

II 回帰分析 (Regression Analysis)

1 回帰分析とは

理論モデル(因果関係の明示)→数学モデル(特定化)→確率モデル(攪乱項の導入)

理論 $Y_i = F(X_i) \rightarrow$ 線形モデル $Y_i = \alpha + \beta X_i$

\rightarrow 線形回帰モデル(Linear Regression Model) $Y_i = \alpha + \beta X_i + \varepsilon_i$

(1) 原因 X_i :説明変数(独立変数) \rightarrow 結果 Y_i :被説明変数(従属変数)

回帰: Galton(1822-1911) 親の身長 \rightarrow 子の身長

(2) 確率モデル(確率的かく乱項 ε)の必要性

①理論の不完全性(X のリストアップが不完全) ②線形近似の不完全性 ③測定誤差

$\varepsilon_i = \sum_{j=1}^{\infty} \varepsilon_i^j \rightarrow$ Central Limit Theorem $\rightarrow N(0, \sigma^2)$ かく乱項 ε は正規分布に従う

(3) 線形モデルの一般性 (p-40)

1) 両対数(double-logarithmic) $[\ln Y = \alpha + \beta \ln X]$:弾力性(elasticity)一定

2) 片対数(semi-logarithmic) $[Y = \alpha + \beta \ln X]$: X の最大値(最小値)が存在する

3) 片対数 $[\ln Y = \alpha + \beta X]$: Y の最大値(最小値)が存在する

4) 逆数(reciprocal) $[Y = \alpha + \beta / X]$: Y の最大値(最小値) $= \alpha$ が存在する, philips curve

5) 逆数 $[Y = \beta / (X - \alpha)]$: X の最大値(最小値) $= \alpha$ が存在する, $1/Y = -\alpha / \beta + 1/\beta X$

6) 高次(kth-order power) $[Y = \alpha + \beta_1 X + \dots + \beta_k X^k]$: 変曲点の存在, wage curve, cost curve

7) ロジット(logit) $[Y = \frac{e^{\alpha + \beta X}}{1 + e^{\alpha + \beta X}}] \rightarrow$ logit 変換 $[y = \log(Y/(1-Y)) = \alpha + \beta X]$

2. 点推定(point estimation)の方法

標本 (X, Y) から母集団 $(Y = \alpha + \beta X + \varepsilon)$ を推測する方法: ①最小2乗法 ②最尤法

2.1 最小2乗法(Least Squares Method) テキスト p-14

残差2乗和を最小化 $\min_{\alpha, \beta} S(\alpha, \beta) = \sum (Y_i - (\alpha + \beta X_i))^2 \rightarrow \partial S / \partial \alpha = \partial S / \partial \beta = 0$

$$S_{\alpha} = \sum 2(Y_i - (\alpha + \beta X_i))(-1) = 0, S_{\beta} = \sum 2(Y_i - (\alpha + \beta X_i))(-X_i) = 0$$

これより正規方程式 $n\alpha + \beta \sum X_i = \sum Y_i, \alpha \sum X_i + \beta \sum X_i^2 = \sum X_i Y_i$ が得られる。

X, Y の平均、分散、共分散が $\bar{X} = \sum X_i / n, s_X^2 = \sum X_i^2 / n - \bar{X}^2, \bar{Y} = \sum Y_i / n, s_Y^2 = \sum Y_i^2 / n - \bar{Y}^2, s_{XY} = \sum X_i Y_i / n - \bar{X} \cdot \bar{Y}$ のように書けることから、正規方程式は

$\bar{Y} - \alpha - \beta \bar{X} = 0, s_{XY} + \bar{X} \cdot \bar{Y} - \bar{X} \alpha - (s_X^2 + \bar{X}^2) \beta = 0$ となり、これを解くと

$$b = \frac{s_{XY}}{s_X^2} = \frac{\text{cov}(X, Y)}{\text{var}(X)}, a = \bar{Y} - b\bar{X} \text{ が得られる。}$$

Y_t とその推定値 $\hat{Y}_t = a + bX_t$ との回帰残差 $e_t = Y_t - (a + bX_t)$ は $\sum e_t = 0, \sum e_t x_t = 0$ となる。

2.2* 最尤法(Maximum Likelihood Method) テキスト p-201

中心極限定理(p-48)から $\varepsilon_i \sim N(0, \sigma^2)$ とすると $f(\varepsilon_i) = \frac{1}{\sqrt{2\pi\sigma}} e^{\left(-\frac{\varepsilon_i^2}{2\sigma^2}\right)}$ となる。

n 個の標本観測誤差が生じる同時確率(尤度)は

$$f(\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n) = f(\varepsilon_1) \cdot f(\varepsilon_2) \dots f(\varepsilon_n) = \left(\frac{1}{\sqrt{2\pi\sigma}} \right)^n e^{\left(-\frac{1}{2\sigma^2} \sum \varepsilon_i^2 \right)} = L(\alpha, \beta, \sigma^2) \text{ となる。}$$

この尤度 L を最大にする問題は単調増加変換した対数尤度 $\ln L$ 最大化問題と同値である

$\ln L(\alpha, \beta, \sigma^2) = n \ln \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right) - \frac{1}{2\sigma^2} \sum (Y_i - \alpha - \beta X_i)^2$ 最大化の1階の条件は最小2乗法の

条件と同一であるから、最小2乗推定量(LSE)と最尤推定量(MLE)は同じになる。

(σ^2 のMLEは $\sum e_i^2 / n$ となる)

3. 当てはまり(goodness of fit)の尺度: 決定係数(Coefficient of Determination) p-17

$e_i = Y_i - \hat{Y}_i$, $\hat{Y}_i = a + bX_i$ とすると $\sum e_i = 0$, $\sum X_i e_i = 0$, $\sum \hat{Y}_i e_i = a \sum e_i + b \sum X_i e_i = 0$ が成り立つ。

$$TSS = \sum (Y_i - \bar{Y})^2 = \sum (\hat{Y}_i - \bar{Y})^2 + \sum (Y_i - \hat{Y}_i)^2 = \sum (\hat{Y}_i - \bar{Y})^2 + \sum e_i^2 = ESS + RSS$$

両辺を TSS で割ると $1 = ESS/TSS + RSS/TSS$ が得られるが、

$$0 \leq r^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} \leq 1 \text{ を決定係数とよぶ。}$$

また相関係数 r は $r = \pm \sqrt{r^2}$ からも得ることができる

4. 重回帰分析(multiple regression analysis) p-53

4.1 最小2乗法(K変数モデル)

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + \dots + \beta_K X_{Kt} + \varepsilon_t, t=1, \dots, n$$

$$\min_{\beta_1, \dots, \beta_K} \sum_{t=1}^n (Y_t - \beta_1 - \beta_2 X_{2t} - \dots - \beta_K X_{Kt})^2$$

$$\sum 2(Y_t - \beta_1 - \beta_2 X_{2t} - \dots - \beta_K X_{Kt}) \cdot (-1) = 0 \rightarrow \sum Y_t = n\beta_1 + \beta_2 \sum X_{2t} + \dots + \beta_K \sum X_{Kt}$$

$$\sum 2(Y_t - \beta_1 - \beta_2 X_{2t} - \dots - \beta_K X_{Kt}) \cdot (-X_{2t}) = 0 \rightarrow \sum X_{2t} Y_t = \beta_1 \sum X_{2t} + \beta_2 \sum X_{2t}^2 + \dots + \beta_K \sum X_{2t} X_{Kt}$$

⋮

$$\sum 2(Y_t - \beta_1 - \beta_2 X_{2t} - \dots - \beta_K X_{Kt}) \cdot (-X_{Kt}) = 0 \rightarrow \sum X_{Kt} Y_t = \beta_1 \sum X_{Kt} + \beta_2 \sum X_{2t} X_{Kt} + \dots + \beta_K \sum X_{Kt}^2$$

この K 本の連立方程式を解けばよい。

※行列で考えるとすっきりするかも...

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + \dots + \beta_K X_{Kt} + \varepsilon_t, t=1, \dots, n \rightarrow \mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \rightarrow \mathbf{b}_{OLSE} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$$

$$\min S = \sum \varepsilon_t^2 = \boldsymbol{\varepsilon}'\boldsymbol{\varepsilon} = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) = \mathbf{y}'\mathbf{y} - 2\boldsymbol{\beta}'\mathbf{X}'\mathbf{y} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \rightarrow \mathbf{S}_{\boldsymbol{\beta}} = -2\mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\boldsymbol{\beta} = 0$$

4.2 当てはまりの尺度 p-68

(1) 決定係数、重相関係数

$$R^2 = 1 - \frac{\sum e_i^2}{\sum (Y_i - \bar{Y})^2} = (\mathbf{y} \text{ と } \hat{\mathbf{y}} \text{ の重相関係数})^2$$

(2) 自由度修正済決定係数

$$\bar{R}^2 = 1 - \frac{RSS/(n-k)}{TSS/(n-1)} = 1 - (1 - R^2) \frac{n-1}{n-k}$$

(3) その他の指標

赤池情報量基準 $AIC = \ln(\mathbf{e}'\mathbf{e}/n) + 2k/n$, Schwarz-Bayes 基準 $SC = \ln(\mathbf{e}'\mathbf{e}/n) + k/n \cdot \ln(n)$