


(中部大学の教育支援サイト <https://edu.isc.chubu.ac.jp/> を参考にしました。)

問題 4個のデータ (x_1, y_1) , (x_2, y_2) , (x_3, y_3) , (x_4, y_4) をもとに回帰直線の方程式を求めます。

方針 「もっともらしい直線」を「残差の二乗の合計を最小にするする直線」と考えます。



図を参考にしながら $S = d_1^2 + d_2^2 + d_3^2 + d_4^2$ として S を実際に計算してみます。

$$\begin{aligned}
 S &= \{y_1 - (ax_1 + b)\}^2 + \{y_2 - (ax_2 + b)\}^2 + \{y_3 - (ax_3 + b)\}^2 + \{y_4 - (ax_4 + b)\}^2 \\
 &= y_1^2 - 2y_1(ax_1 + b) + (ax_1 + b)^2 \\
 &\quad + y_2^2 - 2y_2(ax_2 + b) + (ax_2 + b)^2 \\
 &\quad + y_3^2 - 2y_3(ax_3 + b) + (ax_3 + b)^2 \\
 &\quad + y_4^2 - 2y_4(ax_4 + b) + (ax_4 + b)^2 \\
 &= (y_1^2 + y_2^2 + y_3^2 + y_4^2) + a^2(x_1^2 + x_2^2 + x_3^2 + x_4^2) - 2b(y_1 + y_2 + y_3 + y_4) \\
 &\quad - 2a(x_1y_1 + x_2y_2 + x_3y_3 + x_4y_4) + 2ab(x_1 + x_2 + x_3 + x_4) + 4b^2
 \end{aligned}$$

データに基づく定数部分を
右の表のように置き換えると
 S は次のようになります。

$$\begin{aligned}
 A &= (y_1^2 + y_2^2 + y_3^2 + y_4^2) \\
 B &= (x_1^2 + x_2^2 + x_3^2 + x_4^2) \\
 C &= (y_1 + y_2 + y_3 + y_4) \\
 D &= (x_1y_1 + x_2y_2 + x_3y_3 + x_4y_4) \\
 E &= (x_1 + x_2 + x_3 + x_4)
 \end{aligned}$$

つまり,

$$\boxed{S = A + a^2B - 2bC - 2aD + 2abE + 4b^2 \quad \dots \quad (*1)} \quad \text{となります。}$$

* - - - - * - - - - * - - - - * - - - - * - - - - *



$$S = A + a^2B - 2bC - 2aD + 2abE + 4b^2 \quad \dots (*1)$$

A, B, C, D, E はテータに基づく定数と考えることができます。

そのうえで次のように考えることができます。

- b を固定すると, S は変数 a に関する 2 次関数である。
- a を固定すると, S は変数 b に関する 2 次関数である。

数学 I では 2 次関数の (最小値/最大値を与える) 頂点を平方完成によって求めますが、《頂点における接線の傾きは 0 である》ことを用いて S が最小となる点を見つけます。



(*1) を微分 (偏微分) します。

$$\frac{\partial S}{\partial a} = -2D + 2aB + 2bE = 0 \quad \dots \textcircled{1}$$

$$\frac{\partial S}{\partial b} = -2C + 2aE + 8b = 0 \quad \dots \textcircled{2}$$

①②を連立して a, b を求めます。

b を消去します。

$$\textcircled{1} \times 2 \quad -4D + 4aB + 4bE = 0$$

$$\textcircled{2} \times \frac{1}{2}E \quad -CE + aE^2 + 4bE = 0$$

$$\begin{array}{r} -4D + 4aB + 4bE = 0 \\ - \quad -CE + aE^2 + 4bE = 0 \\ \hline -4D + CE + (4B - E^2)a = 0 \end{array}$$

$$a = \frac{4D - CE}{4B - E^2}$$

a を消去します。

$$\textcircled{1} \times E \quad -2DE + 2aBE + 2bE^2 = 0$$

$$\textcircled{2} \times B \quad -2BC + 2aBE + 8bB = 0$$

$$\begin{array}{r} -2DE + 2aBE + 2bE^2 = 0 \\ - \quad -2BC + 2aBE + 8bB = 0 \\ \hline -2DE + 2BC + (2E^2 - 8B)b = 0 \end{array}$$

$$b = \frac{DE - BC}{E^2 - 4B} = \frac{BC - DE}{4B - E^2}$$

$$a = \frac{4D - CE}{4B - E^2} \quad \text{を一般的に書くと}$$

$$b = \frac{DE - BC}{E^2 - 4B} = \frac{BC - DE}{4B - E^2} \quad \text{は}$$

$$\begin{array}{l} a = \frac{nD - CE}{nB - E^2} \quad \dots \textcircled{3} \\ b = \frac{BC - DE}{nB - E^2} \quad \dots \textcircled{4} \end{array}$$

となります。

* - - - - * - - - - * - - - - * - - - - * - - - - *

このページでは 【③④が $a = \frac{s_{xy}}{s_x^2}$, $b = \bar{y} - \frac{s_{xy}\bar{x}}{s_x^2} = \bar{y} - a\bar{x}$ となることを示します。】

その前に【③, ④を変形するために, 式の表現とその意味をまとめておきます。】

分散の定義は「偏差の2乗の平均」つまり $s_x^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ ですが,

式を変形して「2乗の平均-平均の2乗」 $s_x^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - (\bar{x})^2$ と書くこともできます。

$$\text{つまり } s_x^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - (\bar{x})^2 = \bar{x}^2 - (\bar{x})^2 \quad \dots \textcircled{5}$$

$$\text{同様に } s_y^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 = \frac{1}{n} \sum_{i=1}^n y_i^2 - (\bar{y})^2 = \bar{y}^2 - (\bar{y})^2 \quad \dots \textcircled{6}$$

$$\text{共分散 } s_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \cdot \bar{y} = \overline{xy} - \bar{x} \cdot \bar{y} \quad \dots \textcircled{7} \text{ となります。}$$

$$\text{相関係数は定義により } r_{xy} = \frac{s_{xy}}{s_x s_y} \quad \dots \textcircled{8} \quad \text{これで準備完了です。}$$

【準備ができたところで, ③④を⑤⑥⑦⑧を用いて表現することを考えます。】

$$s_x^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - (\bar{x})^2 = \frac{\sum_{i=1}^n x_i^2}{n} - \left(\frac{\sum_{i=1}^n x_i}{n} \right)^2 = \frac{1}{n^2} (nB - E^2) \quad \dots \textcircled{5} \text{ を変形して}$$

$$\textcircled{3} \text{ の分母 } nB - E^2 = n^2 \cdot s_x^2 \quad \dots \textcircled{9} \text{ を得ます。}$$

$$s_{xy} = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \cdot \bar{y} = \frac{\sum_{i=1}^n x_i y_i}{n} - \frac{\sum_{i=1}^n x_i}{n} \cdot \frac{\sum_{i=1}^n y_i}{n} = \frac{1}{n^2} (nD - CE) \quad \dots \textcircled{7} \text{ を変形して}$$

$$\textcircled{3} \text{ の分子 } nD - CE = n^2 \cdot s_{xy} \quad \dots \textcircled{10} \text{ を得ます。}$$

これによって a を簡潔に表すことができました。

$$a = \frac{nD - CE}{nB - E^2} = \frac{n^2 \cdot s_{xy}}{n^2 \cdot s_x^2} = \frac{s_{xy}}{s_x^2}$$

* - - - - * - - - - * - - - - * - - - - * - - - - *

次に $b = \frac{BC - DE}{nB - E^2} \quad \dots \textcircled{4}$ この式を変形します。

④の分母は③の分母と同じで $nB - E^2 = n^2 \cdot s_x^2$

④の分子について右の置き換えを使います。

$$\begin{aligned} BC - DE &= n \cdot \overline{x^2} \times n \cdot \bar{y} - n \cdot \overline{xy} \times n \cdot \bar{x} \\ &= n^2 (\overline{x^2} \cdot \bar{y} - \overline{xy} \cdot \bar{x}) \\ &= n^2 \{ (s_x^2 + (\bar{x})^2) \cdot \bar{y} - (s_{xy} + \bar{x} \cdot \bar{y}) \cdot \bar{x} \} \end{aligned}$$

$$\begin{aligned} \textcircled{5} \quad s_x^2 &= \overline{x^2} - (\bar{x})^2 \text{ より } \overline{x^2} = s_x^2 + (\bar{x})^2 \\ \textcircled{7} \quad s_{xy} &= \overline{xy} - \bar{x} \cdot \bar{y} \text{ より } \overline{xy} = s_{xy} + \bar{x} \cdot \bar{y} \end{aligned}$$

$$\text{よって } b = \frac{BC - DE}{nB - E^2}$$

$$= \frac{s_x^2 \cdot \bar{y} + (\bar{x})^2 \cdot \bar{y} - s_{xy} \cdot \bar{x} - (\bar{x})^2 \cdot \bar{y}}{s_x^2}$$

$$= \bar{y} - \frac{s_{xy}}{s_x^2} \cdot \bar{x} = \bar{y} - a \cdot \bar{x} \quad \text{示されました。} \quad \textcircled{終}$$

一般の場合

$$A = \sum_{i=1}^n y_i^2 = n \cdot \overline{y^2}$$

$$B = \sum_{i=1}^n x_i^2 = n \cdot \overline{x^2}$$

$$C = \sum_{i=1}^n y_i = n \cdot \bar{y}$$

$$D = \sum_{i=1}^n x_i y_i = n \cdot \overline{xy}$$

$$E = \sum_{i=1}^n x_i = n \cdot \bar{x}$$

回帰直線の方程式は $y = ax + b$ で

$$a = \frac{s_{xy}}{s_x^2}, \quad b = \bar{y} - \frac{s_{xy}\bar{x}}{s_x^2} = \bar{y} - a\bar{x}$$

$$y - \bar{y} = a(x - \bar{x})$$

* - - - - * - - - - * - - - - * - - - - * - - - - *