

Документ подписан простой электронной подписью  
Информация о владельце:  
ФИО: Ястребов Олег Александрович  
Должность: Ректор  
Дата подписания: 22.05.2026 10:38:35  
Уникальный программный ключ:  
ca953a0120d891083f939673078ef1a989dae18a

**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 (ПРОДВИНУТЫЙ КУРС)**

(наименование дисциплины/модуля)

**Рекомендована МССН для направления подготовки/специальности:**

### **02.04.02 ФУНДАМЕНТАЛЬНАЯ ИНФОРМАТИКА И ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ**

(код и наименование направления подготовки/специальности)

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

### **УПРАВЛЕНИЕ ДАННЫМИ И ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ**

(наименование (профиль/специализация) ОП ВО)

**2026 г.**

## 1. ЦЕЛЬ ОСВОЕНИЯ ДИСЦИПЛИНЫ

Дисциплина «Методы машинного обучения (продвинутый курс)» входит в программу магистратуры «Управление данными и искусственный интеллект» по направлению 02.04.02 «Фундаментальная информатика и информационные технологии» и изучается в 1, 2, 3 семестрах 1, 2 курсов. Дисциплину реализует Кафедра прикладного искусственного интеллекта. Дисциплина состоит из 6 разделов и 71 тема и направлена на изучение формирования глубоких знаний об архитектуре, эффективности и ограничениях современных моделей машинного обучения, освоение передовых подходов к построению, интерпретации, оптимизации, адаптации и интеграции моделей в реальных индустриальных и научных задачах. Курс расширяет горизонты студентов масштабными, нестандартными и междисциплинарными задачами машинного обучения, включая задачи работы с большим числом признаков, несбалансированными и разреженными данными, автоматизацию ML-процессов, вопросы интерпретируемости и переносимости решений. Целью освоения дисциплины является научить студентов строить и выводить сложные модели машинного обучения с учётом специфики бизнес- и научных задач, интерпретировать, оптимизировать и объяснять результаты на высоком уровне, эффективно использовать современные open source и облачные инструменты, а также внедрять ML-решения в инженерную, исследовательскую и промышленную практику.

## 2. ТРЕБОВАНИЯ К РЕЗУЛЬТАТАМ ОСВОЕНИЯ ДИСЦИПЛИНЫ

Освоение дисциплины «Методы машинного обучения (продвинутый курс)» 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-6	Способен определить и реализовать приоритеты собственной деятельности и способы ее совершенствования на основе самооценки	УК-6.1 Знает основные принципы самовоспитания и самообразования, профессионального и личностного развития, исходя из этапов карьерного роста и требований рынка труда; УК-6.2 Умеет планировать свое рабочее время и время для саморазвития. Формулировать цели личностного и профессионального развития и условия их достижения, исходя из тенденций развития области профессиональной деятельности, индивидуально-личностных особенностей; УК-6.3 Имеет практический опыт получения дополнительного образования, изучения дополнительных образовательных программ;
УК-7	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-7.1 Знает принципы применения цифровых технологий для сбора, отбора и обобщения информации; УК-7.2 Умеет применять цифровые технологии для поиска, обработки, анализа, хранения и представления информации в области профессиональной деятельности; УК-7.3 Владеет навыками применения цифровых технологий и методов поиска, обработки, анализа, хранения и представления информации в области профессиональной деятельности;

Шифр	Компетенция	Индикаторы достижения компетенции (в рамках данной дисциплины)
ОПК-2	Способен применять компьютерные / суперкомпьютерные методы, современное программное обеспечение (в том числе отечественного производства) для решения задач профессиональной деятельности	ОПК-2.1 Знает основные положения и концепции в области программирования, архитектуру языков программирования, теории коммуникации, знает основную терминологию, знаком с перечнем ПО, включенного в Единый Реестр Российских программ;
ОПК-5	Способен устанавливать и сопровождать программное обеспечение информационных систем, осуществлять эффективное управление разработкой программных средств и проектов	ОПК-5.1 осуществляет эффективное управление проектом разработки, внедрения и сопровождения программных средств и проектов на всех стадиях;
ПК-2	Способен проектировать, разрабатывать и поддерживать интегрированное программное обеспечение с использованием нейросетевых моделей и сквозных технологий искусственного интеллекта	ПК-2.1 Знает методы математического моделирования и машинного обучения, используемые при разработке требований и проектировании программного обеспечения систем и моделей искусственного интеллекта; ПК-2.2 Выбирает и моделирует архитектурные решения для реализации интегрированного программного обеспечения с использованием нейросетевых моделей и сквозных технологий искусственного интеллекта;

### 3. МЕСТО ДИСЦИПЛИНЫ В СТРУКТУРЕ ОП ВО

Дисциплина «Методы машинного обучения (продвинутый курс)» 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 (продвинутый курс)».

*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-7	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		Генеративный искусственный интеллект; Преддипломная практика;
УК-6	Способен определить и		Преддипломная практика;

Шифр	Наименование компетенции	Предшествующие дисциплины/модули, практики*	Последующие дисциплины/модули, практики*
	реализовать приоритеты собственной деятельности и способы ее совершенствования на основе самооценки		Управление проектами в сфере искусственного интеллекта;
ОПК-2	Способен применять компьютерные / суперкомпьютерные методы, современное программное обеспечение (в том числе отечественного производства) для решения задач профессиональной деятельности		
ОПК-5	Способен устанавливать и сопровождать программное обеспечение информационных систем, осуществлять эффективное управление разработкой программных средств и проектов		
ПК-2	Способен проектировать, разрабатывать и поддерживать интегрированное программное обеспечение с использованием нейросетевых моделей и сквозных технологий искусственного интеллекта		Преддипломная практика; Генеративный искусственный интеллект; Искусственный интеллект в компьютерных играх**;

\* - 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 (продвинутый курс)» составляет «12» зачетные единицы.

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)	Семестр(ы)
			1	2
<i>Контактная работа, ак.ч</i>	150		51	51
Лекции (ЛК)	46		17	17
Лабораторные работы (ЛР)	0		0	0
Практические/семинарские занятия (СЗ)	104		34	34
<i>Самостоятельная работа обучающихся, ак.ч.</i>	201		102	66
<i>Контроль (экзамен/зачет с оценкой), ак.ч.</i>	81		27	27
<b>Общая трудоемкость дисциплины ак.ч.</b>	<b>ак.ч.</b>	<b>432</b>	<b>180</b>	<b>144</b>
	<b>зач.ед.</b>	<b>12</b>	<b>5</b>	<b>4</b>

## 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*
Раздел 1	Архитектурные основы современных моделей ML и их масштабирование	1.1	Архитектура современных ансамблей: умные ансамбли, stacking, blending	Изучение продвинутых методов построения ансамблевых моделей. Рассмотрение техник умного объединения предсказаний базовых моделей через stacking (многоуровневое обучение) и blending (взвешенное комбинирование). Практические стратегии повышения качества предсказаний через оптимальную комбинацию разнородных алгоритмов.	ЛК
		1.2	Масштабируемость обучения: параллелизм, распределённое обучение, архитектуры big data ML	Методы распараллеливания процесса обучения моделей на больших объёмах данных. Изучение распределённых вычислений, горизонтального масштабирования, использование кластерных архитектур. Оптимизация использования вычислительных ресурсов при работе с big data.	ЛК
		1.3	Методологии работы с ultra-large datasets (кейс индустрии, подходы отбора/сэмплирования)	Практические подходы к обработке сверхбольших массивов данных. Техники интеллектуального сэмплирования, стратегии отбора репрезентативных подмножеств. Реальные кейсы из индустрии, методы работы с данными, не помещающимися в оперативную память.	ЛК
		1.4	ML pipelines и автоматизация жизненного цикла модели	Построение end-to-end конвейеров машинного обучения от загрузки данных до деплоя модели. Автоматизация этапов предобработки, обучения, валидации и мониторинга. Управление версиями моделей, воспроизводимость экспериментов, CI/CD для ML-систем.	ЛК
		1.5	Реализация stacking/ensemble моделей с использованием популярных ML-библиотек	Практическая реализация ансамблевых методов с использованием scikit-learn, XGBoost, LightGBM, CatBoost. Код-примеры построения многоуровневых ансамблей, оптимизация гиперпараметров, кросс-валидация для предотвращения переобучения.	
		1.6	Внедрение распределённого обучения на примере Spark MLlib или аналогичной платформы	Освоение Apache Spark MLlib для распределённого машинного обучения. Работа с RDD и DataFrame API, параллельное обучение моделей на кластере. Альтернативные платформы: Dask, Ray, Horovod для распределённых вычислений.	
		1.7	Эксперимент с обучением моделей на сверхбольших наборах данных (stratify, subsample, shard)	Практические техники работы с массивными датасетами: стратифицированная выборка для сохранения распределения классов, подвыборка данных, шардирование (разбиение на части). Балансировка между размером выборки и качеством модели.	
		1.8	Проектирование и запуск автоматизированного ML pipeline с MLflow/Prefect	Использование MLflow для отслеживания экспериментов, управления моделями и деплоя. Оркестрация ML-пайплайнов с помощью Prefect. Автоматизация workflows, логирование метрик, версионирование артефактов.	

		1.9	Сравнительный анализ ансамблей и единственных моделей на нестандартных данных	Эмпирическое сравнение производительности ансамблевых подходов и одиночных моделей на сложных, зашумлённых или несбалансированных данных. Анализ trade-off между сложностью модели и качеством предсказаний.	СЗ
		1.10	Обсуждение инфраструктурных	Критерии выбора между локальными и распределёнными вычислениями. Анализ соотношения затрат на инфраструктуру и выигрыша в производительности. Когда	СЗ

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы*
			сценариев: где нужны распределённые вычисления, а где нет	достаточно вертикального масштабирования, а когда необходим кластер.	
		1.11	Разбор ошибок масштабирования: диагностика тряблов при работе с big data	Типичные проблемы при масштабировании: утечки памяти, неэффективная сериализация, проблемы с балансировкой нагрузки. Инструменты профилирования и мониторинга распределённых систем. Стратегии отладки и оптимизации.	СЗ
		1.12	Моделирование end-to-end ML pipeline для прикладной индустриальной задачи	Полный цикл разработки промышленного ML-решения: от формулирования бизнес-задачи до продакшен-деплойа. Интеграция всех компонентов: сбор данных, feature engineering, обучение, валидация, мониторинг в продакшене.	СЗ
Раздел 2	Продвинутые методы регуляризации, сложные пространства признаков и работа с разреженностью	2.1	Теория и практика продвинутых регуляризаций: elastic net, group lasso, dropout-like для nontabular	Глубокое изучение комбинированных регуляризаций: elastic net (L1+L2), group lasso для структурированного отбора признаков. Адаптация dropout-подобных техник для нейросетей к задачам за пределами компьютерного зрения и NLP.	ЛК
		2.2	Работа с разреженными пространствами, методы снижения размерности beyond PCA (ICA, manifold learning, autoencoders)	Продвинутые методы работы с high-dimensional sparse data. Independent Component Analysis (ICA), многообразное обучение (t-SNE, UMAP, Isomap), использование автоэнкодеров для нелинейного снижения размерности и извлечения латентных представлений.	ЛК
		2.3	Многозадачное (multitask) и многоуровневое (multilevel) обучение	Transfer learning и multi-task learning: совместное обучение нескольких связанных задач для улучшения обобщающей способности. Иерархические модели и многоуровневые представления данных. Sharing representations между задачами.	ЛК
		2.4	ML при экстремальном несбалансе и редкости событий	Техники работы с сильно несбалансированными датасетами: SMOTE, ADASYN, cost-sensitive learning. Методы для rare event detection. Специальные метрики качества (precision-recall, F-beta, Matthews correlation coefficient).	ЛК
		2.5	Сравнение и реализация продвинутых регуляризационных техник на реальных данных	Практическое применение различных видов регуляризации на индустриальных датасетах. Сравнительный анализ эффективности L1, L2, elastic net, dropout. Подбор оптимальных гиперпараметров регуляризации.	

		2.6	Снижение размерности альтернативными методами (ICA, t-SNE, UMAP, autoencoders)	Hands-on практика с современными методами dimensionality reduction. Выбор метода в зависимости от типа данных и задачи. Визуализация высокоразмерных данных, сохранение структуры данных при снижении размерности.	
		2.7	Разработка multitask модели (пример — мультиклассовые иерархические задачи)	Построение моделей для одновременного решения нескольких связанных задач. Hard и soft parameter sharing. Применение к иерархической классификации, где нужно предсказывать на разных уровнях таксономии одновременно.	
		2.8	ML для задач fraud detection/rare event prediction на реальных и смоделированных данных	Специфика детектирования мошенничества и редких событий. Работа с temporal dependencies, anomaly detection. Синтетическая генерация fraud-случаев для обучения. Real-time scoring и адаптация моделей.	

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы*
		2.9	Дискуссия: границы применимости разных регуляризаций и риски их формирования	Критический анализ assumptions различных методов регуляризации. Когда регуляризация может ухудшить результаты. Интерпретация штрафов, введение domain knowledge через регуляризацию. Риски overfitting к валидационному набору.	СЗ
		2.10	Разбор ошибок при работе с разреженными признаковыми пространствами	Типичные проблемы: curse of dimensionality, spurious correlations, multicollinearity в sparse data. Техники отладки: feature importance analysis, проверка на избыточность признаков, детектирование data leakage.	СЗ
		2.11	Моделирование мультизадачных задач для разных отраслей	Кейсы применения multi-task learning в различных индустриях: медицина (диагностика нескольких заболеваний), e-commerce (recommendation + churn prediction), финтех (scoring + fraud detection). Архитектурные паттерны для MTL.	СЗ
		2.12	Критический разбор статистических ловушек при анализе редких классов и несбаланса	Статистические проблемы при работе с imbalanced data: Simpson's paradox, selection bias, evaluation metrics pitfalls. Правильная постановка A/B-тестов, расчёт необходимого размера выборки для редких событий, доверительные интервалы для метрик.	СЗ
Раздел 3	Интерпретируемость и прозрачность ML-моделей, Explainable AI	3.1	Современные методы интерпретации ML-моделей (SHAP, LIME, Anchors)	Введение в Explainable AI и его значение в современных ML-системах. Детальное изучение SHAP (SHapley Additive exPlanations) на основе теории игр и значений Шепли. Освоение LIME (Local Interpretable Model-agnostic Explanations) для локальной аппроксимации сложных моделей простыми интерпретируемыми. Метод Anchors для генерации объяснений на основе правил. Сравнительный анализ методов и критерии выбора подходящего инструмента для конкретной задачи.	ЛК
		3.2	Causal inference и оценка причинности в задачах прогнозирования и анализа	Основы причинно-следственного вывода и фундаментальные отличия корреляции от причинности. Построение направленных ациклических графов (DAG) и структурных причинных моделей. Методы оценки причинных эффектов: рандомизированные эксперименты, инструментальные переменные, propensity score matching, inverse probability weighting. Difference-in-differences и synthetic control methods. Применение causal ML в бизнес-задачах: uplift modeling и оценка treatment effects.	ЛК

		3.3	Fairness, bias, этика и безопасность моделей в AI системах	Типология предвзятости в машинном обучении: data bias, algorithmic bias, human bias. Метрики fairness: demographic parity, equalized odds, individual fairness. Методы выявления и снижения bias на различных этапах ML-пайплайна. Fairness-aware алгоритмы машинного обучения. Этические принципы разработки AI-систем: прозрачность, подотчётность, справедливость. Adversarial attacks и robustness моделей. Privacy-preserving ML: differential privacy и federated learning. Регуляторные требования GDPR, AI Act и compliance.	ЛК
		3.4	Генерация "человеческих" объяснений: кастомизация выводов для бизнеса и пользователей	Методы генерации natural language explanations: переход от технических метрик к понятному языку. Template-based и neural-based подходы к генерации объяснений. Персонализация объяснений под различные целевые аудитории: эксперты, менеджеры, конечные пользователи. Визуализация объяснений через dashboards и интерактивные инструменты. Контекстные объяснения с учётом бизнес-логики и доменной специфики. Best practices коммуникации результатов ML-моделей стейкхолдерам.	ЛК
		3.5	Исследование и визуализация важности признаков с помощью	Подготовка сложной модели (ensemble, deep learning) для интерпретационного анализа. Глобальная важность признаков: feature importance, permutation importance. Локальные объяснения для индивидуальных предсказаний с использованием SHAP и LIME.	

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы*
			SHAP/LIME на сложной модели	Построение SHAP summary plots, dependence plots, force plots. Применение LIME для интерпретации табличных данных, текстов и изображений. Анализ взаимодействий признаков и визуализация результатов для стейкхолдеров.	
		3.6	Кейсы моделирования причинных связей и построение counterfactuals	Counterfactual explanations и моделирование "что если" сценариев. Методы генерации контрфактов: optimization-based и model-based подходы. Actionable recourse: определение путей изменения решения модели. Causal discovery для выявления причинных связей из данных. Do-calculus и interventional reasoning. Практическое применение в кредитном скоринге и healthcare для альтернативных стратегий лечения. Освоение инструментов DoWhy, CausalML, DiCE.	
		3.7	Оценка и корректировка bias в моделях с использованием FAIRML/AI Fairness 360	Установка и настройка AI Fairness 360 (AIF360) для аудита ML-моделей. Bias detection: применение метрик и тестов на различных этапах ML-пайплайна. Pre-processing методы: reweighting, resampling, disparate impact remover. In-processing подходы: adversarial debiasing, prejudice remover. Post-processing техники: calibrated equalized odds, reject option classification. Практический проект по обнаружению и устранению bias в HR-модели найма. Анализ trade-offs между accuracy и fairness.	

		3.8	Построение отчёта explainability для реального сценария (например, для эксперта или пользователя платформы)	Структура comprehensive explainability report для различных аудиторий. Executive summary для топ-менеджмента с фокусом на бизнес-метрики. Технический раздел для data scientists и ML engineers. Объяснения для конечных пользователей: клиентов, пациентов. Разработка model card и datasheets for datasets. Документирование ограничений, допущений и границ применимости модели. Создание визуализаций и интерактивных dashboards. Практикум по созданию комплексного отчёта для кредитной или медицинской модели.	
		3.9	Практическое обсуждение кейсов прецедентов Explainable AI	Анализ успешных кейсов внедрения ХАИ в финансах: credit scoring, fraud detection. Healthcare применения: интерпретация диагностических моделей для рентгена и МРТ. Autonomous vehicles: объяснение решений self-driving систем. Риски использования ML в criminal justice на примере COMPAS-скандала. HR и рекрутинг: проблемы справедливости алгоритмов найма. Регуляторные требования GDPR "right to explanation". Lessons learned, типичные ошибки при внедрении ХАИ и будущие направления развития.	СЗ
		3.10	Дебаты о границах причинных выводов в сложных моделях	Фундаментальные ограничения causal inference и проблема confounding. Unmeasured confounders и невозможность полной идентификации причинных эффектов. Внешняя валидность и проблемы generalization причинных выводов. Дискуссия о возможности причинности в deep learning моделях. Сравнение позиций: когда correlation достаточно versus необходимость causation. Определение контекстов, где causal inference критична, и где избыточна. Философские аспекты причинности: подход Judea Pearl versus классический статистический подход.	СЗ
		3.11	Групповое моделирование стратегии борьбы с bias	Формирование команд и распределение ролей для группового проекта. Выбор датасета с потенциальным bias: UCI Adult, COMPAS или аналогичные. Постановка задачи: определение защищённых атрибутов и целевых fairness-метрик. Обучение baseline модели и оценка исходного уровня bias. Brainstorming и выбор стратегий митигации bias. Имплементация выбранных методов и сравнение результатов. Анализ accuracy versus fairness trade-off. Презентация решений и peer review между командами.	СЗ
		3.12	Мастер-класс по	Понимание потребностей non-technical стейкхолдеров и адаптация коммуникации.	СЗ

Номер раздела	Наименование раздела дисциплины	Наименование темы	Содержание темы	Вид учебной работы*
		представлению explainable models для менеджмента/партнёров	Story-telling с данными: построение убедительного нарратива вокруг модели. Ответы на ключевые вопросы менеджмента: ROI, риски, compliance, limitations. Техники визуализации: упрощение без потери сути и точности. Форматы демонстрации: live demo versus подготовленные слайды. Антиципация вопросов и подготовка к возражениям. Практикум: elevator pitch ML-модели. Ролевая игра: презентация перед "советом директоров".	

Раздел 4	Адаптация моделей, перенос (Transfer Learning) и AutoML	4.1	Современные подходы к transfer learning и domain adaptation для ML-моделей	Основы transfer learning: мотивация, типы и условия эффективного переноса знаний. Классификация transfer: inductive, transductive, unsupervised transfer learning. Domain adaptation и типы сдвигов: covariate shift, label shift, concept drift. Стратегии pre-training и fine-tuning: выбор между feature extraction и fine-tuning layers. Multi-task learning и использование auxiliary tasks для улучшения переноса. Domain adversarial neural networks (DANN) для адаптации между доменами. Методы оценки domain similarity и transferability.	ЛК
		4.2	Meta learning (обучение обучаться), zero/few-shot learning	Meta-learning парадигма "learning to learn" и её применение в современном ML. Model-Agnostic Meta-Learning (MAML) и его варианты для быстрой адаптации. Metric learning подходы: siamese networks, triplet loss, prototypical networks, matching networks. Zero-shot learning через semantic embeddings и attribute-based классификацию. Few-shot learning: формулировка N-way K-shot задач и методы решения. Data augmentation техники для сценариев с ограниченными данными. Практическое применение для быстрой адаптации к новым классам и задачам.	ЛК
		4.3	Автоматизация построения моделей: AutoML, hyperparameter optimization, neural architecture search	Обзор современных AutoML фреймворков: Auto-sklearn, H2O AutoML, Google AutoML. Методы hyperparameter optimization: grid search, random search, Bayesian optimization. Продвинутые HPO алгоритмы: Hyperband, BOHB, population-based training. Neural Architecture Search (NAS): основные методы и алгоритмы поиска архитектур. Efficient NAS подходы: ENAS, DARTS, ProxylessNAS для снижения вычислительных затрат. Multi-objective optimization: балансировка accuracy, latency и model size. Применение AutoML для временных рядов и NLP задач.	ЛК
		4.4	Модели, устойчивые к concept drift, и адаптация к меняющейся среде	Типология concept drift: sudden, gradual, incremental, recurring изменения в данных. Методы обнаружения drift: statistical tests, monitoring metrics, drift detectors. Adaptive learning стратегии: online learning и incremental learning. Windowing strategies: sliding window и landmark window подходы. Ensemble методы для работы с drift: dynamic weighted majority. Выбор между periodic retraining и continuous learning. A/B testing для валидации новых версий моделей. Практические кейсы адаптации рекомендательных и прогнозных систем.	ЛК
		4.5	Реализация transfer learning/feature reuse на разнородных задачах	Практика transfer между доменами: images к medical images, general text к domain-specific NLP. Cross-lingual transfer с использованием multilingual models и zero-shot translation. Sim2real transfer: перенос из симуляции в реальный мир. Техники feature reuse: frozen layers, adapter modules, progressive neural networks. Практический проект: fine-tuning BERT для специфической NLP задачи. Transfer learning для табличных данных и его особенности. Методы оценки эффективности transfer в сравнении с training from scratch.	
		4.6	Эксперимент с meta-learning или few-shot	Постановка задачи классификации с ограниченными данными и выбор подхода. Подготовка meta-dataset: создание эпизодов (episodes) для meta-training.	

Номер раздела	Наименование раздела дисциплины	Наименование темы	Содержание темы	Вид учебной работы*
---------------	---------------------------------	-------------------	-----------------	---------------------

			learning для небольших датасетов	Имплементация prototypical networks или MAML с нуля и с использованием библиотек. Data augmentation техники, специфичные для few-shot режима. Оценка на benchmark datasets: Omniglot, miniImageNet. Сравнение с baseline подходами: transfer learning, data augmentation, oversampling. Анализ learning curves, confusion matrices и failure cases.	
		4.7	Автоматизация поиска моделей и гиперпараметров с Optuna/Auto-Sklearn/KerasTuner	Optuna: define-by-run API, pruning неперспективных trials, визуализация результатов. Auto-Sklearn: automated ensemble construction с использованием meta-learning. KerasTuner: hyperband и bayesian optimization для моделей Keras. Определение search space: categorical, numerical, conditional параметры. Distributed optimization: параллельный поиск на multi-GPU и кластерах. Best practices: reproducibility, logging, checkpointing экспериментов. Практикум по оптимизации сложной модели и сравнение фреймворков по скорости и качеству.	
		4.8	Проектирование robust-модели с поддержкой реального concept drift (например, временной ряд, реакция рынка, онлайн-система)	Выбор use case: финансовый рынок, e-commerce динамика, IoT sensors. Проектирование архитектуры online learning pipeline с учётом production constraints. Интеграция drift detection: ADWIN, Page-Hinkley test, DDM в pipeline. Разработка adaptive model update strategy и champion/challenger framework. Построение monitoring dashboard для tracking performance и drift metrics. Реализация fallback mechanisms для реагирования на детектированный drift. End-to-end проект от сбора данных до deployment с continuous adaptation.	
		4.9	Групповой разбор успешных и неудачных примеров transfer learning	Анализ успешных кейсов: ImageNet → medical imaging, BERT → domain-specific NLP. Разбор провалов и negative transfer: когда source и target домены слишком различны. Выявление факторов успеха: domain similarity, task relatedness, data quality. Lessons learned и критерии оценки перспективности transfer для новых задач. Дискуссия о универсальных representations versus domain-specific обучении. Групповая работа по оценке feasibility transfer для задач участников.	C3
		4.10	Мастер-класс по сбору маленьких и сложных датасетов для meta/few-shot задач	Стратегии сбора данных при ограниченных ресурсах и бюджете. Active learning для выбора наиболее информативных примеров для разметки. Data programming и weak supervision с использованием Snorkel. Synthetic data generation для augmentation few-shot datasets. Crowdsourcing через Amazon MTurk и специализированные платформы. Quality control в few-shot режиме: проверка качества разметки. Labeling strategies: hierarchical labeling, consensus-based annotation. Практикум по созданию balanced few-shot dataset для конкретной задачи.	C3
		4.11	Дискуссия: ограничения, риски и лучшие практики применения AutoML	Определение контекстов, где AutoML эффективен, и где избыточен или неприменим. Black-box проблема: сложности интерпретации моделей, найденных AutoML. Computational cost: анализ затрат времени и ресурсов на AutoML поиск. Риск overfitting на validation set через НРО и методы его предотвращения. Reproducibility challenges в AutoML экспериментах. Дискуссия AutoML versus human expertise: дополнение или замена. Этические аспекты автоматизации и вопросы ответственности за решения AutoML-моделей.	C3
		4.12	Кейс-анализ провалов адаптации или переобучения на нестабильных данных	Case study кредитной модели во время кризиса COVID-19 и резкого изменения паттернов. Анализ провала рекомендательной системы при изменении пользовательского поведения. NLP модель на социальных сетях и проблема evolving language. Root cause analysis: разграничение data drift, concept drift, distribution shift. Post-mortem анализ: что пошло не так и на каком этапе. Mitigation strategies:	C3

Номер раздела	Наименование раздела дисциплины	Наименование темы	Содержание темы	Вид учебной работы*	
			превентивные меры и reactive response. Групповое обсуждение похожего опыта участников и формулирование takeaways для предотвращения подобных ситуаций.		
Раздел 5	Продвинутые методы слабоконтролируемого обучения (semi-supervised), обучения без учителя и генеративные техники	5.1	Современные semi-supervised (self-training, co-training, pseudo-labeling) методы в ML	Изучение современных подходов к полуконтролируемому обучению, включая самообучение (self-training), совместное обучение (co-training) и псевдо-разметку (pseudo-labeling). Рассмотрение механизмов использования неразмеченных данных для улучшения качества моделей при ограниченном количестве размеченных примеров.	ЛК
		5.2	Обзор и применение алгоритмов кластеризации и снижения размерности в сложных пространствах	Анализ продвинутых методов кластеризации (DBSCAN, HDBSCAN, спектральная кластеризация) и техник снижения размерности (t-SNE, UMAP, автоэнкодеры) для работы с высокоразмерными данными. Практическое применение для визуализации и предобработки данных.	ЛК
		5.3	Использование генеративных моделей для обогащения данных, аугментации, unsupervised feature extraction	Применение генеративных моделей (VAE, GAN) для создания синтетических данных, аугментации обучающих выборок и извлечения признаков без учителя. Методы улучшения качества и разнообразия данных для обучения моделей.	ЛК
		5.4	Contrastive learning и инструменты для современного representation learning	Изучение контрастивного обучения (SimCLR, MoCo, BYOL) для получения качественных представлений данных. Рассмотрение архитектур и функций потерь, использующих сравнение положительных и отрицательных пар примеров.	ЛК
		5.5	Реализация и сравнительный анализ semi-supervised нейросетевых техник на частично размеченных данных	Практическая реализация методов полуконтролируемого обучения (FixMatch, MixMatch, Mean Teacher) и проведение экспериментов на датасетах с ограниченной разметкой. Сравнение эффективности различных подходов.	
		5.6	Построение пайплайна кластеризации и визуализация скрытых зависимостей в данных	Создание end-to-end пайплайна для кластерного анализа, включая предобработку, выбор алгоритма, оптимизацию гиперпараметров и визуализацию результатов. Интерпретация выявленных паттернов и структур.	
		5.7	Генерация синтетических данных с помощью GAN/VAE для редких классов	Использование генеративно-состязательных сетей (GAN) и вариационных автоэнкодеров (VAE) для синтеза данных недопредставленных классов. Методы борьбы с дисбалансом классов через генерацию.	
		5.8	Реализация contrastive learning для извлечения латентных признаков (SimCLR, MoCo и др.)	Практическая имплементация фреймворков контрастивного обучения, построение проекционных головок, выбор аугментаций и настройка температуры в контрастивных функциях потерь.	

		5.9	Мини-дебаты: когда стоит (и не стоит) применять semi-supervised обучение	Критический анализ применимости полуконтролируемых методов, обсуждение сценариев эффективного использования, ограничений и потенциальных рисков. Сравнение с альтернативными подходами.	СЗ
		5.10	Формирование стратегий кластеризации с учётом	Разработка подходов к кластеризации с учетом практических требований бизнеса: интерпретируемость, масштабируемость, стабильность результатов и возможность	СЗ

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы*
			бизнес-ограничений	инкрементального обновления.	
		5.11	Разбор ошибок генерации и аугментации в реальных ML-кейсах	Анализ типичных проблем при использовании генеративных моделей и аугментации: mode collapse, артефакты генерации, нереалистичные примеры. Методы диагностики и устранения	СЗ
		5.12	Совместная практика: как извлекать пользу из contrastive learning	Практическое занятие по применению контрастивного обучения для решения реальных задач: transfer learning, few-shot learning, поиск по сходству, детекция аномалий.	СЗ
Раздел 6	Индустриальное применение, встраивание, ML Ops и устойчивость ML-систем	6.1	ML Ops: CI/CD, автоматизация мониторинга и управления жизненным циклом моделей	Изучение практик MLOps для автоматизации процессов разработки, тестирования и развертывания моделей. Настройка CI/CD пайплайнов, версионирование моделей и данных, автоматическое переобучение.	ЛК
		6.2	Промышленные стандарты развертывания и интеграции ML в существующие сервисы и ПО	Рассмотрение стандартов и best practices для интеграции ML-моделей в продакшн-системы: REST API, gRPC, контейнеризация, оркестрация, балансировка нагрузки.	ЛК
		6.3	Тестирование, мониторинг, alerting и валидация в реальном времени (drift, outlier detection)	Построение систем мониторинга качества моделей в продакшн: детекция дрефта данных и концепт-дрифта, выявление выбросов, настройка алертов, A/B тестирование.	ЛК
		6.4	Устойчивость, безопасность и поддержка ML-моделей: adversarial attacks, robust training	Изучение методов защиты от adversarial атак, техники robust training, certified defense. Обеспечение безопасности и надежности ML-систем в продакшн-окружении.	ЛК
		6.5	Деплой модели с MLOps-подходами: мониторинг, rollback, обновление	Практики безопасного развертывания моделей: канареечные релизы, blue-green deployment, автоматический откат при деградации метрик, стратегии обновления без простоя.	
		6.6	Интеграция обученной модели в веб/web-сервис или edge-устройство	Методы развертывания моделей в различных окружениях: веб-сервисы, мобильные приложения, IoT и edge-устройства. Оптимизация для ограниченных ресурсов.	

		6.7	Построение пайплайна управления и alert-инга по признакам отказа/деградации	Создание комплексной системы мониторинга с автоматическими уведомлениями при обнаружении аномалий в работе модели, деградации метрик или технических сбоев.	
		6.8	Анализ MLOps-стратегий: кейсы построения устойчивых AI-продуктов	Изучение реальных примеров построения ML-систем в крупных компаниях, разбор архитектурных решений, инструментов и организационных процессов.	
		6.9	Обсуждение фреймворков, применяемых на производстве (Kubeflow,	Сравнительный анализ популярных MLOps-платформ и инструментов: возможности, преимущества, недостатки, сценарии использования, интеграция в существующую инфраструктуру.	СЗ

Номер раздела	Наименование раздела дисциплины	Наименование темы		Содержание темы	Вид учебной работы*
			MLflow, seldon-core и др.)		
		6.10	Разбор провалов реальных ML-продуктов из-за ошибок интеграции / мониторинга	Анализ случаев неудачного внедрения ML-систем, изучение причин провалов: недостаточный мониторинг, игнорирование дрефта, проблемы масштабирования, организационные факторы.	СЗ
		6.11	Круглый стол: борьба с атаками на ML и развитие мер безопасности	Дискуссия о современных угрозах для ML-систем: adversarial examples, data poisoning, model extraction, privacy attacks. Обсуждение методов защиты и регуляторных требований.	СЗ

\* - 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.	
Компьютерный класс	Компьютерный класс для проведения занятий, групповых и индивидуальных консультаций, текущего контроля и промежуточной аттестации, оснащенная персональными компьютерами (в количестве [Параметр] шт.), 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.	
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.	

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

## 7. УЧЕБНО-МЕТОДИЧЕСКОЕ И ИНФОРМАЦИОННОЕ ОБЕСПЕЧЕНИЕ ДИСЦИПЛИНЫ

### Основная литература:

1. Машинное обучение. От основ до продвинутых моделей. Принс Саймон. - Эксмо: БОМБОРА. Серия: Библиотека MIT., 2025. – 608 с. ISBN: 978-5-04-192658-8

### Дополнительная литература:

1. Григорьев Алексей. Машинное обучение. Портфолио реальных проектов. — СПб.: Питер, 2023. — 496 с.: ил. — (Серия «Библиотека программиста»). ISBN 978-5-4461-1978-3

2. Рашка, С. Машинное обучение с PyTorch и Scikit-Learn: Пер. с англ. / С. Рашка, Ю. Лю, В. Мирджалили. - Астана: Фолиант, 2024. - 688 с.: ил. ISBN 978-601-11-0034-2

### 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](http://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 (продвинутый курс)».

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

## РАЗРАБОТЧИКИ

---

Должность

**РУКОВОДИТЕЛЬ БУП**

Заведующий кафедрой

---

Должность

**РУКОВОДИТЕЛЬ ОП ВО**

Заведующий кафедрой прикладного  
искусственного интеллекта

---

Должность

---

Подолько П.М.

Фамилия И.О

---

Подолько П.М.

Фамилия И.О

---

Подолько П.М.

Фамилия И.О