на примере датасета (например, связь между уровнем сахара в крови и диабетом). Постройте статистическую модель (линейная регрессия) и аналитическую модель (с использованием каузационных графов). Сравните их интерпретируемость.

- **Шаги:** Выберите переменные, рассчитайте корреляции, примените SHAP или LIME для интерпретации. Объясните, почему корреляция $\neq$ каузация.

- **Ожидаемый результат:** Отчет с визуализациями, сравнением моделей и обоснованием необходимости аналитических подходов.

2. Граф причинности

- **Задача:** Постройте полный граф причинности для датасета, включая confounder (например, возраст как конфундер для связи курения и диабета), covariate, mediator (например, стресс как медиатор между работой и здоровьем) и moderator (например, возраст как модератор эффекта диеты).
- **Шаги:** Используйте networkx или DAGitty для создания графа. Симулируйте данные для демонстрации взаимного влияния и мультипликативных эффектов. Обсудите, как граф меняет интерпретацию.
- **Ожидаемый результат:** Визуализация графа, анализ связей и симуляция данных с объяснением искажений без учета типов связей.

3. Понятие доверительных интервалов и погрешности в статистической модели

- **Задача:** Оцените погрешность модели на датасете, рассчитав доверительные интервалы для коэффициентов (например, в регрессии). Выведите соотношение числа исходов и признаков, используя метрики (R-квадрат, MSE, стандартная ошибка).
- **Шаги:** Примените bootstrap или стандартные методы для оценки погрешности. Объясните, как погрешность указывает на риск переобучения.
- **Ожидаемый результат:** Таблицы с доверительными интервалами, графики погрешности и рекомендации по соотношению данных/признаков.

4. Интерпретируемость результатов работы моделей

- **Задача:** Постройте модель (например, случайный лес) и интерпретируйте ее результаты с помощью SHAP, LIME и PDP plots. Объясните необходимость интерпретации для этических решений (например, предсказание риска заболеваний).
- **Шаги:** Сравните локальные и глобальные методы интерпретации. Обсудите сценарии, где низкая интерпретируемость приводит к проблемам.
- **Ожидаемый результат:** Визуализации интерпретации, анализ вклада признаков и этические выводы.

5. Работа с качеством данных, высокоскореллированные данные, матрицы корреляций, удаление и объединение признаков

- **Задача:** Проанализируйте качество данных: выявите высокоскореллированные признаки (матрица корреляций), проблемы (пропуски, выбросы). Удалите/объедините признаки для снижения риска переобучения.
- **Шаги:** Постройте heatmap корреляций, примените методы (например, VIF для мультиколлинеарности). Оцените допустимое число признаков по соотношению с размером выборки.
- **Ожидаемый результат:** Отчет с матрицей корреляций, обоснованием изменений в датасете и анализом риска переобучения.

6. Работа с научными статьями, на примере статей посвящённых нелинейным методам снижения размерности (t-SNE, UMAP)

- **Задача:** Изучите 2–3 научные статьи по t-SNE и UMAP (например, оригинальные работы van der Maaten). Примените эти методы к датасету для снижения размерности и визуализации кластеров.
- **Шаги:** Обсудите проблемы нелинейного подхода (потеря глобальной структуры), контрпримеры. Сравните с линейными методами (PCA).

- **Ожидаемый результат:** Аннотация статей, код применения методов, визуализации и анализ преимуществ/недостатков.

7. Физически информированные нейронные сети

- **Задача:** Объедините статистическую модель (регрессия) с аналитической (PINN) для учета физических законов (например, моделирование диффузии глюкозы в организме).
- **Шаги:** Реализуйте PINN в PyTorch, сравните плюсы/минусы (точность vs. интерпретируемость). Объясните способы объединения (встраивание уравнений).
- **Ожидаемый результат:** Код PINN, сравнение с традиционными моделями и обсуждение интеграции.

8. Метод оценки качества данных, определение границ применимости моделей

- **Задача:** Оцените границы применимости модели: проанализируйте переобучение (из-за числа данных/признаков), интерпретируйте p-value для гипотез.
- **Шаги:** Постройте кривые обучения, рассчитайте p-value для коэффициентов. Обсудите проблемы входящих данных и риски.
- **Ожидаемый результат:** Анализ границ (например, минимальный размер выборки), рекомендации по улучшению данных.

Критерии оценки:

- **Техническая корректность (40%):** Качество кода, моделей и визуализаций.
- **Теоретическая глубина (30%):** Интеграция тем, обоснование выборов, ссылки на статьи.
- **Интерпретация и выводы (20%):** Объяснение результатов, этические аспекты, предложения по улучшению.
- **Презентация (10%):** Четкость отчета, отсутствие ошибок.

Задания для промежуточной аттестации по дисциплине (модулю)

№ п/п	Задание	Ответ	Компетенция
1.	Назовите основную проблему, отличающую каузацию от корреляции в анализе данных.	корреляция не подразумевает причинность/причинность не равна корреляции	ОПК-2
2.	Укажите способ публичного представления результатов по понятию каузации и интерпретируемости.	презентация	ПК-3
3.	Назовите общую закономерность в машинном обучении, связанную с необходимостью интерпретации моделей для этических решений.	интерпретируемость результатов	ПК-3
4.	Укажите рекомендацию по оценке переобучения из-за числа признаков.	P-value	ПК-3
5.	Укажите тип связи признаков, где переменная влияет на обе анализируемые переменные, искажая их связь.	confounder/конфаундер	ОПК-2

6.	Укажите формат демонстрации графа причинности и типов связей признаков.	демо	ПК-3
7.	Укажите тип эффекта признаков, где их взаимодействие умножает влияние на исход.	мультипликативный эффект	ПК-3
8.	Укажите рекомендацию по объединению статистической и аналитической моделей.	PINN	ОПК-2
9.	Назовите метод расчета погрешности модели, основанный на повторной выборке данных.	bootstrap/бутстрап	ПК-3
10.	Укажите формат публичного обсуждения физически информированных нейронных сетей.	дискуссия	ПК-3
11.	Назовите проблему, возникающую при недостатке данных относительно числа признаков.	переобучение	ПК-3
12.	Укажите рекомендацию по снижению размерности данных с помощью t-SNE.	нелинейное отображение	ОПК-2
13.	Укажите инструмент для интерпретации вклада признаков в модель, использующий локальные объяснения.	LIME	ПК-3
14.	Укажите способ представления интерпретируемости результатов работы моделей.	визуализация	ПК-3
15.	Укажите инструмент для визуализации графов причинности.	DAGitty	ПК-3
16.	Укажите рекомендацию по расчёту погрешности в статистической модели.	стандартная ошибка	УК-6
17.	Назовите проблему качества данных, связанную с высокой корреляцией между признаками.	мультиколлинеарность	ПК-3
18.	Укажите формат отчета по работе с качеством данных и матрицами корреляций.	график	ПК-3
19.	Назовите подход к снижению размерности, основанный на сохранении глобальной структуры.	PCA	ОПК-2
20.	Укажите рекомендацию по выявлению корреляции вместо каузации в данных.	корреляционная матрица	УК-6