

回帰分析 (Regression Analysis)

緑川章一*

1 回帰直線

1.1 導出

n コのデータ (x_i, y_i) ($i = 1, \dots, n$) が与えられたとき、これらは直線

$$y = \theta_1 + \theta_2 x \quad (1)$$

の周りに確率的にちらばっているものとする。我々は、 θ_1, θ_2 が存在することは知っているが、その値は分からない。データを

$$y_i = \theta_1 + \theta_2 x_i + \varepsilon_i \quad (2)$$

と表す。この時、 ε_i は平均 0、分散 σ^2 の正規分布に従うとする。すなわち、

$$P(y_i | \theta_1 + \theta_2 x_i) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{(y_i - (\theta_1 + \theta_2 x_i))^2}{2\sigma^2} \right\} \quad (3)$$

となるので、

$$E(y_i) = \int y_i P(y_i | \theta_1 + \theta_2 x_i) dy_i = \theta_1 + \theta_2 x_i \quad (4)$$

$$V(y_i) = E(y_i^2) - E(y_i)^2 = \sigma^2 \quad (5)$$

である。同様に、

$$\text{Cov}(y_i, y_j) = E(y_i y_j) - E(y_i)E(y_j) = 0 \text{ for } i \neq j \quad (6)$$

が成り立つとする。すなわち、 $i \neq j$ のとき、 ε_i と ε_j は無相関とする。

(1) ~ (6) 式は、行列表示を用いて簡潔に表すことができる。まず、

$$A = \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix}, \quad \boldsymbol{\theta} = \begin{bmatrix} \theta_1 \\ \theta_2 \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}$$

*Shoichi Midorikawa

を定義する。

(3) 式は、

$$P(\mathbf{y}|A\boldsymbol{\theta}) = \frac{1}{(\sqrt{2\pi\sigma^2})^n} \exp \left\{ -\frac{(\mathbf{y} - A\boldsymbol{\theta})^T (\mathbf{y} - A\boldsymbol{\theta})}{2\sigma^2} \right\} \quad (7)$$

(4) 式は、

$$E(\mathbf{y}) = \int \mathbf{y} P(\mathbf{y}|A\boldsymbol{\theta}) \prod_{i=1}^n dy_i = A\boldsymbol{\theta} \quad (8)$$

(5), (6) 式は、

$$\begin{aligned} V(\mathbf{y}) &= \int (\mathbf{y} - E(\mathbf{y})) (\mathbf{y} - E(\mathbf{y}))^T P(\mathbf{y}|A\boldsymbol{\theta}) \prod_{i=1}^n dy_i \\ &= \int \mathbf{y}\mathbf{y}^T P(\mathbf{y}|A\boldsymbol{\theta}) \prod_{i=1}^n dy_i - E(\mathbf{y})E(\mathbf{y})^T \\ &= E(\mathbf{y}\mathbf{y}^T) - E(\mathbf{y})E(\mathbf{y})^T \\ &= \sigma^2 \mathbf{I} \end{aligned} \quad (9)$$

となる。ここで、 \mathbf{I} は、 $n \times n$ 単位行列である。

直線 (1) 式を求めるときに、普通は、

$$Q = \sum_{i=1}^n (\theta_1 + \theta_2 x_i - y_i)^2 \quad (10)$$

が最小になるような $\hat{\theta}_1, \hat{\theta}_2$ を求める。

まず、

$$\begin{aligned} \frac{\partial Q}{\partial \theta_1} &= 2 \sum_{i=1}^n (\theta_1 + \theta_2 x_i - y_i) \\ &= 2 \left\{ n\theta_1 + \theta_2 \sum_{i=1}^n x_i - \sum_{i=1}^n y_i \right\} = 0 \end{aligned} \quad (11)$$

より、

$$\theta_1 + \theta_2 \bar{x} - \bar{y} = 0 \quad (12)$$

を得る。ここで、

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

である。

次に、

$$\frac{\partial Q}{\partial \theta_2} = 2 \left\{ \theta_1 \sum_{i=1}^n x_i + \theta_2 \sum_{i=1}^n x_i^2 - \sum_{i=1}^n x_i y_i \right\} = 0 \quad (13)$$

を得る。

または、(12) 式より、

$$\theta_1 = \bar{y} - \theta_2 \bar{x} \quad (14)$$

となるので、これを (10) 式に代入する。

$$Q = \sum_{i=1}^n [\theta_2(x_i - \bar{x}) - (y_i - \bar{y})]^2$$

ゆえに、

$$\begin{aligned} \frac{\partial Q}{\partial \theta_2} &= 2 \sum_{i=1}^n (x_i - \bar{x}) [\theta_2(x_i - \bar{x}) - (y_i - \bar{y})] \\ &= 2 \left\{ \theta_2 \sum_{i=1}^n (x_i - \bar{x})^2 - \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \right\} \\ &= 0 \end{aligned}$$

より、

$$\hat{\theta}_2 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (15)$$

を得る。これを (14) 式に代入して、

$$\hat{\theta}_1 = \bar{y} - \hat{\theta}_2 \bar{x} \quad (16)$$

を得る。

2 射影行列

ベクトル \mathbf{b} の \mathbf{a} への射影を \mathbf{p} とする。

$$\mathbf{p} = k\mathbf{a} \quad (17)$$

さらに、 $\mathbf{e} = \mathbf{p} - \mathbf{b}$ とおく。 $\mathbf{e} \perp \mathbf{a}$ だから、

$$0 = \mathbf{a}^T \mathbf{e} = \mathbf{a}^T \mathbf{p} - \mathbf{a}^T \mathbf{b} \quad (18)$$

すなわち、

$$\mathbf{a}^T \mathbf{p} = \mathbf{a}^T \mathbf{b} \quad (19)$$

を得る。

k を求めるには、 \mathbf{a} と \mathbf{p} の内積を取る。

$$\begin{aligned} \mathbf{a}^T \mathbf{p} &= k \mathbf{a}^T \mathbf{a} \\ \therefore k &= \frac{\mathbf{a}^T \mathbf{p}}{\mathbf{a}^T \mathbf{a}} = \frac{\mathbf{a}^T \mathbf{b}}{\mathbf{a}^T \mathbf{a}} \end{aligned} \quad (20)$$

を得る。これは、

$$Q = (\mathbf{b} - k\mathbf{a})^T (\mathbf{b} - k\mathbf{a})$$

から、

$$\frac{dQ}{dk} = -2\mathbf{a}^T (\mathbf{b} - k\mathbf{a}) = 0$$

を解いて得られたものと一致する。

(20)式を(17)式に代入すると、

$$\mathbf{p} = \frac{\mathbf{a}\mathbf{a}^T}{\mathbf{a}^T \mathbf{a}} \mathbf{b}$$

そこで、射影演算子 P は、

$$P = \frac{\mathbf{a}\mathbf{a}^T}{\mathbf{a}^T \mathbf{a}}$$

と書ける。これは、次の関係式を満たす。

$$P^2 = \frac{\mathbf{a}(\mathbf{a}^T \mathbf{a})\mathbf{a}^T}{(\mathbf{a}^T \mathbf{a})^2} = \frac{\mathbf{a}\mathbf{a}^T}{\mathbf{a}^T \mathbf{a}} = P$$

また、(18)式より、

$$P\mathbf{e} = 0$$

を得る。

次に、 $n \times m$ 行列の列ベクトル A と n 次元ベクトル \mathbf{y} を定義する。

$$A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ a_{21} & a_{22} & \dots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nm} \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}$$

ここで、ベクトル

$$\mathbf{a}_1 = \begin{bmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{n1} \end{bmatrix}, \quad \mathbf{a}_2 = \begin{bmatrix} a_{12} \\ a_{22} \\ \vdots \\ a_{n2} \end{bmatrix}, \quad \dots \quad \mathbf{a}_m = \begin{bmatrix} a_{1m} \\ a_{2m} \\ \vdots \\ a_{nm} \end{bmatrix}$$

を定義すると、

$$A = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_m], \quad A^T = \begin{bmatrix} \mathbf{a}_1^T \\ \mathbf{a}_2^T \\ \vdots \\ \mathbf{a}_m^T \end{bmatrix}$$

列ベクトル $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_m$ が作るベクトル空間へのベクトル \mathbf{y} の射影を \mathbf{p} とする。この時、 $\mathbf{y} = \mathbf{p} + \boldsymbol{\varepsilon}$ とすると、

$$\boldsymbol{\varepsilon} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

は、 $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_m$ と直交するので、

$$A^T \boldsymbol{\varepsilon} = 0 \quad \text{または、} \quad \mathbf{a}_i^T \boldsymbol{\varepsilon} = 0, \quad i = 1, 2, \dots, m \quad (21)$$

すなわち、 ε_i ($i = 1, 2, \dots, n$) はすべて独立ではなく、 $\boldsymbol{\varepsilon}$ の自由度は、 $n - m$ である。

(21) 式は、また、

$$A^T(\mathbf{p} - \mathbf{y}) = 0,$$

と書ける。すなわち、

$$A^T \mathbf{p} = A^T \mathbf{y} \quad (22)$$

\mathbf{p} は、 $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_m$ が作る空間内のベクトルだから、

$$\mathbf{p} = A\mathbf{x} \quad (23)$$

となる

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_m \end{bmatrix}$$

が存在する。これを、(22) 式に代入すると、

$$A^T A \mathbf{x} = A^T \mathbf{y} \quad (24)$$

すなわち、

$$\begin{bmatrix} \mathbf{a}_1^T \mathbf{a}_1 & \mathbf{a}_1^T \mathbf{a}_2 & \cdots & \mathbf{a}_1^T \mathbf{a}_m \\ \mathbf{a}_2^T \mathbf{a}_1 & \mathbf{a}_2^T \mathbf{a}_2 & \cdots & \mathbf{a}_2^T \mathbf{a}_m \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{a}_m^T \mathbf{a}_1 & \mathbf{a}_m^T \mathbf{a}_2 & \cdots & \mathbf{a}_m^T \mathbf{a}_m \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_m \end{bmatrix} = \begin{bmatrix} \mathbf{a}_1^T \mathbf{y} \\ \mathbf{a}_2^T \mathbf{y} \\ \vdots \\ \mathbf{a}_m^T \mathbf{y} \end{bmatrix} \quad (25)$$

を得る。

(24) 式より、

$$\mathbf{x} = (A^T A)^{-1} A^T \mathbf{y}$$

この両辺に左から A を掛けると、(23) 式より、

$$\mathbf{p} = A \mathbf{x} = A (A^T A)^{-1} A^T \mathbf{y}$$

を得る。そこで、射影演算子 P は、

$$P = A (A^T A)^{-1} A^T$$

となる。ゆえに、

$$P \mathbf{p} = \mathbf{p}, \quad P \boldsymbol{\varepsilon} = 0$$

が成り立つ。

ここで、

$$\begin{aligned} Q &= \|A \mathbf{x} - \mathbf{y}\|^2 \\ &= (\mathbf{a}_1 x_1 + \mathbf{a}_2 x_2 + \cdots + \mathbf{a}_m x_m - \mathbf{y})^T (\mathbf{a}_1 x_1 + \mathbf{a}_2 x_2 + \cdots + \mathbf{a}_m x_m - \mathbf{y}) \end{aligned}$$

とおいて、

$$\frac{\partial Q}{\partial x_i} = 2 \mathbf{a}_i^T (\mathbf{a}_1 x_1 + \mathbf{a}_2 x_2 + \cdots + \mathbf{a}_m x_m - \mathbf{y}) = 0, \quad (i = 1, 2, \dots, m)$$

とすると、(25) 式を得ることに注意しよう。

3 最小二乗法の幾何学的意味

方程式

$$A\boldsymbol{\theta} = \mathbf{y}$$

は、 $\text{rank } A < \text{rank}[A|\boldsymbol{\theta}]$ のとき、解を持たない。このとき、行列 A の列ベクトルがつくるベクトル空間に \mathbf{y} を射影してできるベクトルを $\hat{\mathbf{y}}$ とすると、方程式

$$A\mathbf{x} = \hat{\mathbf{y}}, \quad \hat{\mathbf{y}} = P\mathbf{y} = A(A^T A)^{-1} A^T \mathbf{y} \quad (26)$$

を、今度は解くことができる。

もしも n コの対の観測データ (x_i, y_i) , $(n = 1, 2, \dots, n)$ 間に線形関係 $y_i = \hat{\theta}_1 + \hat{\theta}_2 x_i$ が成り立つならば、

$$A\hat{\boldsymbol{\theta}} = \mathbf{y}$$

と書くことができる。ここで、

$$A = \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix}, \quad \hat{\boldsymbol{\theta}} = \begin{bmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}$$

とおく。さらに、

$$\mathbf{a}_1 = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}, \quad \mathbf{a}_2 = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$

とおくと、

$$A = [\mathbf{a}_1, \mathbf{a}_2], \quad A^T = \begin{bmatrix} \mathbf{a}_1^T \\ \mathbf{a}_2^T \end{bmatrix}$$

\mathbf{y} に誤差があるとき、すなわち、

$$\mathbf{y} = A\hat{\boldsymbol{\theta}} + \hat{\boldsymbol{\varepsilon}}$$

の場合には、(26) 式が成り立つ。

$$A\hat{\boldsymbol{\theta}} = A(A^T A)^{-1} A^T \mathbf{y}$$

この両辺に A^T を左から掛けると、

$$A^T A \hat{\boldsymbol{\theta}} = A^T \mathbf{y} \quad (27)$$

が得られる。

$$A^T A = \begin{bmatrix} \mathbf{a}_1^T \mathbf{a}_1 & \mathbf{a}_1^T \mathbf{a}_2 \\ \mathbf{a}_2^T \mathbf{a}_1 & \mathbf{a}_2^T \mathbf{a}_2 \end{bmatrix} = \begin{bmatrix} n & \sum_i x_i \\ \sum_i x_i & \sum_i x_i^2 \end{bmatrix} \quad (28)$$

$$A^T \mathbf{y} = \begin{bmatrix} \mathbf{a}_1^T \mathbf{y} \\ \mathbf{a}_2^T \mathbf{y} \end{bmatrix} = \begin{bmatrix} \sum_i y_i \\ \sum_i x_i y_i \end{bmatrix}$$

なので、(27) 式は、

$$\begin{bmatrix} n & \sum_i x_i \\ \sum_i x_i & \sum_i x_i^2 \end{bmatrix} \begin{bmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \end{bmatrix} = \begin{bmatrix} \sum_i y_i \\ \sum_i x_i y_i \end{bmatrix} \quad (29)$$

を得る。これは、(11) 式と (13) 式の行列表示である。

(10) 式のベクトル表示である

$$\begin{aligned} Q(\theta_1, \theta_2) &= \|A\boldsymbol{\theta} - \mathbf{y}\|^2 \\ &= (\theta_1 \mathbf{a}_1 + \theta_2 \mathbf{a}_2 - \mathbf{y})^T (\theta_1 \mathbf{a}_1 + \theta_2 \mathbf{a}_2 - \mathbf{y}) \end{aligned}$$

から

$$\frac{\partial Q(\hat{\theta}_1, \hat{\theta}_2)}{\partial \theta_1} = 0, \quad \frac{\partial Q(\hat{\theta}_1, \hat{\theta}_2)}{\partial \theta_2} = 0$$

としたものに等しい。

(29) 式を解くと、

$$\begin{aligned} \begin{bmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \end{bmatrix} &= (A^T A)^{-1} \begin{bmatrix} \sum_i y_i \\ \sum_i x_i y_i \end{bmatrix} \\ &= \frac{1}{n \sum_i x_i^2 - (\sum_i x_i)^2} \begin{bmatrix} \sum_i x_i^2 & -\sum_i x_i \\ -\sum_i x_i & n \end{bmatrix} \begin{bmatrix} \sum_i y_i \\ \sum_i x_i y_i \end{bmatrix} \\ &= \frac{1}{\sum_i x_i^2 - n\bar{x}^2} \begin{bmatrix} \frac{1}{n} \sum_i x_i^2 & -\bar{x} \\ -\bar{x} & 1 \end{bmatrix} \begin{bmatrix} n\bar{y} \\ \sum_i x_i y_i \end{bmatrix} \\ &= \frac{1}{\sum_i x_i^2 - n\bar{x}^2} \begin{bmatrix} \bar{y} \sum_i x_i^2 - \bar{x} \sum_i x_i y_i \\ -n\bar{x}\bar{y} + \sum_i x_i y_i \end{bmatrix} \\ &= \frac{1}{\sum_i (x_i - \bar{x})^2} \begin{bmatrix} \bar{y} \sum_i (x_i - \bar{x})^2 - \bar{x} \sum_i (x_i - \bar{x})(y_i - \bar{y}) \\ \sum_i (x_i - \bar{x})(y_i - \bar{y}) \end{bmatrix} \end{aligned}$$

ゆえに、

$$\begin{bmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \end{bmatrix} = \begin{bmatrix} 1 - \frac{\bar{x} \sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sum_i (x_i - \bar{x})^2} \\ \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sum_i (x_i - \bar{x})^2} \end{bmatrix} \quad (30)$$

を得る。

また、

$$P\hat{\boldsymbol{\varepsilon}} = A^T \hat{\boldsymbol{\varepsilon}} = 0 \quad (31)$$

より、

$$\mathbf{a}_1^T \hat{\boldsymbol{\varepsilon}} = \mathbf{a}_2^T \hat{\boldsymbol{\varepsilon}} = 0$$

が成り立つ。すなわち、 $\boldsymbol{\varepsilon}$ の自由度は、 $n - 2$ である。

4 最小2乗推定量の平均と分散

4.1 平均

$$\boldsymbol{\theta} = \begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix} \quad (32)$$

とおくと、

$$\mathbf{y} = A\boldsymbol{\theta} + \boldsymbol{\varepsilon} \quad (33)$$

である。ところが、(4)式より、

$$E(\mathbf{y}) = A\boldsymbol{\theta}$$

(27)式より、

$$A^T A E(\hat{\boldsymbol{\theta}}) = A^T E(\mathbf{y}) \quad (34)$$

となるので、

$$E(\hat{\boldsymbol{\theta}}) = \boldsymbol{\theta} \quad (35)$$

を得る。すなわち、

$$E(\hat{\theta}_1) = \theta_1, \quad E(\hat{\theta}_2) = \theta_2 \quad (36)$$

を得る。

4.2 分散

(27) 式より、

$$\begin{bmatrix} \hat{\theta}_1^2 & \hat{\theta}_1 \hat{\theta}_2 \\ \hat{\theta}_1 \hat{\theta}_2 & \hat{\theta}_2^2 \end{bmatrix} = \hat{\boldsymbol{\theta}} \hat{\boldsymbol{\theta}}^T = (A^T A)^{-1} A^T \mathbf{y} \mathbf{y}^T A ((A^T A)^{-1})^T \quad (37)$$

ここで、

$$\mathbf{y} \mathbf{y}^T = \begin{bmatrix} y_1^2 & y_1 y_2 & \cdots & y_1 y_n \\ y_2 y_1 & y_2^2 & \cdots & y_2 y_n \\ \vdots & \vdots & \ddots & \vdots \\ y_n y_1 & y_n y_2 & \cdots & y_n^2 \end{bmatrix}$$

となるので、(4)、(5)、(6)式を用いて、

$$\begin{aligned} E(\mathbf{y} \mathbf{y}^T) - E(\mathbf{y}) E(\mathbf{y}^T) &= \begin{bmatrix} V(y_1) & Cov(y_1, y_2) & \cdots & Cov(y_1, y_n) \\ Cov(y_2, y_1) & V(y_2) & \cdots & Cov(y_2, y_n) \\ \vdots & \vdots & \ddots & \vdots \\ Cov(y_n, y_1) & Cov(y_n, y_2) & \cdots & V(y_n) \end{bmatrix} \\ &= \begin{bmatrix} \sigma^2 & 0 & \cdots & 0 \\ 0 & \sigma^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma^2 \end{bmatrix} \\ &= \sigma^2 \mathbf{I} \end{aligned} \quad (38)$$

を得る。

(37) 式と (38) 式より、

$$\begin{aligned} \Sigma &= \begin{bmatrix} V(\hat{\theta}_1) & Cov(\hat{\theta}_1, \hat{\theta}_2) \\ Cov(\hat{\theta}_1, \hat{\theta}_2) & V(\hat{\theta}_2) \end{bmatrix} \\ &= (A^T A)^{-1} A^T \sigma^2 \mathbf{I} A ((A^T A)^{-1})^T \\ &= \sigma^2 ((A^T A)^{-1})^T \\ &= \sigma^2 (A^T A)^{-1} \end{aligned} \quad (39)$$

最後の変形では、(39) 式が対称行列であることを用いた。この式を (28) 式を用いて書き直すと、

$$\begin{bmatrix} V(\hat{\theta}_1) & Cov(\hat{\theta}_1, \hat{\theta}_2) \\ Cov(\hat{\theta}_1, \hat{\theta}_2) & V(\hat{\theta}_2) \end{bmatrix} = \frac{\sigma^2}{\sum_i (x_i - \bar{x})^2} \begin{pmatrix} \frac{1}{n} \sum_i x_i^2 & -\bar{x} \\ -\bar{x} & 1 \end{pmatrix} \quad (40)$$

を得る。すなわち、

$$\hat{\theta}_1 \text{ は、 } N\left(\theta_1, \frac{\sigma^2 \sum_i x_i^2}{n \sum_i (x_i - \bar{x})^2}\right) \quad (41)$$

$$\hat{\theta}_2 \text{ は、 } N\left(\theta_2, \frac{\sigma^2}{\sum_i (x_i - \bar{x})^2}\right) \quad (42)$$

に従う。

再び、 $\Sigma = \sigma^2(A^T A)^{-1}$ を (28) 式を用いて書き直すと、

$$\begin{aligned} \Sigma &= \begin{pmatrix} \sigma_{11}^2 & \sigma_{12}^2 \\ \sigma_{12}^2 & \sigma_{22}^2 \end{pmatrix} \\ &= \frac{\sigma^2}{|\mathbf{a}_1|^2 |\mathbf{a}_2|^2 - (\mathbf{a}_1^T \mathbf{a}_2)^2} \begin{pmatrix} |\mathbf{a}_2|^2 & -\mathbf{a}_1^T \mathbf{a}_2 \\ \mathbf{a}_1^T \mathbf{a}_2 & |\mathbf{a}_1|^2 \end{pmatrix} \\ &= \frac{\sigma^2}{|A^T A|} \begin{pmatrix} |\mathbf{a}_2|^2 & -\mathbf{a}_1^T \mathbf{a}_2 \\ \mathbf{a}_1^T \mathbf{a}_2 & |\mathbf{a}_1|^2 \end{pmatrix} \end{aligned} \quad (43)$$

5 誤差分散の推定

残差平方和

$$S(\hat{\boldsymbol{\varepsilon}}) = \sum_{i=1}^n \hat{\varepsilon}_i^2 \quad (44)$$

$$= \hat{\boldsymbol{\varepsilon}}^T \hat{\boldsymbol{\varepsilon}} \quad (45)$$

$$= \{(1-P)\mathbf{y}\}^T (1-P)\mathbf{y} \quad (46)$$

ここで、 $E(S(\hat{\boldsymbol{\varepsilon}}))$ を求めたいが、そのためには、上の式を直接に使わないで、

$$\begin{aligned} \mathcal{M}_\varepsilon &= \hat{\boldsymbol{\varepsilon}} \hat{\boldsymbol{\varepsilon}}^T \\ &= \begin{bmatrix} \hat{\varepsilon}_1^2 & \hat{\varepsilon}_1 \hat{\varepsilon}_2 & \cdots & \hat{\varepsilon}_1 \hat{\varepsilon}_n \\ \hat{\varepsilon}_2 \hat{\varepsilon}_1 & \hat{\varepsilon}_2^2 & \cdots & \hat{\varepsilon}_2 \hat{\varepsilon}_n \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\varepsilon}_n \hat{\varepsilon}_1 & \hat{\varepsilon}_n \hat{\varepsilon}_2 & \cdots & \hat{\varepsilon}_n^2 \end{bmatrix} \end{aligned} \quad (47)$$

を定義して、

$$S(\hat{\boldsymbol{\varepsilon}}) = \text{Tr}[\mathcal{M}_\varepsilon] \quad (48)$$

を用いて計算する。

$$\begin{aligned} \text{Tr}[\mathcal{M}_\varepsilon] &= \text{Tr} \left[(1-P)\mathbf{y} \{(1-P)\mathbf{y}\}^T \right] \\ &= \text{Tr} \left[(1-P)\mathbf{y}\mathbf{y}^T (1-P) \right] \\ &= \text{Tr} \left[(1-P)\mathbf{y}\mathbf{y}^T \right] \end{aligned} \quad (49)$$

ここで (38) 式を用いると、

$$\begin{aligned}
S(E(\hat{\boldsymbol{\varepsilon}})) &= \text{Tr}[E(\mathcal{M}_\varepsilon)] \\
&= \sigma^2 \text{Tr}[(1-P)\mathbf{I}] \\
&= \sigma^2 \text{Tr}[\mathbf{I}-P] \\
&= \sigma^2(\text{Tr}[\mathbf{I}]-\text{Tr}[P])
\end{aligned} \tag{50}$$

ここに、 \mathbf{I} は $n \times n$ の単位行列だから、

$$\text{Tr}[\mathbf{I}] = n$$

また、射影演算子 $P = A(A^T A)^{-1} A^T$ も $n \times n$ 行列で、

$$\text{Tr}[P] = \text{Tr}[A(A^T A)^{-1} A^T] = \text{Tr}[A^T A(A^T A)^{-1}]$$

ところが (28) 式からも分かるように、 $A^T A$ も、その逆行列である $(A^T A)^{-1}$ も 2×2 行列であるので、

$$A^T A(A^T A)^{-1} = \mathbf{I}$$

は、 2×2 の単位行列となる。したがって、

$$\text{Tr}[P] = \text{Tr}[\mathbf{I}] = 2$$

である。これらの結果を (50) 式に代入して、

$$S(E(\hat{\boldsymbol{\varepsilon}})) = (n-2)\sigma^2 \tag{51}$$

を得る。よって、

$$\hat{\sigma}^2 = \frac{S(\hat{\boldsymbol{\varepsilon}})}{n-2} = \frac{\sum_{i=1}^n (y_i - (\hat{\theta}_1 + \hat{\theta}_2 x_i))^2}{n-2} \tag{52}$$

が不偏推定量を与える。

6 最尤推定量の分布

(7) 式の指数の肩にある $S(\boldsymbol{\varepsilon}) = (\mathbf{y} - A\boldsymbol{\theta})^T (\mathbf{y} - A\boldsymbol{\theta})$ を $\hat{\boldsymbol{\theta}}$ の周りで展開すると、

$$S(\boldsymbol{\varepsilon}) = (\mathbf{y} - A\boldsymbol{\theta})^T (\mathbf{y} - A\boldsymbol{\theta}) \tag{53}$$

$$= (\mathbf{y} - A\hat{\boldsymbol{\theta}} + A(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}))^T (\mathbf{y} - A\hat{\boldsymbol{\theta}} + A(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}))$$

$$= (\hat{\boldsymbol{\varepsilon}} + A(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}))^T (\hat{\boldsymbol{\varepsilon}} + A(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}))$$

$$= \hat{\boldsymbol{\varepsilon}}^T \hat{\boldsymbol{\varepsilon}} + 2(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T A^T \hat{\boldsymbol{\varepsilon}} + (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T A^T A (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}) \tag{54}$$

ところが、(31) 式より、 $A^T \hat{\boldsymbol{\varepsilon}} = 0$ だから、

$$S(\boldsymbol{\varepsilon}) = S(\hat{\boldsymbol{\varepsilon}}) + (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T A^T A (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}) \quad (55)$$

である。ところが、(39) 式より、 $A^T A = \sigma^2 \boldsymbol{\Sigma}^{-1}$ だから、

$$S(\boldsymbol{\varepsilon}) = S(\hat{\boldsymbol{\varepsilon}}) + \sigma^2 (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T \boldsymbol{\Sigma}^{-1} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})$$

を得る。これを (7) 式に代入して、尤度推定量 $\hat{\boldsymbol{\theta}}$ の分布関数とみなすと、

$$P(\hat{\boldsymbol{\theta}} | \boldsymbol{\theta}, \boldsymbol{\Sigma}) = C \exp \left\{ -\frac{1}{2} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T \boldsymbol{\Sigma}^{-1} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}) \right\} \quad (56)$$

を得る。

C の計算

C を計算するのに、(56) 式の代わりに、 $\boldsymbol{\Sigma}^{-1}$ を $A^T A / \sigma^2$ で置き換えた

$$P(\hat{\boldsymbol{\theta}} | \boldsymbol{\theta}, \boldsymbol{\Sigma}) = C \exp \left\{ -\frac{1}{2\sigma^2} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T A^T A (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}) \right\} \quad (57)$$

を用いる。

$\boldsymbol{\Theta} = \hat{\boldsymbol{\theta}} - \boldsymbol{\theta}$ とおくと、

$$A(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}) = A\boldsymbol{\Theta} = \Theta_1 \mathbf{a}_1 + \Theta_2 \mathbf{a}_2$$

さらに、

$$\mathbf{e}_1 = \left(\frac{\mathbf{a}_1}{|\mathbf{a}_1|} + \frac{\mathbf{a}_2}{|\mathbf{a}_2|} \right) \quad (58)$$

$$\mathbf{e}_2 = \left(\frac{\mathbf{a}_1}{|\mathbf{a}_1|} - \frac{\mathbf{a}_2}{|\mathbf{a}_2|} \right) \quad (59)$$

とおくと、

$$\mathbf{e}_1^T \mathbf{e}_1 = 2 \left(\frac{|\mathbf{a}_1| |\mathbf{a}_2| + \mathbf{a}_1^T \mathbf{a}_2}{|\mathbf{a}_1| |\mathbf{a}_2|} \right) \quad (60)$$

$$\mathbf{e}_2^T \mathbf{e}_2 = 2 \left(\frac{|\mathbf{a}_1| |\mathbf{a}_2| - \mathbf{a}_1^T \mathbf{a}_2}{|\mathbf{a}_1| |\mathbf{a}_2|} \right) \quad (61)$$

$$\mathbf{e}_1^T \mathbf{e}_2 = 0 \quad (62)$$

となることに注意しよう。さらに、

$$\mathbf{i}_1 = \frac{\mathbf{e}_1}{|\mathbf{e}_1|} \quad (63)$$

$$\mathbf{i}_2 = \frac{\mathbf{e}_2}{|\mathbf{e}_2|} \quad (64)$$

$$(65)$$

と置くと、

$$A\Theta = \frac{|e_1|}{2}(\Theta_1|\mathbf{a}_1| + \Theta_2|\mathbf{a}_2|)\mathbf{i}_1 + \frac{|e_2|}{2}(\Theta_1|\mathbf{a}_1| - \Theta_2|\mathbf{a}_2|)\mathbf{i}_2$$

ここで、

$$u_1\sigma = \frac{|e_1|}{2}(\Theta_1|\mathbf{a}_1| + \Theta_2|\mathbf{a}_2|)$$

$$u_2\sigma = \frac{|e_2|}{2}(\Theta_1|\mathbf{a}_1| - \Theta_2|\mathbf{a}_2|)$$

と置くと、

$$A\Theta = u_1\sigma\mathbf{i}_1 + u_2\sigma\mathbf{i}_2 \quad (66)$$

だから、

$$\frac{1}{2\sigma^2}\Theta^T A^T A \Theta = \frac{u_1^2}{2} + \frac{u_2^2}{2} \quad (67)$$

また、

$$\frac{\partial(u_1, u_2)}{\partial(\Theta_1, \Theta_2)} = \begin{vmatrix} \frac{|e_1||\mathbf{a}_1|}{2} & \frac{|e_1||\mathbf{a}_2|}{2} \\ \frac{|e_2||\mathbf{a}_1|}{2} & -\frac{|e_2||\mathbf{a}_2|}{2} \end{vmatrix} \quad (68)$$

$$= -\frac{1}{2\sigma^2}|e_1||e_2||\mathbf{a}_1||\mathbf{a}_2| \quad (69)$$

$$= -\sqrt{\frac{|\mathbf{a}_1|^2|\mathbf{a}_2|^2 - (\mathbf{a}_1^T \mathbf{a}_2)^2}{\sigma^4}} \quad (70)$$

$$= -\sqrt{\frac{|A^T A|}{\sigma^4}} \quad (71)$$

となるので、結局、

$$\frac{\partial(u_1, u_2)}{\partial(\Theta_1, \Theta_2)} = -\frac{1}{\sqrt{|\Sigma|}} \quad (72)$$

を得る。ここで、 $\Sigma = \frac{\sigma^2}{A^T A}$ は、 2×2 行列である。従って、 $|\Sigma| = \frac{\sigma^4}{|A^T A|}$ となることを用いた。

ゆえに、

$$\begin{aligned} \int P(\hat{\theta}|\theta, \Sigma) d\Theta_1 d\Theta_2 &= \left| \frac{\partial(\Theta_1, \Theta_2)}{\partial(u_1, u_2)} \right| C \int \exp \left\{ -\frac{u_1^2}{2} - \frac{u_2^2}{2} \right\} du_1 du_2 \\ &= \sqrt{|\Sigma|} C \int \exp \left\{ -\frac{u_1^2}{2} - \frac{u_2^2}{2} \right\} du_1 du_2 \\ &= 2\pi \sqrt{|\Sigma|} C \\ &= 1 \end{aligned}$$

$$\therefore C = \frac{1}{2\pi\sqrt{|\Sigma|}}$$

以上より、

$$P(\hat{\boldsymbol{\theta}}|\boldsymbol{\theta}, \Sigma) = \frac{1}{2\pi} \sqrt{\frac{|A^T A|}{\sigma^4}} \exp \left\{ -\frac{1}{2\sigma^2} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T A^T A (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}) \right\} \quad (73)$$

$$= \frac{1}{2\pi\sqrt{|\Sigma|}} \exp \left\{ -\frac{1}{2} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T \Sigma^{-1} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}) \right\} \quad (74)$$

を得る。

7 周辺分布と共分散

(73) 式より、

$$P(\hat{\boldsymbol{\Theta}}|\Sigma) = \frac{1}{2\pi} \sqrt{\frac{|A^T A|}{\sigma^4}} \exp \left\{ -\frac{1}{2\sigma^2} \hat{\boldsymbol{\Theta}}^T A^T A \hat{\boldsymbol{\Theta}} \right\} \quad (75)$$

ここで、

$$\hat{\boldsymbol{\Theta}}^T A^T A \hat{\boldsymbol{\Theta}} = \mathbf{a}_1^T \mathbf{a}_1 \hat{\Theta}_1^2 + 2\mathbf{a}_1^T \mathbf{a}_2 \hat{\Theta}_1 \hat{\Theta}_2 + \mathbf{a}_2^T \mathbf{a}_2 \hat{\Theta}_2^2 \quad (76)$$

$$= \left(|\mathbf{a}_1|^2 - \frac{(\mathbf{a}_1^T \mathbf{a}_2)^2}{|\mathbf{a}_2|^2} \right) \hat{\Theta}_1^2 + |\mathbf{a}_2|^2 \left(\hat{\Theta}_2 + \frac{\mathbf{a}_1^T \mathbf{a}_2}{|\mathbf{a}_2|^2} \hat{\Theta}_1 \right)^2 \quad (77)$$

$$= |\mathbf{a}_1|^2 \left(\hat{\Theta}_1 + \frac{\mathbf{a}_1^T \mathbf{a}_2}{|\mathbf{a}_1|^2} \hat{\Theta}_2 \right)^2 + \left(|\mathbf{a}_2|^2 - \frac{(\mathbf{a}_1^T \mathbf{a}_2)^2}{|\mathbf{a}_1|^2} \right) \hat{\Theta}_2^2 \quad (78)$$

だから、

$$\begin{aligned} P(\hat{\Theta}_1|\Sigma) &= \int P(\hat{\boldsymbol{\Theta}}|\Sigma) d\Theta_2 \\ &= \sqrt{\frac{|A^T A|}{2\pi\sigma^2|\mathbf{a}_2|^2}} \exp \left\{ -\frac{1}{2\sigma^2} \left(|\mathbf{a}_1|^2 - \frac{(\mathbf{a}_1^T \mathbf{a}_2)^2}{|\mathbf{a}_2|^2} \right) \hat{\Theta}_1^2 \right\} \\ &= \sqrt{\frac{|A^T A|}{2\pi\sigma^2|\mathbf{a}_2|^2}} \exp \left\{ -\frac{|A^T A|}{2\sigma^2|\mathbf{a}_2|^2} \hat{\Theta}_1^2 \right\} \end{aligned} \quad (79)$$

$$\begin{aligned} P(\hat{\Theta}_2|\Sigma) &= \int P(\hat{\boldsymbol{\Theta}}|\Sigma) d\Theta_1 \\ &= \sqrt{\frac{|A^T A|}{2\pi\sigma^2|\mathbf{a}_1|^2}} \exp \left\{ -\frac{1}{2\sigma^2} \left(|\mathbf{a}_2|^2 - \frac{(\mathbf{a}_1^T \mathbf{a}_2)^2}{|\mathbf{a}_1|^2} \right) \hat{\Theta}_2^2 \right\} \\ &= \sqrt{\frac{|A^T A|}{2\pi\sigma^2|\mathbf{a}_1|^2}} \exp \left\{ -\frac{|A^T A|}{2\sigma^2|\mathbf{a}_1|^2} \hat{\Theta}_2^2 \right\} \end{aligned} \quad (80)$$

を得る。ここで、(43)式を用いると、

$$\begin{aligned} P(\hat{\Theta}_1|\Sigma) &= \frac{1}{\sqrt{2\pi\sigma_{11}^2}} \exp\left(-\frac{\hat{\Theta}_1^2}{2\sigma_{11}^2}\right) \\ &= \sqrt{\frac{n\sum_i(x_i-\bar{x})^2}{2\pi\sigma^2\sum_i x_i^2}} \exp\left(-\frac{n\sum_i(x_i-\bar{x})^2}{2\sigma^2\sum_i x_i^2}\hat{\Theta}_1^2\right) \end{aligned} \quad (81)$$

$$\begin{aligned} P(\hat{\Theta}_2|\Sigma) &= \frac{1}{\sqrt{2\pi\sigma_{22}^2}} \exp\left(-\frac{\hat{\Theta}_2^2}{2\sigma_{22}^2}\right) \\ &= \sqrt{\frac{\sum_i(x_i-\bar{x})^2}{2\pi\sigma^2}} \exp\left(-\frac{\sum_i(x_i-\bar{x})^2}{2\sigma^2}\hat{\Theta}_2^2\right) \end{aligned} \quad (82)$$

$$(83)$$

を得る。

また、

$$\begin{aligned} \sigma_{12}^2 &= \frac{1}{2\pi} \sqrt{\frac{|A^T A|}{\sigma^4}} \int \hat{\Theta}_1 \hat{\Theta}_2 \exp\left\{-\frac{1}{2\sigma^2} \hat{\Theta}^T A^T A \hat{\Theta}\right\} d\hat{\Theta}_1 d\hat{\Theta}_2 \\ &= \frac{1}{2\pi} \sqrt{\frac{|A^T A|}{\sigma^4}} \int d\hat{\Theta}_1 d\hat{\Theta}_2 \hat{\Theta}_1 \hat{\Theta}_2 \\ &\quad \exp\left\{-\frac{1}{2\sigma^2} \left[|\mathbf{a}_1|^2 \left(\hat{\Theta}_1 + \frac{\mathbf{a}_1^T \mathbf{a}_2}{|\mathbf{a}_1|^2} \hat{\Theta}_2\right)^2 + \frac{|A^T A|}{|\mathbf{a}_1|^2} \hat{\Theta}_2^2\right]\right\} \\ &= \frac{1}{2\pi} \sqrt{\frac{|A^T A|}{\sigma^4}} \left(-\frac{\mathbf{a}_1^T \mathbf{a}_2}{|\mathbf{a}_1|^2}\right) \sqrt{\frac{2\pi\sigma^2}{|\mathbf{a}_1|^2}} \int d\hat{\Theta}_2 \hat{\Theta}_2^2 \exp\left\{-\frac{|A^T A|}{2\sigma^2|\mathbf{a}_1|^2} \hat{\Theta}_2^2\right\} \\ &= \frac{1}{2\pi} \sqrt{\frac{|A^T A|}{\sigma^4}} \left(-\frac{\mathbf{a}_1^T \mathbf{a}_2}{|\mathbf{a}_1|^2}\right) \sqrt{\frac{2\pi\sigma^2}{|\mathbf{a}_1|^2}} \frac{\sqrt{\pi}}{2} \frac{(2\sigma^2|\mathbf{a}_1|)^{3/2}}{|A^T A|^{3/2}} \\ &= -\frac{\sigma^2 \mathbf{a}_1^T \mathbf{a}_2}{|A^T A|} \end{aligned} \quad (84)$$

これは、(43)式の結果と一致している。

8 t分布

8.1 一変量 t 分布

(81)式より、 $\hat{\Theta}_1$ は、 $N(0, \sigma_{11}^2)$ の正規分布に従う。そこで、変数変換

$$\begin{aligned} P(u'_1) &= \int \delta\left(u'_1 - \frac{\sqrt{|A^T A|}}{\sigma|\mathbf{a}_2|} \hat{\Theta}_1\right) P(\hat{\Theta}_1|\Sigma) d\hat{\Theta}_1 \\ &= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{u_1'^2}{2}\right) \end{aligned} \quad (85)$$

を行うと、

$$u'_1 = \sqrt{\frac{n \sum_i (x_i - \bar{x})^2}{\sigma^2 \sum_i x_i^2}} (\hat{\theta}_1 - \theta_1) \quad (86)$$

は、 $N(0, 1)$ の正規分布に従う。

一方、

$$v = \frac{S(\hat{\epsilon})}{\sigma^2}$$

は、自由度 $n - 2$ の χ^2 分布に従う。

(52) 式より、不偏分散は、

$$\hat{\sigma}^2 = \frac{S(\hat{\epsilon})}{n - 2} = \frac{(\mathbf{y} - A\hat{\boldsymbol{\theta}})^2}{n - 2}$$

だから、

$$v = \frac{(n - 2)\hat{\sigma}^2}{\sigma^2} \quad (87)$$

と書ける。

(86) 式の σ^2 は未知なので、(52) 式の $\hat{\sigma}^2$ で置き換えた、

$$t'_1 = \sqrt{\frac{n \sum_i (x_i - \bar{x})^2}{\hat{\sigma}^2 \sum_i x_i^2}} (\hat{\theta}_1 - \theta_1) = \sqrt{\frac{n - 2}{v}} u'_1 \quad (88)$$

は、自由度 $n - 2$ の t 分布に従う。

同様にして、

$$t'_2 = \sqrt{\frac{\sum_i (x_i - \bar{x})^2}{\hat{\sigma}^2}} (\hat{\theta}_2 - \theta_2) \quad (89)$$

もまた自由度 $n - 2$ の t 分布に従う。

8.2 二変量 t 分布

(67) 式より、

$$A\hat{\boldsymbol{\Theta}} = A\hat{\boldsymbol{\theta}} - A\boldsymbol{\theta}$$

は $N(\mathbf{0}, \sigma^2 \mathbf{1})$ に従う。

また、(66) 式より、

$$\mathbf{u} = \frac{A\hat{\boldsymbol{\theta}} - A\boldsymbol{\theta}}{\sigma} = u_1 \mathbf{i}_1 + u_2 \mathbf{i}_2 \quad (90)$$

は、 $N(\mathbf{0}, \mathbf{1})$ に従う。

そこで、

$$\mathbf{t} = \frac{A\hat{\boldsymbol{\theta}} - A\boldsymbol{\theta}}{\hat{\sigma}} \quad (91)$$

$$= \frac{(A\hat{\boldsymbol{\theta}} - A\boldsymbol{\theta})}{\sigma} \frac{\sigma}{\hat{\sigma}} \quad (92)$$

$$= \sqrt{\frac{n-2}{v}} \mathbf{u} \quad (93)$$

と置くと、これは自由度 $n-2$ の 2 変量 t 分布に従う。

その分布は、

$$f(\mathbf{t}) = \int du_1 du_2 dv \delta\left(\mathbf{t} - \sqrt{\frac{n-2}{v}} \mathbf{u}\right) \times \frac{1}{2\pi} \exp\left\{-\frac{1}{2} \mathbf{u}^T \mathbf{u}\right\} \frac{1}{2^{(n-2)/2} \Gamma\left(\frac{n-2}{2}\right)} v^{(n-4)/2} e^{-v/2} \quad (94)$$

$$= \frac{1}{\pi(n-2)2^{n/2} \Gamma\left(\frac{n-2}{2}\right)} \int dv v^{(n-2)/2} \exp\left\{-\left(1 + \frac{\mathbf{t}^T \mathbf{t}}{n-2}\right) \frac{v}{2}\right\} \quad (95)$$

となる。ここで、

$$x = \left(1 + \frac{\mathbf{t}^T \mathbf{t}}{n-2}\right) \frac{v}{2}$$

とにおいて、(95) 式の積分を行うと、

$$\begin{aligned} & \int dv v^{(n-2)/2} \exp\left\{-\left(1 + \frac{\mathbf{t}^T \mathbf{t}}{n-2}\right) \frac{v}{2}\right\} \\ &= 2^{n/2} \left(1 + \frac{\mathbf{t}^T \mathbf{t}}{n-2}\right)^{-n/2} \int_0^\infty x^{(n-2)/2} e^{-x} dx \\ &= 2^{n/2} \Gamma\left(\frac{n}{2}\right) \left(1 + \frac{\mathbf{t}^T \mathbf{t}}{n-2}\right)^{-n/2} \end{aligned}$$

となるので、

$$f(\mathbf{t}) = \frac{\Gamma\left(\frac{n}{2}\right)}{(n-2)\pi\Gamma\left(\frac{n-2}{2}\right)} \left(1 + \frac{\mathbf{t}^T \mathbf{t}}{n-2}\right)^{-n/2} \quad (96)$$

を得る。また、ガンマ関数の性質

$$\Gamma\left(\frac{n}{2}\right) = \left(\frac{n-2}{2}\right) \Gamma\left(\frac{n-2}{2}\right)$$

より、(96) 式は、

$$f(\mathbf{t}) = \frac{1}{2\pi} \left(1 + \frac{\mathbf{t}^T \mathbf{t}}{(n-2)} \right)^{-n/2} \quad (97)$$

となる。

(90) 式と同様に (91) 式は、

$$\mathbf{t} = t_1 \mathbf{i}_1 + t_2 \mathbf{i}_2$$

と書けるので、

$$\mathbf{t}^T \mathbf{t} = t_1^2 + t_2^2$$

となる。そこで、(96) 式も、また、

$$f(t_1, t_2) = \frac{1}{2\pi} \left(1 + \frac{t_1^2 + t_2^2}{n-2} \right)^{-n/2}$$

と表すことができる。

(91) 式より、

$$\mathbf{t}^T \mathbf{t} = \frac{1}{\hat{\sigma}^2} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T A^T A (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})$$

ここで、

$$\hat{\boldsymbol{\Sigma}} = \frac{\hat{\sigma}^2}{A^T A}$$

と置くと、

$$\mathbf{t}^T \mathbf{t} = (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T \hat{\boldsymbol{\Sigma}}^{-1} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})$$

また、(72) 式と類似の関係式、

$$\frac{\partial(t_1, t_2)}{\partial(\Theta_1, \Theta_2)} = -\frac{1}{\sqrt{|\hat{\boldsymbol{\Sigma}}|}} \quad (98)$$

が成り立つので、(97) 式を $\boldsymbol{\theta}$ を用いて書き直すと、

$$f_{\boldsymbol{\theta}}(\boldsymbol{\theta}) = \frac{1}{\sqrt{|\hat{\boldsymbol{\Sigma}}|}} f \left(\frac{A\hat{\boldsymbol{\theta}} - A\boldsymbol{\theta}}{\hat{\sigma}} \right) \quad (99)$$

より、

$$f_{\boldsymbol{\theta}}(\boldsymbol{\theta}) = \frac{1}{2\pi \sqrt{|\hat{\boldsymbol{\Sigma}}|}} \left(1 + \frac{(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T \hat{\boldsymbol{\Sigma}}^{-1} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})}{(n-2)} \right)^{-n/2} \quad (100)$$

と表すことができる。