

В реальных условиях функционирования технических объектов и организационно-технических систем зависимость результатов функционирования (откликов) от управляемых и контролируемых воздействий (факторов) проявляется как опосредованная разнообразными случайными причинами (возмущениями). Подобные зависимости принято называть стохастическими.

Стохастическую зависимость, которая проявляется как изменение только математического ожидания отклика, называют корреляционной. Рассматривая корреляционную зависимость отклика от одного фактора, говорят о парной корреляции. Если отклик связан корреляционной зависимостью с несколькими факторами, имеет место множественная корреляция. Характеристикой корреляционной зависимости является статистическая величина, называемая коэффициентом корреляции.

Корреляционный анализ – это метод математической статистики, который позволяет определить степень взаимосвязи между различными параметрами.

### 5.1. Парная корреляция

Для парной корреляции, при допущении, что и фактор и отклик имеют нормальные распределения, коэффициент корреляции выражается формулой:

$$\rho = \frac{M \{ [x - M(X)] [y - M(Y)] \}}{\sqrt{M [x - M(X)]^2 M [y - M(Y)]^2}} = \frac{K_{XY}}{\sqrt{D(X)D(Y)}}, \quad (5.1)$$

где  $K_{XY}$  - корреляционный момент. Он представляет собой математическое ожидание произведения отклонений значений  $x$  и  $y$  случайных величин  $X$  и  $Y$  от их математических ожиданий  $M(X)$  и  $M(Y)$ ;

$D(X)$  - дисперсия случайной величины  $X$ ;

$D(Y)$  - дисперсия случайной величины  $Y$ .

На практике каждая из случайных величин представляется ограниченным числом значений (выборкой размера  $n$ ). Поэтому вместо истинного значения коэффициента корреляции  $\rho$  может быть определена

лишь его оценка  $r$ , рассчитываемая с использованием выборочных характеристик отклика и фактора:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{(n-1) s_X s_Y}; \quad (5.2)$$

где  $\bar{x}$  и  $\bar{y}$  - средние выборочные значения фактора и отклика;

$s_X$  и  $s_Y$  - выборочные стандартные отклонения отклика и фактора;

$n$  - число наблюдений.

Коэффициент корреляции обладает следующими свойствами [4]:

1. Он не имеет размерности, и поэтому сопоставим для различных статистических рядов.

2. Значение  $r$  лежит в интервале от  $-1$  до  $+1$ . Если  $r = \pm 1$ , то зависимость между фактором и откликом является функциональной.

3. Положительное значение коэффициента корреляции указывает на возрастание отклика с увеличением фактора. Отрицательное значение  $r$  свидетельствует об убывании  $Y$  при возрастании  $X$ .

4. Равенство коэффициента парной корреляции нулю не означает отсутствия связи между откликом и фактором. В литературе [1, 3] отмечается, что значение  $r = 0$  указывает лишь, что эта взаимосвязь не является линейной, но не опровергает возможность существования между ними иной, например экспоненциальной, зависимости.

В *MS Excel* коэффициент парной корреляции можно вычислить с применением статистической функции КОРРЕЛ(). Синтаксис функции:

КОРРЕЛ(<Y>;<X>),

где <X> и <Y> - аргументы.

Аргументы должны быть числами, массивами чисел или ссылками на ячейки, содержащие числа. Если аргумент, который является массивом или ссылкой, содержит тексты, логические значения или пустые ячейки, то такие значения игнорируются; однако, ячейки с нулевыми значениями учитываются. Аргументы должны иметь одинаковое количество элементов (точек) данных, в противном случае функция КОРРЕЛ возвращает значение ошибки #Н/Д. Если хотя бы один из аргументов пуст (т. е. не содержит данных), или если стандартное отклонение данных хотя бы в одном из них равно нулю, то функция КОРРЕЛ возвращает значение ошибки #ДЕЛ/0!.

Поскольку коэффициент корреляции вычисляется на основании выборочных данных и является случайной величиной, его значение должно быть проверено на значимость. Смысл проверки состоит в выяснении

вопроса: является ли значение  $r \neq 0$  случайным событием, или коэффициент корреляции действительно не равен нулю?

Наиболее часто [1-5 и др.] критерием значимости коэффициента парной корреляции принимают условие:

$$t = \frac{|r|}{\sqrt{1-r^2}} \sqrt{n-2} > t[\alpha; n-2], \quad (5.3)$$

где  $t$  и  $t[\alpha; n-2]$  - рассчитанное и табличное числа Стьюдента. В MS Excel для определения табличного числа Стьюдента предусмотрена статистическая функция СТЬЮДРАСПОБР ( $\alpha; n-2$ ).

Возможен также иной подход, согласно которому фактическое значение коэффициента парной корреляции  $r$  сравнивается с минимальным статистически значимой величиной  $r_{min}$ :

$$r > r_{min} = \sqrt{\frac{1}{n-2 + \frac{(t[\alpha; n-2])^2}{n-2}}}, \quad (5.4)$$

Условия (3) и (4) не являются взаимоисключающими, поскольку получены из одной и той же исходной предпосылки. Если (3) или (4) выполняется, то коэффициент парной корреляции можно считать значимым с доверительной вероятностью  $p = 1 - \alpha$ .

## 5.2. Множественная корреляция

Множественная корреляция – обусловленность некоторого признака (например, отклика  $Y$ ) одновременным действием нескольких других признаков (например, факторов  $X_1, X_2, \dots, X_j, \dots, X_m$ ). При этом возможна парная корреляция среди факторов.

Взаимодействия отклика с каждым из факторов и факторов между собой отображают в виде *матрицы корреляции* (рис. 5.1).

	$Y$	$X_1$	...	$X_j$	...	$X_m$
$Y$	1	$r_{Y,X_1}$	...	$r_{Y,X_j}$	...	$r_{Y,X_m}$
$X_1$	$r_{Y,X_1}$	1	...	$r_{X_1,X_j}$	...	$r_{X_1,X_m}$
...	...	...	1	...	...	...
$X_j$	$r_{Y,X_j}$	$r_{X_1,X_j}$	...	1	...	$r_{X_j,X_m}$
...	...	...	...	...	1	...
$X_m$	$r_{Y,X_m}$	$r_{X_1,X_m}$	...	$r_{X_j,X_m}$	...	1

Рис. 5.1. Матрица корреляции.

Коэффициент множественной корреляции определяют из предположения, что отклик связан с факторами линейной зависимостью. Расчет выполняют по формуле:

$$R = \sqrt{1 - \frac{\Delta_{YX}}{\Delta_{XX}}}, \quad (5.5)$$

где  $\Delta_{YX}$  - определитель матрицы корреляции;

$\Delta_{XX}$  - определитель матрицы, получаемой из матрицы корреляции вычеркиванием первой строки и первого столбца.

Значимость множественного коэффициента корреляции проверяют с помощью критерия Фишера (F-критерия):

$$F_p = \frac{R^2}{(1 - R^2)} \frac{(n - m - 2)}{m} > F[\alpha; m; n - m - 2], \quad (5.6)$$

где  $F_p$  и  $F[\alpha; m; n - m - 2]$  - рассчитанное и табличное числа Фишера. В *MS Excel* табличное число Фишера можно определить с помощью статистической функции `FPASPOBR`( $\alpha; m; n - m - 2$ ).

Если условие (5.6) выполняется, то коэффициент множественной корреляции можно считать значимым с доверительной вероятностью  $p = 1 - \alpha$ .

При анализе степени совместного влияния комплекса факторов на отклик часто используют коэффициент множественной детерминации  $D = R^2$ . Его значение показывает, на сколько процентов изменчивость отклика обусловлена совместным действием рассматриваемых факторов.

### 5.3. Пример корреляционного анализа в *MS Excel*

В качестве примера рассмотрим анализ взаимосвязи предела текучести металла, прокатанного на широкополосном стане горячей прокатки (ШСП) от температуры конца прокатки (ткп) и смотки (тсм). Фрагмент рабочего листа с результатами работы представлен на рис.5.2.

Исходные данные вводятся с клавиатуры (на рис. 5.2 – в ячейки В3:D30).

	A	B	C	D	E	F	G	H	I
1		<b>ИСХОДНЫЕ ДАННЫЕ</b>				<b>Результат "КОРРЕЛЯЦИЯ"</b>			
2		<b>Ст, МПа</b>	<b>ткп,С</b>	<b>тсм,С</b>		<b>Sm, МПа    tkп,С    тсм,С</b>			
3		364,0	788	560		Ст, МПа	1		
4		341,2	788	584		ткп,С	-0,4736	1	
5		338,4	788	611		тсм,С	-0,8089	0	1
6		284,1	788	639					
7		330,9	788	657		<b>Матрица корреляции г(V,Xj)</b>			
8		281,9	788	715		Ст, МПа	ткп,С	тсм,С	
9		265,9	788	728		Ст, МПа	1	-0,474	-0,809
10		336,4	834	560		ткп,С	-0,474	1	0,000
11		320,5	834	584		тсм,С	-0,809	0,000	1
12		336,8	834	611					
13		299,4	834	639		<b>Оценивание значимости</b>			
14		269,3	834	657		<b>коэффициентов корреляции</b>			
15		240,3	834	715		n		28	
16		206,3	834	728		m		2	
17		334,2	875	560		$\alpha$		0,95	
18		290,3	875	584		t[ $\alpha$ ;n-2]		2,056	
19		318,5	875	611		t(Ст,ткп)		2,742	ДА
20		283,2	875	639		t(Ст,тсм)		7,015	ДА
21		281,0	875	657		t(тсм,ткп)		0,000	НЕТ
22		233,1	875	715					
23		200,0	875	728		<b>МНОЖЕСТВЕННАЯ КОРРЕЛЯЦИЯ</b>			
24		304,4	917	560		R		0,937	ДА
25		307,5	917	584		Fp		86,8019	
26		268,8	917	611		$\alpha$		0,95	
27		225,4	917	639		F[ $\alpha$ ;m;n-m-2]		3,4028	
28		270,3	917	657		D		87,9	%
29		181,3	917	715					
30		175,3	917	728					
31									

Рис. 5.2. Пример оформления рабочего листа при корреляционном анализе

### 5.3.1. Определение коэффициентов парной корреляции и оценивание их значимости

**Применение инструмента «Корреляция».** На рис. 5.2 результаты работы инструмента представлены в ячейках F2:I5. При этом в качестве исходных данных были приняты ячейки B2:D30 (т. е. в область данных включены и обозначения переменных), а в диалоговом окне инструмента «Корреляция» задана опция «Метки данных в первой строке». Более подробно описание работы с инструментом «Корреляция» приведено в приложении 5. В приложении 6 приведен пример построения матрицы корреляции в программе Statistica.

**Использование статистической функции КОРРЕЛ().** На рис. 5.2 результаты, полученные с использованием функции КОРРЕЛ(), оформлены в виде матрицы корреляции (ячейки F8:I11). Здесь обозначения изучаемых переменных введены с клавиатуры. Для определения коэффициента корреляции между пределом текучести и температурой конца прокатки в ячейках G10 и H9 запрограммировано:

$$=КОРРЕЛ(В3:В30;С3:С30).$$

В ячейках I9 и G11 определяется коэффициент парной корреляции между пределом текучести и температурой смотки:

$$=КОРРЕЛ(В3:В30;D3:D30).$$

Коэффициент корреляции между температурами конца прокатки и смотки (ячейки I10 и H11) определяется следующим образом:

$$=КОРРЕЛ(С3:С30;D3:D30).$$

### **Оценивание значимости коэффициентов парной корреляции.**

Для оценивания коэффициентов корреляции необходимо знать число наблюдений  $n$  и число факторов  $m$ . Число наблюдений определяется в ячейке H15 с использованием статистической функции СЧЕТ():

$$=СЧЕТ(В3:В30) .$$

Число факторов задается в ячейку H16 с клавиатуры.

В ячейку H17 с клавиатуры вводится доверительная вероятность  $\alpha$ , с которой будет оцениваться значимость результатов парного корреляционного анализа, а в ячейке H18 определяется табличное число Стьюдента:

$$=СТЮДРАСПОБР(1-H17;H15-2) .$$

В ячейках H19, H20 и H21 определяются числа Стьюдента для соответствующих коэффициентов корреляции, рассчитанные по формуле (3). Например, в ячейке H19:

$$=ABS(G10)*КОРЕНЬ($H$15-2)/КОРЕНЬ(1-G10^2) .$$

Выводы о значимости коэффициентов корреляции формируются в ячейках G19, G20 и G21 с помощью функции ЕСЛИ(). Например, в G19:

$$=ЕСЛИ(H19>$H$18;"ДА";"НЕТ") .$$

### **5.3.2. Определение коэффициента множественной корреляции и его оценивание**

Коэффициент множественной корреляции вычисляется в ячейке H24 по формуле (5.5) с использованием матрицы корреляции, представленной в ячейках F8:I11. В ячейку H24 запрограммировано:

$$=КОРЕНЬ(1-МОПРЕД(G9:I11)/МОПРЕД(H10:I11)) .$$

Расчетное число Фишера в ячейке H25 вычисляется по формуле (5.6):

$$=H24^28(H15-H16-2)/((1-H24^2)*H16) .$$

В ячейку H26 с клавиатуры вводится доверительная вероятность  $\alpha$  для оценивания значимости результатов множественного корреляционного анализа, а в ячейке H27 определяется табличное число Фишера:

$$=FRASPOBR(1-H26;H16;H15-H16-2).$$

Вывод о значимости коэффициента множественной корреляции формируются в ячейке G24 с помощью функции ЕСЛИ():

$$=ЕСЛИ(H25>H27;"ДА";"НЕТ").$$

В ячейке G28 рассчитывается коэффициент множественной детерминации:

$$=100*H24*H24.$$

### 5.3.3. Оценивание результатов

Оценивая результаты корреляционного анализа, необходимо ответить на следующие вопросы:

1. Связь между какими величинами анализировалась?
2. Какие коэффициенты парной корреляции являются статистически значимыми? О чем это свидетельствует?
3. Является ли значимым коэффициент множественной корреляции? Что это означает?
4. О чем свидетельствует значение коэффициента множественной детерминации?

Применительно к рассмотренному примеру можно сделать следующие выводы.

1. Анализировалась связь между пределом текучести металла  $\sigma_T$ , температурой конца прокатки  $t_{кп}$  и смотки  $t_{см}$  при прокатке на ШСГП.

2. С доверительной вероятностью 95% статистически значимыми являются коэффициенты корреляции между пределом текучести и температурой конца прокатки  $r(\sigma_T; t_{кп}) = -0,474$  а также между пределом текучести и температурой смотки  $r(\sigma_T; t_{см}) = -0,809$ . Значимость коэффициентов подтверждается тем, что соответствующие расчетные числа Стьюдента  $t(\sigma_T; t_{кп}) = 2,742$  и  $t(\sigma_T; t_{см}) = 7,015$  больше табличного  $t[0,05; 26] = 2,056$ . Следовательно, предел текучести металла, прокатанного на ШСГП, связан с температурой конца прокатки и смотки.

3. Так как коэффициенты корреляции отрицательные, увеличение как температуры прокатки, так и температуры смотки уменьшает предел текучести прокатанного металла.

4. Так как  $|r(\sigma_T; t_{см})| > |r(\sigma_T; t_{кп})|$ , степень влияния температуры смотки больше чем температуры конца прокатки.

5. С доверительной вероятностью 95% коэффициент множественной корреляции  $R(\sigma_T; t_{кп}; t_{см}) = 0,937$  является статистически значимым, т. к. расчетное число Фишера  $Fp = 86,802$  больше табличного  $F[0,05; 2; 24] = 3,4028$ . Это означает, что предел текучести металла, прока-

танного на ШСГП, обусловлен совместным действием температуры конца прокатки и смотки.

6. Коэффициент множественной детерминации  $D=0,937^2=0,879$  свидетельствует, что для рассмотренных условий прокатки на ШСГП предел текучести металла на 87,9% обусловлен сочетанием температуры конца прокатки и смотки.

#### **5.4. Контрольные вопросы**

1. Задача корреляционного анализа и его разновидности.
2. Коэффициент корреляции и его свойства
3. Характеристика степени взаимосвязи параметров при парном корреляционном анализе и условие, подтверждающее существование такой взаимосвязи
4. Характеристика степени взаимосвязи параметров при множественном корреляционном анализе и условие, подтверждающее существование такой взаимосвязи
5. Коэффициент множественной детерминации. Что он характеризует?