

Федеральное государственное бюджетное образовательное учреждение  
высшего образования  
Московский государственный университет имени М.В. Ломоносова  
Факультет вычислительной математики и кибернетики

**УТВЕРЖДАЮ**  
декан факультета вычислительной  
математики и кибернетики

**И.А. Соколов /**  
**«27» сентября 2023г.**

**ФОНД ОЦЕНОЧНЫХ СРЕДСТВ**

по дисциплине

**Математическое программирование**

---

**Уровень высшего образования:**

**бакалавриат**

**Направление подготовки / специальность:**

**02.03.02 "Фундаментальная информатика и информационные технологии" (3++)**

**Направленность (профиль) ОПОП:**

**Искусственный интеллект и анализ данных**

**Форма обучения:**

**очная**

Рассмотрен и утвержден

*на заседании Ученого совета факультета ВМК*

*(протокол №7, от 27 сентября 2023 года)*

Москва 2023

## 1. ФОРМЫ И ОЦЕНОЧНЫЕ МАТЕРИАЛЫ ТЕКУЩЕГО КОНТРОЛЯ УСПЕВАЕМОСТИ И ПРОМЕЖУТОЧНОЙ АТТЕСТАЦИИ

В процессе и по завершении изучения дисциплины оценивается формирование у студентов следующих компетенций:

Планируемые результаты обучения по дисциплине (модулю)		
Содержание и код компетенции.	Индикатор (показатель) достижения компетенции	Планируемые результаты обучения по дисциплине, сопряженные с индикаторами достижения компетенций
ОПК-2. Способен применять компьютерные/суперкомпьютерные методы, современное программное обеспечение, в том числе отечественного происхождения, для решения задач профессиональной деятельности	ОПК-2.1. Выбирает компьютерные/суперкомпьютерные методы для решения задач профессиональной деятельности; ОПК-2.2. Использует современное программное обеспечение, в том числе отечественного происхождения, для решения задач профессиональной деятельности	<ul style="list-style-type: none"><li>• основные типовые и прикладные задачи, которые решаются с помощью методов проверки гипотез, дисперсионного и регрессионного анализа прикладной статистики, условия применимости и ограничения этих методов, подходы для интерпретации полученных результатов, типовые методы предобработки и данных ;</li><li>• основные методы прикладной статистики для решения задач проверки статистических гипотез, дисперсионного и регрессионного анализа, типовые методы и подходы предобработки и постобработки данных для статистического анализа ;</li><li>• основные понятия, алгоритмы и методы предобработки и постобработки</li></ul>

		<p>данных для статистического анализа ;</p> <ul style="list-style-type: none"> <li>• средства языков программирования аналитической платформы SAS для написания программ прикладного статистического анализа данных ;</li> <li>• особенности методов предобработки и постобработки данных при статистическом анализе ;</li> <li>• факторы, влияющие на эффективность работы программ статистического анализа данных .</li> </ul> <p>Уметь:</p> <ul style="list-style-type: none"> <li>• создавать алгоритмические и математические модели типовых прикладных задач, проводить спецификацию и формализацию задачи, реализовывать программы на языке статистического программирования на базе аналитической платформы SAS, оценивать и интерпретировать полученные результаты, реализовывать алгоритмы предобработки и постобработки данных, формировать отчеты ;</li> <li>• формализовать задачу</li> </ul>
--	--	--

		<p>статистического анализа данных в части методов проверки статистических гипотез, дисперсионного и регрессионного анализа, осуществлять подбор метапараметров и интерпретацию результатов методов прикладного статистического анализа (ОПК-2.М);</p> <ul style="list-style-type: none"> <li>• использовать современные языки программирования аналитической платформы SAS для реализации различных алгоритмов обработки и статистического анализа данных (языки SAS Base, Macro, SQL) ;</li> <li>• разрабатывать и выполнять программы статистического анализа данных для решения задач дисперсионного и регрессионного анализа, а также проверки гипотез .</li> </ul> <p>Владеть:</p> <ul style="list-style-type: none"> <li>• языками программирования SAS Base, SAS Macro, диалектом SAS SQL, возможностями и процедурами библиотеки статистического анализа данных SAS STAT и подсистемы формирования отчетности и работы с графикой SAS ODS ;</li> <li>•</li> </ul>
--	--	---

		<p>теоретическим и знаниями в области прикладной статистики в части решения задач дисперсионного и регрессионного анализа, а также проверки статистических гипотез ;</p> <ul style="list-style-type: none"> <li>• приемами эффективного программирования для задач обработки и статистического анализа данных .</li> </ul>
--	--	--

### 1.1. Текущий контроль успеваемости

Текущий контроль успеваемости осуществляется путем оценки результатов выполнения заданий практических (семинарских) занятий, самостоятельной работы, предусмотренных учебным планом и посещения занятий/активность на занятиях.

В качестве оценочных средств текущего контроля успеваемости предусмотрены:

решение индивидуальных заданий

Примеры заданий

#### Домашнее задание №1 (ПСР №1)

*Целью домашнего задания №1 является освоение языка SAS Base для чтения структурированных наборов данных, разработки и применения форматов и пользовательских функций, методов расчета агрегационных показателей и формирование внешних сложно структурированных наборов данных.*

##### **Формулировка задания:**

На основе набора данных SASHELP.CARS сформировать иерархический текстовый файл вида:

Производитель далее в скобках (Географическая область происхождения Производителя)

Число моделей Производителя по каждому числу цилиндров (CN) в строку вида: C4=X C12=y ...

Средняя мощность для второго варианта по каждому числу цилиндров в строку.

При этом размер счета сохранять в рублях по курсу 57 рублей за доллар и писать в виде CN=XXXXXXXX.XX RUB, а мощность сохранять в ваттах в виде CN=XXXXX,XX Watt. Для этого реализовать необходимые форматы и FCMP функции для пересчета единиц измерения.

## Домашнее задание №2 (ПСР №2)

Целью домашнего задания №2 является освоение работы на языках SAS Base и SAS Macro с внешним сложно структурированным набором данных, реализация методов предобработки (в частности расчетов агрегатов, фильтрации и транспонирования данных) данных.

### Формулировка задания:

Считать сформированный в первом задании текстовый файл и по нему сформировать набор данных с суммарной статистикой по среднему размеру счета «Число цилиндров»Х«География» вида:

	Asia	USA	Europe...	
C4	X	Y	Z	...
C12	...	...	...	...

При этом единицы измерения должны использоваться исходные (доллары и лошадиные силы), для чтения применять шаблоны, для перевода единиц функции FCMP.

## Домашнее задание №3 (ПСР №3)

Целью домашнего задания №3 является освоение процедур и методов проверки статистических гипотез и дисперсионного анализа аналитической платформы SAS, а также изучение процедур формирования отчетности и работы с подсистемой вывода.

### Формулировка задания:

На основе набора данных SASHELP.CARS сделать следующее (Уровень значимости для всех гипотез задается 0.01):

- 1) Проверить влияет ли тип Кузова (Type) на расход бензина в городе (MPG\_city) с заданным уровнем значимости.
- 2) Преобразовать категориальные переменные так, чтобы не было «неразличимых» групп (используя график diffogram, попарный t-test и шаг данных для объединения «неразличимых» групп). Написать соответствующий код.
- 3) Добавить предиктор Страна производитель, чтобы понять улучшается ли модель (по RMSE). Объединения «неразличимых» групп не проводить.
- 4) Проверить, нужен ли предиктор Origin\*Type и если не нужен, то исключить из модели. Построить финальную модель.
- 5) Сформировать pdf отчет, содержащий ТОЛЬКО таблицы: «Least Squares Means for effect ...» шага 2, ANOVA таблицу и таблицу статистик (fit statistics) последнего шага.

## Домашнее задание №4 (ПСР №4)

Целью домашнего задания №4 является освоение методов формирования шаблонов для гибкой настройки процедур работы с подсистемой вывода.

### Формулировка задания:

Бонус (необязательное) задание (позволит сгладить недочеты в других частях задачи или в других задачах): Перед вторым шагом задания 3 написать шаблон с помощью процедуры `template`, чтобы в таблице попарных сравнений «Least Squares Means for effect ...» (имя объекта `stat.GLM.Pdiff`) значение P-values больше заданного уровня значимости (0.01) подсвечивались красным или отмечалось «\*».

## Домашнее задание №5 (ПСР №5)

Целью домашнего задания №5 является освоение методов построения полноценных регрессионных моделей, включая процедуры преобразования и предобработки данных, поиска и удаления выбросов, формирования, оценки и выбора моделей разной сложности (включая обобщенные линейные модели), визуализации результатов.

### Формулировка задания:

Вместе с заданием передается два макроса:

- `prerepare_data` генерирует из набора данных `cars` случайным образом тренировочный и тестовый наборы (с сохранением распределения откликов). С тренировочным набором можно производить любые манипуляции (менять любые переменные, удалять записи и т.д.), в тестовом можно только дописывать входные переменные, например,  $X^*X$  или  $f(X)$ , причем по тем же правилам, что и в тренировочном наборе, менять переменные отклика в тестовом наборе нельзя.
- `calc_mape` считает на тестовом наборе оценку качества модели MAPE.

Задача состоит в том, чтобы построить регрессионную модель для прогнозирования расхода бензина на трассе (`MPG_highway`) от числовых переменных `Length` `Weight` `Wheelbase` `Horsepower` `Invoice` `EngineSize` `Cylinders` и категориальных переменных `Origin` и `Type`. Можно использовать процедуры, рассмотренные в рамках курса: `GLM`, `GLMSELECT`, `REG`, `GLMMOD`, а также их комбинации, например, можно фильтровать переменные одной процедурой, а модель строить другой по отобранным переменным, или оценивать выбросы одной, потом их удалять из тренировочного набора, а строить модель другой процедурой по отфильтрованному набору. Для оценки качества разработанной модели использовать макрос `calc_mape`. Для корректной работы макроса необходимо, чтобы результат прогноза писался в переменную `Result`. Обратите внимание, что при разных запусках `prerepare_data` генерируются разные тестовые и тренировочные наборы. Необходимо получать MAPE строго меньше 0.065. Рекомендуется использовать техники:

- Преобразования категориальных переменных (группировка значений) с использованием дисперсионного анализа (не забывайте делать эти преобразования и в тестовом наборе)
- Отбор значимых переменных с помощью `REG` или `GLMSELECT` (тестовый набор в качестве валидационного использовать нельзя, но можно из тренировочного выделить часть для валидации)
- Преобразование входных переменных и добавление полиномиальных членов в уравнение регрессии (не забывайте делать эти преобразования и в тестовом наборе)

- Преобразование отклика или использование обобщенных линейных моделей с разными распределениями ошибки и функциями связи (не забывайте делать правильный пересчет отклика после прогноза).

Для получения требуемого качества модели обычно достаточно правильно использовать 1-2 из перечисленных выше техник.

Построить 3D график зависимости прогноза отклика от переменных Weight и Horsepower с равномерной сеткой 20 на 20 точек (сетку в наборе данных сгенерировать самостоятельно).

## **1.2. Промежуточная аттестация**

Промежуточная аттестация осуществляется в форме экзамена

В качестве средств, используемых на промежуточной аттестации предусматривается:

Билеты

## **1.3. Типовые задания для проведения промежуточной аттестации**

### **Список вопросов для экзамена**

1. Основные принципы работы шага обработки данных.
2. Работа со структурированными наборами данных и массивами.
3. Форматы и типы данных, процедуры преобразования форматов и типов.
4. Работа с внешними сложно структурированными наборами данных.
5. Организация поиска по ключу с помощью индексов, форматов, хэш-объектов.
6. Пользовательские процедуры и функции.
7. Макропеременные и макроподстановки. Взаимодействие с SAS SQL.
8. Работа с подсистемой вывода.
9. Графические возможности и процедуры аналитической платформы.
10. Процедуры проверки гипотез и дисперсионного анализа.
11. Процедуры построения линейных регрессионных моделей. Смешанные линейные регрессионные модели.
12. Проблема мультиколлинеарности, пошаговый отбор переменных, регуляризация, преобразования пространства признаков.
13. Процедуры поиска главных компонент и кластеризации переменных.
14. Процедуры и инструменты для поиска выбросов.
15. Процедуры построения нелинейных регрессий.
16. Анализ таблиц сопряженности, логистическая регрессия.
17. Обобщенные линейные модели, пуассоновская и гамма регрессии.
18. Сравнение и оценка моделей на тестовом наборе данных.

## 2. КРИТЕРИИ ОЦЕНКИ ПО ДИСЦИПЛИНЕ

ШКАЛА И КРИТЕРИИ ОЦЕНИВАНИЯ результатов обучения (РО) по дисциплине				
Оценка	2 (не зачтено)	3 (зачтено)	4 (зачтено)	5 (зачтено)
виды оценочных средств				
<b>Знания</b> (виды оценочных средств: приведены в п. 1.2.)	Отсутствие знаний	Фрагментарные знания	Общие, но не структурированные знания	Сформированные систематические знания
<b>Умения</b> (виды оценочных средств: приведены в п. 1.2.)	Отсутствие умений	В целом успешное, но не систематическое умение	В целом успешное, но содержащее отдельные пробелы умение (допускает неточности не принципиального характера)	Успешное и систематическое умение
<b>Навыки</b> (владения, опыт деятельности) (виды оценочных средств: приведены в п. 1.2..)	Отсутствие навыков (владений, опыта)	Наличие отдельных навыков (наличие фрагментарного опыта)	В целом, сформированные навыки (владения), но используемые не в активной форме	Сформированные навыки (владения), применяемые при решении задач