

単回帰モデルの確率論的取り扱い

Ver.2022.09.05

松浦 真也

単回帰モデルでは、目的変数 y の値は、説明変数 x の値から確定的に決まる部分に、誤差（ノイズ）が加わっていると考えることによって、確率論的取り扱いが可能となる。具体的には、目的変数に対応して、下記で定まる確率変数 Y_1, Y_2, \dots, Y_n を考える。

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad (i = 1, 2, \dots, n). \quad (\text{a})$$

ここで、 β_0, β_1 は定数とする。また、説明変数に相当する x_1, x_2, \dots, x_n も、値が確定している場合を考え、定数として扱う。さらに、ノイズに相当する $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ は、正規分布 $N(0, \sigma^2)$ に従う確率変数で、互いに独立とする。

確率変数 Y_1, Y_2, \dots, Y_n の実現値（標本）を y_1, y_2, \dots, y_n とし、確率変数 $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ の実現値（標本）を e_1, e_2, \dots, e_n とするとき、(a) 式は、

$$y_i = \beta_0 + \beta_1 x_i + e_i \quad (i = 1, 2, \dots, n) \quad (\text{b})$$

となる。

回帰分析において、 β_1 の推定値 $\hat{\beta}_1$ は、次のように計算される。

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \quad \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i, \quad S_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2, \quad S_{xy} = \sum_{i=1}^n (x_i - \bar{x})(Y_i - \bar{Y}), \quad \hat{\beta}_1 = \frac{S_{xy}}{S_{xx}}.$$

このとき、 $\hat{\beta}_1 \sim N\left(\beta_1, \frac{\sigma^2}{S_{xx}}\right)$ であることを、以下に示す。

ステップ0 まず、以下のことに留意する。

- x_i, \bar{x}, S_{xx} は定数、 $Y_i, \bar{Y}, S_{xy}, \hat{\beta}_1$ は確率変数である。
- $\varepsilon_i \sim N(0, \sigma^2)$ なので、(a) 式より、 $Y_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2)$ である。
- $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ は互いに独立なので、 Y_1, Y_2, \dots, Y_n も互いに独立である。
- $\sum_{i=1}^n (x_i - \bar{x}) = \sum_{i=1}^n x_i - \sum_{i=1}^n \bar{x} = \sum_{i=1}^n x_i - n\bar{x} = \sum_{i=1}^n x_i - \sum_{i=1}^n x_i = 0$.
- $\sum_{i=1}^n (x_i - \bar{x})\bar{Y} = \left\{ \sum_{i=1}^n (x_i - \bar{x}) \right\} \bar{Y} = 0 \cdot \bar{Y} = 0$ なので、 $S_{xy} = \sum_{i=1}^n (x_i - \bar{x})Y_i$ である。
従って、 $\hat{\beta}_1 = \frac{1}{S_{xx}} \sum_{i=1}^n (x_i - \bar{x})Y_i$ である。

ステップ1 Y_1, Y_2, \dots, Y_n は正規分布に従い、互いに独立なので、正規分布の再生性より、これらの線形和である $\hat{\beta}_1$ も正規分布に従う。

ステップ2 期待値の線形性より,

$$\begin{aligned} E[\hat{\beta}_1] &= E\left[\frac{1}{S_{xx}} \sum_{i=1}^n (x_i - \bar{x}) Y_i\right] = \frac{1}{S_{xx}} \sum_{i=1}^n (x_i - \bar{x}) E[Y_i] = \frac{1}{S_{xx}} \sum_{i=1}^n (x_i - \bar{x}) (\beta_0 + \beta_1 x_i) \\ &= \frac{1}{S_{xx}} \sum_{i=1}^n (x_i - \bar{x}) \{\beta_0 + \beta_1 (x_i - \bar{x}) + \beta_1 \bar{x}\} \\ &= \frac{1}{S_{xx}} \left\{ \beta_0 \sum_{i=1}^n (x_i - \bar{x}) + \beta_1 \sum_{i=1}^n (x_i - \bar{x})^2 + \beta_1 \bar{x} \sum_{i=1}^n (x_i - \bar{x}) \right\} = \frac{\beta_1 S_{xx}}{S_{xx}} = \beta_1. \end{aligned}$$

ステップ3 Y_1, Y_2, \dots, Y_n は互いに独立なので,

$$\begin{aligned} V[\hat{\beta}_1] &= V\left[\frac{1}{S_{xx}} \sum_{i=1}^n (x_i - \bar{x}) Y_i\right] = \frac{1}{S_{xx}^2} \sum_{i=1}^n (x_i - \bar{x})^2 V(Y_i) = \frac{1}{S_{xx}^2} \sum_{i=1}^n (x_i - \bar{x})^2 \sigma^2 \\ &= \frac{S_{xx} \sigma^2}{S_{xx}^2} = \frac{\sigma^2}{S_{xx}}. \end{aligned}$$

以上より, $\hat{\beta}_1$ は期待値が β_1 , 分散が $\frac{\sigma^2}{S_{xx}}$ の正規分布に従うことが分かった. すなわち, $\hat{\beta}_1 \sim N\left(\beta_1, \frac{\sigma^2}{S_{xx}}\right)$ である.