

線形回帰モデル (P139)

$$\begin{cases} y_1 = \beta_1 x_{11} + \beta_2 x_{12} + \dots + \beta_k x_{1k} + \varepsilon_1 \\ \vdots \\ y_N = \beta_1 x_{N1} + \beta_2 x_{N2} + \dots + \beta_k x_{Nk} + \varepsilon_N \end{cases} \quad \leftarrow y_i = \beta_1 x_{i1} + \dots + \beta_k x_{ik} + \varepsilon_i \quad (i=1, 2, \dots, N)$$

y_i : 従属変数 or 被説明変数 (確率変数)


x_{ji} : 独立変数 or 説明変数 (定数) $\leftarrow$ 与えられた変数とみなす

ε_i : 誤差項

y を $x_1, \dots, x_k$ で説明する時, 説明できない部分が ε の中に含まれている。

$k=1$ の時, 単回帰モデル

$k \geq 2$ " 重回帰 "



$$\underbrace{\begin{pmatrix} y_1 \\ \vdots \\ y_N \end{pmatrix}}_{\mathbf{y}} = \underbrace{\begin{pmatrix} x_{11} & \dots & x_{1k} \\ \vdots & & \vdots \\ x_{N1} & \dots & x_{Nk} \end{pmatrix}}_{\mathbf{X}} \underbrace{\begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix}}_{\boldsymbol{\beta}} + \underbrace{\begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_N \end{pmatrix}}_{\boldsymbol{\varepsilon}}$$

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad \leftrightarrow \quad \mathbf{y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}) \quad E(\mathbf{y}) = \mathbf{X}\boldsymbol{\beta}$$

$$V(\mathbf{y}) = \sigma^2 \mathbf{I}$$

P141

仮定

(i) $E(\boldsymbol{\varepsilon}) = \mathbf{0}$

(ii) $V(\boldsymbol{\varepsilon}) = E(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}') = \sigma^2 \mathbf{I} = \underbrace{\begin{pmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{pmatrix}}_{\mathbf{I}_N} \Bigg\}^N$

$\uparrow$
互分散行列

$\varepsilon_1, \dots, \varepsilon_N$ は互いに無相関


(iii) $(\mathbf{X}'\mathbf{X})^{-1}$ が存在 (or $\text{rank}(\mathbf{X}) = k$)

proof

ex | $k=2$ $\varepsilon_i \sim N(0, \sigma^2)$ $X = \begin{pmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_N \end{pmatrix}$ $\beta = \begin{pmatrix} \beta_1 \\ \beta_2 \end{pmatrix}$

$$y_i = \beta_1 + \beta_2 x_i + \varepsilon_i \quad (i=1, 2, \dots, N)$$

$$y_i \sim N(\beta_1 + \beta_2 x_i; \sigma^2)$$



最小二乗推定量 (Least Squares Estimator (LSE))

$$\|y - XB\|^2 = (y - XB)'(y - XB) \text{ と最小にする } B = \hat{\beta} \text{ を}$$

最小二乗推定量 と言う。

$$0 = \frac{\partial}{\partial B} \|y - XB\|^2 = \frac{\partial}{\partial B} (y'y - B'X'y - \underline{y'XB} + B'X'XB)$$

$$= \frac{\partial}{\partial B} (y'y - 2B'X'y + B'X'XB)$$

$$= -2X'y + 2X'XB$$

$$\Leftrightarrow X'XB = X'y$$

$$\Leftrightarrow \beta = (X'X)^{-1}X'y$$

$$\hat{\beta} = (X'X)^{-1}X'y$$

$$\begin{aligned}
 \hat{\beta} &= (X'X)^{-1}X'Y = (X'X)^{-1}X'(\beta + \varepsilon) \\
 &= (X'X)^{-1}X'\beta + (X'X)^{-1}X'\varepsilon \\
 &= \beta + (X'X)^{-1}X'\varepsilon \quad (\hat{\beta} \text{ の確率的表現}).
 \end{aligned}$$

(1) 不偏性 (P144-145) $E(\hat{\beta}) = \beta$

PROOF

$$\begin{aligned}
 E(\hat{\beta}) &= E(\beta + (X'X)^{-1}X'\varepsilon) \\
 &= \beta + (X'X)^{-1}X' \underbrace{E(\varepsilon)}_{\mathbf{0}} = \beta
 \end{aligned}$$

(2) 分散共分散行列 $V(\hat{\beta}) = \sigma^2 (X'X)^{-1}$

$$\hat{\beta} - \beta = (X'X)^{-1}X'\varepsilon$$

$$\begin{aligned}
 V(\hat{\beta}) &= E((\hat{\beta} - \beta)(\hat{\beta} - \beta)') \\
 &= E((X'X)^{-1}X'\varepsilon \varepsilon' X (X'X)^{-1}) \quad X'X \text{ は対称}
 \end{aligned}$$

$$= (X'X)^{-1}X' \underbrace{E(\varepsilon \varepsilon')}_{\substack{\text{=} \\ V(\varepsilon) = \sigma^2 I_n}} X (X'X)^{-1}$$

$$= \sigma^2 (X'X)^{-1}X'X \underbrace{(X'X)^{-1}}_{I_k}$$

$$= \sigma^2 (X'X)^{-1}$$

(3) $\hat{\beta} \sim N(\beta, \sigma^2 (X'X)^{-1})$

PROOF

Fact 23.2より

$$\hat{\beta} = \beta + (X'X)^{-1}X'\varepsilon \quad \varepsilon \sim N(0, \sigma^2 I_n)$$

$\hat{\beta}$ は多変量正規分布に従う。 $\hat{\beta}$ の期待値と共分散行列は(1), (2)より

$$\hat{\beta} \sim N(\beta, \sigma^2 (X'X)^{-1})$$

P150

Gauss - Markov の定理

仮定 (i) - (iii).

 $\hat{\beta}$ は BLUE (Best Linear Unbiased Estimator).線形で unbiased 推定量 (Cy) の集まりの中で $\hat{\beta}$ は最も小さい分散を持つ

i.e.,

$$\tilde{\beta} = Cy = \begin{pmatrix} C_{11} & \cdots & C_{1N} \\ \vdots & & \vdots \\ C_{K1} & \cdots & C_{KN} \end{pmatrix} \begin{pmatrix} y_1 \\ \vdots \\ y_N \end{pmatrix}$$

$$\begin{pmatrix} \tilde{\beta}_1 \\ \vdots \\ \tilde{\beta}_K \end{pmatrix}$$

$$\hat{\beta} \quad E(\hat{\beta}) = \beta$$

$$\hat{\beta} = (X'X)^{-1}X'y$$

$$\begin{pmatrix} \hat{\beta}_1 \\ \vdots \\ \hat{\beta}_K \end{pmatrix} \quad C \text{ の } 1 \text{ つ}$$

$$V(\hat{\beta}_k) \leq V(\tilde{\beta}_k) \quad \text{for } \forall k$$

P151

補題1. $CX = I_k$

$$\text{Proof: } \tilde{\beta} = E(\tilde{\beta})$$

$$= E(Cy) \quad y \sim N(X\beta, \sigma^2 I_N)$$

$$= CX\beta \quad (\beta \neq 0 \text{ あり})$$

$$\Rightarrow CX = I_k.$$

補題2 $V(\tilde{\beta}) = \sigma^2 CC'$

$$\text{Proof } \tilde{\beta} = Cy = C(X\beta + \epsilon)$$

$$= CX\beta + C\epsilon \quad \text{補題1より}$$

$$= \beta + C\epsilon$$

$$\tilde{\beta} - \beta = C\epsilon$$

$$V(\hat{\beta}) = E[(\hat{\beta} - \beta)(\hat{\beta} - \beta)']$$

$$\hat{\beta} - \beta = C\epsilon$$

$$= E[C\epsilon(\epsilon\epsilon)']$$

$$= C E[\epsilon\epsilon'] C'$$

$$= C \sigma^2 I_n C'$$

$$= \sigma^2 C C'$$

$$\therefore C = (X'X)^{-1}X' + D \quad \text{where } D: \text{任意の行列.}$$

P153

不偏性の条件 $\hat{\beta} = CX = \{(X'X)^{-1}X' + D\}X$

この時 $DX = 0$

PROOF: $CX = I_k$

$$\Rightarrow \{(X'X)^{-1}X' + D\}X = I_k$$

$$\Rightarrow I_k + DX = I_k$$

$$\Rightarrow DX = 0$$

任意の線形不偏推定量の分散の差

$$\sigma^2 C C' = \sigma^2 (X'X)^{-1} + \sigma^2 D D'$$

PROOF. $\sigma^2 C C' = \sigma^2 \{(X'X)^{-1}X' + D\} \{(X'X)^{-1}X' + D\}'$

$$= \sigma^2 \{(X'X)^{-1}X' + D\} \{X(X'X)^{-1} + D'\}$$

$$= \sigma^2 \left(\underbrace{(X'X)^{-1}X'X}_{I} (X'X)^{-1} + \underbrace{(X'X)^{-1}X'D'}_0 + \underbrace{DX(X'X)^{-1}}_0 + DD' \right)$$

$$= \sigma^2 \{(X'X)^{-1} + DD'\}$$

$$\rightarrow V(\hat{\beta}) = V(\hat{\beta}_K) + \sigma^2 DD'$$

$$V(\hat{\beta}_K) = V(\hat{\beta}_K) + \underbrace{\sigma^2 \cdot \text{対角成分}}_{\geq 0}$$

$$V(\hat{\beta}_K) \geq V(\hat{\beta}_F)$$


P155

$$D = \begin{pmatrix} d_{11} & d_{12} & d_{13} \\ d_{21} & d_{22} & d_{23} \\ d_{31} & d_{32} & d_{33} \end{pmatrix}$$

$$DD' = \begin{pmatrix} \sum d_{1i}^2 & \sum d_{1i}d_{2i} & \sum d_{1i}d_{3i} \\ - & \sum d_{2i}^2 & - \\ - & - & \sum d_{3i}^2 \end{pmatrix}$$

対角成分は 0 以上

残差の分布について.



残差 $\hat{e} = y - X\hat{\beta}$ データと予測値のずれ

$$\begin{pmatrix} \hat{e}_1 \\ \vdots \\ \hat{e}_n \end{pmatrix}$$

$$\hat{e}\hat{e}' = (y - X\hat{\beta})(y - X\hat{\beta})' = \sum_i (y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_k x_{ik}))^2$$

表現 $\hat{e} = (I - X(X'X)^{-1}X')\varepsilon$

$$\hat{e} = y - X(X'X)^{-1}X'y \quad \text{投影ベクトル}$$

$$= (I - X(X'X)^{-1}X')y$$

$$= (I - X(X'X)^{-1}X')(X\beta + \varepsilon)$$

$$= X\beta - X(X'X)^{-1}X'X\beta + (I - X(X'X)^{-1}X')\varepsilon$$

$$= X\beta - X\beta + (I - X(X'X)^{-1}X')\varepsilon \quad \square$$

$M = I - X(X'X)^{-1}X'$ は対称なベキ等行列.

• M は対称、 $M' = M$

• M はベキ等行列 $M^2 = M$

← 演習問題

残差平方和 $\hat{e}\hat{e}' = \varepsilon'(I - X(X'X)^{-1}X')\varepsilon$

$$\begin{aligned} \hat{e}\hat{e}' &= \varepsilon'(I - X(X'X)^{-1}X')(I - X(X'X)^{-1}X')\varepsilon \\ &= \varepsilon'(I - X(X'X)^{-1}X')\varepsilon \end{aligned}$$

定理 (P255, Fact 25.3)

A : 対称なベキ等行列, $\text{rank}(A) = R$

$\varepsilon \sim N(0, \sigma^2 I)$

$$\frac{1}{\sigma^2} \varepsilon' A \varepsilon \sim \chi^2(R)$$

$$\hat{\epsilon}'\hat{\epsilon} = \epsilon'(\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\epsilon$$

"M: 対称, バネ等行列

$\text{rank}(M) = N - K$ (p235 Fact 22.37).

$$\epsilon \sim N(0, \sigma^2 \mathbf{I})$$

定理 (p255 Fact 25.3) より

$$\frac{1}{\sigma^2} \epsilon'(\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\epsilon \sim \chi^2(N - K)$$

$$\therefore E\left(\frac{1}{\sigma^2} \hat{\epsilon}'\hat{\epsilon}\right) = N - K$$

$$E\left(\frac{1}{N - K} \hat{\epsilon}'\hat{\epsilon}\right) = \sigma^2$$

$$\textcircled{c} \quad \hat{\sigma}^2 = \frac{1}{N - K} \hat{\epsilon}'\hat{\epsilon} = \frac{1}{N - K} \sum_i (y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \dots + \hat{\beta}_K x_{Ki}))^2$$

は σ^2 の不偏推定量となる

P119.

[決定係数]

注意!



$$y_i = \beta_1 + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \varepsilon_i$$

$$\text{回帰式 } \hat{y}_i = \hat{\beta}_1 + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_k x_{ik}$$

どのくらい回帰式の当てはまりが良いのか?

ex. (P109) $k=2$

$$y_i = \beta_1 + \beta_2 x_{i2} + \varepsilon_i \quad \mathbf{x} = \begin{pmatrix} 1 & x_{12} \\ \vdots & \vdots \\ 1 & x_{N2} \end{pmatrix} \quad \mathbf{\beta} = \begin{pmatrix} \beta_1 \\ \beta_2 \end{pmatrix}$$



$$R^2 = \frac{\sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2}{\sum_{i=1}^N (y_i - \bar{y})^2}$$

説明された変動
全変動

$$\bar{\hat{y}} = \frac{1}{N} \sum_{i=1}^N \hat{y}_i$$

$$\bar{y} = \frac{1}{N} \sum_{i=1}^N y_i$$

$$\text{実は} = \left\{ \frac{\sum_{i=1}^N (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^N (y_i - \bar{y})^2} \sqrt{\sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2}} \right\}^2$$

y と $\hat{y}$ の相関係数の2乗

$$\sum_{i=1}^N (y_i - \bar{y})^2 = \sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2 + \sum_{i=1}^N \hat{\varepsilon}_i^2 \quad (*) \quad \leftarrow \hat{\varepsilon} = \mathbf{y} - \mathbf{x}\hat{\mathbf{\beta}} = \begin{pmatrix} \hat{\varepsilon}_1 \\ \vdots \\ \hat{\varepsilon}_N \end{pmatrix}$$

$$1 = \underbrace{\frac{\sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2}{\sum_{i=1}^N (y_i - \bar{y})^2}}_{R^2} + \frac{\sum_{i=1}^N \hat{\varepsilon}_i^2}{\sum_{i=1}^N (y_i - \bar{y})^2}$$

回帰式 $\hat{y}_i$ にデータの何% を乗わせているかを示している

P121 Fact 13.2

$$X' \hat{e} = 0 \quad \hat{e}' X = 0'$$

PROOF

$$X' (Y - X\hat{\beta}) = X' Y - X' X (X' X)^{-1} X' Y = 0$$

P122 Fact 13.3.

$$\bar{y} = \bar{y}$$

PROOF. $1 = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} \in N \times 1$. $\frac{1}{N} 1' Y = \frac{1}{N} (1 \cdots 1) \begin{pmatrix} y_1 \\ \vdots \\ y_N \end{pmatrix} = \frac{1}{N} \sum_{i=1}^N y_i$

$$\begin{aligned} \frac{1}{N} 1' \hat{y} &= \frac{1}{N} 1' X \hat{\beta} = \frac{1}{N} 1' (Y - X \hat{e}) + \frac{1}{N} 1' Y \\ &= \frac{1}{N} 1' \hat{e} + \bar{y} \\ &= \frac{1}{N} \sum_{i=1}^N \hat{e}_i + \bar{y} = \bar{y} \end{aligned}$$

$$\uparrow X' \hat{e} = 0 \text{ (Fact 13.2)}$$

$$(\hat{e}_1 \cdots \hat{e}_N) \begin{pmatrix} 1 & x_{12} & \cdots & x_{1k} \\ \vdots & x_{n2} & \cdots & x_{nk} \end{pmatrix} = (0 \cdots 0)$$

補題

$$Y' Y = \hat{y}' \hat{y} + \hat{e}' \hat{e}. \quad (*2)$$

PROOF. $Y' Y = \underbrace{(X \hat{\beta} + Y - X \hat{\beta})'}_{\hat{e}'} \underbrace{(X \hat{\beta} + Y - X \hat{\beta})}_{\hat{e}}$

$$= (\hat{\beta}' X' + \hat{e}') (X \hat{\beta} + \hat{e})$$

$$= \underbrace{\hat{\beta}' X' X \hat{\beta}}_0 + \underbrace{\hat{e}' X \hat{\beta}}_0 + \underbrace{\hat{\beta}' X' \hat{e}}_{\text{Fact 13.2}} + \hat{e}' \hat{e}$$

$$= \hat{y}' \hat{y} + \hat{e}' \hat{e}.$$

(*2)より $\sum_{i=1}^N y_i^2 = \sum_{i=1}^N \hat{y}_i^2 + \sum_{i=1}^N \hat{e}_i^2$ と表わせる

Fact 13.3

$$\sum_{i=1}^N y_i^2 - N \bar{y}^2 = \sum_{i=1}^N \hat{y}_i^2 - N \bar{y}^2 + \sum_{i=1}^N \hat{e}_i^2 \quad \leftarrow \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2 = \frac{1}{N} \sum_{i=1}^N y_i^2 - \bar{y}^2$$

$$\sum_{i=1}^N (y_i - \bar{y})^2 = \sum_{i=1}^N (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^N \hat{e}_i^2$$

$\hat{\sigma}^2$ と $\hat{\beta}$ の関係

定理

$\hat{\sigma}^2$ と $\hat{\beta}$ は独立

(review) < 宮田 数理統計学の基礎 p38-40

確率ベクトル $X = (X_1, \dots, X_n)'$ と $Y = (Y_1, \dots, Y_m)'$ は独立 $X \perp Y$ と書く

def

$$\underbrace{f_{X,Y}}_{X \text{ と } Y \text{ の同時 pdf}}(x, y) = f_X(x) f_Y(y)$$

X と Y の同時 pdf

or

$$P(X \in A, Y \in B) = P(X \in A) P(Y \in B)$$

$$X \perp Y \Rightarrow g(X) \perp h(Y)$$

Fact 24.4. (P247)

$$\epsilon \sim N(0, \sigma^2 I_n)$$

M : 対称な正定値行列

$$\epsilon' M \epsilon \text{ と } \epsilon \text{ が独立} \Leftrightarrow LM = 0$$

PROOF 田舎

$$\text{これをいいると } \hat{\sigma}^2 = \frac{1}{N-k} \epsilon' M \epsilon \quad M = I - X(X'X)^{-1}X'$$

$$(N-k)\hat{\sigma}^2 = \epsilon' M \epsilon.$$

$$\hat{\beta} - \beta = \underbrace{(X'X)^{-1}X'}_I \epsilon$$

$$LM = (X'X)^{-1}X' (I - X(X'X)^{-1}X')$$

$$= (X'X)^{-1}X' - (X'X)^{-1}X'X (X'X)^{-1}X' = 0$$

$$\therefore \hat{\beta} - \beta \text{ と } (N-k)\hat{\sigma}^2 \text{ は独立}$$

$$\Rightarrow \hat{\beta} \text{ と } \hat{\sigma}^2 \text{ は独立}$$

(review)

t-分布 (岩田 暁 - p137-141)

 $X \sim N(0, 1), Y \sim \chi^2(\nu), X \perp Y$ とする. $T = \frac{X}{\sqrt{Y/\nu}}$ は自由度 ν の t 分布に従う. $\leftarrow T \sim t(\nu)$ とかく

$$\text{pdf } f(t) = \frac{\Gamma(\frac{\nu+1}{2})}{\sqrt{\nu\pi} \Gamma(\frac{\nu}{2})} \left(1 + \frac{t^2}{\nu}\right)^{-\frac{\nu+1}{2}} \quad -\infty < t < \infty.$$

$$E(T) = 0 \quad V(T) = \frac{\nu}{\nu-2}$$

定理 $(X'X)^{-1}$ の第 i 対角要素を a^{ii} とする.

$$\frac{\hat{\beta}_i - \beta_i}{\sigma \sqrt{a^{ii}}} \sim t(N-k).$$

$$\text{Proof } \hat{\beta} \sim N(\beta, \sigma^2 (X'X)^{-1}) \quad \leftarrow (X'X)^{-1} = \begin{pmatrix} a^{11} & a^{12} & \dots & a^{1k} \\ a^{21} & a^{22} & \dots & a^{2k} \\ \vdots & \vdots & \ddots & \vdots \\ a^{k1} & a^{k2} & \dots & a^{kk} \end{pmatrix}$$

$$\Rightarrow \hat{\beta}_i \sim N(\beta_i, \sigma^2 a^{ii}) \quad (i=1, 2, \dots, k)$$

$$\Rightarrow \frac{\hat{\beta}_i - \beta_i}{\sigma \sqrt{a^{ii}}} \sim N(0, 1^2).$$

$$\text{一方 } \frac{1}{\sigma^2} \hat{e}' \hat{e} \sim \chi^2(N-k)$$

$$\frac{N-k}{\sigma^2} \hat{\sigma}^2$$

 $\therefore \hat{\beta}_i \perp \hat{\sigma}^2 \Rightarrow X \text{ と } Y \text{ は独立}$

$$T = \frac{X}{\sqrt{Y/\nu}} \sim t(N-k)$$

$$\frac{\hat{\beta}_i - \beta_i}{\sigma \sqrt{a^{ii}}} \cdot \frac{\sqrt{(N-k) \hat{\sigma}^2}}{\hat{\sigma} \sqrt{N-k}} = \frac{\hat{\beta}_i - \beta_i}{\hat{\sigma} \sqrt{a^{ii}}} \quad \square$$

P159 検定


$$y_i = \beta_1 x_{i1} + \beta_2 x_{i2} + \varepsilon_i \quad (i=1, 2, \dots, N)$$

$\uparrow$ $\uparrow$ $\uparrow$
 犬の体重 飼料の体重 運動時間

帰無仮説

対立仮説

$$H_0: \beta_1 = 0 \quad \text{vs} \quad H_a: \beta_1 \neq 0$$

① H_0 が正しいと仮定

② ①の下で $\hat{\beta}_1$ の理論的な確率分布を求める $\rightarrow \frac{\hat{\beta}_1 - \beta_1}{\hat{\sigma} \sqrt{a_{11}}} \sim t(N-2)$


③ 実際のデータから $\hat{\beta}_1$ を計算する (これは $\hat{\beta}_1$ の実現値と言い $\hat{\beta}_1^*$ と書く).

そして $\hat{\beta}_1^*$ と H_0 のすれを測定

$$T = \frac{\hat{\beta}_1 - \beta_1^0}{\hat{\sigma} \sqrt{a_{11}}} \sim t(N-2)$$

$$t^* = \frac{\hat{\beta}_1^* - \beta_1^0}{\hat{\sigma} \sqrt{a_{11}}}$$

p-value
 と言う.



$$2P(T > t^*) < 0.05 \Rightarrow H_0 \text{ を棄却}$$

$$" \geq 0.05 \Rightarrow H_a \text{ を採択}$$

さいゆう
[最尤推定量] $\varepsilon \sim N(0, \sigma^2 I_n)$

(Maximum Likelihood Estimator) $Y = XB + \varepsilon \quad Y \sim N(X\beta, \sigma^2 I_n)$

MLE pdf $f(Y) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left\{-\frac{1}{2\sigma^2}(Y - X\beta)'(Y - X\beta)\right\}$

対数尤度 $\ell(\beta, \sigma^2) = \log f(Y)$

$$= -\frac{N}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2}(Y - X\beta)'(Y - X\beta)$$

$\ell(\beta, \sigma^2)$ を最大になるような β, σ^2 を求める

$$0 = \frac{\partial}{\partial \beta} \ell(\beta, \sigma^2) = -\frac{1}{2\sigma^2} \frac{\partial}{\partial \beta} (Y - X\beta)'(Y - X\beta) = 0$$

$$\frac{\partial}{\partial \beta} (Y - X\beta)'(Y - X\beta) = 0 \quad \text{i.e. } \hat{\beta}_{MLE} = \hat{\beta}$$

$$0 = -\frac{N}{2\sigma^2} + \frac{1}{2\sigma^4} (Y - X\beta)'(Y - X\beta)$$

$$\sigma^2 N = (Y - X\hat{\beta})'(Y - X\hat{\beta})$$

$$\hat{\sigma}_{MLE}^2 = \frac{1}{N} (Y - X\hat{\beta})'(Y - X\hat{\beta}) \neq \sigma^2: \text{不偏推定量}$$

— 最尤推定量とは? <わしくは赤平「統計解析入門」P106, 統計学入門, 東京大学出版会 P217

表が出る確率が p の歪んだコインを N 回投げる。

i 回目に投げたコインの結果を Y_i (1:表) 0:裏) と表わす。

確率 p $1-p$

この時, Y_i の確率関数は $f_{Y_i}(y_i | p) = p^{y_i} (1-p)^{1-y_i}$ ($y_i = 0$ or 1)

となる よって $Y_1, \dots, Y_N$ は iid かつ 同時 pdf は

$$f_Y(Y | p) = \prod_{i=1}^N \{p^{y_i} (1-p)^{1-y_i}\} = p^{\sum y_i} (1-p)^{N - \sum y_i} \quad \text{となる}$$

$$L(p) = p^{\sum_{i=1}^N y_i} (1-p)^{N - \sum_{i=1}^N y_i} \quad \text{を尤度と言う。 (ゆうど)}$$

$$\ell(p) = \log L(p) \text{ を対数尤度と言う。 } \ell(p) = \sum_{i=1}^N y_i \log p + (N - \sum_{i=1}^N y_i) \log(1-p)$$

$\ell(p)$ を最大にする $\hat{p}$ を p の最尤推定量と言う。

$$\frac{d}{dp} \ell(p) = 0 \text{ を解くと } \frac{d}{dp} \ell(p) = \left(\sum_{i=1}^N y_i\right) \frac{1}{p} - (N - \sum_{i=1}^N y_i) \frac{1}{1-p} = 0 \quad \therefore \hat{p} = \frac{1}{N} \sum_{i=1}^N y_i$$

モデル選択

$$\text{Full model: } y = X\beta + \varepsilon \quad X = \begin{pmatrix} x_1 & x_2 & \dots & x_k \end{pmatrix} \quad \beta = \begin{pmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{pmatrix}$$

$\underbrace{\hspace{1.5cm}}_p \quad \underbrace{\hspace{1.5cm}}_{k-p}$

$$MCP: y = x_1\beta + \varepsilon$$

↑

少ない説明変数

・説明変数の数

③ ⇒ データのモデルへの当てはまりが悪くなる


・ β の推定精度が落ちる

・モデルが不安定になり予測誤差が大きくなる

④ ⇒ β の推定精度は高くなる

・データのモデルへの当てはまりが悪くなる

$$y_i = \beta_1 + \beta_2 x_i + \dots + \beta_k x_i^{k-1} + \varepsilon_i$$



• AIC (赤池情報量基準)

$$Y_1, \dots, Y_N \stackrel{iid}{\sim} f(y|\theta)$$

$$M(P): \theta = (\theta_1, \dots, \theta_P)'$$

$$L(\theta) = \prod_{i=1}^N f(y_i|\theta) \quad \text{: 尤度}$$

$$\hat{\theta}_{ML} \quad L(\hat{\theta}_{ML}) = \sup_{\theta} L(\theta)$$

$g(x)$: 真の確率分布

$$\int \log \frac{g(y)}{f(y|\hat{\theta}_{ML})} g(y) dy$$

$$= \underbrace{\int \log g(y) g(y) dy}_{\text{ある値}} - \underbrace{\int \log f(y|\hat{\theta}_{ML}) g(y) dy}_{\text{ss.}}$$

$$\log L(\hat{\theta}_{ML}) - P$$

$M(P)$ に対する AIC は

$$AIC(P) = \underbrace{-2 \log L(\hat{\theta}_{ML})}_T + \underbrace{2P}_{\text{パラメータの数}}$$

これを最小にするモデルを選ぶ

モデルの当てはまりの良さ
モデルの安定性

線形回帰モデルに当てはめてみる

$$M(k+1): Y = XB + \varepsilon, \quad \varepsilon \sim N(0, \sigma^2 I_N)$$

$$L(\theta) = \frac{1}{(\sqrt{2\pi})^N \sigma^N} \exp\left\{-\frac{1}{2\sigma^2} (Y - XB)'(Y - XB)\right\}$$

$$MLE \quad \hat{\theta}_{ML} = (X'X)^{-1}X'Y$$

$$\hat{\sigma}_{ML}^2 = \frac{1}{N} (Y - X\hat{\theta}_{ML})'(Y - X\hat{\theta}_{ML})$$

$$\frac{(Y - X\hat{\theta}_{ML})'(Y - X\hat{\theta}_{ML})}{\hat{\sigma}_{ML}^2} = N$$

$$L(\hat{\theta}_{ML}) = \frac{1}{(\sqrt{2\pi})^N \hat{\sigma}_{ML}^N} \exp\left\{-\frac{N}{2}\right\}$$

$$\log L(\hat{\theta}_{ML}) = -\frac{N}{2} \log(2\pi) - \frac{N}{2} \log \hat{\sigma}_{ML}^2 - \frac{N}{2}$$

$$AIC(k+1) = N \log \hat{\sigma}_{ML}^2 + N(\log 2\pi + 1) + 2(k+1)$$