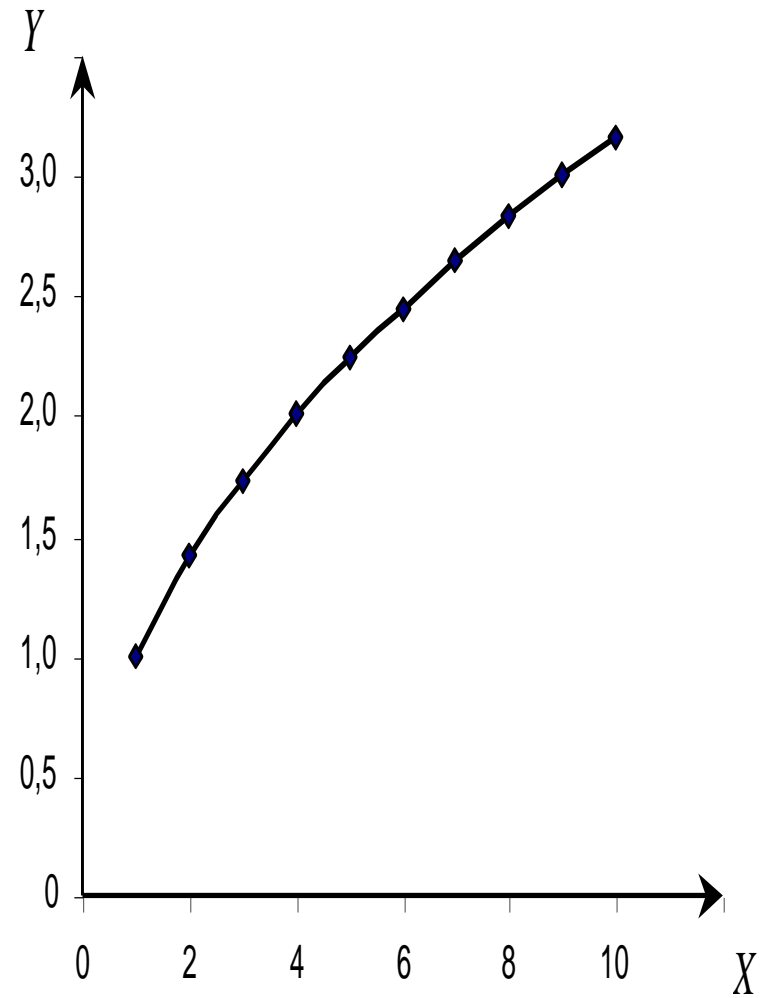


# *Корреляционный анализ.*

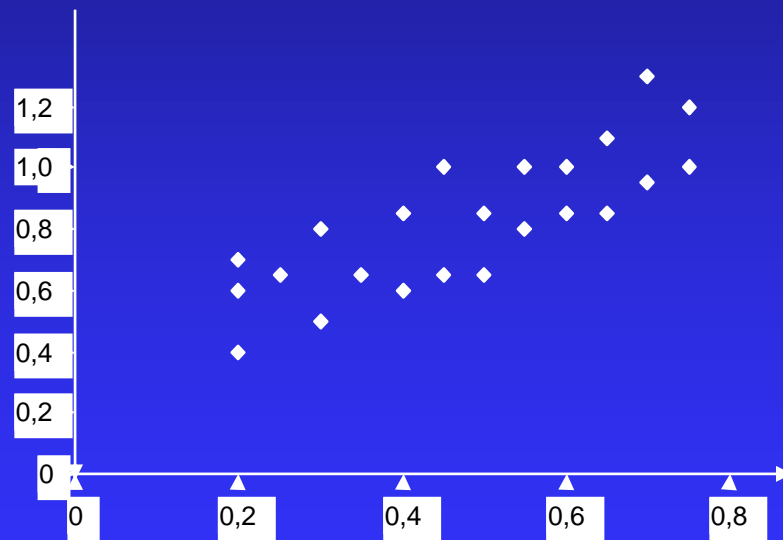
**Корреляционно-регрессионный анализ выполняется на основе анализа эмпирических данных.**

**Методы такого анализа являются составной частью эконометрики, которая устанавливает и исследует количественные закономерности в экономике на основе методов теории вероятностей и математической статистики.**



Детерминированная (функциональная) модель

**В отличие от детерминированных (функциональных) моделей, которые характеризуются однозначным соответствием между факторными и результативными показателями (рис. 3.1), в стохастических (корреляционных) моделях каждому значению факторного признака может соответствовать несколько значений результативного показателя**



**Стохастическая (корреляционная) связь между факторным и результативным показателями**

**Методы корреляционно-регрессионного анализа базируются на следующих положениях.**

**Результативный показатель рассматривается как сумма двух случайных составляющих по формуле**

$$y = f(x_i) + \varepsilon$$

**где  $f(x_i)$  — составляющая результативного показателя, определенная в виде функции от влияющих факторов;**

**$\varepsilon$  — составляющая, которая отражает влияние неучтенных случайных факторов на анализируемый результативный показатель.**

# Процесс корреляционно-регрессионного анализа включает следующие этапы

*Постановочно-информационный этап.*

Устанавливается набор показателей, регистрируемых на каждом из наблюдаемых объектов, определяются цели исследования. Проводится сбор необходимой информации.

## *Корреляционный анализ*

Решаются следующие задачи:

- выбор измерителя корреляционной связи (коэффициента корреляции, корреляционного отношения, коэффициента детерминации и т.д.);
- расчет тесноты связи по имеющимся выборочным данным;
- установление структуры связей между исследуемыми факторными и результативным показателями.

## *Регрессионный анализ.*

Выбирается общий вид функции регрессии, определяются коэффициенты уравнения регрессии.

**В зависимости от числа исследуемых признаков различают парную и множественную корреляцию. Если исследуется связь между двумя признаками (результативным и факторным), то корреляция называется *парной*. Если факторных показателей несколько, то корреляцию называют *множественной*. В процессе анализа парных зависимостей решаются следующие задачи:**

- установление вида зависимости между факториальными и результативным показателями;**
- определение коэффициентов уравнения регрессии;**
- определение тесноты (силы) связи.**


## Установление вида зависимости

Исходные данные для корреляционного анализа, представленные в виде таблицы

$y$	$x$
$y_1$	$x_1$
$y_2$	$x_2$
...	...
$y_i$	$x_i$
...	...
$y_m$	$x_m$

изображаются на графике





— Поле корреляции

1 — эмпирическая линия регрессии;

2 — теоретическая линия регрессии

Устанавливается диапазон изменения факторного признака —  $x_{max}$ ,  $x_{min}$ . Массив данных делится на группы. Длина интервала по каждой группе определяется по формуле, где  $m$  — число наблюдений.

$$\Delta x = \frac{x_{max} - x_{min}}{1 + 3,2 \lg m}$$

Для каждой группы данных определяются средние значения:

$$\bar{x} \text{ и } \bar{y}$$

$$\bar{x}_1 = x_{min} + \frac{\Delta x}{2};$$

$$\bar{x}_2 = \bar{x}_1 + \Delta x;$$

... ..

$$\bar{x}_k = \bar{x}_{k-1} + \Delta x;$$


$$\bar{y}_k = \frac{1}{n} \sum_{j=1}^n y_j,$$

где  $j=1, \dots, n$  — номера точек, попавших в интервал  $k$ .

Ломанная линия, полученная путем соединения соседних точек, носит название эмпирической линии регрессии. По внешнему виду эмпирической линии регрессии можно сделать вывод о виде факторной модели.

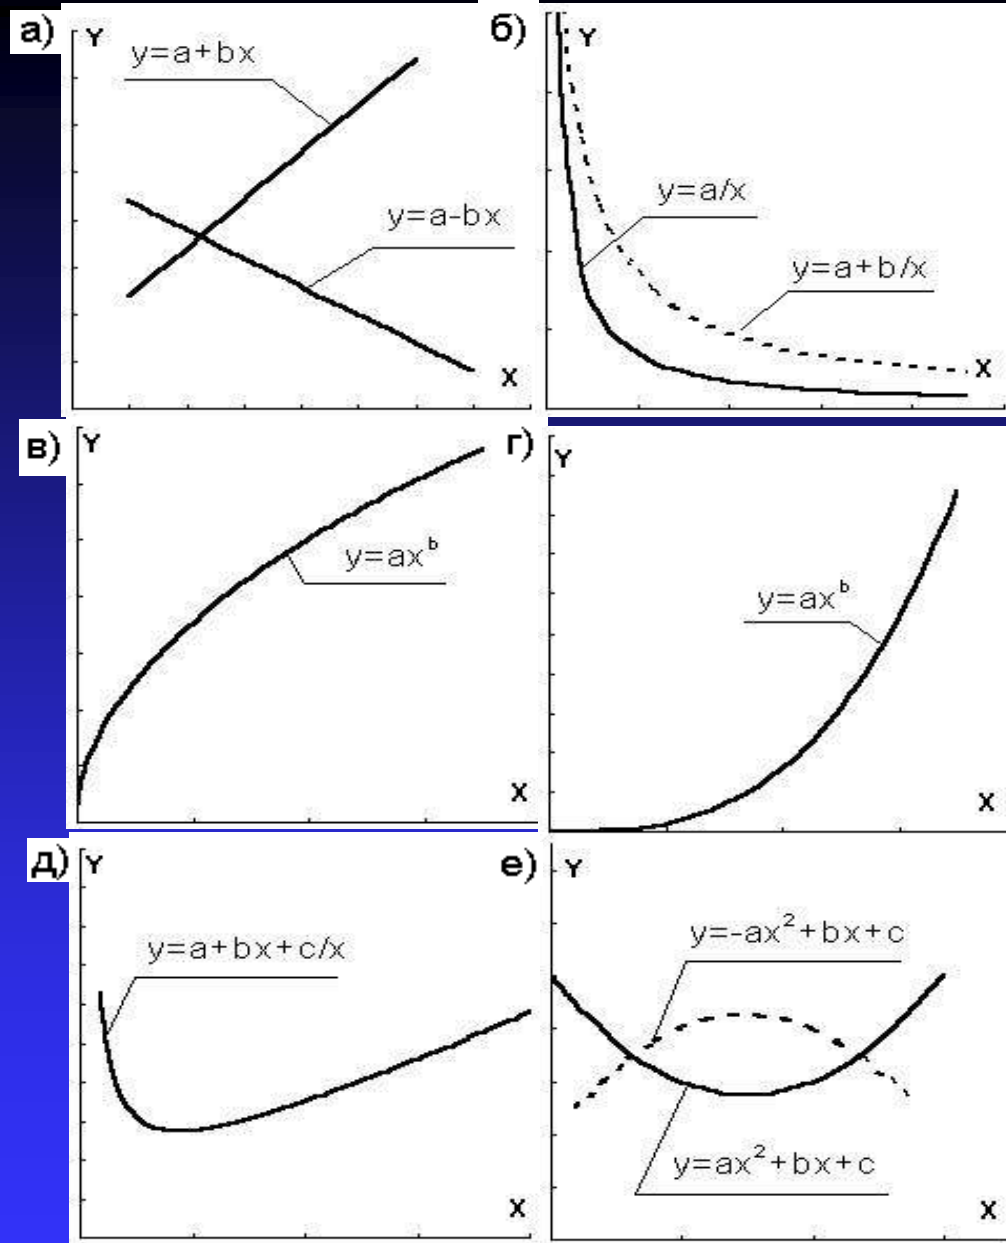
Прежде всего, необходимо гипотетически предположить является ли искомая зависимость линейной или нелинейной. При этом учитываются причинно-следственные связи между фактором и результативным показателем, экономический смысл исследуемой зависимости, опыт предыдущих исследований данной пары признаков.

Конечным результатом анализа является установление вида теоретической линии регрессии.



## Поле корреляции

- 1 — эмпирическая линия регрессии;
- 2 — теоретическая линия регрессии



Факторные модели, используемые в экономическом анализе

# Определение коэффициентов уравнения регрессии

Коэффициенты уравнения регрессии (теоретической линии регрессии) определяются методом наименьших квадратов. Этот метод широко используется при обработке результатов наблюдений в эконометрии.

Суть метода состоит в том, чтобы подобрать параметры (коэффициенты) теоретической линии регрессии с условием минимизации суммы квадратов отклонений теоретических значений результативного показателя от его эмпирических значений.

# Определение тесноты связи

Теснота связи для парных зависимостей отражает долю влияния рассматриваемого фактора  $x$  среди всех факторов (в том числе неучтенных и случайных), оказывающих влияние на результативный показатель  $y$ .

Теснота связи оценивается по величине рассеяния значений  $y$ . Небольшое рассеяние эмпирических точек относительно теоретической линии регрессии свидетельствует о сильной связи между  $x$  и  $y$ , большое рассеяние указывает на слабую связь.

Мера рассеяния признака относительно его среднего значения оценивается величиной дисперсии или среднего квадратического отклонения.

Среднее значение признака  $x$

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





Дисперсия определяется как средний квадрат отклонения признака  $x$  от его среднего значения

$$D_x = \frac{\sum_{i=1}^m (x_i - \bar{x})^2}{m}$$

Среднеквадратическое отклонение

$$\sigma_x = \sqrt{D_x} = \sqrt{\frac{\sum_{i=1}^m (x_i - \bar{x})^2}{m}}$$

Преобразуем формулу дисперсии:

$$\begin{aligned} D_x &= \frac{\sum_{i=1}^m (x_i^2 - 2x_i\bar{x} + \bar{x})}{m} = \\ &= \frac{\sum_{i=1}^m x_i^2}{m} - \frac{2\bar{x} \sum_{i=1}^m x_i}{m} + \frac{m(\bar{x})^2}{m} = \\ &= \overline{x^2} - 2\bar{x}\bar{x} + (\bar{x})^2 = \overline{x^2} - 2(\bar{x})^2 + (\bar{x})^2; \end{aligned}$$

Дисперсия равна разности среднего значения квадратов признака  $x$  и квадрата среднего значения  $x$ .

$$D_x = \overline{x^2} - (\bar{x})^2$$

При оценке тесноты связи долю влияния фактора  $x$  можно определить как отношение дисперсии результативного показателя  $y$  за счет фактора  $x$  к общей дисперсии  $y$ .

Этот показатель называется *коэффициентом детерминации*

$$R^2 = \frac{D_{y_x}}{D_y}$$

Если уравнение теоретической линии имеет вид  
то их среднее значение

$$\bar{y}_x = a + b\bar{x}$$

$$y_x = a + bx$$

Тогда дисперсия за счет фактора  $x$  определяется из выражения:

$$D_{y_x} = \frac{\sum_{i=1}^m [(a + bx) - (a + b\bar{x})]^2}{m}$$

Поскольку

$$\frac{\sum (x - \bar{x})^2}{m} = D_x$$

то

$$D_{y_x} = b^2 \cdot D_x$$

Общая дисперсия показателя  $y$

$$D_y = \frac{\sum_{i=1}^m (y_i - \bar{y})^2}{m}$$

Коэффициент детерминации можно определить следующим образом

$$R^2 = \frac{b^2 D_x}{D_y}$$

Для оценки тесноты связи линейных зависимостей также используется показатель, который называется *коэффициентом корреляции* ( $r$ ):

$$r = \sqrt{R^2}$$

$$r = b \frac{\sigma_x}{\sigma_y}$$


Сильная	$0,7 \div 1,0$	$0,49 - 1,00$
Средняя	$0,3 \div 0,7$	$0,09 - 0,49$
Слабая	$< 0,3$	$< 0,09$

Коэффициент корреляции может быть рассчитан до решения задачи определения коэффициентов уравнения регрессии.

В этом случае его нужно выразить через статистические характеристики исходных данных.

# Теснота связи нелинейных зависимостей

Рассмотрим поле корреляции для нелинейной зависимости



Поле корреляции  
нелинейной зависимости



Всю совокупность исходных данных разделим на несколько групп. Номера групп обозначим буквой  $j$  ( $j=1, \dots, n$ ).

В каждой группе определим средние значения показателя  $y$ :

где  $y_j$  — значения показателя  $y$ , попавшие в  $j$ -ю группу;

$m_j$  — количество точек, попавших в  $j$ -ю группу.

Полученные средние значения  $y$  называются *групповыми средними*.

$$\bar{y}_1 = \frac{\sum y_1}{m_1}$$

$$\bar{y}_2 = \frac{\sum y_2}{m_2}$$

$$\bar{y}_n = \frac{\sum y_n}{m_n}$$

Определим межгрупповую дисперсию, которая представляет собой дисперсию групповых средних относительно общей средней

где  $\bar{y}$  общая средняя показателя  $y$

$$\bar{y} = \frac{\sum_{j=1}^n m_j y_j}{\sum_{j=1}^n m_j}$$

$$D_{\text{межгр}} = \frac{\sum_{j=1}^n m_j (\bar{y}_j - \bar{y})^2}{\sum_{j=1}^n m_j}$$

Теснота связи нелинейных зависимостей оценивается корреляционным отношением, которое представляет собой отношение межгруппового среднего квадратического отклонения к общему среднему квадратическому отклонению показателя  $y$

$$\eta = \frac{\sigma_{\text{межгр}}}{\sigma_{\text{общ}}}$$

$$\sigma_{\text{межгр}} = \sqrt{D_{\text{межгр}}}$$

$$\sigma_{\text{общ}} = \sqrt{D_{\text{общ}}} = \sqrt{\frac{\sum m_j (y_j - \bar{y})^2}{\sum m_j}}$$

Корреляционное отношение служит мерой тесноты связи любой, в том числе и линейной связи. Если корреляционное отношение равно коэффициенту корреляции, то это свидетельствует о том, что исследуемая зависимость может быть выражена в виде линейной корреляционной связи

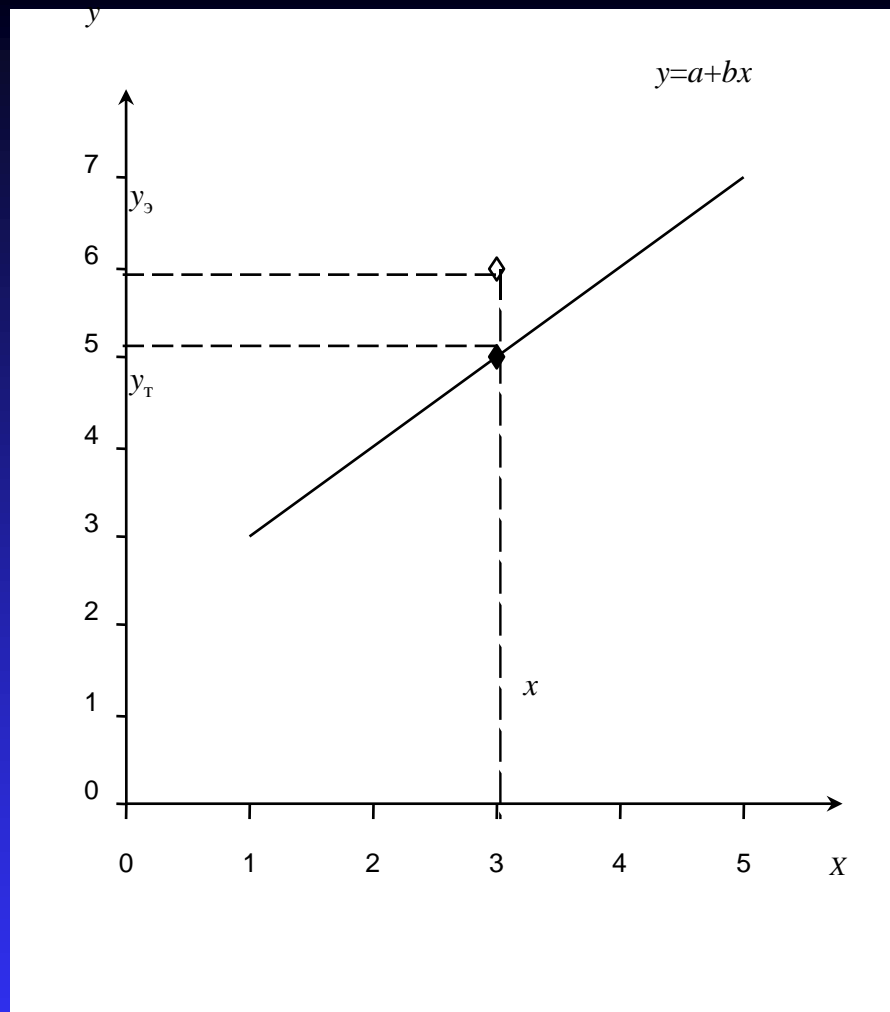
В процессе многомерного корреляционно-регрессионного анализа устанавливается зависимость результативного показателя от нескольких факторов.

Уравнение множественной регрессии имеет следующий вид

$$y = (x_1, \dots, x_i, \dots, x_m)$$

Например, для линейного уравнения регрессии необходимо определить такие значения коэффициентов  $a$  и  $b$ , которые минимизировали бы сумму квадратов отклонений теоретических значений  $y_T$  от эмпирических  $y_э$  для всех точек, построенных по данным наблюдений

$$S = \sum_{i=1}^m (y_{m_i} - y_{э_i})^2 \rightarrow \min$$



Геометрический смысл метода  
наименьших квадратов

## Линейная зависимость

В соответствии с методом наименьших квадратов минимизируемая сумма имеет следующий вид

$$S = \sum_{i=1}^m (a + bx_i - y_i)^2 \rightarrow \min$$

Для отыскания минимума приравняем нулю соответствующие частные производные:

$$\frac{\partial S}{\partial a} = 2 \sum_{i=1}^m (a + bx_i - y_i) = 0$$

$$\frac{\partial S}{\partial b} = 2 \sum_{i=1}^m (a + bx_i - y_i)x_i = 0$$

Выполним простейшие преобразования

$$ma + b \sum x_i - \sum y_i = 0 \quad a \sum x_i + b \sum x_i^2 - \sum x_i y_i = 0.$$

Первое уравнение умножим на  $\sum x_i$ , а второе — на  $(-m)$

$$ma \sum x_i + b \left( \sum x_i \right)^2 - \sum x_i \sum y_i = 0$$

$$-ma \sum x_i - bm \sum x_i^2 + m \sum x_i y_i = 0$$

Решив эту систему уравнений,  
найдем искомые коэффициенты:

$$a = \frac{\sum y_i - b \sum x_i}{m}$$

$$b = \frac{\sum x_i \sum y_i - m \sum x_i y_i}{\left(\sum x_i\right)^2 - m \sum x_i^2}$$



## *Гиперболическая зависимость*

Гиперболическую факторную модель вида можно линеаризовать путем замены переменной  $x$  на  $x'=1/x$ , после этого коэффициенты  $a$  и  $b$  можно определить по формулам, выведенным для линейной зависимости.

$$y = ax^b$$

$$\ln y = \ln a + b \ln x$$

## Степенная зависимость

Степенная факторная модель

линейная

$$y = ax^b$$

методом логарифмирования

Для определения коэффициентов линии регрессии производится замена переменных:

На основе расчетов, выполненных по формулам линейной зависимости, определяются параметры линейной модели

$$y' = a' + bx'$$

Коэффициент  $a$  степенной модели определяется из выражения

$$a = e^{a'}$$

$$a' = \ln a$$

$$y' = \ln y$$

$$x' = \ln x$$

В конечном итоге записывается степенная факторная модель

## Параболическая зависимость

$$(y = ax^2 + bx + c)$$

$$S = \sum (ax^2 + bx + c - y)^2 \rightarrow \min$$

$$\frac{\partial S}{\partial a} = 2 \sum (ax^2 + bx + c - y)x^2 = 0$$

$$\frac{\partial S}{\partial b} = 2 \sum (ax^2 + bx + c - y)x = 0$$

$$\frac{\partial S}{\partial c} = 2 \sum (ax^2 + bx + c - y) = 0$$

Для определения коэффициентов  $a$ ,  $b$  и  $c$  используется следующая система уравнений:

$$a \sum x^4 + b \sum x^3 + c \sum x^2 - \sum yx^2 = 0$$

$$a \sum x^3 + b \sum x^2 + c \sum x - \sum xy = 0$$

$$a \sum x^2 + b \sum x + mc - \sum y = 0$$

# Определение коэффициентов уравнения регрессии для случая двух влияющих факторов

В случае линейной многомерной зависимости, минимизируемая сумма квадратов отклонений теоретических значений результативного показателя от эмпирических имеет следующий вид

$$S = \Sigma(a + bx_1 + cx_2 - y)^2 \rightarrow \min$$

где  $a, b, \dots, k$  — коэффициенты уравнения регрессии;

$x_1, \dots, x_m$  — факторные показатели;

$y_3$  — эмпирические значения результативного показателя.

Определим коэффициенты уравнения регрессии для случая двух влияющих факторов

$$S = \Sigma(a + bx_1 + cx_2 - y)^2 \rightarrow \min$$

$$\frac{\partial S}{\partial a} = 2\Sigma(a + bx_1 + cx_2 - y) = 0$$

$$\frac{\partial S}{\partial b} = 2\Sigma(a + bx_1 + cx_2 - y)x_1 = 0$$

$$\frac{\partial S}{\partial c} = 2\Sigma(a + bx_1 + cx_2 - y)x_2 = 0$$

Коэффициенты  $a$ ,  $b$ , и  $c$

определяются путем

решения системы

уравнений с использованием правила Крамера.

$$na + b \sum x_1 + c \sum x_2 = \sum y$$

$$a \sum x_1 + b \sum x_1^2 + c \sum x_1 \cdot x_2 = \sum x_1 y$$

$$a \sum x_2 + b \sum x_1 \cdot x_2 + c \sum x_2^2 = \sum x_2 y$$

Определитель первой матрицы получается из  $D$  путем замены первого столбца на столбец свободных членов

$$D = \det \begin{pmatrix} n & \Sigma x_1 & \Sigma x_2 \\ \Sigma x_1 & \Sigma x_1^2 & \Sigma x_1 x_2 \\ \Sigma x_2 & \Sigma x_1 x_2 & \Sigma x_2^2 \end{pmatrix}$$

$$D_1 = \det \begin{pmatrix} \Sigma y & \Sigma x_1 & \Sigma x_2 \\ \Sigma x_1 y & \Sigma x_1^2 & \Sigma x_1 x_2 \\ \Sigma x_2 y & \Sigma x_1 x_2 & \Sigma x_2^2 \end{pmatrix}$$

$$D_2 = \det \begin{pmatrix} n & \Sigma y & \Sigma x_2 \\ \Sigma x_1 & \Sigma x_1 y & \Sigma x_1 x_2 \\ \Sigma x_2 & \Sigma x_2 y & \Sigma x_2^2 \end{pmatrix}$$

$$a = \frac{D_1}{D}$$

$$b = \frac{D_2}{D}$$

$$c = \frac{D_3}{D}$$

$$D_3 = \det \begin{pmatrix} n & \Sigma x_1 & \Sigma y \\ \Sigma x_1 & \Sigma x_1^2 & \Sigma x_1 y \\ \Sigma x_2 & \Sigma x_1 x_2 & \Sigma x_2 y \end{pmatrix}$$



МОПРЕД

А	В	С	Д	Е	Ф	Г	Н	І	Ј	К	Л
1	2	3									
4	5	6									
7	8	9									

(A1:C3)

МОПРЕД

Матрица — определитель основной матрицы.  
логично рассчитываются определители  $D_1, D_2$  и

Массив A1:C3 = {1;2;3;4;5;6;7;8;9}  
= 6,66134E-15

Возвращает определитель матрицы (матрица хранится в массиве).

Массив числовой массив с равным количеством строк и столбцов, диапазон ячеек или массив.

Значение: 6,66134E-16

OK Отмена

Помощник

Получаем

Вывести справку по этой теме?

- Да, вывести справку
- Нет, справка не нужна



Microsoft Excel - лабораторная работа 6\_2

Файл Правка Вид Вставка Формат Сервис Данные Окно Справка

75% Times New Roman Cyr 14 Ж У

B12 = 0,0001

	B	C	D	E	F	G	H	I
7								
8								
9								
10	$X_1$	$X_2$	$Y$	$X_1^2$	$X_2^2$	$X_1 \cdot X_2$	$X_1 \cdot Y$	$X_2 \cdot Y$
11	данные							
12	0,0001	0,0001	0,19078266750477	=B12*B12	=C12*C12	=B12*C12	=B12*D12	=C12*D12
13	0,239067585415	1,00006875416	1,07303324047758	=B13*B13	=C13*C13	=B13*C13	=B13*D13	=C13*D13
14	1,143529192918	1,9288430446	3,45277188802869	=B14*B14	=C14*C14	=B14*C14	=B14*D14	=C14*D14
15	1,847163352643	2,53125269648	5,26375064568345	=B15*B15	=C15*C15	=B15*C15	=B15*D15	=C15*D15
16	2,323680740529	2,6198461295	6,38289432359507	=B16*B16	=C16*C16	=B16*C16	=B16*D16	=C16*D16
17	2,6111113953821	2,71276086798	7,07121873671293	=B17*B17	=C17*C17	=B17*C17	=B17*D17	=C17*D17
18	3,338087093622	3,5272938559	9,00681629319257	=B18*B18	=C18*C18	=B18*C18	=B18*D18	=C18*D18
19	4,077888855506	4,3317243161	10,9683478025292	=B19*B19	=C19*C19	=B19*C19	=B19*D19	=C19*D19
20	4,600765757229	4,7171031404	12,2931804383652	=B20*B20	=C20*C20	=B20*C20	=B20*D20	=C20*D20
21	4,617526117833	5,5319316301	12,6052385138988	=B21*B21	=C21*C21	=B21*C21	=B21*D21	=C21*D21
22	5,259450139683	6,0790772228	14,2565739067141	=B22*B22	=C22*C22	=B22*C22	=B22*D22	=C22*D22
23	5,987643268677	6,8751240693	16,1887500960557	=B23*B23	=C23*C23	=B23*C23	=B23*D23	=C23*D23
24	6,175049895016	7,6069283479	16,8630357304393	=B24*B24	=C24*C24	=B24*C24	=B24*D24	=C24*D24
25	6,436196581356	8,5398618915	17,7734701262013	=B25*B25	=C25*C25	=B25*C25	=B25*D25	=C25*D25
26	6,987855413967	8,5925839579	19,0523459274186	=B26*B26	=C26*C26	=B26*C26	=B26*D26	=C26*D26
27	=СУММ(B12:B	=СУММ(C12:	=СУММ(D12:D26)	=СУММ(E12:D26)	=СУММ(F12:D26)	=СУММ(G12:D26)	=СУММ(H12:D26)	=СУММ(I12:I26)
28	$X_1$	$X_2$	$Y$	$X_1^2$	$X_2^2$	$X_1 \cdot X_2$	$X_1 \cdot Y$	$X_2 \cdot Y$

Лист1 Данные

Готово Сумма=274,682



	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R
--	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

27		55,645	66,594	152,44221	279,1545	398,26	332,09577	760,35	905,7										
----	--	--------	--------	-----------	----------	--------	-----------	--------	-------	--	--	--	--	--	--	--	--	--	--

28	$\Sigma$	$X_1$	$X_2$	$Y$	$X_1^2$	$X_2^2$	$X_1 \cdot X_2$	$X_1 \cdot Y$	$X_2 \cdot Y$										
----	----------	-------	-------	-----	---------	---------	-----------------	---------------	---------------	--	--	--	--	--	--	--	--	--	--

29	$D = \det \begin{pmatrix} n & \Sigma x_1 & \Sigma x_2 \\ \Sigma x_1 & \Sigma x_1^2 & \Sigma x_1 x_2 \\ \Sigma x_2 & \Sigma x_1 x_2 & \Sigma x_2^2 \end{pmatrix}$																		
30								15	55,6451	66,5945									
31								55,6451	279,155	332,096	3427,27								
32								66,5945	332,096	398,259									
33																			
34																			
35								$a = \frac{D_1}{D}$		0,19052									
36																			

37	$D_1 = \det \begin{pmatrix} \Sigma y & \Sigma x_1 & \Sigma x_2 \\ \Sigma x_1 y & \Sigma x_1^2 & \Sigma x_1 x_2 \\ \Sigma x_2 y & \Sigma x_1 x_2 & \Sigma x_2^2 \end{pmatrix}$																		
38																			
39								152,442	55,6451	66,5945									
40								760,353	279,155	332,096	652,965								
41								905,697	332,096	398,259									
42																			
43																			
44																			
45								$b = \frac{D_2}{D}$		2,28613									
46																			

47	$D_2 = \det \begin{pmatrix} n & \Sigma y & \Sigma x_2 \\ \Sigma x_1 & \Sigma x_1 y & \Sigma x_1 x_2 \\ \Sigma x_2 & \Sigma x_2 y & \Sigma x_2^2 \end{pmatrix}$																		
48																			
49								15	152,442	66,5945									
50								55,6451	760,353	332,096	7835,18								
51								66,5945	905,697	398,259									
52																			
53																			
54																			

55	$D_3 = \det \begin{pmatrix} n & \Sigma x_1 & \Sigma y \\ \Sigma x_1 & \Sigma x_1^2 & \Sigma x_1 y \\ \Sigma x_2 & \Sigma x_1 x_2 & \Sigma x_2 y \end{pmatrix}$																		
56																			
57																			
58								$c = \frac{D_3}{D}$		0,33595									
59																			
60								15	55,6451	152,442									
61								55,6451	279,155	760,353	1151,39								
62								66,5945	332,096	905,697									