

Документ подписан посредством электронной подписи
Информация о владельце:
ФИО: Шамрай-Курбатова Лидия Викторовна
Должность: Ректор
Дата подписания: 09.06.2026 10:08:49
Уникальный программный ключ:
b1e4399771b07e18f31755456972d73b2ccfc531

Автономная некоммерческая организация высшего образования
«Волгоградский институт бизнеса»

Рабочая программа учебной дисциплины

Машинное обучение

(Наименование дисциплины)

09.03.03 Прикладная информатика, направленность (профиль) «Прикладной искусственный интеллект»

(Направление подготовки / Профиль)

Бакалавр

(Квалификация)

Кафедра разработчик

Экономики и управления

Год набора

2026

Вид учебной деятельности	Трудоемкость (объем) дисциплины	
	Очная форма	Очно-заочная форма
	Д	В
Зачетные единицы	6	6
Общее количество часов	216	216
Аудиторные часы контактной работы обучающегося с преподавателями:	64	32
– Лекционные (Л)	32	16
– Практические (ПЗ)	32	16
– Лабораторные (ЛЗ)		
– Семинарские (СЗ)		
Самостоятельная работа обучающихся (СРО)	98	148
К (Р-Г) Р (П) (+;-)		
Тестирование (+;-)		
ДКР (+;-)		
Зачет (+;-)		
Зачет с оценкой (+;- (Кол-во часов))		
Экзамен (+;- (Кол-во часов))	+(54)	+(36)

Волгоград 2026

Содержание

Раздел 1. Организационно-методический раздел	3
Раздел 2. Тематический план.....	6
Раздел 3. Содержание дисциплины.....	8
Раздел 4. Организация самостоятельной работы обучающихся.....	18
Раздел 5. Фонд оценочных средств для проведения текущего контроля и промежуточной аттестации обучающихся.....	20
Раздел 6. Оценочные средства промежуточной аттестации (с ключами)	19
Раздел 7. Перечень учебной литературы, необходимой для освоения дисциплины	22
Раздел 8. Материально-техническая база и информационные технологии.....	28
Раздел 9. Методические указания для обучающихся по освоению дисциплины	30

Раздел 1. Организационно-методический раздел

1.1. Цели освоения дисциплины

Дисциплина «Машинное обучение» входит в перечень **Обязательных дисциплин (модули) Б1.О.16** подготовки обучающихся по направлению **Прикладная информатика, направленность (профиль) «Прикладной искусственный интеллект».**

Целью дисциплины является формирование **компетенций** (в соответствии с ФГОС ВО и требованиями к результатам освоения основной профессиональной образовательной программы высшего образования (ОПОП ВО)):

ОПК-7 Способен разрабатывать алгоритмы и программы, пригодные для практического применения;

Дескрипторы общепрофессиональных компетенций:

ОПК-7.1 – Способен разработать алгоритм работы компонентов программного продукта, осуществлять выбор языка для решения задачи, обосновывая выбор языка программирования и фреймворков с учетом специфики задач машинного обучения и анализа данных.

ОПК-7.2 Способен разработать программный код в одной из современных сред программирования, в том числе с использованием сред и инструментов, ориентированных на разработку систем искусственного интеллекта.

ПК-1. Способен анализировать возможности реализации требований к компьютерному программному обеспечению.

Дескрипторы профессиональных компетенций:

ПК-1.1. Способен анализировать и обосновывать технические решения при разработке компьютерного программного обеспечения, включая программные системы с элементами искусственного интеллекта

ПК-1.2. Способен анализировать требования к данным и проектным ограничениям при разработке программного обеспечения, включая системы анализа данных и искусственного интеллекта

Перечисленные компетенции формируются в процессе достижения **индикаторов компетенций:**

Обобщенная трудовая функция/ трудовая функция	Код и наименование дескриптора компетенций	Код и наименование индикатора достижения компетенций (из ПС)
	<p>ОПК-7.1 – Способен разработать алгоритм работы компонентов программного продукта, осуществлять выбор языка для решения задачи, обосновывая выбор языка программирования и фреймворков с учетом специфики задач машинного обучения и анализа данных.</p> <p>ОПК-7.2 Способен разработать программный код в одной из современных сред программирования, в том числе с использованием сред и инструментов, ориентированных на разработку систем искусственного интеллекта.</p>	<p>Знает</p> <p>ИД-1 ОПК-7.1 Принципы разработки алгоритмов работы компонентов программного продукта, методы выбора языка программирования и фреймворков с учетом специфики задач машинного обучения и анализа данных (без привязки к профессиональному стандарту)</p> <p>ИД-2 ОПК-7.2 Современные среды программирования, включая инструменты, ориентированные на разработку систем искусственного интеллекта, а также подходы к написанию программного кода (без привязки к профессиональному стандарту)</p> <p>Умеет</p> <p>ИД-3 ОПК-7.1 Разрабатывать алгоритмы работы компонентов программного продукта, осуществлять и обосновывать выбор языка программирования и фрейм-</p>

		<p>ворков с учетом специфики задач машинного обучения и анализа данных (без привязки к профессиональному стандарту)</p> <p>ИД-4 ОПК-7.2 Разрабатывать программный код в одной из современных сред программирования, включая среды и инструменты, ориентированные на разработку систем искусственного интеллекта (без привязки к профессиональному стандарту)</p> <p>Имеет навыки</p> <p>ИД-5 ОПК-7.1 Владение навыками алгоритмизации, выбора и обоснования языка программирования и фреймворков для решения задач машинного обучения и анализа данных (без привязки к профессиональному стандарту)</p> <p>ИД-6 ОПК-7.2 Владение навыками разработки программного кода в современных средах программирования, включая инструменты для создания систем искусственного интеллекта (без привязки к профессиональному стандарту)</p>
<p>ПС 06.001 Программист</p> <p>D Разработка требований и проектирование программного обеспечения</p> <p>D/01.6. Анализ возможностей реализации требований к компьютерному программному обеспечению</p>	<p>ПК-1.1. Способен анализировать и обосновывать технические решения при разработке компьютерного программного обеспечения, включая программные системы с элементами искусственного интеллекта</p> <p>ПК-1.2. Способен анализировать требования к данным и проектным ограничениям при разработке программного обеспечения, включая системы анализа данных и искусственного интеллекта</p>	<p>Знает:</p> <p>ИД-1 ПК 1.1. Методологии разработки компьютерного программного обеспечения и технологии программирования D/01.6</p> <p>ИД-2 ПК 1.2. Методологии и технологии проектирования и использования баз данных D/01.6</p> <p>Умеет:</p> <p>ИД-3 ПК 1.1. Проводить оценку и обоснование рекомендуемых решений D/01.6</p> <p>ИД-4 ПК 1.2. Осуществлять коммуникации с заинтересованными сторонами D/01.6</p> <p>Имеет навыки и (или) опыт:</p> <p>ИД-5 ПК 1.1. Согласования требований к компьютерному программному обеспечению с заинтересованными сторонами D/01.6</p> <p>ИД-6 ПК 1.2. Оценки и согласования сроков выполнения поставленных задач D/01.6</p>

**1.2. Место дисциплины в структуре ОПОП ВО
направления подготовки «09.03.03 Прикладная информатика», направленность (профиль) «Прикладной искусственный интеллект»**

№	Предшествующие дисциплины (дисциплины, изучаемые параллельно)	Последующие дисциплины
<i>1</i>	<i>2</i>	<i>3</i>
1	Линейная алгебра	Современные архитектуры нейронных сетей
2	Математическая логика	Компьютерная лингвистика
3	Машинное обучение	Выполнение и защита выпускной квалификационной работы
4	Методы оптимизации	Учебная практика (Технологическая (проектно-технологическая) практика)
5	Python: основные библиотеки для анализа данных	Учебная практика (Научно-исследовательская работа (получение первичных навыков научно-исследовательской работы))
6		Производственная практика (Технологическая (проектно-технологическая) практика)
7		Учебная практика (Эксплуатационная практика)
8		Производственная практика (Преддипломная практика)

Последовательность формирования компетенций в указанных дисциплинах может быть изменена в зависимости от формы и срока обучения, а также преподавания с использованием дистанционных технологий обучения.

1.3. Нормативная документация

Рабочая программа учебной дисциплины составлена на основе:

- Федерального государственного образовательного стандарта высшего образования по направлению подготовки **09.03.03 Прикладная информатика**;
- Учебного плана направления подготовки **09.03.03 Прикладная информатика, направленность (профиль) «Прикладной искусственный интеллект»** 2026 года набора;
- Образца рабочей программы учебной дисциплины (приказ № 113-О от 01.09.2021 г.).

Раздел 2. Тематический план

Очная форма обучения (полный срок)

№	Тема дисциплины	Трудоемкость				Код индикатора и дескриптора достижения компетенций
		Всего	Аудиторные занятия		СРО	
			Л	ПЗ (ЛЗ, СЗ)		
1	2	3	4	5	6	7
1	Введение в машинное обучение: основные понятия, типы задач (регрессия, классификация, кластеризация), этапы построения моделей	20	4	4	12	ИД-1 ОПК- 7.1 ИД-2 ОПК- 7.2
2	Предобработка данных: очистка данных, работа с пропусками, нормализация и масштабирование, кодирование категориальных признаков	20	4	4	12	ИД-2 ОПК- 7.2 ИД-3 ОПК- 7.1
3	Линейные модели: линейная и логистическая регрессия, функция потерь, регуляризация (L1, L2)	20	4	4	12	ИД-4 ОПК- 7.2 ИД-5 ОПК- 7.1
4	Деревья решений и ансамблевые методы: случайный лес, градиентный бустинг, переобучение и способы его устранения	20	4	4	12	ИД-5 ОПК- 7.1 ИД-6 ОПК- 7.2
5	Методы кластеризации: k-средних, иерархическая кластеризация, оценка качества кластеров	20	4	4	12	ИД-1 ПК- 1.1 ИД-2 ПК- 1.2
6	Методы оценки моделей: метрики качества (accuracy, precision, recall, F1), кросс-валидация, переобучение и недообучение	20	4	4	12	ИД-2 ПК- 1.2 ИД-3 ПК- 1.1
7	Нейронные сети: базовая архитектура, функции активации, обучение с учителем, обратное распространение ошибки	20	4	4	12	ИД-3 ПК- 1.1 ИД-4 ПК- 1.2
8	Применение машинного обучения: работа с библиотеками, построение и внедрение моделей	22	4	4	12	ИД-5 ПК- 1.1 ИД-6 ПК- 1.2
Вид промежуточной аттестации (Экзамен)		+(54)				
Итого		216	32	32	98	

Очно-заочная форма обучения (полный срок)

№	Тема дисциплины	Трудоемкость				Код индикатора и дескриптора достижения компетенций
		Всего	Аудиторные занятия		СРО	
			Л	ПЗ (ЛЗ, СЗ)		
1	2	3	4	5	6	7
1	Введение в машинное обучение: основные понятия, типы задач (регрессия, классификация, кластеризация), этапы построения моделей	24	2	2	20	ИД-1 ОПК- 7.1 ИД-2 ОПК- 7.2

2	Предобработка данных: очистка данных, работа с пропусками, нормализация и масштабирование, кодирование категориальных признаков	24	2	2	20	ИД-2 ОПК- 7.2 ИД-3 ОПК- 7.1
3	Линейные модели: линейная и логистическая регрессия, функция потерь, регуляризация (L1, L2)	22	2	2	18	ИД-4 ОПК- 7.2 ИД-5 ОПК- 7.1
4	Деревья решений и ансамблевые методы: случайный лес, градиентный бустинг, переобучение и способы его устранения	22	2	2	18	ИД-5 ОПК- 7.1 ИД-6 ОПК- 7.2
5	Методы кластеризации: k-средних, иерархическая кластеризация, оценка качества кластеров	22	2	2	18	ИД-1 ПК- 1.1 ИД-2 ПК- 1.2
6	Методы оценки моделей: метрики качества (accuracy, precision, recall, F1), кросс-валидация, переобучение и недообучение	22	2	2	18	ИД-2 ПК- 1.2 ИД-3 ПК- 1.1
7	Нейронные сети: базовая архитектура, функции активации, обучение с учителем, обратное распространение ошибки	22	2	2	18	ИД-3 ПК- 1.1 ИД-4 ПК- 1.2
8	Применение машинного обучения: работа с библиотеками, построение и внедрение моделей	22	2	2	18	ИД-5 ПК- 1.1 ИД-6 ПК- 1.2
Вид промежуточной аттестации (Экзамен)		+(36)				
Итого		216	16	16	148	

Раздел 3. Содержание дисциплины

3.1. Содержание дисциплины

Тема 1. Введение в машинное обучение: основные понятия, типы задач (регрессия, классификация, кластеризация), этапы построения моделей

Определение машинного обучения как подсистемы искусственного интеллекта, способной обучаться на данных без явного программирования правил. Ключевые понятия: признак (feature), целевая переменная (target), объект, выборка (обучающая, валидационная, тестовая). Типы задач: регрессия (прогнозирование непрерывной величины), классификация (отнесение к категориям), кластеризация (группировка без учителя). Дополнительные типы: задачи ранжирования, обнаружения аномалий, понижения размерности. Этапы построения модели: постановка задачи, сбор и предобработка данных, выбор модели, обучение, оценка качества, настройка гиперпараметров, эксплуатация и мониторинг. Роль инженерного подхода: экспериментирование, воспроизводимость, итеративное улучшение. Основные вызовы: переобучение (overfitting), недообучение (underfitting), дисбаланс классов, дрейф данных. История развития машинного обучения: от перцептрона до трансформеров и больших языковых моделей.

Тема 2. Предобработка данных: очистка данных, работа с пропусками, нормализация и масштабирование, кодирование категориальных признаков

Качество данных как основной фактор успеха моделирования. Принцип GIGO (Garbage In, Garbage Out). Очистка данных: удаление дубликатов, исправление опечаток, фильтрация выбросов (методы IQR, Z-оценка). Типы пропусков: MCAR (случайные), MAR (условно-случайные), NMAR (неслучайные). Методы работы с пропусками: удаление строк/столбцов, заполнение константой, средним/медианой/модой, интерполяция, предсказание пропусков с помощью моделей. Нормализация и масштабирование: необходимость для градиентных методов. StandardScaler (Z-нормализация), MinMaxScaler (приведение к отрезку), RobustScaler (устойчив к выбросам), Normalizer (нормировка по длине вектора). Кодирование категориальных признаков: LabelEncoder (порядковое кодирование), OneHotEncoder (бинарные столбцы), OrdinalEncoder (для порядковых переменных), целевое кодирование (mean encoding). Создание новых признаков (feature engineering): полиномиальные признаки, взаимодействия, агрегирование, признаки на основе даты и времени. Обработка текстовых и изображений данных. Балансировка классов: методы ресемплинга (oversampling, undersampling, SMOTE).

Тема 3. Линейные модели: линейная и логистическая регрессия, функция потерь, регуляризация (L1, L2)

Линейная регрессия: модель вида $y = w * x + b$. Метод наименьших квадратов (MSE — Mean Squared Error). Аналитическое решение (нормальные уравнения) и градиентный спуск. Предположения линейной регрессии (линейность, нормальность остатков, гомоскедастичность, независимость ошибок). Оценка качества: R^2 , скорректированный R^2 , MAE, RMSE, MAPE. Логистическая регрессия: модель для бинарной классификации. Сигмоидная функция (логистическая функция) для преобразования линейной комбинации в вероятность. Функция потерь: Log Loss (бинарная кросс-энтропия). Граница принятия решений. Мультиклассовая логистическая регрессия: one-vs-rest (OvR) и softmax (мультиномиальная логистическая регрессия). Проблема переобучения линейных моделей. Регуляризация: L1 (Lasso) — приводит к разреженным коэффициентам, L2 (Ridge) — штрафует квадраты коэффициентов, ElasticNet — комбинация L1 и L2. Выбор силы регуляризации (гиперпараметр C или alpha). Интерпретация коэффициентов: вклад каждого признака в предсказание. Достоинства линейных моделей: простота, интерпретируемость, быстрота обучения и инференса. Недостатки: неспособность моделировать нелинейные зависимости без преобразования признаков.

Тема 4. Деревья решений и ансамблевые методы: случайный лес, градиентный бустинг, переобучение и способы его устранения

Деревья решений: принцип работы (рекурсивное разбиение пространства признаков). Крите-

рии разбиения: энтропия, Gini impurity (классификация), дисперсия (регрессия). Параметры дерева: максимальная глубина, минимальное количество объектов в листе, минимальное количество объектов для разбиения. Преимущества: интерпретируемость, работа с разными типами признаков, отсутствие необходимости масштабирования. Недостатки: склонность к переобучению, нестабильность (малые изменения данных меняют структуру). Ансамблевые методы: объединение нескольких моделей для улучшения качества. Бэггинг (Bagging): случайный лес — построение множества деревьев на случайных подвыборках данных и случайных подмножествах признаков. Усреднение предсказаний, снижение дисперсии. Оценка важности признаков в случайном лесу. Бустинг (Boosting): последовательное обучение моделей, каждая следующая исправляет ошибки предыдущих. Градиентный бустинг (GBM, XGBoost, LightGBM, CatBoost): градиентный спуск в пространстве функций. Преимущества градиентного бустинга: высокая точность, обработка пропусков, встроенная регуляризация. Борьба с переобучением в деревьях: ограничение глубины, увеличение минимального числа объектов в листе, early stopping, субдискретизация (subsampling), регуляризация. Сравнение случайного леса и градиентного бустинга: скорость обучения, интерпретируемость, устойчивость к выбросам.

Тема 5. Методы кластеризации: k-средних, иерархическая кластеризация, оценка качества кластеров

Кластеризация как задача обучения без учителя: группировка объектов на основе их сходства. Алгоритм k-средних (k-means): инициализация центроидов (случайный выбор, k-means++), шаг E (назначение объектов ближайшему центроиду), шаг M (пересчёт центроидов). Критерий остановки (стабилизация центроидов или минимизация WCSS — Within-Cluster Sum of Squares). Проблема выбора числа кластеров k: метод локтя (elbow method), силуэтный коэффициент (silhouette score), индекс Калински-Харабаса. Преимущества k-средних: простота, масштабируемость. Недостатки: чувствительность к инициализации и выбросам, предположение о сферичности кластеров, необходимость задавать k. Иерархическая кластеризация: агломеративные (снизу вверх) и дивизивные (сверху вниз) методы. Метрики расстояния: евклидово, манхэттенское, косинусное. Правила объединения кластеров: single linkage (ближайший сосед), complete linkage (дальний сосед), average linkage (среднее), метод Уорда (минимизация дисперсии). Визуализация: дендрограмма, выбор числа кластеров по высоте разреза. Оценка качества кластеризации без меток: силуэтный коэффициент, индекс Данна, индекс Дэвиса-Болдина. Оценка с метками (если есть): adjusted Rand index (ARI), adjusted mutual information (AMI), homogeneity, completeness, V-measure. Применение кластеризации: сегментация клиентов, анализ документов, сжатие изображений, обнаружение аномалий.

Тема 6. Методы оценки моделей: метрики качества (accuracy, precision, recall, F1), кросс-валидация, переобучение и недообучение

Понятие обобщающей способности модели (generalization). Необходимость оценки качества на данных, не участвовавших в обучении. Разделение выборки: тренировочная, валидационная, тестовая. Метрики для классификации: матрица ошибок (confusion matrix) — TP, TN, FP, FN. Accuracy (доля правильных ответов) — проблема дисбаланса классов. Precision (точность) — доля релевантных среди предсказанных положительных. Recall (полнота) — доля найденных положительных объектов. F1-мера — гармоническое среднее precision и recall. Специфичность (specificity) — доля верно отнесённых отрицательных объектов. ROC-кривая и AUC-ROC (площадь под кривой) для оценки разделяющей способности. PR-кривая (precision-recall) для сильно несбалансированных задач. Метрики для регрессии: MAE (средняя абсолютная ошибка), MSE (средняя квадратичная ошибка), RMSE (корень из MSE), MAPE (средняя абсолютная процентная ошибка), R^2 (коэффициент детерминации). Метрики для кластеризации (внутренние и внешние). Кросс-валидация: k-fold, stratified k-fold (для сохранения пропорции классов), leave-one-out, временная кросс-валидация. Оценка стабильности модели. Переобучение (overfitting): модель слишком сложная, хорошо запоминает обучающую выборку, плохо обобщает. Признаки: высокое качество на обучении, низкое — на тесте. Недообучение (underfitting): модель слишком простая, не выявляет закономерности. Признаки: низкое качество и на обучении, и на тесте. Диагностика с помощью кривых обучения (learning curves) и кривых валидации (validation curves). Стратегии

борьбы с переобучением: упрощение модели, регуляризация, увеличение данных, аугментация, early stopping. Стратегии борьбы с недообучением: усложнение модели, добавление признаков, уменьшение регуляризации.

Тема 7. Нейронные сети: базовая архитектура, функции активации, обучение с учителем, обратное распространение ошибки

Искусственный нейрон как вычислительная единица: взвешенная сумма входов, добавление смещения (bias), применение функции активации. Многослойный перцептрон (MLP): входной слой, скрытые слои, выходной слой. Полносвязные (dense) слои. Функции активации: сигмоида (Sigmoid) — сжимает выход в (0,1), гиперболический тангенс (Tanh) — в (-1,1), ReLU (Rectified Linear Unit) — устраняет проблему затухающего градиента, Leaky ReLU, ELU, Swish, Softmax (для многоклассовой классификации, превращает выходы в вероятности). Функции потерь: MSE (регрессия), бинарная кросс-энтропия (бинарная классификация), категориальная кросс-энтропия (многоклассовая классификация). Обучение нейронных сетей: градиентный спуск (SGD — Stochastic Gradient Descent), оптимизаторы: Momentum, Adam, RMSprop, AdaGrad. Backpropagation (обратное распространение ошибки): вычисление градиентов с помощью цепного правила, распространение ошибки от выхода ко входам. Проблема затухающего градиента (vanishing gradient) и взрывного градиента (exploding gradient). Инициализация весов (Xavier, He). Регуляризация в нейронных сетях: L1, L2 (weight decay), Dropout (случайное отключение нейронов), Batch Normalization (нормализация активаций). Early stopping как способ предотвращения переобучения. Понятие эпохи, батча, learning rate, планировщик скорости обучения. Выбор архитектуры: количество слоёв, количество нейронов на слое. Применение нейронных сетей: компьютерное зрение (CNN), обработка последовательностей (RNN, LSTM, Transformer), генеративные модели (GAN, VAE, диффузионные модели). Ограничения нейронных сетей: необходимость больших объёмов данных, вычислительные ресурсы, неинтерпретируемость.

Тема 8. Применение машинного обучения: работа с библиотеками, построение и внедрение моделей

Экосистема Python для машинного обучения: NumPy (численные вычисления), Pandas (работа с данными), Matplotlib, Seaborn (визуализация), Scikit-learn (классические алгоритмы), XGBoost, LightGBM, CatBoost (градиентный бустинг), TensorFlow, Keras, PyTorch (глубокое обучение). Пайплайн обучения модели: импорт библиотек, загрузка и предобработка данных, разделение выборки, обучение, оценка, настройка гиперпараметров. Использование Pipeline из Scikit-learn для объединения этапов предобработки и моделирования. Настройка гиперпараметров: GridSearchCV (полный перебор), RandomizedSearchCV (случайный поиск), Bayesian Optimization (Optuna, Hyperopt). Сохранение и загрузка моделей: pickle, joblib, onnx, сохранение весов нейронных сетей (h5, SavedModel). Внедрение модели в продуктивную среду: упаковка в контейнер (Docker), развертывание REST API (Flask, FastAPI, TorchServe, TF Serving), пакетный (batch) инференс, использование в облачных платформах (AWS SageMaker, Google Vertex AI, Yandex DataSphere). Мониторинг моделей в продакшене: детекция дрейфа данных (Data Drift) и концепта (Concept Drift), отслеживание метрик качества, логирование предсказаний, алертинг. Экспериментирование и версионирование: MLflow, Weights & Biases, DVC. MLOps: непрерывная интеграция и доставка моделей. Реальные кейсы применения: кредитный скоринг, рекомендательные системы, обнаружение мошенничества, прогнозирование спроса, медицинская диагностика, обработка естественного языка. Этические аспекты внедрения ML: предвзятость (bias), справедливость (fairness), объяснимость (explainability), приватность данных. Оценка экономической эффективности ML-решений.

3.2. Содержание практического блока дисциплины

Очная форма обучения (полный срок)

№	Тема практического (семинарского, лабораторного) занятия
1	Введение в машинное обучение: основные понятия, типы задач (регрессия, класси-

	фикация, кластеризация), этапы построения моделей
ПЗ 1	Знакомство со средой разработки: настройка Jupyter Notebook или VS Code, установка необходимых библиотек (numpy, pandas, matplotlib, seaborn, scikit-learn). Загрузка и первичное исследование датасетов (например, Iris, Boston Housing, Digits). Разделение данных на обучающую и тестовую выборки с помощью train_test_split. Реализация простейших моделей: линейная регрессия для предсказания стоимости жилья, логистическая регрессия для классификации ирисов, KMeans для кластеризации цифр. Сравнение качества моделей на обучающей и тестовой выборках. Визуализация результатов классификации и кластеризации. Обсуждение этапов построения моделей на практике: постановка задачи, подготовка данных, выбор модели, обучение, оценка. Анализ ошибок при неправильном разделении выборки или отсутствии предобработки.
ПЗ 2	Загрузка «грязного» датасета с пропусками, выбросами и категориальными признаками (например, Titanic, Adult Income). Анализ структуры данных: info, describe, isnull, unique. Очистка данных: удаление дубликатов, исправление типов данных. Визуализация выбросов с помощью boxplot и гистограмм, применение методов IQR и Z-оценки для их обнаружения, принятие решений об удалении или трансформации. Работа с пропусками: сравнение стратегий удаления строк (dropna), заполнение средним/медианой/модой (fillna), интерполяция, использование SimpleImputer из scikit-learn. Масштабирование признаков: применение StandardScaler, MinMaxScaler, RobustScaler, визуализация распределений до и после масштабирования. Кодирование категориальных признаков: LabelEncoder (порядковое кодирование для ordinal-переменных), OneHotEncoder (создание dummy-переменных), pd.get_dummies. Создание новых признаков: извлечение из даты (день недели, месяц, год), бинаризация непрерывных признаков, создание полиномиальных признаков с PolynomialFeatures. Оценка влияния предобработки на качество простой модели (логистическая регрессия). Оформление пайплайна предобработки с использованием ColumnTransformer.
ПЗ 3	Реализация линейной регрессии с использованием LinearRegression из scikit-learn на датасете с несколькими признаками. Вычисление коэффициентов модели и их интерпретация. Визуализация предсказаний vs реальных значений. Оценка качества с помощью MSE, MAE, R ² . Реализация логистической регрессии с LogisticRegression для бинарной классификации. Визуализация разделяющей поверхности для двух признаков. Интерпретация вероятностей (predict_proba) и границы принятия решений. Функции потерь: реализация MSE для линейной регрессии и Log Loss для логистической регрессии вручную (без использования готовых библиотек). Применение градиентного спуска: реализация простой версии с настройкой learning rate и числа итераций, сравнение с аналитическим решением. Регуляризация L1 (Lasso) и L2 (Ridge): обучение моделей с различными значениями параметра alpha, визуализация изменения коэффициентов (path plot). Сравнение разреженности коэффициентов при L1 и L2. Подбор оптимального alpha с помощью кросс-валидации (LassoCV, RidgeCV). Сравнение ElasticNet как комбинации L1 и L2. Анализ влияния масштабирования признаков на качество линейных моделей. Применение полиномиальных признаков (PolynomialFeatures) для моделирования нелинейных зависимостей, сравнение качества с обычной линейной регрессией.
ПЗ 4	Реализация дерева решений (DecisionTreeClassifier, DecisionTreeRegressor) на датасете с визуализацией структуры дерева (plot_tree, export_graphviz). Анализ влияния параметров (max_depth, min_samples_split, min_samples_leaf) на переобучение: построение кривых валидации. Реализация случайного леса (RandomForestClassifier, RandomForestRegressor). Оценка важности признаков (feature_importances_), визуализация в виде барплота. Сравнение качества случайного леса с одним деревом решений. Реализация градиентного бустинга: сравнение GradientBoostingClassifier, XGBoost, LightGBM, CatBoost. Подбор гиперпараметров (learning_rate, n_estimators,

	<p>max_depth, subsample) с помощью GridSearchCV и RandomizedSearchCV. Использование early stopping для предотвращения переобучения. Визуализация кривых обучения (learning curves) для диагностики переобучения и недообучения. Применение бэггинга и бустинга к одному и тому же датасету, сравнение времени обучения и качества. Использование кросс-валидации для оценки стабильности ансамблевых методов. Обработка дисбаланса классов с помощью class_weight и параметров scale_pos_weight в XGBoost.</p>
ПЗ 5	<p>Реализация алгоритма k-средних (KMeans) на синтетическом датасете (make_blobs) с визуализацией кластеров. Изучение проблемы инициализации: сравнение random и k-means++. Анализ влияния выбросов на центроиды. Выбор числа кластеров: метод локтя (инерция vs число кластеров), силуэтный коэффициент (silhouette_score), индекс Калински-Харабаса. Визуализация силуэтных диаграмм (silhouette_plot). Реализация иерархической кластеризации (AgglomerativeClustering). Построение дендрограммы с помощью scipy.cluster.hierarchy.dendrogram. Выбор числа кластеров по высоте разреза дендрограммы. Сравнение различных правил объединения (linkage): single, complete, average, ward. Применение кластеризации к реальному датасету (например, сегментация клиентов по поведенческим признакам). Нормализация признаков перед кластеризацией, сравнение результатов с и без масштабирования. Визуализация кластеров в 2D с помощью PCA и t-SNE. Оценка качества кластеризации с помощью внешних метрик (adjusted_rand_score, adjusted_mutual_info_score) если есть истинные метки, или внутренних (silhouette_score, davies_bouldin_score) если меток нет. Обсуждение интерпретации полученных кластеров и их практического применения.</p>
ПЗ 6	<p>Реализация задач классификации на датасете с дисбалансом классов (например, кредитный скоринг, обнаружение мошенничества). Вычисление матрицы ошибок (confusion_matrix) и её визуализация с помощью seaborn.heatmap. Расчёт метрик: accuracy, precision, recall, f1_score вручную и с использованием scikit-learn. Анализ ситуации, когда accuracy неинформативна, сравнение precision и recall. Построение ROC-кривой (roc_curve) и вычисление AUC-ROC (roc_auc_score). Сравнение ROC-AUC и PR-AUC (precision-recall curve) для несбалансированных данных. Кросс-валидация: реализация k-fold (KFold), stratified k-fold (StratifiedKFold) с сохранением пропорции классов. Сравнение результатов кросс-валидации с простым разбиением train/test. Использование cross_val_score, cross_validate. Диагностика переобучения и недообучения: построение кривых обучения (learning_curve) — график зависимости качества от размера обучающей выборки. Построение кривых валидации (validation_curve) для выбора гиперпараметра (например, max_depth дерева). Анализ графиков: зоны недообучения (низкое качество на трейне и тесте), переобучения (разрыв между трейном и тестом). Применение GridSearchCV и RandomizedSearchCV для подбора гиперпараметров с кросс-валидацией. Сравнение времени выполнения и качества различных методов поиска.</p>
ПЗ 7	<p>Знакомство с библиотеками глубокого обучения: установка TensorFlow и PyTorch. Создание простейшей нейронной сети (многослойный перцептрон) для классификации рукописных цифр MNIST. Определение архитектуры: входной слой ($28 \times 28 = 784$ нейрона), скрытые слои (например, 128 нейронов с ReLU), выходной слой (10 нейронов с Softmax). Компиляция модели: выбор оптимизатора (Adam, SGD), функции потерь (categorical_crossentropy), метрик (accuracy). Обучение модели: метод fit, определение эпох и батчей. Визуализация кривых обучения (потери и точность на обучающей и валидационной выборках). Эксперименты с различными функциями активации: ReLU, Sigmoid, Tanh, сравнение скорости сходимости и итогового качества. Изучение проблемы затухающего градиента на глубоких сетях. Реализация Dropout и BatchNormalization для борьбы с переобучением, сравнение результатов. Настройка скорости обучения: использование learning rate scheduling (ReduceLROnPlateau, ExponentialDecay). Реализация обратного распространения ошибки вручную (для простой сети с одним скрытым слоем) с использованием NumPy. Визуализация весов</p>

	и градиентов. Применение ранней остановки (EarlyStopping) для предотвращения переобучения. Сохранение и загрузка обученной модели (model.save, load_model). Загрузка предобученных моделей (например, VGG16, ResNet) из Keras Applications и их применение для извлечения признаков (transfer learning). Сравнение производительности нейронной сети с классическими алгоритмами (случайный лес, градиентный бустинг) на одной и той же задаче.
ПЗ 8	Построение полного пайплайна машинного обучения на примере реальной задачи (например, прогнозирование оттока клиентов или классификация текстов отзывов). Использование Pipeline из scikit-learn для объединения этапов предобработки (масштабирование, кодирование) и моделирования. Применение ColumnTransformer для отдельной обработки числовых и категориальных признаков. Оптимизация гиперпараметров пайплайна с помощью GridSearchCV. Сохранение лучшей модели в файл с помощью joblib или pickle. Создание простого REST API для модели с использованием FastAPI: загрузка сохранённой модели, определение эндпоинта predict, получение запроса в формате JSON, возврат предсказания. Контейнеризация приложения: написание Dockerfile, сборка образа, запуск контейнера. Тестирование API с помощью Postman или curl. Развёртывание модели в облачной среде (Google Colab с ngrok или локальный сервер). Логирование экспериментов с MLflow: фиксация параметров, метрик, артефактов. Настройка мониторинга: логирование предсказаний, вычисление метрик на новых данных, детекция дрейфа (вычисление PSI между обучающими и новыми данными). Оформление отчёта о проекте: постановка задачи, описание данных, выбранные модели, результаты, выводы. Презентация результатов с демонстрацией работы API. Обсуждение лучших практик MLOps и CI/CD для машинного обучения.

Очно-заочная форма обучения (полный срок)

№	Тема практического (семинарского, лабораторного) занятия
1	Введение в машинное обучение: основные понятия, типы задач (регрессия, классификация, кластеризация), этапы построения моделей
ПЗ 1	Знакомство со средой разработки: настройка Jupyter Notebook или VS Code, установка необходимых библиотек (numpy, pandas, matplotlib, seaborn, scikit-learn). Загрузка и первичное исследование датасетов (например, Iris, Boston Housing, Digits). Разделение данных на обучающую и тестовую выборки с помощью train_test_split. Реализация простейших моделей: линейная регрессия для предсказания стоимости жилья, логистическая регрессия для классификации ирисов, KMeans для кластеризации цифр. Сравнение качества моделей на обучающей и тестовой выборках. Визуализация результатов классификации и кластеризации. Обсуждение этапов построения моделей на практике: постановка задачи, подготовка данных, выбор модели, обучение, оценка. Анализ ошибок при неправильном разделении выборки или отсутствии предобработки.
ПЗ 2	Загрузка «грязного» датасета с пропусками, выбросами и категориальными признаками (например, Titanic, Adult Income). Анализ структуры данных: info, describe, isnull, unique. Очистка данных: удаление дубликатов, исправление типов данных. Визуализация выбросов с помощью boxplot и гистограмм, применение методов IQR и Z-оценки для их обнаружения, принятие решений об удалении или трансформации. Работа с пропусками: сравнение стратегий удаления строк (dropna), заполнение средним/медианой/модой (fillna), интерполяция, использование SimpleImputer из scikit-learn. Масштабирование признаков: применение StandardScaler, MinMaxScaler, RobustScaler, визуализация распределений до и после масштабирования. Кодирование категориальных признаков: LabelEncoder (порядковое кодирование для ordinal-переменных), OneHotEncoder (создание dummy-переменных), pd.get_dummies. Создание новых признаков: извлечение из даты (день недели, месяц, год), бинаризация непрерывных признаков, создание полиномиальных признаков с PolynomialFeatures. Оценка влияния предобработки на качество простой модели (логистическая регрес-

	сия). Оформление пайплайна предобработки с использованием ColumnTransformer.
ПЗ 3	<p>Реализация линейной регрессии с использованием LinearRegression из scikit-learn на датасете с несколькими признаками. Вычисление коэффициентов модели и их интерпретация. Визуализация предсказаний vs реальных значений. Оценка качества с помощью MSE, MAE, R². Реализация логистической регрессии с LogisticRegression для бинарной классификации. Визуализация разделяющей поверхности для двух признаков. Интерпретация вероятностей (predict_proba) и границы принятия решений.</p> <p>Функции потерь: реализация MSE для линейной регрессии и Log Loss для логистической регрессии вручную (без использования готовых библиотек). Применение градиентного спуска: реализация простой версии с настройкой learning rate и числа итераций, сравнение с аналитическим решением. Регуляризация L1 (Lasso) и L2 (Ridge): обучение моделей с различными значениями параметра alpha, визуализация изменения коэффициентов (path plot). Сравнение разреженности коэффициентов при L1 и L2. Подбор оптимального alpha с помощью кросс-валидации (LassoCV, RidgeCV). Сравнение ElasticNet как комбинации L1 и L2. Анализ влияния масштабирования признаков на качество линейных моделей. Применение полиномиальных признаков (PolynomialFeatures) для моделирования нелинейных зависимостей, сравнение качества с обычной линейной регрессией.</p>
ПЗ 4	<p>Реализация дерева решений (DecisionTreeClassifier, DecisionTreeRegressor) на датасете с визуализацией структуры дерева (plot_tree, export_graphviz). Анализ влияния параметров (max_depth, min_samples_split, min_samples_leaf) на переобучение: построение кривых валидации. Реализация случайного леса (RandomForestClassifier, RandomForestRegressor). Оценка важности признаков (feature_importances_), визуализация в виде барплота. Сравнение качества случайного леса с одним деревом решений. Реализация градиентного бустинга: сравнение GradientBoostingClassifier, XGBoost, LightGBM, CatBoost. Подбор гиперпараметров (learning_rate, n_estimators, max_depth, subsample) с помощью GridSearchCV и RandomizedSearchCV. Использование early stopping для предотвращения переобучения. Визуализация кривых обучения (learning curves) для диагностики переобучения и недообучения. Применение бэггинга и бустинга к одному и тому же датасету, сравнение времени обучения и качества. Использование кросс-валидации для оценки стабильности ансамблевых методов. Обработка дисбаланса классов с помощью class_weight и параметров scale_pos_weight в XGBoost.</p>
ПЗ 5	<p>Реализация алгоритма k-средних (KMeans) на синтетическом датасете (make_blobs) с визуализацией кластеров. Изучение проблемы инициализации: сравнение random и k-means++. Анализ влияния выбросов на центроиды. Выбор числа кластеров: метод локтя (инерция vs число кластеров), силуэтный коэффициент (silhouette_score), индекс Калински-Харабаса. Визуализация силуэтных диаграмм (silhouette plot). Реализация иерархической кластеризации (AgglomerativeClustering). Построение дендрограммы с помощью scipy.cluster.hierarchy.dendrogram. Выбор числа кластеров по высоте разреза дендрограммы. Сравнение различных правил объединения (linkage): single, complete, average, ward. Применение кластеризации к реальному датасету (например, сегментация клиентов по поведенческим признакам). Нормализация признаков перед кластеризацией, сравнение результатов с и без масштабирования. Визуализация кластеров в 2D с помощью PCA и t-SNE. Оценка качества кластеризации с помощью внешних метрик (adjusted_rand_score, adjusted_mutual_info_score) если есть истинные метки, или внутренних (silhouette_score, davies_bouldin_score) если меток нет. Обсуждение интерпретации полученных кластеров и их практического применения.</p>
ПЗ 6	<p>Реализация задач классификации на датасете с дисбалансом классов (например, кредитный скоринг, обнаружение мошенничества). Вычисление матрицы ошибок</p>

	<p>(<code>confusion_matrix</code>) и её визуализация с помощью <code>seaborn.heatmap</code>. Расчёт метрик: <code>accuracy</code>, <code>precision</code>, <code>recall</code>, <code>f1_score</code> вручную и с использованием <code>scikit-learn</code>. Анализ ситуации, когда <code>accuracy</code> неинформативна, сравнение <code>precision</code> и <code>recall</code>. Построение ROC-кривой (<code>roc_curve</code>) и вычисление AUC-ROC (<code>roc_auc_score</code>). Сравнение ROC-AUC и PR-AUC (<code>precision-recall curve</code>) для несбалансированных данных. Кросс-валидация: реализация <code>k-fold</code> (<code>KFold</code>), <code>stratified k-fold</code> (<code>StratifiedKFold</code>) с сохранением пропорции классов. Сравнение результатов кросс-валидации с простым разбиением <code>train/test</code>. Использование <code>cross_val_score</code>, <code>cross_validate</code>. Диагностика переобучения и недообучения: построение кривых обучения (<code>learning_curve</code>) — график зависимости качества от размера обучающей выборки. Построение кривых валидации (<code>validation_curve</code>) для выбора гиперпараметра (например, <code>max_depth</code> дерева). Анализ графиков: зоны недообучения (низкое качество на трейне и тесте), переобучения (разрыв между трейном и тестом). Применение <code>GridSearchCV</code> и <code>RandomizedSearchCV</code> для подбора гиперпараметров с кросс-валидацией. Сравнение времени выполнения и качества различных методов поиска.</p>
ПЗ 7	<p>Знакомство с библиотеками глубокого обучения: установка <code>TensorFlow</code> и <code>PyTorch</code>. Создание простейшей нейронной сети (многослойный перцептрон) для классификации рукописных цифр <code>MNIST</code>. Определение архитектуры: входной слой ($28 \times 28 = 784$ нейрона), скрытые слои (например, 128 нейронов с <code>ReLU</code>), выходной слой (10 нейронов с <code>Softmax</code>). Компиляция модели: выбор оптимизатора (<code>Adam</code>, <code>SGD</code>), функции потерь (<code>categorical_crossentropy</code>), метрик (<code>accuracy</code>). Обучение модели: метод <code>fit</code>, определение эпох и батчей. Визуализация кривых обучения (потери и точность на обучающей и валидационной выборках). Эксперименты с различными функциями активации: <code>ReLU</code>, <code>Sigmoid</code>, <code>Tanh</code>, сравнение скорости сходимости и итогового качества. Изучение проблемы затухающего градиента на глубоких сетях. Реализация <code>Dropout</code> и <code>BatchNormalization</code> для борьбы с переобучением, сравнение результатов. Настройка скорости обучения: использование <code>learning rate scheduling</code> (<code>ReduceLROnPlateau</code>, <code>ExponentialDecay</code>). Реализация обратного распространения ошибки вручную (для простой сети с одним скрытым слоем) с использованием <code>NumPy</code>. Визуализация весов и градиентов. Применение ранней остановки (<code>EarlyStopping</code>) для предотвращения переобучения. Сохранение и загрузка обученной модели (<code>model.save</code>, <code>load_model</code>). Загрузка предобученных моделей (например, <code>VGG16</code>, <code>ResNet</code>) из <code>Keras Applications</code> и их применение для извлечения признаков (<code>transfer learning</code>). Сравнение производительности нейронной сети с классическими алгоритмами (случайный лес, градиентный бустинг) на одной и той же задаче.</p>

3.3. Образовательные технологии Очная форма обучения (полный срок)

№	Тема занятия	Вид учебного занятия	Форма / Методы интерактивного обучения	% учебного времени
1	2	3	4	5
1	Введение в машинное обучение: основные понятия, типы задач (регрессия, классификация, кластеризация), этапы построения моделей	ПЗ	Дискуссионные технологии, Работа в малых группах, Взаимопроверка, Мозговой штурм, Интерактивные тренажёры	25
2	Предобработка данных: очистка данных, работа с пропусками, нормализация и масштабирование, кодирование категориальных признаков	ПЗ	Дискуссионные технологии, Групповое решение проблемных задач, Кейс-стади, Взаимообучение, Проектно-ориентированное обучение	25
3	Линейные модели: линейная и ло-	ПЗ	Работа в парах, Деловая игра,	25

	гистическая регрессия, функция потерь, регуляризация (L1, L2)		Дискуссионные технологии, Мозговой штурм, Интерактивная визуализация с коллективным обсуждением	
4	Деревья решений и ансамблевые методы: случайный лес, градиентный бустинг, переобучение и способы его устранения	ПЗ	Семинар-дискуссия, Работа в группах с презентацией, Ролевая игра, Интерактивная доска, Кейс-стади	25
5	Методы кластеризации: k-средних, иерархическая кластеризация, оценка качества кластеров	ПЗ	Групповое решение задач, Конкурс, Интерактивная визуализация, Мозговой штурм, Проектно-ориентированное обучение	25
6	Методы оценки моделей: метрики качества (accuracy, precision, recall, F1), кросс-валидация, переобучение и недообучение	ПЗ	Дискуссионные технологии, Работа в малых группах, Кейс-стади, Взаимопроверка, Анализ практических ситуаций	25
7	Нейронные сети: базовая архитектура, функции активации, обучение с учителем, обратное распространение ошибки	ПЗ	Работа в парах, Проектная деятельность, Мозговой штурм, Интерактивные тренажёры, Групповое обсуждение результатов	25
8	Применение машинного обучения: работа с библиотеками, построение и внедрение моделей	ПЗ	Проектно-ориентированное обучение, Работа в группах, Кейс-стади, Практическая работа, Презентация результатов	25
Итого				25%

Очно-заочная форма обучения (полный срок)

№	Тема занятия	Вид учебного занятия	Форма / Методы интерактивного обучения	% учебного времени
1	2	3	4	5
1	Введение в машинное обучение: основные понятия, типы задач (регрессия, классификация, кластеризация), этапы построения моделей	ПЗ	Дискуссионные технологии, Работа в малых группах, Взаимопроверка, Мозговой штурм, Интерактивные тренажёры	25
2	Предобработка данных: очистка данных, работа с пропусками, нормализация и масштабирование, кодирование категориальных признаков	ПЗ	Дискуссионные технологии, Групповое решение проблемных задач, Кейс-стади, Взаимообучение, Проектно-ориентированное обучение	25
3	Линейные модели: линейная и логистическая регрессия, функция потерь, регуляризация (L1, L2)	ПЗ	Работа в парах, Деловая игра, Дискуссионные технологии, Мозговой штурм, Интерактивная визуализация с коллективным обсуждением	25
4	Деревья решений и ансамблевые методы: случайный лес, градиентный бустинг, переобучение и способы его устранения	ПЗ	Семинар-дискуссия, Работа в группах с презентацией, Ролевая игра, Интерактивная доска, Кейс-стади	25

5	Методы кластеризации: k-средних, иерархическая кластеризация, оценка качества кластеров	ПЗ	Групповое решение задач, Конкурс, Интерактивная визуализация, Мозговой штурм, Проектно-ориентированное обучение	25
6	Методы оценки моделей: метрики качества (accuracy, precision, recall, F1), кросс-валидация, переобучение и недообучение	ПЗ	Дискуссионные технологии, Работа в малых группах, Кейс-стади, Взаимопроверка, Анализ практических ситуаций	25
7	Нейронные сети: базовая архитектура, функции активации, обучение с учителем, обратное распространение ошибки	ПЗ	Работа в парах, Проектная деятельность, Мозговой штурм, Интерактивные тренажёры, Групповое обсуждение результатов	25
Итого				25%

Раздел 4. Организация самостоятельной работы обучающихся

4.1. Организация самостоятельной работы обучающихся

№	Тема дисциплины	№ вопро- сов	№ рекоменду- емой литерату- ры
1	2	3	4
1	Введение в машинное обучение: основные понятия, типы задач (регрессия, классификация, кластеризация), этапы построения моделей	1-5	1, 2, 3, 12
2	Предобработка данных: очистка данных, работа с пропусками, нормализация и масштабирование, кодирование категориальных признаков	6-10	1, 2, 4, 13
3	Линейные модели: линейная и логистическая регрессия, функция потерь, регуляризация (L1, L2)	11-15	3, 4, 7, 8
4	Деревья решений и ансамблевые методы: случайный лес, градиентный бустинг, переобучение и способы его устранения	16-20	3, 4, 9, 8
5	Методы кластеризации: k-средних, иерархическая кластеризация, оценка качества кластеров	21-25	2, 7, 8, 9
6	Методы оценки моделей: метрики качества (accuracy, precision, recall, F1), кросс-валидация, переобучение и недообучение	26-30	2, 3, 7, 12
7	Нейронные сети: базовая архитектура, функции активации, обучение с учителем, обратное распространение ошибки	31-35	6, 7, 3, 12
8	Применение машинного обучения: работа с библиотеками, построение и внедрение моделей	36-40	1, 3, 4, 13, 14, 15

Перечень вопросов, выносимых на самостоятельную работу обучающихся

1. Что такое машинное обучение и где оно применяется?
2. Какие существуют типы задач машинного обучения?
3. В чём различие между обучением с учителем и без учителя?
4. Какие этапы включает процесс построения модели?
5. Что такое признаки и целевая переменная?
6. Зачем необходима предобработка данных?
7. Какие методы используются для обработки пропущенных значений?
8. Что такое нормализация и стандартизация данных?
9. Какие существуют способы кодирования категориальных признаков?
10. Что такое выбросы и как их обнаружить?
11. Что такое линейная регрессия?
12. В чём заключается метод наименьших квадратов?
13. Что такое логистическая регрессия и где она применяется?
14. Что такое функция потерь?
15. Зачем нужна регуляризация (L1, L2)?
16. Как устроено дерево решений?
17. Какие критерии используются для разбиения в деревьях?
18. Что такое переобучение?
19. Как работает случайный лес?
20. Что такое градиентный бустинг?
21. Что такое кластеризация?
22. Как работает алгоритм k-средних?
23. Как выбрать число кластеров?
24. Что такое иерархическая кластеризация?

25. Какие метрики используются для оценки кластеризации?
26. Что такое accuracy?
27. В чём разница между precision и recall?
28. Что такое F1-score?
29. Что такое матрица ошибок?
30. Что такое кросс-валидация?
31. Что такое нейронная сеть?
32. Какие функции активации существуют?
33. Что такое обратное распространение ошибки?
34. Что такое градиентный спуск?
35. Из каких слоёв состоит нейронная сеть?
36. Как происходит обучение модели на практике?
37. Какие библиотеки используются для машинного обучения?
38. Как разделяются данные на обучающую и тестовую выборки?
39. Что такое переобучение и как его избежать?
40. Как происходит внедрение модели в реальное приложение?

4.2. Перечень учебно-методического обеспечения самостоятельной работы обучающихся

Самостоятельная работа обучающихся обеспечивается следующими учебно-методическими материалами:

1. Указаниями в рабочей программе по дисциплине (п.4.1.)
2. Лекционные материалы в составе учебно-методического комплекса по дисциплине
3. Заданиями и методическими рекомендациями по организации самостоятельной работы обучающихся в составе учебно-методического комплекса по дисциплине.
4. Глоссарием по дисциплине в составе учебно-методического комплекса по дисциплине.

Раздел 5. Фонд оценочных средств для проведения текущего контроля и промежуточной аттестации обучающихся

Фонд оценочных средств по дисциплине представляет собой совокупность контролирующих материалов, предназначенных для измерения уровня достижения обучающимися установленных результатов образовательной программы. ФОС по дисциплине используется при проведении оперативного контроля и промежуточной аттестации обучающихся. Требования к структуре и содержанию ФОС дисциплины регламентируются Положением о фонде оценочных материалов по программам высшего образования – программам бакалавриата, магистратуры.

5.1. Паспорт фонда оценочных средств

Очная форма обучения (полный срок)

№	Контролируемые разделы (темы) дисциплины	Оценочные средства			
		Л	ПЗ (ЛЗ, СЗ)	СРО	Код индикатора и дескриптора достижения компетенций
1	2	3	4	5	6
1	Введение в машинное обучение: основные понятия, типы задач (регрессия, классификация, кластеризация), этапы построения моделей	УО	ЗЗ, МШ	ПРВ	ИД-1 ОПК- 7.1 ИД-2 ОПК- 7.2
2	Предобработка данных: очистка данных, работа с пропусками, нормализация и масштабирование, кодирование категориальных признаков	УО	ЗЗ, МШ	ПРВ	ИД-2 ОПК- 7.2 ИД-3 ОПК- 7.1
3	Линейные модели: линейная и логистическая регрессия, функция потерь, регуляризация (L1, L2)	УО	ЗЗ, Д, МШ	ПРВ	ИД-4 ОПК- 7.2 ИД-5 ОПК- 7.1
4	Деревья решений и ансамблевые методы: случайный лес, градиентный бустинг, переобучение и способы его устранения	УО	ЗЗ, Д, МП	ПРВ	ИД-5 ОПК- 7.1 ИД-6 ОПК- 7.2
5	Методы кластеризации: k-средних, иерархическая кластеризация, оценка качества кластеров	УО	ЗЗ, МШ	ПРВ	ИД-1 ПК- 1.1 ИД-2 ПК- 1.2
6	Методы оценки моделей: метрики качества (accuracy, precision, recall, F1), кросс-валидация, переобучение и недообучение	УО	ЗЗ, Д	ПРВ	ИД-2 ПК- 1.2 ИД-3 ПК- 1.1
7	Нейронные сети: базовая архитектура, функции активации, обучение с учителем, обратное распространение ошибки	УО	ЗЗ, МШ	ПРВ	ИД-3 ПК- 1.1 ИД-4 ПК- 1.2
8	Применение машинного обучения: работа с библиотеками, построение и внедрение моделей	УО	ЗЗ, Д	ПРВ	ИД-5 ПК- 1.1 ИД-6 ПК- 1.2

Очно-заочная форма обучения (полный срок)

№	Контролируемые разделы (темы) дисциплины	Оценочные средства			
		Л	ПЗ (ЛЗ, СЗ)	СРО	Код индикатора и дескриптора достижения компетенций

1	2	3	4	5	6
1	Введение в машинное обучение: основные понятия, типы задач (регрессия, классификация, кластеризация), этапы построения моделей	УО	ЗЗ, МШ	ПРВ	ИД-1 ОПК- 7.1 ИД-2 ОПК- 7.2
2	Предобработка данных: очистка данных, работа с пропусками, нормализация и масштабирование, кодирование категориальных признаков	УО	ЗЗ, МШ	ПРВ	ИД-2 ОПК- 7.2 ИД-3 ОПК- 7.1
3	Линейные модели: линейная и логистическая регрессия, функция потерь, регуляризация (L1, L2)	УО	ЗЗ, Д, МШ	ПРВ	ИД-4 ОПК- 7.2 ИД-5 ОПК- 7.1
4	Деревья решений и ансамблевые методы: случайный лес, градиентный бустинг, переобучение и способы его устранения	УО	ЗЗ, Д, МП	ПРВ	ИД-5 ОПК- 7.1 ИД-6 ОПК- 7.2
5	Методы кластеризации: k-средних, иерархическая кластеризация, оценка качества кластеров	УО	ЗЗ, МШ	ПРВ	ИД-1 ПК- 1.1 ИД-2 ПК- 1.2
6	Методы оценки моделей: метрики качества (accuracy, precision, recall, F1), кросс-валидация, переобучение и недообучение	УО	ЗЗ, Д	ПРВ	ИД-2 ПК- 1.2 ИД-3 ПК- 1.1
7	Нейронные сети: базовая архитектура, функции активации, обучение с учителем, обратное распространение ошибки	УО	ЗЗ, МШ	ПРВ	ИД-3 ПК- 1.1 ИД-4 ПК- 1.2
8	Применение машинного обучения: работа с библиотеками, построение и внедрение моделей			ПРВ	ИД-5 ПК- 1.1 ИД-6 ПК- 1.2

Условные обозначения оценочных средств (Столбцы 3, 4, 5):

ЗЗ – защита выполненных заданий (творческих, расчетных и т.д.), представление презентаций;

ПРВ – проверка рефератов, отчетов, рецензий, аннотаций, конспектов, графического материала, эссе, переводов, решений заданий, выполненных заданий в электронном виде и т.д.;

МШ – Метод мозгового штурма;

Д – Дискуссия, полемика, диспут, дебаты;

МП – Метод проектов.

5.2. Тематика письменных работ обучающихся

1. Основные этапы разработки моделей машинного обучения
2. Сравнение обучения с учителем и без учителя
3. Методы предобработки данных и их влияние на качество модели
4. Обработка пропущенных данных и выбросов в датасетах
5. Линейная регрессия: теория и практическое применение
6. Логистическая регрессия в задачах классификации
7. Регуляризация моделей и борьба с переобучением
8. Деревья решений: принципы построения и применения
9. Ансамблевые методы: случайный лес и градиентный бустинг
10. Методы кластеризации и их применение на практике
11. Алгоритм k-средних: преимущества и ограничения
12. Оценка качества моделей машинного обучения
13. Метрики классификации: анализ и сравнение
14. Проблема переобучения и методы её решения

15. Основы нейронных сетей и их применение
16. Алгоритм обратного распространения ошибки
17. Градиентный спуск и его разновидности
18. Использование библиотек машинного обучения (например, Scikit-learn)
19. Применение машинного обучения в реальных задачах
20. Развертывание моделей машинного обучения и основы MLOps

5.3. Перечень вопросов промежуточной аттестации по дисциплине

Вопросы к экзамену:

1. Понятие машинного обучения, его цели и области применения
2. Основные типы задач машинного обучения (классификация, регрессия, кластеризация)
3. Обучение с учителем и без учителя: различия и примеры
4. Основные этапы построения модели машинного обучения
5. Понятие признаков и целевой переменной
6. Предобработка данных: цели и основные методы
7. Обработка пропущенных значений и выбросов
8. Нормализация и стандартизация данных
9. Кодирование категориальных признаков
10. Линейная регрессия: модель и интерпретация
11. Метод наименьших квадратов
12. Логистическая регрессия и её применение
13. Функции потерь в машинном обучении
14. Регуляризация (L1, L2) и её роль
15. Деревья решений: структура и принцип работы
16. Критерии разбиения в деревьях решений (Gini, энтропия)
17. Переобучение: причины и способы предотвращения
18. Ансамблевые методы: случайный лес
19. Градиентный бустинг: принцип работы
20. Кластеризация: понятие и задачи
21. Алгоритм k-средних
22. Иерархическая кластеризация
23. Метрики оценки качества кластеризации
24. Метрики оценки моделей классификации (accuracy, precision, recall, F1)
25. Матрица ошибок и её анализ
26. Кросс-валидация и её значение
27. Основы нейронных сетей: структура и элементы
28. Функции активации и их роль
29. Обратное распространение ошибки
30. Развертывание моделей и применение машинного обучения на практике

Раздел 6. Оценочные средства промежуточной аттестации (с ключами)

1. Какой тип задачи машинного обучения относится к обучению без учителя?

- А) Линейная регрессия
- Б) Логистическая регрессия
- В) Кластеризация k-средних
- Г) Градиентный бустинг

Правильный ответ: В

2. Какая метрика используется для оценки качества регрессионной модели?

- А) Accuracy
- Б) F1-мера
- В) R^2

Г) AUC-ROC

Правильный ответ: В

3. Что делает метод StandardScaler в предобработке данных?

А) Приводит данные к диапазону [0, 1]

Б) Преобразует данные к нулевому среднему и единичной дисперсии

В) Удаляет выбросы из данных

Г) Заполняет пропущенные значения медианой

Правильный ответ: Б

4. Какая регуляризация приводит к разреженным коэффициентам модели (обнуляет некоторые признаки)?

А) L1-регуляризация (Lasso)

Б) L2-регуляризация (Ridge)

В) ElasticNet

Г) Dropout

Правильный ответ: А

5. Какая функция активации чаще всего используется в скрытых слоях глубоких нейронных сетей для борьбы с проблемой затухающего градиента?

А) Сигмоида

Б) Tanh

В) ReLU

Г) Softmax

Правильный ответ: В

6. Что такое переобучение (overfitting) в машинном обучении?

А) Модель слишком простая и не выявляет закономерности

Б) Модель слишком сложная и запоминает шумы в обучающих данных

В) Модель не может сойтись в процессе обучения

Г) Модель показывает одинаковое качество на обучении и тесте

Правильный ответ: Б

7. Какая метрика классификации вычисляется как $TP / (TP + FP)$?

А) Recall

Б) Precision

В) Accuracy

Г) F1-мера

Правильный ответ: Б

8. Какой алгоритм используется для поиска кратчайших путей в графах с неотрицательными весами?

А) Алгоритм Краскала

Б) Алгоритм Прима

В) Алгоритм Дейкстры

Г) Алгоритм Флойда-Уоршелла

Правильный ответ: В

9. Что такое кросс-валидация?

А) Метод оценки качества модели на отложенной выборке

Б) Метод подбора гиперпараметров

В) Метод оценки обобщающей способности модели с разбиением данных на несколько блоков

Г) Метод визуализации данных

Правильный ответ: В

10. Какая библиотека Python предназначена для глубокого обучения?

- А) Scikit-learn
- Б) Pandas
- В) TensorFlow
- Г) Matplotlib

Правильный ответ: В

11. Что делает алгоритм k-средних (k-means)?

- А) Строит дерево решений
- Б) Выполняет кластеризацию данных
- В) Обучает линейную регрессию
- Г) Выполняет снижение размерности

Правильный ответ: Б

12. Какая функция потерь используется в логистической регрессии для бинарной классификации?

- А) Mean Squared Error (MSE)
- Б) Mean Absolute Error (MAE)
- В) Binary Cross-Entropy (Log Loss)
- Г) Hinge Loss

Правильный ответ: В

13. Что такое градиентный бустинг?

- А) Ансамблевый метод, строящий деревья на случайных подвыборках
- Б) Ансамблевый метод, последовательно исправляющий ошибки предыдущих моделей
- В) Метод снижения размерности
- Г) Метод кластеризации

Правильный ответ: Б

14. Какой метод используется для визуализации высокоразмерных данных в 2D?

- А) PCA
- Б) KMeans
- В) Random Forest
- Г) Linear Regression

Правильный ответ: А

15. Что такое AUC-ROC?

- А) Метрика, показывающая долю правильных ответов
- Б) Метрика, оценивающая качество бинарной классификации как площадь под ROC-кривой
- В) Метод подбора гиперпараметров
- Г) Алгоритм кластеризации

Правильный ответ: Б

16. Какой метод предобработки лучше всего подходит для данных с выбросами?

- А) StandardScaler
- Б) MinMaxScaler
- В) RobustScaler
- Г) Normalizer

Правильный ответ: В

17. Что такое обратное распространение ошибки (backpropagation)?

- А) Алгоритм инициализации весов нейронной сети
- Б) Алгоритм вычисления градиентов функции потерь по параметрам нейронной сети

- В) Алгоритм выбора функции активации
 - Г) Алгоритм регуляризации
- Правильный ответ: Б

18. Какая метрика является гармоническим средним между precision и recall?

- А) Accuracy
- Б) F1-мера
- В) AUC-ROC
- Г) Specificity

Правильный ответ: Б

19. Что такое случайный лес (Random Forest)?

- А) Одно дерево решений
- Б) Ансамбль деревьев, построенных на случайных подвыборках данных и признаков
- В) Метод градиентного спуска
- Г) Алгоритм кластеризации

Правильный ответ: Б

20. Какой оптимизатор чаще всего используется по умолчанию в современных нейронных сетях?

- А) SGD
- Б) Adam
- В) Momentum
- Г) AdaGrad

Правильный ответ: Б

21. Что делает OneHotEncoder?

- А) Преобразует категориальные признаки в числовые порядковые метки
- Б) Преобразует категориальные признаки в бинарные векторные представления
- В) Масштабирует числовые признаки
- Г) Заполняет пропуски в данных

Правильный ответ: Б

22. Какая из следующих моделей наиболее интерпретируема?

- А) Глубокая нейронная сеть
- Б) Случайный лес
- В) Линейная регрессия
- Г) Градиентный бустинг

Правильный ответ: В

23. Что такое недообучение (underfitting)?

- А) Модель слишком сложная, переобучается
- Б) Модель слишком простая, не выявляет закономерности в данных
- В) Модель не может быть обучена из-за ошибок в данных
- Г) Модель показывает отличное качество на тестовой выборке

Правильный ответ: Б

24. Какой метод позволяет оценить качество модели на нескольких различных разбиениях данных?

- А) Train-test split
- Б) Кросс-валидация
- В) GridSearch
- Г) Градиентный спуск

Правильный ответ: Б

25. Что такое Dropout в нейронных сетях?

- А) Метод инициализации весов
- Б) Метод регуляризации, случайно отключающий нейроны во время обучения
- В) Метод выбора функции активации
- Г) Метод оптимизации

Правильный ответ: Б

26. Какая библиотека предоставляет реализацию алгоритма XGBoost?

- А) Scikit-learn
- Б) XGBoost
- В) TensorFlow
- Г) Pandas

Правильный ответ: Б

27. Что делает метод fit() в Scikit-learn?

- А) Применяет обученную модель к данным
- Б) Обучает модель на переданных данных
- В) Оценивает качество модели
- Г) Визуализирует результаты

Правильный ответ: Б

28. Какой метод используется для поиска оптимальных гиперпараметров модели?

- А) Градиентный спуск
- Б) Кросс-валидация
- В) GridSearchCV
- Г) Train-test split

Правильный ответ: В

29. Что такое эмбединги (embeddings) в контексте машинного обучения?

- А) Векторные представления объектов в непрерывном пространстве
- Б) Метод снижения размерности
- В) Алгоритм кластеризации
- Г) Функция активации

Правильный ответ: А

30. Какая метрика используется для оценки качества кластеризации, если истинные метки неизвестны?

- А) Adjusted Rand Index
- Б) Silhouette score
- В) F1-мера
- Г) Accuracy

Правильный ответ: Б

Раздел 7. Перечень учебной литературы, необходимой для освоения дисциплины

7.1. Основная литература

1. Маккинни У. Python и анализ данных. 3-е изд. Москва : ДМК Пресс, 2020. 540 с.
2. Вандер Плас Дж. Python для сложных задач: наука о данных и машинное обучение. Санкт-Петербург : Питер, 2018. 576 с.
3. Жерон О. Прикладное машинное обучение с помощью Scikit-Learn, Keras и TensorFlow. 3-е изд. Москва : Диалектика, 2021. 848 с.
4. Мюллер А., Гвидо С. Введение в машинное обучение с помощью Python. Москва : Вильямс, 2017. 480 с.

5. Бишоп К. Распознавание образов и машинное обучение. Москва : Вильямс, 2018. 744 с.

7.2. Дополнительная литература

1. Гудфеллоу И., Бенджио Й., Курвилль А. Глубокое обучение. Москва : ДМК Пресс, 2018. 652 с.
2. Мёрфи К. Машинное обучение: вероятностный подход. Москва : Вильямс, 2020. 1100 с.
3. Джеймс Г., Уиттен Д., Хасты Т., Тибширани Р. Введение в статистическое обучение. Москва : ДМК Пресс, 2019. 456 с.
4. Мохри М., Ростамизаде А., Талвалькар А. Основы машинного обучения. Москва : ДМК Пресс, 2018. 432 с.
5. Харрисон М. Машинное обучение на практике. Москва : Питер, 2020. 384 с.

7.3. Перечень ресурсов информационно-телекоммуникационной сети «Интернет»

1. Онлайн-курс «Machine Learning» (Coursera, Andrew Ng). Режим доступа: <https://www.coursera.org/learn/machine-learning> (дата обращения: 10.03.2026).
2. Видеолекции по машинному обучению (Stanford University). Режим доступа: <https://www.youtube.com/playlist?list=PLoROMvovd4rNHU1-iPeDRH-J0cL-CrIda> (дата обращения: 10.03.2026).
3. Документация библиотеки Scikit-learn. Режим доступа: <https://scikit-learn.org/stable/> (дата обращения: 10.03.2026).
4. Электронная библиотечная система «Лань». Режим доступа: <https://e.lanbook.com> (дата обращения: 10.03.2026).
5. Образовательная платформа «Юрайт». Режим доступа: <https://urait.ru> (дата обращения: 10.03.2026).

Раздел 8. Материально-техническая база и информационные технологии

Материально-техническая база, необходимая для осуществления образовательного процесса по дисциплине:

Материально-техническое обеспечение дисциплины «**Машинное обучение**» включает в себя учебные аудитории для проведения занятий, групповых и индивидуальных консультаций, текущего контроля и промежуточной аттестации, самостоятельной работы обучающихся.

Учебные аудитории укомплектованы специализированной мебелью и техническими средствами обучения. Помещения для самостоятельной работы обучающихся оснащены компьютерной техникой с возможностью подключения к сети Интернет.

Дисциплина может реализовываться с применением дистанционных технологий обучения. Специфика реализации дисциплины с применением дистанционных технологий обучения устанавливается дополнением к рабочей программе. В части не противоречащей специфике, изложенной в дополнении к программе, применяется настоящая рабочая программа.

Материально-техническая база, необходимая для осуществления образовательного процесса по дисциплине с применением дистанционных образовательных технологий включает в себя:

Компьютерная техника, расположенная в учебном корпусе Института (ул. Качинцев, 63, кабинет Центра дистанционного обучения):

1. Intel i 3 3.4Ghz\ОЗУ 4Gb\500GB\RadeonHD5450
2. Intel PENTIUM 2.9GHz\ОЗУ 4GB\500GB

3 личные электронные устройства (компьютеры, ноутбуки, планшеты и иное), а также средства связи преподавателей и студентов.

Информационные технологии, необходимые для осуществления образовательного процесса по дисциплине с применением дистанционных образовательных технологий включают в себя:

- система дистанционного обучения (СДО) (Learning Management System) (LMS) Moodle (Modular Object-Oriented Dynamic Learning Environment);

- электронная почта;
- система компьютерного тестирования;
- Цифровой образовательный ресурс IPR SMART;
- система интернет-связи skype;
- телефонная связь;
- ПО для организации конференций.

Обучение обучающихся инвалидов и обучающихся с ограниченными возможностями здоровья осуществляется посредством применения специальных технических средств в зависимости от вида нозологии.

При проведении учебных занятий по дисциплине используются мультимедийные комплексы, электронные учебники и учебные пособия, адаптированные к ограничениям здоровья обучающихся.

Лекционные аудитории оборудованы мультимедийными кафедрами, подключенными к звуковым колонкам, позволяющими усилить звук для категории слабослышащих обучающихся, а также проекционными экранами, которые увеличивают изображение в несколько раз и позволяют воспринимать учебную информацию обучающимся с нарушениями зрения.

При обучении лиц с нарушениями слуха используется усилитель слуха для слабослышащих людей Cyber Ear модель NAP-40, помогающий обучаемым лучше воспринимать учебную информацию.

Обучающиеся с ограниченными возможностями здоровья, обеспечены печатными и электронными образовательными ресурсами (программы, учебники, учебные пособия, материалы для самостоятельной работы и т.д.) в формах, адаптированных к ограничениям их здоровья и восприятия информации:

для лиц с нарушениями зрения:

- в форме электронного документа;
- в форме аудиофайла;

для лиц с нарушениями слуха:

- в печатной форме;
 - в форме электронного документа;
- для лиц с нарушениями опорно-двигательного аппарата:**
- в печатной форме;
 - в форме электронного документа;
 - в форме аудиофайла.

Раздел 9. Методические указания для обучающихся по освоению дисциплины

Дисциплина включает практические занятия, самостоятельную работу обучающегося.

В ходе изучения дисциплины «Машинное обучение» перед обучающимися стоит задача не только закрепить знания о сложных информационных явлениях, о чем свидетельствует содержание тематического плана, глубоко разобраться в объемном учебном материале, но и сформировать у себя на основе полученных компьютерных знаний соответствующие профессионально важные качества.

Практические занятия – один из самых эффективных видов учебных занятий, на которых обучающиеся учатся творчески работать с различной информацией, являются также действенной формой активизации самостоятельной работы обучающихся.

Целью практических занятий является закрепление полученных в ходе лекций, а также в ходе самостоятельной работы над учебной и специальной литературой, знаний, умений и навыков. На практических занятиях особо обращается внимание на умение обучающихся проявлять элементы творчества в процессе самостоятельной работы, применять полученные знания на практике.

Практические занятия занимают центральное место в учебном процессе, так как позволяют на завершающем этапе усвоения материала, после прослушанной лекции и самостоятельного поиска дополнительных сведений по рассматриваемой проблематике, окончательно уточнить, сформировать свои позиции в ходе работы в составе учебной группы.

Основное в подготовке и проведении практикума – это самостоятельная работа обучающегося над изучением темы лекционного материала. Практические занятия проводятся по специальным планам – заданиям, которые содержатся в материалах, подготовленных на кафедре. Обучающийся обязан точно знать план занятия либо конкретное задание к нему.

При подготовке к практическим занятиям следует чаще обращаться к справочной литературе, полнее использовать консультации (групповые и индивидуальные, устные и письменные) с преподавателями, которые читают лекции и проводят практикумы.

Таким образом, в процессе подготовке к практическому занятию рекомендуется:

- ознакомиться с вопросами плана;
- прочитать конспект лекции по изучаемой теме;
- прочитать соответствующие главы учебников, статьи;
- просмотреть перечень научных источников, предлагаемых в рабочей программе, выбрав несколько из них для углубленного изучения данной темы.

По каждому практическому заданию обучающиеся отчитываются преподавателю, оформляя письменный отчет, в котором сохраняют результаты своей работы в виде файлов. Результаты выполнения практических заданий оцениваются с учетом теоретических знаний по соответствующим вопросам дисциплины и уровнем владения практическими навыками при работе на компьютере.

Для углубленного изучения и освоения материала целесообразно выполнение практических работ, наряду с другими различными формами обучения обучающихся: тесты, задачи, упражнения, которые используются при проведении практических занятий, выполнении контрольных и аудиторных работ, а также при самостоятельном изучении данной дисциплины.

Одним из наиболее интенсивных способов изучения дисциплины является самостоятельное выполнение практических работ, на которых вырабатываются навыки по дисциплине «Машинное обучение».

СРО позволяет глубже освоить теоретические и практические вопросы, понять принципы дисциплины «Машинное обучение».

Основными задачами организации процесса самостоятельной работы по дисциплине являются:

- приобретение знаний по теоретическим основам дисциплины «Машинное обучение», являющихся дополнением к материалу лекционных аудиторных занятий;
- приобретение практических навыков по дисциплине «Машинное обучение».

Основные формы реализации СРО – изучение учебно-методической литературы по дисциплине «Машинное обучение». В качестве базовой литературы можно использовать учебники и учебные пособия, согласно приведенному списку в разделе 6 рабочей программы, а также любые

другие источники информации, такие как электронные учебники, обучающие и энциклопедические сайты, публикации журналов и конференций.

Обучающийся допускается к зачетному занятию по результатам успешного выполнения всех практических заданий и самостоятельной работы.

Учебно-методическое издание

Рабочая программа учебной дисциплины

Машинное обучение

(Наименование дисциплины в соответствии с учебным планом)

Скоробогатченко Дмитрий Анатольевич

(Фамилия, Имя, Отчество составителя)
