

Документ подписан простой электронной подписью

Информация о владельце:

ФИО: Ястребов Олег Александрович

Должность: Ректор

Дата подписания: 25.05.2026 12:25:52

Уникальный программный ключ:

sa953a01204891083f939673078ef1a989dae18a

Федеральное государственное автономное образовательное учреждение высшего образования

«Российский университет дружбы народов имени Патриса Лумумбы»

Факультет искусственного интеллекта

(наименование основного учебного подразделения (ОУП)-разработчика ОП ВО)

РАБОЧАЯ ПРОГРАММА ДИСЦИПЛИНЫ

МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ

(наименование дисциплины/модуля)

Рекомендована МССН для направлений подготовки:

**02.03.02 ФУНДАМЕНТАЛЬНАЯ ИНФОРМАТИКА И ИНФОРМАЦИОННЫЕ
ТЕХНОЛОГИИ;**

09.03.03 ПРИКЛАДНАЯ ИНФОРМАТИКА

(код и наименование направления подготовки/специальности)

Освоение дисциплины ведется в рамках реализации основной профессиональной образовательной программы высшего образования (ОП ВО):

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ: РАЗРАБОТКА И ОБУЧЕНИЕ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ

(наименование (профиль/специализация) ОП ВО)

2026 г.

1. ЦЕЛЬ ОСВОЕНИЯ ДИСЦИПЛИНЫ

Дисциплина «Методы машинного обучения» входит в программу бакалавриата «Искусственный интеллект: разработка и обучение интеллектуальных систем» по направлениям подготовки 02.03.02 Фундаментальная информатика и информационные технологии и 09.03.03 Прикладная информатика, и изучается в 5, 6, 7, 8 семестрах 3, 4 курсов. Дисциплину реализует Кафедра прикладного искусственного интеллекта. Дисциплина состоит из 12 разделов и 144 тем и направлена на изучение теоретических основ и практических методов машинного обучения: математических моделей обучения по данным (PAC-learning, VC-размерность, bias-variance tradeoff), линейных моделей (регрессия, классификация), методов оптимизации (градиентный спуск и его вариации), ансамблевых методов (бэггинг, бустинг, стекинг), методов обучения без учителя (кластеризация, снижение размерности, обнаружение аномалий), вероятностных моделей (наивный Байес, EM-алгоритм, гауссовские смеси), методов работы с временными рядами и последовательными данными, основ обучения с подкреплением, а также промышленных практик разработки и эксплуатации ML-систем (MLOps, мониторинг, интерпретируемость, справедливость), применяемых на всех стадиях жизненного цикла ИИ-решений.

Целью освоения дисциплины является формирование у студентов системных знаний и практических навыков в области машинного обучения на уровне, достаточном для самостоятельного проектирования, реализации и эксплуатации ML-решений: от анализа осуществимости требований и подготовки данных до обучения моделей, оценки качества, развёртывания и мониторинга в промышленной среде, включая способность обосновывать выбор метода, оценивать компромиссы между метриками, обеспечивать воспроизводимость и справедливость, а также документировать весь процесс в соответствии с профессиональными стандартами.

2. ТРЕБОВАНИЯ К РЕЗУЛЬТАТАМ ОСВОЕНИЯ ДИСЦИПЛИНЫ

Освоение дисциплины «Методы машинного обучения» направлено на формирование у обучающихся следующих компетенций (части компетенций):

Таблица 2.1. Перечень компетенций, формируемых у обучающихся при освоении дисциплины (результаты освоения дисциплины)

Шифр	Компетенция	Индикаторы достижения компетенции (в рамках данной дисциплины)
УК-12	Способен: искать нужные источники информации и данные, воспринимать, анализировать, запоминать и передавать информацию с использованием цифровых средств, а также с помощью алгоритмов при работе с полученными из различных источников данными с целью эффективного использования полученной информации для решения задач; проводить оценку информации, ее достоверность, строить логические умозаключения на основании поступающих информации и данных	УК-12.2 Способен проводить оценку информации, ее достоверность, строить логические умозаключения на основании поступающих информации и данных;
ОПК-1	Способен применять фундаментальные знания,	ОПК-1.2 Умеет строить математические модели процессов и явлений, применять методы численного анализа и

Шифр	Компетенция	Индикаторы достижения компетенции (в рамках данной дисциплины)
	полученные в области математических и естественных наук, методы математического анализа и моделирования, теоретического и экспериментального исследования в профессиональной деятельности	оптимизации для решения задач машинного обучения и обработки данных; ОПК-1.3 Владеет навыками проведения вычислительных экспериментов, анализа их результатов и обоснования выбора математического аппарата для решения конкретных профессиональных задач в области ИИ;
ОПК-2	Способен понимать принципы работы современных информационных технологий и применять компьютерные методы, современное программное обеспечение, в том числе отечественного происхождения, для решения задач профессиональной деятельности	ОПК-2.2 Умеет применять современное программное обеспечение (в том числе отечественного происхождения), фреймворки машинного обучения и инструменты обработки данных для решения задач в области ИИ;
ОПК-3	Способен разрабатывать алгоритмические и программные решения в области системного и прикладного программирования, математических и информационных моделей, баз данных, средств тестирования, пригодные для практического применения	ОПК-3.3 Владеет навыками создания, тестирования и отладки алгоритмических и программных решений для систем ИИ, включая разработку пайплайнов обработки данных и обучения моделей;
ОПК-6	Способен анализировать и разрабатывать организационно-технические процессы с применением методов системного анализа, математического моделирования и технологий искусственного интеллекта	ОПК-6.2 Умеет анализировать предметную область с позиции системного подхода, определять требования к ИИ-системе, формализовывать бизнес-задачи в задачи машинного обучения;
ОПК-7	Способен решать задачи профессиональной деятельности на основе информационной культуры, применяя методы сбора, обработки, анализа и интерпретации данных с использованием информационно-коммуникационных технологий	ОПК-7.3 Владеет навыками подготовки данных для обучения моделей машинного обучения, оценки качества и репрезентативности обучающих выборок, документирования процессов работы с данными;
ПК-1	Способен анализировать требования к программному обеспечению систем ИИ, разрабатывать технические спецификации и техническое задание на систему	ПК-1.1 Анализирует возможности реализации функциональных и нефункциональных требований к ПО систем ИИ, выявляет противоречия и ограничения; ПК-1.2 Разрабатывает технические спецификации на программные компоненты систем ИИ и описывает их взаимодействие;
ПК-3	Способен разрабатывать и реализовывать стратегии тестирования и контроля качества программного обеспечения систем ИИ	ПК-3.1 Верифицирует требования к ПО систем ИИ, определяет требования к тестам и критерии приёмки; ПК-3.3 Оценивает результаты тестирования, реализует процесс контроля качества ПО систем ИИ;
ВД-1	Способен осуществлять поиск,	ВД-1.2 Обосновывает способы и варианты применения

Шифр	Компетенция	Индикаторы достижения компетенции (в рамках данной дисциплины)
	сбор, очистку и предварительный анализ данных	методов предварительного анализа данных в задачах ИИ, включая их математическое (алгоритмическое) преобразование и адаптацию к специфике задачи; BD-1.3 Применяет методы анализа данных для проверки разведочных гипотез и подготовки данных к применению современных методов ИИ; BD-1.4 Применяет методы понижения размерности для первичной интерпретации и визуализации многомерных данных; BD-1.5 Отбирает признаки данных, значимые для исследования;
BD-2	Способен определять требования к наборам данных для решения задач машинного обучения, проводить разметку и анализ наборов данных, оценивать качество данных, обеспечивать непрерывную интеграцию данных	BD-2.1 Определяет требования к наборам и качеству данных для решения задач машинного обучения;
FC-1	Способен проводить передовые исследования в области архитектур, алгоритмов МО, оптимизации и математики	FC-1.1 Разрабатывает фундаментальные основы и новые алгоритмы машинного обучения;
FC-5	Способен проводить передовые исследования в области безопасности, доверия и объяснимости	FC-5.2 Обеспечивает объяснения причин принятия тех или иных решений в результатах работы искусственного интеллекта;
LC-1	Способен проводить анализ бизнес-проблем с оценкой перспективности применения ИИ для их решения, осуществлять постановку задачи, формулировать требования к системе ИИ	LC-1.2 Выбирает оптимальные технологии под конкретные требования проекта внедрения ИИ;
LC-2	Способен проводить эксперименты на данных, формулировать гипотезы исследования, строить (обучать, дообучать) модели ИИ с оценкой их качества и анализом ошибок, обеспечивать воспроизводимость и масштабируемость исследований на данных	LC-2.1 Проводит эксперименты с моделями ИИ, оценивает их качество (точность, производительность); LC-2.2 Проводит эксперименты на данных и визуализирует результаты с применением технологий анализа данных (статистического анализа), методов и алгоритмов МО;
MF-1	Способен применять современную теоретическую математику для разработки новых алгоритмов и формулирования перспективных задач ИИ	MF-1.1 Обосновывает способы и варианты применения методов и моделей в задачах искусственного интеллекта, включая их модификацию и адаптацию к специфике задачи; MF-1.3 Применяет аппарат теории вероятностей для исследования методов и моделей машинного обучения;
MF-3	Способен применять современные методы оптимизации для обучения моделей машинного обучения, настройки гиперпараметров и решения задач искусственного интеллекта	MF-3.2 Применяет методы оптимизации для настройки гиперпараметров моделей машинного обучения, включая использование методов поиска (поиск по сетке, случайный поиск) и байесовской оптимизации;
MF-4	Способен применять статистические методы для анализа данных, валидации	MF-4.1 Применяет статистические методы анализа и машинного обучения для решения задач анализа данных и проведения экспериментов на данных;

Шифр	Компетенция	Индикаторы достижения компетенции (в рамках данной дисциплины)
	моделей машинного обучения и проведения экспериментов в области ИИ	MF-4.2 Способен применять статистические методы для построения предсказательных моделей, включая методы для анализа и прогнозирования временных рядов, а также моделирования нестационарных случайных процессов; MF-4.3 Способен применять статистические методы для оценки качества моделей ИИ, включая метрики и критерии для регрессии, классификации и кластеризации, а также для проведения статистических тестов для сравнения моделей;
ML-2	Способен применять фундаментальные принципы и методы машинного обучения, включая подготовку данных, оценку качества моделей и работу с признаками	ML-2.1 Различает основные типы задач МО и применяет на практике принципы их решения; ML-2.2 Применяет методы предварительной обработки данных и работы с признаками; ML-2.3 Решает проблемы несбалансированных данных и оценивает качество моделей;
ML-3	Способен применять классические алгоритмы машинного обучения с пониманием их математических основ и областей применения	ML-3.1 Обосновывает способы и варианты применения классических методов и моделей МО в задачах ИИ, включая их математическое (алгоритмическое) преобразование и адаптацию к специфике задачи; ML-3.2 Эффективно применяет классические методы и модели МО для обеспечения достижимости функциональных характеристик систем ИИ; ML-3.3 Оценивает результативность применения классических методов и моделей МО в задачах ИИ на основе сопоставления с аналогами;
ML-4	Способен применять методы обучения без учителя для анализа данных и выявления скрытых закономерностей	ML-4.1 Применяет алгоритмы кластеризации и понижения размерности для решения практических задач; ML-4.2 Выявляет аномалии и применяет методы поиска ассоциативных правил; ML-4.3 Оценивает качество результатов обучения без учителя;
ML-6	Способен применять алгоритмы обучения с подкреплением	ML-6.1 Обосновывает способы и варианты применения алгоритмов обучения с подкреплением в задачах ИИ, включая их преобразование и адаптацию к специфике задачи;
PL-1	Способен применять язык программирования Python для решения задач в области ИИ	PL-1.2 Осуществляет выбор инструментов разработки на Python, приемлемых для создания прикладной системы обработки научных данных, машинного обучения и визуализации с заданными требованиями;
SS-1	Способен учитывать философские, когнитивные и социальные основания концепций ИИ в профессиональной деятельности	SS-1.1 Учитывает в разработке и эксплуатации систем ИИ философские основания концепций интеллекта, языка, знания, агентности; SS-1.2 Применяет методики работы с этическими и социальными рисками, возникающими на разных стадиях жизненного цикла ИИ;
SS-3	Способен к критическому анализу, метарефлексии и переносу знаний при работе с системами ИИ	SS-3.1 Учитывает в работе когнитивные искажения человека и примеры их проявления при работе с данными и ИИ, выявляет предвзятости систем ИИ, аргументированно оценивает надежность данных и выдачи ИИ, применяет базовые принципы критического мышления (оценка источников, проверка аргументов, отличие факта от интерпретации); SS-3.2 Определяет релевантность применения ИИ для решения конкретных задач, анализирует поведение ИИ в техническом, социальном и правовом контекстах, переносит идеи и методы за пределы исходной предметной области;

3. МЕСТО ДИСЦИПЛИНЫ В СТРУКТУРЕ ОП ВО

Дисциплина «Методы машинного обучения» относится к обязательной части блока 1 «Дисциплины (модули)» образовательной программы высшего образования.

В рамках образовательной программы высшего образования обучающиеся также осваивают другие дисциплины и/или практики, способствующие достижению запланированных результатов освоения дисциплины «Методы машинного обучения».

Таблица 3.1. Перечень компонентов ОП ВО, способствующих достижению запланированных результатов освоения дисциплины

Шифр	Наименование компетенции	Предшествующие дисциплины/модули, практики*	Последующие дисциплины/модули, практики*
УК-12	Способен: искать нужные источники информации и данные, воспринимать, анализировать, запоминать и передавать информацию с использованием цифровых средств, а также с помощью алгоритмов при работе с полученными из различных источников данными с целью эффективного использования полученной информации для решения задач; проводить оценку информации, ее достоверность, строить логические умозаключения на основании поступающих информации и данных	Программирование на языке Python; Введение в искусственный интеллект; Методы разработки решений на основе искусственного интеллекта (Git, Docker); Введение в базы данных; Статистические методы и первичный анализ данных; Технологическая (проектно-технологическая) практика (учебная); Эксплуатационная практика (учебная);	
ОПК-6	Способен анализировать и разрабатывать организационно-технические процессы с применением методов системного анализа, математического моделирования и технологий искусственного интеллекта	Введение в искусственный интеллект; Искусственный интеллект и когнитивная психология; Этика и безопасность использования искусственного интеллекта;	
ОПК-1	Способен применять фундаментальные знания, полученные в области математических и естественных наук, методы математического анализа и моделирования, теоретического и экспериментального исследования в профессиональной деятельности	Линейная алгебра; Дискретная математика; Математический анализ; Теория вероятностей и математическая статистика; Дифференциальные уравнения; Численная линейная алгебра; Статистические методы и первичный анализ данных;	
ОПК-2	Способен понимать принципы работы современных информационных технологий и применять компьютерные методы, современное программное	История и теория программирования; Введение в искусственный интеллект; Программирование на языке Python;	

Шифр	Наименование компетенции	Предшествующие дисциплины/модули, практики*	Последующие дисциплины/модули, практики*
	обеспечение, в том числе отечественного происхождения, для решения задач профессиональной деятельности		
ОПК-3	Способен разрабатывать алгоритмические и программные решения в области системного и прикладного программирования, математических и информационных моделей, баз данных, средств тестирования, пригодные для практического применения	Дискретная математика; История и теория программирования; Программирование на языке C++; Алгоритмы и структуры данных; Введение в базы данных; Программирование на языке Python; Методы разработки решений на основе искусственного интеллекта (Git, Docker); Технологическая (проектно-технологическая) практика (учебная);	
ОПК-7	Способен решать задачи профессиональной деятельности на основе информационной культуры, применяя методы сбора, обработки, анализа и интерпретации данных с использованием информационно-коммуникационных технологий	Технологическая (проектно-технологическая) практика (учебная); Теория вероятностей и математическая статистика; Статистические методы и первичный анализ данных; Введение в базы данных;	
ПК-1	Способен анализировать требования к программному обеспечению систем ИИ, разрабатывать технические спецификации и техническое задание на систему	Эксплуатационная практика (учебная); Технологическая (проектно-технологическая) практика (учебная); Правоведение; Введение в искусственный интеллект; Искусственный интеллект и когнитивная психология; Этика и безопасность использования искусственного интеллекта; История и теория программирования; Программирование на языке C++; Методы разработки решений на основе искусственного интеллекта (Git, Docker); Введение в базы данных;	
ПК-3	Способен разрабатывать и реализовывать стратегии тестирования и контроля качества программного обеспечения систем ИИ	Технологическая (проектно-технологическая) практика (учебная); Эксплуатационная практика (учебная); Теория вероятностей и математическая статистика; Этика и безопасность использования искусственного	

Шифр	Наименование компетенции	Предшествующие дисциплины/модули, практики*	Последующие дисциплины/модули, практики*
		интеллекта; Статистические методы и первичный анализ данных; Программирование на языке Python; Методы разработки решений на основе искусственного интеллекта (Git, Docker);	
SS-1	Способен учитывать философские, когнитивные и социальные основания концепций ИИ в профессиональной деятельности	История и теория программирования; Введение в искусственный интеллект; Искусственный интеллект и когнитивная психология; Лингвистические основы анализа естественного языка; Этика и безопасность использования искусственного интеллекта;	
SS-3	Способен к критическому анализу, метарефлексии и переносу знаний при работе с системами ИИ	Эксплуатационная практика (учебная); Теория вероятностей и математическая статистика; Искусственный интеллект и когнитивная психология; Этика и безопасность использования искусственного интеллекта; Статистические методы и первичный анализ данных; Правоведение; Введение в искусственный интеллект; Введение в компьютерное зрение;	
MF-1	Способен применять современную теоретическую математику для разработки новых алгоритмов и формулирования перспективных задач ИИ	Линейная алгебра; Математический анализ; Теория вероятностей и математическая статистика; Статистические методы и первичный анализ данных; Эксплуатационная практика (учебная);	
MF-3	Способен применять современные методы оптимизации для обучения моделей машинного обучения, настройки гиперпараметров и решения задач искусственного интеллекта	Эксплуатационная практика (учебная); Численная линейная алгебра;	
MF-4	Способен применять статистические методы для анализа данных, валидации моделей машинного обучения и проведения экспериментов в области ИИ	Теория вероятностей и математическая статистика; Статистические методы и первичный анализ данных; Дифференциальные уравнения;	
BD-1	Способен осуществлять	Эксплуатационная практика	

Шифр	Наименование компетенции	Предшествующие дисциплины/модули, практики*	Последующие дисциплины/модули, практики*
	поиск, сбор, очистку и предварительный анализ данных	(учебная); Статистические методы и первичный анализ данных;	
BD-2	Способен определять требования к наборам данных для решения задач машинного обучения, проводить разметку и анализ наборов данных, оценивать качество данных, обеспечивать непрерывную интеграцию данных	Статистические методы и первичный анализ данных; Введение в базы данных; Методы разработки решений на основе искусственного интеллекта (Git, Docker); Технологическая (проектно-технологическая) практика (учебная);	
ML-2	Способен применять фундаментальные принципы и методы машинного обучения, включая подготовку данных, оценку качества моделей и работу с признаками	Введение в искусственный интеллект; Статистические методы и первичный анализ данных;	
ML-3	Способен применять классические алгоритмы машинного обучения с пониманием их математических основ и областей применения	Эксплуатационная практика (учебная);	
ML-4	Способен применять методы обучения без учителя для анализа данных и выявления скрытых закономерностей		
ML-6	Способен применять алгоритмы обучения с подкреплением		
PL-1	Способен применять язык программирования Python для решения задач в области ИИ	Технологическая (проектно-технологическая) практика (учебная); Программирование на языке Python; Алгоритмы и структуры данных; Статистические методы и первичный анализ данных;	
LC-1	Способен проводить анализ бизнес-проблем с оценкой перспективности применения ИИ для их решения, осуществлять постановку задачи, формулировать требования к системе ИИ	Введение в искусственный интеллект; Технологическая (проектно-технологическая) практика (учебная);	
LC-2	Способен проводить эксперименты на данных, формулировать гипотезы исследования, строить (обучать, дообучать) модели ИИ с оценкой их качества и анализом ошибок, обеспечивать	Эксплуатационная практика (учебная); Статистические методы и первичный анализ данных;	

Шифр	Наименование компетенции	Предшествующие дисциплины/модули, практики*	Последующие дисциплины/модули, практики*
	воспроизводимость и масштабируемость исследований на данных		
FC-1	Способен проводить передовые исследования в области архитектур, алгоритмов МО, оптимизации и математики	Эксплуатационная практика (учебная); Линейная алгебра; Математический анализ; Теория вероятностей и математическая статистика; Введение в искусственный интеллект; Численная линейная алгебра;	
FC-5	Способен проводить передовые исследования в области безопасности, доверия и объяснимости	Эксплуатационная практика (учебная); Правоведение; Этика и безопасность использования искусственного интеллекта;	

* - заполняется в соответствии с матрицей компетенций и СУП ОП ВО

** - элективные дисциплины /практики

4. ОБЪЕМ ДИСЦИПЛИНЫ И ВИДЫ УЧЕБНОЙ РАБОТЫ

Общая трудоемкость дисциплины «Методы машинного обучения» составляет «15» зачетных единиц.

Таблица 4.1. Виды учебной работы по периодам освоения образовательной программы высшего образования для очной формы обучения.

Вид учебной работы	ВСЕГО, ак.ч.		Семестр(-ы)			
			5	6	7	8
<i>Контактная работа, ак.ч.</i>	291		85	85	65	56
Лекции (ЛК)	61		17	17	13	14
Лабораторные работы (ЛР)	0		0	0	0	0
Практические/семинарские занятия (СЗ)	230		68	68	52	42
<i>Самостоятельная работа обучающихся, ак.ч.</i>	168		32	68	16	52
<i>Контроль (экзамен/зачет с оценкой), ак.ч.</i>	81		27	27	27	0
Общая трудоемкость дисциплины	ак.ч.	540	144	180	108	108
	зач.ед.	15	4	5	3	3

5. СОДЕРЖАНИЕ ДИСЦИПЛИНЫ

Таблица 5.1. Содержание дисциплины (модуля) по видам учебной работы

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
Раздел 1	Введение в машинное обучение и линейные модели	1.1	Введение в машинное обучение. Типы задач и постановка	Определение ML. Типы задач: обучение с учителем (регрессия, классификация), без учителя (кластеризация, снижение размерности), с подкреплением. Формализация: пространство признаков, целевая переменная, гипотеза, функция потерь. Этапы ML-проекта: постановка задачи → данные → модель → оценка → развёртывание. Анализ осуществимости: когда ML подходит, а когда нет	ЛК	MF-1.1, ML-2.1, ПК-1.1
		1.2	Теоретические основы обучения: bias-variance, обобщающая способность	Bias-variance tradeoff: декомпозиция ошибки. Переобучение (overfitting) и недообучение (underfitting). Тренировочная и тестовая ошибки. Обобщающая способность. Регуляризация как способ борьбы с переобучением. PAC-learning и VC-размерность (обзор). Проклятие размерности. Связь с объёмом данных и сложностью модели	ЛК	MF-1.1, MF-1.3, FC-1.1
		1.3	Линейная регрессия и градиентный спуск	Линейная регрессия: модель, функция потерь MSE, нормальные уравнения. Градиентный спуск: идея, learning rate, сходимость. Стохастический GD и мини-батч GD. Регуляризация: Ridge (L2), Lasso (L1), Elastic Net. Полиномиальная регрессия. MLE-интерпретация линейной регрессии	ЛК	MF-1.3, MF-3.2, ОПК-1.2
		1.4	Практикум: EDA и подготовка данных для ML	Загрузка реального датасета (Boston Housing / California Housing). EDA: описательная статистика, визуализация распределений, корреляция. Обработка пропусков и выбросов. Масштабирование: StandardScaler, MinMaxScaler. Train/test split. Фиксация random seed для воспроизводимости	СЗ	BD-1.2, BD-1.3, LC-2.2
		1.5	Практикум: линейная регрессия — реализация с нуля	Реализация линейной регрессии на NumPy: нормальные уравнения, градиентный спуск. Визуализация: ландшафт функции потерь, траектория GD. Влияние learning rate: слишком большой, слишком маленький. Сравнение с sklearn.linear_model.LinearRegression	СЗ	MF-3.2, ОПК-1.3
		1.6	Практикум: регуляризация и полиномиальные признаки	Ridge и Lasso на sklearn. Влияние параметра α : кривые обучения. Lasso для отбора признаков: анализ нулевых	СЗ	MF-1.3, BD-1.4,

Номер раздела	Наименование раздела дисциплины	Наименование темы	Содержание темы	Вид учебной работы *	Формируемые индикаторы
			коэффициентов. Полиномиальные признаки (PolynomialFeatures): от недообучения к переобучению. Визуализация bias-variance tradeoff на примере полиномиальной регрессии		MF-4.1
		1.7 Практикум: метрики регрессии и валидация	Метрики: MSE, RMSE, MAE, R^2 , MAPE. Кросс-валидация: k-fold, Leave-One-Out. Кривые обучения (learning curves): диагностика переобучения/недообучения. Выбор гиперпараметров: GridSearchCV, RandomizedSearchCV. Практика: выбор лучшей модели для датасета с обоснованием	СЗ	ML-2.2, ПК-3.1, ОПК-1.3
		1.8 Практикум: логистическая регрессия — теория и реализация	Задача бинарной классификации. Логистическая функция (сигмоида). Функция потерь: бинарная кросс-энтропия. Вывод из MLE. Градиентный спуск для логистической регрессии. Реализация на NumPy. Разделяющая гиперплоскость. Многоклассовая: One-vs-Rest, Softmax	СЗ	MF-1.3, MF-3.2, ML-2.1
		1.9 Практикум: метрики классификации	Матрица ошибок (confusion matrix). Accuracy, Precision, Recall, F1-score. Macro/Micro/Weighted averaging. ROC-кривая и AUC. Precision-Recall кривая. Порог принятия решения: выбор порога для бизнес-задачи. Практика: оценка модели на несбалансированном датасете	СЗ	ML-2.2, SS-3.1, ПК-3.1
		1.10 Практикум: работа с несбалансированными классами	Проблема дисбаланса: влияние на метрики. Стратегии: oversampling (SMOTE), undersampling, class weights. Стратифицированная кросс-валидация. Выбор метрики: F1 vs. AUC-PR. Практика: сравнение стратегий на датасете с дисбалансом 1:50 (fraud detection)	СЗ	BD-1.5, ML-2.2, SS-3.1
		1.11 Практикум: SVM — метод опорных векторов	Линейный SVM: максимальный зазор, опорные векторы. Мягкий зазор (soft margin): параметр C. Ядровый трюк: полиномиальное, RBF. Параметр γ в RBF. Практика: визуализация разделяющей границы для разных ядер. Подбор C и γ . Сравнение SVM с логистической регрессией	СЗ	ML-2.1, MF-1.3
		1.12 Практикум: метод k ближайших соседей (k-NN)	k-NN: принцип, метрики расстояния (евклидова, манхэттенская, Минковского). Выбор k: bias-variance. Взвешенный k-NN. Проклятие размерности для k-NN. KD-tree и Ball-tree для ускорения. Практика: классификация и регрессия с k-NN, визуализация границ решений	СЗ	ML-2.1, MF-4.1

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
		1.13	Практикум: pipelines в scikit-learn	sklearn.pipeline.Pipeline: цепочка трансформаций и модели. ColumnTransformer для разных типов признаков. Интеграция предобработки в кросс-валидацию (предотвращение утечки данных). Сохранение пайплайна (joblib). Практика: создание полного пайплайна для реального датасета	СЗ	ML-3.1, ОПК-3.3, ПК-1.2
		1.14	Практикум: воспроизводимость и документирование экспериментов	Фиксация random seed. Версионирование данных и кода. Логирование экспериментов: MLflow Tracking (обзор). Структура отчёта по эксперименту: задача, данные, метод, метрики, выводы. Model Card (шаблон). Практика: проведение эксперимента с логированием в MLflow	СЗ	LC-2.2, LC-1.2, FC-5.2
		1.15	Практикум: мини-проект — сравнение линейных моделей	Сквозная задача: реальный датасет → EDA → предобработка → обучение нескольких моделей (LinearRegression, Ridge, Lasso, LogisticRegression, SVM, k-NN) → кросс-валидация → сравнение → выбор → документирование. Обоснование выбора модели	СЗ	ML-2.2, ПК-3.3, LC-2.1
Раздел 2	Деревья решений и ансамблевые методы	2.1	Деревья решений: принцип и алгоритмы	Дерево решений: структура (узлы, рёбра, листья). Критерии разбиения: Gini impurity, информационный выигрыш (энтропия), MSE для регрессии. Алгоритмы: CART, ID3, C4.5. Регуляризация деревьев: max_depth, min_samples_split, min_samples_leaf, max_features. Pruning (обзор). Интерпретируемость деревьев: feature importance	ЛК	ML-2.1, MF-1.3, ОПК-6.2
		2.2	Ансамблевые методы: бэггинг и случайный лес	Идея ансамблирования: «мудрость толпы». Бэггинг (Bootstrap Aggregating): бутстрэп-выборки, агрегация предсказаний. Случайный лес (Random Forest): бэггинг + случайный подвыбор признаков. Out-of-Bag оценка. Feature importance: impurity-based и permutation importance. Параметры: n_estimators, max_features, max_depth	ЛК	ML-2.1, ML-2.3, MF-4.1
		2.3	Ансамблевые методы: бустинг	Бустинг: идея последовательного обучения «слабых» моделей. AdaBoost: перевзвешивание примеров. Градиентный бустинг (GBM): аппроксимация антиградиента. XGBoost: регуляризация, гистограммный метод, параллелизация. LightGBM: leaf-wise growth, эффективность. CatBoost: обработка категорий, ordered boosting. Сравнение библиотек	ЛК	ML-2.1, ML-2.3, ОПК-2.2

Номер раздела	Наименование раздела дисциплины	Наименование темы	Содержание темы	Вид учебной работы *	Формируемые индикаторы	
		2.4	Практикум: деревья решений — обучение и визуализация	Обучение DecisionTreeClassifier/Regressor. Визуализация дерева (plot_tree, export_graphviz). Влияние глубины на переобучение. Feature importance. Практика: обучение дерева для задачи классификации, анализ правил принятия решений	СЗ	ML-2.1, ОПК-6.2
		2.5	Практикум: Random Forest — обучение и настройка	Обучение RandomForestClassifier. Влияние n_estimators: кривая OOB-error. Влияние max_features. Feature importance: impurity vs. permutation. Практика: сравнение дерева и леса по метрикам и устойчивости. Partial dependence plots (PDP)	СЗ	ML-2.1, ML-2.3
		2.6	Практикум: XGBoost — обучение и тонкая настройка	Установка XGBoost. Основные параметры: n_estimators, max_depth, learning_rate, subsample, colsample_bytree, reg_alpha, reg_lambda. Early stopping: eval_set, early_stopping_rounds. Практика: подбор гиперпараметров (Optuna / RandomizedSearchCV). Кривые обучения	СЗ	ML-2.3, MF-3.2
		2.7	Практикум: LightGBM и CatBoost	LightGBM: leaf-wise vs. depth-wise, num_leaves, обработка категориальных признаков. CatBoost: встроенная обработка категорий, ordered boosting, Pool. Практика: сравнение XGBoost, LightGBM, CatBoost на одном датасете по метрикам и времени обучения	СЗ	ML-2.3, ОПК-2.2
		2.8	Практикум: стекинг и блендинг	Стекинг (Stacking): мета-модель поверх базовых. Реализация: StackingClassifier в sklearn. Блендинг: holdout set для метапризнаков. Многоуровневый стекинг. Практика: построение стекинга из RF + XGBoost + LightGBM, сравнение с отдельными моделями	СЗ	ML-2.3, ML-4.1
		2.9	Практикум: подбор гиперпараметров — Optuna	Подходы: GridSearch, RandomSearch, байесовская оптимизация. Optuna: study, trial, suggest_float/int/categorical. Pruning неперспективных испытаний. Визуализация: importance plot, optimization history. Практика: оптимизация гиперпараметров GBM на реальном датасете	СЗ	ML-3.2, MF-3.2
		2.10	Практикум: feature engineering для табличных данных	Создание признаков: взаимодействия, агрегаты, полиномиальные. Target encoding для категорий. Работа с датами: выделение компонентов, циклические признаки. Feature selection: mutual information, permutation importance, Boruta. Практика: feature engineering для соревновательного датасета	СЗ	BD-1.4, ML-3.1, MF-4.1

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
		2.11	Практикум: интерпретируемость ансамблей — SHAP	SHAP (SHapley Additive exPlanations): теоретическая основа (значения Шепли). TreeSHAP для деревьев. SHAP summary plot, dependence plot, waterfall plot, force plot. Глобальная и локальная интерпретируемость. Практика: анализ предсказаний модели GBM с помощью SHAP	СЗ	ОПК-6.2, SS-3.2, ML-6.1
		2.12	Практикум: анализ ошибок модели	Error analysis: на каких примерах модель ошибается? Построение confusion matrix по подгруппам. Визуализация ошибочных примеров. Residual analysis для регрессии. Связь ошибок с качеством данных. Формулирование рекомендаций по улучшению	СЗ	ПК-3.3, ML-2.2, SS-3.1
		2.13	Практикум: формулирование критериев приёмки ML-модели	Трансляция бизнес-требований в метрики ML. Пороги метрик. Тестирование на edge cases. Регрессионные тесты модели. Составление плана тестирования: unit-тесты пайплайна, тесты данных, тесты метрик. Документирование: техническая спецификация ML-компонента	СЗ	ПК-3.1, ПК-1.2, LC-2.1
		2.14	Практикум: Kaggle-соревнование по табличным данным	Участие в мини-соревновании: реальный датасет, фиксированная метрика, лидерборд. Полный цикл: EDA → feature engineering → модели → ансамбль → подбор гиперпараметров → submission. Ретроспектива: что сработало, что нет. Обсуждение: соревнования vs. промышленная разработка	СЗ	ML-4.2, ML-4.3, ОПК-7.3
Раздел 3	Обучение без учителя: кластеризация и снижение размерности	3.1	Кластеризация: методы и метрики	Задача кластеризации. K-Means: алгоритм, инициализация (k-means++), выбор k (метод локтя, силуэтный анализ). Иерархическая кластеризация: агломеративная, дендрограмма, linkage. DBSCAN: плотностная кластеризация, параметры eps и min_samples. Метрики: Silhouette, Calinski-Harabasz, Davies-Bouldin; внешние: ARI, NMI	ЛК	ML-2.1, MF-4.1
		3.2	Снижение размерности: PCA, t-SNE, UMAP	PCA: ковариационная матрица, собственные значения, доля объяснённой дисперсии, выбор числа компонент. Связь с SVD. t-SNE: принцип, перплексия, ограничения (нетранзитивность расстояний, непригодность для новых точек). UMAP: преимущества над t-SNE (скорость, глобальная структура). Применение: визуализация,	ЛК	MF-4.1, PL-1.2, ML-2.1

Номер раздела	Наименование раздела дисциплины	Наименование темы	Содержание темы	Вид учебной работы *	Формируемые индикаторы
			предобработка, обнаружение аномалий		
		3.3 Практикум: K-Means — реализация и визуализация	Реализация K-Means на NumPy. sklearn KMeans. Метод локтя (inertia plot). Силуэтный анализ (silhouette_samples). Визуализация кластеров в 2D. Mini-batch K-Means для больших данных. Практика: сегментация клиентов по поведенческому поведению	СЗ	ML-2.1, MF-4.1
		3.4 Практикум: иерархическая кластеризация	Агломеративная кластеризация: single, complete, average, Ward linkage. Построение и анализ дендрограммы (scipy.cluster.hierarchy). Выбор числа кластеров по дендрограмме. Сравнение с K-Means. Практика: кластеризация текстов по TF-IDF с визуализацией дендрограммы	СЗ	ML-2.1, MF-4.1
		3.5 Практикум: DBSCAN и плотностная кластеризация	DBSCAN: core points, border points, noise. Выбор eps (k-distance plot) и min_samples. Преимущества: произвольная форма кластеров, обнаружение выбросов. HDBSCAN (обзор). Практика: кластеризация геоданных (GPS-точки), обнаружение аномалий	СЗ	ML-2.1, BD-1.5
		3.6 Практикум: PCA — анализ и визуализация	PCA в sklearn: fit_transform, explained_variance_ratio_. Визуализация в пространстве первых двух компонент. Biplot: проекция признаков. Выбор числа компонент: scree plot, порог дисперсии. PCA как предобработка для классификации. Практика: PCA для датасета с большим числом признаков	СЗ	MF-4.1, PL-1.2
		3.7 Практикум: t-SNE и UMAP для визуализации	t-SNE: влияние perplexity, n_iter. Визуализация MNIST, Fashion-MNIST. UMAP: параметры n_neighbors, min_dist. Сравнение: PCA vs. t-SNE vs. UMAP по сохранению структуры. Практика: визуализация эмбедингов и кластеров высокоразмерных данных	СЗ	PL-1.2, ML-2.1
		3.8 Практикум: обнаружение аномалий	Подходы: статистические (z-score, IQR), модельные (Isolation Forest, Local Outlier Factor, One-Class SVM). Isolation Forest: принцип, параметры. LOF: плотностный подход. Метрики: precision/recall при наличии меток, визуальная оценка. Практика: обнаружение мошенничества в транзакциях	СЗ	ML-2.1, BD-1.5, MF-4.1
		3.9 Практикум: гауссовские смеси и EM-	GMM: модель, параметры (средние, ковариации, веса). EM-	СЗ	MF-1.3,

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
			алгоритм	алгоритм: E-шаг, M-шаг, сходимость. Выбор числа компонент: BIC, AIC. Мягкая кластеризация: вероятности принадлежности. Сравнение с K-Means. Практика: кластеризация с GMM, визуализация вероятностных границ		ML-2.1
		3.10	Практикум: кластеризация текстов	TF-IDF для векторизации текстов. Кластеризация: K-Means на TF-IDF. Визуализация: PCA/UMAP проекция кластеров. Определение тем кластеров по ключевым словам. Сравнение с LDA (Latent Dirichlet Allocation, обзор). Практика: тематическая кластеризация новостей	СЗ	ML-2.1, MF-4.2
		3.11	Практикум: оценка и сравнение методов кластеризации	Сравнение K-Means, иерархического, DBSCAN, GMM на нескольких датасетах с разной структурой (шары, полумесяцы, кольца, зашумлённые). Метрики: Silhouette, ARI (при наличии меток). Визуализация результатов. Критерии выбора метода в зависимости от задачи	СЗ	ML-2.2, SS-3.1
		3.12	Практикум: применение снижения размерности в ML-пайплайне	PCA как этап предобработки: PCA + логистическая регрессия. Выбор числа компонент через кросс-валидацию. Ускорение обучения при высокой размерности. Практика: Pipeline(PCA → Classifier), сравнение с обучением без PCA	СЗ	ML-3.1, MF-4.1
		3.13	Практикум: итоговый проект семестра 5 — полный ML-пайплайн	Сквозная задача: реальный датасет → EDA → предобработка (Pipeline) → обучение нескольких моделей (линейные, деревья, ансамбли, кластеризация) → оценка → интерпретация (SHAP) → документирование (Model Card, отчёт). Презентация с обоснованием решений	СЗ	ML-4.1, ПК-3.3, LC-2.1
Раздел 4	Продвинутые методы обучения с учителем	4.1	Наивный байесовский классификатор и вероятностные модели	Наивный Байес: предположение условной независимости. Гауссов, мультиномиальный, Бернулли NB. Оценка параметров MLE, сглаживание Лапласа. Применения: спам-фильтрация, классификация текстов. Связь с генеративными и дискриминативными моделями	ЛК	MF-1.3, ML-2.1, FC-1.1
		4.2	Многоклассовая и многометочная классификация	Стратегии многоклассовой классификации: One-vs-Rest, One-vs-One, Softmax. Многометочная (multi-label): Binary Relevance, Classifier Chains. Иерархическая классификация (обзор). Метрики: multi-class accuracy, macro/micro F1, Hamming loss, subset accuracy. Калибровка вероятностей: Platt scaling, isotonic regression	ЛК	ML-2.1, ML-2.2, SS-3.1
		4.3	Методы отбора и генерации признаков	Фильтрующие методы: корреляция, mutual information, chi-	ЛК	BD-1.4,

Номер раздела	Наименование раздела дисциплины	Наименование темы	Содержание темы	Вид учебной работы *	Формируемые индикаторы
			squared, ANOVA F-test. Обёрточные: forward selection, backward elimination, recursive feature elimination (RFE). Встроенные: L1, feature importance. Генерация: PolynomialFeatures, target encoding, aggregation features. Feature store: концепция хранения признаков. AutoML feature generation (обзор: Featuretools)		ML-3.1, BD-2.1
		4.4 Практикум: наивный Байес для текстовой классификации	Загрузка текстового датасета (20 Newsgroups). Векторизация: CountVectorizer, TfidfVectorizer. Обучение MultinomialNB. Оценка: accuracy, F1, confusion matrix. Визуализация наиболее информативных слов. Сравнение с логистической регрессией	СЗ	ML-2.1, MF-1.3
		4.5 Практикум: калибровка вероятностей	Проверка калибровки: calibration_curve. Reliability diagram. Методы: CalibratedClassifierCV (Platt, isotonic). Brier score. Практика: калибровка GBM, сравнение до/после. Обсуждение: когда нужна калибровка (медицина, финансы, скоринг)	СЗ	ML-2.2, SS-3.2
		4.6 Практикум: multi-label классификация	Преобразование задачи: MultiOutputClassifier, ClassifierChain. Метрики: Hamming loss, subset accuracy, macro F1. Практика: multi-label классификация на датасете тегов (фильмы, статьи). Сравнение стратегий	СЗ	ML-2.1, ML-2.2
		4.7 Практикум: recursive feature elimination и отбор признаков	RFE (sklearn): пошаговый отбор. RFECV: RFE с кросс-валидацией. Сравнение с mutual_info, permutation importance. SelectKBest, SelectFromModel. Практика: отбор признаков для датасета с > 100 признаками, оценка влияния на качество модели	СЗ	BD-1.4, ML-3.1
		4.8 Практикум: автоматическая генерация признаков (Featuretools)	Featuretools: entity sets, relationships, deep feature synthesis. Примитивы: aggregation (mean, count, max), transform (month, year, haversine). Практика: автоматическая генерация признаков для реляционного датасета. Отбор полезных из сгенерированных. Сравнение с ручным feature engineering	СЗ	BD-1.4, ML-3.1, BD-2.1
		4.9 Практикум: метрики для различных бизнес-задач	Выбор метрики для конкретной задачи: кредитный скоринг (precision@threshold), медицинская диагностика (recall), рекомендации (NDCG@K, MAP@K). Пользовательские функции потерь. Cost-sensitive learning. Практика: анализ	СЗ	ML-2.2, ПК-1.1, SS-3.1

Номер раздела	Наименование раздела дисциплины	Наименование темы	Содержание темы	Вид учебной работы *	Формируемые индикаторы
			трёх задач, обоснование выбора метрики, настройка порога		
		4.10	Практикум: обработка категориальных признаков высокой кардинальности	СЗ	BD-1.3, ML-3.1
		4.11	Практикум: работа с пропусками — продвинутые методы	СЗ	BD-1.3, ML-3.1
		4.12	Практикум: утечка данных (data leakage) — обнаружение и предотвращение	СЗ	ML-4.3, BD-1.2, SS-3.1
		4.13	Практикум: cross-validation — продвинутые стратегии	СЗ	ML-4.3, ОПК-1.3
		4.14	Практикум: спецификация ML-компонента	СЗ	ПК-1.2, LC-2.1, ML-3.1
		4.15	Практикум: мини-проект — ML-решение для бизнес-задачи	СЗ	ML-4.1, ПК-1.1, ПК-3.3
Раздел 5	Обучение без учителя:	5.1	Матричные разложения и тематические	ЛК	MF-4.2,

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
	продвинутые методы и тематические модели		модели	Применение: тематическое моделирование, рекомендации. LDA (Latent Dirichlet Allocation): генеративная модель тем, гиббсовский сэмплинг (обзор). Сравнение NMF и LDA. Embedding-based методы: BERTopic (обзор). Когерентность тем (coherence score)		ML-2.1
		5.2	Рекомендательные системы	Коллаборативная фильтрация: user-based, item-based. Матричная факторизация: SVD, ALS. Контентная фильтрация: TF-IDF + cosine similarity. Гибридные подходы. Implicit feedback: BPR (обзор). Метрики: Precision@K, Recall@K, NDCG@K, MAP@K. Проблема холодного старта	ЛК	ML-2.1, MF-4.2, BD-2.1
		5.3	Semi-supervised и self-supervised learning	Semi-supervised: label propagation, pseudo-labeling, co-training. Мотивация: дорогая разметка, малая доля размеченных данных. Self-supervised: pretext tasks, contrastive learning (обзор). Связь с transfer learning и foundation models	ЛК	ML-2.1, FC-1.1, SS-1.1
		5.4	Практикум: NMF для тематического моделирования	NMF на TF-IDF матрице документов. Выбор числа тем. Интерпретация: топ-слова каждой темы. Визуализация тем. Сравнение с LDA (sklearn LatentDirichletAllocation). Coherence score. Практика: тематический анализ корпуса новостей	СЗ	MF-4.2, ML-2.1
		5.5	Практикум: LDA и BERTopic	LDA в gensim: обучение, coherence, визуализация (pyLDAvis). BERTopic: embedding + HDBSCAN + c-TF-IDF. Сравнение: NMF vs. LDA vs. BERTopic. Практика: тематический анализ коллекции отзывов, сравнение интерпретируемости	СЗ	MF-4.2, FC-1.1
		5.6	Практикум: рекомендательная система — коллаборативная фильтрация	Библиотека Surprise: SVD, SVD++, NMF. Оценка: RMSE, MAE. Кросс-валидация. Предсказание рейтинга. Top-N рекомендации. Практика: рекомендательная система на датасете MovieLens	СЗ	ML-2.1, MF-4.2, BD-2.1
		5.7	Практикум: контентная и гибридная рекомендации	Контентная: TF-IDF / эмбединги описаний → cosine similarity. Гибридная: взвешенная комбинация. Практика: гибридная рекомендательная система (collaborative + content). Обсуждение: cold start, scalability	СЗ	ML-2.1, MF-4.2
		5.8	Практикум: semi-supervised learning	Label Propagation и Label Spreading (sklearn). Pseudo-	СЗ	ML-2.1,

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
				labeling: обучение на размеченных → предсказание для неразмеченных → добавление уверенных → переобучение. Практика: классификация с 10% размеченных данных, сравнение supervised vs. semi-supervised		FC-1.1
		5.9	Практикум: manifold learning — Isomap, LLE, Spectral Embedding	Isomap: геодезические расстояния. LLE (Locally Linear Embedding): линейная реконструкция соседей. Spectral Embedding: лапласиан графа. Сравнение с PCA, t-SNE, UMAP на нелинейных датасетах (Swiss Roll). Практика: визуализация высокоразмерных данных	СЗ	MF-4.1, ML-2.1
		5.10	Практикум: обнаружение аномалий — продвинутые методы	Autoencoders для обнаружения аномалий (обзор): ошибка реконструкции как anomaly score. Isolation Forest на больших данных. Ensemble подходы. Практика: обнаружение аномалий в сетевом трафике / IoT-данных	СЗ	ML-2.1, BD-1.5
		5.11	Практикум: метрики для задач без учителя	Проблема оценки без меток. Внутренние метрики: Silhouette, BIC/AIC, coherence. Внешние (при наличии меток): ARI, NMI, Fowlkes-Mallows. Стабильность кластеризации. Практика: комплексная оценка результатов кластеризации несколькими метриками	СЗ	ML-2.2, ОПК-1.3
		5.12	Практикум: работа с текстовыми данными для ML	Предобработка: токенизация, стемминг, лемматизация, стоп-слова. Векторизация: Bag-of-Words, TF-IDF. Классификация текстов: NB, SVM, LR на TF-IDF. Embedding-based: sentence-transformers (обзор). Практика: классификация текстов с полным пайплайном	СЗ	MF-4.2, BD-1.3
		5.13	Практикум: работа с изображениями для ML (без DL)	Признаки изображений: гистограммы цвета, HOG, LBP. Классификация: SVM/RF на ручных признаках. Transfer learning embeddings: извлечение признаков из предобученной CNN (ResNet feature extractor) + классификатор sklearn. Практика: классификация изображений с помощью ML на CNN-эмбедингах	СЗ	MF-4.2, ML-2.1
		5.14	Практикум: итоговый проект семестра 6 — кейс unsupervised + supervised	Сквозная задача: кластеризация данных → разведочный анализ кластеров → использование кластеров как признаков → обучение классификатора → рекомендации. Полная документация: отчёт, Model Card, спецификация. Презентация	СЗ	ML-4.1, LC-2.1, ПК-3.3
Раздел 6	Временные ряды,	6.1	Временные ряды: основы анализа и	Определение временного ряда. Компоненты: тренд,	ЛК	MF-4.2,

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
	последовательности и специальные типы данных		классические методы	сезонность, шум. Декомпозиция: аддитивная, мультипликативная (STL). Стационарность: тест Дики-Фуллера (ADF). Автокорреляция: ACF, PACF. Классические модели: AR, MA, ARMA, ARIMA, SARIMA. Выбор порядка: AIC, BIC		ML-2.1
		6.2	Прогнозирование временных рядов методами ML	ML для временных рядов: создание лаговых признаков, скользящих статистик, календарных. Проблема утечки из будущего: temporal split, TimeSeriesSplit. Модели: LightGBM на лаговых признаках, Prophet (Facebook), модели из sktime. Мультишаговое прогнозирование: direct, recursive, multi-output	ЛК	MF-4.2, ML-2.1, BD-1.4
		6.3	Практикум: анализ и декомпозиция временного ряда	Загрузка временного ряда (pandas DatetimeIndex). Визуализация: линейный график, подграфики по годам/месяцам. Декомпозиция (seasonal_decompose, STL). Тест стационарности (ADF). ACF и PACF (statsmodels). Практика: анализ реального временного ряда (продажи, трафик, погода)	СЗ	MF-4.2, PL-1.2
		6.4	Практикум: ARIMA и SARIMA	Выбор порядка (p, d, q) по ACF/PACF. auto_arima (pmdarima). Обучение ARIMA/SARIMA. Диагностика остатков (plot_diagnostics). Прогнозирование. Метрики: MAE, RMSE, MAPE. Практика: прогнозирование продаж на 12 месяцев	СЗ	MF-4.2, ML-2.2
		6.5	Практикум: Prophet	Prophet (Meta): установка, обучение. Компоненты: тренд (changepoints), сезонность (yearly, weekly, daily), праздники. Настройка: сезонность Фурье, changepoint_prior_scale. Практика: прогнозирование с Prophet, сравнение с ARIMA	СЗ	MF-4.2, ML-2.1
		6.6	Практикум: ML на лаговых признаках для временных рядов	Создание признаков: лаги (lag_1, lag_7, lag_30), скользящие статистики (rolling mean, std), календарные (day_of_week, month, is_holiday). TimeSeriesSplit для валидации. LightGBM на лаговых признаках. Сравнение с ARIMA и Prophet. Практика: прогнозирование спроса	СЗ	MF-4.2, BD-1.4
		6.7	Практикум: мультишаговое прогнозирование	Direct strategy: отдельная модель на каждый горизонт. Recursive: предсказание → подстановка как лаг → следующее предсказание. MultiOutputRegressor. Практика: прогноз на 7 дней вперед, сравнение стратегий, анализ	СЗ	MF-4.2, ML-2.2

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
				нарастания ошибки		
		6.8	Практикум: классификация временных рядов	Представления: raw, статистические признаки, shapelets (обзор). Библиотека tslearn / sktime: KNN на DTW, TimeSeriesForest. Практика: классификация активности человека (HAR) по данным акселерометра	СЗ	MF-4.2, ML-2.1
		6.9	Практикум: обнаружение аномалий во временных рядах	Подходы: статистические (z-score на скользящем окне), ML (Isolation Forest на лаговых признаках), модельные (прогноз + порог на ошибку). Changepoint detection: PELT, Bayesian (ruptures). Практика: обнаружение аномалий в серверных метриках (CPU, latency)	СЗ	MF-4.2, BD-1.5
		6.10	Практикум: работа с геоданными	Признаки: расстояния (haversine), геохеш, пространственные агрегаты. Визуализация: folium, plotly mapbox. Кластеризация: DBSCAN/HDBSCAN на GPS. Практика: анализ пространственных данных (такси, доставка), построение признаков для ML-модели	СЗ	MF-4.2, BD-1.4
		6.11	Практикум: работа с табличными данными с разнородными типами	Комбинирование числовых, категориальных, текстовых, временных, пространственных признаков в одном Pipeline. ColumnTransformer для отдельной обработки. Практика: построение модели для датасета с разнородными типами данных (объявления, транзакции)	СЗ	ML-3.1, BD-1.3
		6.12	Практикум: A/B-тестирование и причинно-следственный вывод (обзор)	A/B-тест: дизайн, расчёт размера выборки, анализ (t-тест, bootstrap). Uplift modeling: идея, CATE (обзор). Причинно-следственный вывод: DoWhy (обзор). Связь ML и каузального вывода. Практика: проведение A/B-теста для оценки ML-модели	СЗ	MF-4.1, SS-3.1, ОПК-1.3
		6.13	Практикум: итоговый проект семестра 6 — прогнозирование на реальных данных	Сквозная задача: временной ряд из открытых источников → анализ → feature engineering → обучение нескольких моделей (ARIMA, Prophet, LightGBM) → мультишаговый прогноз → оценка → документирование. Презентация	СЗ	ML-4.1, MF-4.2, ПК-3.3
Раздел 7	Вероятностные модели и байесовский подход	7.1	Байесовские методы в ML	Байесовский вывод: априорное, правдоподобие, апостериорное. MAP vs. MLE. Сопряжённые распределения. Связь регуляризации с байесовским априором. Байесовская линейная регрессия. Гауссовские процессы: ядро, апостериорное распределение, неопределённость предсказания (обзор). Байесовская	ЛК	FC-1.1, MF-1.3, ML-2.1

Номер раздела	Наименование раздела дисциплины	Наименование темы	Содержание темы	Вид учебной работы *	Формируемые индикаторы
			оптимизация гиперпараметров		
		7.2	Графические модели и вероятностные программы	ЛК	FC-1.1, MF-1.3, ОПК-6.2
		7.3	Практикум: байесовская линейная регрессия	СЗ	FC-1.1, MF-1.3
		7.4	Практикум: гауссовские процессы для регрессии	СЗ	FC-1.1, ML-2.1
		7.5	Практикум: байесовская оптимизация гиперпараметров	СЗ	ML-3.2, FC-1.1
		7.6	Практикум: РуМС — вероятностное программирование	СЗ	FC-1.1, MF-1.3
		7.7	Практикум: байесовские сети	СЗ	FC-1.1, ОПК-6.2
		7.8	Практикум: EM-алгоритм — глубокое погружение	СЗ	MF-1.3, ML-2.1

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
				монотонность ELBO. Практика: реализация EM для GMM с нуля, визуализация итераций		
		7.9	Практикум: моделирование неопределённости и доверительные интервалы	Источники неопределённости: алеаторическая (шум данных), эпистемическая (незнание модели). Методы оценки: bootstrap prediction intervals, conformal prediction (обзор), MC Dropout (обзор). Практика: построение доверительных интервалов для предсказаний GBM через bootstrap	СЗ	FC-1.1, ML-2.2
		7.10	Практикум: conformal predictionж	Conformal prediction: идея гарантированного покрытия. Split conformal: calibration set → nonconformity scores → prediction sets. Для классификации: prediction sets. Для регрессии: prediction intervals. Библиотека MAPIE. Практика: построение prediction intervals с гарантированным покрытием	СЗ	FC-1.1, ML-2.2, ОПК-1.3
		7.11	Практикум: мини-проект — модель с оценкой неопределённости	Сквозная задача: обучение модели → оценка неопределённости (bootstrap / conformal / GP) → принятие решений с учётом неопределённости (отказ от предсказания при высокой неопределённости). Документирование: Model Card с описанием неопределённости	СЗ	FC-1.1, ПК-3.3, ML-4.1
Раздел 8	Обучение с подкреплением и специальные задачи	8.1	Введение в обучение с подкреплением	Формализация: агент, среда, состояние, действие, награда, политика, функция ценности. MDP (Markov Decision Process). Уравнение Беллмана. Типы методов: model-based vs. model-free, value-based vs. policy-based. Exploration vs. exploitation. Многорукий бандит. Epsilon-greedy стратегия	ЛК	ML-2.1, MF-1.1, SS-1.1
		8.2	Методы обучения с подкреплением	Q-learning: алгоритм, таблица Q-значений, сходимость. SARSA: on-policy альтернатива. Deep Q-Network (DQN, обзор): нейросеть вместо таблицы, experience replay, target network. Policy Gradient: REINFORCE. Actor-Critic (обзор). Применения: игры, робототехника, рекомендации, оптимизация	ЛК	ML-2.1, MF-3.2
		8.3	Практикум: многорукий бандит	Реализация: epsilon-greedy, UCB, Thompson Sampling. Среда: набор автоматов с разными вероятностями. Визуализация: cumulative regret. Сравнение стратегий. Обсуждение: связь с A/B-тестированием, рекомендациями	СЗ	ML-2.1, MF-3.2
		8.4	Практикум: Q-learning в среде	Установка Gymnasium (OpenAI Gym). Среды: FrozenLake,	СЗ	ML-2.1,

Номер раздела	Наименование раздела дисциплины	Наименование темы	Содержание темы	Вид учебной работы *	Формируемые индикаторы
		Gymnasium	Taxi. Q-learning: реализация, обновление таблицы, визуализация Q-таблицы. Параметры: learning rate, discount factor, epsilon decay. Визуализация обучения: награда по эпизодам		MF-3.2
		8.5 Практикум: SARSA и сравнение с Q-learning	SARSA: on-policy алгоритм, отличие от Q-learning. Реализация. Сравнение Q-learning и SARSA на среде CliffWalking: разные стратегии (cautious vs. optimal path). Визуализация	СЗ	ML-2.1
		8.6 Практикум: Deep Q-Network (DQN) — обзорная реализация	DQN: нейросеть для аппроксимации Q-функции. Experience replay buffer. Target network. Реализация упрощенного DQN на PyTorch для CartPole. Обучение и визуализация. Обсуждение: масштабирование на сложные среды	СЗ	ML-2.1, MF-3.2
		8.7 Практикум: AutoML — автоматизация подбора модели	Концепция AutoML: автоматический подбор предобработки, модели и гиперпараметров. Инструменты: auto-sklearn, FLAML, H2O AutoML (обзор). Практика: запуск AutoML на реальном датасете, анализ результатов, сравнение с ручным подходом. Обсуждение: когда AutoML полезен, а когда нет	СЗ	ML-3.2, УК-12.2
		8.8 Практикум: Active Learning	Идея: модель запрашивает разметку наиболее информативных примеров. Стратегии: uncertainty sampling, query-by-committee, expected model change. Библиотека modAL. Практика: сравнение random sampling vs. active learning на задаче классификации. Экономия разметки	СЗ	ML-2.1, FC-1.1
		8.9 Практикум: transfer learning для табличных данных	Предобученные эмбединги как признаки. TabNet (обзор): self-supervised pretraining на неразмеченных данных. Fine-tuning. Практика: использование предобученных эмбедингов категориальных признаков для улучшения модели на маленьком датасете	СЗ	ML-2.1, FC-1.1
		8.10 Практикум: мультимодальные данные	Объединение разнородных данных: табличные + текстовые + изображения. Стратегии: отдельные модели → конкатенация предсказаний, early fusion (конкатенация эмбедингов), late fusion (ансамбль). Практика: мультимодальная классификация (описание + изображение)	СЗ	MF-4.3, ML-2.1
		8.11 Практикум: итоговый проект семестра 7	Сквозная задача: выбор задачи из предложенных (RL-среда, рекомендации, временные ряды + ML, модель с	СЗ	ML-4.1, ПК-3.3,

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
				неопределённостью). Полный цикл: постановка → данные → модель → оценка → документирование. Презентация с акцентом на обоснование подхода		LC-2.1
Раздел 9	Интерпретируемость, справедливость и ответственный ML	9.1	Интерпретируемость и объяснимость моделей ML	Интерпретируемые модели: линейные, деревья, правила. Post-hoc объяснения: feature importance (permutation, SHAP), PDP, ICE. Локальные: LIME, SHAP waterfall. Глобальные: SHAP summary. Attention и gradient-based (обзор для нейросетей). Уровни объяснимости: для разработчика, пользователя, регулятора	ЛК	ML-6.1, ОПК-6.2, SS-3.2
		9.2	Справедливость и ответственная разработка ML	Формальные определения справедливости: demographic parity, equalized odds, predictive parity. Невозможность одновременного выполнения. Источники предвзятости: данные, модель, оценка. Методы митигации: preprocessing (resampling, reweighting), in-processing (adversarial debiasing), post-processing (threshold adjustment). Fairlearn, AIF360. Model Card как инструмент ответственности	ЛК	SS-1.2, SS-3.2, FC-5.2
		9.3	Практикум: SHAP — глубокое погружение	SHAP: TreeSHAP, KernelSHAP. Summary plot, dependence plot, waterfall, force plot. Глобальная и локальная интерпретация. Выявление bias через SHAP: различия объяснений по подгруппам. Практика: полный анализ интерпретируемости GBM-модели с SHAP	СЗ	ML-6.1, ОПК-6.2
		9.4	Практикум: LIME и counterfactual explanations	LIME: локальное объяснение через интерпретируемую модель-заменитель. Counterfactual explanations: «что нужно изменить, чтобы получить другое предсказание?». DiCE (Microsoft). Практика: LIME и counterfactual для модели кредитного скоринга	СЗ	ML-6.1, ОПК-6.2
		9.5	Практикум: измерение справедливости модели	Fairlearn: вычисление метрик справедливости по подгруппам (MetricFrame). Demographic parity difference, equalized odds difference. Визуализация disparities. Практика: анализ справедливости модели скоринга по полу/расе/возрасту	СЗ	SS-3.2, FC-5.2
		9.6	Практикум: митигация предвзятости	Методы: resampling (oversampling minority), reweighting (sample_weight), threshold adjustment (Fairlearn ThresholdOptimizer). Adversarial debiasing (обзор). Практика: применение митигации, измерение trade-off accuracy vs.	СЗ	SS-3.2, FC-5.2

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
				fairness		
		9.7	Практикум: Model Card и Datasheet	Составление Model Card (Mitchell et al.): назначение, метрики, ограничения, этические аспекты, оценка по подгруппам. Datasheet for Datasets (Geburu et al.): источник, состав, предвзятости. Практика: заполнение Model Card и Datasheet для учебного проекта	СЗ	FC-5.2, LC-2.2
		9.8	Практикум: юнит-тесты и регрессионные тесты для ML	Тестирование ML-кода: тесты предобработки (pytest), тесты модели (determinism, invariance, directional expectations). Регрессионные тесты: метрика не хуже порога. Great Expectations для тестирования данных (обзор). Практика: написание тестов для ML-пайплайна	СЗ	ОПК-3.3, ПК-3.1
		9.9	Практикум: приёмочное тестирование ML-модели	Чек-лист приёмки: метрики \geq порога, справедливость, интерпретируемость, латентность, размер модели. Тестирование на edge cases и adversarial examples. Документирование результатов тестирования. Практика: проведение приёмочного тестирования для готовой модели	СЗ	ПК-3.1, ПК-3.3
		9.10	Практикум: итоговый проект — ответственный ML-пайплайн	Сквозная задача: модель для чувствительной области (кредиты, здоровье, HR) → обучение → SHAP-анализ → оценка справедливости → митигация → тесты → Model Card → Datasheet. Презентация с акцентом на ответственность	СЗ	ML-4.1, FC-5.2, SS-3.2
Раздел 10	MLOps: развёртывание и мониторинг моделей	10.1	Жизненный цикл ML-модели в продакшене	Стадии: разработка → экспериментирование → развёртывание → мониторинг → переобучение → вывод из эксплуатации. Experiment tracking: MLflow. Model registry: версионирование моделей. CI/CD для ML. Feature store (обзор). Ролевая модель: Data Scientist, ML Engineer, MLOps Engineer	ЛК	LC-1.2, ML-4.1, SS-1.2
		10.2	Развёртывание моделей: паттерны и инструменты	Паттерны: batch prediction (scoring job), online prediction (REST API), streaming prediction. Инструменты: FastAPI + Docker, MLflow Models, BentoML (обзор), Triton (обзор). A/B-тестирование и canary deployment. Shadow mode. Blue-green deployment	ЛК	ML-4.2, PL-1.2, ОПК-2.2
		10.3	Мониторинг ML-моделей в продакшене	Дрейф данных (data drift): covariate shift, prior probability shift. Дрейф модели (concept drift). Методы обнаружения: PSI, KL-divergence, KS-test, ADWIN. Мониторинг метрик:	СЗ	ML-4.3, LC-2.2

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
				accuracy degradation. Инструменты: Evidently AI, NannyML (обзор). Стратегии переобучения: scheduled, trigger-based		
		10.4	Практикум: MLflow — трекинг экспериментов	MLflow Tracking: logging parameters, metrics, artifacts. MLflow UI. Автоматическое логирование (autolog). Сравнение экспериментов. Практика: обучение нескольких моделей с логированием в MLflow, выбор лучшей	СЗ	LC-1.2, ML-4.1
		10.5	Практикум: MLflow — Model Registry и версионирование	MLflow Model Registry: регистрация модели, версии, стадии (Staging, Production, Archived). Переход между стадиями. Загрузка модели из реестра. Практика: полный workflow от логирования до регистрации модели в реестре	СЗ	LC-1.2, ML-4.2
		10.6	Практикум: развёртывание модели как REST API	FastAPI сервис предсказаний: загрузка модели, endpoint /predict, валидация входов (Pydantic), обработка ошибок. Контейнеризация (Dockerfile). Docker Compose с Redis для кэширования. Health check. Практика: развёртывание sklearn/LightGBM модели	СЗ	ML-4.2, ОПК-3.3
		10.7	Практикум: batch prediction pipeline	Сценарий: ежедневное скоринг всех клиентов. Pipeline: загрузка данных из БД → загрузка модели из MLflow → предсказание → сохранение результатов. Планирование: cron / Airflow (обзор). Практика: реализация batch prediction pipeline с логированием	СЗ	ML-4.2, LC-2.2
		10.8	Практикум: мониторинг дрейфа данных (Evidently AI)	Evidently: Data Drift Report, Data Quality Report, Model Performance Report. Интеграция в CI/CD: автоматическая проверка дрейфа. Практика: обнаружение дрейфа на синтетическом примере, настройка порогов, генерация отчётов	СЗ	ML-4.3, LC-2.2
		10.9	Практикум: стратегии переобучения модели	Scheduled retraining: переобучение по расписанию. Triggered retraining: по сигналу дрейфа. Инкрементальное обучение (partial_fit, warm_start). Online learning (обзор). Практика: автоматизация переобучения при обнаружении дрейфа	СЗ	ML-4.3, LC-2.2
		10.10	Практикум: мини-проект — полный MLOps-пайплайн	Сквозная задача: данные → обучение с MLflow → развёртывание (FastAPI + Docker) → мониторинг (Evidently) → переобучение по сигналу. Документирование: архитектурная диаграмма, инструкция по развёртыванию. Презентация	СЗ	ML-4.1, ML-4.2, ML-4.3
Раздел	Продвинутые темы и	11.1	Масштабирование ML: большие данные	ML на больших данных: out-of-core learning (partial_fit),	ЛК	ОПК-2.2,

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
11	масштабирование		и распределённое обучение	Dask-ML, Spark MLlib (повторение). Распределённое обучение: data parallelism (обзор). Ускорение инференса: ONNX, TensorRT (обзор). Квантизация моделей (обзор). Edge deployment (обзор)		ML-3.3, PL-1.3
		11.2	Продвинутое ансамблевые методы и мета-обучение	Двухуровневый стекинг. Blending на holdout. Ансамбль разнородных моделей (табличные + текстовые + нейросетевые). Meta-learning: learning to learn (обзор). Few-shot learning (обзор). Neural Architecture Search (обзор). Связь с AutoML	ЛК	ML-2.3, FC-1.1, ML-3.2
		11.3	Практикум: out-of-core learning	sklearn partial_fit: SGDClassifier, MiniBatchKMeans. Чтение данных чанками (pd.read_csv chunks). Dask-ML: distributed training. Практика: обучение модели на датасете, не помещающемся в память	СЗ	ML-3.3, ОПК-2.2
		11.4	Практикум: ONNX — экспорт и ускорение инференса	Экспорт sklearn/LightGBM модели в ONNX (skl2onnx, onnxmltools). ONNX Runtime: загрузка и инференс. Замер ускорения: ONNX vs. native predict. Практика: конвертация пайплайна в ONNX, интеграция с FastAPI-сервисом	СЗ	ML-3.3, PL-1.3
		11.5	Практикум: двухуровневый стекинг на реальных данных	Уровень 1: разнородные модели (LR, RF, XGBoost, CatBoost, SVM). Out-of-fold predictions. Уровень 2: мета-модель (LR / Ridge). Оценка через nested CV. Практика: сравнение одноуровневого и двухуровневого стекинга	СЗ	ML-2.3, ML-4.1
		11.6	Практикум: воспроизводимость ML-проекта — чек-лист	Полный чек-лист: фиксация seed, версионирование данных (DVC), версионирование кода (Git), фиксация зависимостей (requirements.txt / poetry.lock), Docker, MLflow. Практика: проверка воспроизводимости учебного проекта по чек-листу	СЗ	LC-2.2, LC-1.2
		11.7	Практикум: code review для ML-кода	Специфика code review в ML: проверка утечки данных, корректность валидации, reproducibility, тесты, документация. Чек-лист ML code review. Практика: взаимное ревью ML-проектов по чек-листу	СЗ	ОПК-3.3, ML-4.3
		11.8	Практикум: подготовка ML-решения к передаче заказчику	Формирование delivery package: обученная модель, API, документация (Model Card, README, API spec), тесты, инструкция по развёртыванию. Приёмочное тестирование. Обучение пользователей (обзор). Практика: подготовка полного пакета для передачи	СЗ	ML-4.1, ПК-3.3, LC-2.1

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
		11.9	Практикум: ретроспектива ML-проекта	Ретроспектива: что пошло хорошо, что можно улучшить, какие уроки извлечены. Технический долг в ML. Метрики процесса: время от данных до модели, число итераций. Практика: ретроспектива по учебным проектам семестров 5–8	СЗ	ML-4.3, SS-1.2
Раздел 12	Итоговый проект: промышленное ML-решение	12.1	Постановка итогового проекта и выбор задачи	Требования к итоговому проекту: реальная задача, полный цикл (данные → модель → развёртывание → мониторинг), документация, презентация. Выбор задачи из предложенных или своей. Формулирование бизнес-постановки и трансляция в ML. Определение метрик успеха	ЛК	ПК-1.1, ML-4.1
		12.2	Планирование проекта и обследование данных	Декомпозиция проекта: этапы, сроки, deliverables. Обследование данных: источники, объём, качество, доступность. Анализ осуществимости. Формулирование ТЗ: функциональные и нефункциональные требования. Критерии приёмки	ЛК	ПК-1.1, ПК-1.2, ПК-3.1
		12.3	Практикум: EDA и baseline для итогового проекта	Загрузка и профилирование данных. Полный EDA. Обучение baseline модели (простейшая: mean, majority class, линейная). Фиксация baseline метрик. Обсуждение: превышение baseline как минимальный критерий успеха	СЗ	BD-1.2, ML-2.2
		12.4	Практикум: feature engineering и предобработка	Разработка пайплайна предобработки (Pipeline + ColumnTransformer). Feature engineering для конкретной задачи. Тестирование пайплайна. Документирование: описание признаков, трансформаций, обоснование решений	СЗ	BD-1.4, ML-3.1
		12.5	Практикум: обучение и подбор моделей	Обучение нескольких моделей. Подбор гиперпараметров (Optuna). Стекинг/ансамблирование. Кросс-валидация. Анализ ошибок. SHAP-интерпретация. Оценка справедливости	СЗ	ML-2.3, ML-6.1
		12.6	Практикум: развёртывание и тестирование	Развёртывание модели (FastAPI + Docker). Написание тестов: unit, integration, приёмочные. Мониторинг: настройка проверки дрейфа. MLflow: логирование финальной модели	СЗ	ML-4.2, ОПК-3.3
		12.7	Практикум: документирование итогового проекта	Model Card. Datasheet. Техническая спецификация. README с инструкцией по развёртыванию. Архитектурная диаграмма. План тестирования	СЗ	LC-2.1, FC-5.2, ПК-1.2
		12.8	Практикум: подготовка презентации и	Подготовка презентации: бизнес-контекст → данные →	СЗ	ML-4.1,

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы *	Формируемые индикаторы
			peer review	метод → результаты → ограничения → дальнейшие шаги. Peer review проектов: обратная связь по чек-листу		SS-3.2
		12.9	Практикум: защита итогового проекта	Защита: презентация (15 мин) + ответы на вопросы (10 мин). Критерии: качество модели, обоснованность решений, полнота пайплайна, документация, интерпретируемость, справедливость, воспроизводимость. Подведение итогов курса	СЗ	ML-4.1, ПК-3.3, LC-2.1

* - заполняется только по **ОЧНОЙ** форме обучения: ЛК – лекции; ЛР – лабораторные работы; СЗ – практические/семинарские занятия.

6. МАТЕРИАЛЬНО-ТЕХНИЧЕСКОЕ ОБЕСПЕЧЕНИЕ ДИСЦИПЛИНЫ

Таблица 6.1. Материально-техническое обеспечение дисциплины

Тип аудитории	Оснащение аудитории	Специализированное учебное/лабораторное оборудование, ПО и материалы для освоения дисциплины (при необходимости)
Лекционная	Аудитория для проведения занятий лекционного типа, оснащенная комплектом специализированной мебели; доской (экраном) и техническими средствами мультимедиа презентаций.	
Семинарская	Аудитория для проведения занятий семинарского типа, групповых и индивидуальных консультаций, текущего контроля и промежуточной аттестации, оснащенная комплектом специализированной мебели и техническими средствами мультимедиа презентаций.	Персональные компьютеры, необходимое ПО
Для самостоятельной работы	Аудитория для самостоятельной работы обучающихся (может использоваться для проведения семинарских занятий и консультаций), оснащенная комплектом специализированной мебели и компьютерами с доступом в ЭИОС.	Персональные компьютеры, необходимое ПО

* - аудитория для самостоятельной работы обучающихся указывается **ОБЯЗАТЕЛЬНО!**

7. УЧЕБНО-МЕТОДИЧЕСКОЕ И ИНФОРМАЦИОННОЕ ОБЕСПЕЧЕНИЕ ДИСЦИПЛИНЫ

Основная литература:

1. Основы машинного обучения и нейронные сети. учебное пособие [Электронный ресурс] / Бобрикова Екатерина Васильевна [и др.]. - М.: РУДН, 2024. 124 с. ISBN 978-5-209-12322-4 URL: https://mega.rudn.ru/MegaPro/UserEntry?Action=Link_FindDoc&id=517203&idb=0

2. Татарникова, Татьяна Михайловна. Методы машинного обучения: учебное пособие. - Санкт-Петербург: ГУАП, 2023. - 99 с.: ил., табл.; 21 см.; ISBN 978-5-8088-1885-9

Дополнительная литература:

1. Фомин, Владимир Владимирович. Методы машинного обучения: лабораторный практикум. - Санкт-Петербург: ГУАП, 2024 (Санкт-Петербург). - 37 с.: ил.

2. Платонов, А. В. Машинное обучение : учебное пособие для вузов / А. В. Платонов. — 2-е изд. — Москва : Издательство Юрайт, 2025. — 89 с. — (Высшее образование). — ISBN 978-5-534-20732-3. — Текст : электронный // Образовательная платформа Юрайт [сайт]. — URL: <https://urait.ru/bcode/558662>

Ресурсы информационно-телекоммуникационной сети «Интернет»:

1. ЭБС РУДН и сторонние ЭБС, к которым студенты университета имеют доступ на основании заключенных договоров

- Электронно-библиотечная система РУДН – ЭБС РУДН
<https://mega.rudn.ru/MegaPro/Web>

- ЭБС «Университетская библиотека онлайн» <http://www.biblioclub.ru>
- ЭБС «Юрайт» <http://www.biblio-online.ru>
- ЭБС «Консультант студента» www.studentlibrary.ru
- ЭБС «Знаниум» <https://znanium.ru/>

2. Базы данных и поисковые системы

- Sage <https://journals.sagepub.com/>
- Springer Nature Link <https://link.springer.com/>
- Wiley Journal Database <https://onlinelibrary.wiley.com/>
- Научометрическая база данных Lens.org <https://www.lens.org>

Учебно-методические материалы для самостоятельной работы обучающихся при освоении дисциплины/модуля:*

1. Курс лекций по дисциплине «Методы машинного обучения».

* - все учебно-методические материалы для самостоятельной работы обучающихся размещаются в соответствии с действующим порядком на странице дисциплины **в ТУИС!**