

第9回 回帰分析(直線回帰)

高度な統計的分析の基本は、直線回帰分析である。ここでは、最も単純な単回帰分析について解説する。

単回帰分析は、ふたつの変量 x と y について、 x から y を予測するのに、最も誤差の少ない直線を求めようとする。

$y' = a + bx$ という式を考え、

誤差 $e_i = y_i - y'$ の2乗和を最小にするような a, b を求める。

$$\sum e_i^2 = \sum (y_i - y_i')^2 = \sum \{y_i - (a + bx_i)\}^2 \text{ が最小になればよい。}$$

これは正規方程式

$$\begin{cases} na + b \sum x_i = \sum y_i & \dots(A) \\ a \sum x_i + b \sum x_i^2 = \sum x_i y_i & \dots(B) \end{cases}$$

の解である。

【証明】

$$\sum e_i^2 = \sum (y_i - bx_i - a)^2 \text{ が最小になるように } a, b \text{ の値を決定するには、}$$

$$\frac{\delta}{\delta a} \sum e_i^2 = 0 \quad \text{かつ} \quad \frac{\delta}{\delta b} \sum e_i^2 = 0$$

となればよい。

$$\frac{\delta}{\delta a} \sum e_i^2 = \sum \frac{\delta}{\delta a} (y_i - bx_i - a)^2$$

$$= \sum 2(y_i - bx_i - a)(-1)$$

$$= \sum 2(a + bx_i - y_i)$$

$$= 2 \sum a + 2 \sum bx_i - 2 \sum y_i$$

$$= 2 \left(na + b \sum x_i - \sum y_i \right) = 0 \quad \therefore na + b \sum x_i = \sum y_i \quad \dots(A)$$

$$\begin{aligned}
 \frac{\delta}{\delta b} \sum e_i^2 &= \sum \frac{\delta}{\delta b} (y_i - bx_i - a)^2 \\
 &= \sum 2(y_i - bx_i - a)(-x_i) \\
 &= 2 \sum (ax_i + bx_i^2 - x_i y_i) \\
 &= 2 \left(a \sum x_i + b \sum x_i^2 - \sum x_i y_i \right) = 0 \quad \therefore a \sum x_i + b \sum x_i^2 = \sum x_i y_i \quad \dots \text{(B)}
 \end{aligned}$$

この正規方程式(A)(B)の解は、

$$b = \frac{S_{xy}}{S_x^2} \quad a = \bar{y} - b\bar{x} \quad \text{である。}$$

【証明】この正規方程式を b について解く。

$$\text{(A)} \times \sum x_i$$

$$na \sum x_i + b \sum x_i \sum x_i = \sum y_i \sum x_i \quad \dots \text{(1)}$$

$$\text{(B)} \times n$$

$$na \sum x_i + nb \sum x_i^2 = n \sum x_i y_i \quad \dots \text{(2)}$$

$$(1) - (2)$$

$$b \sum x_i \sum x_i - nb \sum x_i^2 = \sum y_i \sum x_i - n \sum x_i y_i$$

$$b \left(\sum x_i \sum x_i - n \sum x_i^2 \right) = \sum y_i \sum x_i - n \sum x_i y_i$$

$$b = \frac{\sum y_i \sum x_i - n \sum x_i y_i}{\left(\sum x_i \right)^2 - n \sum x_i^2}$$

$$\begin{aligned}
 &= \frac{\frac{1}{n^2} \left(\sum x_i \sum y_i - n \sum x_i y_i \right)}{\frac{1}{n^2} \left(\sum x_i \right)^2 - \frac{1}{n} \sum x_i^2} = \frac{S_{xy}}{S_x^2}
 \end{aligned}$$

$$\frac{1}{n^2} \left(\sum x_i \right)^2 = \bar{x}^2 \quad \text{であることに注意。}$$

a については、(A)を変形して、

$$na = \sum y_i - b \sum x_i$$

$$a = \frac{1}{n} \sum y_i - \frac{1}{n} b \sum x_i$$
$$= \bar{y} - b\bar{x}$$

よって、 $y' = a + bx$

$$= \bar{y} - b\bar{x} + bx$$

$$= \bar{y} + b(x - \bar{x})$$

$$= \bar{y} + \frac{S_{xy}}{S_x^2} (x - \bar{x})$$

ところで、 $r_{xy} = \frac{S_{xy}}{S_x S_y}$

$$\therefore y' = \bar{y} + r_{xy} \frac{S_y}{S_x} (x - \bar{x})$$

つまり、回帰式は、平均値 \bar{x} \bar{y} をとおり、傾きが $r_{xy} \frac{S_y}{S_x}$ の直線である。

また、回帰式の両辺を S_y で割ると、

$$\frac{y' - \bar{y}}{S_y} = r_{xy} \frac{x - \bar{x}}{S_x}$$

$$v' = r_{xy} u$$

相関係数は、標準測度の回帰係数（標準化された回帰係数）である。