

РЕГРЕССИОННЫЙ АНАЛИЗ

ПРИМЕРЫ

1. **Моделирование числа поступивших в университет для лучшего понимания факторов, удерживающих детей в том же учебном заведении.**
2. **Моделирование потоков миграции в зависимости от таких факторов как средний уровень зарплат, наличие медицинских, школьных учреждений, географическое положение...**
3. **Моделирование дорожных аварий как функции скорости, дорожных условий, погоды и т.д.,**
4. **Моделирование потерь от пожаров как функции от таких переменных как количество пожарных станций, время обработки вызова, или цена собственности. Суть регрессионного анализа заключается в нахождении наиболее важных факторов, которые влияют на зависимую переменную.**

статистический метод исследования влияния одной или нескольких независимых переменных X_1, X_2, \dots, X_n на зависимую переменную Y .

Независимые переменные иначе называют *регрессорами или*

$$Y = f(x_1, x_2, x_3) + \varepsilon,$$

где $f(x_1, x_2, x_3)$ — детерминированная составляющая отклика Y , зависящая от x_1, x_2, x_3 , а ε — случайная составляющая.

1) простая линейная регрессия

$$Y = \beta_0 + \beta_1 x + \varepsilon;$$

2) множественная регрессия

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_{k-1} x_{k-1} + \varepsilon;$$

3) полиномиальная регрессия

$$Y = \beta_0 + \beta_1 x + \beta_2 x^2 + \dots + \beta_{k-1} x^{k-1} + \varepsilon;$$

4) регрессионная модель общего вида:

$$Y = \beta_0 + \beta_1 \varphi_1(x_1, x_2, \dots, x_m) + \dots + \beta_{k-1} \varphi_{k-1}(x_1, x_2, \dots, x_m) + \varepsilon,$$

где $\varphi_i(x_1, x_2, \dots, x_m)$, $i = 1, 2, \dots, k-1$, — заданные функции факторов.

Коэффициенты $\beta_0, \beta_1, \dots, \beta_{k-1}$ называются *параметрами регрессии*.

КОЭФФИЦИЕНТ КОРРЕЛЯЦИИ

Количественная характеристика степени линейной зависимости между случайными величинами X и Y

Оценка коэффициента корреляции ρ , по выборке наблюдений (x_i, y_i) , $i = 1, 2, \dots, n$, вычисляется по формуле

$$r = \frac{Q_{xy}}{\sqrt{Q_x \cdot Q_y}},$$




$$Q_x = \sum (x_i - \bar{x})^2 = \sum x_i^2 - \frac{(\sum x_i)^2}{n};$$

$$Q_y = \sum (y_i - \bar{y})^2 = \sum y_i^2 - \frac{(\sum y_i)^2}{n};$$



$$Q_{xy} = \sum (x_i - \bar{x})(y_i - \bar{y}) = \sum x_i y_i - \frac{(\sum x_i)(\sum y_i)}{n};$$

$$\bar{x} = \frac{1}{n} \sum x_i, \quad \bar{y} = \frac{1}{n} \sum y_i.$$

ВАРИАНТЫ РАСПОЛОЖЕНИЯ «ОБЛАКА» ТОЧЕК



Величины X и Y **некоррелированы**, т.е. между ними нет линейной зависимости



$$-1 \leq \rho \leq 1$$

УСЛОВИЕ ПРИМЕНЕНИЯ УРАВНЕНИЯ ЛИНЕЙНОЙ РЕГРЕССИИ

когда между случайными величинами X и Y существует достаточно тесная линейная статистическая зависимость

$$|r| > 0,$$

$$y = \beta_0 + \beta_1 x,$$

где β_0 и β_1 — параметры линейной регрессии; x — независимая переменная (фактор, предиктор); y — зависимая переменная (отклик).

ОЦЕНКА ПАРАМЕТРОВ ЛИНЕЙНОЙ РЕГРЕССИИ y на x

$$\left. \begin{array}{l} \overline{\beta_0} \\ \overline{\beta_1} \end{array} \right\}$$

значения,
минимизирующие

$$Q(\beta_0, \beta_1) = \sum_{i=1}^n [y_i - (\beta_0 + \beta_1 x_i)]^2,$$

$Q(\beta_0, \beta_1)$ сумма квадратов отклонений значений зависимой переменной y_i от значений \tilde{y}_i , вычисляемых по уравнению регрессии: $\tilde{y}_i = \beta_0 + \beta_1 x_i$, $i = 1, 2, \dots, n$,

$$\bar{\beta}_1 = \frac{n \sum x_i y_i - (\sum x_i)(\sum y_i)}{n \sum x_i^2 - (\sum x_i)^2} = \frac{Q_{xy}}{Q_x}$$

$$\bar{\beta}_0 = \bar{y} - \bar{\beta}_1 \bar{x}.$$

ОЦЕНКА ПАРАМЕТРОВ ЛИНЕЙНОЙ РЕГРЕССИИ X

$$\tilde{\beta}'_1 = \frac{Q_{xy}}{Q_y};$$

$$\tilde{\beta}'_0 = \bar{x} - \tilde{\beta}'_1 \bar{y}.$$

Уравнения

$$y = \tilde{\beta}_0 + \tilde{\beta}_1 x = \bar{y} + r \frac{s_y}{s_x} (x - \bar{x})$$

и

$$x = \tilde{\beta}'_0 + \tilde{\beta}'_1 y = \bar{x} + r \frac{s_x}{s_y} (y - \bar{y}),$$

где s_x и s_y — оценки средних квадратических отклонений σ_x и σ_y :

$$s_x = \sqrt{s_x^2} = \sqrt{\frac{Q_x}{n}}, \quad s_y = \sqrt{s_y^2} = \sqrt{\frac{Q_y}{n}},$$

r — оценка коэффициента корреляции ρ , называются *выборочными уравнениями линейной регрессии*.

ЗАДАЧА ЛИНЕЙНОГО РЕГРЕССИОННОГО АНАЛИЗА

по результатам наблюдений $(x_i, y_i), i = 1, 2, \dots, n$

- а) получить наилучшие точечные и интервальные оценки неизвестных параметров β_0, β_1 и σ^2 ;
- б) проверить статистические гипотезы о параметрах модели;
- в) проверить, достаточно ли хорошо модель согласуется с результатами наблюдений (адекватность модели результатам наблюдений).

Несмещенная оценка дисперсии ошибок наблюдений S^2 связана с распределением $\chi^2(n-2)$ следующим соотношением

$$\frac{S^2}{\sigma^2} = \frac{\chi^2(n-2)}{n-2}, \quad S^2 = \frac{Q_e}{n-2}.$$

Всюду в дальнейшем будем предполагать, что ошибки наблюдений ε_i , $i = 1, 2, \dots, n$ имеют нормальное распределение: $\varepsilon_i \sim N(0, \sigma^2)$ и независимы.

Это предположение эквивалентно тому, что результаты наблюдений y_i , $i = 1, 2, \dots, n$ являются реализациями независимых нормально распределенных случайных величин Y_i :

$$Y_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2), \quad i = 1, 2, \dots, n.$$

Оценки $\tilde{\beta}_0$ и $\tilde{\beta}_1$ параметров линейной регрессии, вычисленные по формулам (1) и (2), как линейные функции Y_i , $i = 1, 2, \dots, n$ также будут случайными величинами, имеющими нормальное распределение:

$$\tilde{\beta}_0 \sim N(\beta_0, D[\tilde{\beta}_0]),$$

$$\tilde{\beta}_1 \sim N(\beta_1, D[\tilde{\beta}_1]),$$

где оценки дисперсии $\tilde{\beta}_0$ и $\tilde{\beta}_1$ соответственно равны:

$$D[\tilde{\beta}_0] = \frac{\sigma^2 (\sum x_i^2)}{nQ_x}, \quad D[\tilde{\beta}_1] = \frac{\sigma^2}{Q_x}.$$

Доверительный интервал для дисперсии ошибок наблюдений σ^2 имеет вид

$$\frac{(n-2)S^2}{\chi^2_{1-\frac{\alpha}{2}}(n-2)} < \sigma^2 < \frac{(n-2)S^2}{\chi^2_{\frac{\alpha}{2}}(n-2)},$$

где $\chi^2_p(n-2)$ — квантили распределения χ^2 с $(n-2)$ степенями свободы порядка p , а S^2 — оценка дисперсии ошибок наблюдений.

МАТРИЧНОЕ ПРЕДСТАВЛЕНИЕ ЗАДАЧИ ЛИНЕЙНОГО РЕГРЕССИОННОГО АНАЛИЗА

регрессионная матрица ($n \times 2$) $A = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix}$, вектор $Y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}$,

вектор параметров модели $\beta = \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix}$,

вектор ошибок наблюдений $\varepsilon = \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix}$.

Тогда простая линейная регрессия определяется матричным уравнением

$$Y = A\beta + \varepsilon.$$

ЗАДАНИЕ НА ПРАКТИЧЕСКУЮ РАБОТУ

1		2		3		4		5		6		7	
X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9	X_{10}	X_{11}	X_{12}	X_{13}	X_{14}
-2,2	-4,0	-0,5	3,3	1,2	2,8	2,8	4,0	1,4	-0,7	-1,0	-1,2	2,7	1,0
-0,1	0,2	0,9	0,5	-3,0	-1,1	0,6	4,1	-2,3	3,9	2,5	2,4	0,2	2,8
3,1	5,4	1,5	0,0	-0,4	3,0	3,0	2,9	0,2	1,6	3,3	5,3	-1,2	2,9
-0,2	0,7	0,6	1,0	2,3	4,3	-1,6	5,9	4,8	-2,7	2,2	3,9	-0,5	3,2
1,0	3,5	-0,2	1,7	-0,3	1,3	-0,7	5,5	1,2	-0,6	2,0	0,5	-0,7	2,5
8		9		10		11		12		13		14	
X_8	X_9	X_{10}	X_{11}	X_{12}	X_{13}	X_{14}	X_{15}	X_{16}	X_{17}	X_{18}	X_{19}	X_{20}	X_{21}
3,3	3,8	-0,2	4,5	3,5	2,0	4,2	1,5	1,8	7,1	6,2	2,5	5,3	3,5
1,1	3,7	0,8	6,2	1,5	-0,6	5,3	1,8	4,3	7,8	3,1	2,0	2,8	0,7
-1,4	-1,1	-1,2	3,2	3,5	4,7	1,4	2,5	0,0	1,8	1,7	0,6	3,0	2,1
2,7	3,5	-0,5	2,9	1,8	-0,7	0,3	2,9	1,3	2,3	8,0	3,6	3,5	1,3
0,8	2,5	1,0	5,3	-0,3	0,4	2,0	2,8	3,2	4,7	6,1	1,5	3,0	2,5
15		16		17		18		19		20		21	
X_{15}	X_{16}	X_{17}	X_{18}	X_{19}	X_{20}	X_{21}	X_{22}	X_{23}	X_{24}	X_{25}	X_{26}	X_{27}	X_{28}
5,6	1,0	3,7	2,8	9,2	0,5	1,7	2,3	4,8	6,8	4,4	4,7	7,1	5,4
6,1	2,5	3,7	2,5	1,2	7,8	4,9	5,0	3,0	7,8	3,8	6,4	4,5	6,5
6,1	2,2	3,9	1,3	4,3	5,3	0,6	2,5	5,8	6,1	2,4	4,3	8,3	4,6
5,6	5,5	3,9	1,3	6,5	4,5	8,0	7,1	4,5	6,8	3,4	4,3	6,7	5,4
2,7	6,0	1,9	3,4	4,5	4,2	1,0	3,1	6,5	4,5	2,3	2,7	10,4	4,0