



Método de regresión lineal por mínimos cuadrados


Vamos a suponer que tenemos un conjunto de N datos (x_i, y_i) , donde cada valor y_i tiene un error asociado que llamamos σ_i , o sea $(y_i \pm \sigma_i)$ (los σ_i no tienen que ser iguales). Vamos a suponer que los datos representan cierto fenómeno físico que cumple una ley descrita por una función f .

Ajuste de una función lineal: Regresión lineal

Es el método de ajuste más adecuado para una distribución lineal. Sea un conjunto de datos (x_i, y_i) , las coordenadas del i -ésimo punto experimental, el subíndice i varía desde 1 (primer valor) hasta N (último valor).

$$f(x_i) = ax_i + b \quad (1)$$

Su representación gráfica sería



Si y_i es el valor medido, entonces,

$$ax_i + b \quad (2)$$

será el valor estimado, por lo que la desviación será

$$y_i - (ax_i + b). \quad (3)$$

Definiendo $w_i = 1/\sigma_i^2$, podemos escribir la desviación, tal que

$$s = \sum_{i=1}^N w_i [y_i - (ax_i + b)]^2 = \sum_{i=1}^N w_i [y_i - ax_i - b]^2 \quad (4)$$

sea mínima.

Aplicamos el método de mínimos cuadrados, para obtener a y b . Debe cumplirse las siguientes dos condiciones de mínimo de la función s .

$$\frac{\partial s}{\partial a} = 2 \sum_{i=1}^N w_i [y_i - ax_i - b] (-x_i) = 0 \quad (5)$$

$$\frac{\partial s}{\partial b} = 2 \sum_{i=1}^N w_i [y_i - ax_i - b] (-1) = 0 \quad (6)$$

Obtenemos, entonces, un sistema de dos ecuaciones con dos incógnitas (a y b)

$$\left(\sum_{i=1}^N w_i x_i^2 \right) a + \left(\sum_{i=1}^N w_i x_i \right) b = \left(\sum_{i=1}^N w_i x_i y_i \right) \quad (7)$$

$$\left(\sum_{i=1}^N w_i x_i \right) a + \left(\sum_{i=1}^N w_i \right) b = \left(\sum_{i=1}^N w_i y_i \right) \quad (8)$$

Resolviendo el sistema de ecuaciones, los valores de a y b son:

$$a = \frac{\left(\sum_{i=1}^N w_i \right) \left(\sum_{i=1}^N w_i x_i y_i \right) - \left(\sum_{i=1}^N w_i y_i \right) \left(\sum_{i=1}^N w_i x_i \right)}{\Delta} \quad (9)$$

$$b = \frac{\left(\sum_{i=1}^N w_i y_i \right) \left(\sum_{i=1}^N w_i x_i^2 \right) - \left(\sum_{i=1}^N w_i x_i y_i \right) \left(\sum_{i=1}^N w_i x_i \right)}{\Delta} \quad (10)$$

donde

$$\Delta = \left(\sum_{i=1}^N w_i \right) \left(\sum_{i=1}^N w_i x_i^2 \right) - \left(\sum_{i=1}^N w_i x_i \right)^2 \quad (11)$$

Los errores asociados a a y b son:

$$\sigma_a^2 = \frac{\left(\sum_{i=1}^N w_i \right)}{\Delta} \quad y \quad \sigma_b^2 = \frac{\sum_{i=1}^N w_i x_i^2}{\Delta} \quad (12)$$

Estas ecuaciones son generales y valen para el caso en que los σ_i son diferentes.

En el caso en que los σ_i sean iguales ($= \sigma$, o sea, el mismo valor para todo i), las expresiones

de a , b , σ_a^2 y σ_b^2 se pueden simplificar:

$$a = \frac{N \left(\sum_{i=1}^N x_i y_i \right) - \left(\sum_{i=1}^N y_i \right) \left(\sum_{i=1}^N x_i \right)}{\Delta} \quad (13)$$

$$b = \frac{\left(\sum_{i=1}^N y_i \right) \left(\sum_{i=1}^N x_i^2 \right) - \left(\sum_{i=1}^N x_i y_i \right) \left(\sum_{i=1}^N x_i \right)}{\Delta} \quad (14)$$

donde

$$\Delta = N \left(\sum_{i=1}^N x_i^2 \right) - \left(\sum_{i=1}^N x_i \right)^2 \quad (15)$$

Los errores asociados a a y b son:

$$\sigma_a^2 = \frac{\left(\sum_{i=1}^N w_i \right)}{\Delta} \quad y \quad \sigma_b^2 = \frac{\sum_{i=1}^N w_i x_i^2}{\Delta} \quad (16)$$

Una vez que se tienen los valores de a y b es necesario expresar de forma cuantitativa y cualitativa la calidad de ajuste. Por calidad se entiende intuitivamente lo que se separan los puntos experimentales y_i de la predicción de la recta $ax + b$. Cuantitativamente, la calidad de ajuste viene expresada numéricamente por el valor del coeficiente de correlación.

El **coeficiente de correlación** se define como

$$r = \frac{N \left(\sum_{i=1}^N x_i y_i \right) - \left(\sum_{i=1}^N y_i \right) \left(\sum_{i=1}^N x_i \right)}{\sqrt{N \left(\sum_{i=1}^N x_i^2 \right) - \left(\sum_{i=1}^N x_i \right)^2} \sqrt{N \left(\sum_{i=1}^N y_i^2 \right) - \left(\sum_{i=1}^N y_i \right)^2}} \quad (17)$$

Este coeficiente expresa la calidad del ajuste, en forma relativa es un número sin unidades. Puede demostrarse que cuanto más cercano a 1 sea el valor de r mejor será el ajuste y r nunca puede ser mayor que 1.