

Распределение 50 предприятий по размерам основных производственных фондов X (млн. руб.) и выпуску продукции Y (млн. руб.) дано в таблице.

$X \backslash Y$	40-50	50-60	60-70	70-80	80-90	90-100	Итого
35-45	1	1	1				3
45-55		3	2				5
55-65		4	1	11			16
65-75				6	9		15
75-85				1	1	1	3
85-95					4	4	8
Итого	1	8	4	18	14	5	50

Необходимо:

1. Вычислить групповые средние \bar{x}_i и \bar{y}_j , построить эмпирические линии регрессии.

2. Предполагая, что между переменными X и Y существует линейная корреляционная зависимость:

а) найти уравнения прямых регрессии, построить их графики на одном чертеже с эмпирическими линиями и дать экономическую интерпретацию полученных уравнений;

б) вычислить коэффициент корреляции; на уровне значимости $\alpha = 0,05$ оценить его значимость и сделать вывод о тесноте и направлении связи между переменными X и Y ;

в) используя соответствующее уравнение регрессии, оценить средний выпуск продукции предприятия, основные производственные фонды (ОПФ), которого составляют 81 млн. руб.

Решение.

В корреляционную таблицу занесем данные заданные по условию задачи.

<http://exponenta.ucoz.ru/>

		y						n_x	\bar{y}_x	$u_i n_x$	$u_i^2 n_x$	$\sum u_i v_j n_{ij}$
		40-50	50-60	60-70	70-80	80-90	90-100					
x	y_j											
	x_i	v_j	u_i									
35-45			1	1	1			3				
45-55				3	2			5				
55-65				4	1	11		16				
65-75						6	9	15				
75-85						1	1	3				
85-95							4	8				
	n_y	1	8	4	18	14	5	50 $n_x = n_y$	Σ			
	\bar{x}_y							Σ				
	$v_j n_y$											
	$v_j^2 n_y$											
	$\sum v_j u_i n_{ij}$											

От интервальных рядов перейдем к дискретным
рядам x_i и y_j , используя формулы

$$x_i = \frac{x_{i-1} + x_{i+1}}{2} \quad \text{и} \quad y_j = \frac{y_{j-1} + y_{j+1}}{2}.$$

Получаем

$$x_1 = \frac{35 + 45}{2} = \frac{80}{2} = 40$$

$$y_1 = \frac{40 + 50}{2} = \frac{90}{2} = 45$$

$$x_2 = \frac{45 + 55}{2} = \frac{100}{2} = 50$$

$$y_2 = \frac{50 + 60}{2} = \frac{110}{2} = 55$$

$$x_3 = \frac{55 + 65}{2} = \frac{120}{2} = 60$$

$$y_3 = \frac{60 + 70}{2} = \frac{130}{2} = 65$$

$$x_4 = \frac{65 + 75}{2} = \frac{140}{2} = 70$$

$$y_4 = \frac{70 + 80}{2} = \frac{150}{2} = 75$$

$$x_5 = \frac{75 + 85}{2} = \frac{160}{2} = 80$$

$$y_5 = \frac{80 + 90}{2} = \frac{170}{2} = 85$$

$$x_6 = \frac{85 + 95}{2} = \frac{180}{2} = 90$$

$$y_6 = \frac{90 + 100}{2} = \frac{190}{2} = 95$$

Вычисленные среденные значения интервальных рядов
запишем в корреляционную таблицу.

		y						n_x	\bar{y}_x	$u_i n_x$	$u_i^2 n_x$	$\sum u_i v_j n_{ij}$
		40-50	50-60	60-70	70-80	80-90	90-100					
x	y_j	45	55	65	75	85	95					
	x_i	v_j	u_i									
35-45	40		1	1	1			3				
45-55	50			3	2			5				
55-65	60			4	1	11		16				
65-75	70				6	9		15				
75-85	80				1	1	1	3				
85-95	90					4	4	8				
	n_y	1	8	4	18	14	5	50 $n_x = n_y$	Σ			
	\bar{x}_y							Σ				
	$v_j n_y$											
	$v_j^2 n_y$											
	$\sum v_j u_i n_{ij}$											

Для упрощения расчетов перейдем к новым условным вариантам u_i и v_j :

$$u_i = \frac{x_i - c_1}{k_1} \quad \text{и} \quad v_j = \frac{y_j - c_2}{k_2},$$

где c_1 и c_2 - середины срединных интервалов,
 k_1 и k_2 - ширина интервалов по x , и по y соответственно.

При четном числе интервалов пользуемся правилом:
рекомендуется взять середину интервала, имеющую
большую частоту.

Анализируя интервальные ряды по x и по y приходим
к выводу: $k_1 = 10$, $c_1 = 60$ (т.к. $n_x = 16 > 15$),
 $k_2 = 10$, $c_2 = 75$ ($n_y = 18 > 4$).

$$u_1 = \frac{40 - 60}{10} = -\frac{20}{10} = -2$$

$$v_1 = \frac{45 - 75}{10} = -\frac{30}{10} = -3$$

$$u_2 = \frac{50 - 60}{10} = -\frac{10}{10} = -1$$

$$v_2 = \frac{55 - 75}{10} = -\frac{20}{10} = -2$$

$$u_3 = \frac{60 - 60}{10} = 0$$

$$v_3 = \frac{65 - 75}{10} = -\frac{10}{10} = -1$$

$$u_4 = \frac{70 - 60}{10} = \frac{10}{10} = 1$$

$$v_4 = \frac{75 - 75}{10} = 0$$

$$u_5 = \frac{80 - 60}{10} = \frac{20}{10} = 2$$

$$v_5 = \frac{85 - 75}{10} = \frac{10}{10} = 1$$

$$u_6 = \frac{90 - 60}{10} = \frac{30}{10} = 3$$

$$v_6 = \frac{95 - 75}{10} = \frac{20}{10} = 2$$

Вычисленные условные варианты занесем в
корреляционную таблицу.

		y						n_x	\bar{y}_x	$u_i n_x$	$u_i^2 n_x$	$\sum u_i v_j n_{ij}$
		40-50	50-60	60-70	70-80	80-90	90-100					
x	y_j	45	55	65	75	85	95					
	x_i	v_j	-3	-2	-1	0	1	2				
	u_i											
35-45	40	-2	1	1	1			3				
45-55	50	-1		3	2			5				
55-65	60	0		4	1	11		16				
65-75	70	1				6	9	15				
75-85	80	2				1	1	1	3			
85-95	90	3					4	4	8			
n_y			1	8	4	18	14	5	50 $n_x = n_y$	Σ		
\bar{x}_y									Σ			
$v_j n_y$												
$v_j^2 n_y$												
$\sum v_j u_i n_{ij}$												

Найдем вспомогательные величины

$$u_i \cdot n_x, u_i^2 \cdot n_x, v_j \cdot n_y, v_j^2 \cdot n_y.$$

И найдем соответствующие суммы

$$\sum u_i \cdot n_x, \sum u_i^2 \cdot n_x, \sum v_j \cdot n_y, \sum v_j^2 \cdot n_y$$

Результат вычисления занесем в соответствующие строки и столбцы корреляционной таблицы.

Для вычисления сумм вида $\sum v_j u_i n_{ij}$ и $\sum u_i v_j n_{ij}$ найдем произведения $u_i v_j$ и запишем их по диагонали в соответствующей клетке корреляционной таблицы.



		y						n_x	\bar{y}_x	$u_i n_x$	$u_i^2 n_x$	$\sum u_i v_j n_{ij}$
		40-50	50-60	60-70	70-80	80-90	90-100					
x	y_j	45	55	65	75	85	95	n_x	\bar{y}_x	$u_i n_x$	$u_i^2 n_x$	$\sum u_i v_j n_{ij}$
	x_i	v_j	-3	-2	-1	0	1					
	u_i											
35-45	40	-2	1 6	1 4	1 2			3		-6	12	
45-55	50	-1		3 2	2 1			5		-5	5	
55-65	60	0		4 0	1 0	11 0		16		0	0	
65-75	70	1				6 0	9 1	15		15	15	
75-85	80	2				1 0	1 2	1 4	3	6	12	
85-95	90	3					4 3	4 6	8	24	72	
n_y		1	8	4	18	14	5	50 $n_x = n_y$	\sum	34	116	
\bar{x}_y								\sum				
$v_j n_y$		-3	-16	-4	0	14	10	1				
$v_j^2 n_y$		9	32	4	0	14	20	79				
$\sum v_j u_i n_{ij}$												

Далее, по каждой строке и по каждому столбцу находим произведения $u_i v_j p_{ij}$, и полученные значения складываем.

$$\text{Например, } \sum u_i v_j p_{ij} = 1 \cdot 6 + 1 \cdot 4 + 1 \cdot 2 = 12.$$

Аналогично находим остальные суммы.

Если все расчеты выполнены верно, то сумма значений столбца $\sum u_i v_j p_{ij}$ должна совпасть с суммой значений строки $\sum v_j u_i p_{ij}$.

		y						n_x	\bar{y}_x	$u_i n_x$	$u_i^2 n_x$	$\sum u_i v_j n_{ij}$
		40-50	50-60	60-70	70-80	80-90	90-100					
x	y_j	45	55	65	75	85	95	n_x	\bar{y}_x	$u_i n_x$	$u_i^2 n_x$	$\sum u_i v_j n_{ij}$
	x_i	v_j	-3	-2	-1	0	1					
	u_i											
35-45	40	-2	1 6	1 4	1 2			3		-6	12	12
45-55	50	-1		3 2	2 1			5		-5	5	8
55-65	60	0		4 0	1 0	11 0		16		0	0	0
65-75	70	1				6 0	9 1	15		15	15	9
75-85	80	2				1 0	1 2	1 4	3	6	12	6
85-95	90	3					4 3	4 6	8	24	72	36
n_y		1	8	4	18	14	5	50 $n_x = n_y$	\sum	34	116	
\bar{x}_y								\sum				
$v_j n_y$		-3	-16	-4	0	14	10	1				
$v_j^2 n_y$		9	32	4	0	14	20	79				
$\sum v_j u_i n_{ij}$		6	10	4	0	23	28					71

Групповые средние найдем по формулам:

$$\bar{y}_x = \frac{\sum y_j \cdot n_{ij}}{n_x} \quad \text{и} \quad \bar{x}_y = \frac{\sum x_i \cdot n_{ij}}{n_y}$$

Получаем,

$$\bar{y}_{x=40} = \frac{45 \cdot 1 + 55 \cdot 1 + 65 \cdot 1}{3} = \frac{165}{3} = 55$$

$$\bar{y}_{x=50} = \frac{55 \cdot 3 + 65 \cdot 2}{5} = \frac{295}{5} = 59$$

$$\bar{y}_{x=60} = \frac{55 \cdot 4 + 65 \cdot 1 + 75 \cdot 1}{16} = \frac{1110}{16} = 69,375$$

$$\bar{y}_{x=70} = \frac{75 \cdot 6 + 85 \cdot 9}{15} = \frac{1215}{15} = 81$$

$$\bar{y}_{x=80} = \frac{75 \cdot 1 + 85 \cdot 1 + 95 \cdot 1}{3} = \frac{255}{3} = 85$$

$$\bar{y}_{x=90} = \frac{85 \cdot 4 + 95 \cdot 4}{8} = \frac{720}{8} = 90$$

$$\bar{x}_{y=45} = \frac{40 \cdot 1}{1} = 40$$

$$\bar{x}_{y=55} = \frac{40 \cdot 1 + 50 \cdot 3 + 60 \cdot 4}{8} = \frac{430}{8} = 53,75$$

$$\bar{x}_{y=65} = \frac{40 \cdot 1 + 50 \cdot 2 + 60 \cdot 1}{4} = \frac{200}{4} = 50$$

$$\bar{x}_{y=75} = \frac{60 \cdot 1 + 70 \cdot 6 + 80 \cdot 1}{18} = \frac{1160}{18} = 64,444$$

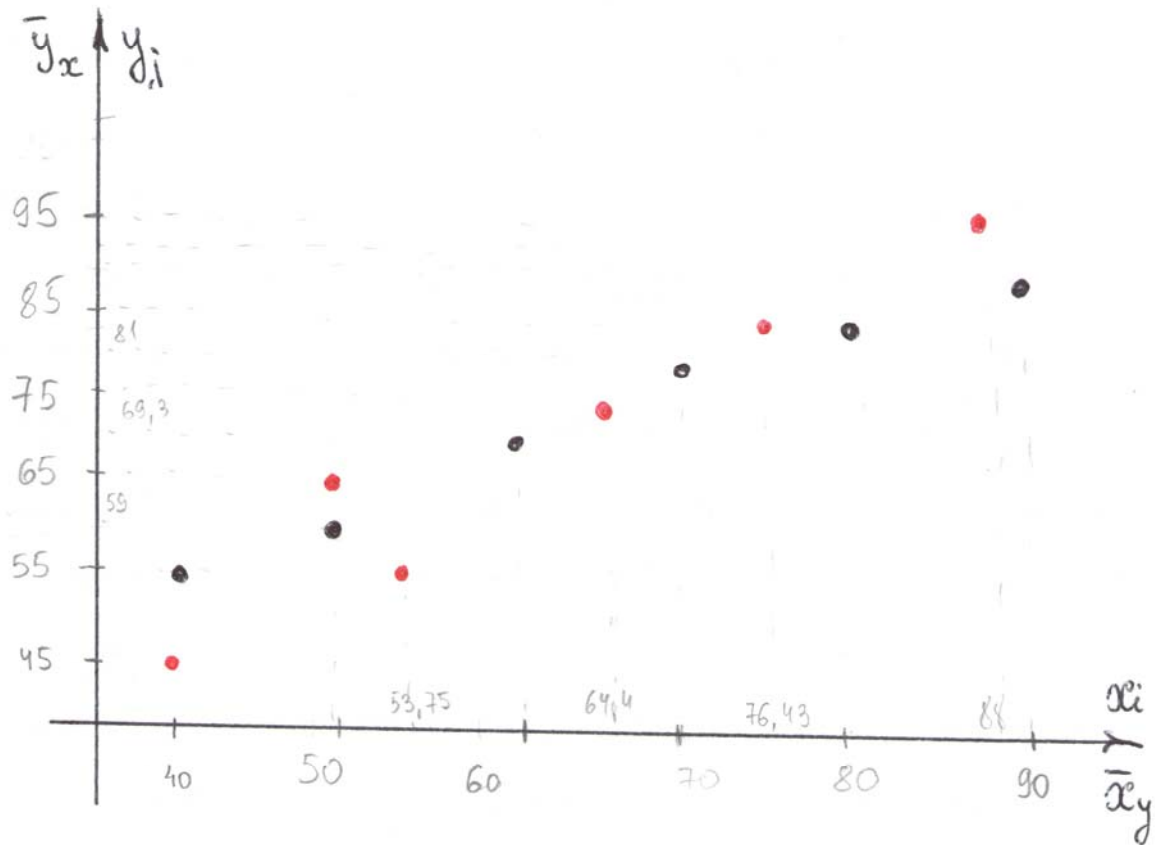
$$\bar{x}_{y=85} = \frac{70 \cdot 9 + 80 \cdot 1 + 90 \cdot 4}{14} = \frac{1070}{14} = 76,428$$

$$\bar{x}_{y=95} = \frac{80 \cdot 1 + 90 \cdot 4}{5} = \frac{440}{5} = 88$$

Вычисленные групповые средние \bar{x}_y и \bar{y}_x занесем в корреляционную таблицу.

		y						n_x	\bar{y}_x	$u_i n_x$	$u_i^2 n_x$	$\sum u_i v_j n_{ij}$	
		40-50	50-60	60-70	70-80	80-90	90-100						
x	y_j	45	55	65	75	85	95	n_x	\bar{y}_x	$u_i n_x$	$u_i^2 n_x$	$\sum u_i v_j n_{ij}$	
	x_i	v_j	-3	-2	-1	0	1						2
	u_i												
35-45	40	-2	1 6	1 4	1 2			3	55	-6	12	12	
45-55	50	-1		3 2	2 1			5	59	-5	5	8	
55-65	60	0		4 0	1 0	11 0		16	69,375	0	0	0	
65-75	70	1				6 0	9 1	15	81	15	15	9	
75-85	80	2				1 0	1 2	1 4	3	85	6	12	6
85-95	90	3					4 3	4 6	8	90	24	72	36
n_y		1	8	4	18	14	5	50 $n_x = n_y$	\sum	34	116		
\bar{x}_y		40	53,75	50	64,444	76,428	88	\sum					
$v_j n_y$		-3	-16	-4	0	14	10	1					
$v_j^2 n_y$		9	32	4	0	14	20	79					
$\sum v_j u_i n_{ij}$		6	10	4	0	23	28					71	

На координатной плоскости XOY_x и X_yOY
 Отмечаем точки с координатами $(x_i; \bar{y}_x)$ и $(\bar{x}_y; y_j)$



$(x_i; \bar{y}_x)$ - эмпирическая точечная линия y на x

$(\bar{x}_y; y_j)$ - эмпирической точечная линия x на y

Пусть между X и Y существует линейная корреляционная зависимость. Для нахождения уравнений прямой регрессии посчитаем:

- средние арифметические \bar{x} , \bar{y} ;
- дисперсии S_x^2 , S_y^2 ;
- коэффициент ковариации μ .

Получаем,

$$\begin{aligned}\bar{x} &= k_1 \bar{u} + c_1 = k_1 \cdot \frac{\sum u_i \cdot n_x}{n} + c_1 = 10 \cdot \frac{34}{50} + 60 = 0,68 + 60 = \\ &= 66,8 \text{ (млн. руб.)} - \text{средняя величина ОПФ.}\end{aligned}$$

$$\begin{aligned}\bar{y} &= k_2 \bar{v} + c_2 = k_2 \cdot \frac{\sum v_j \cdot n_y}{n} + c_2 = 10 \cdot \frac{1}{50} + 75 = 0,2 + 75 = \\ &= 75,2 \text{ (млн. руб.)} - \text{средняя стоимость выпуска продукции.}\end{aligned}$$

$$\begin{aligned}S_x^2 &= k_1^2 (\bar{u}^2 - \bar{u}^2) = k_1^2 \cdot \left(\frac{\sum u_i^2 \cdot n_x}{n} - \left(\frac{\sum u_i \cdot n_x}{n} \right)^2 \right) = \\ &= 10^2 \cdot \left(\frac{116}{50} - \left(\frac{34}{50} \right)^2 \right) = 100 \cdot (2,32 - 0,68^2) = \\ &= 185,76 - \text{дисперсия стоимости ОПФ}\end{aligned}$$

$$S_y^2 = k_2^2 (\overline{v^2} - \bar{v}^2) = k_2^2 \cdot \left(\frac{\sum v_j^2 \cdot n_{y_j}}{n} - \left(\frac{\sum v_j \cdot n_{y_j}}{n} \right)^2 \right) =$$

$$= 10^2 \cdot \left(\frac{79}{50} - \left(\frac{1}{50} \right)^2 \right) = 100 \cdot (1,58 - 0,02^2) =$$

$$= 157,96 - \text{дисперсия стоимости выпуска продукции.}$$

$$\mu = k_1 \cdot k_2 \cdot (\bar{uv} - \bar{u} \cdot \bar{v}) = k_1 \cdot k_2 \cdot \left(\frac{\sum u_i v_j \cdot n_{ij}}{n} - \frac{\sum u_i \cdot n_{ix}}{n} \cdot \frac{\sum v_j \cdot n_{y_j}}{n} \right) =$$

$$= 10 \cdot 10 \cdot \left(\frac{71}{50} - \frac{34}{50} \cdot \frac{1}{50} \right) = 100 \cdot (1,42 - 0,68 \cdot 0,02) =$$

$$= 140,64$$

Уравнение регрессии y по x будем искать в виде:

$$\bar{y}_x - \bar{y} = b_{yx} \cdot (x - \bar{x}),$$

где $b_{yx} = \frac{\mu}{S_x^2}$ - коэффициент регрессии y по x .

Найдем значение b_{yx} , получаем

$$b_{yx} = \frac{\mu}{S_x^2} = \frac{140,64}{185,76} = 0,7571$$

Геометрически b_{yx} означает тангенс угла наклона прямой регрессии y по x к оси абсцисс, т.е.

$$b_{yx} = \operatorname{tg} \alpha = 0,7571 \Rightarrow \alpha = \operatorname{arctg} 0,7571 \approx 37^\circ$$

С экономической точки зрения $b_{yx} = 0,7571$ показывает, что с увеличением x - стоимости ОПФ на 1 млн. руб., стоимость выпуска продукции в среднем увеличится на 0,7571 млн. руб.

Подставим значения \bar{x} , \bar{y} и b_{yx} в уравнение регрессии y по x , получаем

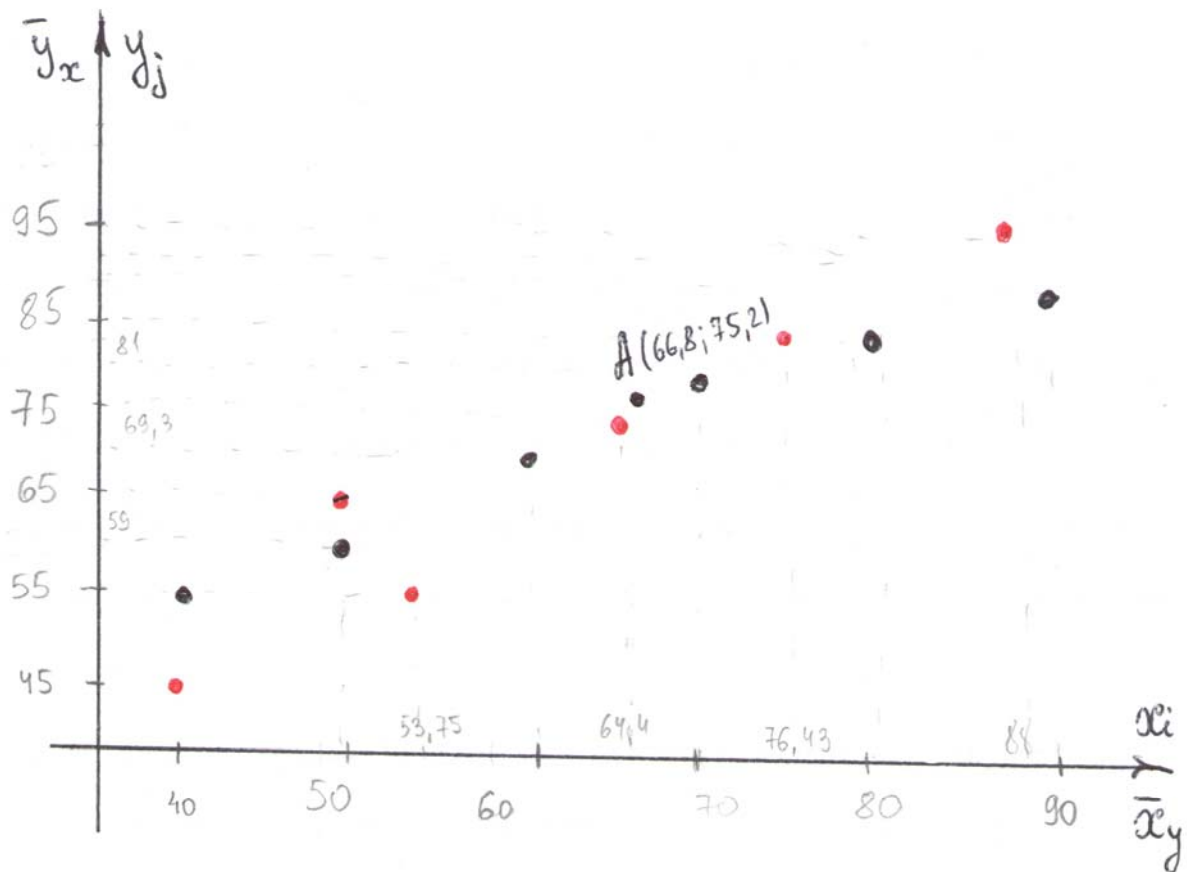
$$\bar{y}_x - 75,2 = 0,7571 \cdot (x - 66,8)$$

$$\bar{y}_x = 0,7571x - 0,7571 \cdot 66,8 + 75,2$$

$$\bar{y}_x = 0,757x + 24,626 \quad - \text{уравнение прямой}$$

регрессии y по x , показывает зависимость средней стоимости продукции от стоимости ОПФ.

Возвращаемся к графику с эмпирическими точечными линиями регрессии и отмечаем точку $A(\bar{x}; \bar{y})$, т.е. $A(66,8; 75,2)$.



$(x_i; \bar{y}_x)$ - эмпирическая точечная линия y на x

$(\bar{x}_y; y_j)$ - эмпирической точечная линия x на y


Для построения графика прямой регрессии y по x найдем координаты дополнительной точки B используя формульное уравнение регрессии:

$$\bar{y}_{x=90} = 0,757 \cdot 90 + 24,626 = 92,756$$

Получаем $B(90; 92,76)$

Через точки А и В проводим линию прямой регрессии y по x .

Отмечаем угол α между прямой регрессии и осью абсцисс.



$(x_i; \bar{y}_x)$ - эмпирическая точечная линия y на x

$(\bar{x}_y; y_j)$ - эмпирической точечная линия x на y

Аналогично находим уравнение регрессии x по y
в виде:

$$\bar{x}_y - \bar{x} = b_{xy} \cdot (y - \bar{y}),$$

где $b_{xy} = \frac{M}{S_y^2}$ - коэффициент регрессии x по y .

Найдем значение b_{xy} , получаем

$$b_{xy} = \frac{M}{S_y^2} = \frac{140,64}{157,96} = 0,8904$$

Геометрически коэффициент регрессии b_{xy} означает тангенс угла наклона прямой регрессии x по y к оси ординат, т.е.

$$b_{xy} = \operatorname{tg} \beta = 0,8904 \Rightarrow \beta = \operatorname{arctg} 0,8904 \approx 42^\circ$$

Экономическая интерпретация выборочного коэффициента регрессии b_{xy} : чтобы увеличить стоимость выпускаемой продукции на 1 млн. руб. необходимо увеличить ОПФ на 0,8904 млн. руб. в среднем.

Подставим значения \bar{x} , \bar{y} и b_{xy} в уравнение регрессии x по y , получаем

$$\bar{x}_y - 66,8 = 0,8904 (y - 45,2)$$

$$\bar{x}_y = 0,8904 y - 0,8904 \cdot 45,2 + 66,8$$

$$\bar{x}_y = 0,890 y - 0,158 \quad - \text{уравнение прямой}$$

регрессии x по y , показывает зависимость средней стоимости ОПФ от стоимости выпущенной продукции.


Для построения графика прямой регрессии x по y найдем координаты дополнительной точки C используя полученное уравнение регрессии:

$$\bar{x}_{y=45} = 0,890 \cdot 45 - 0,158 = 39,892$$

Получаем $C(39,89; 45)$.

Через точки A и C проведем линию прямой регрессии x по y .

Отмечаем угол β между прямой регрессии и осью ординат.



$(x_i; \bar{y}_x)$ - эмпирическая точечная линия y на x

$(\bar{x}_y; y_j)$ - эмпирическая точечная линия x на y

Вычислим коэффициент корреляции по формуле

$$r = \pm \sqrt{b_{yx} \cdot b_{xy}}$$

Правило определения знака перед корнем: знак плюс выбирают если коэффициенты регрессии одновременно положительны, знак минус - коэффициенты регрессии b_{yx} и b_{xy} одновременно отрицательны.

$$\text{Получаем, } r = + \sqrt{0,4541 \cdot 0,8904} = 0,82$$

Вычисленный коэффициент корреляции является выборочным т.к. получен на основе выборочных данных.

Оценим значимость коэффициента корреляции с помощью t -критерия Стьюдента на уровне значимости $\alpha = 0,05$. Для этого выдвинем нулевую гипотезу H_0 .

H_0 : линейная корреляционная зависимость в генеральной совокупности отсутствует.

Чтобы проверить гипотезу вычислим значение статистики $t_{эмп}$ по формуле:

$$t_{эмп} = \sqrt{\frac{r^2}{1-r^2} (n-2)}$$

$$\text{Получаем, } t_{эмп} = \sqrt{\frac{0,82^2}{1-0,82^2} \cdot (50-2)} = \sqrt{98,5201} = 9,92$$

Сравним значение $t_{эмп}$ с табличным значением $t_{кр} = t_{\gamma, k}$, где $\gamma = 1 - \alpha$ и $k = n - 2$ - число степеней свободы.

По таблице значений $t_{\gamma, k}$ - критерия Стьюдента при $\gamma = 1 - 0,05 = 0,95$ и $k = 50 - 2 = 48$ получаем

$$t_{\gamma, k} = t_{0,95, 48} = 2,02.$$

Поскольку $t_{эмп} > t_{кр}$ ($9,92 > 2,02$), то нулевая гипотеза отвергается, следовательно выборочный коэффициент корреляции значим на 5% уровне.

Для определения тесноты связи между переменными X и Y воспользуемся таблицей оценок коэффициента корреляции.

Поскольку $r = 0,82 \in [0,8; 0,9]$, то связь между переменными тесная.

Т.к. $r = 0,82 > 0$, то связь между переменными прямая, т.е. с увеличением стоимости ОПФ стоимость выпускаемой продукции в среднем увеличивается.

Таблицы значений $t_{\gamma, k}$ - критерия Стьюдента и оценок коэффициента корреляции находится на сайте http://exponenta.ucoz.ru/II_kyrs/statisticheskie_tablicy.pdf

Чтобы оценить средний выпуск продукции предприятия, ОПФ которого составляет 81 млн.руб. воспользуемся уравнением регрессии y по x , т.е.

$$\bar{y}_x = 0,757x + 24,626.$$

Получаем $\bar{y}_{x=81} = 0,757 \cdot 81 + 24,626 = 85,943$ (млн.руб.)

Т.о., средний выпуск продукции предприятия, ОПФ которого составляет 81 млн.руб. в среднем составляет 85,943 млн.руб.