

Федеральное государственное бюджетное образовательное учреждение
высшего образования
«Ставропольский государственный аграрный университет»

Кафедра Математика

Составитель: доцент Литвин Д.Б.

**МЕТОДИЧЕСКИЕ УКАЗАНИЯ
ПО ВЫПОЛНЕНИЮ РГР №8
по дисциплине**

МАТЕМАТИКА

наименование дисциплины

21.03.02 Землеустройство

направление подготовки

Городской кадастр

профиль(и) подготовки

Бакалавр

Квалификация (степень) выпускника

Ставрополь, 2019

КОРРЕЛЯЦИОННЫЙ И РЕГРЕССИОННЫЙ АНАЛИЗ

1.1. Линейная корреляция

Если в результате осуществления некоторого эксперимента наблюдаются две величины X и Y , то *выборочный корреляционный момент (ковариация) $\mu_{x,y}^*$* величин X и Y определяется формулой:

$$\mu_{x,y}^* = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \bar{xy} - \bar{x} \cdot \bar{y} \quad (1)$$

где $(x_1, y_1), \dots, (x_n, y_n)$ — n пар наблюденных значений, полученных в n

независимых повторениях эксперимента, $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$, $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$.

Выборочный коэффициент корреляции r_B^ :*

$$r_B^* = \frac{\mu_{x,y}^*}{\sigma_x^* \cdot \sigma_y^*} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}, \quad (2)$$

где σ_x^* и σ_y^* — выборочные СКО

$$\sigma_x^* = \sqrt{D^*(X)} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}, \quad \sigma_y^* = \sqrt{D^*(Y)} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}.$$

Выборочные коэффициенты регрессий

$$Y \text{ на } X: \quad \rho_{y/x}^* = r_B^* \frac{\sigma_y^*}{\sigma_x^*} = \frac{\mu_{x,y}^*}{(\sigma_x^*)^2}; \quad (3)$$

$$X \text{ на } Y: \quad \rho_{x/y}^* = r_B^* \frac{\sigma_x^*}{\sigma_y^*} = \frac{\mu_{x,y}^*}{(\sigma_y^*)^2}. \quad (4)$$

Выборочные уравнения линейных регрессий (среднеквадратических)

$$Y \text{ на } X: \quad y - \bar{y} = \rho_{y/x}^* (x - \bar{x}) \quad \text{или} \quad \frac{y - \bar{y}}{\sigma_y^*} = r_B^* \frac{x - \bar{x}}{\sigma_x^*}, \quad (5)$$

$$X \text{ на } Y: \quad \frac{x - \bar{x}}{\sigma_x^*} = r_B^* \frac{y - \bar{y}}{\sigma_y^*} \quad \text{или} \quad \frac{y - \bar{y}}{\sigma_y^*} = \frac{1}{r_B^*} \frac{x - \bar{x}}{\sigma_x^*}. \quad (6)$$

Пример 3.1. Для выборки двумерной случайной величины

Таблица 3.1

i	1	2	3	4	5	6	7	8	9	10
x_i	1,2	1,5	1,8	2,1	2,3	3	3,6	4,2	5,7	6,3
y_i	4,6	5,8	7,3	10,4	12,30	14,4	14,9	14,8	15,2	16,5

вычислить выборочные средние наблюдаемых признаков, выборочные средние квадратические отклонения, выборочный коэффициент корреляции и составить выборочные уравнения линейных регрессий. Представить корреляционное поле и линейные регрессии на графике.

Решение.

Удобно исходную таблицу дополнить строкой $x_i y_i$ и столбцом ср.знач.

Таблица 3.2

i	1	2	3	4	5	6	7	8	9	10	ср.знач
x_i	1,2	1,5	1,8	2,1	2,3	3	3,6	4,2	5,7	6,3	3,17
y_i	4,6	5,8	7,3	10,4	12,30	14,4	14,9	14,8	15,2	16,5	11,62
$x_i y_i$	5,52	8,7	13,14	21,84	28,29	43,2	53,64	62,16	86,64	103,95	42,71

Тогда искомые выборочные параметры распределения

$$\bar{x}_B = \frac{1,2 + 1,5 + \dots + 6,3}{10} = 3,17; \quad \bar{y}_B = \frac{4,6 + 5,8 + \dots + 16,5}{10} = 11,62.$$

$$D_B(X) = 0,1(1,2^2 + 1,5^2 + \dots + 6,3^2) - 3,17^2 = 2,79; \quad \sigma_X = \sqrt{2,79} = 1,67.$$

$$D_B(Y) = 0,1(4,6^2 + 5,8^2 + \dots + 16,5^2) - 11,62^2 = 16,90; \quad \sigma_Y = \sqrt{16,90} = 4,11.$$

$$\frac{1}{10} \sum_{i=1}^{10} x_i y_i = \frac{1}{10} (1,2 \cdot 4,6 + 1,5 \cdot 5,8 + \dots + 6,3 \cdot 16,5) = 42,71.$$

$$\mu_{x,y}^* = 42,71 - 3,17 \cdot 11,62 = 5,87; \quad r_B^* = \frac{42,71 - 3,17 \cdot 11,62}{1,67 \cdot 4,11} = 0,85.$$

Выборочное уравнение линейной регрессии Y/X имеет вид (5):

$$y - 11,62 = 0,85 \cdot \frac{4,11}{1,67} (x - 3,17) \text{ или } y = 2,1x + 4,95.$$

Выборочное уравнение линейной регрессии X/Y имеет вид (6):

$$y - 11,62 = \frac{1}{0,85} \cdot \frac{4,11}{1,67} (x - 3,17) \text{ или } y = 2,88x + 2,45.$$

Поскольку линии регрессии прямые, то строим их по двум крайним точкам




Рисунок 3.1 - Линейные регрессии

Для вычисления корреляционного момента (ковариации) и коэффициента корреляции в табличном процессоре *Excel* используются функции *KOVAR(массив1; массив2)* и *KОРРЕЛ(массив1; массив2)* соответственно.

1.2. Нелинейная корреляция

При совместном исследовании двух случайных величин по имеющейся выборке $(x_1, y_1), (x_2, y_2), \dots, (x_k, y_k)$ возникает задача определения "наиболее подходящей", в том числе и нелинейной, зависимости между ними. Если вид функции $y = f(x, a, b, \dots)$ задан, то требуется найти такие значения коэффициентов a, b, \dots , при которых y_i "наименее" отличаются от $f(x_i)$. В качестве критерия оптимальности часто используют минимум суммы квадратов ошибок

$$\sum_{i=1}^k (y_i - f(x_i))^2 \rightarrow \min. \quad (7)$$

Коэффициенты a, b, \dots функции $y = f(x, a, b, \dots)$ и сама функция, обеспечивающие минимум критерия (7) называются оптимальными в смысле метода наименьших квадратов для этого класса функций. При этом, для другого класса функций, например $y = g(x, a, b, \dots)$, критерий (7) может принять значение еще более близкое к нулю. В этом случае функция $y = g(x, a, b, \dots)$, очевидно, лучше описывает статистическую взаимосвязь наблюдаемых признаков, нежели функция $y = f(x, a, b, \dots)$.

В качестве оценки тесноты нелинейной корреляционной связи используют коэффициент детерминации R^2 (корреляционное отношение),

который показывает долю объясненной изменением факторного признака дисперсии от общей дисперсии:

$$R^2 = \frac{\sigma_e^2}{\sigma^2} = 1 - \frac{\sigma_u^2}{\sigma^2}, \quad (8)$$

где $\sigma^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 = \frac{1}{n} \sum_{i=1}^n \Delta y_i^2$ - общая (total) дисперсия

результативного признака y_i - относительно общей средней \bar{y} .

$$\sigma_e^2 = \frac{1}{n} \sum_{i=1}^n (f(x_i) - \bar{y})^2 = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad \text{- объясненная (межгрупповая, explained)}$$

дисперсия - дисперсия точек линии регрессии $f(x_i)$ относительно общей средней \bar{y} ;

$$\sigma_u^2 = \frac{1}{n} \sum_{i=1}^n (y_i - f(x_i))^2 = \frac{1}{n} \sum_{i=1}^n u_i^2 \quad \text{- остаточная (внутригрупповая, unexplained) дисперсия - дисперсия признака } y_i \text{ относительно модельной линии регрессии } f(x_i).$$

Смысл коэффициента детерминации поясняется на рисунке 3.1.

$$\text{Здесь } y_i - \bar{y} = \Delta y_i = (y_i - y_x) + (y_x - \bar{y}) = u_i + e_i.$$

Доказывается, что $\sum \Delta y_i = \sum u_i + \sum e_i$, т.к. $2 \sum u_i e_i = 0$.




Рисунок 3.1 -
К пояснению суммы дисперсий

Поэтому имеет место *правило сложения дисперсий* - общая дисперсия σ^2 результативного признака равна сумме объясненной (межгрупповой) σ_e^2 и остаточной (необъясненной, внутригрупповой) σ_u^2 дисперсий:

$$\sigma^2 = \sigma_e^2 + \sigma_u^2 \quad (9)$$

Из выражения (8) следует пределы изменения значений R^2 :

$$0 \leq R^2 \leq 1.$$

Рассмотрим методику определения оптимальных по методу наименьших квадратов (МНК) параметров для некоторых классов функций (модельных регрессий).

а) Пусть модельной линией регрессии является линейная зависимость

$$y(x) = a_0 + a_1 x.$$

В качестве критерия тесноты корреляционной связи используем сумму квадратов отклонений значений признака y_i относительно линии регрессии $y(x_i)$

$$F(a_0, a_1) = \sum_{i=1}^n (y_i - (a_0 + a_1 x_i))^2 \rightarrow \min.$$

Определим неизвестные параметры регрессии (a_0, a_1) из условия минимума $F(a_0, a_1)$: $F'_{a_0} = F'_{a_1} = 0$.

$$F'_{a_0} = 2 \sum (y_i - a_0 - a_1 x_i) \cdot (-1) = 0; \quad \sum (-y_i + a_0 + a_1 x_i) = 0;$$

$$\sum y_i = n \cdot a_0 + a_1 \sum x_i; \quad \bar{y} = a_0 + \bar{x} \cdot a_1.$$

$$F'_{a_1} = 2 \sum (y_i - a_0 - a_1 x_i) \cdot (-x_i) = 0; \quad \sum (-x_i y_i + a_0 x_i + a_1 x_i^2) = 0;$$

$$\sum x_i y_i = a_1 \sum x_i^2 + a_0 \sum x_i; \quad \bar{xy} = \bar{x} \cdot a_0 + \bar{x^2} \cdot a_1.$$

$$\begin{cases} \bar{y} = a_0 + \bar{x} \cdot a_1 \\ \bar{xy} = \bar{x} \cdot a_0 + \bar{x^2} \cdot a_1 \end{cases} \text{ или } \begin{pmatrix} \bar{y} \\ \bar{xy} \end{pmatrix} = \begin{pmatrix} 1 & \bar{x} \\ \bar{x} & \bar{x^2} \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \end{pmatrix}. \quad (10)$$

б) Квадратичная зависимость $y(x) = a_0 + a_1 x + a_2 x^2$. Приравнивая частные производные суммы квадратов ошибок к нулю, по аналогии с пунктом а) получим:

$$\begin{pmatrix} \bar{y} \\ \bar{xy} \\ \bar{x^2y} \end{pmatrix} = \begin{pmatrix} 1 & \bar{x} & \bar{x^2} \\ \bar{x} & \bar{x^2} & \bar{x^3} \\ \bar{x^2} & \bar{x^3} & \bar{x^4} \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \\ a_2 \end{pmatrix}. \quad (11)$$

в) Логарифмическая зависимость $y(x) = a_0 + a_1 \ln x$. Вводя новую переменную $z = \ln x$ приводим логарифмическую зависимость к линейной. Тогда на основании выражений (10) получим:

$$\begin{cases} \bar{y} = a_0 + \bar{z} \cdot a_1 \\ \bar{zy} = \bar{z} \cdot a_0 + \bar{z}^2 \cdot a_1 \end{cases} \text{ или } \begin{pmatrix} \bar{y} \\ \bar{zy} \end{pmatrix} = \begin{pmatrix} 1 & \bar{z} \\ \bar{z} & \bar{z}^2 \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \end{pmatrix}. \quad (12)$$

Пример 3.2. Найти параметры и построить линии регрессий y от x для выборки из предыдущего примера 3.1 (табл.3.2) для случаев:

- 1) линейной зависимости $y(x) = a_0 + a_1 x$;
- 2) квадратичной зависимости $y(x) = a_0 + a_1 x + a_2 x^2$;
- 3) логарифмической зависимости $y(x) = a_0 + a_1 \ln x$.

Решение.

В соответствие с (10)- (12) дополним исходную таблицу необходимыми строками и последним столбцом - ср.знач. После заполнения таблица примет вид (вычисления проводились в MS Excel):

Таблица 3.3

i	1	2	3	4	5	6	7	8	9	10	ср.знач
x_i	1,2	1,5	1,8	2,1	2,3	3	3,6	4,2	5,7	6,3	3,17
y_i	4,6	5,8	7,3	10,4	12,30	14,4	14,9	14,8	15,2	16,5	11,62
xy	5,52	8,70	13,14	21,84	28,29	43,20	53,64	62,16	86,64	103,95	42,71
$(x^2)y$	6,62	13,05	23,65	45,86	65,07	129,60	193,10	261,07	493,85	654,89	188,68
x^2	1,44	2,25	3,24	4,41	5,29	9,00	12,96	17,64	32,49	39,69	12,84
x^3	1,73	3,38	5,83	9,26	12,17	27,00	46,66	74,09	185,19	250,05	61,53
x^4	2,07	5,06	10,50	19,45	27,98	81,00	167,96	311,17	1055,60	1575,30	325,61
$z=\ln x$	0,18	0,41	0,59	0,74	0,83	1,10	1,28	1,44	1,74	1,84	1,01
z^2	0,03	0,16	0,35	0,55	0,69	1,21	1,64	2,06	3,03	3,39	1,31
zy	0,84	2,35	4,29	7,72	10,24	15,82	19,09	21,24	26,46	30,37	13,84
$Y_{лин}$	7,48	8,11	8,74	9,37	9,79	11,26	12,52	13,79	16,94	18,20	11,62
$Y_{кв}$	4,79	6,59	8,23	9,73	10,65	13,36	15,04	16,13	16,31	15,36	11,62
$Y_{лог}$	5,56	7,18	8,51	9,63	10,30	12,23	13,56	14,68	16,91	17,63	11,62

Искомые векторы неизвестных параметров определим из систем линейных уравнений (10)- (12), например методом Крамера или матричным методом, с использованием последнего столбца таблицы 3.3.

В результате получим уравнения регрессий:

$$1) \begin{pmatrix} a_0 \\ a_1 \end{pmatrix} = \begin{pmatrix} 1 & 3,17 \\ 3,17 & 12,84 \end{pmatrix}^{-1} \cdot \begin{pmatrix} 11,62 \\ 42,71 \end{pmatrix} = \begin{pmatrix} 4,95 \\ 2,10 \end{pmatrix}; \quad \text{линейной } y(x) = 4,95 + 2,10x;$$

$$2) \begin{pmatrix} a_0 \\ a_1 \\ a_2 \end{pmatrix} = \begin{pmatrix} 1 & 3,17 & 12,84 \\ 3,17 & 12,84 & 61,53 \\ 12,84 & 61,53 & 325,61 \end{pmatrix}^{-1} \cdot \begin{pmatrix} 11,62 \\ 42,71 \\ 188,68 \end{pmatrix} = \begin{pmatrix} -3,84 \\ 8,17 \\ -0,81 \end{pmatrix};$$

квадратичной $y(x) = -3,84 + 8,17x - 0,81x^2;$

$$3) \begin{pmatrix} a_0 \\ a_1 \end{pmatrix} = \begin{pmatrix} 1 & 1,01 \\ 1,01 & 1,31 \end{pmatrix}^{-1} \cdot \begin{pmatrix} 11,62 \\ 13,84 \end{pmatrix} = \begin{pmatrix} 4,23 \\ 7,28 \end{pmatrix};$$

логарифмической $y(x) = 4,23 + 7,28 \ln x.$

Построим графики всех полученных уравнений регрессии по точкам x_i (последние строки в таблице 3.3), как показано на рисунке 3.3




Рисунок 3.3 - Корреляционное поле и линии регрессий

Пример 3.3. Определите общую, объясненную и остаточную дисперсии для рассмотренных уравнений регрессий, а также коэффициенты детерминации.

Решение.

Вычислим общую, объясненную и остаточную дисперсии для рассмотренных уравнений регрессий с помощью MS Excel. Для этого составим следующую таблицу:

Таблица 3.4

i	1	2	3	4	5	6	7	8	9	10	ср.знач
y_i	4,6	5,8	7,3	10,4	12,30	14,4	14,9	14,8	15,2	16,5	11,62
$Y_{\text{линей}} = y_{x1}$	7,48	8,11	8,74	9,37	9,79	11,26	12,52	13,79	16,94	18,20	11,62
$Y_{\text{KB}} = y_{x2}$	5,5	7,0	8,5	10,0	11,5	13,0	14,5	16,0	17,5	19,0	11,62

<i>i</i>	1	2	3	4	5	6	7	8	9	10	ср.знач
$Y_{\text{лог}} = y_{x3}$	5,56	7,18	8,51	9,63	10,30	12,23	13,56	14,68	16,91	17,63	11,62
$\Delta y_i = y_i - \bar{y}$	-7,02	-5,82	-4,32	-1,22	0,68	2,78	3,28	3,18	3,58	4,88	0,00
Δy_i^2	49,280	33,872	18,662	1,488	0,462	7,728	10,758	10,112	12,816	23,814	16,90
$e_1 = y_{x1} - \bar{y}$	-4,14	-3,51	-2,88	-2,25	-1,83	-0,36	0,90	2,17	5,32	6,58	0,00
$e_2 = y_{x2} - \bar{y}$	-6,83	-5,03	-3,39	-1,89	-0,97	1,74	3,42	4,51	4,69	3,74	0,00
$e_3 = y_{x3} - \bar{y}$	-6,06	-4,44	-3,11	-1,99	-1,32	0,61	1,94	3,06	5,29	6,01	0,00
e_1^2	17,17	12,34	8,30	5,06	3,35	0,13	0,82	4,69	28,32	43,34	12,35
e_2^2	46,58	25,32	11,46	3,55	0,93	3,02	11,68	20,38	22,00	13,95	15,89
e_3^2	36,73	19,68	9,66	3,94	1,75	0,37	3,76	9,38	27,94	36,17	14,94
$u_1 = y_i - y_{x1}$	-2,88	-2,31	-1,44	1,03	2,51	3,14	2,38	1,01	-1,74	-1,70	0,00
$u_2 = y_i - y_{x2}$	-0,19	-0,79	-0,93	0,67	1,65	1,04	-0,14	-1,33	-1,11	1,14	0,00
$u_3 = y_i - y_{x3}$	-0,96	-1,38	-1,21	0,77	2,00	2,17	1,34	0,12	-1,71	-1,13	0,00
u_1^2	8,27	5,32	2,07	1,06	6,30	9,84	5,64	1,03	3,03	2,90	4,55
u_2^2	0,04	0,62	0,87	0,44	2,71	1,09	0,02	1,78	1,23	1,31	1,01
u_3^2	0,92	1,92	1,47	0,59	4,01	4,70	1,80	0,01	2,91	1,29	1,96

Легко проверить выполнение правила сложения дисперсий (9):

$$\sigma_{\text{лии}}^2 = \sigma_{e1}^2 + \sigma_{u1}^2 = 12,35 + 4,55 = 16,90; \quad \sigma_{\text{кв}}^2 = \sigma_{e2}^2 + \sigma_{u2}^2 = 15,89 + 1,01 = 16,90;$$

$$\sigma_{\text{лог}}^2 = \sigma_{e3}^2 + \sigma_{u3}^2 = 14,94 + 1,96 = 16,90.$$

Коэффициенты детерминации примут значения (8):

$$R_{\text{лии}}^2 = \frac{\sigma_{e1}^2}{\sigma^2} = \frac{12,35}{16,90} = 0,73; \quad R_{\text{кв}}^2 = \frac{\sigma_{e2}^2}{\sigma^2} = \frac{15,89}{16,90} = 0,94;$$

$$R_{\text{лог}}^2 = \frac{\sigma_{e3}^2}{\sigma^2} = \frac{14,94}{16,90} = 0,88, \quad \text{где } \sigma^2 = \sigma_{\text{лии}}^2 = \sigma_{\text{кв}}^2 = \sigma_{\text{лог}}^2 = 16,90.$$

Максимальный коэффициент детерминации соответствует квадратичной регрессии, значит она и является наиболее удачной из рассмотренных.

2. ПРОВЕРКА СТАТИСТИЧЕСКИХ ГИПОТЕЗ

Под *статистической гипотезой* понимается всякое высказывание о генеральной совокупности (случайной величине X), проверяемое по выборочной совокупности (по результатам наблюдений).

Для проверки гипотезы определяют специальную величину (статистику) K с известным законом распределения, как функцию выборочных данных $K = K(x_1, x_2, \dots, x_n)$. Величину K называют *статистическим критерием*. Полагая, что распределение признака X подчинено гипотезе H_0 , рассчитывают область возможных значений (с заданной вероятностью) статистики K . Эта область *принятия основной гипотезы*. Критической называют область практически невозможных (с вероятностью α) значений статистики K , если верна гипотеза H_0 .

По имеющимся наблюдениям рассчитывают выборочное значение K . Если оно принадлежит критической области, то основную гипотезу отвергают.

Решение о том, можно ли считать гипотезу H_0 верной для генеральной совокупности, принимается по выборочным данным, т.е. по ограниченному объему информации. Следовательно, это решение может быть ошибочным. При этом может иметь место ошибка двух родов (рисунок 4.1):

- ошибка первого рода совершается при отклонении верной гипотезы H_0 . Вероятность такой ошибки называют *уровнем значимости критерия* $\alpha = P(H_1 / H_0)$;
- ошибка второго рода совершается при принятии неверной гипотезы H_1 . Вероятность ошибки второго рода обозначим как $\beta = P(H_0 / H_1)$.

Значение $1 - \beta = P(H_1 / H_1)$ - вероятность отвергнуть основную гипотезу когда она неверна, называют *мощностью критерия*.




Рисунок 4.1 - К проверке гипотез

Критическую область следует выбирать из условия обеспечения максимума мощности критерия при заданном уровне значимости. Критическая область может быть *левосторонней*, если она задается неравенством ($K < k_{kp}$), *двусторонней* ($k_{kp1} > K \cup K > k_{kp2}$) или *правосторонней* ($K > k_{kp}$) (рис. 4.2).




Рисунок 4.2 - Критические области

2.1. Проверка гипотез о числовых значениях

Проверка гипотезы о равенстве математического ожидания нормального распределения заданному значению

Проверка гипотезы о числовом значении МО при известной дисперсии.

Предполагается, что $X = N(a, \sigma^2)$, причем значение математического ожидания a неизвестно, а числовое значение дисперсии σ^2 известно.

По известной выборочной средней \bar{x} необходимо проверить при уровне значимости α нулевую гипотезу $H_0: a = a_0$ о том, что математическое ожидание генеральной совокупности a равно предполагаемому значению a_0 .

Если дисперсия генеральной совокупности известна (или неизвестна, но выборка достаточно большая $n > 30$), то в качестве критерия K проверки нулевой гипотезы принимают *z-статистику* - нормально распределенную случайную величину с параметрами $N(0;1)$.

Вычислим наблюдаемое значение *z-критерия*:

$$Z_{\text{набл}} = \frac{(\bar{x} - a_0)\sqrt{n}}{\sigma} = N(0;1).$$

Критическую точку z_{kp} определим в зависимости от альтернативной гипотезы (типа критической области) с использованием функции Лапласа (Приложение 2).

Правило 1. При конкурирующей гипотезе $H_1: a \neq a_0$, найдем критическую

точку z_{kp} двусторонней критической области из равенства

$$\Phi(z_{kp}) = \frac{1}{2} - \frac{\alpha}{2} = \frac{(1-\alpha)}{2}. \quad (13)$$

Если $|Z_{набл}| < z_{kp}$ нет оснований отвергнуть нулевую гипотезу. Если $|Z_{набл}| > z_{kp}$ - нулевую гипотезу отвергают.

Правило 2. При конкурирующей гипотезе $H_1: a > a_0$ критическую точку правосторонней критической области находят из равенства

$$\Phi(z_{kp}) = \frac{1}{2} - \alpha = \frac{(1-2\alpha)}{2}. \quad (14)$$

Если $Z_{набл} < z_{kp}$ нет оснований отвергнуть нулевую гипотезу. Если $Z_{набл} > z_{kp}$ - нулевую гипотезу отвергают.

Правило 3. При конкурирующей гипотезе $H_1: a < a_0$ сначала находят вспомогательную критическую точку z_{kp} , как в пункте 2), а затем полагают границу левосторонней критической области $z_{левост.kp} = -z_{kp}$.

Если $Z_{набл} > -z_{kp}$ - нет оснований отвергнуть нулевую гипотезу. Если $Z_{набл} < -z_{kp}$ - нулевую гипотезу отвергают.

Пример 574.

Из нормальной генеральной совокупности с известным средним квадратическим отклонением $\sigma = 5,2$ извлечена выборка объема $n=100$ и по ней найдена выборочная средняя $\bar{x} = 27,56$. Требуется при уровне значимости 0,05 проверить нулевую гипотезу $H_0: a = a_0 = 26$ при конкурирующей гипотезе $H_1: a \neq 26$.

Решение. Найдем наблюдаемое значение критерия:

$$z_{набл} = \frac{(\bar{x} - a_0)\sqrt{n}}{\sigma} = \frac{(27,56 - 26)\sqrt{100}}{5,2} = 3.$$

По условию, конкурирующая гипотеза имеет вид $a \neq a_0$, поэтому критическая область — двусторонняя. Найдем критическую точку из равенства (13)

$$\Phi(z_{kp}) = \frac{(1-\alpha)}{2} = \frac{(1-0,05)}{2} = 0,475.$$

По таблице функции Лапласа (см. приложение 2) находим $z_{kp} = 1,96$.


Так как $Z_{\text{набл}} > z_{\text{кр}}$ — нулевую гипотезу отвергаем. Другими словами, математическое ожидание генеральной совокупности α значимо отличается от гипотетического значения $a_0 = 26$.

В табличном процессоре Excel для проверки рассмотренной выше гипотезы используется функция ZTEST с обязательным указанием СКО. Обращение к ней имеет вид:

$$=\text{ZTEST}(\text{массив}; a_0; [\sigma]),$$

где *массив* — адреса ячеек, содержащих выборочные данные;

a_0 и σ — имеют прежний смысл, при этом, если параметр σ опущен, то используется исправленная выборочная дисперсия s , вычисленная по той же выборке.



Функция ZTEST численно равна вероятности того, что $P(X_0 > \bar{x})$, где $X_0 = N(a_0; \sigma)$ - гипотетическая случайная величина.

$$\text{ZTEST}(\text{массив}; a_0; [\sigma]) = P(X_0 > \bar{x}) = \gamma.$$

Проверка гипотезы о числовом значении МО при неизвестной дисперсии.

Предполагается, что $X = N(a, \sigma)$, значения математического ожидания a и дисперсии σ^2 неизвестны.

Если дисперсия генеральной совокупности неизвестна (например, в случае малых выборок), то в качестве критерия проверки нулевой гипотезы принимают *t-статистику* - случайную величину

$$K = T_{n-1} = \frac{(\bar{X}_e - a_0) \sqrt{n}}{s},$$

которая имеет распределение Стьюдента с числом степеней свободы $k = n - 1$.

Для того чтобы при заданном уровне значимости α проверить нулевую гипотезу $H_0: a = a_0$ о равенстве неизвестной генеральной средней a гипотетическому значению a_0 , вначале надо вычислить наблюдаемое значение критерия

$$T_{\text{набл}} = \frac{(\bar{x} - a_0) \sqrt{n}}{s}. \quad (15)$$

Затем, в зависимости от конкурирующей гипотезы определить критическую точку указанного распределения и критерий принятия гипотезы.

Правило 1. При конкурирующей гипотезе $H_1: a \neq a_0$, по заданному уровню значимости α , помещенному **в верхней строке таблицы** (прилож.5), и числу степеней свободы $k = n - 1$ найти критическую точку $t_{\text{двуст.кп}}(\alpha, k)$.

Если $|T_{\text{набл}}| < t_{\text{двуст.кп}}(\alpha, k)$ — нет оснований отвергнуть нулевую гипотезу.

Если $|T_{\text{набл}}| > t_{\text{двуст.кп}}(\alpha, k)$ — нулевую гипотезу отвергают.

Правило 2. При конкурирующей гипотезе $H_1: a > a_0$ по уровню значимости α , помещенному **в нижней строке таблицы** (в 2 раза меньше) приложения 5, и числу степеней свободы $k = n - 1$ находят критическую точку $t_{\text{правст.кп}}(\alpha, k)$ правосторонней критической области.

Если $T_{\text{набл}} < t_{\text{правст.кп}}(\alpha, k)$ — нет оснований отвергнуть нулевую гипотезу.

Если $T_{\text{набл}} > t_{\text{правст.кп}}(\alpha, k)$ — нулевую гипотезу отвергают.

Правило 3. При конкурирующей гипотезе $H_1: a < a_0$ сначала находят «вспомогательную» критическую точку (по правилу 2) $t_{\text{правст.кп}}(\alpha, k)$ и полагают границу левосторонней критической области $t_{\text{левост.кп}}(\alpha, k) = -t_{\text{правст.кп}}(\alpha, k)$.

Если $T_{\text{набл}} > -t_{\text{правст.кп}}(\alpha, k)$ — нет оснований отвергнуть нулевую гипотезу.

Если $T_{\text{набл}} < -t_{\text{правст.кп}}(\alpha, k)$ — нулевую гипотезу отвергают.

Примечание.

Для проверки указанной гипотезы можно применять критерий Стьюдента (Приложение 3), использовавшийся для интервального оценивания.

В этом случае

$$P(|T_{n-1}| < t_\gamma) = \gamma; \quad P(|T_{n-1}| > t_\gamma) = 1 - \gamma = \alpha. \quad (16)$$

Поэтому определим вероятность γ следующим образом:

для двусторонней критической области $1 - \gamma = \alpha \rightarrow \gamma = 1 - \alpha$.

для односторонней критической области $1 - \gamma = 2\alpha \rightarrow \gamma = 1 - 2\alpha$;

1) Гипотеза $H_1: a \neq a_0$ - критическая область двусторонняя $t_{kp} = t_\gamma(1 - \alpha, k)$.

При $|T_{\text{набл}}| > t_{kp} = t_\gamma(1 - \alpha, k)$ — нулевую гипотезу отвергают.

2) Гипотеза $H_1: a > a_0$ - критическая область правосторонняя.

При $T_{набл} > t_{kp} = t_\gamma(1 - 2\alpha, k)$ — нулевую гипотезу отвергают.

3) Гипотеза $H_1: a < a_0$ - критическая область левосторонняя.

При $T_{набл} < -t_{kp} = -t_\gamma(1 - 2\alpha, k)$ — нулевую гипотезу отвергают.

Пример 4.1. Хронометраж затрат времени на сборку узла машины $n = 20$ слесарей показал, что $\bar{x}_e = 77$ мин, а $s^2 = 4$ мин². В предположении о нормальности распределения решить вопрос: можно ли на уровне значимости $\alpha = 0.05$ считать 80 мин нормативом (математическим ожиданием) трудоемкости?

Решение. В качестве основной гипотезы принимается $H_0: a = 80$ мин, в качестве альтернативной $H_1: a \neq 80$ мин, т.е. имеем случай двусторонней критической области, при этом $a_0 = 80$.

Используя таблицу Приложения 5, находим по верхней строкке $\alpha = 0.05$ для $k = n - 1 = 19$ критическое значение $t_{двуст. kp} = 2,09$. Таким образом, критерий отклонения нулевой гипотезы - принадлежность наблюдаемого значения критической области $|T_{набл}| > 2,09$.

С использованием таблицы Приложения 3 получим тот же критерий отклонения нулевой гипотезы $|T_{набл}| > t_\gamma(1 - \alpha, k) = t_\gamma(0,95; 19) = 2,093$.

По формуле (15) вычисляем $T_{набл} = \frac{(77 - 80)\sqrt{20}}{2} = -6,71$.

Так как число $-6,71$ попадает в критическую область (конкретно в интервал $(-\infty, -2.09)$), то гипотеза $H_0: a = 80$ мин отвергается.

В табличном процессоре Excel для проверки рассмотренной выше гипотезы используется уже известная функция ZTEST без указания СКО. Обращение к ней имеет вид:

$$=ZTEST(массив; a_0; [\sigma]),$$

где *массив* – адреса ячеек, содержащих выборочные данные;

a_0 и σ – имеют прежний смысл, при этом, если параметр σ опущен, то используется исправленная выборочная дисперсия s , вычисленная по той же выборке.

Проверка гипотезы о числовом значении дисперсии нормального распределения

Полагаем, что $X = N(a, \sigma)$. При этом по выборке объема n найдена исправленная дисперсия s^2 .

Необходимо при заданном уровне значимости α проверить нулевую гипотезу $H_0: \sigma^2 = \sigma_0^2$ о равенстве неизвестной генеральной дисперсии σ^2 гипотетическому (предполагаемому) значению σ_0^2 .

В качестве критерия возьмем случайную величину

$$K = \chi_{n-1}^2 = \frac{(n-1)s^2}{\sigma_0^2}, \quad (17)$$

которая подчиняется χ^2 -распределению с числом степеней свободы $k = n - 1$.

После вычисления наблюдаемого значения критерия (17) определим его критические значения в зависимости от альтернативной гипотезы H_1 при заданном уровне значимости α и числу степеней свободы $k = n - 1$ (Прил. 4):

Правило 1. При конкурирующей гипотезе $H_1: \sigma^2 > \sigma_0^2$ критическая область правосторонняя с критической точкой $\chi_{kp}^2(\alpha; k)$.

Если $\chi_{набл}^2 > \chi_{kp}^2$ — нулевую гипотезу отвергают. В противном случае, если $\chi_{набл}^2 < \chi_{kp}^2$, — нет оснований отвергнуть нулевую гипотезу.

Правило 2. При конкурирующей гипотезе $H_1: \sigma^2 \neq \sigma_0^2$ критическая область двусторонняя. Находят левую $\chi_{лев.kp}^2(1 - \alpha/2; k)$ и правую $\chi_{прав.kp}^2(\alpha/2; k)$ критические точки.

Если $\chi_{набл}^2 < \chi_{лев.kp}^2$ или $\chi_{набл}^2 > \chi_{прав.kp}^2$ — нулевую гипотезу отвергают. Если $\chi_{лев.kp}^2 < \chi_{набл}^2 < \chi_{прав.kp}^2$ — нет оснований отвергнуть нулевую гипотезу.

Правило 3. При конкурирующей гипотезе $H_1: \sigma^2 < \sigma_0^2$ критическая область левосторонняя с критической точкой $\chi_{kp}^2(1 - \alpha; k)$.

Если $\chi_{набл}^2 < \chi_{kp}^2(1 - \alpha; k)$ — нулевую гипотезу отвергают. Если $\chi_{набл}^2 > \chi_{kp}^2(1 - \alpha; k)$ — нет оснований отвергнуть нулевую гипотезу.

З а м е ч а н и е . Если число степеней свободы $k > 30$, то критическую точку $\chi_{kp}^2(\alpha, k)$ можно найти из равенства Уилсона—Гильферти [4]:

$$\chi_{kp}^2(\alpha, k) = k \left(1 - \frac{2}{9k} + z_a \sqrt{\frac{2}{9k}} \right)^3, \quad (18)$$

где z_a находят, используя функцию Лапласа, из равенства

$$\Phi(z_a) = (1 - 2\alpha)/2.$$

Пример 560.

Из нормальной генеральной совокупности извлечена выборка объема $n = 21$ и по ней найдена исправленная выборочная дисперсия $s^2 = 16,2$. Требуется при уровне значимости 0,01 проверить нулевую гипотезу $H_0: \sigma^2 = \sigma_0^2 = 15$, приняв в качестве конкурирующей гипотезы $H_1: \sigma^2 > 15$.

Решение. Найдем наблюдаемое значение критерия:

$$\chi_{набл}^2 = \frac{(n-1)s^2}{\sigma_0^2} = \frac{(21-1)16,2}{15} = 21,6.$$

По условию, конкурирующая гипотеза имеет вид $\sigma^2 > 15$, поэтому критическая область — правосторонняя (правило 1). По таблице приложения 4, по уровню значимости 0,01 и числу степеней свободы $k = n - 1 = 21 - 1 = 20$ находим критическую точку $\chi_{kp}^2(0,01; 20) = 37,6$

Так как $\chi_{набл}^2 < \chi_{kp}^2$ — нет оснований отвергнуть нулевую гипотезу о равенстве генеральной дисперсии гипотетическому значению $\sigma_0^2 = 15$. Другими словами, различие между исправленной дисперсией и гипотетической генеральной дисперсией незначимо.

Пример 565.

Партия изделий принимается, если дисперсия контролируемого размера значимо не превышает 0,2. Исправленная выборочная дисперсия, найденная по выборке объема $n = 21$, оказалась равной $s_x^2 = 0,3$. Можно ли принять партию при уровне значимости 0,01?

Решение. Нулевая гипотеза $H_0: \sigma^2 = \sigma_0^2 = 0,2$. Найдем наблюдаемое значение критерия:

$$\chi_{набл}^2 = \frac{(n-1)s^2}{\sigma_0^2} = \frac{120 \cdot 0,3}{0,2} = 180.$$

Конкурирующая гипотеза имеет вид $H_1: \sigma^2 > 0,2$, следовательно, критическая область правосторонняя. Поскольку в таблице приложения 4 не содержится числа степеней свободы $k = 120$, найдем критическую точку приближенно из равенства Уилсона — Гильферти (18):

$$\chi^2_{kp}(\alpha, k) = k \left(1 - \frac{2}{9k} + z_\alpha \sqrt{\frac{2}{9k}} \right)^3.$$

Найдем предварительно (учитывая, что по условию $\alpha = 0,01$) $z_\alpha = z_{0,01}$ из равенства

$$\Phi(z_{0,01}) = (1 - 2\alpha)/2 = (1 - 2 \cdot 0,01)/2 = 0,49.$$

По таблице функции Лапласа (см. приложение 2), используя линейную интерполяцию, находим: $z_{0,01} = 2,326$. Подставив $k = 120$, $z_\alpha = 2,326$ в формулу Уилсона — Гильферти, получим $\chi^2_{kp}(0,01; 120) = 158,85$. (Это приближение достаточно хорошее: в более полных таблицах χ^2 приведено значение 158,95). Так как $\chi^2_{набл} > \chi^2_{kp}$ — нулевую гипотезу отвергаем. Партию принять нельзя.

Проверка гипотезы о числовом значении вероятности события

Пусть по достаточно большому числу n независимых испытаний, в каждом из которых вероятность p появления события постоянна, но неизвестна, найдена относительная частота m/n . Требуется при заданном уровне значимости α проверить нулевую гипотезу $H_0: p = p_0$ о равенстве неизвестной вероятности p некоторому гипотетическому значению p_0 .

В качестве критерия возьмем величину

$$Z = \frac{(m/n - p_0)\sqrt{n}}{\sqrt{p_0 q_0}} = N(0,1), \quad (19)$$

значение которой подчиняется стандартному нормальному распределению.

Критическое значение критерия z_{kp} определим в зависимости от альтернативной гипотезы (типа критической области) с использованием функции Лапласа (Приложение 2) по формулам (13), (14) для МО.

Замечание. Удовлетворительные результаты обеспечивает выполнение неравенства $np_0q_0 > 9$.

Пример 586. По 100 независимым испытаниям найдена относительная частота $m/n = 0,14$. При уровне значимости 0,05 требуется проверить нулевую гипотезу $H_0: p = p_0 = 0,20$ при конкурирующей гипотезе $H_1: p \neq 0,20$.

Решение.

Найдем наблюдаемое значение критерия, учитывая, что $q_0 = 1 - p_0 = 0,8$:

$$Z_{\text{набл}} = \frac{(0,14 - 0,2) \sqrt{100}}{\sqrt{0,2 \cdot 0,8}} = -1,5.$$

По условию, конкурирующая гипотеза имеет вид $H_1: p \neq 0,2$, поэтому критическая область — двусторонняя. Найдем критическую точку z_{kp} по равенству (13)

$$\Phi(z_{kp}) = \frac{1-\alpha}{2} = \frac{1-0,05}{2} = 0,475.$$

По таблице функции Лапласа (см. приложение 2) находим $z_{kp} = 1,96$.

Так как $|Z_{\text{набл}}| < z_{kp}$ — нет оснований отвергнуть нулевую гипотезу.

Другими словами, наблюдаемая относительная частота 0,14 незначимо отличается от гипотетической вероятности 0,20.

Проверка гипотезы о значимости выборочного коэффициента корреляции

Пусть двумерная генеральная совокупность (X, Y) распределена нормально. Из этой совокупности извлечена выборка объема n и по ней найден выборочный коэффициент корреляции $r_B \neq 0$. Требуется проверить нулевую гипотезу $H_0: r_B = 0$ о равенстве нулю генерального коэффициента корреляции.

Если нулевая гипотеза принимается, то это означает, что X и Y некоррелированы; в противном случае — коррелированы.

Для того чтобы при уровне значимости α проверить нулевую гипотезу о равенстве нулю генерального коэффициента корреляции нормальной двумерной случайной величины при конкурирующей гипотезе $H_1: r_B \neq 0$, надо вычислить наблюдаемое значение критерия

$$K = T_{\text{набл}} = r_B \sqrt{n-2} / \sqrt{1-r_B^2} \quad (20)$$

и по таблице критических точек распределения Стьюдента, по заданному уровню значимости α и числу степеней свободы $k = n - 2$ найти критическую точку $t_{kp}(\alpha, k)$ двусторонней критической области. Если $|T_{\text{набл}}| < t_{kp}$ — нет оснований отвергнуть нулевую гипотезу. Если $|T_{\text{набл}}| > t_{kp}$ — нулевую гипотезу отвергают.

Пример 610.

По выборке объема $n=100$, извлеченной из двумерной нормальной генеральной совокупности (X, Y) , найден выборочный коэффициент

корреляции $r_B = 0,2$. Требуется при уровне значимости 0,05 проверить нулевую гипотезу $H_0 : r_\Gamma = 0$ о равенстве нулю генерального коэффициента корреляции при конкурирующей гипотезе $H_1 : r_\Gamma \neq 0$.

Решение.

Найдем наблюдаемое значение критерия (20)

$$T_{набл} = 0,2 \sqrt{100 - 2} / \sqrt{1 - 0,2^2} = 2,02.$$

По условию, конкурирующая гипотеза $H_1 : r_\Gamma \neq 0$, поэтому критическая область - двусторонняя.

По таблице критических точек t -распределения Стьюдента (прил.5), по уровню значимости $\alpha = 0,05$ в верхней части таблицы и числу степеней свободы $k=100-2=98$ методом линейной интерполяции находим критическую точку двусторонней критической области $t_{kp}(0,05; 98) = 1,99$.

Поскольку $|T_{набл}| > t_{kp}$, то нулевую гипотезу отвергаем. Генеральный коэффициент корреляции значимо отличается от нуля, а генеральные совокупности (X, Y) коррелированы.

Типовой вариант задания

1. Регрессионный анализ и проверка гипотез.

- 1.1. i -му варианту соответствуют выборки случайных величин X и Y , расположенные в соответствующих строках.
- 1.2. По данным выборки определить:
 - оценку вектора математического ожидания;
 - оценку вектора выборочной дисперсии;
 - выборочную ковариацию;
 - выборочный коэффициент корреляции;
 - выборочные коэффициенты линейных регрессий Y на X и X на Y ;
 - выборочные уравнения линейных регрессий Y на X и X на Y .
- 1.3. Используя метод наименьших квадратов, найти параметры линейной, квадратичной и логарифмической регрессий.
- 1.4. Определите общую, объясненную и остаточную дисперсии для рассмотренных уравнений регрессий, а также коэффициенты детерминации.
- 1.5. Построить поле корреляции и найденные линии регрессии.
- 1.6. Полагая в дальнейшем, что наблюдаемые признаки X и Y распределены по нормальному закону, проверить гипотезы о равенстве их математических ожиданий гипотетическим значениям $H_0 : a = a_0$ с уровнями значимости α_m при альтернативе $H_1 : a \text{ "знак" } a_0$ (см. таблицу).
- 1.7. Проверить гипотезы о равенстве генеральных дисперсий гипотетическим значениям $H_0 : \sigma^2 = D_0$ с уровнями значимости α_m при альтернативе $H_1 : \sigma^2 \neq D_0$ (см. таблицу).
- 1.8. Проверить гипотезу $H_0 : D(X) = D(Y)$ о равенстве генеральных дисперсий признаков X и Y по их выборкам при конкурирующей гипотезе об их неравенстве при уровне значимости α_s (см. таблицу).
- 1.9. Проверить гипотезу о значимости выборочного коэффициента корреляции при уровне значимости α_s .

Вариант	Номер измерения															
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
x	2,3	2,1	4,6	4,9	3,7	5	2,8	1,6	4,8	3,7	1,1	2,4	4,3	4,5	3,2	2,4
y	-1,9	-0,2	0,0	1,6	0,6	-0,9	0,0	-2,4	0,4	3,2	-4,6	-1,9	3,0	2,6	2,8	1,0

Интервал. оц.			Проверка гипотез				
γ_m	δ_m	γ_D	α_m	зн	a_0	D_0	α_s
0,95	0,16	0,95	0,05	<4,8		0,75	
			0,02	>-0,3		7,35	0,05

ЛИТЕРАТУРА

1. **Вентцель Е.С.** Теория вероятностей: учебник для студентов вузов. – 10 изд. – М.: Издательский центр «Академия», 2005. – 576с.
2. **Гмурман В.Е.** Теория вероятностей и математическая статистика: уч. пособие. – 12-е изд. – М.: Высшее образование, 2008. - 479с.
3. **Кремер Н.Ш.** Теория вероятностей и математическая статистика: учебник для вузов. – М.: ЮНИТИ-ДАНА, 2000. - 543с.
4. **Гмурман В.Е.** Руководство к решению задач по теории вероятностей и математической статистике: уч. пособие для студентов вузов. – 4-е изд. – М.: Высшая школа, 1997. - 400с.
5. **Письменный Д.Т.** Конспект лекций по теории вероятностей, математической статистике и случайным процессам. – 3-е изд. – М.: Айрис-пресс, 2008. – 288с.
6. **Гулай Т.А., Долгополова А.Ф., Литвин Д.Б., Мелешко С.В.** Теория вероятностей и математическая статистика. - 2-е изд. - Ставрополь : Агрус, 2013. - 256с.
7. **Литвин Д.Б., Мелешко С.В.** Элементы теории вероятностей: Учебное пособие. – Ставрополь: Сервисшкола, 2017. – 86 с.