

$$\Pi_X^2 = \Pi_X$$

$$\text{rank } \Pi_X = \text{tr } \Pi_X = \text{tr } \{X(X'X)^{-1}X'\} = p$$

さて、

$$\min Q = Q(\hat{\beta}) = \|e\|^2 = \mathbf{y}'(I - \Pi_X)\mathbf{y}$$

証明終

[注意] 定数項がある場合、Prop.1.2.4 は、Prop.1.2.1 と同じ。

2つの問題の解と最小値は、一見違っているが、実は同じであることが確かめられる。

Def.1.2.2.

$$\hat{\mathbf{y}} := X\hat{\beta} = \Pi_X\mathbf{y} : \text{回帰ベクトル}$$

$$\mathbf{e} := \mathbf{y} - \hat{\mathbf{y}} = (I - \Pi_X)\mathbf{y} : \text{残差ベクトル}$$

$$\hat{\beta} := (X'X)^{-1}X'\mathbf{y} : \text{最小二乗解}$$

幾何学的意味：データ \mathbf{y} を、回帰空間 ($X\beta$ の作る空間) $M(X)$ に射影する。 Π_X は、この回帰空間への射影であり、 $I - \Pi_X$ は $M(X)^\perp$ (誤差空間) への射影である。

Prop.1.2.5. $\|\hat{\mathbf{y}}\|^2 = \mathbf{y}'\Pi_X\mathbf{y}$

$$\|e\|^2 = \mathbf{y}'(I - \Pi_X)\mathbf{y}$$

$$\hat{\mathbf{y}}'e = 0$$

[注意] : $\mathbf{y} = \hat{\mathbf{y}} + e$

長さ $\|\mathbf{y}\|^2 = \mathbf{y}'\Pi_X\mathbf{y} + \mathbf{y}'\Pi_X^\perp\mathbf{y}$

ただし、 $\Pi_X^\perp := I - \Pi_X$

1.3. 母数モデルの回帰分析

確率を導入する。

$$y_i = \boldsymbol{\beta}' \mathbf{x}_i + \varepsilon_i, \quad (i = 1, \dots, n)$$

ここで、 $\varepsilon_1, \dots, \varepsilon_n$ は r.v. (確率変数) で 誤差 と呼ばれる。

$$E(\varepsilon_i) = 0, \quad E(\varepsilon_i \varepsilon_j) = \sigma^2 \delta_{ij}, \quad (i, j = 1, \dots, n)$$

$$\mathbf{x}_1, \dots, \mathbf{x}_n : \text{given}, \quad \sigma > 0$$

$$\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

$$E(\boldsymbol{\varepsilon}) = \mathbf{0}, \quad \text{Var}(\boldsymbol{\varepsilon}) = E(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}') = \sigma^2 I_n$$

$$X : \text{known} \quad (\text{rank } X = p)$$

$$\boldsymbol{\beta}, \sigma^2 : \text{unknown}$$

問題 $\boldsymbol{\beta}, \sigma^2$ に関する推測

Def.1.3.1. $\hat{\boldsymbol{\beta}}, \hat{\mathbf{y}}, \mathbf{e}$: 1.2 節の Def.1.2.2. の通り

$$\hat{\mathbf{y}} := X\hat{\boldsymbol{\beta}} = \Pi_X \mathbf{y} : \text{回帰ベクトル}$$

$$\mathbf{e} := \mathbf{y} - \hat{\mathbf{y}} = (I - \Pi_X) \mathbf{y} : \text{残差ベクトル}$$

$$\hat{\boldsymbol{\beta}} := (X'X)^{-1} X' \mathbf{y} : \text{最小二乗解}$$

$$\hat{\sigma}^2 := Q(\hat{\boldsymbol{\beta}})/(n - p)$$

Prop.1.3.1.

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

$$E(\hat{\boldsymbol{\beta}}) = \boldsymbol{\beta}, \quad \text{Var}(\hat{\boldsymbol{\beta}}) = \sigma^2 (X'X)^{-1}$$

$$(ii) \mathbf{e} = (I - \Pi_X) \boldsymbol{\varepsilon}$$

$$E(\mathbf{e}) = \mathbf{0}, \quad \text{Var}(\mathbf{e}) = \sigma^2 (I - \Pi_X)$$

$$(iii) \text{Cov}(\hat{\boldsymbol{\beta}}, \mathbf{e}) = \mathbf{0}$$

$$(iv) (n - p) \hat{\sigma}^2 = \|\mathbf{e}\|^2 = \boldsymbol{\varepsilon}' (I - \Pi_X) \boldsymbol{\varepsilon}$$

$$E(\hat{\sigma}^2) = \sigma^2$$

補足 : (i) と (iv) より、 $\hat{\boldsymbol{\beta}}, \hat{\sigma}^2$ は $\boldsymbol{\beta}, \sigma^2$ の不偏推定量であることがわかる。

証明 : (i) $\hat{\boldsymbol{\beta}} = (X'X)^{-1} X' \mathbf{y} = (X'X)^{-1} X' (X\boldsymbol{\beta} + \boldsymbol{\varepsilon})$

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

$$\text{ゆえに、} E(\hat{\boldsymbol{\beta}}) = \boldsymbol{\beta}$$

$$\text{Var}(\hat{\boldsymbol{\beta}}) = (X'X)^{-1} X' \text{Var}(\boldsymbol{\varepsilon}) X (X'X)^{-1} = \sigma^2 (X'X)^{-1}$$

(ii) Prop.1.2.4 の証明において、 $H := I - \Pi_X$ とすれば、

$$e = Hy = H(X\beta + \varepsilon) = H\varepsilon$$

$$\text{ゆえに、} E(e) = \mathbf{0}$$

$$\text{Var}(e) = H \text{Var}(\varepsilon) H = \sigma^2 H^2 = \sigma^2 H$$

$$(iii) \text{Cov}(\hat{\beta}, e) = E\left\{(\hat{\beta} - \beta)e'\right\} = (X'X)^{-1}X' E(\varepsilon\varepsilon') H = \sigma^2(X'X)^{-1}X'H = O$$

$$(iv) (n-p)\hat{\sigma}^2 = Q(\hat{\beta}) = \|e\|^2 = \varepsilon'H\varepsilon$$

$$E(\varepsilon'H\varepsilon) = \text{tr} E(H\varepsilon'\varepsilon) = \sigma^2 \text{tr} H = (n-p)\sigma^2$$

$$\text{ゆえに、} E(\hat{\sigma}^2) = \sigma^2$$

証明終

Def.1.3.2. $c : p \times 1$

(i) $L = a'y$, $a : n \times 1$ が、

$$E(L|\beta) = c'\beta, \quad \forall \beta$$

を満たすとき、 $c'\beta$ の 線形不偏推定量 という。

(ii) L_0 が、 $c'\beta$ の 最良線形不偏推定量 (BLUE) とは、
線形不偏推定量の中で、分散最小 であること。

Prop.1.3.2.(Gauss-Markov) $\forall c : n \times 1$ $c'\hat{\beta}$ は $c'\beta$ の BLUE である。

証明 : (i) linear $L_0 := c'\hat{\beta} = c'(X'X)^{-1}X'y$

(ii) 不偏 $E(L_0|\beta) = E(c'\hat{\beta}|\beta) = c'\beta, \quad \forall \beta$

(iii) 最小分散 問題
$$\begin{cases} \min_{\mathbf{a}} \text{Var} L \\ \text{条件} \begin{cases} L = \mathbf{a}'\mathbf{y}, \quad \mathbf{a} : n \times 1 \\ E(L|\beta) = c'\beta, \quad \forall \beta \end{cases} \end{cases}$$

を解いた解が、 $c'\hat{\beta}$ であることを言えばよい。

$$E(L|\beta) = \mathbf{a}'E(\mathbf{y}|\beta) = \mathbf{a}'X\beta$$

$$L : \text{不偏} \iff \mathbf{a}'X = c' \iff X'\mathbf{a} = c$$

$$\text{Var}(L) = \mathbf{a}' \text{Var}(\mathbf{y}) \mathbf{a} = \sigma^2 \mathbf{a}'\mathbf{a}$$

$$\text{問題} \begin{cases} \min_{\mathbf{a}} \|\mathbf{a}\| \\ \text{条件} : X'\mathbf{a} = c \end{cases}$$

Prop.B1 より、

$$\text{解} : \mathbf{a} = X(X'X)^{-1}c$$

$$\text{ゆえに、} L = \mathbf{a}'\mathbf{y} = c'(X'X)^{-1}X'y = c'\hat{\beta}$$

証明終

以後、この節では、

ε_i *i.i.d.* $N(0, \sigma^2)$ とする。

Prop.1.3.3. β, σ^2 の MLE(最尤推定量) は、それぞれ、 $\hat{\beta}, \frac{1}{n}\|e\|^2 =: \hat{\sigma}_M^2$ である。

$$\begin{aligned} \text{証明: } L(\beta, \sigma^2) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{1}{2\sigma^2}(y_i - \beta'x_i)^2\right\} \\ &= K\sigma^{-n} \exp\left\{-\frac{1}{2\sigma^2}Q(\beta)\right\} \quad K := (2\pi)^{-\frac{n}{2}} \end{aligned}$$

これを、 β について最大にするには、 $Q(\beta)$ を β について最小にすることであり、Prop.1.2.4 より、 $\beta = \hat{\beta}$

$$\text{このとき、} L(\hat{\beta}, \sigma^2) = K\sigma^{-n} \exp\left\{-\frac{1}{2\sigma^2}\|e\|^2\right\}$$

これを、 σ^2 について最大にするには、 $t = \sigma^2$ と置いて (対数を取り) 微分すれば分かる。

$$\sigma^2 = \frac{1}{n}\|e\|^2$$

証明終

[注意] : 尤度関数の最大値 $= (2\pi)^{-\frac{n}{2}}\hat{\sigma}_M^{-n} \exp(-\frac{n}{2})$

補足 : 最尤推定量, MLE(Maximum Likelihood Estimator) について

密度関数 $f(x; \theta)$ は、通常、母数 θ が定数で与えられており、 x の起こりやすさを表していると解釈される。この発想を逆転して、この関数を、 x が得られたとき、母数 θ の関数とみて、 $L(\theta) = L(\theta; x) = f(x; \theta)$ とおくと、この関数 $L(\theta)$ を 尤度関数 (Likelihood Function) という。また、この関数が最大になる θ の値を、尤度を最大にする推定量 (最尤推定量) という。このような方法を、最尤法という。

(後で行う、尤度比検定にも繋がる考え方である。)

Prop.1.3.4. (i) $\hat{\beta} \sim N_p(\beta, \sigma^2(X'X)^{-1})$

(ii) $e \sim N_n(\mathbf{0}, \sigma^2(I - \Pi_X))$

(iii) $\hat{\beta} \perp e$

(iv) $(n-p)\hat{\sigma}^2 \sim \sigma^2\chi_{n-p}^2$

(v) $\hat{\beta} \perp \hat{\sigma}^2$

証明 : Prop.1.3.1 より、

$$\begin{bmatrix} \hat{\beta} \\ e \end{bmatrix} = \begin{bmatrix} \beta \\ \mathbf{0} \end{bmatrix} + \begin{bmatrix} (X'X)^{-1}X' \\ I - \Pi_X \end{bmatrix} \varepsilon$$

Prop.C14 より、

$$\begin{bmatrix} \hat{\beta} \\ e \end{bmatrix} \sim N_{p+n}\left(\begin{bmatrix} \beta \\ \mathbf{0} \end{bmatrix}, \Phi\right)$$

$$\text{ここで、} \Phi = \begin{bmatrix} (X'X)^{-1}X' \\ I - \Pi_X \end{bmatrix} \text{Var}(\varepsilon) \begin{bmatrix} (X'X)^{-1}X' \\ I - \Pi_X \end{bmatrix}' = \sigma^2 \begin{bmatrix} (X'X)^{-1} & O \\ O & I - \Pi_X \end{bmatrix}$$