

Документ подписан простой электронной подписью
Информация о владельце:
ФИО: Костровец Лариса Борисовна
Должность: директор
Дата подписания: 18.05.2026 12:45:59
Уникальный программный ключ:
6882606104c36dbde41c4ab93a65382136a292d6

Приложение 4
к образовательной программе

РАБОЧАЯ ПРОГРАММА ДИСЦИПЛИНЫ

Б1.О.03 Современные технологии анализа информации
(индекс, наименование дисциплины в соответствии с учебным планом)

09.04.03 Прикладная информатика
(код, наименование направления подготовки/специальности)

Корпоративные информационные системы
(наименование образовательной программы)

Очная форма обучения
(форма обучения)

Год набора – 2026
Донецк

Автор(ы)-составитель(и) РПД:

*Верзилов Александр Николаевич, канд. физ.-мат. наук, доцент, доцент
кафедры информационных технологий*

Заведующий кафедрой:

Брадул Наталья Валерьевна, канд. физ.-мат. наук, заведующий
кафедрой информационных технологий

Рабочая программа дисциплины Б1.О.03 Современные технологии
анализа информации одобрена на заседании кафедры информационных
технологий факультета государственной службы и управления Донецкого
филиала РАНХиГС.

Протокол № 7 от «05» марта 2026 г.

СОДЕРЖАНИЕ

1. Перечень планируемых результатов обучения по дисциплине, соотнесенных с планируемыми результатами освоения образовательной программы
2. Объем и место дисциплины в структуре образовательной программы
3. Содержание и структура дисциплины
4. Типы оценочных материалов, показатели и критерии их оценивания
5. Формы аттестации, типовые оценочные материалы для текущего контроля успеваемости обучающихся, критерии и шкалы оценивания по контрольным точкам
6. Формы промежуточной аттестации, критерии и шкала оценивания, типовые оценочные материалы по дисциплине
7. Методические материалы по освоению дисциплины
8. Учебная литература и ресурсы информационно-телекоммуникационной сети «Интернет»
9. Материально-техническая база, информационные технологии, программное обеспечение и информационные справочные системы

1. Перечень планируемых результатов обучения по дисциплине, соотнесенных с планируемыми результатами освоения образовательной программы

Дисциплина Б1.О.03 Современные технологии анализа информации обеспечивает формирование у обучающихся следующих общепрофессиональных компетенций*:

ОТФ/ТФ и реквизиты ПС (при наличии)**	Код компетенции **	Наименование компетенции* *	Код индикатора достижения компетенции**	Наименование индикатора достижения компетенции **	Образовательный результат **
-	ОПК-3	Способен анализировать профессиональную информацию, выделять в ней главное, структурировать, оформлять и представлять в виде аналитических обзоров с обоснованными выводами и рекомендациями	ОПК-3.1	Анализирует профессиональную информацию, выделяет в ней главное, структурирует, оформляет и представляет в виде аналитических обзоров с обоснованными выводами и рекомендациями, применяет ее для решения профессиональных задач	Знает методы сбора, анализа, структурирования и интерпретации профессиональной информации. Умеет анализировать информацию, выделять ключевые аспекты и представлять результаты в виде аналитических материалов

* Дисциплина может формировать компетенцию полностью или частично.

** Должно соответствовать Приложению 1 к образовательной программе

2. Объем и место дисциплины в структуре образовательной программы

Общий объем дисциплины:

4,00 з.е., 144 ак.час

Контактная работа обучающихся с преподавателем по видам учебных занятий: 38 ак. час на контактную работу с преподавателем, из них 18 ак. час на лекции и 20 ак. час на практические занятия. 77 ак. час на самостоятельную работу обучающихся.

Б1.О.03 Современные технологии анализа информации реализуется на 1-м семестре 1-го курса.

3. Содержание и структура дисциплины

3.1. Структура дисциплины

Очная форма обучения

№ п/п	Наименование тем и (или) разделов	ВСЕ ГО	Объем дисциплины, ак.час												Форма текущего контроля успеваемости, промежуточной аттестации
			Контактная работа обучающихся с преподавателем по видам учебных занятий								Самостоятельная работа				
			Период теоретического обучения						Период промежуточной аттестации (сессия)						
			Занятия лекционного типа		Занятия семинарского типа		ИК	КСР	КЭ	Каттэк	Контроль	СРкр	СРэк	СР	
			Л	ВЛ	ЛР	ПЗ									
РАЗДЕЛ 1. Технологии многомерного статистического анализа информации															
Тема 1	Введение в предмет. Организация хранилища данных	12	2	0	0	2	0	0	0	0	0	0	0	8	Устный опрос, контрольные задания, КТ№1
Тема 2	Многомерная модель данных. Архитектура OLAP - систем	12	2	0	0	2	0	0	0	0	0	0	0	8	Устный опрос, контрольные задания, КТ№1
РАЗДЕЛ 2. Технологии интеллектуального анализа данных															
Тема 3	Задачи и модели Data	14	2	0	0	2	0	0	0	0	0	0	0	10	Устный опрос, контрольное

	Mining														здание, КТ№2
Тема 4	Методы и средства Data Mining	14	2	0	0	2	0	0	0	0	0	0	0	10	Устный опрос, контрольные задания, КТ№2
Тема 5	Визуальный анализ данных Visual Mining	12	2	0	0	2	0	0	0	0	0	0	0	8	Устный опрос, контрольное задание, КТ№2
РАЗДЕЛ 3. Решение основных задач анализа информации															
Тема 6	Классификация и регрессия	24	4	0	0	4	0	0	0	0	0	0	0	16	Устный опрос, контрольное задание, КТ№3
Тема 7	Поиск ассоциативных правил	12	2	0	0	2	0	0	0	0	0	0	0	8	Устный опрос, контрольное задание, КТ№3
Тема 8	Кластеризация	15	2	0	0	4	0	0	0	0	0	0	0	9	Устный опрос, контрольное задание, КТ№3
Промежуточная аттестация		29	0	0	0	0	0	0	2	9	0	0	18	0	Экзамен
Итого		144	18	0	0	20	0	0	2	9	0	0	18	77	

Используемые сокращения:

Л – лекции - занятия, предусматривающие преимущественную передачу учебной информации обучающимся педагогическими работниками организации и (или) лицами, привлекаемыми организацией к реализации образовательных программ на иных условиях,).

ВЛ – видео лекции.

ЛР – лабораторные работы.

ПЗ – практические занятия (за исключением лабораторных работ).

ИК – индивидуальные консультации.

КСР – контроль самостоятельной работы

КЭ – консультации перед экзаменом

Каттэк – контактная работа на аттестацию в период экзаменационных сессий

Контроль - контактная работа на аттестацию в период экзаменационных сессий для заочной формы обучения

СРкр – самостоятельная работа на подготовку курсовой работы/ курсового проекта.

СРэк – самостоятельная работа на подготовку к экзамену.

СР – самостоятельная работа в семестре на подготовку к учебным занятиям.

3.2. Содержание дисциплины

РАЗДЕЛ 1. ТЕХНОЛОГИИ МНОГОМЕРНОГО СТАТИСТИЧЕСКОГО АНАЛИЗА ИНФОРМАЦИИ

Тема 1. Введение в предмет. Организация хранилища данных ми. ОПК-3.1

Задачи систем поддержки принятия решений. Основная задача СППР. Классификация задач анализа информации. Использование OLTP-систем и их неэффективность.

Концепция хранилища данных. Организация хранилища данных. Проблемы очистки данных. Методы очистки данных.

Уровни типовой архитектуры хранилища данных.

Тема 2. Многомерная модель данных. Архитектура OLAP - систем. ОПК-3.1

Определение OLAP-систем. Концептуальное многомерное представление.

Основные компоненты OLAP-системы. Преимущества использования многомерных БД. Реляционный OLAP. Гибридный OLAP.

Показатели многомерного регрессионного и корреляционного анализа. Основные процедуры факторного и компонентного анализа.

РАЗДЕЛ 2. ТЕХНОЛОГИИ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДАННЫХ

Тема 3. Задачи и модели Data Mining. ОПК-3.1

Классификация задач Data Mining. Практическое применение Data Mining.

Предсказательные модели. Описательные модели

Тема 4. Методы и средства Data Mining. ОПК-3.1

Базовые методы Data Mining. Нечеткая логика. Генетические алгоритмы. Нейронные сети. Процесс обнаружения знаний. Управление знаниями. Программные реализации методов Data Mining.

Тема 5. Визуальный анализ данных Visual Mining. ОПК-3.1

Выполнение визуального анализа данных. Характеристики средств визуализации данных.

Метод геометрических преобразований. Иерархические образы.

РАЗДЕЛ 3. РЕШЕНИЕ ОСНОВНЫХ ЗАДАЧ АНАЛИЗА ИНФОРМАЦИИ

Тема 6. Классификация и регрессия. ОПК-3.1

Постановка задачи. Способы представления результатов.

Алгоритм построения 1-правил. Метод Naive Bayes. Методика «разделяй и властвуй». Алгоритм ID3. Алгоритм C4.5. Алгоритм покрытия.

Задачи сегментации и классификации. Логистическая регрессия. Прогнозирование.

Тема 7. Поиск ассоциативных правил. ОПК-3.1

Постановка задачи. Способы представления результатов.

Алгоритм Apriori. Разновидности алгоритма Apriori.

Генерация и интерпретация ассоциативных правил. Визуализатор «Что-если» в ассоциативных правилах

Тема 8. Кластеризация. ОПК-3.1

Постановка задачи и базовые алгоритмы кластеризации. Адаптивные методы кластеризации. Выбор наилучшего решения.

Использование формальных критериев. Примеры адаптивной кластеризации.

Исследование методов кластерного анализа при интеллектуальной обработке данных

4. Типы оценочных материалов, показатели и критерии оценивания

4.1. Оценочные материалы по дисциплине Б1.О.03 Современные технологии анализа информации входят в состав оценочных материалов по образовательной программе. Совокупность оценочных материалов по всем дисциплинам (модулям) образовательной программы составляет фонд оценочных средств (далее – ФОС). ФОС используется при проведении текущего контроля успеваемости и промежуточной аттестации обучающихся с целью оценивания достижения обучающимися планируемых результатов обучения.

4.2. ФОС разработан как комплекс проверочных заданий различного типа и уровня сложности, включает критерии и шкалы оценивания, а также «ключи» правильных ответов. ФОС формируется как отдельный документ и хранится в электронном виде, доступ к ФОС предоставлен ограниченному кругу лиц.

4.3. Для самостоятельной работы обучающихся при подготовке к текущему контролю успеваемости и промежуточной аттестации в рабочих программах дисциплин размещены типовые проверочные задания, которые можно условно разделить на задания закрытого, комбинированного и открытого типов.

Задания закрытого типа – это тестовые задания, в которых каждый вопрос сопровождается готовыми вариантами ответов, из которых

необходимо выбрать один или несколько правильных.

Задания комбинированного типа – это тестовые задания, в которых каждый вопрос сопровождается готовыми вариантами ответов, из которых необходимо выбрать один или несколько правильных и обосновать свой выбор.

Задания открытого типа – это задания, в которых на каждый вопрос должен быть предложен развернутый обоснованный ответ.

В зависимости от типа задания рекомендованы определенная последовательность выполнения и система оценивания выполнения заданий.

4.4. Типы заданий, сценарии выполнения, критерии оценивания

ТИП ЗАДАНИЯ	ИНСТРУКЦИЯ	СЦЕНАРИИ ВЫПОЛНЕНИЯ	КРИТЕРИИ ОЦЕНИВАНИЯ
Задание закрытого типа с выбором одного правильного ответа из нескольких вариантов предложенных	Прочитайте текст, выберите правильный ответ	<ol style="list-style-type: none"> 1. Внимательно прочитать текст задания и понять, что в качестве ответа ожидается только один из предложенных вариантов. 2. Внимательно прочитать предложенные вариант-ты ответа. 3. Выбрать один верный ответ. 4. Записать только номер (или букву) выбранного варианта ответа (например, 3 или В). 	Ответ считается верным, если правильно указана цифра или буква
Задание закрытого типа на установление соответствия	Прочитайте текст и установите соответствие	<ol style="list-style-type: none"> 1. Внимательно прочитать текст задания и понять, что в качестве ответа ожидаются пары элементов. 2. Внимательно прочитать оба списка: список 1 – вопросы, утверждения, факты, понятия и т.д.; список 2 – утверждения, свойства объектов и т.д. 3. Сопоставить элементы списка 1 с элементами списка 2, сформировать пары элементов. 4. Записать попарно буквы и цифры (в зависимости от задания) вариантов ответа (например, А1 или Б4). 	Ответ считается верным, если правильно указаны цифры или буквы

<p>Задание закрытого типа с выбором нескольких правильных ответов из нескольких вариантов предложенных</p>	<p>Прочитайте текст, выберите правильные ответы</p>	<ol style="list-style-type: none">1. Внимательно прочитать текст задания и понять, что в качестве ответа ожидается несколько правильных ответов из предложенных вариантов.2. Внимательно прочитать предложенные варианты ответа.3. Выбрать несколько правильных ответов.4. Записать только номера (или буквы) выбранного варианта ответа (например, 1 4 или А Г).	<p>Ответ считается верным, если правильно установлены все соответствия (позиции из одного столбца верно сопоставлены с позициями другого)</p>
------------------------------------------------------------------------------------------------------------	-----------------------------------------------------	------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	-----------------------------------------------------------------------------------------------------------------------------------------------

<p>Задание закрытого типа на установление последовательности</p>	<p>Прочитайте текст и установите последовательность</p>	<ol style="list-style-type: none"> 1. Внимательно прочитайте текст задания и понять, что в качестве ответа ожидается последовательность элементов. 2. Внимательно прочитайте предложенные варианты ответа. 3. Построить верную последовательность из предложенных элементов. 4. Записать буквы/цифры (в зависимости от задания) вариантов ответа в нужной последовательности (например, БВА или 135). 	<p>Ответ считается верным, если правильно указана вся последовательность цифр</p>
<p>Задание комбинированного типа с выбором одного правильного ответа из предложенных и обоснованием выбора</p>	<p>Прочитайте текст, выберите правильный ответ и запишите аргументы, обосновывающие выбор ответа</p>	<ol style="list-style-type: none"> 1. Внимательно прочитайте текст задания и понять, что в качестве ответа ожидается только один из предложенных вариантов. 2. Внимательно прочитайте предложенные варианты ответа. 3. Выбрать один верный ответ. 4. Записать только номер (или букву) выбранного варианта ответа. 5. Записать аргументы, обосновывающие выбор ответа (например, 4 текст обоснования). 	<p>Ответ считается верным, если правильно указана цифра или буква и приведены корректные аргументы, используемые при выборе ответа</p>

<p>Задание открытого типа с развернутым ответом</p>	<p>Прочитайте текст и запишите развернутый обоснованный ответ</p>	<ol style="list-style-type: none">1. Внимательно прочитать текст задания и понять суть вопроса.2. Продумать логику и полноту ответа.3. Записать ответ, используя четкие компактные формулировки.4. В случае расчетной задачи, записать решение и ответ	<p>Ответ считается верным:</p> <ol style="list-style-type: none">1. Отсутствие фактических ошибок.2. Раскрытие объема используемых понятий (полнота ответа).3. Обоснованность ответа (наличие аргументов).4. Логическая последовательность излагаемого материала.
-----------------------------------------------------	-------------------------------------------------------------------	-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

4.5. Общая шкала оценивания результатов текущего контроля успеваемости и промежуточной аттестации обучающихся с применением БРС

Оценка по шкале ECTS	Сумма баллов за все виды учебной деятельности	Оценка по государственной шкале	Определение
A	90 – 100	«Отлично»	отличное выполнение с незначительным количеством неточностей
B	80 – 89	«Хорошо»	в целом правильно выполненная работа с незначительным количеством ошибок (до 10%)
C	75 – 79		в целом правильно выполненная работа с незначительным количеством ошибок (до 15%)
D	70 – 74	«Удовлетворительно»	неплохо, но со значительным количеством недостатков
E	60 – 69		выполнение удовлетворяет минимальные критерии
FX	35 – 59	«Не удовлетворительно»	с возможностью повторной сдачи
F	0 – 34		с обязательным повторным изучением дисциплины (выставляется комиссией)

Соотношение баллов за текущий контроль успеваемости и промежуточную аттестацию, а также повторную промежуточную аттестацию:

Максимальная сумма баллов за текущий контроль успеваемости	Максимальная сумма баллов за промежуточную аттестацию	Максимальная итоговая балльная оценка	Максимальная сумма баллов за повторную промежуточную аттестацию
100 баллов	100 баллов	100 баллов	100 баллов

5. Формы аттестации, типовые оценочные материалы для текущего контроля успеваемости обучающихся, критерии и шкалы оценивания по контрольным точкам

5.1. В ходе реализации дисциплины Б1.О.03 Современные технологии анализа информации используются следующие формы текущего контроля успеваемости обучающихся (в том числе, задания к контрольным точкам): доклад, устный опрос, тестирование, контрольные задания.

Таблица 5.1.

Распределение баллов по видам учебной деятельности (БРС)

Раздел/Темы	Формы текущего контроля		КТ
	УО	КЗ	
Р-1. / Т-1	5	3	12
Р-1. / Т-2	5	3	
Р-2. / Т-3	5	3	12
Р-2. / Т-4	5	3	
Р-2. / Т-5	5	3	
Р-3. / Т-6	5	3	12
Р-3. / Т-7	5	3	
Р-3. / Т-8	5	3	
Итого: 100 б	40	24	36

- УО – устный опрос;
- ТЗ – тестовое задание;
- КЗ – контрольные задания;
- КТ – контрольная точка;
- ПЗ – практическое занятие;
- Д – доклад;
- КЗР – контрольные работы по разделу.

Критерии оценивания опроса:

Баллы	Описание критерия
5	Обучающийся полно излагает материал (отвечает на вопрос), дает правильное определение основных понятий; обнаруживает понимание материала, может обосновать свои суждения, применить знания на практике, привести необходимые примеры не только из учебника, но и самостоятельно составленные; излагает материал последовательно и правильно с точки зрения норм литературного языка.
3-4	Обучающийся дает ответ, удовлетворяющий тем же требованиям, что и для оценки «отлично», но допускает 1–2 ошибки, которые сам же исправляет, и 1–2 недочета в последовательности и языковом оформлении излагаемого.
1=2	Обучающийся обнаруживает знание и понимание основных положений данной темы, но излагает материал неполно и допускает неточности в определении понятий или формулировке правил; не умеет достаточно глубоко и доказательно обосновать свои суждения и привести свои примеры; излагает материал непоследовательно и допускает ошибки в языковом оформлении излагаемого.
0	Обучающийся обнаруживает незнание вопроса, допускает ошибки в формулировке определений и правил, искажающие их смысл,

беспорядочно и неуверенно излагает материал.

0* - в журнал академической группы не выставляется

Критерии оценивания контрольных заданий:

Балы	Описание критерия	
3	Свыше 90% правильных ответов.	Обучающийся демонстрирует глубокое познание в освоенном материале.
2	Свыше 70% правильных ответов.	Обучающимся материал освоен полностью, без существенных ошибок.
1	Реализовано более 50% поставленных задач	Обучающимся материал освоен не полностью, имеются значительные пробелы в знаниях.
0	Реализовано менее 30% поставленных задач.	Обучающимся материал не освоен, знания обучающегося ниже базового уровня.

0* - в журнал академической группы не выставляется

Критерии оценивания контрольных точек:

Балы	Описание критерия
10-12	Обучающимся задание выполнено без ошибок и в полном объеме.
7-9	Обучающимся в целом задание выполнено, имеются отдельные неточности или недостаточно полные ответы, не содержащие ошибок.
4-6	Обучающимся допущены отдельные ошибки при выполнении задания
0-3	У обучающегося отсутствуют ответы на большинство вопросов задачи, задание не выполнено или выполнено не верно.

0* - в журнал академической группы не выставляется

5.2. Типовые оценочные материалы для текущего контроля успеваемости обучающихся (вне контрольных работы):

РАЗДЕЛ 1. ТЕХНОЛОГИИ МНОГОМЕРНОГО СТАТИСТИЧЕСКОГО АНАЛИЗА ИНФОРМАЦИИ

Тема 1. Введение в предмет. Организация хранилища данных

Контрольные вопросы для проведения опроса:

1. Чем многомерный статистический анализ принципиально отличается от одномерного?
2. Приведите пример задачи, которая принципиально не решается одномерными методами.
3. В чем суть перехода к главным компонентам? Как интерпретируются «собственные числа» и «нагрузки» (factor loadings) и как по ним определить, сколько главных компонент следует оставить в модели?.
4. Почему при росте числа признаков (p) большинство методов МСА сталкиваются с трудностями? Назовите два способа борьбы с этим

- эффектом (редукция размерности и регуляризация).
5. Как формулируется задача поиска максимальной корреляции между двумя наборами признаков (множествами X и Y)? Что представляют собой канонические переменные?
 6. Чем корпоративное хранилище данных (Enterprise Data Warehouse, EDW) принципиально отличается от «Озера данных» (Data Lake) с точки зрения структуры, целей использования и целевой аудитории?
 7. Перечислите минимум четыре уровня типовой архитектуры хранилища данных (от источников до потребителя) и объясните назначение слоя Staging Area (промежуточной области)

Контрольные задания:

Задания открытого типа с развернутым ответом.

В таблице приведены результаты химического анализа 32 образцов сланцевых пород на содержание двуокиси кремния ($\text{SiO}_2 - x$) и двуокиси алюминия ($\text{Al}_2\text{O}_3 - y$).

1	X	Y	1	X	Y	1	X	Y	1	X	Y
1	57.8	17.2	9	53.9	16.1	17	53.8	16.3	25	50.9	14.7
2	54.6	17.9	10	60	14.8	18	53.1	17.2	26	49.6	16.1
3	54.8	18.8	11	56.2	17	19	51.5	15.8	27	52.2	19.5
4	51.7	19.9	12	55.2	17.8	20	54	15	28	50.5	15.6
5	61.1	16	13	53.3	19.9	21	50.4	14.4	29	51.1	18.1
6	62.3	17.8	14	57.9	17.1	22	53	15.3	30	52.2	19,5
7	52.2	18.8	15	54	15.5	23	53.3	16.6	31	49.2	15.7
8	49.2	19.3	16	52.6	17.6	24	51.6	14.9	32	49.3	13.2

Задание 1. Построить диаграмму рассеяния для этой выборки.

Задание 2. Определить выборочные характеристики: среднее, дисперсию, коэффициент корреляции.

Задание 3. Построить диаграмму рассеяния и двумерную гистограмму.

Тема 2. Многомерная модель данных. Архитектура OLAP - систем

Контрольные вопросы для проведения опроса:

1. Дайте определение многомерной модели данных. Чем она принципиально отличается от реляционной модели (3NF)?
2. Что такое «факт» и «измерение» (размерность) в контексте многомерного куба (OLAP-куба)? Приведите пример для задачи «Анализ продаж».
3. Что такое иерархия в измерении? Приведите пример из измерения «Время» (например, Год -> Квартал -> Месяц) и объясните, зачем она нужна.
4. В чем разница между схемой «Звезда» (Star Schema) и схемой «Снежинка» (Snowflake Schema)? Назовите одно главное

преимущество «Снежинки» и один ее недостаток по сравнению со «Звездой»?

- Опишите проблему медленно меняющихся измерений (Slowly Changing Dimensions).

Контрольные задания:

Задание открытого типа с развернутым ответом.

Задание 1. На заводе разработаны две новые технологии T_1 и T_2 . Чтобы оценить, как изменится дневная производительность при переводе на новые технологии, завод в течение 10 дней работал по каждой, включая существующую T_0 . Дневная производительность в условных единицах приводится в таблице.

№	T_0	T_1	T_2	№	T_0	T_1	T_2
1	46	74	52	6	44	68	70
2	48	82	63	7	66	76	78
3	73	64	72	8	46	88	68
4	52	72	64	9	60	70	70
5	72	84	48	10	48	60	54

Проверить гипотезу об отсутствии влияния технологии на производительность.

Задание 2. В таблице приведена урожайность (ц/га) четырех сортов пшеницы (4 уровня фактора А) с использованием пяти типов удобрений (5 уровней фактора В); данные получены на 20 участках одинакового размера и почвенного состава.

Фактор В - тип удобрения	Фактор А - сорт пшеницы				$x_{i\bullet}$
	A_1	A_2	A_3	A_4	
B_1	19	25	17	21	20.5
B_2	22	19	19	18	19.5
B_3	26	23	22	25	24
B_4	18	26	20	23	21.75
B_5	21	22	21	24	22
$x_{\bullet j}$	21.2	23	19.8	22.2	21.55

Используя результаты дисперсионного анализа, сделать вывод о влиянии сорта и типа удобрения на урожайность.

РАЗДЕЛ 2. ТЕХНОЛОГИИ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДАННЫХ

Тема 3. Задачи и модели Data Mining

Контрольные вопросы для проведения опроса:

- В чем принципиальное различие между дескриптивными (описательными) и предиктивными (прогнозными) задачами Data Mining? Приведите по одному примеру бизнес-задачи для каждого

- типа.
2. Объясните суть задачи «поиск ассоциативных правил» (Association rule learning). Что такое "Support" (поддержка) и "Confidence" (достоверность) правила на примере корзины покупок: «Если купил хлеб и масло, то купит молоко»?.
 3. В чем заключается фундаментальное различие между обучением с учителем (supervised learning) и обучением без учителя (unsupervised learning) в контексте Data Mining?
 4. Задача Data Mining может быть дескриптивной (описательной) или предиктивной (прогнозной). Объясните разницу на примере двух задач.
 5. Приведите пример задачи Data Mining, которая одновременно содержит черты и кластеризации, и классификации. Может ли одна и та же модель решать обе задачи? Поясните.

Контрольное задание:

Задание открытого типа с развернутым ответом.

Задание 1. Запуск и навигация: изучите главное окно Deductor Studio, найдите панели «Сценарии» и «Отчеты».

Задание 2. Импорт данных: Создайте новый сценарий (клавиша F6 — мастер импорта). Импортируйте демонстрационный файл из папки C:\Program Files\BaseGroup\Deductor\Samples*.txt или *.xls.

Задание 3. Первая визуализация: после импорта примените мастер визуализации (клавиша F5). Посмотрите, как одни и те же данные выглядят в виде таблицы, диаграммы и OLAP-куба.

Тема 4. Методы и средства Data Mining

Контрольные вопросы для проведения опроса:

1. Чем отличаются задачи кластеризации от задач классификации в Data Mining? Приведите пример для каждого типа задач.
2. Что такое «энтропия» и «Information Gain»? Как эти понятия используются при построении дерева решений (например, алгоритм ID3 или C4.5)?
3. Для чего используется метод «гребневой регрессии» (Ridge regression) или LASSO? Какую проблему классической линейной регрессии они решают?
4. Опишите матрицу ошибок (Confusion Matrix). Для задачи бинарной классификации объясните, что такое: TP, TN, FP, FN, и как на их основе вычисляется метрика F1-мера.
5. Что такое «функция активации» и градиентный спуск в контексте обучения нейронной сети? Назовите проблему «затухающего градиента»?
6. Объясните суть метода главных компонент (PCA). Чем PCA отличается от отбора признаков (Feature Selection)?

7. Каковы ключевые отличия в архитектуре и задачах между инструментами типа Pandas/Sci-kit learn (Python) и специализированными BI-средствами (например, Tableau, Power BI) для выполнения анализа данных?
8. Что такое «переобучение» (overfitting) модели? Назовите три различных способа борьбы с переобучением и кратко опишите, как каждый из них работает.

Контрольные задания:

Задание открытого типа с развернутым ответом.

Задание 1. Импортируйте данные из файла CreditSample.txt (из Samples – содержит поля: ФИО, возраст, доход, цель кредита, просрочки, факт дефолта). Примените обработчик «Фильтрация», чтобы разделить клиентов на две группы: «Молодые» (до 30 лет) и «Опытные» (старше 30 лет).

Задание 2. Для каждой из двух групп постройте отдельное дерево решений. В настройках мастера обработки (F7) укажите:

- Входные поля: Возраст, Доход, Цель, Есть_просрочки.
- Выходное поле: Давать_кредит (Да/Нет).
- В параметрах обязательно включите флажок «Строить дерево с более достоверными правилами в ущерб сложности» (отсечение ветвей), чтобы избежать переобучения

Задание 3. Сравните списки правил (визуализатор «Правила») для двух групп. Пример вывода: «Если Доход > 50 000 → Кредит ДА» работает для обеих групп, а «Если Есть_просрочки» для молодежи критичнее, чем для опытных.

Тема 5. Визуальный анализ данных Visual Mining

Контрольные вопросы для проведения опроса:

1. Чем «визуальный анализ данных» (Visual Analytics) принципиально отличается от обычной «информационной визуализации» (Infovis) и «статической статистической графики»?
2. Опишите классический «цикл визуального анализа» (модель Keim). Из каких четырёх основных этапов он состоит?
3. Назовите три основные задачи (цели), которые преследует визуальный анализ (например: обнаружение выбросов, поиск кластеров, выявление зависимостей).
4. Что такое «агрегация данных» (aggregation) и «биннинг» (binning) при визуальном анализе больших массивов? К чему приводит агрегация при изучении распределения плотности (парадокс ансамбля).
5. Согласно исследованиям Кливленда и МакГилла, расположите следующие визуальные каналы (элементы кодирования) по убыванию точности восприятия количественных данных: Угол наклона, Длина линии, Площадь круга, Положение на общей шкале, Цветовой оттенок.

Контрольные задания:

Задание открытого типа с развернутым ответом.

Задание 1. Импортируйте любой плоский файл с продажами (Дата, Товар, Регион, Сумма).

В мастере визуализации выберите «OLAP-куб».

Перетащите поля: «Регион» и «Товар» в строки (Rows), «Сумма» в данные (Data). Посмотрите на сумму продаж в разрезе регионов.

Примените фильтр по дате (например, «только последний квартал»).

Задание 2. После выполнения задания 1 перейдите на панель «Отчеты».

Перетащите мышкой (Drag&Drop) созданные вами узлы сценария (импорт, дерево решений, визуализации) в область отчетов.

Создайте папки «Исходные данные», «Модель», «Графики» и разложите узлы по папкам.

Сохраните проект (.das) и экспортируйте отчет (F8) в HTML или PDF.

РАЗДЕЛ 3. РЕШЕНИЕ ОСНОВНЫХ ЗАДАЧ АНАЛИЗА ИНФОРМАЦИИ

Тема 6. Классификация и регрессия

Контрольные вопросы для проведения опроса:

1. Чем принципиально отличается задача классификации от задачи регрессии?
2. В задаче бинарной классификации «обнаружение мошеннических транзакций» в выборке 99,8% транзакций — честные, 0,2% — мошеннические. Какая проблема возникает при обучении модели на таких данных?
3. Модель классификации показала на обучающей выборке Accuracy = 99%, а на тестовой — Accuracy = 72%. Как называется это явление?
4. Классификация и регрессия относятся к обучению с учителем. Назовите главный критерий, который определяет, какую из этих двух моделей следует применить к данным?
5. Представьте, что банк строит модель для кредитного скоринга (решение: одобрить/отказать). Является ли эта задача классификацией или регрессией?

Контрольные задания:

Задание открытого типа с развернутым ответом.

Задание 1. Скачайте файл Ирисы.txt (обычно содержит поля: длина/ширина чашелистика и лепестка, сорт).

Запустите мастер обработки (F7) → группа Data Mining → Дерево

решений.

В настройках укажите: поле «Сорт» (Species) как «Выходное» (Target), остальные числовые поля — как «Входные» (Input) .

Постройте дерево и изучите «Правила» (Rules). Вы должны увидеть логику: «Если длина лепестка < 2.5 см, то это Setosa».

Задание 2. Импортируйте файл CreditSample.txt (данные о заемщиках: возраст, доход, цель кредита, факт дефолта).

Постройте дерево решений, где «Давать кредит» — выходное поле.

Используйте мастер обработки для фильтрации данных (группа «Очистка данных» → «Фильтрация»). Создайте две ветки сценария: «Активные» (до 40 лет) и «Пассивные» заемщики.

Проанализируйте, отличаются ли правила выдачи кредита для разных возрастных групп

Тема 7. Поиск ассоциативных правил

Контрольные вопросы для проведения опроса:

1. Дайте определение ассоциативному правилу в виде $X \Rightarrow Y$. Что означают антецедент (левая часть) и консеквент (правая часть) в контексте анализа потребительской корзины?
2. Объясните физический смысл трех ключевых метрик: поддержка (support), достоверность (confidence) и лифт (lift).
3. Приведите пример двух правил, которые имеют высокую достоверность (confidence), но при этом являются бесполезными или вводящими в заблуждение.
4. В чем заключается главный принцип работы алгоритма Apriori («антимонотонность поддержки»)? Почему этот принцип позволяет сократить перебор кандидатов?
5. Назовите два основных недостатка алгоритма Apriori. В каких случаях (характеристики данных) эти недостатки становятся критическими, и алгоритм перестает работать эффективно?

Контрольные задания:

Задание открытого типа с развернутым ответом.

Задание 1. Найти связи между товарами (знаменитый пример «пиво и подгузники»).

- Загрузите транзакционный файл (данные чеков: номер чека + название товара). В мастере импорта обязательно укажите для поля «Номер чека» тип — «Идентификатор транзакции (ID)», для названия товара — «Элемент».
- Запустите обработку «Ассоциативные правила».
- Настройка параметров: Задайте минимальный уровень поддержки (например, 20%) и достоверности (например, 50%).

Поэкспериментируйте с цифрами, чтобы увидеть, как меняется количество найденных правил.

Проанализируйте результат во вьюверах «Популярные наборы» и «Дерево правил». Найдите правило с самой высокой достоверностью.

Тема 8. Кластеризация

Контрольные вопросы для проведения опроса:

1. Дайте определение кластеризации.
2. Чем задача кластеризации принципиально отличается от задачи классификации в машинном обучении?
3. На чем основано объединение объектов в кластеры?
4. Какую математическую меру чаще всего используют для оценки «близости» объектов в евклидовом пространстве и почему ее нельзя использовать для категориальных данных?
5. Что такое «жесткая» и «мягкая» (нечеткая) кластеризация? Приведите пример алгоритма для каждого типа.
6. В чем разница между агломеративным (восходящим) и дивизивным (нисходящим) подходами в иерархической кластеризации? Что такое дендрограмма?
7. Назовите два подхода к оценке качества кластеризации. В чем разница между внешними (external) и внутренними (internal) метриками оценки?

Контрольные задания:

Задание открытого типа с развернутым ответом.

Задание 1. Выделить однородные группы респондентов (кластеры) и описать их портрет.

Данные: Файл опроса студентов (Анкетирование.txt): возраст, курс, доход семьи, время в соцсетях, успеваемость, удовлетворенность специальностью.

- Запустите мастер обработки → Кластеризация → выберите «K-Means» (метод K-средних).
- Настройте параметры: укажите количество кластеров (например, попробуйте от 3 до 5).
- Откройте результат во вьювере «Таблица сопряженности» или «Визуализация кластеров»

Задание 2. Определите, какой кластер получил название «Отличники» (высокая успеваемость), какой — «Завсегдатаи соцсетей» (много времени в интернете), а какой — «Скептики» (низкая удовлетворенность специальностью).

5.3. Один или несколько тематических блоков дисциплины завершаются контрольной точкой по разделу (далее – КТ). Текущий контроль успеваемости по дисциплине предусматривает не менее 2 (двух) и не более 10 (десяти) КТ в течение периода освоения дисциплины.

Максимальное количество баллов за любой тип работ в рамках КТ составляет 100 (сто) баллов.

Распределение весовых коэффициентов по КТ в рамках текущего контроля успеваемости по дисциплине и формулы расчета:

Наименование контрольной точки	Максимальное количество баллов за работу в рамках КТ, которое может набрать студент	Коэффициент веса контрольной точки	Результат контрольной точки, участвующий в формировании итоговой балльной оценки по дисциплине
КТ№1	100	0,12	12
КТ№2	100	0,12	12
КТ№3	100	0,12	12
Итого:	x	0,36	36

Формула расчета результата контрольной точки:

Результат контрольной точки = Количество баллов за работу в рамках КТ X Коэффициент веса контрольной точки.

5.4. Формы текущего контроля успеваемости обучающихся в рамках КТ и типовые оценочные материалы:

Контрольная точка №1.

Задание 1. В табл. представлены данные 12 опытов, проведенных в учхозе «Березовский» Воронежского Агро университета.

Номер опыта	x ₁	x ₂	x ₃	x ₄	x ₅	x ₆	x ₇
1	282	30	17,3	65,3	65,4	20	50
2	326	80	20,2	61	43	17	80
3	374	76	18,9	73	131,6	17	46
4	374	109	18,8	66	55,1	17	40
5	424	104	18,1	72	171,9	11	84
6	522	99	22	62,1	46,6	14	61
7	212	30	19	73,2	95,7	20	50
8	411	50	17,3	66,3	119,7	14	52

9	164	30	17,3	65,3	65,4	20	50
10	411	50	17,3	66,3	149,1	14	52
11	438	102	18	69,3	63	21	65
12	364	69	22	76	219	12	70

Исследовать зависимость урожайности семян люцерны от следующих факторов:

- 1) x_1 - количество осадков в период сентябрь -20 апреля (мл);
- 2) x_2 - количество осадков в период 20 апреля -20 мая (мл);
- 3) x_3 -температура воздуха в фазе цветения (C0);
- 4) x_4 -относительная влажность воздуха в фазе цветения (%);
- 5) x_5 -количество осадков в фазе цветения (мл);
- 6) x_6 -температура почвы на глубине 20 см 20 мая (C0);
- 7) x_7 -высота растения 20 мая (мм)

Задание 2. Имеются данные по сельскохозяйственным предприятиям области с различной формой собственности.

Введем следующие переменные:

ФОРМА — организационно-правовая форма предприятия:

ОАО — открытые акционерные общества,

ЗАО — закрытые акционерные общества,

К — колхозы,

СХ_УГОД —площадь сельскохозяйственных угодий, га,

ОСН_ФОНД — стоимость основных средств, тыс. руб.,

ПРИБЫЛЬ — прибыль/убыток, тыс. руб.,

ИЗДЕРЖКИ — издержки производства, тыс. руб.,

ЗАР_ПЛ — среднегодовая заработная плата работника, руб.

Оценить по имеющимся данным факторы, оказывающие существенное влияние на величину заработной платы, получаемой работниками сельскохозяйственных предприятий

Контрольная точка №2.

Предоставляется набор данных (telecom_churn.csv), содержащий информацию о 5000 клиентах телеком-оператора.

Задание 1.

- Импортируйте данные из CSV-файла. Укажите корректные типы полей в соответствии с описанием.
- Используя визуализатор «Таблица» и «Статистика», проведите первичный анализ:
- Определите долю клиентов, покинувших компанию.
- Выявите поля с пропущенными значениями.
- Сформируйте отчёт по результатам первичного анализа

Задание 2.

Обработайте пропущенные значения в поле TotalCharges (замените медианным значением).

Преобразуйте категориальные переменные в числовой формат с

помощью обработчика «Преобразование данных → Кодирование» (для бинарных полей используйте замену Yes/No на 1/0) .

Проверьте и устраните выбросы в числовых полях с помощью «Очистка данных → Парциальная обработка»

Задание 3.

Разбейте данные на обучающую (70%) и тестовую (30%) выборки (способ — «Случайно»).

Проанализируйте полученную модель с помощью визуализаторов:

- «Дерево решений» (просмотрите структуру, проанализируйте глубину);
- «Правила» (изучите извлечённые правила классификации);
- «Значимость атрибутов» (определите топ-5 факторов, влияющих на отток)

Контрольная точка №3.

Предоставляется файл market_basket.csv, содержащий данные о 10 000 транзакциях (чеках) продуктового магазина. Формат данных — два поля: TransactionID и Product. Список товаров в ассортименте (всего 45 позиций). Данные содержат информацию только о товарах в чеке — каждая строка соответствует одному товару в одном чеке

Задание 1.

Импортируйте данные из CSV-файла с помощью мастера импорта.

К узлу импорта добавьте обработчик «Ассоциативные правила». На шаге настройки назначения полей укажите: TransactionID — идентификатор транзакции; Product — элемент транзакции.

Настройте параметры алгоритма Apriori:

- Минимальная поддержка — 3%;
- Максимальная поддержка — 50%;
- Минимальная достоверность — 40%;
- Максимальная достоверность — 100%;
- Максимальная мощность множеств — 4 (ограничение длины товарных наборов)

Запустите обработку и проанализируйте полученные результаты

Задание 2.

Используйте следующие визуализаторы для анализа. Определите множество состояний и выходные значения для каждого состояния:

- Популярные наборы.
- Дерево правил).
- Что-если
- Оценка правил по лифту

Задание 3.

На основе выявленных ассоциативных правил предложите:

- 1) 2 рекомендации по размещению товаров на полках (cross-merchandising);
- 2) 2 акции типа «Каждому, купившему А и В — товар С в подарок/со скидкой»;
- 3) Прогноз — какие товары можно рекомендовать клиенту, который уже имеет в корзине товары из вашего примера

6. *Формы промежуточной аттестации, критерии и шкала оценивания, типовые оценочные материалы по дисциплине*

6.1. Промежуточная аттестация проводится в форме экзамена в первом семестре в письменной форме. Обучающийся получает экзаменационный билет с вариантами заданий. Обучающийся получает чистые маркированные листы бумаги для записей, затем приступает к выполнению. Необходимо дать ответ в письменном виде, подробно изложив ход мыслей.

6.2. Типовые оценочные материалы промежуточной аттестации.

РАЗДЕЛ 1. ТЕХНОЛОГИИ МНОГОМЕРНОГО СТАТИСТИЧЕСКОГО АНАЛИЗА ИНФОРМАЦИИ

Тема 1. Введение в предмет. Организация хранилища данных. ОПК-3.1

Экзаменационные вопросы:

1. Чем многомерный статистический анализ принципиально отличается от одномерного?
2. Приведите пример задачи, которая принципиально не решается одномерными методами.
3. В чем суть перехода к главным компонентам? Как интерпретируются «собственные числа» и «нагрузки» (factor loadings) и как по ним определить, сколько главных компонент следует оставить в модели?
4. Почему при росте числа признаков (p) большинство методов МСА сталкиваются с трудностями? Назовите два способа борьбы с этим эффектом (редукция размерности и регуляризация).
5. Как формулируется задача поиска максимальной корреляции между двумя наборами признаков (множествами X и Y)? Что представляют собой канонические переменные?
6. Чем корпоративное хранилище данных (Enterprise Data Warehouse, EDW) принципиально отличается от «Озера данных» (Data Lake) с точки зрения структуры, целей использования и целевой аудитории?
7. Перечислите минимум четыре уровня типовой архитектуры хранилища данных (от источников до потребителя) и объясните назначение слоя Staging Area (промежуточной области).

Практическое задание к билету:

Имеются данные: 5 вопросов анкеты (оценки от 1 до 7) по 6 респондентам.

Респондент	Зарплата	Коллектив	Карьера	Нагрузка	Условия труда
1	5	6	4	3	5
2	4	5	3	4	4
3	6	7	6	2	6
4	2	4	2	5	3
5	5	5	5	3	5
6	3	6	3	4	4

1. Вычислить корреляционную матрицу.
2. Найти собственные числа и векторы корреляционной матрицы.
3. Определить количество главных компонент по критерию Кайзера (собственное значение >1).
4. Дать содержательную интерпретацию выделенных факторов

Тема 2. Многомерная модель данных. Архитектура OLAP - систем. ОПК-3.1

Экзаменационные вопросы:

1. Дайте определение многомерной модели данных. Чем она принципиально отличается от реляционной модели (3NF)?
2. Что такое «факт» и «измерение» (размерность) в контексте многомерного куба (OLAP-куба)? Приведите пример для задачи «Анализ продаж».
3. Что такое иерархия в измерении? Приведите пример из измерения «Время» (например, Год -> Квартал -> Месяц) и объясните, зачем она нужна.
4. В чем разница между схемой «Звезда» (Star Schema) и схемой «Снежинка» (Snowflake Schema)? Назовите одно главное преимущество «Снежинки» и один ее недостаток по сравнению со «Звездой»?
5. Опишите проблему медленно меняющихся измерений (Slowly Changing Dimensions)

Практическое задание к билету:

Имеются данные о 8 квартирах.

Квартира	Цена (тыс. \$)	Площадь (м ²)	Количество комнат	Этаж	Расстояние до метро (мин)
1	120	70	3	5	10
2	95	55	2	3	20
3	160	90	4	7	5
4	75	45	1	2	25
5	140	80	3	6	8

6	85	50	2	4	15
7	105	65	2	1	12
8	150	85	4	8	6

1. Построить уравнение линейной регрессии (например, в Excel или Python).
2. Проверить значимость коэффициентов (p-value, t-статистика).
3. Рассчитать VIF (variance inflation factor) для каждого фактора. Сделать вывод о мультиколлинеарности.
4. Удалить один из факторов (если есть мультиколлинеарность) и построить новую модель.
5. Сравнить скорректированный R^2 исходной и новой модели

РАЗДЕЛ 2. ТЕХНОЛОГИИ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДАННЫХ

Тема 3. Задачи и модели Data Mining. ОПК-3.1

Экзаменационные вопросы:

1. В чем принципиальное различие между дескриптивными (описательными) и предиктивными (прогнозными) задачами Data Mining? Приведите по одному примеру бизнес-задачи для каждого типа.
2. Объясните суть задачи «поиск ассоциативных правил» (Association rule learning). Что такое "Support" (поддержка) и "Confidence" (достоверность) правила на примере корзины покупок: «Если купил хлеб и масло, то купит молоко»?.
3. В чем заключается фундаментальное различие между обучением с учителем (supervised learning) и обучением без учителя (unsupervised learning) в контексте Data Mining?
4. Задача Data Mining может быть дескриптивной (описательной) или предиктивной (прогнозной). Объясните разницу на примере двух задач.
5. Приведите пример задачи Data Mining, которая одновременно содержит черты и кластеризации, и классификации. Может ли одна и та же модель решать обе задачи? Поясните.

Практическое задание к билету:

Сгенерируйте простую таблицу в Excel или Блокноте (табуляция):

Месяц	Расход_на_рекламу (руб)	Продажи (руб)
1	1000	10000
2	1500	13500
3	2000	16000

- 1) Добавьте 10-15 строк.

- 2) Импортируйте файл. Убедитесь, что поле «Продажи» имеет тип «Непрерывный» (Continuous).
- 3) Выберите «Мастер обработки» -> «Data Mining» -> «Линейная регрессия». В качестве «Зависимой переменной» (Output) укажите «Продажи», в качестве «Входов» (Input) — «Расход_на_рекламу».
- 4) Используйте визуализатор «Что-если» (What-If). Подставьте значение рекламного бюджета 5000 руб. во входное поле и посмотрите, какой прогноз по продажам выдаст система.

Тема 4. Методы и средства Data Mining. ОПК-3.1

Экзаменационные вопросы:

1. Чем отличаются задачи кластеризации от задач классификации в Data Mining? Приведите пример для каждого типа задач.
2. Что такое «энтропия» и «Information Gain»? Как эти понятия используются при построении дерева решений (например, алгоритм ID3 или C4.5)?
3. Для чего используется метод «гребневой регрессии» (Ridge regression) или LASSO? Какую проблему классической линейной регрессии они решают?
4. Опишите матрицу ошибок (Confusion Matrix). Для задачи бинарной классификации объясните, что такое: TP, TN, FP, FN, и как на их основе вычисляется метрика F1-мера.
5. Что такое «функция активации» и градиентный спуск в контексте обучения нейронной сети? Назовите проблему «затухающего градиента»?
6. Объясните суть метода главных компонент (PCA). Чем PCA отличается от отбора признаков (Feature Selection)?
7. Каковы ключевые отличия в архитектуре и задачах между инструментами типа Pandas/Sci-kit learn (Python) и специализированными BI-средствами (например, Tableau, Power BI) для выполнения анализа данных?
8. Что такое «переобучение» (overfitting) модели? Назовите три различных способа борьбы с переобучением и кратко опишите, как каждый из них работает.

Практическое задание к билету:

Построить модель, оценивающую вероятность невозврата кредита. Исходные данные: Файл «Кредитная история» (например, scoring.txt).

- 1) Убедитесь, что целевое поле «Просрочка» имеет тип «Категория».
- 2) В мастере обработки выберите «Data Mining» → «Логистическая регрессия». Укажите «Просрочка» как зависимая переменная (Output). Остальные поля — входные (Input).

- 3) Используйте визуализатор «Что-если» . Подставьте значения «молодой клиент с низким доходом» и «пожилой клиент с высоким доходом» и сравните вероятность дефолта.

Тема 5. Визуальный анализ данных Visual Mining. ОПК-3.1

Экзаменационные вопросы:

1. Чем «визуальный анализ данных» (Visual Analytics) принципиально отличается от обычной «информационной визуализации» (Infovis) и «статической статистической графики»?
2. Опишите классический «цикл визуального анализа» (модель Keim). Из каких четырёх основных этапов он состоит?
3. Назовите три основные задачи (цели), которые преследует визуальный анализ (например: обнаружение выбросов, поиск кластеров, выявление зависимостей).
4. Что такое «агрегация данных» (aggregation) и «биннинг» (binning) при визуальном анализе больших массивов? К чему приводит агрегация при изучении распределения плотности (парадокс ансамбля).
5. Согласно исследованиям Кливленда и МакГилла, расположите следующие визуальные каналы (элементы кодирования) по убыванию точности восприятия количественных данных: Угол наклона, Длина линии, Площадь круга, Положение на общей шкале, Цветовой оттенок.

Практическое задание к билету:

Построить многомерные куб (OLAP) для быстрого анализа продаж и выявления «узких мест» без использования сложных алгоритмов.

Исходные данные: Демо-файл «Продажи магазина» (обычно есть в samples) или создайте свой CSV с полями: Дата, Товарная_группа, Регион, Сумма_продаж, Количество.

- 1) Импортируйте файл.
- 2) С помощью «Мастер обработки» создайте «OLAP-куб» .
- 3) Откройте визуализатор «Таблица». Найдите самую убыточную товарную группу в конкретном регионе.
- 4) Используйте «Срез» (Slice) по дате, чтобы посмотреть динамику только за последний квартал.
- 5) Опишите, какой товар и в каком регионе требует немедленного внимания руководства на основе визуального анализа куба.

РАЗДЕЛ 3. РЕШЕНИЕ ОСНОВНЫХ ЗАДАЧ АНАЛИЗА ИНФОРМАЦИИ

Тема 6. Классификация и регрессия. ОПК-3.1

Экзаменационные вопросы:

1. Чем принципиально отличается задача классификации от задачи регрессии?

2. В задаче бинарной классификации «обнаружение мошеннических транзакций» в выборке 99,8% транзакций — честные, 0,2% — мошеннические. Какая проблема возникает при обучении модели на таких данных?
3. Модель классификации показала на обучающей выборке Accuracy = 99%, а на тестовой — Accuracy = 72%. Как называется это явление?
4. Классификация и регрессия относятся к обучению с учителем. Назовите главный критерий, который определяет, какую из этих двух моделей следует применить к данным?
5. Представьте, что банк строит модель для кредитного скоринга (решение: одобрить/отказать). Является ли эта задача классификацией или регрессией?

Практическое задание к билету:

Имеются данные о 10 клиентах (обучающая выборка):

Клиент	Доход (тыс. руб.)	Стаж работы (лет)	Возраст	Долг по другим кредитам	Класс
1	90	5	32	10	0
2	45	1	25	50	1
3	120	10	45	5	0
4	60	2	30	40	1
5	80	4	35	15	0
6	40	1	22	60	1
7	110	8	41	0	0
8	55	2	28	45	1
9	95	6	38	8	0
10	50	1	24	55	1

1. Рассчитать линейную дискриминантную функцию (ЛДФ) вручную или с помощью ПО (Excel, R, Python).
2. Классифицировать нового клиента с параметрами: доход = 70, стаж = 3, возраст = 31, долг = 25.
3. Оценить точность модели на обучающей выборке (матрица ошибок)

Тема 7. Поиск ассоциативных правил. ОПК-3.1

Экзаменационные вопросы:

1. Дайте определение ассоциативному правилу в виде $X \Rightarrow Y$. Что означают антецедент (левая часть) и консеквент (правая часть) в контексте анализа потребительской корзины?
2. Объясните физический смысл трех ключевых метрик: поддержка (support), достоверность (confidence) и лифт (lift).
3. Приведите пример двух правил, которые имеют высокую

достоверность (confidence), но при этом являются бесполезными или вводящими в заблуждение.

4. В чем заключается главный принцип работы алгоритма Apriori («антимонотонность поддержки»)? Почему этот принцип позволяет сократить перебор кандидатов?
5. Назовите два основных недостатка алгоритма Apriori. В каких случаях (характеристики данных) эти недостатки становятся критическими, и алгоритм перестает работать эффективно.

Практическое задание к билету:

Исходные данные: Файл транзакций магазина. Он должен содержать два столбца: ID_чека и Товар. (Важно: в мастере импорта столбцу ID_чека назначьте тип «Идентификатор транзакции», а столбцу Товар — тип «Элемент»).

- 1) Запустите мастер обработки и выберите «Ассоциативные правила».
- 2) Настройте метрики. Задайте Поддержку (Support) от 20% до 60% и Достоверность (Confidence) от 40% до 90%. Это отсекает редкие и ненадежные правила.
- 3) Посмотрите, какие товары (или сочетания из 2-3 товаров) встречаются чаще всего.
- 4) Найдите правило с самой высокой достоверностью.
- 5) Сделайте скриншот визуализатора «Дерево правил» и объясните, какой товар является «якорем» (например, «Хлеб» тянет за собой «Масло»).

Тема 8. Кластеризация. ОПК-3.1

Экзаменационные вопросы:

1. Дайте определение кластеризации.
2. Чем задача кластеризации принципиально отличается от задачи классификации в машинном обучении?
3. На чем основано объединение объектов в кластеры?
4. Какую математическую меру чаще всего используют для оценки «близости» объектов в евклидовом пространстве и почему ее нельзя использовать для категориальных данных?
5. Что такое «жесткая» и «мягкая» (нечеткая) кластеризация? Приведите пример алгоритма для каждого типа.
6. В чем разница между агломеративным (восходящим) и дивизивным (нисходящим) подходами в иерархической кластеризации? Что такое дендрограмма?
7. Назовите два подхода к оценке качества кластеризации. В чем разница между внешними (external) и внутренними (internal) метриками оценки?

Практическое задание к билету:

Имеются данные о 7 регионах по 3 показателям (условные единицы)

Регион	Среднедушевой доход	Уровень безработицы (%)	Инвестиции в основной капитал
А	35	5.2	12
Б	42	4.1	18
В	28	7.0	7
Г	45	3.8	22
Д	31	6.5	10
Е	38	4.5	15
Ж	22	8.2	5

1. Нормировать данные (Z-оценка).
2. Выполнить кластеризацию методом k-средних (k=3).
3. Интерпретировать полученные кластеры.
4. Визуализировать результат на плоскости первых двух главных компонент.

6.3. Критерии и шкала оценивания на основе БРС.

Соответствие государственной шкалы оценивания академической успеваемости и шкалы ECTS при экзамене

Оценка по шкале ECTS	Сумма баллов за все виды учебной деятельности	Оценка по государственной шкале	Определение
A	90 – 100	«Отлично»	отличное выполнение с незначительным количеством неточностей
B	80 – 89	«Хорошо»	в целом правильно выполненная работа с незначительным количеством ошибок (до 10%)
C	75 – 79		в целом правильно выполненная работа с незначительным количеством ошибок (до 15%)
D	70 – 74	«Удовлетворительно»	неплохо, но со значительным количеством недостатков
E	60 – 69		выполнение удовлетворяет минимальные критерии
FX	35 – 59	«Не удовлетворительно»	с возможностью повторной сдачи
F	0 – 34		с обязательным повторным изучением дисциплины (выставляется комиссией)

6.4. Описание дополнительных материалов и оборудования, необходимых для выполнения проверочных заданий

Компьютер с операционной системой РЕД ОС или MS Windows, на котором установлены Р7-Офис или MS Office, Deductor Academic - бесплатная версия аналитической платформы Deductor.

7. Методические материалы по освоению дисциплины

Получение углубленных знаний по изучаемой дисциплине достигается за счет дополнительных часов к аудиторной работе самостоятельной работы студентов. Выделяемые часы целесообразно использовать для знакомства с дополнительной научной литературой по проблематике дисциплины, анализа научных концепций и современных подходов к осмыслению рассматриваемых проблем. К самостоятельному виду работы студентов относится работа в библиотеках, в электронных поисковых системах и т.п. по сбору материалов, необходимых для проведения практических занятий или выполнения конкретных заданий преподавателя по изучаемым темам. Студенты могут установить диалог с преподавателем, получать консультации по выполнению заданий. В качестве оценочных средств на протяжении семестра используются тестовые и иные задания.

Обучение по дисциплине «Современные технологии анализа информации» предполагает изучение курса на аудиторных занятиях (лекции, практические занятия) и самостоятельную работу студентов. Практические занятия дисциплины предполагают их проведение в различных формах с целью выявления полученных знаний, умений, навыков и компетенций с проведением контрольных мероприятий. С целью обеспечения успешного обучения студент должен готовиться к лекции, поскольку она является важнейшей формой организации учебного процесса, поскольку:

- знакомит с новым учебным материалом;
- разъясняет учебные элементы, трудные для понимания;
- систематизирует учебный материал;
- ориентирует в учебном процессе.

Работа обучающегося на лекции:

Слушание и запись лекций – сложный вид вузовской аудиторной работы. Внимательное слушание и конспектирование лекций предполагает интенсивную умственную деятельность обучающегося. Краткие записи лекций, их конспектирование помогает усвоить учебный материал. Конспект является полезным тогда, когда записано самое существенное, основное и сделано это самим обучающимся.

Подготовка к практическим занятиям:

Подготовку к каждому практическому занятию каждый обучающийся должен начать с ознакомления с планом, который отражает содержание предложенной темы. Тщательное продумывание и изучение вопросов плана основывается на проработке текущего материала лекции, а затем изучения обязательной и дополнительной литературы, рекомендованную к данной теме. Если программой дисциплины предусмотрено выполнение практического задания, то его необходимо выполнить с учетом предложенной инструкции. Все новые понятия по изучаемой теме необходимо внести в глоссарий, который целесообразно вести с самого начала изучения курса. Результат такой работы должен проявиться в способности обучающегося свободно ответить на теоретические вопросы практического занятия, его выступлении и участии в коллективном обсуждении вопросов изучаемой темы, правильном выполнении практических заданий и контрольных работ.

Структура практического занятия:

В зависимости от содержания и количества отведенного времени на изучение каждой темы может практическое занятие состоять из четырех-пяти частей:

1. Устный опрос.
2. Обсуждение теоретических вопросов, определенных программой дисциплины.
3. Выполнение практических заданий с последующим разбором полученных результатов или обсуждение практического задания, выполненного дома.
4. Подведение итогов занятия.

Работа с литературными источниками:

В процессе подготовки к практическим занятиям, обучающимся необходимо обратить особое внимание на самостоятельное изучение рекомендованной учебно-методической (а также научной и популярной) литературы. Самостоятельная работа с учебниками, учебными пособиями, научной, справочной и популярной литературой, материалами периодических изданий и Интернета, статистическими данными является наиболее эффективным методом получения знаний, позволяет значительно активизировать процесс овладения информацией, способствует более глубокому усвоению изучаемого материала, формирует у обучающихся свое отношение к конкретной проблеме. Более глубокому раскрытию вопросов способствует знакомство с дополнительной литературой, рекомендованной преподавателем, что позволяет обучающимся проявить свою индивидуальность в рамках выступления на занятиях, выявить широкий спектр мнений по изучаемой проблеме.

8. Учебная литература и ресурсы информационно-телекоммуникационной сети Интернет

8.1. Основная литература

1. Гончаренко А. Н. Многомерный статистический анализ : учебно-методическое пособие / Н. Г. . — Москва : МИСИС, 2022 — Часть 1 — 2022. — 53 с. — Текст : электронный // Лань : электронно-библиотечная система. — URL: <https://e.lanbook.com/book/263435> (дата обращения: 13.05.2026). — Режим доступа: для авториз. пользователей.

2. Гончаренко А. Н. Многомерный статистический анализ : учебно-методическое пособие / Н. Г. . — Москва : МИСИС, 2022 — Часть 2 — 2022. — 70 с. — Текст : электронный // Лань : электронно-библиотечная система. — URL: <https://e.lanbook.com/book/263438> (дата обращения: 13.05.2026). — Режим доступа: для авториз. пользователей.

3. Прозорова, Л. Ю. Практикум по статистическим методам анализа данных и технологиям Data Mining : учебное пособие / Л. Ю. Прозорова. — Пермь : ПНИПУ, 2023. — 139 с. — ISBN 978-5-398-03091-4. — Текст : электронный // Лань : электронно-библиотечная система. — URL: <https://e.lanbook.com/book/416468> (дата обращения: 13.05.2026). — Режим доступа: для авториз. пользователей.

4. Морозов, П. Е. Выход из научного застоя: о необходимости использования технологии Data Mining в науке трудового права : монография / П. Е. Морозов. — Москва : Проспект, 2019. — 120 с. — ISBN 978-5-392-30788-3. — Текст : электронный // Лань : электронно-библиотечная система. — URL: <https://e.lanbook.com/book/181091> (дата обращения: 13.05.2026). — Режим доступа: для авториз. пользователей.

8.2. Дополнительная литература

5. Макшанов, А. В. Технологии интеллектуального анализа данных : учебное пособие / А. В. Макшанов, А. Е. Журавлев. — 2-е изд., стер. — Санкт-Петербург : Лань, 2022. — 212 с. — ISBN 978-5-8114-4493-9. — Текст : электронный // Лань : электронно-библиотечная система. — URL: <https://e.lanbook.com/book/206711> (дата обращения: 13.05.2026). — Режим доступа: для авториз. пользователей.

6. Основы анализа данных и интеллектуальные системы : учебное пособие для вузов / С. Н. Косников, А. Л. Золкин, Ф. Р. Ахмадуллин [и др.]. — Санкт-Петербург : Лань, 2025. — 176 с. — ISBN 978-5-507-50239-4. — Текст : электронный // Лань : электронно-библиотечная система. — URL: <https://e.lanbook.com/book/440060> (дата обращения: 13.05.2026). — Режим доступа: для авториз. пользователей.

7. Макшанов, А. В. Технологии интеллектуального анализа данных : учебное пособие / А. В. Макшанов, А. Е. Журавлев. — 2-е изд., стер. — Санкт-Петербург : Лань, 2022. — 212 с. — ISBN 978-5-8114-4493-9. —

Текст : электронный // Лань : электронно-библиотечная система. — URL: <https://e.lanbook.com/book/206711> (дата обращения: 13.05.2026). — Режим доступа: для авториз. пользователей.

8. Москвитин, А. А. Данные, информация, знания: методология, теория, технологии / А. А. Москвитин. — 2-е изд., стер. — Санкт-Петербург : Лань, 2023. — 236 с. — ISBN 978-5-507-45865-3. — Текст : электронный // Лань : электронно-библиотечная система. — URL: <https://e.lanbook.com/book/288968> (дата обращения: 13.05.2026). — Режим доступа: для авториз. пользователей.

8.3. Нормативные правовые документы и иная правовая информация

1. Конституция Российской Федерации. — Текст : электронный // Сайт Президента Российской Федерации. — URL: <http://www.kremlin.ru/acts/constitution>

8.4 Интернет-ресурсы

1. Введение в интеллектуальный анализ данных (курс). — URL: <https://www.hse.ru/ma/msa/courses/918965742.html>
2. Методы машинного обучения и интеллектуального анализа данных (курс). — URL: <https://www.hse.ru/edu/courses/1048846287>
3. Анализ данных. В.С. Мхитарян и др.—(электронный учебник) URL: <https://urait.ru/bcode/560311>
4. Электронно-библиотечная система «Лань». — URL: <http://e.lanbook.com>
5. Анализ данных в бизнесе (курс)— URL: <https://id.hse.ru/edu/courses/908657711>
6. Электронно-библиотечная система «Юрайт» — учебники — URL: <https://urait.ru/>

9. Материально-техническая база, информационные технологии, программное обеспечение и информационные справочные системы

Материально-техническое обеспечение дисциплины включает в себя:

- лекционные аудитории, оборудованные видеопроекторным оборудованием для презентаций, средствами звуковоспроизведения, экраном;

- помещения для проведения семинарских и практических занятий, оборудованные учебной мебелью.

Дисциплина поддержана соответствующими программными продуктами с открытой лицензией: РЕД ОС, Р7-Офис, Deductor Academic.

Вуз обеспечивает каждого обучающегося рабочим местом в

компьютерном классе в соответствии с объемом изучаемых дисциплин, обеспечивает выход в сеть Интернет.

Помещения для самостоятельной работы обучающихся включают следующую оснащенность: столы аудиторные, стулья, доски аудиторные, компьютеры с подключением к локальной сети института (для компьютерных аудиторий) и Интернет. Для изучения учебной дисциплины используются автоматизированная библиотечная информационная система и электронные библиотечные системы.