

### Регрессионный анализ

**Этимология:** «регрессия» – отступление, возврат  
 $x$  – отклонение от среднего роста отца  
 $y$  – отклонение от среднего роста сына  
 }  $\Leftarrow$  Положительная связь, но тенденция возврата  
 (отклонение у сына < отклонения у отца)  
 Закономерность – функция регрессии.

#### Классическая линейная модель множественной регрессии (КЛММР)

$$y_i = \theta_0 + \theta_1 x_i^{(1)} + \dots + \theta_p x_i^{(p)} + \varepsilon_i, \quad i = 1, \dots, n.$$

- 1)  $M\varepsilon_i = 0, \quad i = 1, \dots, n;$
- 2)  $M(\varepsilon_i \varepsilon_j) = \begin{cases} \sigma^2, & i = j \\ 0, & i \neq j \end{cases}$  – гомоскедастичность;  
 – взаимная некоррелированность;
- 3)  $rank X = p + 1 < n$  – одна объясняющая переменная не выражается через другую,  
 существует  $(X^T X)^{-1}$ ,  
 если  $p + 1 \geq n$ , то для выводов недостаточно данных.

#### Матричная форма:

$$Y = \begin{pmatrix} y_1 \\ \dots \\ y_n \end{pmatrix} \quad X = \begin{pmatrix} x_1^{(0)} = 1 & x_1^{(1)} & \dots & x_1^{(p)} \\ \dots & \dots & \dots & \dots \\ x_n^{(0)} = 1 & x_n^{(1)} & \dots & x_n^{(p)} \end{pmatrix} \quad \Theta = \begin{pmatrix} \theta_0 \\ \dots \\ \theta_p \end{pmatrix} \quad \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \dots \\ \varepsilon_n \end{pmatrix} \quad \sum_{\varepsilon} = \begin{pmatrix} M(\varepsilon_1^2) & \dots & M(\varepsilon_1 \varepsilon_n) \\ \dots & \dots & \dots \\ M(\varepsilon_n \varepsilon_1) & \dots & M(\varepsilon_n^2) \end{pmatrix}$$

$\uparrow$   
ковариационная матрица остатков

$$Y = X\Theta + \varepsilon, \quad M\varepsilon = \mathbf{0}_n, \quad \sum_{\varepsilon} = \sigma^2 E_n, \quad rank X = p + 1 < n.$$

Если  $\varepsilon \sim N(0; \sigma^2 E_n)$ , то нормальная КЛММР.

#### Оценивание неизвестных параметров. Метод наименьших квадратов (МНК)

Модельные значения  $\hat{y}_i = \hat{\theta}_0 + \hat{\theta}_1 x_i^{(1)} + \dots + \hat{\theta}_p x_i^{(p)}$  минимально отличаются от наблюдаемых  $y_i$ :

$$\sum_{i=1}^n \varepsilon_i^2 \rightarrow \min_{\theta_0, \dots, \theta_p}, \quad \varepsilon_i = y_i - \theta_0 - \theta_1 x_i^{(1)} - \dots - \theta_p x_i^{(p)}.$$

#### Матричная форма:

$$\varepsilon = Y - X\Theta, \quad (Y - X\Theta)^T (Y - X\Theta) \rightarrow \min_{\Theta}, \quad \boxed{(AB)^T = B^T A^T}$$

$$Y^T Y - 2\Theta^T X^T Y + \Theta^T X^T X \Theta \rightarrow \min_{\Theta}, \quad -2X^T Y + 2X^T X \Theta = 0,$$

$$\boxed{\hat{\Theta} = (X^T X)^{-1} X^T Y}$$

$\uparrow$  невырожденная

#### Случай парной регрессии:

$$X = \begin{pmatrix} 1 & x_1 \\ \dots & \dots \\ 1 & x_p \end{pmatrix} \quad X^T X = \begin{pmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{pmatrix} \quad X^T Y = \begin{pmatrix} \sum y_i \\ \sum x_i y_i \end{pmatrix}.$$

$$\begin{cases} n\theta_0 + \theta_1 \sum x_i = \sum y_i, \\ \theta_0 \sum x_i + \theta_1 \sum x_i^2 = \sum x_i y_i. \end{cases} \quad \theta_0 = \frac{\sum y_i - \theta_1 \sum x_i}{n},$$

$$\sum x_i \sum y_i - \theta_1 (\sum x_i)^2 + \theta_1 n \sum x_i^2 = n \sum x_i y_i, \quad \boxed{\hat{\theta}_1 = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{n \sum x_i^2 - (\sum x_i)^2}}, \quad \boxed{\hat{\theta}_0 = \bar{y} - \theta_1 \bar{x}}$$

## Помесячные данные о печати фотографий в некоторой фирме

	месяц	у, кол-во, шт.	$z^{(1)}$ , цена, руб.	$z^{(2)}$ , рекл., руб.	$z^{(3)}$ , праздники	$z^{(i)}$ , индекс цен
1	январь, 2003	12 500	2,5	0	3	1
2	февраль	7 600	3	0	1	0,99
3	март	6 900	3	0	1	1,01
4	апрель	13 500	3	5 000	0	1,01
5	май	9 700	3	0	3	1,03
6	июнь	10 700	3	2 000	1	1,04
7	июль	12 100	3	2 000	0	1,05
8	август	9 700	3,5	2 000	0	1,03
9	сентябрь	7 000	4	2 000	0	1,05
10	октябрь	7 200	4	2 000	0	1,05
11	ноябрь	8 200	4	2 000	1	1,06
12	декабрь	8 400	4	2 000	1	1,1
13	январь, 2004	13 100	4	2 000	3	1,11
14	февраль	8 700	4	0	1	1,12
15	март	12 200	4	5 000	1	1,14
16	апрель	6 900	4	0	0	1,16
17	май	6 200	4	0	3	1,17
18	июнь	9 600	4	0	1	1,19
19	июль	8 700	4	0	0	1,18
20	август	11 900	4	4 000	0	1,18
21	сентябрь	12 600	4	6 000	0	1,2
22	октябрь	7 900	4	1 000	0	1,22
23	ноябрь	9 300	4	2 000	1	1,24
24	декабрь	11 800	4	2 000	1	1,27

	у	$x^{(1)} = z^{(1)} / z^{(i)}$	$x^{(2)} = z^{(2)} / z^{(i)}$	$x^{(3)} = z^{(3)}$	$\hat{y}$ , прогноз	$\varepsilon$ , остатки
1	12 500	2,50	0	3	11 552	948
2	7 600	3,03	0	1	8 792	-1 192
3	6 900	2,97	0	1	8 968	-2 068
4	13 500	2,97	4 950	0	13 975	-475
5	9 700	2,91	0	3	10 339	-639
6	10 700	2,88	1 923	1	11 398	-698
7	12 100	2,86	1 905	0	10 857	1 243
8	9 700	3,40	1 942	0	9 310	390
9	7 000	3,81	1 905	0	8 059	-1 059
10	7 200	3,81	1 905	0	8 059	-859
11	8 200	3,77	1 887	1	8 745	-545
12	8 400	3,64	1 818	1	9 071	-671
13	13 100	3,60	1 802	3	10 350	2 750
14	8 700	3,57	0	1	7 202	1 498
15	12 200	3,51	4 386	1	12 354	-154
16	6 900	3,45	0	0	6 963	-63
17	6 200	3,42	0	3	8 852	-2 652
18	9 600	3,36	0	1	7 819	1 781
19	8 700	3,39	0	0	7 135	1 565
20	11 900	3,39	3 390	0	10 974	926
21	12 600	3,33	5 000	0	12 964	-364
22	7 900	3,28	820	0	8 390	-490
23	9 300	3,23	1 613	1	10 044	-744
24	11 800	3,15	1 575	1	10 225	1 575

$$X^T X = \begin{pmatrix} 24 & 79,23 & 36820 & 22 \\ 79,23 & 264,18 & 123426 & 70,42 \\ 36820 & 123426 & 114453587 & 18607 \\ 22 & 70,42 & 18607 & 46 \end{pmatrix}, \quad (X^T X)^{-1} = \begin{pmatrix} 4,83 & -1,39 & -0,00003 & -0,17 \\ -1,39 & 0,414 & -0,000005 & 0,0326 \\ -0,00003 & -0,000005 & 0,00000002 & 0,00001 \\ -0,17 & 0,0326 & 0,00001 & 0,0483 \end{pmatrix},$$

$$X^T Y = \begin{pmatrix} 232400 \\ 760351 \\ 407592667 \\ 217900 \end{pmatrix}, \quad \hat{\Theta} = \begin{pmatrix} 17094 \\ -2938 \\ 1,1327 \\ 600,86 \end{pmatrix}, \quad \hat{y}_i = 17094 - 2938x_i^{(1)} + 1,1327x_i^{(2)} + 600,86x_i^{(3)}.$$