


# 回帰分析と相関係数

## 1 回帰分析

下図のように  $(x, y)$  のデータをプロットしたとき,  $x, y$  に比例関係が成り立ちそうな場合がある. このデータにぴったり当てはまる直線の式  $y = ax + b$  を決定するのに最小二乗法が適用できる. このような, 二つの変数の間の関係式を求める分析を回帰分析と呼んでいる.



求める直線の式を  $y = ax + b$  とし,  $n$  個のデータを  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  とすると, 各計測値の残差は  $ax_i + b - y_i$  と表すことが出来る. 最小二乗法を適用するには, この残差の二乗和が最小となる  $a, b$  を求めることである. 残差の二乗和の関数  $\Phi$  は, 以下の式で表すことが出来る.

$$\Phi = \sum_{i=1}^n (ax_i + b - y_i)^2 \quad (1)$$

$\Phi$  の最小値を求めるが, このとき変数が  $X, Y$  の二個あるので偏微分により最小値を求める. すなわち,  $\Phi$  を  $X$  と  $Y$  とでそれぞれ偏微分し, それが 0 となる  $X, Y$  を計算する.

$$\begin{cases} \frac{\partial \Phi}{\partial a} = 2 \sum_{i=1}^n \{x_i(ax_i + b - y_i)\} = 0 \\ \frac{\partial \Phi}{\partial b} = 2 \sum_{i=1}^n (ax_i + b - y_i) = 0 \end{cases} \quad (2)$$

これを行列を用いて整理すると, 以下の式を得る. なお総和記号  $\sum$  は, ガウスの総和記号  $\Sigma$  で代用した.

$$\begin{pmatrix} \begin{bmatrix} x_i^2 \\ x_i \end{bmatrix} & \begin{bmatrix} x_i \\ n \end{bmatrix} \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} \begin{bmatrix} x_i y_i \\ y_i \end{bmatrix} \end{pmatrix} \quad (3)$$

この連立方程式を解けば, 最確値  $a, b$  が求まる.

## 2 相関係数

回帰分析によって求まった式が，どの程度の正確かを表すのに相関係数が一般に利用されている．相関係数は，分散と共分散を用いて計算できる． $x$  の平均 ( $\bar{x}$ ) 分散 ( $v_x$ )， $y$  の平均 ( $\bar{y}$ ) 分散 ( $v_y$ )， $x, y$  の共分散 ( $v_{xy}$ ) は，以下の式で表すことが出来る．

$$v_x = \sum_{i=1}^n (\bar{x} - x_i)^2 / n \quad (4)$$


$$v_y = \sum_{i=1}^n (\bar{y} - y_i)^2 / n \quad (5)$$

$$v_{xy} = \sum_{i=1}^n (\bar{x} - x_i)(\bar{y} - y_i) / n \quad (6)$$

相関係数 ( $r$ ) は，以下の式で表される．

$$r = \frac{v_{xy}}{\sqrt{v_x} \sqrt{v_y}} \quad (7)$$

相関係数は， $-1 \leq r \leq 1$  の範囲で， $1$  に近いほど正の相関が高く， $0$  に近いほど無相関， $-1$  に近いほど負の相関が高いといえる．下図においては，右側のグラフは相関が高く，左のグラフは相関が低い．



共分散が相関係数の値を左右しており，ランダムな点の集まりであれば， $(\bar{x} - x_i)$  の項と  $(\bar{y} - y_i)$  の項の符号はランダムに出現し，最終的に共分散の値は小さくなる．逆に共分散の値が大きくなる場合は， $(\bar{x} - x_i)$  の項と  $(\bar{y} - y_i)$  の項の符号プラス同士かマイナス同士で同じ場合である．

また共分散の意味は，ベクトルの内積と同じである． $(\bar{x} - x_i)$  の項を  $a_i$ ， $(\bar{y} - y_i)$  の項を  $b_i$  とおき，全てのデータを  $n$  次元のベクトル  $a(a_1, a_2, a_3, \dots, a_n)$  とベクトル  $b(b_1, b_2, b_3, \dots, b_n)$  とみなす．するとそれらの内積は， $a_1 b_1 + a_2 b_2 + a_3 b_3 + \dots + a_n b_n$  となり，それを  $n$  で割ったものが共分散である．一方，分散はベクトルの大きさと意味が同じである．つまり， $a^2 = (a_1^2 + a_2^2 + a_3^2 + \dots + a_n^2)$  となるからである．したがって相関係数  $r$  は，2つのベクトルのなす角度  $\theta$  の余弦といえ，その値は  $-1 \leq r \leq 1$  の範囲となる．

$$r = \frac{\mathbf{a} \cdot \mathbf{b}}{|\mathbf{a}| |\mathbf{b}|} = \cos \theta \quad (8)$$

したがって，相関係数が高いほど，二つのベクトルの方向が同じであるといえる．