

**Государственное образовательное учреждение
"Приднестровский государственный университет им. Т.Г. Шевченко"**

Инженерно-технический институт

**Кафедра информационных технологий
и автоматизированного управления производственными процессами**

УТВЕРЖДАЮ

Заведующий кафедрой ИТиАУПП

 Ю.А. Столяренко

«29» августа 2022 г.

ФОНД ОЦЕНОЧНЫХ СРЕДСТВ

**по дисциплине
ПРИКЛАДНЫЕ ЗАДАЧИ АНАЛИЗА ДАННЫХ**

Направление подготовки
2.09.03.01 Информатика и вычислительная техника

Профиль подготовки
Вычислительные машины, комплексы, системы и сети

Квалификация (степень)
выпускника: **бакалавр**

Форма обучения: **очная, заочная**

Год набора: **2021 г.**

Разработал:
к.т.н., доцент кафедры ИТиАУПП,

 /В.С. Попукайло

«29» августа 2022 г.

Тирасполь, 2022

Паспорт фонда оценочных средств по учебной дисциплине

1. В результате изучения дисциплины «Прикладные задачи анализа данных» у обучающегося должны быть сформированы следующие компетенции:

Категория (группа) компетенций	Код и наименование	Код и наименование индикатора достижения универсальной компетенции
<i>Общепрофессиональные компетенции и индикаторы их достижения</i>		
	ОПК-1. Способен применять естественнонаучные и общеинженерные знания, методы математического анализа и моделирования, теоретического и экспериментального исследования в профессиональной деятельности	ИД-1 _{ОПК-1} Знать основы высшей математики, физики, экологии, инженерной графики, информатики и программирования ИД-2 _{ОПК-1} Уметь решать стандартные профессиональные задачи с применением естественнонаучных и общеинженерных знаний, методов математического анализа и моделирования ИД-3 _{ОПК-1} Владеть методами теоретического и экспериментального исследования объектов профессиональной деятельности

2. Программа оценивания контролируемой компетенции:

Текущая аттестация	Контролируемые модули, разделы (темы) дисциплины их название	Код контролируемой компетенции (или ее части)	Наименование оценочного средства
РУБЕЖНЫЙ КОНТРОЛЬ	Раздел 1 Раздел 2 Раздел 3	ОПК-1	Лабораторные работы №1-5
РУБЕЖНАЯ АТТЕСТАЦИЯ	Раздел 4 Раздел 5 Раздел 6		Лабораторные работы №6-9 Тестирование
Промежуточная аттестация		Код контролируемой компетенции (или ее части)	Наименование оценочного средства
№1		ОПК-1	зачет

3. Показатели и критерии оценивания компетенции по этапам формирования, описание шкал оценивания

Этапы оценивания компетенции	Показатели достижения заданного уровня освоения компетенции	Критерии оценивания результатов обучения			
		2	3	4	5
Первый этап	ИД-1 _{ОПК-1} Знать основы высшей математики, физики, экологии, инженерной графики, информатики	Не знает	Знает основные понятия но не знает способы использования в	Знает основы высшей математики, физики, экологии, инженерной	Знает основы высшей математики, физики, экологии, инженерной графики, ин-

Этапы оценивания компетенции	Показатели достижения заданного уровня освоения компетенции	Критерии оценивания результатов обучения			
		2	3	4	5
	и программирования		профессиональной деятельности	графики, информатики и программирования, но не может применять знания в полной мере в профессиональной деятельности	форматики и программирования и может использовать в профессиональной деятельности
Второй этап	ИД-2 опк-1 Уметь решать стандартные профессиональные задачи с применением естественнонаучных и общеинженерных знаний, методов математического анализа и моделирования	Не умеет	Уметь решать некоторые стандартные профессиональные задачи с применением естественнонаучных и общеинженерных знаний, методов математического анализа и моделирования	Умеет решать стандартные профессиональные задачи с применением естественнонаучных и общеинженерных знаний, методов математического анализа и моделирования, но не в полной мере	Умеет решать стандартные профессиональные задачи с применением естественнонаучных и общеинженерных знаний, методов математического анализа и моделирования
Третий этап	ИД-3опк-1 Владеть методами теоретического и экспериментального исследования объектов профессиональной деятельности	Не владеет	Владеет методами теоретического и экспериментального исследования объектов профессиональной деятельности, но не владеет ими в междисциплинарном контексте	Владеет методами теоретического и экспериментального исследования объектов профессиональной деятельности, но ошибается в обработке их результатов	Владеет методами теоретического и экспериментального исследования объектов профессиональной деятельности, в том числе в новой или незнакомой среде и в междисциплинарном контексте

4. Шкала оценивания

Согласно Положению «О порядке организации аттестации в ИТИ ПГУ им. Т.Г. Шевченко, итоговая оценка представляет собой сумму баллов, полученных студентом по итогу освоения дисциплины (модуля):

Оценка в традиционной шкале	Оценка в 100-балльной шкале	Буквенные эквиваленты оценок в шкале ЗЕ (% успешно аттестованных)
5 (отлично)	88–100	A (отлично) – 88-100 баллов
4 (хорошо)	70–87	B (очень хорошо) – 80-87 баллов C (хорошо) – 70-79 баллов
3 (удовлетворительно)	50–69	D (удовлетворительно) – 60-69 баллов

		E (посредственно) – 50-59 баллов
2 (неудовлетворительно)	0–49	Fx – неудовлетворительно, с возможной пересдачей – 21-49 баллов
		F – неудовлетворительно, с повторным изучением дисциплины – 0-20 баллов

Расшифровка уровня знаний, соответствующего полученным баллам, дается в таблице, указанной ниже

A	“Отлично” - теоретическое содержание курса освоено полностью, без пробелов, необходимые практические навыки работы с освоенным материалом сформированы, все предусмотренные программой обучения учебные задания выполнены, качество их выполнения оценено числом баллов, близким к максимальному.
B	“Очень хорошо” - теоретическое содержание курса освоено полностью, без пробелов, необходимые практические навыки работы с освоенным материалом в основном сформированы, все предусмотренные программой обучения учебные задания выполнены, качество выполнения большинства из них оценено числом баллов, близким к максимальному.
C	“Хорошо” - теоретическое содержание курса освоено полностью, без пробелов, некоторые практические навыки работы с освоенным материалом сформированы недостаточно, все предусмотренные программой обучения учебные задания выполнены, качество выполнения ни одного из них не оценено минимальным числом баллов, некоторые виды заданий выполнены с ошибками.
D	“Удовлетворительно” - теоретическое содержание курса освоено частично, но пробелы не носят существенного характера, необходимые практические навыки работы с освоенным материалом в основном сформированы, большинство предусмотренных программой обучения учебных заданий выполнено, некоторые из выполненных заданий, возможно, содержат ошибки.
E	“Посредственно” - теоретическое содержание курса освоено частично, некоторые практические навыки работы не сформированы, многие предусмотренные программой обучения учебные задания не выполнены, либо качество выполнения некоторых из них оценено числом баллов, близким к минимальному.
FX	“Условно неудовлетворительно” - теоретическое содержание курса освоено частично, необходимые практические навыки работы не сформированы, большинство предусмотренных программой обучения учебных заданий не выполнено, либо качество их выполнения оценено числом баллов, близким к минимальному; при дополнительной самостоятельной работе над материалом курса возможно повышение качества выполнения учебных заданий.
F	“Безусловно неудовлетворительно” - теоретическое содержание курса не освоено, необходимые практические навыки работы не сформированы, все выполненные учебные задания содержат грубые ошибки, дополнительная самостоятельная работа над материалом курса не приведет к какому-либо значимому повышению качества выполнения учебных заданий.

5. Типовые контрольные задания или иные материалы, необходимые для оценки знаний, умений, навыков и (или) опыта деятельности, характеризующих этапы формирования компетенций при изучении учебной дисциплины в процессе освоения образовательной программы

5.1 Образец индивидуального задания к лабораторной работе №1

1. Сгенерировать 100 выборок со стандартным нормальным законом распределения ($M=0$, $s=1$) и объемом выборки $N=(\text{№ по варианту} + 15)$.
2. Рассчитать для каждой выборки точечные оценки среднего, дисперсии и стандартного отклонения.
3. Рассчитать средние значения для оцененных параметров. Сравнить полученные результаты с генеральными значениями параметров.
4. Рассчитать для каждой выборки интервальные значения среднего, дисперсии и стандартного отклонения, приняв за априорное утверждение, что нам не известны генеральные значения данных параметров. Расчет произвести для вероятностей $P=0,90$, $P=0,95$.
5. Сделать выводы о точности точечных и интервальных оценок неизвестных параметров распределений.

5.2. Образец индивидуального задания к лабораторной работе №2

1. Сгенерировать 1000 выборок со стандартным нормальным законом распределения и объемом выборки N , где $N = \text{№ по списку в журнале} + 20$.
2. Рассчитать для каждой выборки точечные оценки среднего.
3. Для каждой из выборок построить графики, позволяющие оценить вид закона распределения: гистограммы, *qq-plot*, *boxplot*, *violinplot*.
4. Построить аналогичные графики для вектора, состоящего из средних значений.
5. Сделать выводы о проделанной работе.

5.3 Образец индивидуального задания к лабораторной работе №3

1. Загрузить файл «Данные для расчетов».
2. Проверить гипотезу о нормальности для каждой выборки.
3. Построить гистограммы выборок, для которых удалось отвергнуть гипотезу о нормальности.
4. Произвести логарифмическую трансформацию и изучить её влияние на распределение данных, построив гистограммы и проверив гипотезу о нормальности.
5. Для наглядности, сгенерировать выборку из экспоненциального распределения и построить гистограммы по сгенерированным данным и после их логарифмирования.
6. Сделать выводы о проделанной работе.

5.4 Образец индивидуального задания к лабораторной работе №4

1. Загрузить данные из файла «Данные для расчетов».
2. Сделать срез из данных, такой, чтобы в исследуемом *data.frame* остались только столбцы с номерами: [№ по журналу; № по журналу+10]

3. Проверить предпосылки для применения классического однофакторного дисперсионного анализа.
4. Провести параметрический или непараметрический дисперсионный анализ, в зависимости от полученных результатов на предыдущем шаге.
5. При отклонении гипотезы о равенстве всех математических ожиданий провести попарные сравнения изучаемых групп.
6. Визуализировать полученные различия при помощи boxplot + violinplot..
7. Сделать выводы о проделанной работе.

5.5 Образец индивидуального задания к лабораторной работе №5

1. Загрузить набор данных для своего варианта, ознакомиться с его содержимым.
2. Построить график корреляционного поля для каждого фактора.
3. Построить уравнение парной линейной регрессии для каждого фактора
4. Проверить значимость каждого из полученных уравнений регрессии. Показать уравнения регрессии с заданным в варианте доверительным интервалом на графиках.
5. Построить прогнозы по каждому из уравнений парной регрессии для заданных в варианте значений факторов.
6. Построить уравнение множественной линейной регрессии и получить корреляционную матрицу.
7. Построить прогноз по уравнению множественной регрессии для заданных в варианте значений факторов.

5.6 Образец индивидуального задания к лабораторной работе №6

1. Загрузить набор данных для своего варианта, ознакомиться с его содержимым.
2. Построить модель логистической регрессии для заданной целевой переменной.
3. Оцените качество полученной модели. Определите, какой метрикой лучше пользоваться в данном случае.
4. Постройте ROC кривую для полученной модели.
5. Постройте дерево решений для данных своего варианта.
6. Оцените качество полученной модели. Определите, какой метрикой лучше пользоваться в данном случае.
7. Постройте ROC кривую для полученной модели.
8. Сделать выводы о проделанной работе.

5.7 Образец индивидуального задания к лабораторной работе №7

1. Загрузить набор данных для своего варианта, ознакомиться с его содержимым.
2. Используя пакет caret постройте модели: наивный байесовский классификатор, машины опорных векторов, случайный лес и AdaBoost.
3. Оцените качество полученных моделей при помощи метрик Accuracy и Кappa.
4. Сделать выводы о проделанной работе.

5.8 Образец индивидуального задания к лабораторной работе №8

1. Загрузить набор данных для своего варианта, ознакомиться с его содержимым.
2. Проведите процедуру кластеризации при помощи метода k-means и иерархической кластеризации.
3. Постройте дендрограмму и определите оптимальное количество кластеров.
4. Сделать выводы о проделанной работе.

5.9 Образец индивидуального задания к лабораторной работе №9

1. Загрузить набор данных для своего варианта, ознакомиться с его содержимым.
2. Проведите разведывательный анализ данных, ответьте на вопросы.
3. Постройте графики, указанные в заданиях.
4. Рассчитайте статистические критерии.
5. Оцените величину корреляционной связи между величинами.
6. Постройте математическую модель по данным.
7. Оформите отчёт в виде RMarkdown файла.

5.10 Образец тестового задания №1

Пример вопросов теста №1:

1. Критерий Стьюдента может применяться:

- a. Для проверки равенства средних значений в двух выборках
- b. Для проверки равенство дисперсий в двух выборках
- c. Для проверки значимости коэффициентов в регрессионных моделях
- d. Для проверки значимости регрессионных моделей в целом

2. В каком случае необходимо применять непараметрические критерии:

- a. Если распределение экспериментальных данных согласуется с семейством нормальных распределений
- b. Если распределение экспериментальных данных не согласуется с семейством нормальных распределений
- c. Если объём экспериментальных данных больше 100
- d. Если необходимо проанализировать количественные данные

3. Оценка называется состоятельной, если:

- a. её математическое ожидание равно оцениваемому параметру
- b. она асимптотически приближается к оцениваемому параметру
- c. её дисперсия является наименьшей среди других оценок

4. Основной целью дисперсионного анализа является:

- a. Исследование значимости различий между средними с помощью анализа дисперсий
- b. Исследование значимости различий между дисперсиями с помощью анализа средних
- c. Исследование значимости различий между дисперсиями с помощью анализа распределений
- d. Исследование значимости различий между распределениями с помощью анализа дисперсий

5. Мощностью критерия называется:

- a. Вероятность ошибки первого рода (ложная тревога)
- b. Вероятность ошибки второго рода (пропуск цели)
- c. Единица минус вероятность ошибки первого рода
- d. Единица минус вероятность ошибки второго рода

6. Для сравнения качества моделей с различным количеством предикторов можно использовать:

- a. Коэффициент корреляции
- b. Коэффициент детерминации
- c. Исправленный коэффициент корреляции
- d. Исправленный коэффициент детерминации
- e. Информационный критерий Акаике
- f. Информационный критерий Шварца
- g. Информационный критерий Стьюдента

h. Критерий Фишера

7. Какой из пороговых значений р-уровня значимости лучше выбрать, если весьма рискованно отклонить нулевую гипотезу, когда она на самом деле верна:

- a. 0,001
- b. 0,5
- c. 0,05
- d. 0,1
- e. 0,01

8. Назовите два основных типа переменных в статистике:

- a. Качественные и номинативные
- b. Качественные и количественные
- c. Ранговые и номинативные
- d. Непрерывные и количественные
- e. Количественные и дискретные

9. В каких случаях вместо среднего значения лучше использовать моду или медиану в качестве меры центральной тенденции?

- a. Если в данных есть выбросы
- b. Если распределение асимметрично
- c. Если распределение симметрично и унимодально

10. Может ли дисперсия принимать отрицательные значения?

- a. Может, если все значения выборки отрицательные
- b. Не может, дисперсия всегда положительная
- c. Может, если все значения в выборке равны друг-другу
- d. Не может, дисперсия всегда изменяется в диапазоне от 0 до 1

11. Какой из пороговых значений р-уровня значимости лучше выбрать, если весьма рискованно отклонить нулевую гипотезу, когда она на самом деле верна:

- a. 0,001
- b. 0,5
- c. 0,05
- d. 0,1
- e. 0,01

12. Стандартное нормальное распределение – это:

- a. Нормальное распределение с средним и дисперсией = 0
- b. Нормальное распределение с средним и дисперсией = 1
- c. Нормальное распределение с средним и СКО = 0
- d. Нормальное распределение с средним и СКО = 1
- e. Нормальное распределение с средним = 0 и дисперсией = 1
- f. Нормальное распределение с средним = 1 и дисперсией = 0
- g. Нормальное распределение с средним = 0 и СКО = 1
- h. Нормальное распределение с средним = 1 и СКО = 0

13. Укажите верные высказывания:

- a. Т-распределение унимодально
- b. Т-распределение асимметрично
- c. При достаточно большом количестве степеней свободы t-распределение стремится к стандартному нормальному распределению.
- d. Т-распределение зависит от двух параметров: среднего и дисперсии

14. Критерий Стьюдента может применяться:

- a. Для проверки равенства средних значений в двух выборках
- b. Для проверки равенства дисперсий в двух выборках
- c. Для проверки значимости коэффициентов в регрессионных моделях
- d. Для проверки значимости регрессионных моделей в целом

15. Выберите меры изменчивости данных:

- a. Дисперсия
- b. Асимметрия
- c. Стандартное отклонение
- d. Эксцесс
- e. Медиана
- f. Размах

16. Если мы рассчитали 95% доверительный интервал для среднего значения, то какие из следующих утверждений являются верными?

- a. Мы можем быть на 95% уверены, что истинное среднее значение принадлежит рассчитанному доверительному интервалу.
- b. Истинное среднее значение точно принадлежит рассчитанному доверительному интервалу.
- c. Истинное среднее значение точно превышает нижнюю границу 95% доверительного интервала.
- d. Если многократно повторять эксперимент, то 95 % выборочных средних значений будут принадлежать рассчитанному нами доверительному интервалу.
- e. Если многократно повторять эксперимент, для каждой выборки рассчитывать свой доверительный интервал, то в 95 % случаев истинное среднее будет находиться внутри доверительного интервала.

17. Основной принцип метода проверки гипотез заключается в:

- a. Выдвигается нулевая гипотеза и мы пытаемся её подтвердить
- b. Выдвигается нулевая гипотеза и мы пытаемся её опровергнуть
- c. Выдвигаются нулевая и альтернативная гипотезы и наша задача узнать, какая из них правильная
- d. Выдвигается нулевая и альтернативные гипотезы и наша задача принять одну из них

18. Укажите верные высказывания:

- a. Коэффициент корреляции может принимать значения на промежутке [-1;1]
- b. Коэффициент корреляции показывает насколько разброс одной переменной зависит от разброса другой переменной

- c. Чем ближе значение коэффициента корреляции к 1 или к -1, тем сильнее взаимосвязь двух переменных.
- d. Положительное значение коэффициента корреляции говорит нам о том, что с увеличением значений од-ной переменной значения второй пе-ременной уменьшаются.

19. Метод наименьших квадратов минимизирует:

- a. Расстояние Хи-квадрат между фактическими и предсказанными значениями зависимой переменной
- b. Евклидово расстояние между фактическими и предсказанными значениями зависимой переменной
- c. Расстояние Хи-квадрат между значениями зависимой и независимой переменной
- d. Евклидово расстояние между значениями зависимой и независимой переменной

20. В каком случае необходимо применять непараметрические критерии:

- a. Если распределение экспериментальных данных согласуется с семейством нормальных распределений
- b. Если распределение экспериментальных данных не согласуется с семейством нормальных распределений
- c. Если объём экспериментальных данных больше 100
- d. Если необходимо проанализировать количественные данные

21. Если при проверке гипотезы р-уровень значимости оказался равен 0,02:

- a. Вероятность принять нулевую гипотезу равна 2%
- b. Вероятность отклонить нулевую гипотезу равна 2%
- c. Вероятность принять альтернативную гипотезу равна 2%
- d. Вероятность отклонить нулевую гипотезу равна 2%
- e. Следует принять нулевую гипотезу
- f. Следует отклонить нулевую гипотезу

22. Оценка называется состоятельной, если:

- a. её математическое ожидание равно оцениваемому параметру
- b. она асимптотически приближается к оцениваемому параметру
- c. её дисперсия является наименьшей среди других оценок

23. Заключение, сделанное из статистического наблюдения по своей сути является:

- a. Дедуктивным
- b. Индуктивным
- c. Абдуктивным
- d. Абсурдным

24. Проверить гипотезу о равенстве средних можно при помощи критерия:

- a. Стьюдента
- b. Фишера
- c. Бартлетта
- d. Манна-Уитни
- e. Хи-квадрат

25. Гистограмма – это:

- a. Эмпирический аналог функции плотности распределения

- b. Эмпирический аналог интегральной функции распределения
- c. Теоретический аналог функции плотности распределения
- d. Теоретический аналог интегральной функции распределения

26. Если при проверке гипотезы р-уровень значимости оказался равен 0,62:

- a. С вероятностью в 62% следует принять нулевую гипотезу
- b. С вероятностью в 62% следует отклонить нулевую гипотезу
- c. Нулевая гипотеза верна!
- d. Нулевая гипотеза не верна!
- e. У нас нет оснований, чтобы отклонить нулевую гипотезу
- f. У нас нет оснований, чтобы принять нулевую гипотезу

27. Основными предпосылками Метода наименьших квадратов для построения регрессионных моделей являются:

- a. Линейность модели относительно y
- b. Линейность модели относительно предикторов
- c. Нормальное распределение предикторов
- d. Нормальное распределение остатков
- e. Нормальное распределение регрессоров
- f. Гомоскедастичность
- g. Мультиколлинеарность
- h. Гетероскедастичность
- i. Отсутствие мультиколлинеарности
- j. Независимость наблюдений

28. Основной целью дисперсионного анализа является:

- a. Исследование значимости различий между средними с помощью анализа дисперсий
- b. Исследование значимости различий между дисперсиями с помощью анализа средних
- c. Исследование значимости различий между дисперсиями с помощью анализа распределений
- d. Исследование значимости различий между распределениями с помощью анализа дисперсий

29. Если сравнить доверительные интервалы, рассчитанные для 95% и 99%:

- a. 95% интервал будет уже
- b. 95% интервал будет шире
- c. Доверительные интервалы будут равны
- d. Возможен любой из вариантов
- e. Нет правильного ответа

30. Предпосылками дисперсионного анализа являются:

- a. Нормальное распределение факторов
- b. Нормальное распределение остатков
- c. Однородность дисперсий
- d. Однородность средних.

5.11 Перечень вопросов к зачёту по предмету

1. Распределение Хи-квадрат.
2. Этапы анализа данных.
3. Рассчитайте точечную и интервальную оценки среднего и дисперсии.
4. Распределение Стьюдента.
5. Однофакторный дисперсионный анализ.

6. Рассчитайте величину линейной корреляционной связи между выборками.
7. Нормальное распределение.
8. Определите, являются ли значимыми различия между выборками.
9. Равномерное распределение.
10. Оценка качества классификатора.
11. Рассчитайте описательные статистики для выборки: среднее арифметическое, коэффициент вариации, выборочную дисперсию, стандартное отклонение.
12. Корреляционный анализ. Методы и подходы.
13. Определите, имеют ли распределения выборок равные дисперсии.
14. Регрессионный анализ. Цели и задачи.
15. Проверьте гипотезу о принадлежности генеральной совокупности к нормальному закону распределения по данным выборки.
16. Идея р-уровня значимости.
17. Оценка качества регрессионной модели.
18. Квантили распределения.
19. Графические способы оценки вида закона распределения.
20. Свойства статистических оценок.
21. Дисперсионный анализ. Цели и задачи.
22. Понятие мощности статистических критериев. Виды ошибок.
23. Гипотеза о наличии в данных выбросов.
24. Центральная предельная теорема.
25. Алгоритмы кластеризации.
26. Алгоритмы классификации.
27. Ограничения метода наименьших квадратов.
28. Логистическая регрессия.
29. Задача обработки естественного языка.