

第5章 統計学の回帰分析への応用

5.1 確率的モデル：単回帰モデル

再び，話を簡単にするために単回帰モデルを考えることにしよう。すなわち， (X_1, Y_1) ， (X_2, Y_2) ， \dots ， (X_n, Y_n) のように n 組のデータがあり， X_i と Y_i との間に線型関係を想定する。

$$Y_i = \alpha + \beta X_i$$

最小二乗法を用いて、データに直線のあてはめを行った。その結果、 $\hat{\alpha}$ 、 $\hat{\beta}$ 、 \hat{Y}_i を求めるための公式は、

$$\hat{\beta} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} = \frac{\sum_{i=1}^n X_i Y_i - n\bar{X}\bar{Y}}{\sum_{i=1}^n X_i^2 - n\bar{X}^2}$$
$$\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X}$$

であった。

$\hat{Y}_i = \hat{\alpha} + \hat{\beta}X_i$ とするとき、 Y_i 、 \hat{Y}_i 、 \hat{u}_i 、 $\hat{\alpha}$ 、 $\hat{\beta}$ の関係は以下の通りである。

$$Y_i = \hat{Y}_i + \hat{u}_i = \hat{\alpha} + \hat{\beta}X_i + \hat{u}_i$$

残差 \hat{u}_i が必ず含まれることから，回帰モデルを

$$Y_i = \alpha + \beta X_i + u_i$$

として誤差項（または，攪乱項） u_i を含め，それを確率変数として考える。

u_i は平均 0 ，分散 σ^2 の正規分布が仮定されることが多い。

ある確率密度分布（ここでは正規分布）があって，その分布に従い，データ（ここでは Y_i ）が生成されるモデルのことを確率的モデルと呼ぶ。

u_i は確率変数なので， Y_i も確率変数となる。

Y_i ：被説明変数，従属変数

X_i ：説明変数，独立変数

α, β : 未知母数 (未知パラメータ)

$\hat{\alpha}, \hat{\beta}$: 推定量 (ここでは, 最小二乗推定量), 時には, 推定値 (最小二乗推定値)

(* 復習) 推定量と推定値 :

統計学では,

母平均 μ の推定量は $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$, 推定値は $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$

母分散 σ^2 の推定量は $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$, 推定値は $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$

x_1, x_2, \dots, x_n は観測値 (または, 実現値)

X_1, X_2, \dots, X_n はそれぞれの観測値に対応する確率変数

1. 残差 \hat{u}_i は u_i の実現値としてみなすことができる。
2. 推定量 $\hat{\alpha}$, $\hat{\beta}$ の性質を統計学的に考察可能となる。

5.2 回帰モデルの仮定

回帰モデル

$$Y_i = \alpha + \beta X_i + u_i$$

の仮定：

1. X_i は確率変数でないと仮定する（固定された値）。

2. すべての i について , $\mathbf{E}(u_i) = 0$ とする。

3. すべての i について , $\mathbf{V}(u_i) = \sigma^2$ とする ($\mathbf{V}(u_i) = \mathbf{E}(u_i^2) = \sigma^2$ に注意)。

(* 復習) 分散 :

確率変数 X の平均 $\mu = \mathbf{E}(X)$, 分散 $\sigma^2 = \mathbf{V}(X)$

分散の定義 : $\sigma^2 = \mathbf{V}(X) = \mathbf{E}((X - \mu)^2) = \mathbf{E}(X^2) - \mu^2$

もし $\mu = \mathbf{E}(X) = 0$ であれば , $\sigma^2 = \mathbf{V}(X) = \mathbf{E}(X^2)$

4. すべての $i \neq j$ について , $\mathbf{Cov}(u_i, u_j) = 0$ とする ($\mathbf{Cov}(u_i, u_j) = \mathbf{E}(u_i u_j) = 0$ に注意)。

(* 復習) 共分散 :

確率変数 X, Y の平均 $\mu_X = \mathbf{E}(X)$, $\mu_Y = \mathbf{E}(Y)$, 共分散 $\sigma_{XY} = \mathbf{Cov}(X, Y)$

共分散の定義 : $\sigma_{XY} = \mathbf{Cov}(X, Y) = \mathbf{E}((X - \mu_X)(Y - \mu_Y)) = \mathbf{E}(XY) - \mu_X\mu_Y$

もし $\mu_X = \mathbf{E}(X) = 0$, または , $\mu_Y = \mathbf{E}(Y) = 0$ であれば , $\sigma_{XY} = \mathbf{Cov}(X, Y) = \mathbf{E}(XY)$

5. すべての i について , $u_i \sim N(0, \sigma^2)$ とする (正規分布)。

6. $n \rightarrow \infty$ のとき (データ数が無限大になると) , $\sum_{i=1}^n (X_i - \bar{X})^2 \rightarrow \infty$ とする。

攪乱項 u_1, u_2, \dots, u_n はそれぞれ互いに独立で，それぞれは平均ゼロ，分散 σ^2 の正規分布を仮定する。

再度，まとめて，回帰モデル：

$$Y_i = \alpha + \beta X_i + u_i \quad i = 1, 2, \dots, n$$

ただし， u_1, u_2, \dots, u_n はそれぞれ互いに独立で，

すべての $i = 1, 2, \dots, n$ について， $u_i \sim N(0, \sigma^2)$ を仮定する。

ただし，

Y_i ：被説明変数，従属変数

X_i ：説明変数，独立変数

α, β, σ^2 : 未知母数 (未知パラメータ)

$\hat{\alpha}, \hat{\beta}, s^2$: 推定量 (最小二乗推定量), s^2 (σ^2 の推定量) については後述。

(* 復習) 期待値 :

定数 a, b , 確率変数 X について, $\mathbf{E}(aX \pm b) = a\mathbf{E}(X) \pm b$

特に, 回帰直線 $Y_i = \alpha + \beta X_i + u_i$ について,

$$\mathbf{E}(Y_i) = \mathbf{E}(\alpha + \beta X_i + u_i) = \alpha + \beta X_i + \mathbf{E}(u_i) = \alpha + \beta X_i$$

として解釈される (α, β, X_i は非確率変数, u_i は確率変数)。

5.2.1 誤差項（攪乱項）の経済学的意味

1. 経済理論自身が不完全： X 以外にも他の説明変数が必要であるにもかかわらず、それを誤って除いている可能性がある。
2. モデルの定式化が不完全： Y と X との間の線形関係が誤りかもしれない。
3. 理論モデルとデータとの対応： 理論モデルで考えられる変数と実際に用いたデータが適当でないかもしれない。例：所得のデータについては国民総生産，国民所得，可処分所得，労働所得…，金利では公定歩合，国債利回り，定期預金金利，全国銀行平均約定金利…
4. 測定上の誤差： 経済データは一般的に推計されているため完全ではない。誤差を含む。

5.3 $\hat{\alpha}$, $\hat{\beta}$ の統計的性質

もう一度, 2つの式を並べて比べる。

$$Y_i = \alpha + \beta X_i + u_i \quad u_1, u_2, \dots, u_n \text{ はそれぞれ互いに独立で, } u_i \sim N(0, \sigma^2) \text{ を仮定}$$

$$Y_i = \hat{\alpha} + \hat{\beta} X_i + \hat{u}_i$$

$(\hat{\alpha}, \hat{\beta})$ は (α, β) の最小二乗法による推定量である。

すなわち,

$$\hat{\beta} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad \hat{\alpha} = \bar{Y} - \hat{\beta} \bar{X}$$

となる。

ただし ,

$$\bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i \quad \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

とする。

\hat{u}_i は残差で , $\hat{u}_i = Y_i - \hat{\alpha} - \hat{\beta}X_i$ と計算される。

5.3.1 $\hat{\beta}$ について

β の最小二乗推定量 $\hat{\beta}$ は次のように変形される。分母の添え字を j に変更する。

$$\begin{aligned}\hat{\beta} &= \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{j=1}^n (X_j - \bar{X})^2} \\ &= \frac{\sum_{i=1}^n (X_i - \bar{X})Y_i - \bar{Y} \sum_{i=1}^n (X_i - \bar{X})}{\sum_{j=1}^n (X_j - \bar{X})^2} \\ &= \frac{\sum_{i=1}^n (X_i - \bar{X})Y_i}{\sum_{j=1}^n (X_j - \bar{X})^2} \\ &= \frac{\sum_{i=1}^n (X_i - \bar{X})(\alpha + \beta X_i + u_i)}{\sum_{j=1}^n (X_j - \bar{X})^2} \\ &= \frac{\alpha \sum_{i=1}^n (X_i - \bar{X}) + \beta \sum_{i=1}^n (X_i - \bar{X})X_i + \sum_{i=1}^n (X_i - \bar{X})u_i}{\sum_{j=1}^n (X_j - \bar{X})^2}\end{aligned}$$

$$\begin{aligned}
&= \frac{\beta \sum_{i=1}^n (X_i - \bar{X})X_i - \beta \sum_{i=1}^n (X_i - \bar{X})\bar{X}}{\sum_{j=1}^n (X_j - \bar{X})^2} + \frac{\sum_{i=1}^n (X_i - \bar{X})u_i}{\sum_{j=1}^n (X_j - \bar{X})^2} \\
&= \frac{\beta \sum_{i=1}^n (X_i - \bar{X})^2}{\sum_{j=1}^n (X_j - \bar{X})^2} + \frac{\sum_{i=1}^n (X_i - \bar{X})u_i}{\sum_{j=1}^n (X_j - \bar{X})^2} \\
&= \beta + \frac{\sum_{i=1}^n (X_i - \bar{X})u_i}{\sum_{j=1}^n (X_j - \bar{X})^2} \\
&= \beta + \sum_{i=1}^n \omega_i u_i
\end{aligned}$$

である。ただし， $\omega_i = \frac{(X_i - \bar{X})}{\sum_{j=1}^n (X_j - \bar{X})^2}$ とする。

途中の計算（2行目の分子第2項目，5行目の分子第1項，6行目の分子第2項）で， $\sum_{i=1}^n (X_i - \bar{X}) = 0$ に注意せよ（ $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ から得られる）。

3行目から4行目では， $Y_i = \alpha + \beta X_i + u_i$ が代入されている。

3行目では， ω_i を使って，

$$\begin{aligned}\hat{\beta} &= \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{j=1}^n (X_j - \bar{X})^2} \\ &= \frac{\sum_{i=1}^n (X_i - \bar{X})Y_i}{\sum_{j=1}^n (X_j - \bar{X})^2} \\ &= \sum_{i=1}^n \omega_i Y_i\end{aligned}$$

と書き直すこともできる。

→ β の最小二乗推定量 $\hat{\beta}$ は Y_i の線形推定量となっている。

よって，まとめると，

$$\hat{\beta} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{j=1}^n (X_j - \bar{X})^2}$$

$$\begin{aligned} &= \sum_{i=1}^n \omega_i Y_i \\ &= \beta + \sum_{i=1}^n \omega_i u_i \end{aligned}$$

となる。 $\omega_i = \frac{(X_i - \bar{X})}{\sum_{j=1}^n (X_j - \bar{X})^2}$ である。

5.3.2 $\hat{\alpha}$ について

α の最小二乗推定量 $\hat{\alpha}$ については、

$$\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X}$$

$$\begin{aligned} &= \frac{1}{n} \sum_{i=1}^n Y_i - \bar{X} \sum_{i=1}^n \omega_i Y_i \\ &= \sum_{i=1}^n \left(\frac{1}{n} - \bar{X} \omega_i \right) Y_i \\ &= \sum_{i=1}^n \lambda_i Y_i \end{aligned}$$

となる。ただし， $\lambda_i = \frac{1}{n} - \bar{X} \omega_i$ である。

→ α の最小二乗推定量 $\hat{\alpha}$ は Y_i の線形推定量となっている。

さらに，書き換える。

$$\hat{\alpha} = \sum_{i=1}^n \left(\frac{1}{n} - \bar{X} \omega_i \right) Y_i$$

$$\begin{aligned}
&= \sum_{i=1}^n \left(\frac{1}{n} - \bar{X}\omega_i\right)(\alpha + \beta X_i + u_i) \\
&= \sum_{i=1}^n \left(\frac{1}{n} - \bar{X}\omega_i\right)\alpha + \sum_{i=1}^n \beta \left(\frac{1}{n} - \bar{X}\omega_i\right)X_i + \sum_{i=1}^n \left(\frac{1}{n} - \bar{X}\omega_i\right)u_i \\
&= \alpha + \sum_{i=1}^n \left(\frac{1}{n} - \bar{X}\omega_i\right)u_i \\
&= \alpha + \sum_{i=1}^n \lambda_i u_i
\end{aligned}$$

下記が途中で，

$$\begin{aligned}
\sum_{i=1}^n \omega_i &= \frac{\sum_{i=1}^n (X_i - \bar{X})}{\sum_{j=1}^n (X_j - \bar{X})^2} = 0 \\
\sum_{i=1}^n \omega_i X_i &= \sum_{i=1}^n \omega_i X_i - \sum_{i=1}^n \omega_i \bar{X} = \sum_{i=1}^n \omega_i (X_i - \bar{X}) = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sum_{j=1}^n (X_j - \bar{X})^2} = 1
\end{aligned}$$

が使われている ($\sum_{i=1}^n \beta(\frac{1}{n} - \bar{X}\omega_i)X_i = 0$ に注意)。

下記のように書き換えても同じ結果が得られる。

$$\begin{aligned}\hat{\alpha} &= \bar{Y} - \hat{\beta}\bar{X} \\ &= \alpha - (\hat{\beta} - \beta)\bar{X} + \bar{u} \\ &= \alpha - \bar{X} \sum_{i=1}^n \omega_i u_i + \frac{1}{n} \sum_{i=1}^n u_i \\ &= \alpha + \sum_{i=1}^n \left(\frac{1}{n} - \bar{X}\omega_i\right) u_i \\ &= \alpha + \sum_{i=1}^n \lambda_i u_i\end{aligned}$$

となる。 $\lambda_i = \frac{1}{n} - \bar{X}\omega_i$ としている。

1行目の \bar{Y} に $\bar{Y} = \alpha + \beta\bar{X} + \bar{u}$ が代入されている($Y_i = \alpha + \beta X_i + u_i$ を i について足し合わせて、 n で割ると、この式が得られる)。ただし、 $\bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i$ 、 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ 、 $\bar{u} = \frac{1}{n} \sum_{i=1}^n u_i$ である。

2行目の $\hat{\beta} - \beta$ に $\hat{\beta} = \beta + \sum_{i=1}^n \omega_i u_i$ が使われている。

まとめると、

$$\begin{aligned}\hat{\alpha} &= \alpha + \sum_{i=1}^n \left(\frac{1}{n} - \bar{X}\omega_i\right)u_i \\ &= \alpha + \sum_{i=1}^n \lambda_i u_i\end{aligned}$$

となる。

5.3.3 $\hat{\alpha}$, $\hat{\beta}$ の期待値 (平均)

$\hat{\beta}$ は次のように書き換えられた。

$$\hat{\beta} = \beta + \sum_{i=1}^n \omega_i u_i$$

の両辺に期待値をとる。

(* 復習) 期待値 :

定数 a, b , 確率変数 X について, $\mathbf{E}(aX \pm b) = a\mathbf{E}(X) \pm b \rightarrow$ (再掲)

(* 復習) 確率変数の和の期待値 :

2つの確率変数 X, Y について, $\mathbf{E}(X \pm Y) = \mathbf{E}(X) \pm \mathbf{E}(Y)$

$$\mathbf{E}(\hat{\beta}) = \mathbf{E}\left(\beta + \sum_{i=1}^n \omega_i u_i\right) = \beta + \sum_{i=1}^n \mathbf{E}(\omega_i u_i) = \beta + \sum_{i=1}^n \omega_i \mathbf{E}(u_i) = \beta$$

となる。

$\hat{\beta}$ は β の不偏推定量であると言える。

(* 復習) 不偏推定量について：

n 個の確率変数 X_1, X_2, \dots, X_n は互いに独立で，

それぞれは母数 θ に依存するものとする（例えば， $\theta = (\mu, \sigma^2)$ である）。

θ の推定量を $\hat{\theta} = \hat{\theta}(X_1, X_2, \dots, X_n)$ とする。

$E(\hat{\theta}) = \theta$ となるとき， $\hat{\theta}$ は θ の不偏推定量であるという。

$\hat{\alpha}$ については,

$$\hat{\alpha} = \alpha + \sum_{i=1}^n \lambda_i u_i$$

を利用して, 辺々に期待値をとると,

$$\mathbf{E}(\hat{\alpha}) = \mathbf{E}\left(\alpha + \sum_{i=1}^n \lambda_i u_i\right) = \alpha + \sum_{i=1}^n \lambda_i \mathbf{E}(u_i) = \alpha$$

$\lambda_i = \frac{1}{n} - \bar{X}\omega_i$ は非確率変数であることに注意。

$\hat{\alpha}$ は α の不偏推定量であると言える。