

По семи территориям Уральского экономического района за 199X г. Известны значения двух признаков (см. табл. 4) показателей «Среднедневная заработная плата одного работающего» (x, руб.) и «Доля расходов на покупку продовольственных товаров в общих расходах» (y, %).

Таблица 4

Регион	Доля расходов на покупку продовольственных товаров в общих расходах, % (y)	Среднедневная заработная плата одного работающего, руб. (x)
Удмуртская респ.	68,8	45,1
Свердловская обл.	61,2	59,0
Башкортостан	59,9	57,2
Челябинская обл.	56,7	61,8
Пермская обл.	55,0	58,8
Курганская обл.	54,3	47,2
Оренбургская обл.	49,3	55,2

Требуется:

- 1) оценить тесноту линейной корреляционно-регрессионной зависимости;
- 2) построить уравнение парной линейной регрессии;
- 3) записать модель парной линейной регрессии;
- 4) оценить качество уравнения регрессии.

Решение.

Объем выборки n = 7.

1) Теснота линейной корреляционно-регрессионной зависимости оценивается с помощью коэффициента парной корреляции.

Коэффициент парной корреляции найдем по формуле

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

Составим расчетную таблицу (см. табл. 2) (расчеты выполнены в Excel).

Таблица 2

Расчетная таблица

№ п/п	x_i	y_i	$(x_i - \bar{x})$	$(y_i - y_i)$	$(x_i - \bar{x})(y_i - y_i)$	$(x_i - \bar{x})^2$	$(y_i - y_i)^2$
1	45,1	68,8	-9,8	10,91	-106,96	96,04	119,12
2	59	61,2	4,1	3,31	13,59	16,81	10,98
3	57,2	59,9	2,3	2,01	4,63	5,29	4,06
4	61,8	56,7	6,9	-1,19	-8,18	47,61	1,41
5	58,8	55	3,9	-2,89	-11,25	15,21	8,33
6	47,2	54,3	-7,7	-3,59	27,61	59,29	12,86
7	55,2	49,3	0,3	-8,59	-2,58	0,09	73,71
Сумма	384,3	405,2			-83,14	240,34	230,47

Средние значения признаков равны

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{384,3}{7} = 54,9$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i = \frac{405,2}{7} = 57,9$$

Коэффициент парной корреляции равен

$$r_{xy} = \frac{-83,14}{\sqrt{240,34 \cdot 230,47}} = -0,353$$

Статистическую значимость коэффициента корреляции проверим с помощью критерия Стьюдента. Найдем

$$t_{расч} = \frac{r_{xy}}{\sqrt{1 - r_{xy}^2}} \cdot \sqrt{n - m - 1} = \frac{-0,353}{\sqrt{1 - (-0,353)^2}} \sqrt{7 - 1 - 1} = -0,844 \quad (m = 1).$$

Табличное значение t-критерия Стьюдента при уровне значимости $\alpha = 0,05$ и числе степеней свободы $df = n - m - 1 = 7 - 1 - 1 = 5$ составляет $t_{табл} = 2,57$. (табличное значение найдено с помощью встроенной функции Excel «СТЮДРАСПОБР»).

Так как $|t_{расч}| > t_{табл}$ ($|-0,844| < 2,57$), значение коэффициента корреляции статистически не значимо.

Величина статистически не значимого коэффициента парной корреляции свидетельствует об умеренной связи (близкой к слабой) между

Долей расходов на покупку продовольственных товаров в общих расходах и Среднедневной заработной платой одного работающего.

Коэффициент детерминации

$$R^2 = (r_{yx})^2 = (-0,353)^2 = 0,125$$

Показывает, что *на 12,5% изменение Доли расходов на покупку продовольственных товаров в общих расходах объясняется изменениями Среднедневной заработной платой одного работающего.* Оставшиеся 87,5% приходятся на другие факторы, не включенные в модель.

Построение уравнения парной линейной регрессии теоретически обосновано.

2) Уравнение парной линейной регрессии $\hat{y} = b_0 + b_1x$

найдем методом наименьших квадратов по формулам, предварительно проведя необходимые расчеты (здесь и далее см. табл. 3):

$$b_1 = \frac{\sum_{i=1}^n x_i y_i - \frac{1}{n} \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{\sum_{i=1}^n x_i^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2} = \frac{22162,34 - 405,2 \cdot 384,3 : 7}{21338,41 - (384,3)^2 : 7} = -0,346 ,$$

$$b_0 = \bar{y} - b_1 \bar{x} = 57,9 - (-0,346) \cdot 54,9 = 76,877$$

Уравнение парной линейной регрессии имеет вид:

$$\hat{y} = 76,877 - 0,346 \cdot x .$$

Коэффициент регрессии $b_1 = -0,346$ показывает, что с увеличением Среднедневной заработной платы одного работающего на 1 руб. Доля расходов на покупку продовольственных товаров в общих расходах уменьшается на 0,346%.

Подставляя в полученное уравнение регрессии значения x_i можно определить *теоретические значения* \hat{y}_i .

Расчетная таблица

% п/п	x_i	y_i	x_i^2	$x_i \cdot y_i$	\hat{y}_i	$\left \frac{y_i - \hat{y}_i}{y_i} \right $	$(\hat{y}_i - \bar{y})^2$	$(\hat{y}_i - y_i)^2$	$(x_i - \bar{x})^2$
1	45,1	68,8	3102,88	2034,01	61,28	0,11	11,49	56,61	96,04
2	59	61,2	3610,80	3481,00	56,47	0,08	2,01	22,40	16,81
3	57,2	59,9	3426,28	3271,84	57,09	0,05	0,63	7,90	5,29
4	61,8	56,7	3504,06	3819,24	55,50	0,02	5,70	1,44	47,61
5	58,8	55	3234,00	3457,44	56,54	0,03	1,82	2,36	15,21
6	47,2	54,3	2562,96	2227,84	60,55	0,12	7,09	39,05	59,29
7	55,2	49,3	2721,36	3047,04	57,78	0,17	0,01	71,94	0,09
Сумма	384,3	405,2	22162,34	21338,41	405,20	0,57	28,76	201,71	240,34
Среднее	54,9	57,9			57,89	0,081			

3) Модель парной линейной регрессии имеет вид

$$y = 76,877 - 0,346 \cdot x + \varepsilon$$

или

$$y_i = 76,877 - 0,346 \cdot x_i + \varepsilon_i$$

4) Оценим качество уравнения регрессии;

а) Найдем среднюю относительную ошибку аппроксимации

$$\bar{A} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \cdot 100\% = \frac{0,57}{7} \cdot 100\% = 8,14\% .$$

Так как $\bar{A} < 10\%$, **уравнение имеет хорошую точность.**

б) Проверим статистическую значимость уравнения регрессии в целом с помощью критерия Фишера. Необходимые расчеты приведены в табл. 3.

$$F_{расч} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (\hat{y}_i - y_i)^2} \cdot \frac{n - m - 1}{m} = \frac{28,76}{201,71} \cdot \frac{7 - 1 - 1}{1} = 0,713 .$$

Табличное значение критерия Фишера с $df_1 = m = 1$ и $df_2 = n - m - 1 = 7 - 1 - 1 = 5$ степенями свободы при уровне значимости $\alpha = 0,05$ найдем с помощью встроенной функции Excel «ФРАСПОБР». $F_{\text{табл}} = 6,61$.

Поскольку $F_{\text{расч}} < F_{\text{табл}}$, **уравнение регрессии статистически не значимо в целом.**

в) Проверим статистическую значимость параметров уравнения регрессии с помощью критерия Стьюдента. Необходимые расчеты приведены в табл. 3.

Расчетные значения критерия равны

$$t_{b_0} = \left| \frac{b_0}{m_{b_0}} \right| = \frac{76,877}{22,62} = 3,40 ,$$

$$t_{b_1} = \left| \frac{b_1}{m_{b_1}} \right| = \frac{|-0,346|}{0,41} = 0,844 .$$

Средние квадратические ошибки параметров равны

$$m_{b_0} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{(n-2)} \cdot \frac{\sum_{i=1}^n x_i^2}{n \sum_{i=1}^n (x_i - \bar{x})^2}} = \sqrt{\frac{201,71}{7-2} \cdot \frac{21338,41}{7 \cdot 240,34}} = 22,62 ,$$

$$m_{b_1} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{(n-2) \cdot \sum_{i=1}^n (x_i - \bar{x})^2}} = \sqrt{\frac{201,71}{(7-2) \cdot 240,34}} = 0,41 .$$

Табличное значение критерия Стьюдента $t_{\text{табл}} = 2,57$ найдено в пункте 1).

Так как $t_{b_0} > t_{\text{табл}}$, **параметр b_0 статистически значим**; $t_{b_1} < t_{\text{табл}}$, **параметр b_1 статистически не значим.**

г) Найдем интервальные оценки параметров по формулам:

$$\left(b_0 - m_{b_0} \cdot t_{\text{табл}} ; b_0 + m_{b_0} \cdot t_{\text{табл}} \right) ;$$

$$\left(76,877 - 22,62 \cdot 2,57 ; 76,877 + 22,62 \cdot 2,57 \right) ;$$

$$\left(b_1 - m_{b_1} \cdot t_{табл} \ ; \ b_1 + m_{b_1} \cdot t_{табл} \right);$$
$$\left(-0,346 - 0,41 \cdot 2,57 \ ; \ -0,346 + 0,41 \cdot 2,57 \right).$$

Интервальная оценка b_0 : (18,73 ; 135,02).

Интервальная оценка b_1 : (-1,40 ; 0,71).

Вывод: полученное уравнение не значимо в целом, коэффициент b_1 и коэффициент корреляции не значимы