

**МИНИСТЕРСТВО ТРАНСПОРТА РОССИЙСКОЙ ФЕДЕРАЦИИ**  
**ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ АВТОНОМНОЕ ОБРАЗОВАТЕЛЬНОЕ**  
**УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ**  
**«РОССИЙСКИЙ УНИВЕРСИТЕТ ТРАНСПОРТА»**  
**(РУТ (МИИТ))**



Рабочая программа дисциплины (модуля),  
как компонент образовательной программы  
базового высшего образования  
по направлению подготовки  
09.03.01 Информатика и вычислительная техника,  
утвержденной первым проректором РУТ (МИИТ)  
Тимониным В.С.

**РАБОЧАЯ ПРОГРАММА ДИСЦИПЛИНЫ (МОДУЛЯ)**

**Машинное обучение и нейронные сети**

Направление подготовки: 09.03.01 Информатика и вычислительная техника

Направленность (профиль): Технологии разработки программного обеспечения

Форма обучения: Очная

Рабочая программа дисциплины (модуля) в виде электронного документа выгружена из единой корпоративной информационной системы управления университетом и соответствует оригиналу

Простая электронная подпись, выданная РУТ (МИИТ)  
ID подписи: 5665  
Подписал: заведующий кафедрой Нутович Вероника Евгеньевна  
Дата: 01.09.2026

## 1. Общие сведения о дисциплине (модуле).

Дисциплина «Машинное обучение и нейронные сети» формирует у студентов компетенции, критически востребованные на современном рынке труда в сфере разработки программного обеспечения и цифровой трансформации транспортной отрасли. Курс отвечает на острый кадровый дефицит ML-инженеров, способных не только обучать математические модели в изолированных средах, но и бесшовно интегрировать их в корпоративные информационные системы. В рамках дисциплины рассматриваются классические алгоритмы машинного обучения, архитектуры глубоких нейронных сетей для работы с табличными данными, временными рядами и изображениями, а также современные практики инженерии искусственного интеллекта. Студенты на практике осваивают полный жизненный цикл интеллектуального компонента – от формализации бизнес-задачи и конструирования признаков до экспорта моделей в производственные форматы, создания высокопроизводительных REST API и контейнеризации микросервисов с использованием отечественного и открытого программного обеспечения. Выпускник получает навыки проектирования отказоустойчивых систем предиктивной аналитики и компьютерного зрения, готовых к внедрению в критическую инфраструктуру.

Целью освоения дисциплины является формирование у обучающихся системных теоретических знаний и прикладных инженерных навыков в области машинного обучения и глубоких нейронных сетей, необходимых для самостоятельного проектирования, обучения, оптимизации и бесшовной интеграции компонентов искусственного интеллекта в реальные программные продукты и корпоративные информационные системы.

Для достижения поставленной цели в рамках дисциплины решается комплекс задач, направленных на формирование у обучающихся способности: анализировать бизнес-требования и формализовать их в виде математических постановок задач машинного обучения, конструировать отказоустойчивые конвейеры предобработки многомерных данных и временных рядов, выбирать и обучать классические алгоритмы и ансамблевые методы с учетом дисбаланса классов и цены ошибки, проектировать и регуляризовать архитектуры сверточных и рекуррентных нейронных сетей для задач компьютерного зрения и прогнозирования, экспортировать обученные модели в кроссплатформенные форматы, а также разрабатывать, тестировать и контейнеризировать высокопроизводительные микросервисы на базе REST API для промышленного развертывания.

## 2. Планируемые результаты обучения по дисциплине (модулю).

Перечень формируемых результатов освоения образовательной программы (компетенций) в результате обучения по дисциплине (модулю):

**ПК-6** - Способен проектировать и интегрировать в программные продукты компоненты на основе технологий искусственного интеллекта.

Обучение по дисциплине (модулю) предполагает, что по его результатам обучающийся будет:

### **Знать:**

- концептуальные основы и жизненный цикл разработки систем машинного обучения, методология CRISP-DM;
- математический аппарат линейной и нелинейной регрессии, методы оптимизации и градиентного спуска;
- теоретические основы задач классификации, логистическая регрессия и метод опорных векторов (SVM);
- алгоритмы построения деревьев решений, критерии информативности и метрические методы классификации;
- архитектура и математическое обоснование ансамблевых методов (бэггинг, случайный лес, градиентный бустинг);
- методы обучения без учителя, алгоритмы кластеризации и понижения размерности пространства признаков (PCA);
- статистические метрики оценки качества моделей, стратегии кросс-валидации и компромисс между смещением и дисперсией (bias-variance tradeoff);
- архитектура конвейеров обработки данных (Scikit-Learn Pipeline) и методы предотвращения утечки информации (data leakage);
- математическая модель искусственного нейрона, архитектура перцептрона и алгоритм обратного распространения ошибки (backpropagation);
- принципы построения глубоких многослойных сетей (MLP), классы функций активации и функции потерь;
- методы борьбы с переобучением нейронных сетей, техники регуляризации (Dropout, L2) и пакетной нормализации (BatchNorm);
- архитектурные принципы сверточных нейронных сетей (CNN), концепция рецептивных полей и слои пулинга для задач компьютерного зрения;
- методология переноса обучения (Transfer Learning) и стратегии адаптации предобученных моделей под прикладные задачи;

- архитектура рекуррентных сетей (RNN, LSTM, GRU) для анализа последовательностей и прогнозирования временных рядов;
- методы оптимизации, сжатия и квантования нейросетевых моделей для развертывания на периферийных устройствах (Edge AI);
- стандарты сериализации, экспорта и кроссплатформенного инференса ML-моделей (ONNX, pickle, SavedModel);
- архитектурные паттерны проектирования REST API и микросервисов для бесшовной интеграции ИИ-компонентов;
- технологии контейнеризации, изоляции зависимостей и подготовки среды для промышленного развертывания (Docker);
- принципы инженерии машинного обучения (MLOps), версионирование артефактов и мониторинг дрейфа данных в продакшене.

### **Уметь:**

- проектировать архитектуру ML-пайплайна при помощи Scikit-Learn Pipeline и DAG-схем в условиях обеспечения воспроизводимости экспериментов и предотвращения утечки данных (data leakage);
- конструировать признаки из временных рядов телеметрии при помощи Pandas, NumPy и методов скользящих окон (rolling features, Fourier transform) в условиях работы с многомерными данными датчиков подвижного состава;
- выбирать и обучать алгоритмы регрессии и классификации при помощи Scikit-Learn (Logistic Regression, SVM, Decision Trees) в условиях учета дисбаланса классов и специфики транспортной задачи;
- применять ансамблевые методы (Random Forest, Gradient Boosting) при помощи CatBoost и Scikit-Learn в условиях настройки гиперпараметров через кросс-валидацию с временным разбиением (TimeSeriesSplit);
- оценивать качество моделей с использованием специфичных метрик при помощи ROC-AUC, Precision-Recall, Confusion Matrix и анализа стоимости ошибок в условиях обоснования выбора метрики перед бизнес-заказчиком;
- проектировать и обучать многослойные нейронные сети (MLP) при помощи TensorFlow/Keras или PyTorch в условиях применения методов регуляризации (Dropout, BatchNorm, L2) и ранней остановки (Early Stopping);
- разрабатывать сверточные нейронные сети (CNN) для задач компьютерного зрения при помощи современных архитектур (ResNet, EfficientNet) и Transfer Learning в условиях детекции дефектов на изображениях транспортной инфраструктуры;
- применять рекуррентные сети (RNN/LSTM/GRU) для анализа последовательностей при помощи TensorFlow/Keras в условиях работы с

временными рядами телеметрии и прогнозирования остаточного ресурса узлов;

- экспортировать обученные модели в производственные форматы при помощи ONNX Runtime, pickle и SavedModel в условиях проведения бенчмарков скорости инференса и кроссплатформенной совместимости;

- интегрировать ML-модели в программные продукты через REST API при помощи FastAPI и валидации входных данных (Pydantic) в условиях обеспечения обработки некорректных запросов (HTTP 400) и документирования endpoints через OpenAPI/Swagger;

- контейнеризировать ML-сервисы для развертывания при помощи Docker и Docker Compose в условиях изоляции зависимостей, воспроизводимости окружения и подготовки к CI/CD-пайплайну.

### **Владеть:**

- инструментарием контейнеризации и оркестрации микросервисов для изолированного развертывания компонентов искусственного интеллекта;

- методами экспорта и кроссплатформенного инференса нейросетевых моделей в производственных средах;

- навыками настройки конвейеров предобработки данных с гарантией отсутствия утечки информации;

- приемами отладки и профилирования производительности REST API, обслуживающего запросы к моделям машинного обучения;

- методиками статистической валидации и мониторинга дрейфа данных внедряемых интеллектуальных компонентов.

## 3. Объем дисциплины (модуля).

### 3.1. Общая трудоемкость дисциплины (модуля).

Общая трудоемкость дисциплины (модуля) составляет 5 з.е. (180 академических часа(ов)).

3.2. Объем дисциплины (модуля) в форме контактной работы обучающихся с педагогическими работниками и (или) лицами, привлекаемыми к реализации образовательной программы на иных условиях, при проведении учебных занятий:

Тип учебных занятий	Количество часов	
	Всего	Семестр №6
Контактная работа при проведении учебных занятий (всего):	96	96
В том числе:		
Занятия лекционного типа	32	32
Занятия семинарского типа	64	64

3.3. Объем дисциплины (модуля) в форме самостоятельной работы обучающихся, а также в форме контактной работы обучающихся с педагогическими работниками и (или) лицами, привлекаемыми к реализации образовательной программы на иных условиях, при проведении промежуточной аттестации составляет 84 академических часа (ов).

3.4. При обучении по индивидуальному учебному плану, в том числе при ускоренном обучении, объем дисциплины (модуля) может быть реализован полностью в форме самостоятельной работы обучающихся, а также в форме контактной работы обучающихся с педагогическими работниками и (или) лицами, привлекаемыми к реализации образовательной программы на иных условиях, при проведении промежуточной аттестации.

#### 4. Содержание дисциплины (модуля).

##### 4.1. Занятия лекционного типа.

№ п/п	Тематика лекционных занятий / краткое содержание
1	<b>Введение в машинное обучение и жизненный цикл ML-проектов</b> Рассматриваемые вопросы: - концептуальные основы машинного обучения как инженерной дисциплины; - методология CRISP-DM и этапы разработки ML-систем; - роль ML-инженера в ИТ-команде и интеграция моделей в продукты; - постановка бизнес-задачи и её формализация в терминах ML.
2	<b>Линейная и нелинейная регрессия: математический аппарат и оптимизация</b> Рассматриваемые вопросы: - математическая модель линейной регрессии и метод наименьших квадратов; - градиентный спуск и его модификации (SGD, Adam); - полиномиальная регрессия и регуляризация (Ridge, Lasso); - интерпретируемость моделей и анализ коэффициентов.
3	<b>Задачи классификации: от логистической регрессии до SVM</b> Рассматриваемые вопросы: - логистическая регрессия и сигмоидная функция активации; - метод опорных векторов (SVM) и концепция максимального зазора; - ядерный трюк (kernel trick) для нелинейного разделения; - многоклассовая классификация (one-vs-rest, one-vs-one).
4	<b>Деревья решений и метрические методы классификации</b> Рассматриваемые вопросы: - алгоритмы построения деревьев решений (ID3, C4.5, CART); - критерии информативности (энтропия, индекс Джини); - методы отсечения (pruning) для борьбы с переобучением; - метрические классификаторы (kNN) и выбор метрик расстояния.

№ п/п	Тематика лекционных занятий / краткое содержание
5	<b>Ансамблевые методы: от бэггинга до градиентного бустинга</b> Рассматриваемые вопросы: <ul style="list-style-type: none"> <li>- принцип бэггинга и архитектура случайного леса (Random Forest);</li> <li>- концепция бустинга и AdaBoost;</li> <li>- градиентный бустинг (GBM) и его реализации (XGBoost, LightGBM, CatBoost);</li> <li>- интерпретация важности признаков в ансамблях.</li> </ul>
6	<b>Обучение без учителя: кластеризация и понижение размерности</b> Рассматриваемые вопросы: <ul style="list-style-type: none"> <li>- алгоритм k-means и методы выбора числа кластеров (elbow method, silhouette);</li> <li>- иерархическая кластеризация и дендрограммы;</li> <li>- метод главных компонент (PCA) и его геометрическая интерпретация;</li> <li>- t-SNE и UMAP для визуализации многомерных данных.</li> </ul>
7	<b>Оценка качества моделей и стратегии валидации</b> Рассматриваемые вопросы: <ul style="list-style-type: none"> <li>- метрики регрессии (MAE, MSE, RMSE, R?) и классификации (Accuracy, Precision, Recall, F1);</li> <li>- ROC-кривая и площадь под кривой (ROC-AUC);</li> <li>- Precision-Recall кривая для задач с дисбалансом классов;</li> <li>- стратегии кросс-валидации (k-fold, stratified, TimeSeriesSplit);</li> <li>- компромисс между смещением и дисперсией (bias-variance tradeoff).</li> </ul>
8	<b>Конвейеры обработки данных и предотвращение утечки информации</b> Рассматриваемые вопросы: <ul style="list-style-type: none"> <li>- архитектура Scikit-Learn Pipeline и его преимущества;</li> <li>- концепция утечки данных (data leakage) и её последствия;</li> <li>- правильная последовательность предобработки внутри пайплайна;</li> <li>- пользовательские трансформеры (FunctionTransformer, BaseEstimator).</li> </ul>
9	<b>Искусственные нейронные сети: от перцептрона к глубоким архитектурам</b> Рассматриваемые вопросы: <ul style="list-style-type: none"> <li>- математическая модель нейрона и перцептрон Розенблатта;</li> <li>- алгоритм обратного распространения ошибки (backpropagation);</li> <li>- многослойный перцептрон (MLP) и универсальная теорема аппроксимации;</li> <li>- функции активации (ReLU, sigmoid, tanh) и проблема исчезающих градиентов.</li> </ul>
10	<b>Регуляризация и борьба с переобучением нейронных сетей</b> Рассматриваемые вопросы: <ul style="list-style-type: none"> <li>- L1 и L2 регуляризация весов нейронной сети;</li> <li>- метод Dropout и его стохастическая природа;</li> <li>- пакетная нормализация (Batch Normalization) и её влияние на сходимость;</li> <li>- ранняя остановка (Early Stopping) и мониторинг validation loss.</li> </ul>
11	<b>Свёрточные нейронные сети для задач компьютерного зрения</b> Рассматриваемые вопросы: <ul style="list-style-type: none"> <li>- концепция свёртки и рецептивного поля;</li> <li>- архитектура CNN: свёрточные слои, пулинг, полносвязные слои;</li> <li>- эволюция архитектур (LeNet, AlexNet, VGG, ResNet, EfficientNet);</li> <li>- техники аугментации данных для изображений.</li> </ul>
12	<b>Перенос обучения и адаптация предобученных моделей</b> Рассматриваемые вопросы: <ul style="list-style-type: none"> <li>- концепция Transfer Learning и её преимущества;</li> <li>- стратегии fine-tuning и feature extraction;</li> <li>- работа с предобученными моделями из TensorFlow Hub и PyTorch Hub;</li> <li>- адаптация моделей под специфичные транспортные задачи.</li> </ul>

№ п/п	Тематика лекционных занятий / краткое содержание
13	Рекуррентные нейронные сети для анализа последовательностей Рассматриваемые вопросы: - архитектура RNN и проблема долгосрочных зависимостей; - LSTM и GRU как решения проблемы исчезающих градиентов; - двунаправленные рекуррентные сети (BiLSTM); - применение RNN для прогнозирования временных рядов телеметрии.
14	Оптимизация и экспорт моделей в производственные форматы Рассматриваемые вопросы: - стандарты сериализации моделей (pickle, joblib, SavedModel, .h5); - формат ONNX и его преимущества для кроссплатформенности; - квантование и сжатие моделей для Edge AI; - бенчмаркинг скорости инференса и оптимизация под целевое железо.
15	Архитектура REST API для интеграции ML-моделей Рассматриваемые вопросы: - принципы REST и проектирование endpoints для ML-сервисов; - фреймворк FastAPI и валидация данных через Pydantic; - обработка ошибок и HTTP-коды ответов; - автоматическая генерация документации через OpenAPI/Swagger.
16	Контейнеризация и основы MLOps для промышленного развертывания Рассматриваемые вопросы: - концепция контейнеризации и преимущества Docker; - написание Dockerfile для ML-сервиса и оптимизация размера образа; - Docker Compose для оркестрации многокомпонентных систем; - основы MLOps: версионирование моделей, мониторинг дрейфа данных.

## 4.2. Занятия семинарского типа.

### Лабораторные работы

№ п/п	Наименование лабораторных работ / краткое содержание
1	Настройка среды разработки и версионирование данных Студент разворачивает локальную среду разработки с настройкой виртуального окружения и системы контроля версий. Пишется базовый скрипт для загрузки и первичного разведочного анализа телеметрических данных. Настраивается структура каталогов проекта для обеспечения воспроизводимости экспериментов.
2	Реализация Scikit-Learn Pipeline с кастомными трансформерами Студент программирует конвейер предобработки с использованием объектно-ориентированного подхода и базовых классов библиотеки Scikit-Learn. Создаются пользовательские трансформеры для извлечения статистических признаков из многомерных временных рядов. Проводится тестирование конвейера на предмет отсутствия утечки данных при кросс-валидации.
3	Программная реализация градиентного спуска и обучение линейных моделей Студент реализует алгоритм градиентного спуска с нуля с использованием матричных операций библиотеки NumPy. Обучаются модели линейной регрессии с применением L1 и L2 регуляризации на подготовленном наборе данных. Проводится визуализация сходимости алгоритма и анализируется влияние скорости обучения на стабильность оптимизации.
4	Обучение классификаторов и визуализация разделяющих гиперплоскостей Студент обучает модели логистической регрессии и метода опорных векторов на табличных данных о состоянии инфраструктуры. Программно визуализируются разделяющие гиперплоскости и

№ п/п	Наименование лабораторных работ / краткое содержание
	области принятия решений в пространстве признаков. Проводится анализ влияния параметра регуляризации на ширину зазора и качество классификации.
5	<b>Обучение деревьев решений и kNN с анализом гиперпараметров</b> Студент обучает деревья решений и метод k-ближайших соседей с автоматическим подбором гиперпараметров через поиск по сетке. Проводится визуализация структуры построенного дерева и анализ влияния глубины на ошибку обобщения. Оценивается вычислительная стоимость инференса метрического классификатора на тестовой выборке.
6	<b>Обучение ансамблей и анализ важности признаков через SHAP</b> Студент обучает модели случайного леса и градиентного бустинга на подготовленных табличных данных. Программно вычисляются и визуализируются метрики важности признаков с использованием алгоритма SHAP. Проводится сравнительный анализ скорости обучения и качества предсказаний различных ансамблей.
7	<b>Реализация кросс-валидации и расчет специфичных метрик</b> Студент реализует различные стратегии кросс-валидации и вычисляет матрицы ошибок на валидационных блоках. Строятся ROC-кривые и Precision-Recall кривые с расчетом площади под ними для всех обученных моделей. Проводится статистический тест на значимость различий в качестве между конкурирующими алгоритмами.
8	<b>Программирование и обучение многослойного перцептрона</b> Студент программирует архитектуру полносвязной нейронной сети с использованием тензорных операций современного фреймворка. Реализуется цикл обучения с логированием значений функции потерь и метрик на тренировочной и валидационной выборках. Проводится эксперимент по влиянию размера мини-батча и выбора оптимизатора на скорость сходимости сети.
9	<b>Внедрение методов регуляризации и анализ кривых обучения</b> Студент внедряет слои Dropout и пакетной нормализации в архитектуру ранее обученной нейронной сети. Реализуется механизм ранней остановки с сохранением лучших весов модели на основе валидационной метрики. Проводится сравнительный анализ кривых обучения до и после применения методов регуляризации.
10	<b>Обучение CNN с нуля и применение аугментации изображений</b> Студент программирует сверточную нейронную сеть с нуля и настраивает генераторы аугментации изображений в реальном времени. Проводится обучение сети с визуализацией карт активации промежуточных сверточных слоев. Анализируется влияние архитектурных решений на точность локализации дефектов на тестовых изображениях.
11	<b>Адаптация предобученной модели под транспортную задачу</b> Студент загружает предобученную модель из официального репозитория и заменяет её классификационную головку. Проводится цикл дообучения с заморозкой весов сверточного основания и последующей тонкой настройкой всех слоев. Сравняется качество и скорость обучения полученной модели с архитектурой, обученной с нуля.
12	<b>Обучение LSTM-сети для прогнозирования остаточного ресурса</b> Студент реализует архитектуру сети с LSTM-ячейками и настраивает генератор последовательностей из многомерных временных рядов. Проводится обучение модели с использованием техники принудительного обучения и анализируется динамика скрытых состояний. Визуализируются предсказанные траектории деградации оборудования в сравнении с реальными показаниями датчиков.
13	<b>Конвертация моделей в ONNX и бенчмаркинг инференса</b> Студент экспортирует обученные модели и нейронные сети в универсальный формат ONNX. Программно замеряется время инференса и потребление оперативной памяти для нативных и экспортированных версий моделей. Проводится верификация численной эквивалентности предсказаний до и после конвертации.
14	<b>Разработка микросервиса на FastAPI с валидацией данных</b> Студент разрабатывает асинхронный веб-сервер на базе FastAPI с реализацией спроектированных

№ п/п	Наименование лабораторных работ / краткое содержание
	endpoints. Внедряется строгая валидация входных данных с использованием моделей Pydantic и генерируется OpenAPI-документация. Проводится нагрузочное тестирование API с использованием специализированных утилит для оценки пропускной способности.
15	<b>Создание интерактивного веб-приложения на Streamlit</b> Студент программирует интерактивное веб-приложение на базе Streamlit, связывающее пользовательский интерфейс с ML-сервисом. Реализуются виджеты для загрузки файлов телеметрии и изображений с последующей визуализацией результатов инференса. Проводится интеграция с ранее разработанным REST API и настраивается обработка сетевых ошибок.
16	<b>Упаковка ML-сервиса в Docker и оркестрация компонентов</b> Студент пишет оптимизированный Dockerfile и собирает образ контейнера с установленным стеком машинного обучения. Создается конфигурация Docker Compose для одновременного запуска API-сервера и базы PostgreSQL. Проводится тестовое развертывание системы в изолированной среде и проверяется корректность взаимодействия всех компонентов.

### Практические занятия

№ п/п	Тематика практических занятий/краткое содержание
1	<b>Формализация бизнес-задачи и проектирование архитектуры ML-пайплайна</b> Студент анализирует бизнес-требования к системе предиктивной диагностики и формализует их в виде математической постановки задачи машинного обучения. В среде P7-Офис оформляется техническое задание с описанием целевых метрик и критериев приемки модели. Разрабатывается концептуальная схема архитектуры будущего программного продукта и потоков данных. Результатом работы является утвержденный план разработки и спецификация требований к входным данным.
2	<b>Проектирование конвейера предобработки данных и конструирование признаков</b> Студент проектирует последовательность шагов предобработки сырых данных и конструирования признаков из временных рядов. Формируется схема скользящих окон и выбираются математические функции для агрегации телеметрических показателей. Разрабатывается стратегия обработки пропусков и выбросов с учетом физической природы датчиков. Результатом является блок-схема конвейера обработки данных для последующей программной реализации.
3	<b>Аналитический выбор алгоритмов регрессии и методов оптимизации</b> Студент проводит аналитическое сравнение алгоритмов линейной и полиномиальной регрессии для задачи оценки износа оборудования. Выбираются методы регуляризации и стратегии оптимизации функции потерь. Оценивается интерпретируемость моделей и влияние мультиколлинеарности признаков. Формируется обоснование выбора базового алгоритма для дальнейшего усложнения архитектуры.
4	<b>Проектирование моделей классификации с учетом ядерных функций</b> Студент проектирует модели классификации для задачи бинарного определения предотказного состояния узлов. Анализируется применимость метода опорных векторов с различными ядерными функциями для нелинейно разделимых данных. Разрабатывается стратегия кодирования категориальных признаков и масштабирования числовых переменных. Подготавливается спецификация для программной реализации многоклассовых классификаторов.
5	<b>Анализ деревьев решений и стратегий отсечения</b> Студент анализирует структуру деревьев решений и формулирует правила остановки роста для предотвращения переобучения. Выбираются критерии информативности для задач регрессии и классификации телеметрических показателей. Проектируется стратегия использования метрических классификаторов для задач с высокой размерностью пространства. Формируется матрица сравнения алгоритмов по вычислительной сложности и интерпретируемости.
6	<b>Проектирование ансамблевых моделей и стратегии бустинга</b> Студент проектирует архитектуру ансамблевых моделей для повышения устойчивости

№ п/п	Тематика практических занятий/краткое содержание
	предсказаний к шуму в данных датчиков. Анализируются принципы бэггинга и стратегии построения случайного леса с декорреляцией деревьев. Выбирается алгоритм градиентного бустинга и формулируется план подбора его гиперпараметров. Разрабатывается методология интерпретации вклада отдельных признаков в итоговый прогноз.
7	<b>Статистический анализ качества моделей и выбор стратегии валидации</b> Студент разрабатывает стратегию статистической оценки качества моделей с учетом специфики временных рядов. Выбираются метрики, чувствительные к дисбалансу классов и цене ошибок первого и второго рода. Проектируется схема кросс-валидации с блокировкой будущего для предотвращения оптимистичного смещения. Формируется шаблон итогового отчета для бизнес-заказчика с визуализацией неопределенности предсказаний.
8	<b>Архитектурное проектирование многослойного перцептрона</b> Студент проектирует архитектуру многослойного перцептрона для задачи классификации сложных нелинейных паттернов в телеметрии. Выбираются функции активации для скрытых слоев и обосновывается выбор функции потерь. Формулируется стратегия инициализации весов и подбора архитектуры сети. Разрабатывается план мониторинга процесса обучения для своевременной диагностики проблем сходимости.
9	<b>Проектирование стратегии регуляризации нейронных сетей</b> Студент анализирует кривые обучения нейросети и проектирует комплексную стратегию борьбы с переобучением. Выбираются методы стохастической регуляризации и стратегии нормализации внутренних представлений сети. Формулируются критерии для автоматической остановки процесса обучения при деградации качества на валидации. Разрабатывается план аугментации данных для искусственного расширения обучающей выборки.
10	<b>Архитектурное проектирование сверточной сети для детекции дефектов</b> Студент проектирует архитектуру сверточной нейронной сети для задачи детекции визуальных дефектов на изображениях инфраструктуры. Анализируется влияние размера ядра свертки и шага страйда на рецептивное поле сети. Выбирается стратегия пулинга и структура полносвязной головки классификатора. Разрабатывается план пространственной аугментации изображений для повышения инвариантности модели.
11	<b>Проектирование стратегии переноса обучения</b> Студент разрабатывает стратегию переноса обучения для минимизации вычислительных затрат при малом объеме размеченных данных. Выбирается базовая предобученная архитектура и формулируется план адаптации её слоев под целевую задачу. Анализируются подходы полного дообучения и использования сети как экстрактора признаков. Формируется критерий остановки дообучения для предотвращения катастрофического забывания.
12	<b>Проектирование рекуррентной сети для прогнозирования временных рядов</b> Студент проектирует архитектуру рекуррентной сети для прогнозирования остаточного ресурса оборудования по последовательностям показаний датчиков. Анализируется способность различных типов ячеек улавливать долгосрочные временные зависимости. Выбирается стратегия формирования скользящих окон для подачи последовательностей на вход сети. Разрабатывается методология оценки качества прогноза на различных временных горизонтах.
13	<b>Проектирование стратегии экспорта и бенчмаркинга моделей</b> Студент анализирует требования к задержкам инференса в реальной ИТ-инфраструктуре заказчика и выбирает формат сериализации моделей. Проектируется стратегия квантования и сжатия весов для развертывания на периферийных устройствах. Разрабатывается план бенчмаркинга производительности на целевом оборудовании. Формируется спецификация для передачи моделей команде backend-разработки.
14	<b>Архитектурное проектирование REST API и схемы базы данных</b> Студент проектирует архитектуру REST API для интеграции ML-моделей в корпоративную информационную систему. Разрабатывается схема валидации входящих запросов и структура JSON-ответов с кодами ошибок. Формулируются требования к безопасности endpoints и стратегии

№ п/п	Тематика практических занятий/краткое содержание
	аутентификации клиентов. Проектируется схема логирования запросов и предсказаний в базу данных для последующего мониторинга дрейфа.
15	<b>Проектирование пользовательского интерфейса и дашборда</b> Студент проектирует пользовательский интерфейс для демонстрации работы интеллектуального микросервиса бизнес-заказчику. Разрабатывается структура интерактивного дашборда с визуализацией входных данных и уверенности предсказаний модели. Формулируются требования к отзывчивости интерфейса и обработке состояний загрузки. Выбирается стратегия кэширования результатов для оптимизации пользовательского опыта.
16	<b>Проектирование стратегии контейнеризации и деплоя</b> Студент проектирует стратегию изоляции зависимостей и подготовки среды для промышленного развертывания системы. Разрабатывается многоэтапная сборка контейнера для минимизации размера финального образа. Формулируется схема оркестрации взаимодействия ML-сервиса и базы данных. Разрабатывается инструкция по запуску системы для инженеров эксплуатации.

#### 4.3. Самостоятельная работа обучающихся.

№ п/п	Вид самостоятельной работы
1	Изучение рекомендованной литературы.
2	Подготовка к лабораторным работам.
3	Выполнение курсового проекта.
4	Подготовка к промежуточной аттестации.
5	Подготовка к текущему контролю.

#### 4.4. Примерный перечень тем курсовых проектов

Проектирование отказоустойчивого ML-пайплайна (Scikit-Learn) для обработки многомерных телеметрических данных с предотвращением утечки информации.

Конструирование признаков из временных рядов телеметрии подвижного состава с использованием скользящих окон и преобразования Фурье.

Оценка износа оборудования транспортного предприятия на основе градиентного бустинга (CatBoost) с интерпретацией признаков через SHAP.

Классификация предотказных состояний узлов при сильном дисбалансе классов: подбор метрик и учет цены ошибки первого и второго рода.

Поиск аномалий в показаниях датчиков инфраструктуры методами обучения без учителя (кластеризация, PCA, t-SNE).

Применение метода опорных векторов (SVM) с ядерным трюком для бинарной классификации состояний критических транспортных узлов.

Прогнозирование остаточного ресурса оборудования по данным телеметрии с использованием рекуррентных нейронных сетей (LSTM/GRU).

Детекция визуальных дефектов транспортной инфраструктуры с применением сверточных нейронных сетей (CNN) и пространственной аугментации.

Стратегия переноса обучения (Transfer Learning) для адаптации предобученных моделей под задачи мониторинга железнодорожного или автомобильного полотна.

Архитектурное проектирование и регуляризация многослойного перцептрона (MLP) для выявления сложных нелинейных паттернов в телеметрии.

Разработка и контейнеризация высокопроизводительного REST API микросервиса предиктивной диагностики на базе FastAPI и Docker.

Экспорт, квантование и кроссплатформенный бенчмаркинг ML-моделей в формат ONNX для задач Edge AI на периферийных устройствах.

Создание интерактивного аналитического дашборда (Streamlit) для бесшовной интеграции ML-модели в корпоративную информационную систему.

Внедрение практик MLOps: версионирование артефактов (DVC) и мониторинг дрейфа данных в продакшен-системе предиктивной аналитики.

Сравнительный анализ стратегий кросс-валидации временных рядов (TimeSeriesSplit) и оптимизация гиперпараметров ансамблей для прогнозирования сбоев.

5. Перечень изданий, которые рекомендуется использовать при освоении дисциплины (модуля).

№ п/п	Библиографическое описание	Место доступа
1	Флах, П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных / П. Флах. — Москва : ДМК Пресс, 2015. — 400 с. — ISBN 978-5-97060-273-7. — Текст : электронный	Лань : электронно-библиотечная система. — URL: <a href="https://e.lanbook.com/book/69955">https://e.lanbook.com/book/69955</a> (дата обращения: 19.06.2026)
2	Митяков, Е. С. Искусственный интеллект и машинное обучение : учебное пособие для вузов / Е. С. Митяков, А. Г. Шмелева, А. И. Ладынин. — 2-е изд., стер. — Санкт-Петербург : Лань, 2026. — 252 с. — ISBN 978-5-507-51198-3. — Текст : электронный	Лань : электронно-библиотечная система. — URL: <a href="https://e.lanbook.com/book/507451">https://e.lanbook.com/book/507451</a> (дата обращения: 19.06.2026)
3	Артемов, М. А. Машинное обучение : учебно-методическое пособие / М. А. Артемов, С. В. Золотарев, Е. С. Барановский. — Воронеж : ВГУ, 2021. — 22 с. — Текст : электронный	Лань : электронно-библиотечная система. — URL: <a href="https://e.lanbook.com/book/455024">https://e.lanbook.com/book/455024</a> (дата обращения: 19.06.2026)

6. Перечень современных профессиональных баз данных и информационных справочных систем, которые могут использоваться при освоении дисциплины (модуля).

ЭБС Издательства «Лань» – <https://e.lanbook.com/>

ЭБС «Юрайт» – <https://urait.ru/>

Официальная документация Scikit-learn – <https://scikit-learn.org/stable/>

Официальная документация CatBoost – <https://catboost.ai/docs/>

Официальная документация FastAPI – <https://fastapi.tiangolo.com/ru/>

Спецификация ONNX – <https://onnx.ai/onnx/>

7. Перечень лицензионного и свободно распространяемого программного обеспечения, в том числе отечественного производства, необходимого для освоения дисциплины (модуля).

Операционные системы – Astra Linux / ALT Linux / РЕД ОС.

Офисные пакеты – Р7-Офис / МойОфис (для подготовки отчетов и презентаций по ГОСТ).

Среда разработки – VS Code Community Edition (оффлайн-версии), GIGA IDE.

Системы контроля версий – GitVerse / GitFlic.

Технологический стек ИИ и Data Science – Python 3.10+, Pandas, NumPy, Matplotlib, Seaborn, Scikit-learn, CatBoost (разработка Яндекса), PyTorch, ONNX Runtime.

Работа с API и сетями – FastAPI, Uvicorn, Postman / Hoppscotch (открытый аналог), curl.

СУБД – Postgres Pro (в реестре ПО РФ) / PostgreSQL, расширение PostGIS.

Разметка данных – CVAT / Label Studio.

Дашборды и визуализация – Streamlit / Dash.

Контейнеризация и MLOps – Docker, Docker Compose, DVC, MLflow.

8. Описание материально-технической базы, необходимой для осуществления образовательного процесса по дисциплине (модулю).

Учебные аудитории для проведения учебных занятий, оснащенные компьютерной техникой и наборами демонстрационного оборудования.

Для практических и лабораторных занятий – наличие персональных компьютеров вычислительного класса.

9. Форма промежуточной аттестации:

Курсовой проект в 6 семестре.

Экзамен в 6 семестре.

10. Оценочные материалы.

Оценочные материалы, применяемые при проведении промежуточной аттестации, разрабатываются в соответствии с локальным нормативным актом РУТ (МИИТ).

Авторы:

старший преподаватель кафедры  
«Цифровые технологии управления  
транспортными процессами»

А.Ю. Кремнев

Согласовано:

Заведующий кафедрой ЦТУТП

В.Е. Нутович

Председатель учебно-методической  
комиссии

Н.А. Андриянова