

## < 2次元正規分布に従うデータと回帰直線 2 >

前ページの性質 [2] を示す。

各  $(X_i, Y_i)$  は 2次元正規分布に従い、その密度関数は

$$p(x, y) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} e^{-\frac{1}{2(1-\rho^2)}\left\{\left(\frac{x-m_X}{\sigma_1}\right)^2 - 2\rho\left(\frac{x-m_X}{\sigma_1}\right)\left(\frac{y-m_Y}{\sigma_2}\right) + \left(\frac{y-m_Y}{\sigma_2}\right)^2\right\}}$$

とする。これより P.16 定理 3 から

$$E[X_i] = m_X, \quad E[Y_i] = m_Y, \quad V(X_i) = E[(X_i - m_X)^2] = \sigma_1^2$$

$$V(Y_i) = E[(Y_i - m_Y)^2] = \sigma_2^2, \quad Cov(X_i, Y_i) = E[(X_i - m_X)(Y_i - m_Y)] = \rho\sigma_1\sigma_2$$

となる。一方、2次元データ  $(X_i, Y_i)$  ( $1 \leq i \leq n$ ) の統計量は

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i, \quad \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i, \quad S_{xx} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

$$S_{yy} = \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y})^2, \quad S_{xy} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$$

である。それらは確率変数であるから、その平均をとると

$$E[\bar{X}] = m_X, \quad E[\bar{Y}] = m_Y, \quad E[S_{xx}] = \frac{n-1}{n}\sigma_1^2$$

$$E[S_{yy}] = \frac{n-1}{n}\sigma_2^2, \quad E[S_{xy}] = \frac{n-1}{n}\rho\sigma_1\sigma_2$$

となる。(証明は不偏分散の項です。) 大数の法則より、 $n \rightarrow \infty$  のとき平均に近づくので、 $n$  が十分大きければ

$$\bar{X} \doteq m_X, \quad \bar{Y} \doteq m_Y, \quad S_{xx} \doteq \sigma_1^2, \quad S_{yy} \doteq \sigma_2^2, \quad S_{xy} \doteq \rho\sigma_1\sigma_2$$

とみなせる。

一方、データ  $(X_i, Y_i)$  の回帰直線の方程式は

$$y = \frac{S_{xy}}{S_{xx}}(x - \bar{X}) + \bar{Y} \quad (\text{データの回帰直線})$$

であるが、傾きは  $\frac{S_{xy}}{S_{xx}} \doteq \frac{\rho\sigma_1\sigma_2}{\sigma_1^2} = \rho\frac{\sigma_2}{\sigma_1}$  であり  $\bar{X} \doteq m_X, \bar{Y} \doteq m_Y$  より

この直線は

$$y = \rho\frac{\sigma_2}{\sigma_1}(x - m_X) + m_Y \quad (\text{前ページ直線②})$$

で近似できるので、性質 [2] が示された。