

4_3: МЕТОД НАИМЕНЬШИХ КВАДРАТОВ

Пусть в результате измерений получена таблица некоторых значений функции $f(x)$:

x	x_1	x_2	$\dots$	x_n
$f(x)$	y_1	y_2	$\dots$	y_n

Нужно найти формулу, выражающую эту зависимость аналитически. Можно применить метод интерполяции: построить интерполяционный многочлен, значения которого в точках $x_1, x_2, \dots, x_n$, будут совпадать с соответствующими значениями функции $f(x)$ из таблицы. Однако совпадение значений в узлах может не означать совпадения характеров поведения исходной и интерполирующей функций.

Поставим задачу так, чтобы обязательно учитывался характер поведения табличной функции: найти функцию заданного вида

$$y = F(x), \quad (1)$$

которая в точках $x_1, x_2, \dots, x_n$ принимает значения **как можно более близкие** к табличным значениям $y_1, y_2, \dots, y_n$.

Вид приближающей функции F можно определить, построив точечный график функции $f(x)$, и проведя плавную кривую, **наилучшим образом** отражающую характер расположения точек (рис. 1).




Рис. 1

Формула (1) называется эмпирической формулой или **уравнением регрессии** y на x . Формула позволяет находить значения функции $f(x)$ для нетабличных значений x , "сглаживая" результаты измерений величины y .

Рассмотрим один из распространенных способов нахождения формулы (1). Предположим, что приближающая функция F в точках $x_1, x_2, \dots, x_n$ принимает значения

$$\overline{y_1}, \overline{y_2}, \dots, \overline{y_n} \quad (2)$$

Требование близости табличных значений $y_1, y_2, \dots, y_n$ и значений (2) можно истолковать следующим образом.

Будем рассматривать совокупность значений функции f из таблицы и совокупности (2), как координаты двух точек n -мерного пространства. Тогда задача приближения функции может быть сформулирована так: найти такую функцию F заданного вида, чтобы **расстояние** между точками $M(y_1, y_2, \dots, y_n)$ и $\overline{M}(\overline{y_1}, \overline{y_2}, \dots, \overline{y_n})$ **было наименьшим**. В Евклидовом пространстве приходим к требованию: величина

$$\sqrt{(y_1 - \overline{y_1})^2 + (y_2 - \overline{y_2})^2 + \dots + (y_n - \overline{y_n})^2} \quad (3)$$

минимальна, что равносильно следующему: сумма квадратов

$$(y_1 - \overline{y_1})^2 + (y_2 - \overline{y_2})^2 + \dots + (y_n - \overline{y_n})^2 \quad (4)$$

должна быть **наименьшей**.

Окончательно задачу приближения функции f сформулируем следующим образом: для функции f , заданной таблицей, найти функцию F определенного вида так, чтобы сумма квадратов (4) была наименьшей. Задача носит название приближения функции **методом наименьших квадратов**.

В качестве приближающих функций в зависимости от характера точечного графика функции f используют следующие функции:

- | | |
|------------------------|----------------------------|
| 1. $y = ax + b$ | 5. $y = \frac{1}{ax + b}$ |
| 2. $y = ax^2 + bx + c$ | 6. $y = a \ln x + b$ |
| 3. $y = ax^m$ | 7. $y = a \frac{1}{x} + b$ |
| 4. $y = ae^{mx}$ | 8. $y = \frac{x}{ax + b}$ |

Здесь a, b, c, m – параметры. Когда вид приближающей функции установлен, задача сводится к отысканию значений параметров.

Рассмотрим метод нахождения параметров приближающей функции в общем виде на примере функции с тремя параметрами:

$$y = F(x, a, b, c) \quad (5)$$

Составим сумму квадратов разностей $\sum_{i=1}^n (y_i - F(x_i, a, b, c))^2 = \Phi(a, b, c)$

Эта сумма является функцией $\Phi(a, b, c)$ трех переменных a, b, c . Задача сводится к отысканию ее минимума.

Необходимые условия экстремума:

$$\frac{\partial \Phi}{\partial a} = 0 \quad \frac{\partial \Phi}{\partial b} = 0 \quad \frac{\partial \Phi}{\partial c} = 0, \quad \text{т. е.}$$

$$\begin{cases} \sum_{i=1}^n [y_i - F(x_i, a, b, c)] \cdot F'_a(x_i, a, b, c) = 0 \\ \sum_{i=1}^n [y_i - F(x_i, a, b, c)] \cdot F'_b(x_i, a, b, c) = 0 \\ \sum_{i=1}^n [y_i - F(x_i, a, b, c)] \cdot F'_c(x_i, a, b, c) = 0 \end{cases} \quad (6)$$

Решив эту систему трех уравнений с тремя неизвестными относительно параметров a, b, c , получим конкретный вид искомой функции $y = F(x, a, b, c)$.

Значения найденной функции $y = F(x, a, b, c)$ в точках $x_1, x_2, \dots, x_n$ будут отличаться от табличных значений $y_1, y_2, \dots, y_n$.

$$\text{Разности } y_i - F(x_i, a, b, c) = \varepsilon_i \quad (i = 1, 2, \dots, n) \quad (7)$$

называются отклонениями измеренных значений от вычисленных по (5).

Для найденной эмпирической формулы (5) в соответствии с исходной таблицей можно найти сумму квадратов отклонений:

$$\sigma = \sum_{i=1}^n \varepsilon_i^2, \quad (8)$$

которая в соответствии с принципом наименьших квадратов для заданного вида приближающей функции и найденных параметров a, b, c должна быть наименьшей. Из двух разных приближений одной и той же табличной функции, следуя принципу наименьших квадратов, лучшим нужно считать то, для которого сумма (8) имеет наименьшее значение.

Линейная регрессия

Будем искать приближающую функцию в виде

$$F(x, a, b) = ax + b \quad (9)$$

Частные производные по параметрам равны: $\frac{\partial F}{\partial a} = x$; $\frac{\partial F}{\partial b} = 1$

$$\sum_{i=1}^n (y_i - ax_i - b)x_i = 0$$

Составим систему:

$$\sum_{i=1}^n (y_i - ax_i - b) = 0$$

$$\sum_{i=1}^n x_i y_i - a \sum_{i=1}^n x_i^2 - b \sum_{i=1}^n x_i = 0$$

Преобразуем

$$\sum_{i=1}^n y_i - a \sum_{i=1}^n x_i - nb = 0 \quad (10)$$

$$\left(\frac{1}{n} \sum_{i=1}^n x_i^2 \right) a + \left(\frac{1}{n} \sum_{i=1}^n x_i \right) b = \frac{1}{n} \sum_{i=1}^n x_i y_i$$

Разделим каждое уравнение на n :

$$\left(\frac{1}{n} \sum_{i=1}^n x_i \right) a + b = \frac{1}{n} \sum_{i=1}^n y_i$$

$$M_x = \frac{1}{n} \sum_{i=1}^n x_i$$

$$M_y = \frac{1}{n} \sum_{i=1}^n y_i$$

Обозначим:

$$M_{xy} = \frac{1}{n} \sum_{i=1}^n x_i y_i$$

$$M_{x^2} = \frac{1}{n} \sum_{i=1}^n x_i^2$$

(11)

$$M_{x^2} \cdot a + M_x \cdot b = M_{xy}$$

Тогда система (10) будет иметь вид:

$$M_x \cdot a + b = M_y \quad (12)$$

Коэффициенты этой системы M_x , M_y , M_{x^2} , M_{xy} — числа, которые в каждой конкретной задаче приближения могут быть легко выражены по формулам (11), где x_i , y_i — значения из таблицы. Решив систему (12) (метод Крамера), получим значения параметров a и b , а, следовательно, и конкретный вид линейной функции.

Можно показать, что нахождение приближающей функции в виде функции с двумя параметрами из приведенного списка сводится к линейной функции.