

Министерство науки и высшего образования Российской Федерации
НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ТОМСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ (НИ ТГУ)

Институт прикладной математики и компьютерных наук

УТВЕРЖДЕНО:

Директор
А. В. Замятин

Оценочные материалы по дисциплине

Введение в интеллектуальный анализ данных

по направлению подготовки

01.03.02 Прикладная математика и информатика

Направленность (профиль) подготовки:

Прикладная математика и инженерия цифровых проектов

Форма обучения

Очная

Квалификация

Бакалавр

Год приема

2024

СОГЛАСОВАНО:

Руководитель ОП
Д.Д. Даммер

Председатель УМК
С.П. Сущенко

1. Компетенции и индикаторы их достижения, проверяемые данными оценочными материалами

Целью освоения дисциплины является формирование следующих компетенций:

ОПК-1 Способен применять фундаментальные знания, полученные в области математических и (или) естественных наук, и использовать их в профессиональной деятельности.

ОПК-4 Способен понимать принципы работы современных информационных технологий и использовать их для решения задач профессиональной деятельности.

ПК-2 Способен собирать, обрабатывать и анализировать данные для проведения научно-исследовательских работ в зависимости от проблемной и предметной области, создавать математическую модель исследуемого объекта.

ПК-3 Способен проектировать и разрабатывать программное обеспечение компьютерных и информационных систем, а также формализовать и алгоритмизировать поставленную задачу в рамках проекта в зависимости от проблемной и предметной области.

Результатами освоения дисциплины являются следующие индикаторы достижения компетенций:

ИОПК-1.4 Демонстрирует понимание и навыки применения на практике математических моделей и компьютерных технологий для решения практических задач, возникающих в профессиональной деятельности

ИОПК-4.1 Обладает необходимыми знаниями в области информационных технологий, в том числе понимает принципы их работы

ИОПК-4.2 Применяет знания, полученные в области информационных технологий, при решении задач профессиональной деятельности

ИОПК-4.3 Использует современные информационные технологии на всех этапах решения задач профессиональной деятельности

ИОПК-4.4 Демонстрирует умение составлять научные обзоры, рефераты и библиографии по тематике научных исследований.

ИПК-2.2 Способен строить математическую модель исследуемого объекта и/или процесса в зависимости от проблемной и предметной области

ИПК-3.1 Способен предложить техническое и алгоритмическое решение для решения поставленной задачи в исследуемой предметной области

ИПК-3.2 Осуществляет оформление программного кода в соответствии с установленными требованиями, разработку процедур проверки работоспособности и измерения характеристик программного обеспечения

2. Оценочные материалы текущего контроля и критерии оценивания

Элементы текущего контроля:

- лабораторные работы;
- реферат.

Реферат (на согласованную тему). К реферату необходимо сделать презентацию.

Примеры тем:

1. Современные нейронные сети в обработке данных (изображений, видео, технологических сигналов, музыки и т.п.).
2. Современные алгоритмы классификации (изображений, текстов и т.п.).
3. Интеллектуальная обработка данных в ... (промышленности, медицине, бизнесе, индустрии развлечений, досуга и др.).
4. Извлечение знаний из текстов.
5. Детектирование аномалий.
6. Разновидности сверточных нейронных сетей.
7. Интеллектуальные алгоритмы в ранней диагностике заболеваний.

8. Интеллектуальные алгоритмы в персонализированной медицине.
9. Интеллектуальные алгоритмы в робототехнике, транспортных системах и т.п..
10. Интеллектуальные алгоритмы в банковском деле/страховании/....

Задание №1: Проведение разведочного анализа данных.

Цель: Провести разведочный анализ выбранного набора данных.

Задачи: Выбрать набор табличных данных (например на сайте [kaggle.com](https://www.kaggle.com/)), набор данных должен содержать не менее 10 столбцов и 1000 строк различных типов. Определить характеристики набора данных (типы данных, размер набора данных, наличие пропусков, дубликатов, категориальных переменных). Провести корреляционный анализ признаков и вывести корреляционную матрицу. Построить различные визуализации для признаков (не менее 3 различных). Сделать выводы по полученным результатам.

Описание отчета: Название «№Лабораторной_Ф_И_И_№группы», отчет в формате html/pdf должен содержать исходный код, полученные результаты, комментарии, выводы.

Задание №2: Предварительная обработка данных и оптимизация признаковового пространства.

Цель: провести предварительную обработку и оптимизировать признаковое пространство.

Задачи: выбрать набор табличных данных (например на сайте [Kaggle.com](https://www.kaggle.com/)), набор данных должен содержать пропуски и категориальные переменные. Оценить наличие пропусков, дубликатов, категориальных переменных и их характеристики. Построить корреляционную матрицу, оценить возможность использовать ее для отбора признаков. Заполнить пропуски в данных (попробовать 3 различных способа). Закодировать категориальные переменные (попробовать 3 различных способа). Оценить наличие выбросов (z-оценка или ящик с усами), удалить выбросы. Используя метод главных компонент, сжать признаковое пространство (до 3х компонент), визуализировать результат относительно целевой переменной (если целевой переменной нет, то в качестве ее взять один из категориальных признаков). Сделать выводы по полученным результатам.

Описание отчета: Название «№Лабораторной_Ф_И_И_№группы», отчет в формате html/pdf должен содержать исходный код, полученные результаты, комментарии, выводы.

Задание №3: Классификация данных. Неконтролируемая классификация (кластеризация).

Цель: Провести кластеризацию геоданных и классификацию табличных данных.

Задачи: для решения задачи кластеризации выбрать набор содержащий геоданные (координаты) (например на сайте [Kaggle.com](https://www.kaggle.com/)). Провести кластеризацию этих данных (двумя моделями), настроить гиперпараметры, оценить качество кластеризации, визуализировать результат с использованием карты. Для решения задачи классификации выбрать набор табличных данных, обучить три модели, настроить гиперпараметры моделей (использовать `grid-search/random-search`), оценить качество классификации, построить гос-кривую, выбрать лучшую модель. Сделать выводы по полученным результатам.

Описание отчета: Название «№Лабораторной_Ф_И_И_№группы», отчет в формате html/pdf должен содержать исходный код, полученные результаты, комментарии, выводы.

Примеры тем для самостоятельного изучения:

- Нейросетевые методы анализа данных, сверточные сети (convolution neural networks). глубинное обучение (deep learning).
- Методы интеллектуального анализа медиа (social media data mining).
- Методы машинного обучения в задачах финансовой аналитики.
- Методы машинного обучения в задачах ранней медицинской диагностики.
- Комбинирование моделей в анализе данных, бустинг.
- Метод анализа независимых компонент (independent component analysis).
- Методы визуализации данных высокой размерности.

Критерии оценивания реферата:

Результаты подготовки и защиты реферата определяются оценками «зачтено», «не зачтено».

Оценка «зачтено» выставляется, если реферат подготовлен на достаточно высоком методическом уровне, а тема в достаточной степени раскрыта в пояснительной записке.

Критерии оценивания лабораторных работ:

Оценка «зачтено» выставляется, если лабораторные работы выполнены и защищены в полном объеме.

3. Оценочные материалы итогового контроля (промежуточной аттестации) и критерии оценивания

Видом промежуточной аттестации является зачет с оценкой. Экзаменационный билет состоит из трёх частей, каждая в виде вопроса по одной из тем, освещенной на лекциях. К зачету с оценкой допускается обучающийся, успешно выполнивший все лабораторные работы, подготовивший и защитивший реферат по теме, согласованной с преподавателем.

Темы лекционных модулей (вопросы для зачета с оценкой):

1. Введение. Основные понятия. Терминология. Области и примеры применения
2. Этапы Data Science
3. Машинное обучение, общая постановка задачи
4. CRISP-DM
5. Регрессия, переобучение
6. Топологии нейросетей и задачи для них
7. Нейросетевая классификация, Deep Learning
8. Сверточные нейронные сети
9. Кластеризация (k-means)
10. Метрики расстояний
11. Критерии точности (Карра, ROC, RMSE), ошибки I/II рода, гипотеза A/B
12. Предварительная обработка данных
13. Оптимизация признакового пространства
14. Классификация (деревья решений)
15. Классификация (статистическая, байесовский подход)
16. SVM (метод опорных векторов)
17. Регуляризация (L1, L2)
18. Ассоциативные алгоритмы (ассоциация, последовательная ассоциация)
19. Высокопроизводительная обработка данных (принципы и модели)
20. Критерии эффективности
21. Многоуровневое машинное обучение. Визуализация
22. Обработка естественного языка
23. Программные среды и сервисы (Hadoop, MapReduce, Spark, Yarn, Cassandra)

Критерии оценивания:

Результаты зачета с оценкой определяются оценками «отлично», «хорошо», «удовлетворительно», «неудовлетворительно».

Оценка «отлично» выставляется, если даны правильные ответы на все вопросы без ошибок.

Оценка «хорошо» выставляется, если имеются незначительные неточности в ответах или незначительный дефицит в детализации ответа.

Оценка «удовлетворительно» выставляется, если имеются значительные неточности в ответах или значительный дефицит в детализации ответа.

Оценка «неудовлетворительно» выставляется, если отсутствует понимание предмета.

4. Оценочные материалы для проверки остаточных знаний (сформированности компетенций)

Проверка остаточных знаний проводится в форме теста.

Примеры вопросов к тесту:

1. Выберите все верные утверждения:
 - а) Последовательность имеет место в случае, если несколько событий связаны друг с другом.
 - б) Отнесение нового объекта к какому-либо из существующих классов выполняется путем классификации.
 - в) В случае, если несколько событий связаны друг с другом во времени, имеет место тип зависимости, именуемый ассоциацией.
 - г) Хранимая ретроспективная информация позволяет определить еще одну закономерность, заключающуюся в поиске существующих кластеров.
2. Выявление лояльных или нелояльных держателей кредитных карт относится к задаче
 - а) Контролируемой классификации
 - б) Ассоциации
 - в) Прогнозирования
 - г) Неконтролируемой классификации
3. Для построения алгоритма машинного обучения требуется три типа выборок:
 - а) Обучающая
 - б) Валидационная
 - в) Тестовая
 - г) Стратифицированная
 - д) Квотная
4. Нейросетевые классификаторы относят к:
 - а) Параметрическим подходам
 - б) Непараметрическим подходам
 - в) Прагматическим подходам
 - г) Эклектический подход
5. Индуктивный подход ...
 - а) к исследованию данных позволяет сформулировать гипотезу и найти с ее помощью новые пути аналитических решений
 - б) к исследованию данных предполагает наличие некоторой сформулированной гипотезы, подтверждение или опровержение которой после анализа данных позволяет получить некоторые частные сведения

Ключи: 1 в) 2 г) 3 а)б)в) 4 б) 5 а)

Информация о разработчиках

Замятин Александр Владимирович, д-р техн. наук, профессор, заведующий кафедрой теоретических основ информатики НИ ТГУ, директор института прикладной математики и компьютерных наук НИ ТГУ.

Карев Святослав Васильевич, ассистент кафедры теоретических основ информатики НИ ТГУ.