

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



Рабочая программа дисциплины (модуля),
как компонент образовательной программы
высшего образования - программы бакалавриата
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 анализ данных

Направление подготовки: 09.03.01 Информатика и вычислительная техника

Направленность (профиль): Цифровая инженерия транспортных процессов

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: 937226
Подписал: руководитель образовательной программы
Проневич Ольга Борисовна
Дата: 10.06.2024

1. Общие сведения о дисциплине (модуле).

Целями освоения учебной дисциплины являются формирование у обучающихся профессиональных знаний и навыков в области использования моделей и методов систем искусственного интеллекта (ИИ); усвоение основ разработки и применения методов систем ИИ при решении прикладных задач обработки информации и оптимального управления, а также формирование у обучающихся компетенций в области построения и функционирования систем ИИ, методов оптимального представления и обработки знаний в этих системах, методов и алгоритмов обработки информации и оптимального управления.

Дисциплина предназначена для формирования и закрепления у обучающихся компетенций, необходимых для решения следующих профессиональных задач (в рамках проектной деятельности):

- Проверка реализации запросов на изменение (верификация) в соответствии с полученным планом;
- Обеспечение качества в проектах в области ИТ в соответствии с установленными регламентами;
- Организация приемо-сдаточных испытаний (валидация) в проектах малого и среднего уровня сложности в области ИТ в соответствии с установленными регламентами.

2. Планируемые результаты обучения по дисциплине (модулю).

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

ОПК-8 - Способен разрабатывать алгоритмы и программы, пригодные для практического применения;

ПК-1 - Способен анализировать большие данные с использованием существующей в организации методологической и технологической инфраструктуры.

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

Знать:

требования к персональным компьютерам и серверным ресурсам, реализующим алгоритмы машинного обучения

основные методы оптимального представления и обработки больших данных в системах ИИ

особенности машинного обучения с/без учителя
программы для практической реализации машинного обучения

Уметь:

разрабатывать и проводить сравнительный анализ алгоритмов распознавания и обработки больших данных

проектировать вычислительную инфраструктуру для хранения больших объемов данных

осуществлять отбор данных для машинного обучения

Владеть:

навыками применения методов машинного обучения при решении профессиональных задач

навыками разработки алгоритмов машинного обучения

навыками подбора компонентов для инфраструктуры задач глубокого обучения

навыками формирования технического задания на машинное обучение

3. Объем дисциплины (модуля).

3.1. Общая трудоемкость дисциплины (модуля).

Общая трудоемкость дисциплины (модуля) составляет 3 з.е. (108 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 №4
Контактная работа при проведении учебных занятий (всего):	64	64
В том числе:		
Занятия лекционного типа	32	32
Занятия семинарского типа	32	32

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 44 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	<p>Тема 1. Введение в машинное обучение. Жизненный цикл разработки моделей машинной обучения.</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - машинное обучение на транспорте. Виды данных - нормативные документы в области машинного обучения - жизненный цикл машинного обучение - разведочный анализ данных
2	<p>Тема 2. Разведочный анализ данных (EDA). Часть 1 - Анализ.</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - Макроуровень EDA - Микроуровень EDA - описательные статистика для EDA - Проверка статистических гипотез для определения количества массивов данных
3	<p>Тема 3. Разведочный анализ данных. Часть 2 - Преобразование.</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - переход к целевой структуре данных - анализ аномалий
4	<p>Тема 4. Инженерия данных. Обработка числовых и категориальных данных</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - масштабирование данных - преобразование данных категориальных типов - снижение размерности - генерация новых признаков
5	<p>Тема 5. Обработка текстовых данных</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - токенизация текста - переход от текста к числовой форме TF-IDF - переход от текста к числовой форме мешок-слов - лемматизация
6	<p>Тема 6. Виды машинного обучение. Формальная постановка задачи ML</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - машинное обучение с учителем

№ п/п	Тематика лекционных занятий / краткое содержание
	- машинное обучение без учителя - гибридные методы
7	Тема 7. Модели классификации Рассматриваемые вопросы: - дерево решений - опорные вектора - градиентный бустинг - логистическая регрессия
8	Тема 8. Модели регрессии Рассматриваемые вопросы: - линейная регрессия - гребневая регрессия - модели прогнозирования временных рядов
9	Тема 9. Гиперпараметры моделей машинного обучения Рассматриваемые вопросы: - основные гиперпараметры - gridsearchcv - k-fold
10	Тема 10. Метрики качества моделей и визуализация результатов Рассматриваемые вопросы: - метрики качества регрессионных моделей - метрики качества классификация - визуализация результатов
11	Тема 11. Кластеризация и балансировка классов Рассматриваемые вопросы: - методы поиска ближайших соседей - методы кластеризации - методы балансировки классов
12	Тема 12. Погружение в технологии машинного обучения Рассматриваемые вопросы: - градиентный спуск - виды градиентного бустинга
13	Тема 13. Работа с временными рядами Рассматриваемые вопросы: - avtoArima - динамическая трансформация временных рядов

4.2. Занятия семинарского типа.

Практические занятия

№ п/п	Тематика практических занятий/краткое содержание
1	Тема 1. Что такое машинное обучение (МО) Рассматриваемые вопросы: - Задачи машинного обучения (постановка) - Жизненный цикл - Классификация
2	Тема 2. EDA\Feature engineering Рассматриваемые вопросы:

№ п/п	Тематика практических занятий/краткое содержание
	<ul style="list-style-type: none"> - Место в жизненном цикле интеллектуального анализа данных. - Задачи микроуровня и макроуровня. - Обязательные анализы, необходимы при проведении EDA для различных типов данных. - Инженерия данных
3	<p>Тема 3. Кластеризация</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - Виды кластеризации - k-means
4	<p>Тема 4. Поиск аномалий</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - Что такое аномалии? - Методы выявления и обработки аномалий. - 3-сигма, автоматизированные методы, методы с помощью нейронных сетей
5	<p>Тема 5. Метрики качества</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - Для чего нужны метрики? - RMSE, MAE, MSE - Accuracy, Precision,
6	<p>Тема 6. Регрессия</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - Линейная регрессия - Дерево решений - Нейронные сети - Случайный лес
7	<p>Тема 7. Классификация</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - Логистическая регрессия - Дерево решений - Случайный лес - Градиентный бустинг
8	<p>Тема 8. Интерпретация моделей машинного обучения</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - LIME - SHAP - ICE - PD
9	<p>Тема 9. Подбор гиперпараметров и Auto ML</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - Кросс-валидация - Grid Search - Optuna - Auto ML-библиотеки - Ансамбли моделей
10	<p>Тема 10. Low Code инструменты для моделирования</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - Open Source инструменты - Российский рынок ПО для ML
11	<p>Тема 11. MLOps</p> <p>Рассматриваемые вопросы:</p> <ul style="list-style-type: none"> - ModelOps и MLOps

№ п/п	Тематика практических занятий/краткое содержание
	- Из чего собрать платформу для работы с машинным обучением? - Подводные камни, регламентные процессы, проектный опыт

4.3. Самостоятельная работа обучающихся.

№ п/п	Вид самостоятельной работы
1	Изучение литературы
2	Работа с документацией библиотек pandas, matplotlib, seaborn, pandas_profiling
3	Выполнение курсовой работы.
4	Подготовка к промежуточной аттестации.
5	Подготовка к текущему контролю.
6	Выполнение курсовой работы.
7	Подготовка к промежуточной аттестации.
8	Подготовка к текущему контролю.

4.4. Примерный перечень тем курсовых работ

1. Использование метода опорных векторов в задачах машинного обучения.
2. Использование метода наименьших квадратов в задачах машинного обучения.
3. Использование нейронных сетей долгой краткосрочной памяти в задачах анализа временных рядов.
4. Использование библиотеки TensorFlow в задачах машинного обучения.
5. Использование IBM Watson Studio для создания когнитивных приложений.
6. Использование IBM Watson Studio в задачах распознавания образов.
7. Обработка естественного языка в когнитивных приложениях.
8. Алгоритмы поиска ассоциативных правил.
9. Рекомендательные системы.
10. Распознавание образов с использованием искусственных нейронных сетей глубокого обучения.
11. Обучение с подкреплением в системах искусственного интеллекта.
12. Сегментация изображений с использованием методов кластерного анализа.

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

№ п/п	Библиографическое описание	Место доступа
1	Габдуллин, Н. М. Развитие человеческого капитала и цифровой экономики в регионах России: факторный и кластерный анализ : монография / Н. М. Габдуллин. — Казань : КФУ, 2019. — 268 с. — ISBN 978-5-00130-291-9	https://e.lanbook.com/book/173018
2	Гласнер, Э. Глубокое обучение без математики. Том 2. Практика : руководство / Э. Гласнер ; перевод с английского В. А. Яроцкого. — Москва : ДМК Пресс, 2020. — 610 с. — ISBN 978-5-97060-767-1	https://e.lanbook.com/book/131710
3	Гулятьева, Т. А. Методы статистического обучения в задачах регрессии и классификации : монография / Т. А. Гулятьева, А. А. Попов, А. С. Саутин. — Новосибирск : НГТУ, 2016. — 323 с. — ISBN 978-5-7782-2817-7	https://e.lanbook.com/book/118291
4	Кук, Д. Машинное обучение с использованием библиотеки H2O / Д. Кук ; перевод с английского А. Б. Огурцова. — Москва : ДМК Пресс, 2018. — 250 с. — ISBN 978-5-97060-508-0	https://e.lanbook.com/book/97353
5	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	https://e.lanbook.com/book/69955
6	Шалев-Шварц, Ш. Идеи машинного обучения : учебное пособие / Ш. Шалев-Шварц, Бен-Давид Ш. ; перевод с английского А. А. Слинкина. — Москва : ДМК Пресс, 2019. — 436 с. — ISBN 978-5-97060-673-5	https://e.lanbook.com/book/131686

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

Документация библиотеки pandas. <https://pandas.pydata.org/docs/>

Документация библиотеки matplotlib. <https://matplotlib.org/stable/users/index>

Документация библиотеки seaborn. <https://seaborn.pydata.org/tutorial.html>

Документация библиотеки pandas_profiling. <https://pandas-profiling.github.io/pandas-profiling/docs/master/index.html#pandas-profiling>

Документация scikit-learn https://scikit-learn.org/stable/user_guide.html
Документация библиотеки lime <https://github.com/marcotcr/lime>
<https://habr.com/ru> - база знаний в виде статей, обзоров
<https://journal.tinkoff.ru/short/ai-for-all/> - база данных нейронных сетей
<https://vc.ru/services/916617-luchshie-neyroseti-bolshaya-podborka-iz-top-200-ii-generatorov-po-kategoriyam> - база данных нейронных сетей
<https://github.com/abalmumcu/bert-rest-api> - профессиональная платформа для командой работы над проектов (нейронная сеть bert)
<http://library.miit.ru/> - электронно-библиотечная система Научно-технической библиотеки МИИТ
<https://proglib.io/p/raspoznavanie-obektov-s-pomoshchyu-yolo-v3-na-tensorflow-2-0-2020-11-08> - профессиональная библиотека программистов
https://yandex.cloud/ru/blog/posts/2022/12/andrey-berger-and-yandex-cloud?utm_referrer=https%3A%2F%2Fyandex.ru%2F – библиотека профессиональных статей разработчиков Яндекс
<https://yandex.cloud/ru/blog> - библиотека профессиональных статей разработчиков Яндекс
<https://tproger.ru/translations/opencv-python-guide> - библиотека основных команд OpenCV

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

MS Office (Excel, Word)
Notepad++
Браузер Chrome
Anaconda

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

MS Office (Excel, Word)
Notepad++
Браузер Chrome
Anaconda

9. Форма промежуточной аттестации:

Зачет в 4 семестре.
Курсовая работа в 4 семестре.

10. Оценочные материалы.

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

Авторы:

доцент, к.н. Академии "Высшая инженерная школа"

Б.В. Игольников

Согласовано:

Директор

Б.В. Игольников

Руководитель образовательной программы

О.Б. Проневич

Председатель учебно-методической комиссии

Д.В. Паринов