

Министерство образования и науки Российской Федерации  
НОВОСИБИРСКИЙ ГОСУДАРСТВЕННЫЙ ТЕХНИЧЕСКИЙ  
УНИВЕРСИТЕТ

# **Компьютерные технологии анализа данных и исследования статистических закономерностей**

Методические указания  
к выполнению лабораторных работ  
для студентов I-го курса магистратуры ФПМИ (семестр 2)  
по направлению 010400.68  
дневного отделения

Новосибирск, 2012

Методические указания предназначены для студентов, выполняющих лабораторные работы по курсу "Компьютерные технологии анализа данных и исследования статистических закономерностей" (направление 010400.68). Указания содержат необходимые сведения для выполнения лабораторных работ, порядок выполнения, варианты заданий и контрольные вопросы, по которым осуществляется их защита.

Составители: доктор техн. наук., проф. *Б.Ю. Лемешко*,  
канд. техн. наук, доц. *С.Н. Постовалов*,  
канд. техн. наук, доц. *Е.В. Чимитова*

Работа подготовлена на кафедре  
прикладной математики

## Содержание

ВВЕДЕНИЕ.....	4
Лабораторная работа № 1. Исследование распределений статистик критериев проверки однородности выборок .....	5
Лабораторная работа № 2 Исследование распределений статистик критериев проверки гипотез о математических ожиданиях и дисперсиях.....	8
Лабораторная работа № 3 Исследование распределений статистик критериев проверки однородности средних.....	11
Лабораторная работа № 4. Исследование распределений статистик критериев проверки однородности дисперсий .....	15
Лабораторная работа № 5. Исследование статистик корреляционного анализа .....	18
Приложение 1. Законы распределения наблюдаемых случайных величин, с которыми проверяются гипотезы о согласии .....	26

## ВВЕДЕНИЕ

В лабораторных работах по компьютерным технологиям анализа данных и исследования статистических закономерностей применяется методика компьютерного моделирования фундаментальных статистических закономерностей. В основе методики лежит использование метода Монте-Карло для моделирования эмпирических распределений некоторых функций от случайных величин. Преимуществом метода Монте-Карло является несложность реализации процедур моделирования сложных статистических закономерностей, обычно не поддающихся определению аналитическими методами.

Выполнение работ носит исследовательский характер и в большинстве случаев опирается на разработанное программное обеспечение.

При выполнении лабораторных работ необходимо учитывать точность полученных результатов. Поскольку в большинстве работ требуется сравнивать эмпирические распределения, то малые объемы моделируемых выборок статистик или оценок могут нивелировать разницу в статистических методах, а иногда и давать некорректные (противоположные аналитическим выводам) результаты.

Согласие эмпирических распределений с теоретическими следует проверять, опираясь на статистические критерии, так как сравнение графиков распределений "на глаз" является субъективной процедурой и не учитывает возможной статистической погрешности, которая зависит от объемов выборок.

Отчет по лабораторной работе должен содержать цель, задание на выполнение, результаты исследований в соответствии с заданием, необходимые таблицы, графики, иллюстрирующие результаты, анализ результатов, общие выводы по работе.

Основной теоретический материал, необходимый для выполнения работ, изложен в учебном пособии [1], дополнительные материалы и программное обеспечение размещены на персональных сайтах авторов <http://ami.nstu.ru/~headrd> и <http://postovalov.net>.

## Лабораторная работа № 1. Исследование распределений статистик критериев проверки однородности выборок

**Цель работы.** Исследовать распределения статистик критериев однородности Смирнова и Лемана-Розенблатта. Исследовать и проанализировать мощность критериев.

### Методические указания

Задача проверки однородности двух выборок формулируется следующим образом.

Пусть имеется две упорядоченные по возрастанию выборки размера  $m$  и  $n$ :

$$x_1 < x_2 < \dots < x_m \text{ и } y_1 < y_2 < \dots < y_n.$$

Для определенности обычно полагают, что  $m \leq n$ . Проверяется гипотеза о том, что две выборки извлечены из одной и той же генеральной совокупности, т.е.  $H_0: F(x) = G(x)$  при любом  $x$ .

**1. Критерий однородности Смирнова.** Предполагается, что функции распределения  $F(x)$  и  $G(x)$  являются непрерывными. Статистика критерия Смирнова измеряет различие между эмпирическими функциями распределения, построенными по выборкам

$$D_{m,n} = \sup_x |G_m(x) - F_n(x)|.$$

При практическом использовании критерия значение статистики  $D_{m,n}$  рекомендуется вычислять в соответствии с соотношениями

$$D_{m,n}^+ = \max_{1 \leq r \leq m} \left[ \frac{r}{m} - F_n(x_r) \right] = \max_{1 \leq s \leq n} \left[ G_m(y_s) - \frac{s-1}{n} \right],$$

$$D_{m,n}^- = \max_{1 \leq r \leq m} \left[ F_n(x_r) - \frac{r-1}{m} \right] = \max_{1 \leq s \leq n} \left[ \frac{s}{n} - G_m(y_s) \right],$$

$$D_{m,n} = \max(D_{m,n}^+, D_{m,n}^-).$$

Если гипотеза  $H_0$  справедлива, то при неограниченном увеличении объемов выборок

$$\lim_{m \rightarrow \infty} P \left\{ \sqrt{\frac{mn}{m+n}} D_{m,n} < s \right\} = K(s), \text{ т.е. статистика}$$

$$S_C = \sqrt{\frac{mn}{m+n}} D_{m,n} \quad (12.1)$$

в пределе подчиняется распределению Колмогорова  $K(s)$ .

**2. Критерий однородности Лемана-Розенблатта.** Критерий однородности Лемана-Розенблатта представляет собой критерий типа  $\omega^2$ . Критерий был предложен в работе Леманом (Lehmann E.L.) и подробно исследован в розенблаттом (Rosenblatt M.). Статистика критерия имеет вид

$$T = \frac{mn}{m+n} \int_{-\infty}^{\infty} [G_m(x) - F_n(x)]^2 dH_{m+n}(x),$$

где  $H_{m+n}(x) = \frac{m}{m+n} G_m(x) + \frac{n}{m+n} F_n(x)$  – эмпирическая функция распределения,

построенная по вариационному ряду объединения двух выборок. Как правило, статистика  $T$  используется в форме

$$T = \frac{1}{mn(m+n)} \left[ n \sum_{i=1}^n (r_i - i)^2 + m \sum_{j=1}^m (s_j - j)^2 \right] - \frac{4mn-1}{6(m+n)}, \quad (12.2)$$

где  $r_i$  – порядковый номер (ранг)  $y_i$ ,  $s_j$  – порядковый номер (ранг)  $x_j$  в объединенном вариационном ряду.

Розенблаттом было показано, что статистика (2) в пределе распределена как  $a1(t)$ :

$$\lim_{\substack{m \rightarrow \infty \\ n \rightarrow \infty}} P\{T < t\} = a1(t).$$

Это то же распределение, которому подчинена статистика критерия согласия  $\omega^2$  Крамера-Мизеса-Смирнова при проверке простых гипотез.

В отличие от статистики критерия Смирнова распределение статистики  $T$  быстро сходится к предельному закону  $a1(T)$ .

Более подробная информация доступна по адресу:

[http://www.ami.nstu.ru/~headrd/seminar/publik\\_html/Izm\\_T\\_8.htm](http://www.ami.nstu.ru/~headrd/seminar/publik_html/Izm_T_8.htm)

### Порядок выполнения

Используя программу ISW 4.0, исследовать распределения статистик критериев проверки однородности Смирнова и Лемана-Розенблатта.

- Исследовать сходимость к предельным распределениям, для чего смоделировать распределения статистик критериев при различных объемах выборок ( $n_i = 10, 20, 50, 100$ ) [ $H_0: F(x) = G(x) = F(x, \theta)$ ] при  $m_i = n_i$ . Объем выборок статистик 5000-10000 наблюдений. Оценить близость к предельным распределениям визуально (по графикам) и по критериям согласия. Провести данные исследования отдельно для критерия Смирнова и критерия Лемана-Розенблатта. Для критерия Смирнова исследовать влияние на распределение статистики выбора различных объемов выборок  $m_i \neq n_i$ .
- Оценить мощность критериев относительно заданной альтернативы [ $H_1: F(x) = F(x, \theta); G(x) = F_1(x, \theta)$ ] при различных объемах выборок.

### Варианты заданий.

№	$F(x, \theta)$	$F_1(x, \theta_1)$
1	Нормальное (0, 1)	Экспоненциальное семейство с параметром формы (3)
2	Нормальное (0, 2)	Коши (0,1)
3	Нормальное (0, 1)	Экспоненциальное семейство с параметром формы (1)
4	Экспоненциальное (0, 1)	Гамма-распределение с параметром формы (2)

5	Нормальное (0, 1)	Su-Джонсона (0, 1)
6	Экспоненциальное (0, 1)	Вейбулла (2,1)
7	Логистическое (0, 1)	Нормальное (0,2)
8	Нормальное (0, 1)	Экспоненциальное семейство с параметром формы (5)
9	Логарифмически нормальное (0,1)	Вейбулла (2)

### Контрольные вопросы

1. В чем отличие критериев однородности от критериев однородности средних и однородности дисперсий?
2. Какие недостатки можно отметить в критерии Смирнова и как устранить влияние негативных факторов?
3. Можно ли однозначно отдать предпочтение некоторому критерию однородности?

## Лабораторная работа № 2 Исследование распределений статистик критериев проверки гипотез о математических ожиданиях и дисперсиях

**Цель работы.** Исследовать, что происходит с распределениями классических статистик, используемых в критериях проверки гипотез о математических ожиданиях и дисперсиях, если наблюдаемый закон в той или иной мере отличается от нормального. Проверить, насколько будут корректны статистические выводы, базирующиеся на классических результатах, если нарушено предположение о нормальности.

### Методические указания

#### Классические критерии проверки гипотез о математических ожиданиях и дисперсиях.

Пусть мы имеем выборку  $n$  случайных величин, распределенных по нормальному закону  $x_1, \dots, x_n \in N(\mu_{уст}, \sigma_{уст}^2)$ . В этом случае задачи проверки гипотез о математических ожиданиях и дисперсиях формулируются следующим образом.

1. В критерии проверки гипотез вида  $H_0: \mu = \mu_0$  при известной дисперсии  $\sigma_{уст}^2$  используется статистика  $T_1 = \frac{1}{n} \sum_{i=1}^n x_i$ , которая при справедливости гипотезы  $H_0$

подчиняется нормальному распределению:  $G(T_1 | H_0) = N\left(\mu_0, \frac{\sigma_{уст}^2}{n}\right)$ . Проверяемая

гипотеза  $H_0$  отклоняется при больших отклонениях  $T_1$  от  $\mu_0$ .

2. Для проверки гипотезы  $H_0: \mu = \mu_0$  при неизвестной дисперсии  $\sigma_{уст}^2$  используется статистика  $T_2 = \frac{\bar{x} - \mu_0}{\bar{\sigma}} \sqrt{n}$ , где  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ ,  $\bar{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$ . При

справедливости  $H_0$  статистика  $T_2$  распределена как  $G(T_2 | H_0) = t_{n-1}$  – распределение Стьюдента.

3. Для проверки гипотезы вида  $H_0: \sigma^2 = \sigma_0^2$  при известном математическом ожидании  $\mu_{уст}$  вычисляется статистика  $T_3 = \frac{1}{\sigma_0^2} \sum_{i=1}^n x(\xi_i - \mu_{уст})^2$ , условным

распределением которой является  $G(T_3 | H_0) = \chi_n^2$  – распределение.

4. В критерии проверки гипотезы вида  $H_0: \sigma^2 = \sigma_0^2$  при неизвестном математическом ожидании  $\mu_{уст}$  используется статистика  $T_4 = \frac{1}{\sigma_0^2} \sum_{i=1}^n (x_i - \bar{x})^2$ ,

подчиняющаяся  $G(T_4 | H_0) = \chi_{n-1}^2$  – распределению.

Более подробная информация доступна по адресу:

[http://www.ami.nstu.ru/~headrd/seminar/publik\\_html/Izm\\_T\\_3.htm](http://www.ami.nstu.ru/~headrd/seminar/publik_html/Izm_T_3.htm)

### Порядок выполнения.



В процессе выполнения работы использовать программу **isw.exe**.

3. Исследовать распределения статистик  $T_1, T_2, T_3, T_4$  в условиях принадлежности наблюдений нормальному закону с заданными параметрами при некотором объеме выборок  $n$ . Объем выборок статистик  $N$  задавать порядка 5000-10000. Убедиться в близости полученных распределений статистик теоретическим законам визуально. Проверить согласие полученных эмпирических распределений статистик с соответствующими теоретическими, для чего использовать все доступные критерии согласия.
4. Исследовать (оценить) мощность критериев относительно заданных конкурирующих гипотез ( $H_1: \mu = \mu_0 + \delta\mu, H_1: \sigma^2 = (\sigma_0 + \delta\sigma)^2$ ) и заданного  $n$  в случае нормального закона.
5. Исследовать влияние отклонения наблюдаемого закона от нормального на распределения статистик  $T_1, T_2$ . Для этого смоделировать распределения статистик: при различных симметричных законах наблюдаемых случайных величин с различной “тяжестью хвостов распределений”; при асимметричных законах. Определить, какие отклонения от нормального закона не приводят к заметным изменениям распределений статистик, в каких случаях заметно изменение в распределениях, какие отклонения приводят к существенным изменениям распределений статистик  $T_1, T_2$ ?
6. Провести аналогичные исследования распределений статистик  $T_3, T_4$ , убедиться в существенной зависимости распределений статистик от наблюдаемого закона.

#### Варианты заданий.

№	$F(x, \theta)$	$F_1(x, \theta_1)$
1	Нормальное (0, 1)	Экспоненциальное семейство с параметром формы (1)
2	Нормальное (0.1, 1)	Экспоненциальное семейство с параметром формы (3)
3	Нормальное (0.1, 2)	Экспоненциальное семейство с параметром формы (5)
4	Нормальное (0.5, 1)	Коши (0,1)
5	Нормальное (0.5, 2)	Экспоненциальное семейство с параметром формы (0.5)
6	Нормальное (0, 1.5)	Экспоненциальное семейство с параметром формы (0.2)
7	Нормальное (0, 2)	Гамма-распределение с параметром формы (2)
8	Нормальное (0, 3)	Распределение минимального значения
9	Экспоненциальное (0, 1)	Распределение максимального значения
10	Нормальное (1, 3)	Показательное распределение

#### Контрольные вопросы

1. Виды статистик, используемых в классических критериях проверки гипотез о математических ожиданиях и дисперсиях?
2. При каких видах нарушений исходных предположений применение классических критериев проверки гипотез о математических ожиданиях остается корректным?
3. Варианты действий в ситуации, когда применение классических критериев проверки гипотез о математических ожиданиях невозможно?

4. Варианты действий в случае проверки гипотез о дисперсиях и нарушении предположений о нормальности наблюдаемого закон

### Лабораторная работа № 3 Исследование распределений статистик критериев проверки однородности средних.

**Цель работы.** Исследовать распределения статистик параметрических и непараметрических критериев, используемых для проверки гипотез об однородности средних.

#### 1.

##### Методические указания

Проверяемая гипотеза о равенстве математических ожиданий (об однородности математических ожиданий) случайных величин, соответствующих двум выборкам, задается в виде

$$H_0 : \mu_1 = \mu_2 ,$$

а конкурирующая –

$$H_1 : \mu_1 \neq \mu_2$$

В общем случае, гипотеза о равенстве математических ожиданий имеет вид

$$H_0 : \mu_1 = \mu_2 = \dots = \mu_m$$

при конкурирующей

$$H_1 : \mu_{i_1} \neq \mu_{i_2} .$$

Для проверки гипотезы  $H_0$  может использоваться целый ряд критериев. Условием применения параметрических критериев является принадлежность наблюдений нормальному закону. К ним, например, относятся: критерий сравнения двух выборочных средних при известных дисперсиях; сравнения двух выборочных средних при неизвестных, но равных дисперсиях (критерий Стьюдента); сравнения двух выборочных средних при неизвестных и неравных дисперсиях (проблема Беренса-Фишера). Для этих же целей предназначена целая совокупность непараметрических критериев:  $U$  –критерий Уилкоксона, критерий Манна–Уитни,  $H$  –критерий Краскела–Уаллиса.

**1. Сравнение двух выборочных средних при известных дисперсиях.** Применение критерия сравнения двух выборочных средних (по двум выборкам) при известных и равных дисперсиях предусматривает вычисление статистики

$$z = \frac{\bar{x}_1 - \bar{x}_2 - \mu_1 + \mu_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} , \quad (14.1)$$

где  $\bar{x}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} x_j$ ,  $n_i$  - объем  $i$ -й выборки,  $i = 1, 2$ . В случае принадлежности наблюдений

нормальным законам статистика  $z$  подчиняется стандартному нормальному закону.

**2. Сравнение двух выборочных средних при неизвестных, но равных дисперсиях.** Применение критерия сравнения двух выборочных средних при неизвестных, но равных дисперсиях предусматривает вычисление статистики  $t$ :

$$t = \frac{|\bar{x}_1 - \bar{x}_2|}{\sqrt{\left[ \frac{n_1 + n_2}{n_1 n_2} \right] \left[ \frac{Q_1 + Q_2}{n_1 + n_2 - 2} \right]}} , \quad (14.2)$$

где  $n_i$  – объем  $i$ -й выборки,

$$Q_i = \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2, \quad \bar{x}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} x_{ij}.$$

В случае принадлежности выборок нормальному закону эта статистика при справедливости гипотезы  $H_0$  подчиняется распределению Стьюдента с числом степеней свободы  $\nu = n_1 + n_2 - 2$ .

**3. Сравнение двух выборочных средних при неизвестных и неравных дисперсиях.** При неравных объемах выборок  $n_1 \neq n_2$  статистика критерия имеет вид:

$$t = \frac{|\bar{x}_1 - \bar{x}_2|}{\sqrt{\left[ \frac{s_1^2}{n_1} + \frac{s_2^2}{n_2} \right]}}, \quad (14.3)$$

где  $n_i$  – объем  $i$ -й выборки,  $s_i = \frac{1}{n_i - 1} \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2$ ,  $\bar{x}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} x_{ij}$ .

В случае нормального закона и справедливости гипотезы  $H_0$  статистика (14.3) подчиняется распределению Стьюдента с числом степеней свободы

$$\nu = \frac{\left( \frac{s_1^2}{n_1} + \frac{s_2^2}{n_2} \right)^2}{\frac{\left( \frac{s_1^2}{n_1} \right)^2}{n_1 - 1} + \frac{\left( \frac{s_2^2}{n_2} \right)^2}{n_2 - 1}}.$$

При равных объемах выборок  $n_1 = n_2 = n$  –

$$t = \frac{|\bar{x}_1 - \bar{x}_2|}{\sqrt{\left[ \frac{s_1^2 + s_2^2}{n} \right]}},$$

а число степеней свободы распределения Стьюдента –

$$\nu = n - 1 + \frac{2n - 2}{\frac{s_1^2}{s_2^2} + \frac{s_2^2}{s_1^2}}.$$

**4.  $U$  – критерий Уилкоксона, Манна и Уитни.** Ранговый критерий Манна и Уитни основан на критерии Уилкоксона для независимых выборок. Он является непараметрическим аналогом  $t$ -критерия для сравнения двух средних значений непрерывных распределений. Для вычисления статистики упорядочивают  $m + n$  значений объединенной выборки, определяют сумму рангов  $R_1$ , соответствующую элементам первой выборки, и сумму рангов второй  $R_2$ . Вычисляются

$$U_1 = mn + \frac{m(m-1)}{2} - R_1,$$

$$U_2 = mn + \frac{n(n-1)}{2} - R_2.$$

Статистика критерия имеет вид:  $U = \min\{U_1, U_2\}$ .

Для достаточно больших выборок ( $m + n > 60$ ), когда объемы выборок не слишком малы ( $m \geq 8, n \geq 8$ ) используется статистика

$$\tilde{z} = \frac{\left| U - \frac{mn}{2} \right|}{\sqrt{\frac{mn(m+n+1)}{12}}}, \quad (14.4)$$

которая приближенно распределена в соответствии со стандартным нормальным законом.

**5.  $H$  – критерий Краскела–Уаллиса.**  $H$  – критерий Краскела–Уаллиса является развитием  $U$  – критерия для проверки гипотезы (о равенстве средних) по  $k$  выборкам. Объединенную

выборку  $n = \sum_{i=1}^k n_i$  упорядочивают и вычисляют суммы рангов  $R_i$  для  $i$ -й выборки,

$i = \overline{1, k}$ . Статистика для проверки гипотезы  $H_0$  имеет вид

$$H = \left[ \frac{12}{n(n+1)} \right] \left[ \sum_{i=1}^k \frac{R_i^2}{n_i} \right] - 3(n-1). \quad (14.5).$$

$H$  представляет собой дисперсию ранговых сумм. При больших  $n_i$  и  $k$  (практически  $n_i \geq 5, k \geq 4$ ) при справедливости гипотезы  $H_0$  статистика подчиняется  $\chi_{k-1}^2$ -распределению.

### Порядок выполнения.

В процессе выполнения работы использовать программу **isw.exe**.

1. По указанию преподавателя исследовать распределения статистик (14.1), (14.2) или (14.3) в условиях принадлежности наблюдений нормальным законам с заданными параметрами при некоторых объемах выборок. Убедиться в близости полученных распределений статистик соответствующим теоретическим законам визуально. Проверить согласие полученных эмпирических распределений статистик с соответствующими теоретическими, для чего использовать все доступные критерии согласия.
2. Исследовать влияние нарушений предположения о нормальности наблюдаемых законов на распределение исследуемой статистики. Для этого смоделировать распределение статистики при тех же объемах выборок: при различных симметричных законах наблюдаемых случайных величин с различной “тяжестью хвостов распределений”; при асимметричных законах. Определить, какие отклонения от нормального закона не приводят к заметным изменениям распределений статистики, в каких случаях заметно изменение в распределении, какие отклонения приводят к существенным изменениям распределения статистики?
3. Исследовать (оценить) мощность соответствующего критерия относительно заданных конкурирующих гипотез и заданных объемов выборок в случае нормального закона. Для расчета значений мощности критериев рассмотреть одну из конкурирующих гипотез, для которой величина математического ожидания одной из выборок отличается на величину  $w_i \cdot \sigma$ , где  $w_1 = 0.1, w_2 = 0.2, w_3 = 0.3, w_4 = 0.4, w_5 = 0.5$  (выбор  $w_i$  по заданию преподавателя).

4. Исследовать сходимость распределения статистики (14.4) критерия Манна-Уитни к стандартному нормальному закону с ростом объемов выборок. Убедиться, что распределения статистики (14.4) не зависят от вида закона, из которого извлекаются выборки.
5. Исследовать сходимость распределения статистики (14.5) критерия к соответствующему  $\chi^2_{k-1}$ -распределению в зависимости от объемов выборок. Проверить, что критерий Краскела–Уаллиса действительно является непараметрическим, и распределения статистики (5) не зависят от вида закона, из которого извлекаются выборки.
6. Для тех же конкурирующих гипотез и объемов выборок (см. п.3) оценить мощность критериев Манна-Уитни и Краскела–Уаллиса.

#### Варианты для выбора законов.

№	$F(x, \theta)$	$F_1(x, \theta_1)$
1	Нормальное (0, 1)	Экспоненциальное семейство с параметром формы (1)
2	Нормальное (0.1, 1)	Экспоненциальное семейство с параметром формы (3)
3	Нормальное (0.1, 2)	Экспоненциальное семейство с параметром формы (5)
4	Нормальное (0.5, 1)	Коши (0,1)
5	Нормальное (0.5, 2)	Экспоненциальное семейство с параметром формы (0.5)
6	Нормальное (0, 1.5)	Экспоненциальное семейство с параметром формы (0.2)
7	Нормальное (0, 2)	Гамма-распределение с параметром формы (2)
8	Нормальное (0, 3)	Распределение минимального значения
9	Экспоненциальное (0, 1)	Распределение максимального значения
10	Нормальное (1, 3)	Показательное распределение

#### Контрольные вопросы

1. Виды статистик, используемых в классических (параметрических) критериях проверки гипотез об однородности математических ожиданий?
2. При каких видах нарушений исходных предположений применение классических (параметрических) критериев проверки гипотез об однородности математических ожиданий остается корректным?
3. Что можно предпринять в ситуации, когда применение классических критериев проверки гипотез об однородности математических ожиданий невозможно?

## Лабораторная работа № 4. Исследование распределений статистик критериев проверки однородности дисперсий

**Цель работы.** Исследовать распределения статистик критериев, используемых для проверки гипотез об однородности дисперсий.

### Методические указания

Проверяемая гипотеза о постоянстве дисперсии  $m$  выборок имеет вид:

$$H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_m^2.$$

а конкурирующая с ней гипотеза –

$$H_1 : \sigma_{i_1}^2 \neq \sigma_{i_2}^2,$$

где неравенство выполняется, по крайней мере, для одной пары индексов  $i_1, i_2$ . Для проверки такого вида гипотез применяются критерии Бартлетта и Кокрена.

**1. Критерий Бартлетта.** Статистика критерия Бартлетта вычисляется в соответствии с соотношением:

$$\chi^2 = M \left[ 1 + \frac{1}{3(m-1)} \left( \sum_{i=1}^m \frac{1}{v_i} - \frac{1}{N} \right) \right]^{-1} \quad (15.1)$$

где  $n_i$  – объемы выборок,  $v_i = n_i$ , если математическое ожидание известно, и  $v_i = n_i - 1$ ,

если неизвестно,  $N = \sum_{i=1}^m v_i$ ,

$$M = N \ln \left( \frac{1}{N} \sum_{i=1}^m v_i S_i^2 \right) - \sum_{i=1}^m v_i \ln S_i^2,$$

$S_i^2$  – оценки выборочных дисперсий. При неизвестном математическом ожидании оценки

$$S_i^2 = \frac{1}{n_i - 1} \sum_{j=1}^{n_i} (X_{ji} - \bar{X}_i)^2, \text{ где } \bar{X}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} X_{ji} \text{ и } v_i = n_i - 1. \text{ Если гипотеза } H_0$$

верна, все  $v_i > 3$  и выборки извлекаются из нормальной генеральной совокупности, то статистика (1) приближенно подчиняется  $\chi_{m-1}^2$ -распределению.

**2. Критерий Кокрена.** Когда все  $n_i$  одинаковы,  $n_1 = n_2 = \dots = n_m = n$ , возможно использование более простого критерия Кокрена. Статистика  $Q$  критерия Кокрена выражается формулой

$$Q = \frac{S_{\max}^2}{S_1^2 + S_2^2 + \dots + S_m^2}, \quad (15.2)$$

где  $S_{\max}^2 = \max(S_1^2, S_2^2, \dots, S_m^2)$ , где  $m$  – число независимых оценок дисперсий (число выборок).

Распределения статистики Кокрена сильно зависят от объема наблюдаемых выборок. Поэтому в справочной литературе приводятся только таблицы процентных точек, которые и используются при проверке гипотез.

**3. Критерий Фишера для сравнения двух выборочных дисперсий из нормальных совокупностей.** Для определения того, относятся ли две выборки к одной и той же

генеральной совокупности, проверяется гипотеза вида  $H_0 : \sigma_1^2 = \sigma_2^2$ . Статистика для проверки гипотезы имеет вид

$$F = \frac{s_1^2}{s_2^2}. \quad (15.3)$$

В случае принадлежности выборок нормальному закону и справедливости  $H_0$  эта статистика подчиняется  $F_{v_1, v_2}$ -распределению Фишера с числом степеней свободы  $v_1 = n_1 - 1$  и  $v_2 = n_2 - 1$ .

**4. Проверка равенства нескольких дисперсий для выборок равного объема по Хартли.** Статистика для проверки гипотезы имеет вид

$$F = \frac{s_{\max}^2}{s_{\min}^2}. \quad (15.4)$$

Степенями свободы для распределения статистики являются число выборок  $v_1 = m$  и  $v_2 = n - 1$ . В литературе приводятся таблицы процентных точек для статистики (3).

**5. Критерий Левене об однородности дисперсий.** Считается, что критерий Левене менее чувствителен к отклонениям от нормальности, чем критерий Бартлетта.

Пусть  $n_i$  – объем  $i$ -й выборки,  $N = \sum_{i=1}^m n_i$ ,  $X_{ij}$  –  $j$ -е наблюдение в  $i$ -й выборке.

Статистика критерия Левене имеет вид:

$$W = \frac{N - m \sum_{i=1}^m n_i (\bar{Z}_{i\bullet} - \bar{Z}_{\bullet\bullet})^2}{m - 1 \sum_{i=1}^m \sum_{j=1}^{n_i} (Z_{ij} - \bar{Z}_{i\bullet})^2}, \quad (15.5)$$

где  $Z_{ij}$  определяется соотношением  $Z_{ij} = |X_{ij} - \bar{X}_{i\bullet}|$ , в котором  $\bar{X}_{i\bullet}$  – есть среднее в  $i$ -й выборке.  $\bar{Z}_{i\bullet}$  – есть среднее  $Z_{ij}$  по  $i$ -й выборке,  $\bar{Z}_{\bullet\bullet}$  – есть среднее  $Z_{ij}$  по всем выборкам.

В случае принадлежности выборок нормальному закону и справедливости  $H_0$  эта статистика подчиняется  $F_{v_1, v_2}$ -распределению Фишера с числом степеней свободы  $v_1 = m - 1$  и  $v_2 = N - m$ .

В оригинальном критерии Левене предусмотрено использование только выборочных средних. В ISW возможно исследование данного случая. Brown и Forsythe расширили критерий Левене на случай использования выборочных медиан и усеченного среднего ( $Z_{ij} = |X_{ij} - \tilde{X}_{i\bullet}|$ , где  $\tilde{X}_{i\bullet}$  – есть медиана в  $i$ -й выборке;  $Z_{ij} = |X_{ij} - \bar{X}'_{i\bullet}|$  где  $\bar{X}'_{i\bullet}$  – есть усеченное среднее в  $i$ -й выборке). В этих случаях критерий становится устойчивей нарушению предположений о нормальности, однако, надо полагать, распределение статистики должно отличаться от  $F_{v_1, v_2}$ -распределения.

**Порядок выполнения.**

В процессе выполнения работы использовать программу **isw.exe**.



1. Исследовать сходимость распределений статистики (15.1) критерия Бартлетта к предельному  $\chi_{m-1}^2$ -распределению в зависимости от объемов выборок.
2. Исследовать влияние нарушений предположения о нормальности наблюдаемых законов на распределение статистики критерия Бартлетта. Для этого смоделировать распределение статистики при тех же объемах выборок: при различных симметричных законах наблюдаемых случайных величин с различной “тяжестью хвостов распределений”; при асимметричных законах.
3. Исследовать (оценить) мощность критерия Бартлетта относительно заданных конкурирующих гипотез и заданных объемов выборок в случае нормального закона. Пусть конкурирующая гипотеза предполагает, что одна из выборок, например, выборка с номером  $m$  имеет некоторую другую дисперсию. Остальные  $m - 1$  выборки принадлежат нормальному закону с  $\sigma = \sigma_0$  ( $H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_m^2 = \sigma_0^2$ ). Для расчета значений мощности критерия рассмотреть одну из следующих конкурирующих гипотез:  $H_1^1: \sigma_m = 1.05\sigma_0$ ;  $H_1^2: \sigma_m = 1.1\sigma_0$  и  $H_1^3: \sigma_m = 1.2\sigma_0$  (выбор по заданию преподавателя).
4. Исследовать распределения статистики (15.2) критерия Кокрена в зависимости от объемов выборок при извлечении выборок из нормальной совокупности.
5. Аналогично п.2 исследовать распределения статистики (15.2) критерия Кокрена.
6. Для тех же конкурирующих гипотез и объемов выборок (см. п.3) оценить мощность критерия Кокрена.
7. Исследовать распределения и устойчивость критерия Фишера со статистикой (15.3).
8. Исследовать распределения и устойчивость критерия Хартли со статистикой (15.4).
9. Исследовать распределения и устойчивость критерия Левене со статистикой (15.5).

**Содержание отчета.** Цель работы, графики (наиболее наглядно характеризующие поведение распределений статистик), результаты статистического анализа распределений, оценки мощности (таблицы), выводы.

### Варианты заданий

№	$F(x, \theta)$	$F_1(x, \theta_1)$
1	Нормальное (0, 1)	Экспоненциальное семейство с параметром формы (1)
2	Нормальное (0.1, 1)	Экспоненциальное семейство с параметром формы (3)
3	Нормальное (0.1, 2)	Экспоненциальное семейство с параметром формы (5)
4	Нормальное (0.5, 1)	Коши (0,1)
5	Нормальное (0.5, 2)	Экспоненциальное семейство с параметром формы (0.5)
6	Нормальное (0, 1.5)	Экспоненциальное семейство с параметром формы (0.2)
7	Нормальное (0, 2)	Гамма-распределение с параметром формы (2)
8	Нормальное (0, 3)	Распределение минимального значения
9	Экспоненциальное (0, 1)	Распределение максимального значения
10	Нормальное (1, 3)	Показательное распределение

### Контрольные вопросы

1. Виды статистик, используемых в критериях проверки гипотез об однородности дисперсий?
2. Распределения статистик каких критериев проверки гипотез об однородности дисперсий слабо зависят от объемов выборок?

### Лабораторная работа № 5. Исследование статистик корреляционного анализа

**Цель работы.** Вычисление статистик корреляционного анализа по эмпирическим данным, полученным при моделировании многомерного нормального закона распределения с различными параметрами. Исследование распределений статистик корреляционного анализа с ростом объемов выборок.

#### Методические указания

Введем для дальнейшего использования следующие обозначения:

- $X_1, X_2, \dots, X_n$  – выборка  $m$ -мерного случайного вектора объема  $n$ ;
- $M = [m_i]_{i=1}^m$  – вектор математического ожидания случайного вектора  $X_i$ ;
- $\Sigma = [\sigma_{ij}]_{i,j=1}^m$  – ковариационная матрица случайного вектора  $X_i$ ;
- $\hat{M}$  и  $\hat{\Sigma}$  – оценки максимального правдоподобия (ОМП) для вектора математического ожидания и ковариационной матрицы, вычисляемые по негруппированным данным:

$$\hat{M} = \frac{1}{n} \sum_{i=1}^n X_i \quad \text{и} \quad \hat{\Sigma} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \hat{M})(X_i - \hat{M})^T.$$

В данной работе проведены исследования распределений статистик, связанных с проверкой следующих гипотез.

#### 1. Проверка гипотезы о равенстве математического ожидания некоторому неизвестному вектору

Важной статистической проблемой является проблема проверки гипотезы о том, что вектор среднего значения нормального распределения является данным вектором. Такая задача очень часто возникает на практике, когда, например, на основании наблюдений некоторого технологического процесса желают убедиться, что эти показатели равны номинальному значению, т.е. процесс протекает нормально, а отклонения наблюдаемых значений от номинальных объясняются лишь ошибками наблюдений (измерений). Рассмотрим эту проблему сначала в предположении, что ковариационная матрица известна, а затем – когда неизвестна.

Гипотеза имеет вид  $H_0 : M = M_0$ . И, как ранее отмечалось, здесь возможны две ситуации.

а) В случае, когда нам известна ковариационная матрица  $\Sigma$  (например, из ранее проводимых экспериментов или предположений), то для вывода предельных распределений статистик, используемых при проверке данной гипотезы, в многомерном случае используется факт, что разность между векторами среднего значения выборки и среднего значения генеральной совокупности распределена нормально с вектором математического ожидания, равным нулю, и известной ковариационной матрицей.

В этом случае согласно вычисляется статистика:

$$X_m^2 = n(\hat{M} - M_0)^T \Sigma^{-1}(\hat{M} - M_0). \quad (11.1)$$

При справедливой гипотезе  $H_0$  предельное распределение статистики

$G(X_m^2 | H_0) = \chi_m^2$  - распределение, с числом степеней свободы  $m$ . Таким образом, гипотеза  $H_0$  принимается, если

$$X_m^2 < \chi_{m,\alpha}^2,$$

где  $\alpha$  - уровень значимости и

$$1 - \alpha = P\{X_m^2 > \chi_{m,\alpha}^2\} = \frac{1}{2^{m/2} \Gamma(m/2)} \int_0^{\chi_{m,\alpha}^2} s^{m/2-1} e^{-s/2} ds.$$

б) Другая более важная группа статистических задач связана с вопросами, касающимися оценки математического ожидания многомерного нормального распределения, дисперсия которого неизвестна. Так в одномерном случае используется статистика, являющаяся частным от деления разности между выборочным средним значением и гипотетическим математическим ожиданием генеральной совокупности на среднее квадратичное отклонение. В предложено многомерный аналог данной величины, в которую также вовлечены математическое ожидание и обратная матрица к оценке ковариационной матрицы.

В этом случае согласно используется статистика:

$$T^2 = \frac{n(n-m)}{m(n-1)} (\hat{M} - M_0)^T \hat{\Sigma}^{-1} (\hat{M} - M_0). \quad (11.2)$$

Тогда при справедливости гипотезы  $H_0$  предельное распределение статистики

$G(T^2 | H_0) = F_{m,n-m}$  - распределение Фишера с параметрами  $m$  и  $n-m$ . В данном случае гипотеза  $H_0$  принимается, если выполняется условие

$$T^2 < F_{m,n-m,\alpha}.$$

Величина  $F_{m,n-m,\alpha}$  определяются из равенства

$$1 - \alpha = P\{T^2 > F_{m,n-m,\alpha}\} = \left(\frac{m}{n-m}\right) \frac{\Gamma\left(\frac{n}{2}\right)}{\Gamma\left(\frac{m}{2}\right)\Gamma\left(\frac{n-m}{2}\right)} \int_0^{F_{m,n-m,\alpha}} s^{m/2-1} \left(1 + \frac{m}{n-m}s\right)^{-n/2} ds.$$

## 2. Проверка гипотез о коэффициенте парной корреляции

При анализе совокупности случайных величин нас может интересовать, например, взаимосвязь между несколькими случайными величинами, либо зависимость одной или большего числа величин от остальных. Когда рассматривается взаимосвязь двух величин, то речь идет о парной корреляции. Взаимозависимость же величин при устранении влияния совокупности других – есть частная корреляция, а вот зависимость одной величины от группы величин характеризуется множественной корреляцией.

Под парной корреляцией понимается обычная корреляция между двумя величинами.

Если оценка ковариационной матрицы  $\hat{\Sigma}$  уже известна, то оценка парного коэффициента корреляции может быть найдена в соответствии с выражением

$$\hat{r}_{ij} = \frac{\hat{\sigma}_{ij}}{\sqrt{\hat{\sigma}_{ii}\hat{\sigma}_{jj}}}.$$

Здесь можно решать следующие задачи: определение оценки парного коэффициента корреляции, проверка гипотезы о его значимости (гипотеза вида:  $H_0 : r_{ij} = 0$ ) и проверка

гипотезы о равенстве его определенному значению (гипотеза вида:  $H_0 : r_{ij} = r_0$ ).

Для проверки гипотезы  $H_0 : r_{ij} = 0$  согласно вычисляется статистика:

$$t = \frac{\sqrt{n-2} |\hat{r}_{ij}|}{\sqrt{1-\hat{r}_{ij}^2}}. \quad (11.3)$$

При этом предельное распределение статистики  $G(t | H_0) = t_{n-2}$  - распределение Стьюдента с числом степеней свободы  $n-2$ . При конкурирующей гипотезе  $H_1 : r_{ij} \neq 0$  гипотеза  $H_0$  принимается, если

$$t < t_{n-2, \alpha/2},$$

где  $\alpha$  - уровень значимости. Величина  $t_{n-2, \alpha/2}$  при  $k = n - 2$  определяется равенством

$$1 - \alpha = P\{t < t_{k, \alpha/2}\} = \frac{\Gamma\left(\frac{k+1}{2}\right)}{\sqrt{k\pi}\Gamma\left(\frac{k}{2}\right)} \int_{-t_{k, \alpha/2}}^{t_{k, \alpha/2}} \left(1 + \frac{s^2}{k}\right)^{-\frac{k+1}{2}} ds.$$

Если же гипотеза имеет вид  $H_0 : r_{ij} = r_0$ , то используется статистика:

$$z_0 = \sqrt{n-3} \left( \frac{1}{2} \ln \left( \frac{1 + \hat{r}_{ij}}{1 - \hat{r}_{ij}} \right) - \frac{1}{2} \ln \left( \frac{1 + r_0}{1 - r_0} \right) - \left( \frac{r_0}{2(n-1)} \right) \right). \quad (11.4)$$

При этом предельное распределение статистики  $G(z_0 | H_0) = N_{0,1}$  - стандартное нормальное распределение. Гипотеза  $H_0$  принимается, если

$$z < t_{\alpha/2},$$

где  $t_{\alpha/2}$  - квантиль стандартного нормального распределения и

$$1 - a = P\{t < t_{\alpha/2}\} = \frac{1}{\sqrt{2\pi}} \int_{-t_{\alpha/2}}^{t_{\alpha/2}} e^{-s^2/2} ds.$$

### 3. Проверка гипотез о коэффициенте частной корреляции

В случае двух нормальных или почти нормальных величин коэффициент корреляции между ними может быть использован в качестве меры взаимозависимости. Однако на практике при интерпретации «взаимозависимости» часто встречаются определенные трудности, а именно: если одна величина коррелирована с другой, то это может быть всего лишь отражением того факта, что они обе коррелированы с некоторой третьей величиной или с совокупностью величин. Указанная возможность приводит к рассмотрению условных корреляций между двумя величинами при фиксированных значениях остальных величин. Это так называемые *частные корреляции*.

Если корреляция между двумя величинами уменьшается при фиксировании некоторой другой случайной величины, то это означает, что их взаимозависимость возникает частично через воздействие этой величины; если же частная корреляция равна нулю или очень мала, то делается вывод, что их взаимозависимость целиком обусловлена этим воздействием. Наоборот, когда частная корреляция больше первоначальной корреляции между двумя величинами, то следует, что другие величины ослабляли связь, или, можно сказать, «маскировали» корреляцию. Но нужно помнить, что даже в последнем случае нельзя предполагать наличие причинной связи, так как некоторая, совершенно отличная от рассматриваемых при анализе, величина может быть источником этой корреляции. Как при обычной корреляции, так и при частных корреляциях предположение о причинности должно всегда иметь внестатистические основания.

Представим случайный вектор  $X$  в следующем виде:

$$X = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix},$$

где  $X_1 = (x_1, x_2, \dots, x_l)^T$ ,  $X_2 = (x_{l+1}, x_{l+2}, \dots, x_m)^T$ , соответственно вектор математических ожиданий и ковариационную матрицу

$$M = \begin{bmatrix} M_1 \\ M_2 \end{bmatrix}, \Sigma = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{bmatrix}.$$

Если случайный вектор  $X$  подчиняется нормальному закону с вектором средних  $M$  и ковариационной матрицей  $\Sigma$ , то условное распределение подвектора  $X_1$  при известном  $X_2$  является нормальным с математическим ожиданием  $M_1 + B(X_2 - M_2)$  и ковариационной матрицей  $\Sigma_{11 \bullet 2}$ , где  $B = \Sigma_{12} \Sigma_{22}^{-1}$ ,  $\Sigma_{11 \bullet 2} = \Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21}$ .

ОМП для частного коэффициента корреляции определяется следующим соотношением:

$$\hat{r}_{ij;l+1,\dots,m} = \frac{\hat{\sigma}_{ij;l+1,\dots,m}}{\sqrt{\hat{\sigma}_{ii;l+1,\dots,m} \hat{\sigma}_{jj;l+1,\dots,m}}},$$

где  $\hat{\sigma}_{ij \bullet l+1,\dots,m}$  - элемент  $i$ -й строки и  $j$ -го столбца матрицы  $\Sigma_{11 \bullet 2}$ ,  $l$  - число компонент в условном распределении,  $2 \leq l \leq m$ .

В данном случае при оценке взаимозависимости между компонентами  $x_i$  и  $x_j$  случайной величины  $X$  исключается влияние компонент  $x_{l+1}, x_{l+2}, \dots, x_m$ .

При проверке гипотез вида  $H_0 : r_{ij \bullet l+1,\dots,m} = 0$  и  $H_0 : r_{ij \bullet l+1,\dots,m} = r_0$  используются те же самые статистики, что и для парного коэффициента корреляции. В этом случае в соответствующих соотношениях  $n$  заменяется на  $n - m + l$ .

Для проверки гипотезы  $H_0 : r_{ij;l+1,\dots,m} = 0$  вычисляется статистика:

$$t = \frac{\sqrt{n - m + l - 2} |\hat{r}_{ij \bullet l+1,\dots,m}|}{\sqrt{1 - \hat{r}_{ij \bullet l+1,\dots,m}^2}}. \quad (11.5)$$

При этом предельное распределение статистики  $G(t | H_0) = t_{n-m+l-2}$  - распределение Стьюдента с числом степеней свободы  $n-m+l-2$ .

Если же гипотеза имеет вид  $H_0 : r_{ij;l+1,\dots,m} = r_0$ , тогда используется статистика:

$$z_0 = \sqrt{n-3} \left( \frac{1}{2} \ln \left( \frac{1 + \hat{r}_{ij \bullet l+1,\dots,m}}{1 - \hat{r}_{ij \bullet l+1,\dots,m}} \right) - \frac{1}{2} \ln \left( \frac{1 + r_0}{1 - r_0} \right) - \left( \frac{r_0}{2(n-1)} \right) \right). \quad (11.6)$$

При этом предельное распределение статистики  $G(z_0 | H_0) = N(0,1)$  - стандартное нормальное распределение.

#### 4. Проверка гипотезы о коэффициенте множественной корреляции

Множественный коэффициент корреляции является мерой зависимости компоненты многомерной случайной величины от некоторого множества компонент.

Можно рассматривать корреляцию между одной компонентой случайного вектора и множеством всех остальных или каким-то подмножеством.

Следует отметить, что множественный коэффициент корреляции  $r_i$  случайной величины  $x_i$  относительно некоторого множества других случайных величин всегда не меньше, чем абсолютная величина любого парного коэффициента корреляции  $r_{ij}$  с таким же

первичным индексом. Более того, множественный коэффициент корреляции никогда нельзя уменьшить путем расширения множества величин, относительно которых измеряется зависимость  $x_i$ .

Если коэффициент корреляции между  $x_i$  и множеством всех остальных компонент многомерной случайной величины равен нулю ( $r_i = 0$ ), то все коэффициенты корреляции этой величины относительно любого подмножества также равны 0, т.е. величина  $x_i$  полностью некоррелирована со всеми остальными величинами.

С другой стороны, если  $r_i$  относительно множества всех остальных компонент равен единице  $r_i = 1$ , то, по крайней мере, один из коэффициентов корреляции относительно некоторого подмножества компонент должен быть равен 1.

Надо отметить, что коэффициент корреляции, например, между  $x_l$  и множеством всех остальных компонент является обычным коэффициентом корреляции между  $x_l$  и условным математическим ожиданием  $E[x_l | x_2, x_3, \dots, x_n]$ .

Если представить случайный вектор  $X$  в том виде, как это было показано в разделе частной корреляции, то ОМП множественного коэффициента корреляции между  $x_i$ ,  $i \leq l$  и множеством компонент  $x_{l+1}, x_{l+2}, \dots, x_m$  определяется соотношением

$$\hat{r}_{i;l+1,\dots,m} = \sqrt{\frac{\hat{\sigma}_{(i)} \Sigma_{22}^{-1} \hat{\sigma}_{(i)}^T}{\hat{\sigma}_{ii}}},$$

где:

- $\hat{\sigma}_{(i)}$  -  $i$ -ая строка матрицы  $\Sigma_{12}$ ,
- $\hat{\sigma}_{ii}$  - элемент матрицы  $\Sigma_{11}$ .

Для гипотезы  $H_0 : r_{i \bullet l+1, \dots, m} = 0$ , согласно вычисляется статистика:

$$F = \frac{n - m + l - 1}{m - l} \frac{\hat{r}_{i \bullet l+1, \dots, m}^2}{1 - \hat{r}_{i \bullet l+1, \dots, m}^2}. \quad (11.7)$$

При этом предельное распределение статистики  $G(F | H_0) = F_{m-l, n-m+l-1}$  - распределение Фишера с параметрами  $m-l$  и  $n-m+l-1$ . Гипотеза  $H_0$  принимается, если

$$F < F_{m-l, n-m+l-1, \alpha},$$

где  $\alpha$  - уровень значимости, а  $F_{m-l, n-m+l-1, \alpha}$  - критическая точка критерия с уровнем значимости  $\alpha$ .

### Порядок выполнения.

1. Вычислить, если это необходимо, значения для коэффициентов корреляции.

Используя программу **STAR System.exe**:

2. Смоделировать выборки статистик корреляционного анализа по предложенным параметрам и гипотезам, соответствующим варианту задания, с сохранением в файл. Исследовать влияние различных значений объемов выборок многомерной случайной величины на значения критериев согласия. Определить какие статистики корреляционного анализа зависят от объемов выборок многомерной случайной величины.

3. Построить графики эмпирических функций распределения смоделированных выборок статистик корреляционного анализа и их теоретических распределений.

4. На основании полученных результатов сделать выводы о распределениях статистик корреляционного анализа.

## Варианты заданий

### Наборы параметров для моделирования

Перечислим используемые параметры для моделирования законов распределения:

$$M = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}, \Sigma = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (P1)$$

$$M = \begin{bmatrix} 1 \\ 2 \\ 3 \end{bmatrix}, \Sigma = \begin{bmatrix} 5 & 1 & 2,5 \\ 1 & 6 & 1 \\ 2,5 & 1 & 5 \end{bmatrix} \quad (P2)$$

$$M = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}, \Sigma = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0,5 \\ 0 & 0,5 & 1 \end{bmatrix} \quad (P3)$$

$$M = \begin{bmatrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \end{bmatrix}, \Sigma = \begin{bmatrix} 10 & 2 & 1 & 0,5 & 0,3 \\ 2 & 10 & 2 & 1 & 0,5 \\ 1 & 2 & 10 & 2 & 1 \\ 0,5 & 1 & 2 & 10 & 2 \\ 0,3 & 0,5 & 1 & 2 & 10 \end{bmatrix} \quad (P4)$$

### Гипотезы корреляционного анализа

1. О равенстве МО некоторому известному вектору при известной ковариационной матрице.
2. О равенстве МО некоторому известному вектору при неизвестной ковариационной матрице.
3. О нулевом парном коэффициенте корреляции.
4. О парном коэффициенте корреляции, которой равен заданному значению.
5. О нулевом частном коэффициенте корреляции.
6. О частном коэффициенте корреляции, которой равен заданному значению.
7. О нулевом множественном коэффициенте корреляции.

№ варианта	Параметры моделирования	Гипотезы	Индексы коэффициентов корреляции
1.	(P4)	1, 2	
2.	(P2), (P3)	3 с параметрами (3), 4 с параметрами (2)	$R_{1,2}$
3.	(P2), (P3)	5 с параметрами (3), 6 с параметрами (2)	$R_{1,2}$ для 5, $R_{1,2}$ для 6
4.	(P3)	5, 7	$R_{1,2}$
5.	(P1), (P4)	1, 2	

### Контрольные вопросы

1. Какие предельные распределения используются при проверке гипотез о векторе математического ожидания и как осуществляется проверка гипотезы?

2. Какие предельные распределения используются при проверке гипотез о парном коэффициенте корреляции и как осуществляется проверка гипотезы?
3. Какие предельные распределения используются при проверке гипотез о частном коэффициенте корреляции и как осуществляется проверка гипотезы?
4. Какое предельное распределение используются при проверке гипотезы о множественном коэффициенте корреляции и как осуществляется проверка гипотезы?



### Список литературы

1. Лемешко Б.Ю., Постовалов С.Н. [Компьютерные технологии анализа данных и исследования статистических закономерностей: Учебное пособие. – Новосибирск: Изд-во НГТУ, 2004. – 119 с.](#)
2. Статистический анализ данных, моделирование и исследование вероятностных закономерностей. Компьютерный подход : монография / Б.Ю. Лемешко, С.Б. Лемешко, С.Н. Постовалов, Е.В. Чимитова. – Новосибирск : Изд-во НГТУ, 2011. – 888 с. (серия "Монографии НГТУ").

**Приложение 1. Законы распределения случайных величин**

№ п/п	Распределение случайной величины	Функция плотности
1.	Лапласа	$\frac{\theta_0}{2} e^{-\theta_0 x-\theta_1 }$
2.	Нормальное	$\frac{1}{\theta_0\sqrt{2\pi}} e^{-(x-\theta_1)^2/2\theta_0^2}$
3.	Логнормальное	$\frac{1}{x\theta_0\sqrt{2\pi}} e^{-(\ln x - \theta_1)^2/2\theta_0^2}$
4.	Логистическое	$\frac{\pi}{\theta_0\sqrt{3}} \exp\left\{-\frac{\pi(x-\theta_1)}{\theta_0\sqrt{3}}\right\} / \left[1 + \exp\left\{-\frac{\pi(x-\theta_1)}{\theta_0\sqrt{3}}\right\}\right]^2$
5.	Вейбулла- Гнеденко	$\frac{\theta_0 x^{\theta_0-1}}{\theta_1^{\theta_0}} \exp\left\{-\left(\frac{x}{\theta_1}\right)^{\theta_0}\right\}$

