


● 回帰直線の定義

変量  $x$  と  $y$  から得られた 2 次元データ  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  に対して、 $a, b$  の関数

$$f(a, b) = \sum_{i=1}^n \{y_i - (ax_i + b)\}^2$$

が最小になるように  $a, b$  の値を定める。

このとき、直線  $y = ax + b$  を「 $y$  の  $x$  への回帰直線」、傾き  $a$  を「 $y$  の  $x$  への回帰係数」という。



$y$  の  $x$  への回帰直線

$$e_i = y_i - (ax_i + b)$$

距離の 2 乗の和が  $\sum_i e_i^2$  が最小

【方針】  $e_i = y_i - (ax_i + b)$  として  $a, b$  の関数  $f(a, b) = \sum_{i=1}^n e_i^2$  が最小になるような  $a, b$  の値を求めます。

$e_i = y_i - (ax_i + b)$  の右辺に  $-\bar{y} + \bar{y}$  と  $-a\bar{x} + a\bar{x}$  を加えます。

$$\begin{aligned} &= y_i - ax_i - b - \bar{y} + \bar{y} - a\bar{x} + a\bar{x} \\ &= (y_i - \bar{y}) - a(x_i - \bar{x}) + \bar{y} - a\bar{x} - b \end{aligned}$$

←→  
c と置きます

3項の 2 乗の展開公式を使います

$$e_i^2 = (y_i - \bar{y})^2 + a^2(x_i - \bar{x})^2 + c^2 - 2a(x_i - \bar{x})(y_i - \bar{y}) - 2ac(x_i - \bar{x}) + 2c(y_i - \bar{y})$$

$i$  を 1 から  $n$  まで動かして和を考えます。(Σは簡略表現します。)

$$\sum e_i^2 = \sum (y_i - \bar{y})^2 + a^2 \sum (x_i - \bar{x})^2 + nc^2 - 2a \sum (x_i - \bar{x})(y_i - \bar{y}) - 2ac \sum (x_i - \bar{x}) + 2c \sum (y_i - \bar{y})$$

分散、共分散の定義に従うと

この 2 項は 0 です。偏差の合計は 0 になるからです。

$$= n \cdot s_y^2 + na^2 \cdot s_x^2 + nc^2 - 2an \cdot s_{xy}$$

$$\frac{1}{n} \sum e_i^2 = a^2 \cdot s_x^2 - 2ars_x \cdot s_y + s_y^2 + c^2$$

$$= (as_x - rs_y)^2 - r^2s_y^2 + s_y^2 + c^2$$

$$= (as_x - rs_y)^2 + (1 - r^2)s_y^2 + c^2$$

平方完成  
「しばいてきます」

$$r = \frac{s_{xy}}{s_x \cdot s_y} \text{ より}$$

$$s_{xy} = rs_x \cdot s_y \text{ と置き換えると}$$

これにより、残差の 2 乗の平均は  $\begin{cases} as_x - rs_y = 0 \\ c = \bar{y} - a\bar{x} - b = 0 \end{cases}$  のとき最小となります。

つまり  $\begin{cases} a = \frac{rs_y}{s_x} = \frac{s_y}{s_x} \cdot \frac{s_{xy}}{s_x \cdot s_y} = \frac{s_{xy}}{s_x^2} \\ \bar{y} = a\bar{x} + b \end{cases}$  となります。 (終)