

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ
РОССИЙСКОЙ ФЕДЕРАЦИИ
ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«ЛУГАНСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
ИМЕНИ ВЛАДИМИРА ДАЛЯ»

Краснодонский факультет инженерии и менеджмента (филиал)
Кафедра информационных технологий и транспорта



УТВЕРЖДАЮ:

Директор

Панайотов К.К.

(подпись)

«14» марта 2025 года

ФОНД ОЦЕНОЧНЫХ СРЕДСТВ
по учебной дисциплине

Технологии анализа данных и машинное обучение

(наименование учебной дисциплины, практики)

38.04.05 Бизнес-информатика

(код и наименование направления подготовки (специальности))

«Бизнес-аналитика»

наименование профиля подготовки (специальности, магистерской программы); при отсутствии ставится прочерк)

Разработчик(разработчики):

доцент

(подпись)

Бихдрикер А.С.

ФОС рассмотрен и одобрен на заседании кафедры информационных технологий и транспорта от «26» февраля 2025 г., протокол № 7

Заведующий кафедрой
информационных
технологий и транспорта

(подпись)

Верительник Е.А

Краснодон 2025

**Комплект оценочных материалов по дисциплине
«Технологии анализа данных и машинное обучение»**

Задания закрытого типа

Задания закрытого типа на выбор правильного ответа

Выберите один правильный ответ.

1. Выберите верное определение для термина переобучение (overfitting) в контексте машинного обучения:

- А) Ситуация, когда модель слишком обобщена.
- Б) Ситуация, когда модель слишком хорошо подстроилась под тренировочные данные.
- В) Ситуация, когда модель слишком проста для данных.
- Г) Ситуация, когда модель слишком сложная для данных.

Правильный ответ: Б

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

2. Метод прогнозирования категориальных значений в машинном обучении?

- А) Регрессия.
- Б) Кластерный анализ.
- В) Классификация.
- Г) Обучение с учителем.

Правильный ответ: В

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

3. Выберите верное определение для кросс-валидация в машинном обучении:

- А) Метод обучения без учителя.
- Б) Метод оценки производительности модели.
- В) Метод оптимизации модели.
- Г) Метод обучения с учителем.

Правильный ответ: Б

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

4. Выберите виды обучения, которые существуют в машинном обучении:

- А) Обучение с учителем и без учителя.
- Б) Обучение с учителем, без учителя и с подкреплением.
- В) Обучение с учителем и с подкреплением.

Правильный ответ: Б

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

5. Выберите наиболее часто используемую метрику для оценки качества модели классификации:

- А) F1-мера.
- Б) Среднеквадратичная ошибка (MSE).
- В) Коэффициент детерминации
- Г) Средняя абсолютная ошибка (MAE).

Правильный ответ: А

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

Задания закрытого типа на установление соответствия

Установите правильное соответствие.

Каждому элементу левого столбца соответствует только один элемент правого столбца.

1. Типы задач машинного обучения и примеры приложений. Установите соответствие типу задач машинного обучения и приложению.

Тип		Приложение	
1)	Классификация	А)	Определение спама в электронной почте.
2)	Регрессия	Б)	Прогнозирование стоимости жилья.
3)	Кластеризация	В)	Сегментация аудитории для маркетинговых кампаний.
4)	Обучение подкреплением	с Г)	Обучение игрового агента в компьютерных играх.
		Д)	Генерация изображений по текстовым запросам.

Правильный ответ: 1А, 2Б, 3В, 4Г

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

2. Установите соответствие методу оценки качества моделей и его описанию.

Метод		Описание	
1)	1 Кросс-валидация	А)	График, отображающий степень корректности классификации в зависимости от выбранного порогового значения.
2)	2 Матрица ошибок	Б)	Разбиение данных на n частей и последовательное использование каждой части в качестве теста, а оставшихся в качестве обучения.
3)	3 MSE / RMSE	В)	Таблица, используемая для оценки точности предсказаний бинарной классификации при несбалансированных классах.

- Г) Среднеквадратичная ошибка / корень из среднеквадратичной ошибки для оценки точности регрессионных моделей.

Правильный ответ: 1Б, 2В, 3Г, 4А

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

3. Установите соответствие этапу построения модели и его описанию.

Этап		Описание	
1)	Подготовка данных	А)	Используется для улучшения точности и обобщающей способности модели. Включает в себя анализ ошибок, настройку параметров модели, а также использование регуляризации и ансамблей моделей.
2)	Выбор метода и создание модели	Б)	Этап, на котором проверяется способность модели к обобщению на новые данные, не использовавшиеся в процессе обучения.
3)	Оценка и улучшение качества модели	В)	Этап, на котором осуществляется разметка данных.
4)	Оценка качества модели на тестовой выборке	Г)	Этап, на котором осуществляется сбор, очистка, преобразование данных, а также разделение на обучающую и тестовую выборки.
5)		Д)	На этом этапе определяется, какой алгоритм машинного обучения будет использоваться, настраиваются параметры модели, и происходит ее обучение на обучающей выборке.

Правильный ответ: 1Г, 2Д, 3А, 4Б

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

4. Установите соответствие примерам алгоритмов машинного обучения их описанию.

Алгоритм		Описание	
1)	SVM (Support Vector Machines)	А)	Алгоритм классификации, основанный на построении гиперплоскостей в многомерном пространстве.
2)	K-Means	Б)	Алгоритм, способный строить деревья решений на основе случайных подвыборок признаков и наблюдений, затем комбинируя результаты.
3)	Random Forest	В)	Алгоритм кластеризации, который разбивает набор данных на заранее

- 4) Наивный Байесовский классификатор
- Г) Алгоритм регрессии, основанный на линейной зависимости между признаками и целевым значением.
Алгоритм классификации на основе вероятностного подхода, основанного на теореме Байеса

Правильный ответ: 1А, 2В, 3Б, 4Г

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

5. Установите соответствие типу ансамблей моделей их описанию.

Тип	Описание
1) Баггинг (Bootstrap Aggregating)	А) Метод, при котором несколько моделей голосуют за окончательный прогноз, взвешенное или равномерное количество голосов разных моделей может быть использовано.
2) Бустинг (Boosting)	Б) Способ построения последовательности слабых моделей, каждая следующая обучается на данных, на которых предыдущая допускала ошибки.
3) Стекинг (Stacking)	В) Метод построения нескольких моделей на основе случайных подвыборок обучающей выборки, агрегирование результатов для получения окончательного прогноза. Г) Метод, в котором несколько моделей обучаются независимо, а затем их результаты используются в качестве признаков в общей модели.

Правильный ответ: 1В, 2Б, 3Г

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

Задания закрытого типа на установление правильной последовательности

Установите правильную последовательность.

Запишите правильную последовательность букв слева направо.

1. Расположите по возрастанию сложности задачи машинного обучения.

- А) Классификация.
- Б) Регрессия.
- В) Кластеризация.

Правильный ответ: Б, А, В

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

2. Упорядочите следующие шаги построения модели машинного обучения по порядку.

А) Обучение модели.

Б) Оценка модели.

В) Предварительная обработка данных.

Правильный ответ: В, А, Б

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

3. Упорядочите виды обучения с учителем по степени сложности.

А) Классификация.

Б) Регрессия.

В) Обучение с подкреплением.

Правильный ответ: Б, А, В

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

4. Расположите по порядку шаги борьбы с переобучением модели.

А) Увеличение объёма обучающей выборки.

Б) Регуляризация.

В) Уменьшение сложности модели.

Правильный ответ: В, А, Б

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

Задания открытого типа

Задания открытого типа на дополнение

Напишите пропущенное слово (словосочетание).

1. Регрессия, метод опорных векторов (SVM), наивный байесовский классификатор и др. — это модели машинного обучения для решения задачи _____.

Правильный ответ: Прогнозирования.

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

2. _____ - модель, используемая для анализа связи между числовыми переменными с использованием линейной функции.

Правильный ответ: Линейная регрессия.

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

3. Для построения рекомендательных систем используется алгоритм _____ фильтрации.

Правильный ответ: Коллаборативной.

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

4. Кластеризация, снижение размерности данных, поиск аномалий и др. - это алгоритмы в которых используется обучение _____.

Правильный ответ: Обучение без учителя.

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

Задания открытого типа с кратким свободным ответом

Дайте ответ на вопрос.

1. Дайте определение понятию «Байесовский классификатор».

Правильный ответ: Статистический метод машинного обучения, основанный на теореме Байеса.

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

2. Как называются данные, которые имеют категориальное значение и не поддаются измерению по числовой шкале?

Правильный ответ: Категориальные данные / Качественные данные.

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

3. Как называется метод уменьшения размерности, основанный на поиске главных компонент данных?

Правильный ответ: РСА / Метод главных компонент / Анализ главных компонент.

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

4. Как называется процесс разделения данных на группы на основе их сходства?

Правильный ответ: Кластеризация / Группировка / Сегментация.

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

Задания открытого типа с развернутым ответом

Дайте развернутый ответ на вопрос.

1. Опишите, что такое выбор признаков (Feature Selection) в контексте машинного обучения и анализа данных. Объясните, почему выбор признаков является важным этапом, какие преимущества он предоставляет, и какие существуют основные методы выбора признаков.

Время выполнения - 20 мин.

Ожидаемый результат:

Выбор признаков (Feature Selection) – это процесс выбора подмножества наиболее релевантных признаков из исходного набора признаков для построения модели машинного обучения. Это важный этап, так как использование всех доступных признаков не всегда приводит к лучшим результатам.

Преимущества выбора признаков.

1. Улучшение точности модели. Удаление нерелевантных или избыточных признаков может снизить шум и улучшить обобщающую способность модели.
2. Уменьшение времени обучения модели. Модель с меньшим количеством признаков обучается быстрее.
3. Упрощение модели. Более простую модель легче интерпретировать и понимать.
4. Снижение переобучения. Уменьшение количества признаков снижает риск переобучения модели на обучающихся данных.

Основные методы выбора признаков.

1. Фильтры. Используют статистические показатели для оценки релевантности признаков (например, коэффициент корреляции, критерий хи-квадрат).
2. Обертки. Оценивают качество подмножеств признаков, обучая и оценивая модель на каждом подмножестве (например, прямой и обратный отбор).
3. Встроенные методы. Выполняют выбор признаков в процессе обучения модели (например, L1-регуляризация в линейных моделях, важность признаков в деревьях решений).

Критерии оценивания: Ответ должен содержать описание преимуществ и методов минимум одним предложением.

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

2. Опишите различные методы обработки пропущенных значений в наборах данных. Объясните, какие факторы следует учитывать при выборе метода обработки пропущенных значений.

Время выполнения - 20 мин.

Ожидаемый результат:

Пропущенные значения – это обычное явление в наборах данных. Их наличие может негативно влиять на результаты анализа и обучения моделей машинного обучения. Существует несколько методов обработки пропущенных значений.

1. Удаление строк/столбцов с пропущенными значениями. Простой метод, но может привести к потере большого количества данных, если пропущенных значений много.
2. Заполнение пропущенных значений константой. Заполнение пропущенных значений определенным значением (например, 0, -1).

3. Заполнение пропущенных значений средним/медианой/модой. Заполнение пропущенных значений средним значением для числовых признаков, медианой - если есть выбросы, модой - для категориальных.

4. Заполнение пропущенных значений на основе других признаков. Использование других признаков для предсказания пропущенных значений (например, с помощью регрессионной модели).

5. Использование алгоритмов, устойчивых к пропущенным значениям. Некоторые алгоритмы машинного обучения (например, деревья решений) могут обрабатывать пропущенные значения без предварительной обработки. Факторы, влияющие на выбор метода.

1. Процент пропущенных значений. Если пропущенных значений очень много, удаление строк может привести к значительной потере данных.

2. Тип данных. Для числовых признаков можно использовать заполнение средним/медианой, для категориальных – модой.

3. Важность признака. Если признак важен для модели, лучше использовать более сложные методы заполнения, чем просто удаление строк.

4. Характер пропусков. Важно понимать, случайно ли пропущены значения, связаны ли они с другими признаками или с самим значением признака.

Критерии оценивания: Ответ должен содержать три метода и три фактора.

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

3. Опишите, как оценивать качество моделей кластеризации. Объясните, какие метрики используются для оценки кластеризации, и чем они отличаются друг от друга.

Время выполнения - 20 мин.

Ожидаемый результат:

Оценка качества моделей кластеризации – важный этап, позволяющий определить, насколько хорошо алгоритм кластеризации разделил данные на группы. В отличие от задач классификации и регрессии, в задачах кластеризации часто нет «правильных» ответов, поэтому оценка качества является более сложной задачей.

Существуют два основных типа метрик для оценки кластеризации.

Внутренние метрики. Оценивают качество кластеризации на основе самих данных и результатов кластеризации, не используя внешнюю информацию (например, метки классов).

1. Индекс силуэта. Оценивает, насколько объект похож на объекты в своем кластере по сравнению с объектами в других кластерах. Значение индекса силуэта варьируется от -1 до 1, где более высокие значения указывают на лучшую кластеризацию.

2. Индекс Дэвиса-Болдина. Оценивает среднее сходство каждого кластера с его наиболее похожим кластером. Меньшие значения индекса Дэвиса-Болдина указывают на лучшую кластеризацию.

Внешние метрики. Оценивают качество кластеризации, сравнивая результаты кластеризации с известными метками классов.

1. Индекс Рэнда. Оценивает процент правильных пар объектов (объекты, которые находятся в одном кластере и имеют одинаковые метки, или объекты, которые находятся в разных кластерах и имеют разные метки).

2. Adjusted Rand index (ARI). Является нормализованной версией индекса Рэнда, учитывающей случайное соглашение между кластеризацией и метками классов.

3. Нормализованная взаимная информация. Измеряет количество информации, которой одна кластеризация делится с другой.

Выбор метрики зависит от доступности информации о данных и целей анализа.

Критерии оценивания: Каждая метрика должна быть описана минимум одним предложением.

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

4. Объясните, что такое ансамблевые методы машинного обучения. Опишите общую концепцию, лежащую в основе ансамблей, их преимущества и недостатки по сравнению с отдельными моделями.

Время выполнения - 20 мин.

Ожидаемый результат:

Ансамблевые методы в машинном обучении – это методы, объединяющие предсказания нескольких базовых моделей (слабых учеников) для получения более точных и устойчивых предсказаний. Основная идея заключается в том, что коллективный «разум» нескольких моделей часто превосходит производительность любой отдельной модели.

Преимущества ансамблей.

1. Повышенная точность – ансамбли обычно показывают лучшую производительность по сравнению с отдельными моделями за счет усреднения или комбинирования предсказаний.

2. Устойчивость – ансамбли менее подвержены переобучению и лучше обобщаются на новые данные.

3. Улучшенная обобщающая способность – ансамбли могут охватывать различные аспекты данных и захватывать сложные зависимости.

Недостатки ансамблей:

1. Сложность - обучение и настройка ансамблей может быть более сложной задачей, чем обучение отдельной модели.

2. Вычислительные затраты - обучение и предсказание с использованием ансамблей может занимать больше времени и ресурсов, чем для одной модели.

3. Интерпретируемость – ансамбли могут быть менее интерпретируемыми, чем отдельные модели, особенно, если они состоят из большого количества компонентов.

Ансамбли показывают лучшую производительность, потому что они уменьшают дисперсию, смещение или и то и другое. Усреднение предсказаний различных моделей уменьшает чувствительность к выбросам и

шуму в данных. Объединение моделей, обученных на разных подмножествах данных или с использованием различных алгоритмов, может компенсировать недостатки отдельных моделей.

Критерии оценивания: Ответ должен содержать определение, преимущества и недостатки, которые описаны минимум одним предложением.

Компетенции (индикаторы): ОПК-3 (ОПК-3.3), ОПК-5(ОПК-5.3)

Экспертное заключение

Представленный фонд оценочных средств (далее – ФОС) по дисциплине «Численные методы в экономических расчетах» соответствует требованиям ФГОС ВО.


Предлагаемые формы и средства текущего и промежуточного контроля адекватны целям и задачам реализации основной профессиональной образовательной программы по направлению подготовки 38.03.05 Бизнес-информатика.

Оценочные средства для текущего контроля успеваемости, промежуточной аттестации по итогам освоения дисциплины представлены в полном объеме.

Виды оценочных средств, включенные в представленный фонд, отвечают основным принципам формирования ФОС.

Разработанный и представленный для экспертизы фонд оценочных средств рекомендуется к использованию в процессе подготовки обучающихся по указанному направлению 38.03.05 Бизнес-информатика.

Председатель учебно-методической
комиссии Краснодарского факультета
инженерии и менеджмента (филиала)

 Родионова О.Ю.

Лист изменений и дополнений

№ п/п	Виды дополнений и изменений	Дата и номер протокола заседания кафедры (кафедр), на котором были рассмотрены и одобрены изменения и дополнения	Подпись (с расшифровкой) заведующего кафедрой (заведующих кафедрами)