


УТВЕРЖДАЮ

Заместитель директора УрСЭИ (филиал)
ОУП ВО "АТиСО" по УВР

 О.В. Зубкова

РАБОЧАЯ ПРОГРАММА ДИСЦИПЛИНЫ (МОДУЛЯ)

Анализ данных и машинное обучение

Направление подготовки

09.03.03 Прикладная информатика

(код и наименование направления подготовки)

Направленность (профиль)

Корпоративные информационные системы

Квалификация выпускника

Бакалавр

Кафедра: Информатики и математики

Разработчики программы:

Кондрашкин Владимир Валентинович

Программа обсуждена на заседании кафедры Информатики и математики

Заведующий кафедрой Информатики и математики

ОГЛАВЛЕНИЕ

1. ЦЕЛЬ И ЗАДАЧИ ИЗУЧЕНИЯ ДИСЦИПЛИНЫ (МОДУЛЯ)	3
2. ТРЕБОВАНИЯ К РЕЗУЛЬТАТАМ ОСВОЕНИЯ ДИСЦИПЛИНЫ (МОДУЛЯ)	3
2.1. Планируемые результаты обучения по дисциплине	3
2.2. Результаты освоения образовательной программы	3
3. МЕСТО ДИСЦИПЛИНЫ (МОДУЛЯ) В СТРУКТУРЕ ОБРАЗОВАТЕЛЬНОЙ ПРОГРАММЫ	4
4. ОБЪЕМ ДИСЦИПЛИНЫ (МОДУЛЯ) И ВИДЫ УЧЕБНОЙ РАБОТЫ	4
5. СОДЕРЖАНИЕ ДИСЦИПЛИНЫ (МОДУЛЯ)	5
5.1. Содержание дисциплины (модуля)	5
5.2. Разделы / темы дисциплины, их трудоемкость и виды занятий	6
6. ПЕРЕЧЕНЬ УЧЕБНО-МЕТОДИЧЕСКОГО ОБЕСПЕЧЕНИЯ ДЛЯ САМОСТОЯТЕЛЬНОЙ РАБОТЫ ОБУЧАЮЩИХСЯ ПО ДИСЦИПЛИНЕ (МОДУЛЮ)	7
7. ОСНОВНАЯ И ДОПОЛНИТЕЛЬНАЯ УЧЕБНАЯ ЛИТЕРАТУРА	10
8. ПЕРЕЧЕНЬ ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ, ИНФОРМАЦИОННЫХ СПРАВОЧНЫХ СИСТЕМ И ИНТЕРНЕТ - РЕСУРСОВ, НЕОБХОДИМЫХ ДЛЯ ОСВОЕНИЯ ДИСЦИПЛИНЫ (МОДУЛЯ)	13
9. ТРЕБОВАНИЯ К МАТЕРИАЛЬНО-ТЕХНИЧЕСКОМУ И УЧЕБНО-МЕТОДИЧЕСКОМУ ОБЕСПЕЧЕНИЮ ДИСЦИПЛИНЫ (МОДУЛЯ)	15
10. ОБРАЗОВАТЕЛЬНЫЕ ТЕХНОЛОГИИ	15
11. ФОНД ОЦЕНОЧНЫХ СРЕДСТВ	16

1. ЦЕЛЬ И ЗАДАЧИ ИЗУЧЕНИЯ ДИСЦИПЛИНЫ (МОДУЛЯ)

Цель:

Изучить технологии анализа данных (OLAP, KDD, Data Mining) и подготовки данных, дать представление об автоматизированных моделях анализа данных, применить методы анализа данных на примере решения задач сегментации, классификации, прогнозирования.

Задачи:

- 1.изучение понятийно-категориального аппарата в области углубленного анализа данных.
- 2.формирование представлений об общей методологии консолидации, подготовки и анализа данных.
- 3.обеспечение освоения современных методов OLAP, KDD, Data Mining.

2. ТРЕБОВАНИЯ К РЕЗУЛЬТАТАМ ОСВОЕНИЯ ДИСЦИПЛИНЫ (МОДУЛЯ)

2.1 Планируемые результаты обучения по дисциплине

Изучение дисциплины Анализ данных и машинное обучение направлено на формирование следующих компетенций:

профессиональных компетенций и индикаторов их достижения:

Категория (группа) ПК	Код и наименование универсальной компетенции	Код и наименование индикатора достижений универсальной компетенции
Производственно-технологические	ПК-2 Способен выполнять работы по созданию (модификации) и сопровождению ИС, автоматизирующих задачи организационного управления и бизнеспроцессы.	ПК-2.1. Знает методологию и технологии проектирования информационных систем, проектирование обеспечивающих подсистем; основные команды для платформы 1С, приемы программирования в 1С.. ПК-2.2. Умеет создавать, модифицировать и сопровождать информационные системы для решения задач бизнес-процессов и организационного управления; проводить сравнительный анализ и выбор ИКТ для решения прикладных задач и создания информационных систем; разрабатывать на платформе 1С информационную систему, позволяющую автоматизировать конкретные бизнес-процессы для заданной организации.. ПК-2.3. Владеет навыками создания и сопровождения информационных систем, автоматизирующих задачи организационного управления и бизнес-процессы продукта; методологией и технологией проектирования информационных систем, проектирования обеспечивающих подсистем; навыками работы в 1С Конфигураторе и программирования на платформе 1С..

2.2. Результаты освоения образовательной программы:

В результате изучения дисциплины студент должен:

Знать:

- 1.основные понятия и основные методы теории анализа данных, интеллектуальной обработки данных.
- 2.основные стандарты в области интеллектуального анализа данных.

Уметь:

- 1.использовать математические и инструментальные средства для анализа данных.

Владеть (навыки и/или опыт деятельности):

1.навыками проведения анализа данных с использованием аналитических платформ и прикладного программного обеспечения.

3. МЕСТО ДИСЦИПЛИНЫ (МОДУЛЯ) В СТРУКТУРЕ ОБРАЗОВАТЕЛЬНОЙ ПРОГРАММЫ

Дисциплина относится к дисциплинам части, формируемой участниками образовательных отношений направления подготовки 09.03.03 Прикладная информатика профиль "Корпоративные информационные системы".

4. ОБЪЕМ ДИСЦИПЛИНЫ (МОДУЛЯ) И ВИДЫ УЧЕБНОЙ РАБОТЫ

Объем дисциплины	Всего часов		
	Для очной формы обучения	Для очно-заочной формы обучения	Для заочной формы обучения
Общая трудоемкость дисциплины (зачетных единиц/часов)	7 / 252	0 / 0	7 / 252
Контактная работа – аудиторные занятия:	122		26
Лекции	36		10
Семинары, практические занятия	72		12
Контактная работа (зачет, экзамен, курсовая работа)	14		4
Самостоятельная работа обучающегося	100		217
Промежуточная аттестация	30		9
Вид промежуточной аттестации	Экзамен		Экзамен

5. СОДЕРЖАНИЕ ДИСЦИПЛИНЫ (МОДУЛЯ)

5.1 Содержание дисциплины (модуля)

Тема 1. Большие данные и машинное обучение.

Введение в анализ данных. Проблема обработки данных. Матрица данных. Гипотезы компактности и скрытых факторов. Структура матрицы данных и задачи обработки. Матрица объект-объект и признак-признак. Расстояние и близость. Измерение признаков. Отношения и их представление. Основные проблемы измерений. Основные типы шкал. Проблема адекватности. Основные задачи анализа и интерпретации данных.

Тема 2. Классификация данных с использованием детерминированных моделей.

Решающие поверхности и дискриминантные функции. Линейные дискриминантные функции классификатор по минимуму расстояния. Линейная разделимость. Кусочнолинейные дискриминантные функции. Нелинейные дискриминантные функции. Фимашины. Потенциальные функции как дискриминантные функции. Пространство весов. Процедуры обучения с коррекцией ошибок: правило с фиксированным приращением, правило абсолютной коррекции, частично корректирующее правило. Обобщенные градиентные методы.

Тема 3. Классификация данных на основе статистических моделей.

Функция потерь. Байесовская дискриминантная функция. Принятие решение по максимуму правдоподобия. Оптимальная дискриминантная функция для нормально распределенных образов. Дискриминантная функция Фишера. Множественный дискриминантный анализ. Пошаговый дискриминантный анализ. Ошибки классификации. Примеры построения статистических дискриминантных функций для различных статистических нескольких моделей данных. Обучение для статистических дискриминантных функций. Оценки максимального правдоподобия, байесовские оценки. Непараметрическое оценивание. Парзеновские окна, метод непараметрического оценивания на основе Кближайшего соседства.

Тема 4. Кластер-анализ.

Основные типы задач кластер-анализа. Меры подобия и функции расстояния. Выбор критерия кластеризации. Кластерные методы, основанные на евклидовой метрике. Иерархическая кластеризация. Метод К-внутригрупповых средних. Использование методов теории графов в задачах кластеризации. Кластеризация на основе анализа плотностей вероятностей.

Тема 5. Методы снижения размерностей данных.

Анализ матриц исходных данных. Метод главных компонент. Корреляционная матрица и ее основные свойства. Собственные векторы и собственные числа корреляционной матрицы. Приведение корреляционной матрицы к диагональной форме. Геометрическая интерпретация главных компонент на плоскости. Модели факторного анализа. Оценка факторных нагрузок методом максимального правдоподобия и центроидным методом. Вращение факторов и их интерпретация. Использование кластеризации признаков для снижения размерности. Многомерное шкалирование (МИ). Метрический и неметрический подход к МИ. Методы ортогонального проектирования. Нелинейные методы МИ. Многомерное шкалирование неметрических данных. Многомерные развертки.

Тема 6. Методы прогнозирования временных рядов.

Классификация методов прогнозирования. Оценивание трендов. Методы скользящего среднего. Экспоненциальное сглаживание. Регрессионный анализ и прогнозирование. Линейные параметрические модели временных рядов. Методы оценивания моделей авторегрессии, скользящего среднего и смешанных моделей. Сезонные модели. Прогнозирование на основе параметрических моделей. Прогнозирование с использованием нейронных сетей.

Тема 7. Системы DATA MINING. в задачах анализа и интерпретации данных.

Понятие об интеллектуальных системах анализа и интерпретации данных. DATA MINING - системы извлечения новых знаний из данных. Типы систем DATA MINING - предметноориентированные аналитические системы, статистические пакеты, нейронные сети, деревья решений, обнаружение логических закономерностей, генетические алгоритмы, системы визуализации многомерных данных.

Тема 8. Современные пакеты прикладных программ для решения задач обработки экспериментальных данных.

Табличные процессоры и базы данных в задачах обработки данных. Виды статистических пакетов. Требования к статистическим пакетам общего назначения.

5.2 Разделы/темы дисциплины, их трудоемкость и виды занятий

Общая трудоемкость изучения дисциплины по учебному плану: 3.Е. (часов) 7/252

Форма обучения: очная

Вид контроля: Экзамен

№	Наименование темы	Вс	сг	о	Л	к	ц	и	и	м	и	н	а	р	ш	и	/	А	т	е	л	ь	н	а	о	м	п	е	т	е	а	(с	с	ы
---	-------------------	----	----	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	----	---	---

РАБОЧАЯ ПРОГРАММА ДИСЦИПЛИНЫ

1	Тема 1. Большие данные и машинное обучение.	25	4	9		12	ПК-2	Л.1-6
2	Тема 2. Классификация данных с использованием детерминированных моделей.	25	4	9		12	ПК-2	Л.1-6
3	Тема 3. Классификация данных на основе статистических моделей.	25	4	9		12	ПК-2	Л.1-6
4	Тема 4. Кластер-анализ.	25	4	9		12	ПК-2	Л.1-6
5	Тема 5. Методы снижения размерностей данных.	27	5	9		13	ПК-2	Л.1-6
6	Тема 6. Методы прогнозирования временных рядов.	27	5	9		13	ПК-2	Л.1-6
7	Тема 7. Системы DATA MINING. в задачах анализа и интерпретации данных.	27	5	9		13	ПК-2	Л.1-6
8	Тема 8. Современные пакеты прикладных программ для решения задач обработки экспериментальных данных.	27	5	9		13	ПК-2	Л.1-6
9	Консультации (контактная).	14			14			
10	Промежуточная аттестация (часов).	30			30			
	Всего часов	252	36	72	44	100		

Форма обучения: заочная

Вид контроля: Экзамен

№	Наименование темы	Всего	Лекции	Мини-ар	ци и / А	те ль на ом	пе те а	(с ы)
1	Тема 1. Большие данные и машинное обучение.	29	1	1		27	ПК-2	Л.1-6
2	Тема 2. Классификация данных с использованием детерминированных моделей.	29	1	1		27	ПК-2	Л.1-6
3	Тема 3. Классификация данных на основе статистических моделей.	29	1	1		27	ПК-2	Л.1-6
4	Тема 4. Кластер-анализ.	29	1	1		27	ПК-2	Л.1-6
5	Тема 5. Методы снижения размерностей данных.	30	1	2		27	ПК-2	Л.1-6
6	Тема 6. Методы прогнозирования временных рядов.	30	1	2		27	ПК-2	Л.1-6
7	Тема 7. Системы DATA MINING. в задачах анализа и интерпретации данных.	31	2	2		27	ПК-2	Л.1-6
8	Тема 8. Современные пакеты прикладных программ для решения задач обработки экспериментальных данных.	32	2	2		28	ПК-2	Л.1-6
9	Консультации (контактная).	4			4			
10	Промежуточная аттестация (часов).	9			9			
	Всего часов	252	10	12	13	217		

6. ПЕРЕЧЕНЬ УЧЕБНО-МЕТОДИЧЕСКОГО ОБЕСПЕЧЕНИЯ ДЛЯ САМОСТОЯТЕЛЬНОЙ РАБОТЫ ОБУЧАЮЩИХСЯ ПО ДИСЦИПЛИНЕ (МОДУЛЮ)

Самостоятельная работа включает следующие ее виды:

- изучение тем самостоятельной подготовки по учебно-тематическому плану;
- самоподготовка к практическим и другим видам занятий – расчетно-аналитическая работа по индивидуальному учебному заданию;
- самостоятельная работа слушателей при подготовке к итоговому тестированию.

Эти виды работ предполагают:

- самостоятельную работу слушателя в библиотеке;
- изучение материалов специализированных сайтов по темам дисциплины в сети Интернет;
- изучение электронных учебных материалов (электронных учебников, методических материалов, представленных на сайте УрСЭИ);

Задания для самостоятельной работы слушателей включают в себя:

- выполнение тестовых заданий, размещенных в программной оболочке Moodle – по темам, вынесенным на самостоятельное изучение;
- подготовка докладов по отдельным вопросам курса.

Указания и задания по самостоятельной работе выдаются на практических занятиях с учетом индивидуального уровня освоения материала слушателями.

Перечень вопросов для самостоятельной работы

1. Основные понятия – информация, данные, знания. Виды информации. Обработка данных и ее виды. DataMining. Классификация задач DataMining.
2. Модели процессов обработки данных. Модель: конечные автоматы.
3. Модели процессов обработки данных. Модель: сети Петри.
4. Задачи обработки данных различных типов. Прикладные области обработки данных. Оцифровка сигналов. Теорема Котельникова.
5. Базы данных. OLTP–системы. Неэффективность OLTP для анализа данных. Определение свойства хранилищ данных.
6. Физические и виртуальные хранилища данных (ХД). Основные проблемы создания ХД.
7. Витрины данных.
8. Данные в хранилищах данных. ETL процесс.
9. Представление данных в виде гиперкуба. Операции над гиперкубом. Пример. Технология OLAP. Тест FASMI.
10. Многомерное представление данных и многомерный куб. Представление данных в виде гиперкуба. Пример.
11. Основные понятия гиперкубов (OLAP кубов). Структура OLAP куба. Операции над гиперкубом.
12. Архитектура OLAP. Компоненты OLAP. MOLAP, ROLAP, HOLAP.
13. Задача анализа текстов. Этапы анализа. Предобработка текста.
14. Извлечение ключевых понятий из текста.
15. Классификация текстовых документов. Методы классификации текстовых документов.
16. Большие данные. Свойства больших данных.
17. Машинное обучение, формализация задачи машинного обучения.
18. Признаковое описание объекта. Ответы и типы задач машинного обучения. Модель алгоритмов. Метод обучения. Этап обучения и этап применения.
19. Функционалы качества. Сведение задачи обучения к задаче оптимизации.
20. Переобучение и обобщение. Пример переобучения (Рунге). Эмпирические оценки обобщающей способности.
21. Примеры задач машинного обучения: задачи классификации.
22. Примеры задач машинного обучения: задачи регрессии.
23. Примеры задач машинного обучения: задача ранжирования.
24. Эксперименты в машинном обучении: эксперименты на реальных и синтетических данных.
25. Формализация метрической классификации. Обобщенный метрический классификатор.
26. Метод ближайшего соседа.
27. Метод квзвешенных ближайших соседей.
28. Метод парзеновского окна.
29. Метод потенциальных функций.
30. Отбор эталонных объектов. Понятие отступа объекта. Типы объектов в зависимости от отступа.
31. Отбор эталонов, алгоритм STOLP.
32. Логическая закономерность. Основы вопросы построения логических алгоритмов классификации. Виды закономерностей.
33. Критерии информативности: простые критерии, статистический критерий, энтропийный критерий. Схема локального поиска информативных закономерностей.
34. Определение бинарного решающего дерева. Жадный алгоритм построения дерева ID3.
35. Варианты критериев ветвления в ID3.
36. Алгоритм ID3: достоинства и недостатки.
37. Обработка пропусков в ID3, алгоритм обработки пропусков на этапе обучения и этапе классификации.
38. Стратегии редукции решающих деревьев.
39. Небрежные решающие деревья.
40. Бинаризация вещественного признака

Тема 1. Большие данные и машинное обучение.

Темы докладов, рефератов, сообщений

1. Почему язык Python?
2. Для чего используется библиотека NumPy?
3. Для чего используются библиотеки SciPy, matplotlib, pandas?
4. Как выполняется индексация и извлечение данных в Pandas?
5. Как выполняется группировка данных в Pandas?
6. Для чего применяются таблицы сопряженности в Pandas?
7. Как выполняется загрузка данных в DataFrame в библиотеке Pandas?
8. Как выполняется доступ к столбцам DataFrame в библиотеке Pandas?

Вопросы для дискуссии

1. Общая постановка задачи машинного обучения.
2. Обучение с учителем и без учителя, обучение с подкреплением.
3. Задачи классификации, восстановления регрессии, предсказания.
4. Модели алгоритмов.
5. Признаки. Типы признаков.
6. Понятие функционала качества.
7. Вероятностная постановка задачи.
8. Оценка обобщающей способности.
9. Проблема переобучения.
10. Критерии оценки качества работы алгоритмов машинного обучения. ROC-кривые.
11. Примеры практических задач машинного обучения.

Практические задания

1. Первичный анализ данных с библиотекой Pandas.
2. Визуальный анализ данных с библиотеками Seaborn и Matplotlib.

Тема 2. Классификация данных с использованием детерминированных моделей.

Темы докладов, рефератов, сообщений

1. В чем идея гипотезы компактности?
2. В чем состоит смысл обучения в метрических методах?
3. Для чего используется библиотека Scikit-learn?
4. Для чего выполняют масштабирование признаков?
5. Как обычно выполняется масштабирование количественных признаков?
6. В каком классе Scikit-learn реализован метод kNN?
7. Какой параметр метода k ближайших соседей, задает число соседей для построения прогноза?
8. В чем смысл кросс-валидации?
9. Как вычисляется весовая Евклидова метрика?

Вопросы для дискуссии

1. Решающие поверхности и дискриминантные функции.
2. Линейные дискриминантные функции классификатор по минимуму расстояния.
3. Линейная делимость.
4. Кусочнолинейные дискриминантные функции.
5. Нелинейные дискриминантные функции.
6. Функции.
7. Потенциальные функции как дискриминантные функции.
8. Пространство весов.
9. Процедуры обучения с коррекцией ошибок: правило с фиксированным приращением, правило абсолютной коррекции, частично корректирующее правило.
10. Обобщенные градиентные методы.

Практические задания

Лабораторная работа. Метрические методы классификации в Scikit-learn.

План:

1. Метрические методы классификации.
2. Признаковые описания объекта.
3. Гипотеза компактности.
4. Метрики, виды метрик.
5. Весовая Евклидова метрика, метрика Минковского.
6. Масштабирование признаков.
7. Метод k ближайших соседей.
8. Реализация kNN в `sklearn.neighbors.KNeighborsClassifier`.
9. Кросс-валидация.
10. Алгоритм выполнения кросс-валидации по блокам.
11. Вычисление ошибки на разбиениях.

Тема 3. Классификация данных на основе статистических моделей.

Темы докладов, рефератов, сообщений

1. В каких классах `scikit-learn` реализуются решающие деревья для задач классификации и регрессии?
2. С помощью какой функции `scikit-learn` реализуется обучение модели решающих деревьев?
3. Какая переменная содержит массив "важностей" признаков?
4. С помощью какой функции можно проверить, является ли число `nan`?
5. Основы вопросы построения логических алгоритмов классификации.
6. Определение бинарного решающего дерева.
7. Реализация решающих деревьев в библиотеке `scikit-learn`.
8. Важность признаков

Вопросы для дискуссии

1. Функция потерь.
2. Байесовская дискриминантная функция.
3. Принятие решения по максимуму правдоподобия.
4. Оптимальная дискриминантная функция для нормально распределенных образов.
5. Дискриминантная функция Фишера.
6. Множественный дискриминантный анализ.
7. Пошаговый дискриминантный анализ.
8. Ошибки классификации.
9. Примеры построения статистических дискриминантных функций для различных статистических нескольких моделей данных.
10. Обучение для статистических дискриминантных функций.
11. Оценки максимального правдоподобия, байесовские оценки.
12. Непараметрическое оценивание.
13. Парзеневские окна, метод непараметрического оценивания на основе Кближайшего соседства.

Практические задания

Лабораторная работа. Деревья решений. Важность признаков

План:

1. Логическая закономерность.
2. Основы вопросы построения логических алгоритмов классификации.
3. Определение бинарного решающего дерева.
4. Реализация решающих деревьев в библиотеке scikit-learn.
5. Важность признаков.
6. Пропуски в данных.

Тема 4. Кластер-анализ.

Темы докладов, рефератов, сообщений

1. Сформулируйте постановку задачи линейной классификации.
2. Как выполняется стандартизация признаков?
3. В каком классе scikit-learn реализуется перцептрон?
4. Для чего используется функция sklearn.metrics.accuracy_score?
5. Каким классом удобно воспользоваться для стандартизации признаков?
8. На что направлен функционал, который он оптимизирует метод опорных векторов? Какие объекты называют опорными

Вопросы для дискуссии

1. Основные типы задач кластер-анализа.
2. Меры подобия и функции расстояния.
3. Выбор критерия кластеризации.
4. Кластерные методы, основанные на евклидовой метрике.
5. Иерархическая кластеризация.
6. Метод K-внутригрупповых средних.
7. Использование методов теории графов в задачах кластеризации.
8. Кластеризация на основе анализа плотностей вероятностей.

Практические задания

Лабораторная работа. Линейная классификация. Нормализация признаков.

План:

1. Линейные алгоритмы классификации.
2. Персептрон.
3. Нормализация признаков. Стандартизация признаков.
4. Реализация линейных классификаторов в библиотеке scikit-learn.
5. Метрика качества.
6. Метод опорных векторов.
7. Опорные объекты.

Тема 5. Методы снижения размерностей данных.

Вопросы для дискуссии

1. Анализ матриц исходных данных.
2. Метод главных компонент.
3. Корреляционная матрица и ее основные свойства.
4. Собственные векторы и собственные числа корреляционной матрицы.
5. Приведение корреляционной матрицы к диагональной форме.
6. Геометрическая интерпретация главных компонент на плоскости.
7. Модели факторного анализа.
8. Оценка факторных нагрузок методом максимального правдоподобия и центроидным методом.
9. Вращение факторов и их интерпретация.
10. Использование кластеризации признаков для снижения размерности.
11. Многомерное шкалирование (МИ).
12. Метрический и неметрический подход к МИ.
13. Методы ортогонального проектирования.
14. Нелинейные методы МИ.
15. Многомерное шкалирование неметрических данных.
16. Многомерные развертки.

Практические задания

По таблице данных рассчитать параметры признаков при пяти интервалах:

- среднее значение;
- дисперсию;
- среднеквадратичное отклонение;
- минимальное значение;
- максимальное значение;
- нижнюю границу диапазона;
- верхнюю границу диапазона;
- ширину диапазона значений признака;
- шаг по интервалу;

Тема 6. Методы прогнозирования временных рядов.

Вопросы для дискуссии

1. Классификация методов прогнозирования.
2. Оценивание трендов.
3. Методы скользящего среднего.
4. Экспоненциальное сглаживание.
5. Регрессионный анализ и прогнозирование.
6. Линейные параметрические модели временных рядов.
7. Методы оценивания моделей авторегрессии, скользящего среднего и смешанных моделей.
8. Сезонные модели.
9. Прогнозирование на основе параметрических моделей.
10. Прогнозирование с использованием нейронных сетей.

Тема 7. Системы DATA MINING. в задачах анализа и интерпретации данных.

Вопросы для дискуссии

1. Понятие об интеллектуальных системах анализа и интерпретации данных.
2. DATA MINING - системы извлечения новых знаний из данных.
3. Типы систем DATA MINING -предметноориентированные аналитические системы, статистические пакеты, нейронные сети, деревья решений, обнаружение логических закономерностей, генетические алгоритмы, системы визуализации многомерных данных

Тема 8. Современные пакеты прикладных программ для решения задач обработки экспериментальных данных.

Вопросы для дискуссии

1. Табличные процессоры и базы данных в задачах обработки данных.
2. Виды статистических пакетов.
3. Требования к статистическим пакетам общего назначения.

Практические задания

Смоделировать данные по схеме:

X1, X2 - случайные числа (функция СЛЧИС)

X3 - равномерное распределение с параметрами (a,b) - получить путём преобразования случайных чисел (a=5,b=15).

X4, X5 - стандартное нормальное распределение получить путём преобразования случайных чисел.

X6,X7 - нормальное распределение с параметрами (m1,s1), (m2,s2).

Среднее признака X6 m1=5, стандартное отклонение признака X6 s1=2.

Среднее признака X7 m2=15, стандартное отклонение признака X7 s2=4

X8 - нормальное распределение с параметрами (m3,s3) получить с помощью генератора EXCEL.

Среднее признака X7 m3=10, стандартное отклонение признака X8 s3=3.

7. ОСНОВНАЯ И ДОПОЛНИТЕЛЬНАЯ УЧЕБНАЯ ЛИТЕРАТУРА, НЕОБХОДИМАЯ ДЛЯ ОСВОЕНИЯ ДИСЦИПЛИНЫ (МОДУЛЯ)

Основная литература

1. Платонов, А. В. Машинное обучение : учебник для вузов / А. В. Платонов. — 2-е изд. — Москва : Издательство Юрайт, 2026. — 78 с. — (Высшее образование). — ISBN 978-5-534-22200-5. — Текст : электронный // Образовательная платформа Юрайт [сайт]. — URL: <https://urait.ru/bcode/600893>.
2. Машинное обучение в финансах : учебник : [16+] / С. Ю. Богатырев, А. А. Помулев, А. В. Затевахина [и др.] ; под общ. ред. С. Ю. Богатырева ; Международный банковский институт имени Анатолия Собчака. — Москва : Прометей, 2024. — 224 с. : ил., табл. — Режим доступа: по подписке. — URL: <https://biblioclub.ru/index.php?page=book&id=721423>. — Библиогр. в кн. — ISBN 978-5-00172-572-5. — Текст : электронный.

3. Анализ данных : учебник для вузов / под редакцией В. С. Мхитаряна. — Москва : Издательство Юрайт, 2026. — 448 с. — (Высшее образование). — ISBN 978-5-534-19964-2. — Текст : электронный // Образовательная платформа Юрайт [сайт]. — URL: <https://urait.ru/bcode/583032>.

4. Машинное обучение : учебник : [16+] / Е. Ю. Бутырский, В. В. Цехановский, Н. А. Жукова [и др.]. — Москва : Директ-Медиа, 2023. — 368 с. : ил., табл., схем., граф. — Режим доступа: по подписке. — URL: <https://biblioclub.ru/index.php?page=book&id=701807>. — Библиогр. в кн. — ISBN 978-5-4499-3778-0. — DOI 10.23681/701807. — Текст : электронный.

Дополнительная литература

5. Трубочкина, Н. К. Основы технологии производства и машинное обучение : учебник для вузов / Н. К. Трубочкина. — Москва : Издательство Юрайт, 2026. — 383 с. — (Высшее образование). — ISBN 978-5-534-22010-0. — Текст : электронный // Образовательная платформа Юрайт [сайт]. — URL: <https://urait.ru/bcode/600548>.

6. Миркин, Б. Г. Базовые методы анализа данных : учебник и практикум для вузов / Б. Г. Миркин. — 3-е изд., перераб. и доп. — Москва : Издательство Юрайт, 2026. — 297 с. — (Высшее образование). — ISBN 978-5-534-19709-9. — Текст : электронный // Образовательная платформа Юрайт [сайт]. — URL: <https://urait.ru/bcode/583143>.

7. Рабчевский, А. Н. Синтетические данные и развитие нейросетевых технологий : учебник для вузов / А. Н. Рабчевский. — Москва : Издательство Юрайт, 2026. — 187 с. — (Высшее образование). — ISBN 978-5-534-17716-9. — Текст : электронный // Образовательная платформа Юрайт [сайт]. — URL: <https://urait.ru/bcode/589394>.

8. ПЕРЕЧЕНЬ ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ, ИНФОРМАЦИОННЫХ СПРАВОЧНЫХ СИСТЕМ И ИНТЕРНЕТ - РЕСУРСОВ, НЕОБХОДИМЫХ ДЛЯ ОСВОЕНИЯ ДИСЦИПЛИНЫ (МОДУЛЯ)

Программное обеспечение

№	Наименование	Описание
1	MS Office 2007 - 2019	Пакеты прикладных программ, включающие текстовые процессоры, табличные процессоры, инструменты создания презентаций.
2	Microsoft SQL Server	Система управления реляционными базами данных компании Microsoft.
3	MySQL	Системы управления базами данных MySQL.
4	QT среда разработки	Интегрированная среда разработки программного обеспечения.

Интернет-ресурсы, информационные и справочные системы

№	Наименование	Описание
1	IT-портал «Сервер Информационных Технологий»	http://citforum.ru/
2	MSDN – сеть разработчиков Microsoft	https://msdn.microsoft.com/ru-ru/
3	Интернет Университет Информационных Технологий - бесплатное дистанционное образование.	www.intuit.ru/

4	Информационных ресурс для программистов SQL.	http://www.sql.ru/
5	Обучение Python. Сайт-самоучитель для начинающих.	https://python-ucheba.ru/samouchitel-python
6	Самоучитель Python.	http://pythonworld.ru/samouchitel-python

9. ТРЕБОВАНИЯ К МАТЕРИАЛЬНО-ТЕХНИЧЕСКОМУ И УЧЕБНО-МЕТОДИЧЕСКОМУ ОБЕСПЕЧЕНИЮ ДИСЦИПЛИНЫ (МОДУЛЯ)

Помещения, в которых проводятся занятия, представляют собой учебные аудитории для проведения учебных занятий. Данные аудитории оснащенные оборудованием и техническими средствами обучения.

Компьютеры, информационно-телекоммуникационные сети, аппаратно-программные и аудиовизуальные средства, находящиеся в учебных аудиториях:

- персональный компьютер или ноутбук (для преподавателя) с выходом в сеть интернет;
- проектор;
- акустическая система
- экран для проектора;
- доска маркерная (ученическая доска);

Помещения для самостоятельной работы обучающихся оснащены компьютерной техникой и имеют возможность подключения к сети интернет и обеспечивают доступ к электронной информационно-образовательной среде академии.

10. ОБРАЗОВАТЕЛЬНЫЕ ТЕХНОЛОГИИ

В процессе освоения дисциплины используются следующие образовательные технологии:

1. Стандартные методы обучения:

- лекции;
- практические занятия, на которых обсуждаются основные проблемы, освещенные в лекциях и сформулированные в домашних заданиях;
- письменные или устные домашние задания;
- самостоятельная работа студентов, в которую входит освоение теоретического материала, подготовка к практическим/лабораторным занятиям, выполнение указанных выше письменных/устных заданий, работа с литературой.

2. Методы обучения с применением интерактивных форм образовательных технологий:

- круглые столы;
- групповые дискуссии и проекты;
- обсуждение результатов работы студенческих исследовательских групп.

11. ФОНД ОЦЕНОЧНЫХ СРЕДСТВ

Код ком п.	Идентиф.	Тип задания	Уровень	Вре м (мин)	Задание	Ключ
ПК-2	Знать	Задание закрытого типа на установление соответствия	Базовый	3	Установите соответствие между термином (А–Г) и его определением (1–4). Термины: А) Data Mining; Б) Обучение с учителем; В) Кластеризация; Г) Переобучение. Определения: 1) Разбиение объектов на группы по схожести без использования меток классов; 2) Алгоритм слишком точно запоминает обучающую выборку и плохо работает на новых данных; 3) Процесс извлечения скрытых закономерностей из больших массивов данных; 4) Задача машинного обучения, когда для объектов известны правильные ответы (метки).	А-3, Б-4, В-1, Г-2
ПК-2	Уметь	Задание закрытого типа на установление соответствия	Повышенн ый	4	Установите соответствие между практической задачей (А–Г) и методом машинного обучения (1–4). Задачи: А) Прогнозирование цены акции на завтра; Б) Разделение клиентов по поведению; В) Определение,	А-1, Б-3, В-2, Г-4

					является ли письмо спамом; Г) Снижение числа признаков при сохранении информации. Методы: 1) Регрессия; 2) Классификация; 3) Кластеризация; 4) Метод главных компонент (РСА).	
ПК-2	Знать	Задание закрытого типа на установление последовательности	Базовый	3	Расположите этапы анализа данных в правильном логическом порядке: 1) Очистка и предобработка данных; 2) Постановка задачи; 3) Визуализация и интерпретация результатов; 4) Выбор и применение модели машинного обучения.	2, 1, 4, 3
ПК-2	Уметь	Задание закрытого типа на установление последовательности	Повышенный	4	Расположите команды Python в порядке, необходимом для чтения CSV-файла и вывода первых 5 строк: 1) df.head(); 2) import pandas as pd; 3) df = pd.read_csv("data.csv").	2, 3, 1
ПК-2	Знать	Задание комбинированного типа с выбором одного верного ответа и обоснованием	Базовый	2	Что такое «большие данные» (Big Data)? Варианты: 1) Данные, которые не помещаются в оперативную память одного компьютера; 2) Данные, характеризующиеся большим объемом, скоростью поступления и разнообразием; 3)	Ответ: 2. Обоснование: Big Data описывается тремя V: Volume, Velocity, Variety — большой объем, высокая скорость, разнообразие форматов.

					Любые данные, собранные из интернета; 4) Данные, содержащие только числа.	
ПК-2	Уметь	Задание комбинированного типа с выбором одного верного ответа и обоснованием	Повышенный	5	Из 100 тестовых примеров модель правильно предсказала 85. Какова точность (accuracy) в процентах? Варианты: 1) 15%; 2) 85%; 3) 0,85%; 4) 100%.	Ответ: 2. Обоснование: Точность = число правильных ответов / общее число примеров $\times 100\% = 85/100 = 0,85 \rightarrow 85\%$.
ПК-2	Знать	Задание комбинированного типа с выбором одного верного ответа и обоснованием	Базовый	2	Что означает термин «переобучение» (overfitting) в машинном обучении? Варианты: 1) Модель слишком хорошо обобщает новые данные; 2) Модель запоминает шумы и случайности обучающей выборки; 3) Модель не может обучиться даже на обучающих данных; 4) Модель использует слишком мало параметров.	Ответ: 2. Обоснование: Переобучение — модель идеально работает на обучении, но плохо на новых данных из-за запоминания частных особенностей.
ПК-2	Уметь	Задание комбинированного типа с выбором одного верного ответа и обоснованием	Повышенный	4	К какому типу данных относятся тексты, email-сообщения, изображения, аудио и видеофайлы? Варианты: 1) Структурированные; 2) Неструктурированные; 3) Полуструктурированные; 4) Слабоструктурированные	Ответ: 2. Обоснование: Тексты, email, изображения, аудио и видео — неструктурированные данные, так как не имеют строго заданной схемы.

					ные.	
ПК-2	Уметь	Задание комбинированного типа с выбором нескольких верных ответов и развёрнутым обоснованием	Повышенный	5	Выберите два верных утверждения о нормализации данных: 1) Нормализация приводит все признаки к одному диапазону, например [0,1]; 2) Нормализация нужна только для категориальных признаков; 3) Нормализация помогает алгоритмам, чувствительным к масштабу признаков (например, kNN); 4) Нормализация обязательно удаляет выбросы.	Ответы: 1, 3. Обоснование: min-max нормализация сжимает значения в отрезок [0,1]; методы, основанные на расстояниях, требуют одинакового масштаба признаков.
ПК-2	Уметь	Задание комбинированного типа с выбором нескольких верных ответов и развёрнутым обоснованием	Повышенный	5	Выберите два визуальных метода, которые помогают обнаружить выбросы: 1) Ящик с усами (box plot); 2) Столбчатая диаграмма; 3) Тепловая карта; 4) Диаграмма рассеяния (scatter plot).	Ответы: 1, 4. Обоснование: box plot визуально показывает выбросы как точки за «усами»; scatter plot показывает точки, сильно удалённые от основного скопления данных.
ПК-2	Знать	Задание комбинированного типа с выбором нескольких верных ответов и развёрнутым обоснованием	Базовый	3	Выберите два термина, которые используются для оценки качества классификации: 1) Точность (accuracy); 2) Средняя абсолютная ошибка (MAE); 3) Полнота	Ответы: 1, 3. Обоснование: accuracy и recall применяются в классификации; MAE и R^2 — в регрессии.

					(recall); 4) Коэффициент детерминации R^2 .	
ПК-2	Уметь	Задание комбинированного типа с выбором нескольких верных ответов и развёрнутым обоснованием	Повышенный	4	Выберите два свойства, характерных для дерева решений: 1) Результат легко интерпретировать; 2) Дерево всегда даёт лучшую точность, чем нейронная сеть; 3) Дерево может работать как с числовыми, так и с категориальными признаками; 4) Дерево не может переобучаться.	Ответы: 1, 3. Обоснование: деревья решений дают наглядные правила, понятные человеку; поддерживают признаки разных типов.
ПК-2	Знать	Задание открытого типа	Базовый	3	Что такое кластер в задачах кластеризации данных?	Кластер — это группа объектов, которые похожи друг на друга по выбранным признакам и отличаются от объектов из других групп.
ПК-2	Уметь	Задание открытого типа	Высокий	8	Напишите метод, который выводит сводную информацию о датафрейме: количество строк и колонок, названия колонок, количество непустых значений в них, типы данных.	<code>df.info()</code>
ПК-2	Практический опыт	Задание открытого типа	Высокий	8	Опишите основные этапы решения задачи машинного обучения. Приведите не менее четырёх этапов.	1) Постановка задачи; 2) Сбор и подготовка данных; 3) Выбор и обучение модели; 4)

						Оценка качества и настройка; 5) Внедрение.
ПК-2	Практический опыт	Задание комбинированного типа с выбором нескольких верных ответов и развёрнутым обоснованием	Высокий	7	Какие из перечисленных методов относятся к обучению с учителем? Выберите два: 1) Линейная регрессия; 2) K-means; 3) Логистическая регрессия; 4) Метод главных компонент.	Ответы: 1, 3. Обоснование: линейная и логистическая регрессия используют метки классов (обучение с учителем). K-means и PCA — обучение без учителя.