

Министерство образования Республики Беларусь  
Учреждение образования «Витебский государственный  
университет имени П.М. Машерова»  
Кафедра геометрии и математического анализа

**С.М. Бородич, Т.В. Кавитова**

# **МАТЕМАТИЧЕСКАЯ СТАТИСТИКА**

*Методические рекомендации*

*Витебск  
ВГУ имени П.М. Машерова  
2020*

УДК 519.22(075.8)  
ББК 22.172я73  
Б83

Печатается по решению научно-методического совета учреждения образования «Витебский государственный университет имени П.М. Машерова». Протокол № 6 от 18.06.2020.

Авторы: старшие преподаватели кафедры геометрии и математического анализа ВГУ имени П.М. Машерова **С.М. Бородич, Т.В. Кавитова**

Рецензент:  
заведующий кафедрой математики  
и информационных технологий УО «ВГТУ»,  
кандидат физико-математических наук *Т.В. Никонова*

Научный редактор:  
доцент кафедры геометрии и математического анализа ВГУ  
имени П.М. Машерова, кандидат физико-математических наук *Т.Л. Сурин*

**Б83** **Бородич, С.М.**  
Математическая статистика : методические рекомендации /  
С.М. Бородич, Т.В. Кавитова. – Витебск : ВГУ имени П.М. Маше-  
рова, 2020. – 48 с.

Настоящее учебное издание содержит теоретический материал, примеры решения задач и задачи для самостоятельного решения. Оно может использоваться для организации самостоятельной работы студентов, а также при проведении практических занятий.

Предназначается для студентов, обучающихся по специальностям «Программное обеспечение информационных технологий», «Прикладная математика», «Прикладная информатика», «Математика и информатика», «Компьютерная безопасность (радиофизические методы и программно-технические средства)», «Управление информационными ресурсами».

УДК 519.22(075.8)  
ББК 22.172я73

© Бородич С.М., Кавитова Т.В., 2020  
© ВГУ имени П.М. Машерова, 2020

## Содержание

Введение .....	4
1. Выборка. Статистическое распределение выборки и ее графическое представление .....	5
2. Эмпирическая функция распределения .....	8
3. Числовые характеристики выборки .....	9
4. Точечные оценки неизвестных параметров распределения .....	10
5. Методы нахождения оценок неизвестных параметров распределения .....	14
6. Распределения $\chi^2$ (хи-квадрат), Стьюдента и Фишера .....	17
7. Интервальное оценивание. Доверительные интервалы для параметров нормального распределения .....	20
8. Проверка параметрических гипотез .....	21
9. Проверка гипотез о законе распределения .....	26
10. Статистическое исследование зависимости между случайными величинами. Линейная регрессия .....	29
11. Выборочное корреляционное отношение .....	33
Задачи для самостоятельного решения .....	37
Литература .....	47

## Введение

Математическая статистика, являющаяся частью прикладной математической дисциплины «Теория вероятностей и математическая статистика», изучает случайные явления, используя одинаковые с теорией вероятностей методы и понятия. Математическая статистика отличается от теории вероятностей специфичностью решаемых ею задач. Если в теории вероятностей мы считаем заданной модель явления и производим расчёт возможного реального течения этого явления, то в математической статистике на основе реализаций каких-либо случайных событий (т. е. на основе экспериментальных данных) подбирается подходящая теоретико-вероятностная модель.

Учебное издание организовано следующим образом: в пунктах 1–3 рассматриваются основные понятия описательной статистики, применяемые для первичного анализа экспериментальных данных (выборка, способы её представления, эмпирическая функция распределения, основные числовые характеристики выборки); в пунктах 4–7 излагаются основы теории точечных и интервальных оценок неизвестных параметров распределений; в пунктах 8, 9 рассмотрены некоторые важные задачи проверки статистических гипотез; пункты 10, 11 посвящены вопросам статистического исследования зависимости между случайными величинами.

По каждой теме приводится краткий теоретический материал. Кроме того, издание содержит разобранные примеры, позволяющие закрепить, углубить теоретические знания и получить навыки практического использования методов математической статистики. В конце издания приведен список задач, который полностью охватывает все изучаемые темы и вполне обеспечивает необходимую самостоятельную работу студентов.

Настоящее учебное издание адресуется прежде всего студентам факультета математики и информационных технологий ВГУ имени П.М. Машерова, обучающимся по специальностям «Программное обеспечение информационных технологий», «Прикладная математика», «Прикладная информатика», «Математика и информатика», «Компьютерная безопасность (радиофизические методы и программно-технические средства)», «Управление информационными ресурсами».

# 1. Выборка. Статистическое распределение выборки и ее графическое представление

Будем предполагать, что каждый исход некоторого случайного эксперимента характеризуется одним из возможных значений случайной величины  $X$ . Повторив  $n$  раз эксперимент в одинаковых условиях, получим последовательность из  $n$  наблюдаемых значений этой случайной величины:  $x_1, x_2, \dots, x_n$ . Набор чисел  $x_1, x_2, \dots, x_n$  называется *выборкой*.

Числа  $x_i$  ( $i = 1, 2, \dots, n$ ) называются *элементами выборки*, а их количество  $n$  — *объемом выборки*.

Выборку можно упорядочить, расположив её элементы в неубывающем порядке:

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}.$$

Полученная таким образом последовательность чисел

$$x_{(1)}, x_{(2)}, \dots, x_{(n)}$$

называется *вариационным рядом*.

Различные значения случайной величины  $X$ , представленные в выборке, называются *вариантами*.

Если в выборке объема  $n$  варианта  $x_i$  встретилась  $n_i$  раз, то число  $n_i$  называется *частотой*, а число  $w_i = \frac{n_i}{n}$  — *относительной частотой* (частотью) этой варианты. Очевидно, что

$$\sum_{i=1}^n n_i = n, \quad \sum_{i=1}^n w_i = 1.$$

*Статистическим рядом распределения* выборки называют перечень вариант и соответствующих им частот или относительных частот. Обычно статистический ряд записывается в виде таблицы, первая строка которой содержит варианты  $x_i$ , а вторая — их частоты  $n_i$  (или относительные частоты  $w_i$ ). При этом варианты располагаются в порядке возрастания.

Как правило, статистический ряд распределения составляется в случае, когда наблюдаемая случайная величина  $X$  является дискретной.

Графически статистический ряд распределения выборки изображается следующим образом. В прямоугольной декартовой системе координат строят точки с координатами  $(x_i, n_i)$ . Последовательно соединив их отрезками, получают ломаную линию, называемую *полигоном частот*. Аналогично строится *полигон относительных частот*.

**Пример 1.** Имеется выборка значений случайной величины  $X$  объема  $n = 15$ :

$$0, 3, -5, -3, 1, 0, 1, 3, 0, 0, -3, 1, -1, 0, -1.$$

Вариационным рядом для неё будет последовательность

– 5, – 3, – 3, – 1, – 1, 0, 0, 0, 0, 0, 1, 1, 1, 3, 3.

Статистический ряд распределения данной выборки имеет вид

$x_i$	– 5	– 3	– 1	0	1	3
$n_i$	1	2	2	5	3	2

или

$x_i$	– 5	– 3	– 1	0	1	3
$w_i$	$\frac{1}{15}$	$\frac{2}{15}$	$\frac{2}{15}$	$\frac{5}{15}$	$\frac{3}{15}$	$\frac{2}{15}$

Полигон частот изображён на рис. 1.

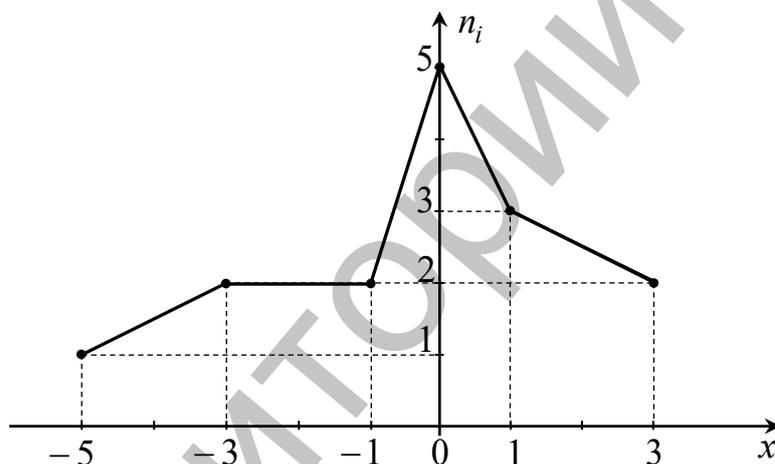


Рис.1

В случае, когда  $X$  является непрерывной случайной величиной или же вариационный ряд имеет большое количество вариантов, элементы выборки объединяют в группы (разряды), представляя результаты опытов в виде *интервального (группированного) статистического ряда распределения*. Для этого интервал, содержащий все значения выборки, разбивают на  $k$  непересекающихся интервалов

$$[a_0, a_1), [a_1, a_2), \dots, [a_{k-1}, a_k].$$

Затем для каждого интервала разбиения определяют *частоту* – количество элементов выборки, попавших в этот интервал:  $n_i$  – частота, соответствующая  $i$ -му интервалу разбиения ( $i = 1, 2, \dots, k$ ). Наряду с частотами находят также *относительные частоты*

$$w_i = \frac{n_i}{n}$$

( $n$  – объём выборки). Интервальный статистический ряд записывают в виде таблицы, в первой строке которой содержатся интервалы группировки, а во второй – соответствующие частоты  $n_i$  или относительные частоты  $w_i$ .

Интервальный статистический ряд распределения изображают с помощью *гистограммы частот*. Для этого на оси абсцисс откладывают интервалы группировки и на них, как на основании, строят прямоугольники с высотами

$$h_i = \frac{n_i}{a_i - a_{i-1}} \quad (i = 1, 2, \dots, k).$$

Аналогично строится *гистограмма относительных частот*.

**Пример 2.** Выборка 100 значений наблюдаемой непрерывной случайной величины  $X$  представлена в виде следующего интервального статистического ряда распределения:

Интервал	[22, 24)	[24, 26)	[26, 28)	[28, 30)	[30, 32)	[32, 34]
Частота	2	14	34	40	8	2

Построить гистограмму частот.

*Решение.* В данном случае  $a_i - a_{i-1} = 2$  ( $i = 1, 2, 3, 4, 5, 6$ ). Находим высоты прямоугольников:

$$h_1 = \frac{2}{2} = 1, \quad h_2 = \frac{14}{2} = 7, \quad h_3 = \frac{34}{2} = 17,$$

$$h_4 = \frac{40}{2} = 20, \quad h_5 = \frac{8}{2} = 4, \quad h_6 = \frac{2}{2} = 1.$$

Гистограмма частот изображена на рис. 2.

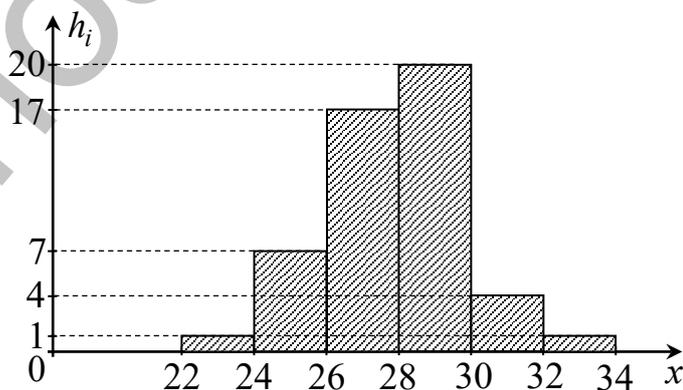


Рис. 2

## 2. Эмпирическая функция распределения

Эмпирической (выборочной) функцией распределения случайной величины  $X$ , построенной по выборке  $x_1, x_2, \dots, x_n$ , называют функцию  $F_n^*(x)$ , которая при каждом  $x \in \mathbf{R}$  равна относительной частоте события  $X < x$ , т.е.

$$F_n^*(x) = \frac{n_x}{n},$$

где  $n_x$  – число элементов выборки, меньших  $x$ .

Эмпирическая функция распределения обладает следующими свойствами:

1.  $0 \leq F_n^*(x) \leq 1$  для любого  $x \in \mathbf{R}$ ;
2.  $F_n^*(x)$  не убывает на  $\mathbf{R}$ ;
3.  $F_n^*(x) = 0$  при  $x \leq x_{\min}$ ,  $F_n^*(x) = 1$  при  $x > x_{\max}$ , где  $x_{\min}$  и  $x_{\max}$  – соответственно наименьший и наибольший элементы выборки;
4.  $F_n^*(x)$  непрерывна слева в любой точке  $x_0 \in \mathbf{R}$ .

График эмпирической функции распределения имеет ступенчатый вид. В промежутках между соседними вариантами выборки  $F_n^*(x)$  сохраняет постоянное значение. В точках оси  $Ox$ , равных вариантам выборки,  $F_n^*(x)$  претерпевает скачки; величина скачка в точке  $x = x_i$  равна относительной частоте варианты  $x_i$ .

**Пример 3.** В условиях примера 1 найти эмпирическую функцию распределения случайной величины  $X$  и построить её график.

*Решение.* В данном случае  $n = 15$ . По статистическому ряду распределения находим

$$F_{15}^*(x) = \begin{cases} 0 & \text{при } x \leq -5, \\ \frac{1}{15} & \text{при } -5 < x \leq -3, \\ \frac{3}{15} & \text{при } -3 < x \leq -1, \\ \frac{5}{15} & \text{при } -1 < x \leq 0, \\ \frac{10}{15} & \text{при } 0 < x \leq 1, \\ \frac{13}{15} & \text{при } 1 < x \leq 3, \\ 1 & \text{при } x > 3. \end{cases}$$

График  $F_{15}^*(x)$  изображён на рис. 3.

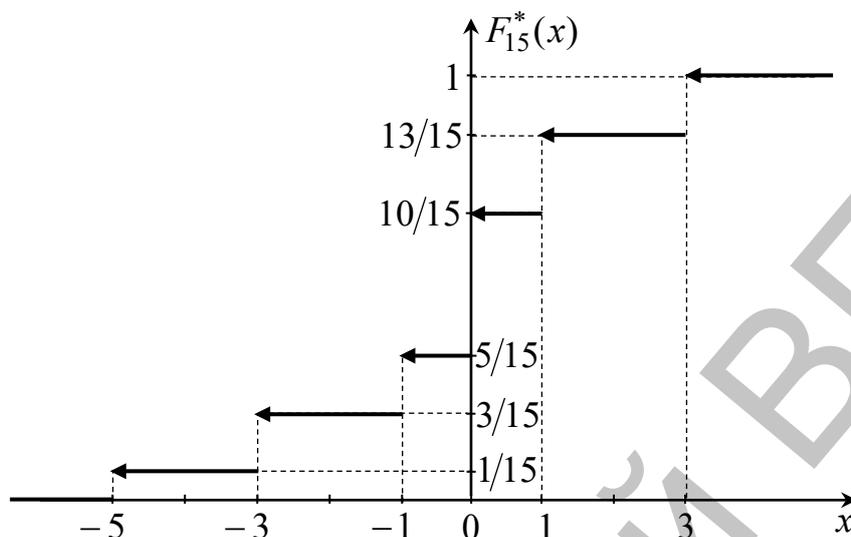


Рис. 3

### 3. Числовые характеристики выборки

Пусть  $x_1, x_2, \dots, x_n$  – выборка объёма  $n$ .

Выборочным средним  $\bar{x}$  называется среднее арифметическое всех значений выборки:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i.$$

Выборочной дисперсией  $s^2$  называют среднее арифметическое квадратов отклонений значений выборки от выборочного среднего  $\bar{x}$ :

$$s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2.$$

Выборочную дисперсию можно вычислять также по формуле

$$s^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - (\bar{x})^2.$$

**Замечание 1.** Если выборка представлена статистическим рядом распределения, то значения  $\bar{x}$  и  $s^2$  находят по формулам

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k x_i n_i, \tag{1}$$

$$s^2 = \frac{1}{n} \sum_{i=1}^k (x_i - \bar{x})^2 n_i = \frac{1}{n} \sum_{i=1}^k x_i^2 n_i - (\bar{x})^2, \tag{2}$$

где  $x_i$  – варианты,  $n_i$  – соответствующие им частоты. •

**Замечание 2.** Для интервального статистического ряда выборочное среднее и выборочную дисперсию также вычисляют по формулам (1) и (2).

В качестве  $x_i$  берут середины интервалов ряда, а в качестве  $n_i$  – частоты соответствующих интервалов. ●

*Выборочное среднее квадратическое отклонение  $s$*  определяется формулой

$$s = \sqrt{s^2}.$$

*Модой  $M_o^*$*  выборки называют варианту, имеющую наибольшую частоту.

*Медианой  $M_e^*$*  выборки называется число, которое делит вариационный ряд

$$x_{(1)}, x_{(2)}, \dots, x_{(n)}$$

на две части, содержащие равное число элементов, а именно: если  $n = 2k$  ( $k \in \mathbb{N}$ ), то  $M_e^* = \frac{x_{(k)} + x_{(k+1)}}{2}$ ; если  $n = 2k + 1$ , то  $M_e^* = x_{(k+1)}$ .

#### 4. Точечные оценки неизвестных параметров распределения

Пусть  $F(x, \theta)$  – функция распределения случайной величины  $X$ ,  $\theta$  – неизвестный параметр. Предполагаем, что общий вид функции  $F(x, \theta)$  задан.

Пусть в результате  $n$  наблюдений за случайной величиной  $X$  получена выборка

$$x_1, x_2, \dots, x_n. \quad (3)$$

По выборке требуется найти приближённое значение параметра  $\theta$ .

Элементы выборки (3) можно рассматривать последовательно как частные значения  $n$  независимых случайных величин

$$X_1, X_2, \dots, X_n,$$

каждая из которых имеет тот же закон распределения, что и случайная величина  $X$ .

Любая функция случайных величин  $X_1, X_2, \dots, X_n$  называется *статистикой*.

Пусть  $\tilde{\theta} = \tilde{\theta}(X_1, X_2, \dots, X_n)$  – некоторая статистика. Значение  $\tilde{\theta}(x_1, x_2, \dots, x_n)$ , принятое статистикой  $\tilde{\theta}$  на выборке (3), называется её *выборочным значением*.

Важными примерами статистик являются *выборочное среднее*

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

и *выборочная (статистическая) дисперсия*

$$S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2.$$

Определённые в пункте 3 числовые характеристики выборки  $\bar{x}$  (выборочное среднее) и  $s^2$  (выборочная дисперсия) являются выборочными значениями одноимённых статистик  $\bar{X}$  и  $S^2$ .

Статистика  $\tilde{\theta}$ , выборочное значение которой принимается за приближённое значение неизвестного параметра  $\theta$ , называется его *точечной оценкой* или просто *оценкой*.

Основными свойствами оценок, характеризующими их качество, являются *несмещённость*, *состоятельность* и *эффективность*.

Оценку  $\tilde{\theta}$  параметра  $\theta$  называют *несмещённой*, если

$$M(\tilde{\theta}) = \theta.$$

В противном случае оценка называется *смещённой*.

Разность  $M(\tilde{\theta}) - \theta$  называется *смещением*.

Несмещённость оценки гарантирует, что при оценивании неизвестного параметра не будет систематических ошибок в сторону завышения или занижения.

Оценку  $\tilde{\theta}_n = \tilde{\theta}_n(X_1, X_2, \dots, X_n)$  параметра  $\theta$  называют *состоятельной*, если она сходится по вероятности к  $\theta$  при  $n \rightarrow \infty$ , т. е. для любого  $\varepsilon > 0$  выполняется соотношение

$$\lim_{n \rightarrow \infty} P(|\tilde{\theta}_n - \theta| \geq \varepsilon) = 0.$$

Свойство состоятельности означает, что с ростом объёма выборки выборочные значения оценки приближаются к неизвестному значению параметра.

**Теорема 1.** Выборочное среднее  $\bar{X}$  является несмещённой и состоятельной оценкой математического ожидания наблюдаемой случайной величины  $X$ .

*Доказательство.* Поскольку случайные величины  $X_i$  распределены так же, как и сама наблюдаемая случайная величина  $X$ , то  $M(X_i) = M(X)$ ,  $i = 1, 2, \dots, n$ . В силу свойств математического ожидания имеем

$$M(\bar{X}) = M\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n M(X_i) = \frac{1}{n} n M(X) = M(X),$$

и значит,  $\bar{X}$  – несмещённая оценка  $M(X)$ .

Так как последовательность  $X_1, X_2, \dots, X_n$  состоит из независимых одинаково распределённых случайных величин с конечным математическим ожиданием и дисперсией, то в силу следствия теоремы Чебышева (см. [1], [2])

$$\frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{P} M(X).$$

Следовательно,  $\bar{X}$  – состоятельная оценка  $M(X)$ . ◀

**Теорема 2.** Выборочная дисперсия  $S^2$  является смещённой и состоятельной оценкой дисперсии случайной величины  $X$ .

Ограничимся лишь доказательством смещённости оценки  $S^2$ .

*Доказательство.* Преобразуем формулу выборочной дисперсии:

$$\begin{aligned} S^2 &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n} \sum_{i=1}^n [(X_i - M(X)) - (\bar{X} - M(X))]^2 = \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - M(X))^2 - 2 \cdot \frac{1}{n} (\bar{X} - M(X)) \sum_{i=1}^n (X_i - M(X)) + \\ &\quad + \frac{1}{n} \cdot n (\bar{X} - M(X))^2 = \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - M(X))^2 - 2(\bar{X} - M(X))^2 + (\bar{X} - M(X))^2 = \\ &\quad = \frac{1}{n} \sum_{i=1}^n (X_i - M(X))^2 - (\bar{X} - M(X))^2. \end{aligned}$$

Таким образом,

$$\begin{aligned} M(S^2) &= \frac{1}{n} \sum_{i=1}^n M[(X_i - M(X))^2] - M[(\bar{X} - M(X))^2] = \\ &= \frac{1}{n} \cdot n D(X) - D(\bar{X}) = D(X) - \frac{D(X)}{n} = \frac{n-1}{n} D(X). \end{aligned}$$

Поскольку  $M(S^2) \neq D(X)$ , то  $S^2$  – смещённая оценка дисперсии случайной величины  $X$ . ◀

**Замечание 3.** Из доказательства теоремы 2 следует, что статистика

$$S_0^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \quad (4)$$

является несмещённой оценкой дисперсии  $\sigma^2$ . Действительно,

$$S_0^2 = \frac{n}{n-1} \cdot \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{n}{n-1} S^2,$$

и значит,

$$M(S_0^2) = \frac{n}{n-1} M(S^2) = \frac{n}{n-1} \cdot \frac{n-1}{n} D(X) = D(X).$$

Можно доказать также, что  $S_0^2$  является состоятельной оценкой  $D(X)$ . •

Статистика  $S_0^2$ , определённая формулой (4), называется *исправленной выборочной дисперсией*.

Отметим, что при больших значениях  $n$  выборочные значения статистик  $S^2$  и  $S_0^2$  отличаются мало. Поэтому на практике оценку  $S_0^2$  используют для оценки дисперсии в основном лишь при малых объёмах выборки (обычно при  $n \leq 30$ ).

Несмещённая оценка  $\tilde{\theta}$  параметра  $\theta$  называется *эффективной*, если она имеет наименьшую дисперсию среди всех возможных несмещённых оценок параметра  $\theta$ .

Эффективность оценки означает, что статистика, используемая в качестве точечной оценки неизвестного параметра, обеспечивает минимальный среди всех несмещённых оценок разброс приближённых значений параметра около его истинного значения.

Пусть  $p(x, \theta)$  – плотность распределения непрерывной случайной величины  $X$  или же вероятность  $p(x, \theta) = P(X = x)$  – в случае, если случайная величина  $X$  дискретная. В предположении, что  $p(x, \theta)$  и статистика  $\tilde{\theta}$  удовлетворяют некоторым условиям регулярности (см. [11]), для дисперсии несмещённой оценки  $\tilde{\theta}$  параметра  $\theta$  выполняется *неравенство Рао – Крамера*:

$$D(\tilde{\theta}) \geq \frac{1}{J_n(\theta)},$$

где

$$J_n(\theta) = nM \left[ \left( \frac{\partial \ln p(X, \theta)}{\partial \theta} \right)^2 \right]$$

– *информация Фишера* относительно неизвестного параметра  $\theta$ , содержащаяся в выборке объёма  $n$ .

Таким образом, для доказательства эффективности несмещённой оценки  $\tilde{\theta}$  (в случае выполнения упомянутых выше условий регулярности) достаточно установить равенство

$$D(\tilde{\theta}) = \frac{1}{J_n(\theta)}.$$

**Пример 4.** Пусть  $x_1, x_2, \dots, x_n$  – выборка из нормально распределённой генеральной совокупности с параметрами  $m$  и  $\sigma$ . Показать, что выборочное среднее  $\bar{X}$  является эффективной оценкой параметра  $m$ .

*Решение.* Нам известно, что  $\bar{X}$  – несмещённая оценка  $M(X)$ , и так как  $M(X) = m$ , то  $\bar{X}$  – несмещённая оценка параметра  $m$ .

Находим

$$D(\bar{X}) = D\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n D(X_i) = \frac{1}{n^2} \cdot n\sigma^2 = \frac{\sigma^2}{n}.$$

Вычислим информацию Фишера  $J_n(m)$ . Имеем:

$$p(x, m) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-m)^2}{2\sigma^2}};$$

$$\ln p(x, m) = -\frac{(x-m)^2}{2\sigma^2} - \ln \sqrt{2\pi}\sigma,$$

$$\frac{\partial \ln p(x, m)}{\partial m} = \frac{x-m}{\sigma^2},$$

$$M \left[ \left( \frac{\partial \ln p(X, m)}{\partial m} \right)^2 \right] = M \left[ \frac{(X-m)^2}{\sigma^4} \right] = \frac{1}{\sigma^4} M(X - M(X))^2 =$$

$$= \frac{D(X)}{\sigma^4} = \frac{\sigma^2}{\sigma^4} = \frac{1}{\sigma^2},$$

$$J_n(m) = nM \left[ \left( \frac{\partial \ln p(X, m)}{\partial m} \right)^2 \right] = \frac{n}{\sigma^2}.$$

Таким образом,

$$D(\bar{X}) = \frac{1}{J_n(m)},$$

и следовательно,  $\bar{X}$  – эффективная оценка параметра  $m$ . •

**Замечание 4.** Оценки  $S^2$  и  $S_0^2$  не являются эффективными оценками дисперсии. В случае, когда известно математическое ожидание  $m$  наблюдаемой случайной величины  $X$ , несмещённой, состоятельной и эффективной оценкой  $D(X)$  является оценка

$$S_1^2 = \frac{1}{n} \sum_{i=1}^n (X_i - m)^2. \bullet$$

## 5. Методы нахождения оценок неизвестных параметров распределения

Рассмотрим два наиболее распространённых метода получения точечных оценок неизвестных параметров распределения: метод максимального правдоподобия и метод моментов.

**Метод максимального правдоподобия.** Предположим, что известен вид закона распределения случайной величины  $X$ , но неизвестен параметр  $\theta$ , которым определяется этот закон (параметр  $\theta$  может быть и векторным:  $\theta = (\theta_1, \theta_2, \dots, \theta_r)$ ). Пусть  $x_1, x_2, \dots, x_n$  – выборка наблюдений случайной величины  $X$ , по которой требуется оценить параметр  $\theta$ .

Функцией правдоподобия для оценки параметра  $\theta$  называется функция

$$L(\theta) = p(x_1, \theta) p(x_2, \theta) \dots p(x_n, \theta),$$

где  $p(x, \theta)$  – плотность распределения случайной величины  $X$ , если эта величина непрерывная, и  $p(x, \theta) = P(X = x)$ , если случайная величина  $X$  дискретная.

Метод максимального правдоподобия состоит в том, что в качестве оценки параметра  $\theta$  принимается статистика  $\tilde{\theta}$  (векторная статистика  $\tilde{\theta} = (\tilde{\theta}_1, \dots, \tilde{\theta}_r)$ , если  $\theta = (\theta_1, \dots, \theta_r)$ ), выборочное значение которой  $\tilde{\theta}(x_1, x_2, \dots, x_n)$  доставляет максимум функции правдоподобия. Такую оценку называют *оценкой максимального правдоподобия* (коротко: *МП-оценкой*).

Для упрощения вычислений, связанных с получением МП-оценки, в некоторых случаях удобно использовать логарифмическую функцию правдоподобия  $\ln L(\theta)$ .

**Метод моментов.** Пусть  $X$  — непрерывная случайная величина, плотность распределения вероятностей которой  $p(x, \theta_1, \theta_2, \dots, \theta_r)$  содержит неизвестные параметры  $\theta_1, \theta_2, \dots, \theta_r$ . Определим с помощью этой плотности  $r$  каких-либо теоретических моментов случайной величины  $X$ , например, первые  $r$  начальных моментов:

$$\alpha_k(\theta_1, \theta_2, \dots, \theta_r) = M[X^k] = \int_{-\infty}^{+\infty} x^k p(x, \theta_1, \theta_2, \dots, \theta_r) dx, \quad k = 1, 2, \dots, r.$$

По выборке наблюдений случайной величины  $X$  найдем значения соответствующих выборочных моментов  $\alpha_k^*$ :

$$\alpha_k^* = \frac{1}{n} \sum_{i=1}^n x_i^k, \quad k = 1, 2, \dots, r.$$

Приравняв теоретические моменты  $\alpha_k$  их выборочным аналогам  $\alpha_k^*$ , получаем систему  $r$  уравнений с неизвестными  $\theta_1, \theta_2, \dots, \theta_r$ :

$$\alpha_k(\theta_1, \theta_2, \dots, \theta_r) = \alpha_k^*, \quad k = 1, 2, \dots, r.$$

Решая полученную систему относительно неизвестных  $\theta_1, \theta_2, \dots, \theta_r$ , найдем оценки  $\tilde{\theta}_1, \tilde{\theta}_2, \dots, \tilde{\theta}_r$  неизвестных параметров.

Аналогично находятся оценки неизвестных параметров по выборке наблюдений дискретной случайной величины.

**Пример 5.** Найти МП-оценки математического ожидания  $m$  и дисперсии  $\sigma^2$  нормально распределенной генеральной совокупности.

*Решение.* Пусть  $x_1, x_2, \dots, x_n$  – выборка наблюдений случайной величины  $X$  с плотностью распределения

$$p(x, m, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-m)^2}{2\sigma^2}}.$$

Найдем функцию правдоподобия  $L(m, \sigma^2)$ :

$$L(m, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(x_i-m)^2}{2\sigma^2}} = \frac{1}{(2\pi)^{n/2} \sigma^n} e^{-\frac{\sum(x_i-m)^2}{2\sigma^2}}.$$

Логарифмическая функция правдоподобия имеет следующий вид:

$$\ln L(m, \sigma^2) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 - \frac{\sum(x_i-m)^2}{2\sigma^2}.$$

Используя необходимые условия максимума  $L(m, \sigma^2)$ , получаем систему уравнений для нахождения оценок максимального правдоподобия:

$$\begin{cases} \frac{\partial \ln L(m, \sigma^2)}{\partial m} = \frac{1}{\sigma^2} \sum(x_i - m) = 0, \\ \frac{\partial \ln L(m, \sigma^2)}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum(x_i - m)^2 = 0. \end{cases}$$

Из первого уравнения системы находим

$$m = \frac{1}{n} \sum x_i = \bar{x}.$$

Подставляя это значение во второе уравнение, получаем

$$\sigma^2 = \frac{1}{n} \sum (x_i - \bar{x})^2 = s^2.$$

Таким образом,  $\tilde{m} = \bar{X}$ ,  $\tilde{\sigma}^2 = S^2$  – искомые оценки. •

**Пример 6.** Пусть случайная величина  $X$  распределена по показательному закону с плотностью распределения вероятностей

$$p(x, \lambda) = \begin{cases} \lambda e^{-\lambda x} & \text{при } x \geq 0, \\ 0 & \text{при } x < 0, \end{cases}$$

содержащей неизвестный параметр  $\lambda$ . Используя метод моментов, по выборке  $x_1, x_2, \dots, x_n$  найти оценку параметра  $\lambda$ .

*Решение.* Вычисляем теоретический начальный момент первого порядка:

$$\alpha_1(\lambda) = \int_{-\infty}^{+\infty} xp(x, \lambda) dx = \lambda \int_0^{+\infty} xe^{-\lambda x} dx = \frac{1}{\lambda}.$$

Начальный выборочный момент первого порядка равен выборочному среднему:

$$\alpha_1^* = \bar{x}.$$

Приравниваем найденные теоретический и выборочный моменты:

$$\frac{1}{\lambda} = \bar{x}.$$

Отсюда получаем  $\lambda = \frac{1}{\bar{x}}$ . Следовательно,  $\tilde{\lambda} = \frac{1}{\bar{X}}$  – искомая оценка. •

## 6. Распределения $\chi^2$ (хи-квадрат), Стьюдента и Фишера

Рассмотрим три широко распространённых в математической статистике распределения –  $\chi^2$ , Стьюдента и Фишера. Приведём также используемые в дальнейшем теоремы о статистиках, имеющих эти распределения.

**Распределение  $\chi^2$ .** Пусть случайные величины  $X_1, X_2, \dots, X_n$  независимы и распределены нормально с параметрами  $m=0$  и  $\sigma=1$ . *Распределением  $\chi^2$  (или  $\chi^2$ -распределением) с  $n$  степенями свободы* называется закон распределения случайной величины

$$\chi_n^2 = \sum_{i=1}^n X_i^2.$$

Плотность распределения  $\chi^2$  с  $n$  степенями свободы имеет вид

$$p_{\chi^2}(x) = \begin{cases} 0 & \text{при } x \leq 0, \\ \frac{1}{2^{n/2} \Gamma(n/2)} x^{n/2-1} e^{-x/2} & \text{при } x > 0, \end{cases}$$

где  $\Gamma(a) = \int_0^{\infty} t^{a-1} e^{-t} dt$  – гамма-функция Эйлера.

С возрастанием числа степеней свободы  $n$  распределение  $\chi^2$  приближается к нормальному (при  $n > 30$  распределение  $\chi^2$  практически не отличается от нормального).

Для  $n \leq 30$  составлена таблица, содержащая такие значения  $\chi_n^2 = \chi_{\alpha, n}^2$ , для которых

$$P(\chi_n^2 > \chi_{\alpha, n}^2) = \int_{\chi_{\alpha, n}^2}^{+\infty} p_{\chi^2}(x) dx = \alpha$$

( $\alpha$  – заданный уровень вероятности). Значение  $\chi_{\alpha, n}^2$  называется *квантилью распределения  $\chi^2$* , отвечающей заданному уровню вероятности  $\alpha$  и заданному уровню степеней свободы  $n$ .

Для  $n > 30$  и  $\alpha \leq 0,5$  применяют формулу

$$\chi_{\alpha, n}^2 = 0,5(u_{\alpha} + \sqrt{2n-1})^2,$$

где  $u_{\alpha}$  (квантиль уровня  $\alpha$  нормального распределения с параметрами  $m=0$ ,  $\sigma=1$ ) находится по таблице функции Лапласа из условия

$$\Phi(u_{\alpha}) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{u_{\alpha}} e^{-t^2/2} dt = 1 - \alpha.$$

**Теорема 3.** Пусть наблюдаемая случайная величина  $X$  распределена нормально с параметрами  $m$  и  $\sigma$ . Тогда статистика

$$\frac{(n-1)S_0^2}{\sigma^2}$$

имеет распределение  $\chi^2$  с  $n-1$  степенями свободы. Здесь  $n$  – объём выборки,  $S_0^2$  – исправленная выборочная дисперсия.

**Распределение Стьюдента.** Пусть  $X_0, X_1, \dots, X_n$  – независимые случайные величины, распределённые нормально с параметрами  $m=0$  и  $\sigma=1$ . *Распределением Стьюдента с  $n$  степенями свободы* называется закон распределения случайной величины

$$T_n = \frac{X_0}{\sqrt{\frac{1}{n} \sum_{i=1}^n X_i^2}}.$$

**Замечание 5.** Очевидно, что случайную величину  $T_n$  можно записать в следующем виде:

$$T_n = \frac{X_0 \sqrt{n}}{\sqrt{\chi_n^2}}.$$

Плотность распределения Стьюдента с  $n$  степенями свободы имеет вид

$$p_T(x) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\Gamma\left(\frac{n}{2}\right) \sqrt{\pi n}} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}, \quad x \in \mathbf{R}.$$

При  $n \rightarrow \infty$  распределение Стьюдента приближается к нормальному с параметрами  $m=0$ ,  $\sigma=1$ . Практически уже при  $n > 30$  распределение Стьюдента можно считать приближённо нормальным.

Составлена таблица *квантилей  $t_{\alpha/2, n}$  распределения Стьюдента*, отвечающих числу степеней свободы  $n$  и заданному уровню вероятности  $\alpha$ . Значение квантили  $t_{\alpha/2, n}$  определяется из условия

$$P(|T_n| > t_{\alpha/2, n}) = 2 \int_{t_{\alpha/2, n}}^{+\infty} p_T(x) dx = \alpha.$$

**Теорема 4.** Пусть наблюдаемая случайная величина  $X$  распределена нормально с параметрами  $m$  и  $\sigma$ . Тогда статистика

$$\frac{(\bar{X} - m)\sqrt{n}}{S_0}$$

имеет распределение Стьюдента с  $n-1$  степенями свободы ( $n$  – объём выборки,  $\bar{X}$  – выборочное среднее,  $S_0 = \sqrt{S_0^2}$  – исправленное выборочное среднее квадратическое отклонение).

**Теорема 5.** Пусть  $\bar{X}_1, S_{01}^2$  и  $\bar{X}_2, S_{02}^2$  — выборочные средние и исправленные выборочные дисперсии в двух независимых выборках объёмов  $n_1$  и  $n_2$  из нормально распределённых генеральных совокупностей, математические ожидания которых известны и равны  $m_1$  и  $m_2$  соответственно, а неизвестные дисперсии одинаковы. Тогда случайная величина

$$T = \frac{\bar{X}_1 - \bar{X}_2 - (m_1 - m_2)}{\sqrt{(n_1 - 1)S_{01}^2 + (n_2 - 1)S_{02}^2}} \cdot \sqrt{\frac{n_1 n_2 (n_1 + n_2 - 2)}{n_1 + n_2}}$$

имеет распределение Стьюдента с  $\nu = n_1 + n_2 - 2$  степенями свободы.

**Распределение Фишера.** Пусть случайные величины  $U^2$  и  $V^2$  имеют  $\chi^2$ -распределения с  $n_1$  и  $n_2$  степенями свободы соответственно. *Распределением Фишера с  $n_1$  и  $n_2$  степенями свободы* называется закон распределения случайной величины

$$F_{n_1, n_2} = \frac{U^2}{V^2} \cdot \frac{n_2}{n_1}.$$

Плотность распределения Фишера с  $n_1$  и  $n_2$  степенями свободы имеет вид

$$p_F(x) = \begin{cases} 0 & \text{при } x \leq 0, \\ \frac{\Gamma\left(\frac{n_1 + n_2}{2}\right) \left(\frac{n_1}{n_2}\right)^{\frac{n_1}{2}}}{\Gamma\left(\frac{n_1}{2}\right) \Gamma\left(\frac{n_2}{2}\right)} x^{\frac{n_1}{2} - 1} \left(1 + \frac{n_1}{n_2} x\right)^{-\frac{n_1 + n_2}{2}} & \text{при } x > 0. \end{cases}$$

Для распределения Фишера составлена таблица, в которой для различных значений  $n_1, n_2$  и  $\alpha$  указаны значения квантилей  $F_{\alpha, n_1, n_2}$ , определяемых из условия

$$P(F_{n_1, n_2} > F_{\alpha, n_1, n_2}) = \int_{F_{\alpha, n_1, n_2}}^{+\infty} p_F(x) dx = \alpha.$$

**Теорема 6.** Пусть  $S_{01}^2$  и  $S_{02}^2$  — исправленные выборочные дисперсии в двух независимых выборках объёмов  $n_1$  и  $n_2$ , взятых из нормально распределённых генеральных совокупностей с одинаковыми дисперсиями. Тогда случайная величина

$$F = \frac{S_{01}^2}{S_{02}^2}$$

имеет распределение Фишера с  $n_1 - 1$  и  $n_2 - 1$  степенями свободы.

## 7. Интервальное оценивание. Доверительные интервалы для параметров нормального распределения

Пусть  $\theta$  – неизвестный параметр распределения случайной величины  $X$ .

Пусть статистики  $\tilde{\theta}_1 = \tilde{\theta}_1(X_1, \dots, X_n)$  и  $\tilde{\theta}_2 = \tilde{\theta}_2(X_1, \dots, X_n)$  таковы, что интервал  $(\tilde{\theta}_1, \tilde{\theta}_2)$  содержит (накрывает) истинное значение параметра  $\theta$  с заданной вероятностью  $p = 1 - \alpha$ :

$$P(\tilde{\theta}_1 < \theta < \tilde{\theta}_2) = 1 - \alpha.$$

Тогда интервал  $(\tilde{\theta}_1, \tilde{\theta}_2)$  называется *доверительным интервалом* для параметра  $\theta$ , вероятность  $p = 1 - \alpha$  – *доверительной вероятностью (надёжностью)*, а число  $\alpha$  – *уровнем значимости*.

Пусть  $X$  – нормально распределённая случайная величина. Тогда:

1. Если среднее квадратическое отклонение  $\sigma$  известно, то доверительный интервал для математического ожидания  $m$  имеет вид

$$\left( \bar{X} - u_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + u_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right),$$

где  $n$  – объём выборки,  $\bar{X}$  – выборочное среднее,  $u_{\alpha/2}$  находится по таблице значений функции Лапласа

$$\Phi_0(x) = \frac{1}{\sqrt{2\pi}} \int_0^x e^{-\frac{t^2}{2}} dt$$

из условия

$$\Phi_0(u_{\alpha/2}) = \frac{1 - \alpha}{2}.$$

2. Если среднее квадратическое отклонение  $\sigma$  неизвестно, то доверительный интервал для математического ожидания  $m$  имеет вид

$$\left( \bar{X} - t_{\alpha/2, n-1} \frac{S_0}{\sqrt{n}}, \bar{X} + t_{\alpha/2, n-1} \frac{S_0}{\sqrt{n}} \right),$$

где

$$S_0 = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$$

(исправленное выборочное среднее квадратическое отклонение),  $t_{\alpha/2, n-1}$  находится по таблице квантилей распределения Стьюдента из условия

$$P(T_{n-1} > t_{\alpha/2, n-1}) = \alpha/2$$

(здесь  $T_{n-1}$  – случайная величина, распределённая по закону Стьюдента с  $n - 1$  степенью свободы).

**Пример 7.** По результатам 6 независимых наблюдений над нормально распределённой случайной величиной  $X$  найдены выборочное среднее  $\bar{x} = 5,63$  и исправленная выборочная дисперсия  $s_0^2 = 0,0625$ . Требуется найти доверительный интервал для математического ожидания случайной величины  $X$ , соответствующий доверительной вероятности  $1 - \alpha = 0,99$ .

*Решение.* Находим  $s_0 = \sqrt{s_0^2} = \sqrt{0,0625} = 0,25$ . В нашем случае  $n - 1 = 5$ ,  $\alpha/2 = 0,005$ . По таблице квантилей распределения Стьюдента находим значение  $t_{\alpha/2, n-1} = t_{0,005; 5} = 4,03$ . Вычисляем

$$t_{\alpha/2, n-1} \frac{s_0}{\sqrt{n}} = 4,03 \cdot \frac{0,25}{\sqrt{6}} \approx 0,41.$$

Искомый доверительный интервал таков:  $(5,63 - 0,41; 5,63 + 0,41)$ , т. е.  $(5,22; 6,04)$ . •

Доверительный интервал для среднего квадратического отклонения  $\sigma$  нормально распределённой случайной величины  $X$  имеет вид

$$\left( S_0 \sqrt{\frac{n-1}{\chi_{\alpha/2, n-1}^2}}, S_0 \sqrt{\frac{n-1}{\chi_{1-\alpha/2, n-1}^2}} \right),$$

где  $\chi_{1-\alpha/2, n-1}^2$  и  $\chi_{\alpha/2, n-1}^2$  находятся по таблице квантилей  $\chi^2$ -распределения из условий

$$P(\chi_{n-1}^2 < \chi_{1-\alpha/2, n-1}^2) = \alpha/2, \quad P(\chi_{n-1}^2 > \chi_{\alpha/2, n-1}^2) = \alpha/2$$

(здесь  $\chi_{n-1}^2$  – случайная величина, имеющая  $\chi^2$ -распределение с  $n - 1$  степенью свободы).

## 8. Проверка параметрических гипотез

*Статистической гипотезой* или просто *гипотезой* называется любое предположение о распределениях наблюдаемых в эксперименте случайных величин, проверяемое по результатам наблюдений.

Статистическая гипотеза называется *параметрической*, если в ней сформулировано предположение относительно значений параметров распределения известного вида.

Параметрическая гипотеза называется *простой*, если она однозначно определяет параметры функции распределения; в противном случае гипотеза называется *сложной*.

Относительно параметра (параметров) распределения формулируется некоторая *основная (нулевая)* гипотеза  $H_0$ . Наряду с гипотезой  $H_0$  рассмат-

ривается одна из *альтернативных (конкурирующих)* гипотез  $H_1$ . Если основная гипотеза отклоняется, то принимается альтернативная.

Правило, которое позволяет по результатам соответствующих наблюдений принять или отклонить гипотезу  $H_0$ , называется *статистическим критерием* (или просто *критерием*) для проверки гипотезы  $H_0$ .

Проверка соответствия результатов эксперимента (выборочных данных) выдвинутой гипотезе  $H_0$  осуществляется с помощью специально подобранной статистики  $Z$ , точное или приближённое распределение которой в случае справедливости гипотезы  $H_0$  известно. Статистика  $Z$  называется *статистикой критерия*. По выборочному значению  $z_\epsilon$  статистики критерия судят о справедливости гипотезы  $H_0$ .

Множество всех возможных значений статистики критерия разбивают на два непересекающихся подмножества: одно из них содержит значения статистики  $Z$ , при которых гипотеза  $H_0$  отклоняется, другое – при которых она принимается.

*Критической областью* называется совокупность всех значений статистики критерия, при которых принимается решение отклонить гипотезу  $H_0$ .

Совокупность всех значений статистики критерия, при которых гипотезу  $H_0$  принимают, называется *областью принятия гипотезы*.

Таким образом, если выборочное значение  $z_\epsilon$  статистики критерия принадлежит критической области, то гипотезу  $H_0$  отклоняют; если же  $z_\epsilon$  принадлежит области принятия гипотезы, то гипотезу  $H_0$  принимают.

Поскольку проверка статистической гипотезы осуществляется на основе выборочных данных, носящих случайный характер, то всегда присутствует возможность принятия неправильного решения. С каждым статистическим критерием связаны ошибки двух родов:

*ошибка первого рода* — отклонение гипотезы  $H_0$ , когда на самом деле она верна;

*ошибка второго рода* — принятие гипотезы  $H_0$ , когда эта гипотеза ошибочна.

Вероятность ошибки первого рода называется *уровнем значимости* критерия и обозначается  $\alpha$ . Как правило, уровень значимости (вероятность отклонения верной гипотезы  $H_0$ ) задаётся заранее; при этом для  $\alpha$  обычно используются стандартные значения:  $\alpha = 0,001; 0,005; 0,01; 0,05; 0,1$ .

При заданном уровне значимости  $\alpha$  критическую область выбирают такой, чтобы вероятность ошибки второго рода была минимальной.

Различают левостороннюю, правостороннюю и двустороннюю критические области. *Левосторонняя* критическая область определяется неравенством  $Z < z_1$ , *правосторонняя* — неравенством  $Z > z_2$ . *Двусторонняя*

критическая область определяется совокупностью неравенств  $Z < z_1$  и  $Z > z_2$ , где  $z_1 < z_2$ .

Точки  $z_1$  и  $z_2$ , отделяющие критическую область от области принятия гипотезы, называются *критическими*.

Критические точки ищут исходя из требования, чтобы при условии справедливости гипотезы  $H_0$  вероятность попадания значения статистики критерия в критическую область была равна принятому уровню значимости  $\alpha$ :

$P(Z < z_1) = \alpha$  – для критерия с левосторонней критической областью;

$P(Z > z_2) = \alpha$  – для критерия с правосторонней критической областью;

$P(Z < z_1) + P(Z > z_2) = \alpha$  – для критерия с двусторонней критической областью.

При нахождении критических точек используется таблица распределения, которому подчиняется (точно или приближённо) статистика  $Z$  в предположении, что верна гипотеза  $H_0$ .

**Замечание 6.** Если распределение статистики критерия (при условии справедливости гипотезы  $H_0$ ) симметрично относительно нуля, то для критерия с двусторонней критической областью критические точки  $z_1$  и  $z_2$  также выбираются симметричными относительно нуля:  $z_1 = -z_2$ . Таким образом, в данном случае критическая область задаётся неравенством  $|Z| > z_2$ , и значит, точка  $z_2$  должна удовлетворять условию  $P(|Z| > z_2) = \alpha$ , которое (в силу симметричности относительно нуля распределения статистики  $Z$ ) равносильно условию  $P(Z > z_2) = \frac{\alpha}{2}$ . •

Рассмотрим следующий пример построения статистического критерия для проверки параметрической гипотезы о математическом ожидании нормально распределённой с.в.

Пусть наблюдаемая в эксперименте случайная величина  $X$  имеет нормальный закон распределения с неизвестными параметрами  $m$  и  $\sigma$ . По результатам выборки объёма  $n$  требуется при заданном уровне значимости  $\alpha$  проверить гипотезу  $H_0 : m = m_0$ . Предполагается, что в качестве альтернативной гипотезы выбрана гипотеза  $H_1 : m \neq m_0$ .

Статистикой критерия выбирается случайная величина

$$T = \frac{(\bar{X} - m_0)\sqrt{n}}{S_0},$$

где  $S_0$  – исправленное выборочное среднее квадратическое отклонение. Если гипотеза  $H_0$  справедлива, то в силу теоремы 4 статистика  $T$  имеет распределение Стьюдента с  $n - 1$  степенями свободы. При данном выборе

альтернативной гипотезы ( $m \neq m_0$ ) строят двустороннюю критическую область. По таблице квантилей распределения Стьюдента по уровню значимости  $\alpha$  и числу степеней свободы  $n - 1$  находят критическую точку  $t_{\alpha/2, n-1}$ , для которой

$$P(|T| > t_{\alpha/2, n-1}) = \alpha.$$

Неравенство  $|T| > t_{\alpha/2, n-1}$  определяет критическую область критерия.

Далее вычисляется выборочное значение  $T_0$  статистики критерия:

$$T_0 = \frac{(\bar{x} - m_0)\sqrt{n}}{s_0},$$

где

$$s_0 = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}.$$

Если  $|T_0| > t_{\alpha/2, n-1}$ , то гипотеза  $H_0$  отклоняется и принимается гипотеза  $H_1$ . Если  $|T_0| \leq t_{\alpha/2, n-1}$ , то считается, что оснований для отклонения гипотезы  $H_0$  нет.

Если в рассмотренном нами примере альтернативную гипотезу « $m \neq m_0$ » заменить на гипотезу « $m < m_0$ », то критическую область нужно строить левосторонней, а если на гипотезу « $m > m_0$ », то правосторонней.

В таблицах 1–4 приводятся критерии проверки некоторых параметрических гипотез о параметрах нормально распределенных генеральных совокупностей.

Таблица 1. Критерии для проверки гипотезы о математическом ожидании случайной величины, имеющей нормальное распределение

Гипотеза $H_0$	Условие	Статистика $Z$ критерия	Распределение $Z$ , если $H_0$ верна	Гипотеза $H_1$	Критич. область
$m = m_0$	$\sigma$ известно	$\frac{(\bar{X} - m_0)\sqrt{n}}{\sigma}$	Нормальное с параметрами (0, 1)	$m > m_0$	$Z > u_\alpha$
				$m < m_0$	$Z < -u_\alpha$
				$m \neq m_0$	$ Z  > u_{\alpha/2}$
	$\sigma$ неизвестно	$\frac{(\bar{X} - m_0)\sqrt{n}}{S_0}$	Стьюдента с числом степеней свободы $\nu = n - 1$	$m > m_0$	$Z > t_{\alpha, \nu}$
				$m < m_0$	$Z < -t_{\alpha, \nu}$
				$m \neq m_0$	$ Z  > t_{\alpha/2, \nu}$

Таблица 2. Критерии для проверки гипотезы о равенстве математических ожиданий двух случайных величин, имеющих нормальное распределение

Гипотеза $H_0$	Условия	Статистика $Z$ критерия	Распределение $Z$ , если $H_0$ верна	Гипотеза $H_1$	Критич. область
$m_1 = m_2$	$\sigma_1$ и $\sigma_2$ известны	$\frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\sigma_1^2/n_1 + \sigma_2^2/n_2}}$	Нормальное с параметрами (0, 1)	$m_1 > m_2$	$Z > u_\alpha$
				$m_1 < m_2$	$Z < -u_\alpha$
				$m_1 \neq m_2$	$ Z  > u_{\alpha/2}$
	$\sigma_1$ и $\sigma_2$ неизвестны, $\sigma_1 = \sigma_2$	$\frac{\bar{X}_1 - \bar{X}_2}{\sqrt{(n_1-1)S_{01}^2 + (n_2-1)S_{02}^2}} \times \sqrt{\frac{n_1 n_2 (n_1 + n_2 - 2)}{n_1 + n_2}}$	Стьюдента с числом степ. свободы $\nu = n_1 + n_2 - 2$	$m_1 > m_2$	$Z > t_{\alpha, \nu}$
				$m_1 < m_2$	$Z < -t_{\alpha, \nu}$
				$m_1 \neq m_2$	$ Z  > t_{\alpha/2, \nu}$
	$\sigma_1$ и $\sigma_2$ неизвестны, $\sigma_1 \neq \sigma_2$	$\frac{\bar{X}_1 - \bar{X}_2}{\sqrt{S_{01}^2/n_1 + S_{02}^2/n_2}}$	Стьюдента с числом степ. свободы $\nu \approx \frac{(S_{01}^2/n_1 + S_{02}^2/n_2)^2}{\frac{(S_{01}^2/n_1)^2}{n_1-1} + \frac{(S_{02}^2/n_2)^2}{n_2-1}}$	$m_1 > m_2$	$Z > t_{\alpha, \nu}$
				$m_1 < m_2$	$Z < -t_{\alpha, \nu}$
				$m_1 \neq m_2$	$ Z  > t_{\alpha/2, \nu}$

( $S_{01}^2$  и  $S_{02}^2$  – исправленные выборочные дисперсии)

Таблица 3. Критерий для проверки гипотезы о дисперсии случайной величины, имеющей нормальное распределение

Гипотеза $H_0$	Условие	Статистика $Z$ критерия	Распределение $Z$ , если $H_0$ верна	Гипотеза $H_1$	Критич. область
$\sigma^2 = \sigma_0^2$	$m$ неизвестно	$\frac{(n-1)S_0^2}{\sigma_0^2}$	$\chi^2$ с числом степ. свободы $\nu = n - 1$	$\sigma^2 > \sigma_0^2$	$Z > \chi_{\alpha, \nu}^2$
				$\sigma^2 < \sigma_0^2$	$Z < \chi_{1-\alpha, \nu}^2$
				$\sigma^2 \neq \sigma_0^2$	$Z > \chi_{\alpha/2, \nu}^2$ или $Z < \chi_{1-\alpha/2, \nu}^2$

Таблица 4. Критерий для проверки гипотезы о равенстве дисперсий двух случайных величин, имеющих нормальное распределение

Гипотеза $H_0$	Условие	Статистика $Z$ критерия	Распределение $Z$ , если $H_0$ верна	Гипотеза $H_1$	Критич. область
$\sigma_1^2 = \sigma_2^2$	$m_1$ и $m_2$ неизвестны	$\frac{S_{01}^2}{S_{02}^2}$	Фишера с $\nu_1 = n_1 - 1$ и $\nu_2 = n_2 - 1$ степ. свободы	$\sigma_1^2 > \sigma_2^2$	$Z > F_{\alpha, \nu_1, \nu_2}$

**Пример 8.** Из нормально распределённой генеральной совокупности извлечена выборка объёма  $n = 13$  и по ней найдена исправленная выборочная дисперсия  $s_0^2 = 10,3$ . Требуется при уровне значимости  $0,02$ , проверить нулевую гипотезу  $H_0: \sigma^2 = 12$ , приняв в качестве конкурирующей гипотезы  $H_1: \sigma^2 \neq 12$ .

*Решение.* Для проверки гипотезы  $H_0$  используем статистику

$$Z = \frac{(n-1)S_0^2}{\sigma_0^2},$$

имеющую, при условии справедливости нулевой гипотезы,  $\chi^2$ -распределение с  $v = n - 1$  степенями свободы (см. таблицу 3).

Найдем выборочное значение статистики критерия

$$z_6 = \frac{(13 - 1) \cdot 10,3}{12} = 10,3.$$

Так как конкурирующая гипотеза имеет вид  $\sigma^2 \neq 12$ , то критическая область — двусторонняя.

По таблице квантилей  $\chi^2$ -распределения находим критические точки:

$$z_1 = \chi_{1-\alpha/2, v}^2 = \chi_{0,99, 12}^2 = 3,6, \quad z_2 = \chi_{\alpha/2, v}^2 = \chi_{0,01, 12}^2 = 26,2.$$

Следовательно, областью принятия гипотезы  $H_0$  является отрезок  $[3,6; 26,2]$ . Так как  $z_6$  принадлежит этому отрезку, то гипотеза  $H_0$  принимается. ●

## 9. Проверка гипотез о законе распределения

Пусть необходимо проверить гипотезу  $H_0$ , состоящую в том, что наблюдаемая в эксперименте случайная величина  $X$  распределена по некоторому известному закону (нормальному, биномиальному, Пуассона и т.д.). Статистический критерий, применяемый для проверки такой гипотезы, называется *критерием согласия*.

Критериев согласия существует много. Рассмотрим наиболее часто используемый на практике критерий согласия – *критерий  $\chi^2$  Пирсона*.

Предположим, что сформулирована гипотеза  $H_0$ , состоящая в том, что случайная величина  $X$  имеет закон распределения известного вида, зависящий от параметров  $\theta_1, \dots, \theta_r$  (например, нормальный закон с параметрами  $m$  и  $\sigma$  или закон Пуассона с параметром  $\lambda$ ).

Пусть в результате наблюдений за случайной величиной  $X$  получена выборка объёма  $n$ :  $x_1, x_2, \dots, x_n$ .

Для проверки гипотезы  $H_0$  с помощью критерия  $\chi^2$  Пирсона поступают следующим образом.

1. Выбирают уровень значимости  $\alpha$  (вероятность отвергнуть гипотезу  $H_0$  в случае, если она верна).

2. По выборке методом максимального правдоподобия (см. п. 5) оценивают параметры предполагаемого закона распределения.

3. Область возможных значений случайной величины  $X$  разбивают на  $k$  непересекающихся множеств  $S_1, S_2, \dots, S_k$ , которые представляют собой интервалы в случае, когда  $X$  – непрерывная случайная величина, либо группы отдельных значений, если эта величина дискретная.

4. Для каждого множества  $S_i, i=1, 2, \dots, k$ , подсчитывают число  $n_i$  элементов выборки, попавших в это множество (т.е. находят эмпирические частоты).

5. Используя предполагаемый закон распределения, вычисляют гипотетические вероятности  $p_i$  попадания случайной величины  $X$  в множества  $S_i$ :

$$p_i = P(X \in S_i), \quad i = 1, 2, \dots, k.$$

6. Находят теоретические частоты  $n'_i$  попадания значений случайной величины  $X$  в множества  $S_i$ :

$$n'_i = np_i.$$

7. Вычисляют выборочное значение  $\chi^2_{\text{в}}$  статистики критерия  $\chi^2$  Пирсона – случайной величины

$$\chi^2 = \sum_{i=1}^k \frac{(n_i - n'_i)^2}{n'_i}. \quad (5)$$

Применение статистики (5) для проверки гипотезы  $H_0$  основано на следующей теореме.

**Теорема 7.** Если гипотеза  $H_0$  верна, то статистика (5) критерия  $\chi^2$  асимптотически при  $n \rightarrow \infty$  распределена по закону  $\chi^2$  с  $\nu = k - r - 1$  степенями свободы, где  $k$  – число множеств  $S_i, r$  – число параметров предполагаемого распределения, оцененных по выборке.

8. По таблице квантилей  $\chi^2$ -распределения по заданному уровню значимости  $\alpha$  и числу степеней свободы  $\nu = k - r - 1$  находят значение  $\chi^2_{\alpha, \nu}$ , удовлетворяющее условию

$$P(\chi^2_{\nu} > \chi^2_{\alpha, \nu}) = \alpha.$$

9. Сравнивают значения  $\chi^2_{\text{в}}$  и  $\chi^2_{\alpha, \nu}$ . В соответствии с критерием  $\chi^2$  Пирсона гипотеза  $H_0$  принимается, если  $\chi^2_{\text{в}} \leq \chi^2_{\alpha, \nu}$  (в этом случае говорят также, что гипотеза  $H_0$  согласуется с результатами наблюдений). Если  $\chi^2_{\text{в}} > \chi^2_{\alpha, \nu}$ , то гипотеза  $H_0$  отклоняется.

**Замечание 7.** Необходимым условием применения критерия  $\chi^2$  Пирсона является выполнение неравенства  $n'_i \geq 5$  для всех множеств  $S_i$ . Если

для некоторых множеств  $S_i$  это условие не выполняется, то их следует объединить с соседними.

**Пример 9.** Результаты исследования прочности на сжатие 200 образцов бетона представлены в виде сгруппированного статистического ряда:

Интервалы прочности, МПа	19–20	20–21	22–23	23–24	24–25	25–26
Частоты $n_i$	10	26	56	64	30	14

С помощью критерия  $\chi^2$  Пирсона требуется проверить гипотезу  $H_0$  о нормальном распределении прочности на сжатие (случайной величины  $X$ ). Уровень значимости принять равным 0,05.

*Решение.* Определяем значения  $x_i^*$  середин интервалов и находим точечные оценки математического ожидания  $m$  и среднего квадратического отклонения  $\sigma$  гипотетического нормального распределения:

$$\begin{aligned}\tilde{m} = \bar{x} &= \frac{1}{n} \sum_{i=1}^k x_i^* n_i = \\ &= \frac{1}{200} (19,5 \cdot 10 + 20,5 \cdot 26 + 21,5 \cdot 56 + 22,5 \cdot 64 + 23,5 \cdot 30 + 24,5 \cdot 14) = \\ &= 22,1 \text{ МПа};\end{aligned}$$

$$\begin{aligned}s^2 &= \frac{1}{n} \sum_{i=1}^k (x_i^* - \bar{x})^2 n_i = \\ &= \frac{1}{200} ((-2,6)^2 \cdot 10 + (-1,6)^2 \cdot 26 + (-0,6)^2 \cdot 56 + \\ &\quad + 0,4^2 \cdot 64 + 1,4^2 \cdot 30 + 2,4^2 \cdot 14) = 1,52 \text{ МПа}^2;\end{aligned}$$

$$\tilde{\sigma} = \sqrt{s^2} = \sqrt{1,52} \approx 1,233 \text{ МПа}.$$

По формуле

$$u_i = (x_i - \tilde{m}) / \tilde{\sigma},$$

вычисляем концы нормированных интервалов, при этом наименьшее значение  $u_i$  полагаем равным  $-\infty$ , а наибольшее —  $+\infty$ :

$$\begin{aligned}u_0 &= -\infty; & u_1 &\approx -1,70; & u_2 &\approx -0,89; & u_3 &\approx -0,08; \\ & & u_4 &\approx 0,73; & u_5 &\approx 1,54; & u_6 &= +\infty.\end{aligned}$$

Находим вероятности  $p_i$  попадания случайной величины  $X$ , имеющей нормальное распределение с параметрами  $m = 22,1$ ,  $\sigma = 1,233$ , в частичные интервалы  $[x_{i-1}, x_i)$  по формуле

$$p_i = P\{x_{i-1} \leq X < x_i\} = \Phi_0(u_i) - \Phi_0(u_{i-1}),$$

где

$$\Phi_0(x) = \frac{1}{\sqrt{2\pi_0}} \int_0^x e^{-\frac{t^2}{2}} dt.$$

Используем при этом таблицу значений функции Лапласа. Полученные результаты, а также дальнейшие вычисления, необходимые для определения выборочного значения статистики критерия  $\chi^2$ , приведем в таблице:

Интервалы наблюдаемых значений с.в. $X$ [ $x_{i-1}, x_i$ )	Частоты $n_i$	Нормированные интервалы [ $u_{i-1}, u_i$ )	$p_i$	$n_i' = np_i$	$(n_i - n_i')^2$	$\frac{(n_i - n_i')^2}{n_i'}$
19 – 20	10	$(-\infty; -1,70)$	0,045	9	1	0,11
20 – 21	26	$[-1,70; -0,89)$	0,142	28,4	5,76	0,20
21 – 22	56	$[-0,89; -0,08)$	0,281	56,2	0,04	0,00
22 – 23	64	$[-0,08; 0,73)$	0,299	59,8	17,64	0,29
23 – 24	30	$[0,73; 1,54)$	0,171	34,2	17,64	0,52
24 – 25	14	$[1,54; +\infty)$	0,062	12,4	2,56	0,23
$\Sigma$	$n = 200$		1,000	200,0		$\chi^2 = 1,35$

В результате вычислений получили  $\chi^2 = 1,35$ . Находим по таблице квантилей  $\chi^2$ -распределения по заданному уровню значимости  $\alpha = 0,05$  и числу степеней свободы  $\nu = k - r - 1 = 6 - 2 - 1 = 3$  критическое значение  $\chi_{0,5,3}^2 = 7,815$ . Так как  $\chi^2 < \chi_{0,5,3}^2$ , то гипотеза о нормальном распределении предела прочности на сжатие принимается. ●

## 10. Статистическое исследование зависимости между случайными величинами. Линейная регрессия

Пусть эксперимент описывается двумерной случайной величиной  $(X, Y)$ . Изучается связь между случайными величинами  $X$  и  $Y$ .

Зависимость математического ожидания одной случайной величины от значений, принимаемых другой, называется *регрессионной зависимостью (регрессией)*.

Условное математическое ожидание  $M(Y | X = x)$  случайной величины  $Y$ , рассматриваемое как функция от  $x$ , т. е.  $M(Y | X = x) = \varphi(x)$ , называется *функцией регрессии  $Y$  на  $X$* . Аналогично определяется *функция регрессии  $X$  на  $Y$* .

Вид функции регрессии (линейная, квадратичная, показательная и т. д.) характеризует форму связи между случайными величинами.

Для нахождения функций регрессий надо знать закон распределения случайного вектора  $(X, Y)$ . Однако на практике этот закон, как правило, неизвестен. Поэтому, исходя из экспериментальных данных, строят оценки функций регрессий  $Y$  на  $X$  и  $X$  на  $Y$ , называемые *выборочными (эмпириче-*

скими) функциями этих регрессий и обозначаемые соответственно  $\bar{y}_x = f(x)$  и  $\bar{x}_y = g(y)$ .

Пусть  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  — выборка значений двумерной случайной величины  $(X, Y)$ . Если наблюдаемые данные изобразить в виде точек в декартовой системе координат, то получится точечная диаграмма, называемая *корреляционным полем*.

Общий вид выборочной функции регрессии  $\bar{y}_x = f(x; a_0, a_1, \dots, a_m)$  ( $a_i$  — параметры) часто выбирают исходя из анализа расположения точек  $(x_i, y_i)$  на корреляционном поле. Неизвестные значения параметров находятся из условия минимизации функции

$$S(a_0, a_1, \dots, a_m) = \sum_{i=1}^n (y_i - f(x_i; a_0, a_1, \dots, a_m))^2.$$

При этом применяется метод наименьших квадратов.

Для параметров линейной выборочной функции регрессии  $\bar{y}_x = ax + b$  получается следующая система уравнений:

$$\begin{cases} b \sum x_i + a \sum x_i^2 = \sum x_i y_i, \\ nb + a \sum x_i = \sum y_i. \end{cases}$$

Параметры линейной выборочной функции регрессии  $\bar{x}_y = cy + d$  находятся из аналогичной системы.

Величина

$$r_g = \frac{\frac{1}{n} \sum x_i y_i - \bar{x} \bar{y}}{s_X s_Y},$$

где  $s_X, s_Y$  — выборочные средние квадратические отклонения случайных величин  $X$  и  $Y$ , а  $\bar{x}, \bar{y}$  — их выборочные средние, называется *выборочным коэффициентом корреляции* этих величин.

Заметим, что при замене  $(x_i, y_i)$  на  $\left(\frac{x_i - c_1}{h_1}, \frac{y_i - c_2}{h_2}\right)$ , где  $h_1 > 0, h_2 > 0$ , а постоянные  $c_1$  и  $c_2$  произвольны, выборочный коэффициент корреляции не меняет своего значения (т. е. переход к условным вариантам не изменяет величины  $r_g$ ).

Имеет место оценка  $|r_g| \leq 1$ .

Выборочный коэффициент корреляции характеризует тесноту линейной связи между случайными величинами  $X$  и  $Y$  (оценивает величину рассеяния наблюдаемых данных  $(x_i, y_i)$  относительно прямых линий регрессий  $\bar{y}_x = ax + b$  и  $\bar{x}_y = cy + d$ ). Чем ближе  $|r_g|$  к 1, тем линейная связь между  $X$  и  $Y$  сильнее; чем ближе  $|r_g|$  к 0, тем эта связь слабее. Если  $|r_g| = 1$ , то между

$X$  и  $Y$  существует линейная функциональная связь. Если  $r_e = 0$ , то линейная регрессионная зависимость между  $X$  и  $Y$  отсутствует.

Выборочные уравнения прямых линий регрессий  $Y$  на  $X$  и  $X$  на  $Y$  можно записать в следующем виде:

$$\bar{y}_x - \bar{y} = r_e \frac{S_Y}{S_X} (x - \bar{x}), \quad \bar{x}_y - \bar{x} = r_e \frac{S_X}{S_Y} (y - \bar{y}).$$

Величины  $\rho_{YX} = r_e \frac{S_Y}{S_X}$  и  $\rho_{XY} = r_e \frac{S_X}{S_Y}$  называются *линейными коэффициентами регрессий*.

Выборочный коэффициент корреляции является точечной оценкой коэффициента корреляции генеральной совокупности (т. е. теоретического коэффициента корреляции).

Пусть  $r_e$  – выборочный коэффициент корреляции, вычисленный по выборке объема  $n$  из генеральной совокупности  $(X, Y)$ , имеющей двумерное нормальное распределение. Если  $r_e \neq 0$ , то это еще не значит, что коэффициент корреляции генеральной совокупности  $r_T$  также отличен от нуля. Проверка нулевой гипотезы  $H_0: r_T = 0$  против альтернативной гипотезы  $H_1: r_T \neq 0$  осуществляется с помощью статистики

$$T = \frac{r_e \sqrt{n-2}}{\sqrt{1-r_e^2}},$$

которая, при условии справедливости гипотезы  $H_0$ , имеет распределение Стьюдента с  $\nu = n - 2$  степенями свободы. Критическая область критерия при уровне значимости  $\alpha$  определяется неравенством  $|T| > t_{\alpha/2, n-2}$ .

Если гипотеза  $H_0$  отклоняется, то это означает, что выборочный коэффициент корреляции  $r_e$  значимо отличается от нуля (коротко: значим), а  $X$  и  $Y$  коррелированы, т. е. связаны линейной регрессионной зависимостью.

Если гипотеза  $H_0$  принимается, то выборочный коэффициент корреляции незначим, а  $X$  и  $Y$  некоррелированы, т.е. не связаны линейной регрессионной зависимостью.

**Пример 10.** Найти уравнения линейных регрессий  $Y$  на  $X$  и  $X$  на  $Y$  по 10 парам наблюдаемых значений двумерной случайной величины  $(X, Y)$ :

$x_i$	6	11	11	7	8	10	12	6	10	9
$y_i$	27	32	33	30	30	33	34	29	31	32

*Решение.* Найдем коэффициенты (параметры) искомым уравнений. Для этого составим расчетную таблицу:

$x_i$	$y_i$	$x_i y_i$	$x_i^2$	$y_i^2$
6	27	162	36	729
11	32	352	121	1024
11	33	363	121	1089
7	30	210	49	900
8	30	240	64	900
10	33	330	100	1089
12	34	408	144	1156
6	28	168	36	784
10	31	310	100	961
9	32	288	81	1024
$\sum x_i = 90$	$\sum y_i = 310$	$\sum x_i y_i = 2831$	$\sum x_i^2 = 852$	$\sum y_i^2 = 9656$

Записываем систему уравнений для нахождения коэффициентов  $a$  и  $b$  уравнения линейной регрессии  $Y$  на  $X$ :

$$\begin{cases} 90b + 852a = 2831, \\ 10b + 90a = 310. \end{cases}$$

Решая ее, находим:  $a \approx 0,98$ ,  $b \approx 22,18$ . Следовательно, уравнение линейной регрессии  $Y$  на  $X$  имеет вид

$$\bar{y}_x = 0,98x + 22,18.$$

Коэффициенты  $c$  и  $d$  уравнения линейной регрессии  $X$  на  $Y$  удовлетворяют системе уравнений

$$\begin{cases} 310d + 9656c = 2831, \\ 10d + 310c = 90. \end{cases}$$

Решая систему, находим  $c \approx 0,89$ ,  $d \approx -18,59$ . Следовательно, уравнение линейной регрессии  $X$  на  $Y$  имеет вид

$$\bar{x}_y = 0,89y - 18,59. \bullet$$

**Пример 11.** По выборке объема  $n = 122$ , извлеченной из нормальной двумерной совокупности  $(X, Y)$ , найден выборочный коэффициент корреляции  $r_g = 0,4$ . При уровне значимости  $0,05$  проверить нулевую гипотезу о равенстве нулю генерального коэффициента корреляции  $r_\Gamma$  при конкурирующей гипотезе  $H_1: r_\Gamma \neq 0$ .

*Решение.* Найдем выборочное значение статистики критерия:

$$T_g = \frac{0,4\sqrt{122-2}}{\sqrt{1-0,4^2}} \approx 4,78.$$

По условию конкурирующая гипотеза имеет вид  $r_\Gamma \neq 0$ , поэтому критическая область – двусторонняя.

По уровню значимости  $\alpha = 0,05$  и числу степеней свободы  $\nu = n - 2 = 122 - 2 = 120$  находим по таблице квантилей распределения Стьюдента критическую точку  $t_{\alpha/2, n-2} = t_{0,025; 120} = 1,98$ .

Поскольку  $T_e = 4,78 > 1,98$ , нулевую гипотезу отвергаем. Другими словами, выборочный коэффициент корреляции значимо отличается от нуля. ●

## 11. Выборочное корреляционное отношение

Будем исследовать тесноту любой, вообще говоря, нелинейной корреляционной связи между случайными величинами  $X$  и  $Y$ .

Наблюдённые данные для случайного вектора  $(X, Y)$  представим в виде *корреляционной таблицы*.

$X \backslash Y$	$y_1$	$y_2$	...	$y_l$	$n_i$
$x_1$	$m_{11}$	$m_{12}$	...	$m_{1l}$	$n_1$
$x_2$	$m_{21}$	$m_{22}$	...	$m_{2l}$	$n_2$
...	...	...	...	...	...
$x_k$	$m_{k1}$	$m_{k2}$	...	$m_{kl}$	$n_k$
$m_j$	$m_1$	$m_2$	...	$m_l$	$n$

Эта таблица включает в себя следующие элементы:

$x_1, x_2, \dots, x_k$  и  $y_1, y_2, \dots, y_l$  – различные наблюдённые значения (варианты) случайных величин  $X$  и  $Y$  соответственно;

$m_{ij}$  – число появлений пары значений  $(x_i, y_j)$  в выборке (частота этой пары);

$n_i$  – частота значения  $x_i$  ( $n_i = \sum_j m_{ij}$ );

$m_j$  – частота значения  $y_j$  ( $m_j = \sum_i m_{ij}$ );

$n$  – объём выборки ( $n = \sum_i n_i = \sum_j m_j = \sum_{i,j} m_{ij}$ ).

Для каждого значения  $x_i$  найдём среднее значение случайной величины  $Y$ :

$$\bar{y}_i = \frac{1}{n_i} \sum_j y_j m_{ij}.$$

Величины  $\bar{y}_i$  называются *групповыми (условными) средними*.

Рассеяние условных средних относительно общего выборочного среднего характеризуется величиной

$$s_{\bar{y}}^2 = \frac{1}{n} \sum_i (\bar{y}_i - \bar{y})^2 n_i,$$

которая называется *межгрупповой дисперсией*.

Величина

$$s_{\bar{y}} = \sqrt{s_{\bar{y}}^2}$$

называется *межгрупповым средним квадратическим отклонением*.

*Выборочным корреляционным отношением  $Y$  на  $X$*  называют величину

$$\eta_{YX} = \frac{s_{\bar{y}}}{s_Y},$$

где  $s_Y$  – выборочное среднее квадратическое отклонение случайной величины  $Y$ . Аналогично определяется  $\eta_{XY}$  – выборочное корреляционное отношение  $X$  на  $Y$ .

Выборочное корреляционное отношение обладает следующими свойствами:

1.  $0 \leq \eta_{YX} \leq 1$ .
2. Если  $\eta_{YX} = 0$ , то корреляционная зависимость  $Y$  на  $X$  отсутствует.
3. Если  $\eta_{YX} = 1$ , то существует функциональная зависимость  $Y$  от  $X$ .
4.  $\eta_{YX} \geq |r_{\epsilon}|$ .
5.  $\eta_{YX} = |r_{\epsilon}|$  тогда и только тогда, когда имеет место точная линейная корреляционная зависимость  $Y$  от  $X$ .

Выборочное корреляционное отношение  $\eta_{YX}$  является мерой тесноты корреляционной зависимости  $Y$  от  $X$ :

чем ближе  $\eta_{YX}$  к 1, тем выше степень корреляционной зависимости  $Y$  от  $X$ , которая при  $\eta_{YX} = 1$  переходит в функциональную зависимость;

чем ближе  $\eta_{YX}$  к 0, тем меньше степень корреляционной зависимости  $Y$  от  $X$ , причём при  $\eta_{YX} = 0$  корреляционная зависимость  $Y$  на  $X$  отсутствует.

Проверка гипотезы  $H_0$  об отсутствии корреляционной зависимости  $Y$  от  $X$  производится с помощью статистики

$$W = \frac{(n-k)\eta_{YX}^2}{(k-1)(1-\eta_{YX}^2)}, \quad (6)$$

где  $n$  – объём выборки,  $k$  – число различных наблюдаемых значений случайной величины  $X$  в выборке. Если гипотеза  $H_0$  верна, то статистика (6) имеет распределение Фишера с числом степеней свободы  $\nu_1 = k-1$  и  $\nu_2 = n-k$ . Границу критического множества определяет квантиль  $F_{\alpha, \nu_1, \nu_2}$  ( $\alpha$  – уровень значимости). Гипотеза  $H_0$  отвергается, если выборочное значение статистики  $W$  принадлежит критическому множеству, т. е. если  $W_{\epsilon} > F_{\alpha, \nu_1, \nu_2}$ .

При проверке гипотезы  $H_0$  о наличии *линейной* корреляционной связи между случайными величинами  $Y$  и  $X$  используется статистика

$$W^* = \frac{(n-k)(\eta_{YX}^2 - r_6^2)}{(k-2)(1-\eta_{YX}^2)}, \quad (7)$$

имеющая при справедливости гипотезы  $H_0$  распределение Фишера с  $\nu_1 = k-2$  и  $\nu_2 = n-k$  степенями свободы.

**Пример 12.** Данные 15 наблюдений над двумерной случайной величиной  $(X, Y)$  представлены в таблице:

$x_i$	2	4	9	13	15
$y_{ij}$	1, 3, 4	7, 8, 12	14, 19, 21	11, 9, 6	8, 7, 3

Проверить гипотезу об отсутствии корреляционной зависимости  $Y$  от  $X$  при уровне значимости  $\alpha = 0,05$ .

*Решение.* Имеем  $k=5$ ,  $n=15$ ,  $n_i=3$  ( $i=1,2,3,4,5$ ). Находим

$$\bar{y}_1 = \frac{1+3+4}{3} \approx 2,67, \quad \bar{y}_2 = \frac{7+8+12}{3} = 9, \quad \bar{y}_3 = \frac{14+19+21}{3} = 18,$$

$$\bar{y}_4 = \frac{11+9+6}{3} \approx 8,67, \quad \bar{y}_5 = \frac{8+7+3}{3} = 6;$$

$$\bar{y} = \frac{1}{15} \sum_{i=1}^k \sum_{j=1}^{n_i} y_{ij} = \frac{133}{15} \approx 8,87;$$

$$\begin{aligned} s_{\bar{y}}^2 &= \frac{1}{n} \sum_{i=1}^k (\bar{y}_i - \bar{y})^2 n_i = \\ &= \frac{(2,67-8,87)^2 + (9-8,87)^2 + (18-8,87)^2 + (8,67-8,87)^2 + (6-8,87)^2}{5} = \\ &= \frac{(-6,2)^2 + 0,13^2 + 9,13^2 + (-0,2)^2 + (-2,87)^2}{5} = \\ &= \frac{38,44 + 0,0169 + 83,3569 + 0,04 + 8,2369}{5} = \frac{130,0907}{5} = 26,01814; \end{aligned}$$

$$s_Y^2 = \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} y_{ij}^2 - (\bar{y})^2 = \frac{1641}{15} - 8,87^2 = 30,7231.$$

Тогда

$$\eta_{YX}^2 = \frac{26,01814}{30,7231} \approx 0,8469.$$

Вычисляем далее

$$W_6 = \frac{(n-k)\eta_{YX}^2}{(k-1)(1-\eta_{YX}^2)} = \frac{10 \cdot 0,8469}{4 \cdot (1-0,8469)} \approx 13,83$$

По таблице квантилей распределения Фишера находим  $F_{0,05;4;10} = 3,48$ .

Как видим,  $W_e > F_{0,05;4;10}$ . Следовательно, нулевую гипотезу об отсутствии корреляционной зависимости  $Y$  от  $X$  отвергаем. Таким образом, корреляционная зависимость  $Y$  от  $X$  существует. ●

**Пример 13.** В условиях примера 12 проверить гипотезу о наличии линейной корреляционной зависимости  $Y$  от  $X$  при уровне значимости  $\alpha = 0,05$ .

*Решение.* Находим

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k x_i n_i = \frac{43}{5} = 8,6; \quad \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} x_i y_{ij} = \frac{1218}{15} = 81,2;$$

$$s_X^2 = \frac{1}{n} \sum_{i=1}^k x_i^2 n_i - (\bar{x})^2 = 99 - 8,6^2 = 25,04.$$

Тогда

$$r_e^2 = \frac{\left( \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} x_i y_{ij} - \bar{x} \cdot \bar{y} \right)^2}{s_X^2 s_Y^2} = \frac{(81,2 - 8,6 \cdot 8,87)^2}{25,04 \cdot 30,7231} \approx 0,0314.$$

Находим выборочное значение статистики (7):

$$W_e^* = \frac{(n-k)(\eta_{YX}^2 - r_e^2)}{(k-2)(1-\eta_{YX}^2)} = \frac{10(0,8469 - 0,0314)}{3(1-0,8469)} \approx 17,76.$$

По таблице квантилей распределения Фишера находим критическое значение  $F_{0,05;3;10} = 3,71$ .

Так как  $W_e^* > F_{0,05;3;10}$ , то гипотезу о наличии линейной корреляционной зависимости  $Y$  от  $X$  следует отклонить. ●

## Задачи для самостоятельного решения

### Задачи к пунктам 1-3

1. Имеются результаты измерения длины (в мм) 30 случайно отобранных заготовок:

39, 41, 40, 40, 43, 41, 44, 42, 41, 41, 43, 42, 39, 40, 42,  
43, 41, 42, 41, 39, 42, 41, 42, 40, 41, 43, 41, 39, 40, 41.

Составить вариационный и статистический ряды данной выборки. Построить полигон частот.

2. Измерения ёмкости у 80 транзисторов дали следующие результаты:

1,9 3,1 1,3 0,7 3,2 1,1 2,9 2,7 2,7 4,0  
1,7 3,2 0,9 0,8 3,1 1,2 2,6 1,9 2,3 3,2  
4,1 1,3 2,4 4,5 2,5 0,9 1,4 1,6 2,2 3,1  
1,5 1,1 2,3 4,3 2,1 0,7 1,2 1,5 1,8 2,9  
0,8 0,9 1,7 4,1 4,3 2,6 0,9 0,8 1,2 2,1  
3,2 2,9 1,1 3,2 4,5 2,1 3,1 5,1 1,1 1,9  
0,9 3,1 0,9 3,1 3,3 2,8 2,5 4,0 4,3 1,1  
2,1 3,8 4,6 3,8 2,3 3,9 2,4 4,1 4,2 0,9

Построить гистограмму относительных частот по этой выборке, предварительно проведя группировку. В качестве длины интервала группировки взять следующие значения:

а)  $\Delta = 0,3$ ; б)  $\Delta = 1,2$ .

3. Найти эмпирическую функцию распределения и начертить ее график для выборки, представленной следующим статистическим рядом:

$x_i$	39	40	41	42	43	44
$n_i$	4	5	9	7	4	1

4. Построить гистограмму частот для выборки, представленной следующим интервальным статистическим рядом:

$x_{i-1} - x_i$	10 - 20	20 - 30	30 - 40	40 - 50	50 - 60	60 - 70	70 - 80
$n_i$	1	2	7	18	12	8	2

5. Найти среднее и дисперсию выборки, представленной следующим интервальным статистическим рядом:

$x_{i-1} - x_i$	1 - 3	3 - 5	5 - 7	7 - 9	9 - 11	11 - 13
$n_i$	1	2	4	2	1	1

6. Доказать следующие свойства выборочного среднего:

а)  $\sum_{i=1}^n (x_i - \bar{x}) = 0;$

б)  $\sum_{i=1}^n (x_i - \bar{x})^2 < \sum_{i=1}^n (x_i - a)^2$ , где  $a \in \mathbf{R}$ ,  $a \neq \bar{x}$ .

#### Задачи к пункту 4

7. Пусть  $\tilde{\theta}$  – несмещенная оценка параметра  $\theta$ ,  $D(\tilde{\theta}) < \infty$ . Показать, что  $(\tilde{\theta})^2$  является смещенной оценкой  $\theta^2$ , и вычислить смещение.

8. Доказать, что выборочная дисперсия  $S^2$  является состоятельной оценкой дисперсии наблюдаемой случайной величины  $X$ .

9. Показать, что значение эмпирической функции распределения  $F_n^*(x)$  в точке  $x$  является несмещенной и состоятельной оценкой значения теоретической функции распределения  $F(x)$  в той же точке.

10. Показать, что выборочное среднее  $\bar{x}$  является эффективной оценкой параметра  $\lambda$  распределения Пуассона.

11. Показать, что относительная частота  $\frac{k}{n}$  появления события  $A$  в  $n$  независимых испытаниях является эффективной оценкой вероятности  $p$  появления события  $A$  в одном испытании.

12. По выборке объема  $n$  из нормально распределенной генеральной совокупности с параметрами  $m$  и  $\sigma$  ( $m$  известно) оценивается дисперсия  $\sigma^2$ . Показать, что статистика

$$S_1^2 = \frac{1}{n} \sum_{i=1}^n (X_i - m)^2$$

является эффективной оценкой  $\sigma^2$ .

13. Пусть  $x_1, x_2, \dots, x_n$  – выборка из генеральной совокупности с показательной плотностью распределения

$$p(x, \theta) = \begin{cases} (1/\theta)e^{-x/\theta} & \text{при } x \geq 0, \\ 0 & \text{при } x < 0, \end{cases}$$

где  $\theta > 0$ . Показать, что  $\bar{x}$  является эффективной оценкой параметра  $\theta$ .

14. Пусть  $x_1, x_2, \dots, x_n$  – выборка из нормально распределенной генеральной совокупности с параметрами  $m$  и  $\sigma$ . Найти информацию Фишера  $J_n(\sigma^2)$ .

#### Задачи к пункту 5

15. Найти оценку максимального правдоподобия параметра  $\lambda$  распределения Пуассона.

16. Найти оценку максимального правдоподобия параметра  $\theta > 0$  показательного распределения с плотностью

$$p(x, \theta) = \begin{cases} (1/\theta)e^{-x/\theta} & \text{при } x \geq 0, \\ 0 & \text{при } x < 0. \end{cases}$$

17. Случайная величина  $X$  имеет плотность распределения

$$p(x) = \begin{cases} kx & \text{при } x \in [0, \sqrt{2/k}], \\ 0 & \text{при } x \notin [0, \sqrt{2/k}]. \end{cases}$$

Найти оценку максимального правдоподобия математического ожидания случайной величины  $X$  по выборке объема  $n$ .

18. Найти оценку максимального правдоподобия параметра  $\theta$  равномерного на отрезке  $[0, \theta]$  распределения.

19. Случайная величина  $X$  имеет равномерное на отрезке  $[a, b]$  распределение. Методом моментов найти оценки неизвестных параметров  $a$  и  $b$ .

20. Используя метод моментов, найти оценки неизвестных параметров  $a > 0$  и  $b > 0$  для гамма-распределения с плотностью

$$p(x) = \begin{cases} \frac{b^a}{\Gamma(a)} x^{a-1} e^{-bx} & \text{при } x > 0, \\ 0 & \text{при } x \leq 0. \end{cases}$$

### Задачи к пункту 7

21. По выборке объема  $n=64$  найдена средняя длина детали  $\bar{x}=50$  мм. Считая, что длина детали  $X$  – нормально распределенная случайная величина, найти доверительный интервал, который с доверительной вероятностью  $1-\alpha=0,95$  покрывает неизвестное математическое ожидание  $m$  длины детали, если генеральное среднее квадратическое отклонение  $\sigma=0,5$  мм.

22. Имеется выборка объема 12 из нормально распределённой генеральной совокупности:

№ элемента выборки	1	2	3	4	5	6	7	8	9	10	11	12
Наблюдённое значение	-0,5	1,2	0	0,8	1,2	-0,4	0,2	-0,2	1,5	0,6	-0,4	1,0

Найти доверительный интервал с вероятностью  $1-\alpha=0,95$  для ее математического ожидания.

23. Из нормально распределенной генеральной совокупности извлечена выборка объема  $n = 10$ . Результаты приведены в таблице:

Наблюдаемое значение ( $x_i$ )	-2	1	2	3	4	5
Частота ( $n_i$ )	2	1	2	2	2	1

Найти доверительный интервал для математического ожидания  $m$  генеральной совокупности. Доверительную вероятность  $1 - \alpha$  принять равной 0,95.

**24.** Найти минимальный объем выборки, на основании которой можно было бы оценить математическое ожидание времени исполнения некоторой технической операции с ошибкой, не превышающей 10 с, и надежностью  $1 - \alpha = 0,95$ , если предположить, что время исполнения этой технической операции  $X$  является нормально распределенной случайной величиной, имеющей среднее квадратическое отклонение  $\sigma = 50$  с.

**25.** Систематические ошибки измерительного прибора практически равны нулю, а случайные распределены нормально со средним квадратическим отклонением  $\sigma = 20$  м. Необходимо, чтобы абсолютное значение разности между оценкой измеряемой величины и истинным ее значением не превосходило 10 м. Определить, с какой вероятностью будет выполнено это условие, если число наблюдений равно 25.

**26.** По независимым выборкам  $x_1, x_2, \dots, x_n$  и  $y_1, y_2, \dots, y_n$  из двух нормально распределенных генеральных совокупностей с параметрами  $(m_1, \sigma_1)$  и  $(m_2, \sigma_2)$  соответственно построить доверительный интервал с доверительной вероятностью  $1 - \alpha$  для разности  $m_1 - m_2$ , если  $\sigma_1$  и  $\sigma_2$  известны.

**27.** Построить доверительный интервал с вероятностью  $1 - \alpha = 0,95$  для дисперсии  $\sigma^2$  нормально распределенной случайной величины  $X$ , если исправленная выборочная дисперсия  $s_0^2 = 10$ , а объем выборки  $n = 20$ .

**28.** Из партии однотипных сопротивлений отобрано для контроля 10 штук. Измерения дали следующие отклонения от номинала (в килоомах):

№ сопротивления	1	2	3	4	5	6	7	8	9	10
Отклонение	+1	+2	-2	+2	+4	+2	+5	+3	-2	+10

Считая, что отклонение сопротивления от номинала  $X$  – нормально распределенная случайная величина, найти доверительные интервалы для математического ожидания  $m$  и дисперсии  $\sigma^2$  этого отклонения. Доверительную вероятность  $1 - \alpha$  принять равной 0,95.

## Задачи к пункту 8

**29.** По паспортным данным автомобильного двигателя расход топлива на 100 км пробега составляет 10 л. В результате изменения конструкции двигателя ожидается, что расход топлива уменьшится. Для проверки проводятся испытания 25 случайно отобранных автомобилей с модернизированным двигателем, причем выборочное среднее расходов топлива на 100 км пробега по результатам испытаний составило  $\bar{x}=9,3$  л. Предполагается, что выборка расходов топлива получена из нормально распределенной генеральной совокупности с дисперсией  $\sigma^2=4$  л<sup>2</sup>. Проверить гипотезу, утверждающую, что изменение конструкции двигателя не повлияло на расход топлива. Уровень значимости принять равным 0,05.

**30.** Автомат производит болты с номинальным значением контролируемого размера  $m_0 = 40$  мм. Результаты предыдущих измерений дают основание предполагать, что действительные размеры болтов образуют нормально распределенную совокупность с дисперсией  $\sigma^2=1$  мм<sup>2</sup>. Партия болтов бракуется, если среднее выборочное контролируемого размера будет больше 40,1 мм. Найти вероятность ошибок первого и второго рода при альтернативной гипотезе  $H_1: m = 40,3$  мм, если решение принимается по выборке объема  $n = 36$ .

**31.** Техническая норма предусматривает в среднем 40 с на выполнение определенной технической операции. От работников поступили сигналы, что они в действительности затрачивают на эту операцию больше времени. Для проверки произведены измерения времени выполнения операции у 16 работников и получены следующие результаты:  $\bar{x}=42$  с (среднее время выполнения операции),  $s_0=3,5$  с (исправленное среднее квадратическое отклонение). Предполагается, что распределение контролируемого промежутка времени является нормальным. Можно ли по имеющимся хронометрическим данным на уровне значимости  $\alpha = 0,01$  отклонить гипотезу о том, что действительное среднее время исполнения данной технической операции соответствует норме?

**32.** Для нормально распределенной случайной величины проверяется нулевая гипотеза о математическом ожидании  $H_0: m = 10$  при альтернативной гипотезе  $H_1: m = 9$ . Известна дисперсия распределения:  $\sigma^2=4$ . Какой минимальный объем выборки  $n$  следует взять, чтобы ошибка первого рода была равна  $\alpha = 0,01$ , а ошибка второго рода не превышала 0,1?

**33.** Выборка 50 электроламп завода  $A$  показала среднюю продолжительность работы  $\bar{x}_A=1282$  ч, а такая же по объему выборка того же типа ламп завода  $B$  —  $\bar{x}_B=1208$  ч. Предполагается, что продолжительности работы электроламп, выпускаемых заводами  $A$  и  $B$ , являются нормально распределенными случайными величинами со средними квадратическими от-

клонениями  $\sigma_A=80$  ч и  $\sigma_B=94$  ч соответственно. Проверить гипотезу о том, что эти заводы выпускают лампы одинакового качества (средний срок службы ламп обоих заводов одинаков). Уровень значимости принять равным 0,05.

**34.** При обработке втулок на станке-автомате было отобрано две пробы по 10 штук деталей в каждой. Результаты измерения диаметров этих втулок в порядке обработки указаны в следующей таблице:

№ детали	1	2	3	4	5	6	7	8	9	10
Проба 1	2,066	2,063	2,068	2,060	2,067	2,063	2,059	2,062	2,062	2,060
Проба 2	2,063	2,060	2,057	2,056	2,059	2,058	2,062	2,059	2,059	2,057

Предполагается, что выборки диаметров втулок получены из нормально распределенных генеральных совокупностей с одинаковыми средними квадратическими отклонениями. Проверить гипотезу о том, что средние (математические ожидания) генеральных совокупностей в моменты выбора обеих проб равны, т. е. что режим работы станка от пробы к пробе не изменился. Уровень значимости принять равным 0,05.

**35.** Выдвинута гипотеза, что применение нового типа резца сокращает время обработки некоторой детали. Проведено 10 измерений времени, затрачиваемого на обработку этой детали старым и новым резцами. Получены следующие результаты (в минутах): старый тип резца — 58, 58, 56, 38, 70, 38, 42, 75, 68, 67; новый тип резца — 57, 55, 63, 24, 67, 43, 33, 68, 56, 54. Предполагается, что время обработки детали старым и новым резцами — случайные величины, имеющие нормальные распределения с равными средними квадратическими отклонениями. Проверить гипотезу равенства среднего времени, затрачиваемого на изготовление детали с помощью двух типов резцов. Уровень значимости принять равным 0,05.

**36.** Точность работы станка-автомата проверяется по дисперсии контролируемого размера деталей, которая не должна превышать  $\sigma_0^2 = 0,04$ . Взята проба из 11 случайно отобранных деталей, и получены следующие результаты (в мм): 100,6; 99,6; 100,0; 100,1; 100,3; 100,0; 99,9; 100,2; 100,4; 100,6; 100,5. Предполагается, что распределение контролируемого размера является нормальным. На основании имеющихся данных проверить, обеспечивает ли станок заданную точность. Уровень значимости принять равным 0,05.

**37.** До наладки станка была проверена точность изготовления 10 втулок и найдено значение исправленной выборочной дисперсии  $s_{01}^2 = 9,6$  мкм<sup>2</sup>. После наладки подверглись контролю еще 15 втулок и получено новое значение исправленной выборочной дисперсии  $s_{02}^2 = 5,7$  мкм<sup>2</sup>. Предполагается, что контролируемый размер втулки имеет нормальное

распределение. Можно ли считать, что в результате наладки станка точность изготовления деталей увеличилась? Принять  $\alpha = 0,15$ .

**38.** При измерении производительности двух агрегатов получены следующие результаты (в кг вещества за час работы):

№ замера	1	2	3	4	5
Агрегат <i>A</i>	14,1	10,1	14,7	13,7	14,0
Агрегат <i>B</i>	14,0	14,5	13,7	12,7	14,1

Можно ли считать, что производительности агрегатов *A* и *B* одинаковы, в предположении, что обе выборки получены из нормально распределённых генеральных совокупностей? Принять  $\alpha = 0,10$ .

**39.** Из нормально распределённых генеральных совокупностей с параметрами  $(m_1, \sigma)$  и  $(m_2, \sigma)$  получены две выборки объёмов  $n_1$  и  $n_2$  соответственно. Предлагается отклонить гипотезу  $H_1: m_1 = m_2$ , если доверительные интервалы для  $m_1$  и  $m_2$  не пересекаются. Показать, что при доверительной вероятности  $1 - \alpha$  уровень значимости этого критерия меньше  $\alpha$ .

#### Задачи к пункту 9

**40.** При 50 подбрасываниях монеты герб появился 20 раз. Можно ли считать монету симметричной? Принять  $\alpha = 0,10$ .

**41.** При 120 бросаниях игральной кости шестерка выпала 40 раз. Согласуется ли этот результат с утверждением, что кость правильная? Принять  $\alpha = 0,05$ .

**42.** На экзамене студент отвечает только на один вопрос по одной из трех частей курса. Анализ вопросов, заданных 60 студентам, показал, что 23 студента получили вопросы из первой, 15 — из второй и 22 — из третьей части курса. Можно ли считать, что студент, идущий на экзамен, с равной вероятностью получит вопрос по любой из трех частей курса? Принять  $\alpha = 0,10$ .

**43.** Приведены данные о фактических объёмах сбыта (в условных единицах) в пяти районах:

Район	1	2	3	4	5
Фактический объём сбыта	110	130	70	90	100

Согласуются ли эти результаты с предположением о том, что сбыт продукции в этих районах должен быть одинаковым? Принять  $\alpha = 0,01$ .

**44.** Приведены данные об отказах аппаратуры за 10 000 часов работы (всего обследовано  $n = 757$  экземпляров):

Число отказов, $k$	0	1	2	3	4	5	$\geq 6$
Количество случаев, в которых наблюдалось $k$ отказов, $n_k$	427	235	72	21	1	1	0

Проверить гипотезу  $H_0$  о том, что число отказов имеет распределение Пуассона, при  $\alpha=0,10$ .

45. Произведены 500 измерений боковой ошибки наводки при стрельбе с самолета по наземной цели. Результаты измерений (в тысячных долях радиана) сведены в статистический ряд:

$x_{i-1} \div x_i$	$-4 \div -3$	$-3 \div -2$	$-2 \div -1$	$-1 \div 0$	$0 \div 1$	$1 \div 2$	$2 \div 3$	$3 \div 4$
$n_i$	6	25	72	133	120	88	46	10

С помощью критерия  $\chi^2$  Пирсона проверить гипотезу  $H_0$  о том, что измерения подчиняются нормальному распределению при  $\alpha=0,01$ .

46. Выборка представлена следующим интервальным статистическим рядом:

$x_{i-1} - x_i$	3,0–3,6	3,6–4,2	4,2–4,8	4,8–5,4	5,4–6,0	6,0–6,6	6,6–7,2
$n_i$	2	8	35	43	22	15	5

При уровне значимости  $\alpha = 0,01$  проверить гипотезу о нормальном распределении генеральной совокупности.

47. Выборка представлена интервальным статистическим рядом:

$x_{i-1} - x_i$	0 – 5	5 – 10	10 – 15	15 – 20	20 – 25	25 – 30
$n_i$	133	45	15	4	2	1

При уровне значимости  $\alpha = 0,05$  проверить гипотезу о показательном распределении генеральной совокупности.

### Задачи к пунктам 10, 11

48. По данным выборки вычислить коэффициент корреляции и найти уравнения прямых регрессий  $Y$  на  $X$  и  $X$  на  $Y$ . Изобразить эти прямые на корреляционном поле.

$x_i$	8	10	5	8	9
$y_i$	1	3	1	2	3

49. Вычислить коэффициент корреляции и найти уравнения прямых регрессий  $Y$  на  $X$  и  $X$  на  $Y$  по данным, приведенным в следующей корреляционной таблице:

$X \backslash Y$	5 – 15	15 – 25	25 – 35	35 – 45	45 – 55	55 – 65
10 – 20	5	7				
20 – 30		20	23			
30 – 40			30	47	2	
40 – 50			10	11	20	6
50 – 60				9	7	3

**50.** По выборке объема  $n = 122$ , извлеченной из нормальной двумерной совокупности  $(X, Y)$ , найден выборочный коэффициент корреляции  $r_g = 0,4$ . При уровне значимости  $0,05$  проверить нулевую гипотезу о равенстве нулю генерального коэффициента корреляции  $r_T$  при конкурирующей гипотезе  $H_1: r_T \neq 0$ .

**51.** Какое наименьшее значение выборочного коэффициента корреляции следует считать значимым на  $5\%$ -ном уровне значимости (т. е. при  $\alpha = 0,05$ ), если объем выборки  $n = 38$ ? Предполагается, что выборка извлечена из нормально распределенной двумерной генеральной совокупности

**52.** Найти выборочное уравнение регрессии  $\bar{y}_x = ax^2 + bx + c$  по данным корреляционной таблицы

$X \backslash Y$	25	45	110
2	20		
3		30	1
5		1	48

**53.** Найти выборочное уравнение регрессии  $Y$  на  $X$  вида  $\bar{y}_x = b + \frac{a}{x}$  по данным корреляционной таблицы

$X \backslash Y$	3,4–3,8	3,8–4,2	4,2–4,6	4,6–5,0	5,0–5,4	5,4–5,8	5,8–6,2	6,2–6,6
4 – 6						2	3	3
6 – 8				3	3	2		1
8 – 10			1	1	2	1	1	
10 – 12		1	4	3				
12 – 14		1	2	3				
14 – 16		3	2					
16 – 18	2	2						
18 – 20	3	1						

**54.** Для совокупности 50 однотипных предприятий исследуется зависимость между величиной основных производственных фондов  $X$  (млн. руб.) и суточной выработкой продукции  $Y$  (т).

Величина ОПФ, млн. руб.(X)	Средины интервалов	Суточная выработка продукции, т (Y)					Всего $n_i$
		7 – 11	11 – 15	15 – 19	19 – 23	23 – 27	
	$y_j \backslash x_i$	9	13	17	21	25	
20 – 25	22,5	2	1	–	–	–	3
25 – 30	27,5	3	6	4	–	–	13
30 – 35	32,5	–	3	11	7	–	21
35 – 40	37,5	–	1	2	6	2	13
40 – 45	42,5	–	–	–	1	1	2
Всего $n_i$		5	11	17	14	3	

Вычислить выборочный коэффициент корреляции  $r_e$  и статистическое корреляционное отношение  $\eta_{YX}$ . При уровне значимости  $\alpha=0,05$  проверить гипотезу о наличии линейной корреляционной связи между случайными величинами  $X$  и  $Y$ .

## Литература

1. Бородич, С.М. Теория вероятностей и математическая статистика : методические рекомендации / С.М. Бородич, Т.В. Кавитова. – Витебск : ВГУ имени П.М. Машерова, 2015. – 51 с.
2. Бородич, С.М. Теория вероятностей и математическая статистика : методические рекомендации / С.М. Бородич, Т.В. Кавитова. – Витебск : ВГУ имени П.М. Машерова, 2017. – 52 с.
3. Бочаров, П.П. Теория вероятностей. Математическая статистика / П.П. Бочаров, А.В. Печинкин. – 2-е изд. – М.: ФИЗМАТЛИТ, 2005. – 296 с.
4. Герасимович, А.И. Математическая статистика / А.И. Герасимович, Я.И. Матвеева. – Минск: Выш. шк., 1978. – 200 с.
5. Гмурман, В.Е. Теория вероятностей и математическая статистика: учеб. пособие для вузов / В.Е. Гмурман. – 9-е изд., стер. – М.: Высш. шк., 2003. – 479 с.
6. Гмурман, В.Е. Руководство к решению задач по теории вероятностей и математической статистике: учеб. пособие для студентов вузов / В.Е. Гмурман. – 9-е изд., стер. – М.: Высш. шк., 2004. – 404 с.
7. Емельянов, Г.В. Задачник по теории вероятностей и математической статистике: учеб. пособие / Г.В. Емельянов, В.П. Скитович. – 2-е изд., стер. – СПб. [и др.]: Лань, 2007. – 332 с.
8. Кремер, Н.Ш. Теория вероятностей и математическая статистика: учебник для вузов / Н.Ш. Кремер. – 2-е изд., перераб. и доп. – М.: ЮНИТИ-ДАНА, 2004. – 573 с.
9. Кремлёв, А.Г. Математика. Раздел “Статистика” : учеб. пособие / А.Г. Кремлёв. – Екатеринбург: Изд-во УрГЮА, 2001. – 140 с.
10. Максимов, Ю.Д. Математика. Выпуск 8. Математическая статистика: опорный конспект / Ю.Д. Максимов. – СПб.: Изд-во СПбГПУ, 2002. – 96 с.
11. Севастьянов, Б.А. Курс теории вероятностей и математической статистики / Б.А. Севастьянов. – М.: Наука. Главная редакция физико-математической литературы, 1982. – 256 с.

Учебное издание

**БОРОДИЧ** Сергей Митрофанович

**КАВИТОВА** Татьяна Валерьевна

**МАТЕМАТИЧЕСКАЯ СТАТИСТИКА**

Методические рекомендации

Технический редактор

*Г.В. Разбоева*

Компьютерный дизайн

*Л.Р. Жигунова*

Подписано в печать 2020. Формат 60x84<sup>1/16</sup>. Бумага офсетная.

Усл. печ. л. 2,79. Уч.-изд. л. 1,56. Тираж экз. Заказ .

Издатель и полиграфическое исполнение – учреждение образования  
«Витебский государственный университет имени П.М. Машерова».

Свидетельство о государственной регистрации в качестве издателя,

изготовителя, распространителя печатных изданий

№ 1/255 от 31.03.2014.

Отпечатано на ризографе учреждения образования

«Витебский государственный университет имени П.М. Машерова».

210038, г. Витебск, Московский проспект, 33.