

## Informationの多変数解析への応用について

羽鳥, 司  
東京学芸大学

<https://doi.org/10.15017/12723>

---

出版情報：統計科学研究. 1 (3), pp.15-27, 1956-09. Research Association of Statistical Sciences  
バージョン：  
権利関係：

# Information の多変数解析 への応用について

羽 鳥 司 (東京学芸大)

## § 1. 序

最近 *information* を用いて統計解析を行う傾向があり、以下述べて見たいと思う。

### 定義 1

確率密度函数  $f_1(x)$ ,  $f_2(x)$  の間の差  $I(f_1, f_2)$  とは

$$(1) \dots I(f_1, f_2) = I(1, 2) = \int f_1(x) \log \frac{f_1(x)}{f_2(x)} dx$$

以下積分範囲は特にことわらないときは  $(-\infty, \infty)$  とす。

又、弁別距離 (*discriminative information or divergence*) とは

$$(2) \dots J(f_1, f_2) = J(1, 2) = \int [f_1(x) - f_2(x)] \log \frac{f_1(x)}{f_2(x)} dx$$

ここで (2) は Mahalanobis の *distance* などと特別の場合として含んでおり、Shannon, Wiener の *information* の考えによる *measure* である。S. Kullback, R. A. Leibler が 1951 年の論文で使われ始めた。

次に、これを  $k$  変数正規母集団の場合に適用したらどうなるか。証明を述べず結果だけのべよう。

### 定理 1.

二つの  $k$  変数正規分布の密度函数  $f_1(x)$ ,  $f_2(x)$  において

$$(3) \dots f_i(x) = \frac{1}{\sqrt{(2\pi)^k |\sigma_{(i)}|}} e^{-\frac{1}{2}(x - \mu_{(i)})' \sigma_{(i)}^{-1} (x - \mu_{(i)})}$$

ここで

$\mu_{(i)}$  は *mean vector*

$\sigma_{(i)}$  は *variance and covariance matrix*

$x' = (x_1, x_2, \dots, x_k)$

(16)

$$\mu_{(i)} = (\mu_{1(i)}, \mu_{2(i)}, \dots, \mu_{k(i)})$$

$$\sigma_{(i)} = (\sigma_{st}) \quad s, t = 1, \dots, k \quad \sigma_{zs} = \sigma_{st}$$

$$i = 1, 2$$

とするとき

$$I(1, 2) = I(f_1, f_2)$$

$$(4) \dots = \frac{1}{2} \log \frac{|\sigma_{(2)}|}{|\sigma_{(1)}|} + \frac{1}{2} \text{tr}(\sigma_{(1)} - \sigma_{(2)}) \sigma_{(2)}^{-1} + \frac{1}{2} \delta' \sigma_{(2)}^{-1} \delta$$

$$\text{ただし } \delta = \mu_{(1)} - \mu_{(2)}$$

$$J(1, 2) = J(f_1, f_2)$$

$$(5) \dots = \frac{1}{2} \text{tr}[(\sigma_{(1)} - \sigma_{(2)})(\sigma_{(2)}^{-1} - \sigma_{(1)}^{-1})] + \frac{1}{2} \delta'(\sigma_{(1)}^{-1} + \sigma_{(2)}^{-1}) \delta$$

or

$$(6) \dots = \frac{1}{2} \text{tr} \sigma_{(1)} \sigma_{(2)}^{-1} + \frac{1}{2} \text{tr} \sigma_{(2)} \sigma_{(1)}^{-1} - k + \frac{1}{2} \delta'(\sigma_{(1)}^{-1} + \sigma_{(2)}^{-1}) \delta$$

証明. S. Kullback: *An application of information theory to multivariate analysis*. Ann. Math. Stat. Vol. 23 (1952) 参照.

当然のことであるが、次の系が得る。

### 系 1. 1

両母集団の平均ベクトル等しいとき、及び分散共分散行列等しいときは次のように簡単になる。

$$(7) \mu_{(1)} = \mu_{(2)} \Rightarrow I(1, 2) = \frac{1}{2} \log \frac{|\sigma_{(2)}|}{|\sigma_{(1)}|} + \frac{1}{2} \text{tr}(\sigma_{(1)} - \sigma_{(2)}) \sigma_{(2)}^{-1}$$

$$(8) \mu_{(1)} = \mu_{(2)} \Rightarrow J(1, 2) = \frac{1}{2} \text{tr}(\sigma_{(1)} - \sigma_{(2)})(\sigma_{(2)}^{-1} - \sigma_{(1)}^{-1})$$

$$\text{例えば一変数のときは } J(1, 2) = \frac{1}{2} (\sigma_1^2 - \sigma_2^2) \left( \frac{1}{\sigma_2^2} - \frac{1}{\sigma_1^2} \right) = \frac{1}{2} \left( \frac{\sigma_1^2}{\sigma_2^2} + \frac{\sigma_2^2}{\sigma_1^2} \right) - 1.$$

$$(9) \sigma_{(1)} = \sigma_{(2)} \Rightarrow I(1, 2) = \frac{1}{2} \delta' \sigma \delta \quad \sigma \equiv \sigma_{(1)} = \sigma_{(2)}$$

$$(10) \sigma_{(1)} = \sigma_{(2)} \Rightarrow J(1, 2) = \delta' \sigma \delta = 2I(1, 2)$$

これは常数倍のちがいで Mahalanobis の distance を表わす。例えば一変数の場合だと

$$2I(1, 2) = J(1, 2) = \frac{(\mu_1 - \mu_2)^2}{\sigma^2} \quad \text{である。}$$

## §2. Maximum information principleについて

今  $I(1, 2) = I(f_1, f_2)$  において  $f_2$  が既知のとき Information の差  $I(f_1, f_2)$  を最大ならしむるように  $f_1$  をきめる。この principle を Maximum information principle とよび、これを用いて、検定、推定等の principle にする。

先ず、その一般論として次にのべる。

### 定理 2

$I(g^*(x), g_2(x|\theta))$  において

$g_2(x|\theta)$  は与えられたとし

$g^*(x)$  の平均  $\int x g^*(x) dx = a$  も分ったとき

$\Rightarrow I(g^*(x), g_2(x|\theta))$  を Maximize する  $g^*$  は

$$(11) \quad \dots \quad g^*(x) = e^{tx} g_2(x) / M_2(t)$$

ただし

$$M_2(t) = \int e^{tx} g_2(x) dx$$

### 証明

$$(12) \quad \dots \quad I(g^*, g_2) = \int g^*(x) \log \frac{g^*(x)}{g_2(x)} dx$$

$$(13) \quad \dots \quad \text{今, 条件 } \int g^* dx = 1, \quad \int x g^* dx = a$$

の下で求める

$$(14) \quad \dots \quad \text{これは } X = \int (g^*(x) \log \frac{g^*(x)}{g_2(x)} + k g^*(x) + l x g^*(x)) dx$$

を Max. にすることと同値

故に変分法で

$$(15) \quad \dots \quad \delta X = 0 = \int \delta g^*(x) \left[ \log \frac{g^*(x)}{g_2(x)} + k + lx \right] dx$$

$$\text{ゆえに } \log \frac{g^*(x)}{g_2(x)} + k + lx = 0$$

$$(16) \quad \text{よって } g^*(x) = e^{-k-lx} g_2(x)$$

(18)

$$\text{又} \quad 1 = \int g^*(x) dx = \int e^{-k-\ell x} g_2(x)$$

$$(17) \quad = e^{-k} \int e^{-\ell x} g_2(x)$$

$$-\ell = t \quad \text{とおくと}$$

$$= e^{-k} \int e^{tx} g_2(x)$$

$$(18) \quad = e^{-k} M_2(t)$$

$$(19) \quad \text{よって} \quad g^*(x) = e^{tx} g_2(x) / M_2(t)$$

$$(20) \quad M_2(t) = \int e^{tx} g_2(x) \quad (\text{Q.E.D.})$$

これで最大ならしめるものの形がわかった。

このときの最大 information  $I^*(\theta, t)$  は

系 2, 1.

$$I^*(\theta, t) \equiv I(g^*(x), g_2(x|\theta))$$

$$(21) \quad = \int g^*(x) \log \frac{g^*(x)}{g_2(x)} dx = at - \log M_2(t)$$

証明. 明かである。

又, 弁別距離  $J(g^*, g_2)$  の方については

系 2, 2.

$$(22) \quad J^*(\theta, t) \equiv J(g^*, g_2) = \int (g^* - g_2) \log \frac{g^*}{g_2} dx$$

$$= t(a - E_2(x))$$

証

$$\int g_2(x) \log \frac{g^*(x)}{g_2(x)} dx = \log M_2(t) - tE_2(x)$$

より出る。(終)

次に  $a, t$  共に Matrix で支えられているときに拡張すると容易に分る。

系 2, 3.

$$(23) \quad \dots \quad I^*(\theta, t) = \text{tr}[a, t] - \log M_2(t)$$

### § 3. $k$ 変数正規母集団の解析への応用

Maximum information principle を多変数正規母集団の等分散仮説の検定, 等平均仮説の検定等への応用をのべる.

先ず, 上記の  $M_2(t)$  即ち *moment of generating function* の一般化したものを求めよう.

#### 補題 1

$i = 1, \dots, r$  として  $\pi_i$  なる  $r$  個の  $k$ 変数正規母集団からそれぞれ  $n_i$  個の *observations* をとったとき, その *sample mean vector* を  $\bar{x}_i = (\bar{x}_{i1}, \dots, \bar{x}_{ik})$ . *unbiased sample variance and covariance matrix* を  $S_i$  即ち 変動  $V_i$ , 自由度  $N_i$  としたとき  $V_i = N_i S_i$  ( $i = 1, \dots, r$ )

$(\bar{x}_1, \dots, \bar{x}_r, V_1, V_2, \dots, V_r)$  の *moment of generating function*  $M_2(t)$  は

$$(24) \quad \dots \quad M_2(t) = M_2(t_1, \dots, t_r, T_1, \dots, T_r)$$

$$= \prod_{i=1}^r |I - 2\theta_i T_i|^{-\frac{N_i}{2}} \exp(t_i' \mu_i + \frac{1}{2} t_i' \frac{\sigma_i}{n_i} t_i)$$

ただし  $t_i = (t_{i1}, t_{i2}, \dots, t_{ik})$

$T_i = (t_{lm}^{(i)}) \quad l, m = 1, \dots, k \quad k$  次 *matrix*

$I$  は単位行列

#### 証明

$(\bar{x}_1, \dots, \bar{x}_r)$  は正規分布とし,  $(V_1, \dots, V_r)$  は独立に Wishart 分布をすることを考慮すれば S. S. Wilks の *Mathematical Statistics* にある低次元の場合を同様に拡張出来る。(終)

この  $M_2(t)$  を用いて多変量解析の場合の (21) 式にある  $I^*(\theta|t)$  に相当するものを求めよう.

#### 補題 2

$$\theta = (\mu_1, \dots, \mu_r, \sigma_1, \sigma_2, \dots, \sigma_r)$$

$$a = (\bar{x}_1, \dots, \bar{x}_r, V_1, V_2, \dots, V_r)$$

とするとき, 前定理の系の  $I^*(\theta|t)$  は次のように与えられる.

$$(25) \quad \dots \quad I^*(\theta, t) = \sum_{i=1}^r t_i' \bar{x}_i - t_i' \mu_i - \frac{1}{2} t_i' \frac{\sigma_i}{n_i} t_i$$

(20)

$$+ \sum_{i=1}^r \text{tr } T_i V_i$$

$$+ \frac{1}{2} \sum_{i=1}^r N_i \log |I - 2\sigma_i T_i|$$

証明  $I^*(\theta, t) = \text{tr}(a, t) - \log M_2(t)$

こゝで  $t = (t_1, \dots, t_r, T_1, \dots, T_r)$  であるから  $\text{tr}(a, t) = \sum t_i' \bar{x}_i + \sum \text{tr}(T_i V_i)$

$$\log M_2(t) = \sum t_i' \mu_i + \frac{1}{2} t_i' \frac{\sigma_i}{n_i} t_i - \sum \frac{N_i}{2} \log |I - 2\sigma_i T_i|$$

からである。(終)

### 補題3

(25)式の  $I^*(\theta, t)$  を Maximize する  $t = (t_1, \dots, t_r, T_1, \dots, T_r)$  は

$$(26) \quad t_i = n_i \sigma_i^{-1} (\bar{x}_i - \mu_i)$$

$$(27) \quad T_i = \frac{1}{2} \sigma_i^{-1} - \frac{1}{2} S_i^{-1}$$

であり, その最大値  $I^*(\theta)$  は

$$(28) \quad I^*(\theta) = \sum \frac{n_i}{2} (\bar{x}_i - \mu_i)' \sigma_i^{-1} (\bar{x}_i - \mu_i)$$

$$+ \sum \frac{N_i}{2} \left( \log \frac{|\sigma_i|}{|S_i|} - k + \text{tr}[\sigma_i^{-1}, S_i] \right)$$

### 証明

$$(29) \quad \frac{\partial}{\partial t_i} I^*(\theta, t) = \bar{x}_i - \mu_i - \frac{\sigma_i}{n_i} t_i = 0$$

$$\frac{\partial}{\partial T_i} I^*(\theta, t) = 0$$

$$(30) \quad \text{すなわち } t_i' (dT_i) V_i - N_i \text{tr}(I - 2\sigma_i T_i)^{-1} \sigma_i (dT_i) = 0$$

これを計算すると

$$\text{tr}(I - 2\sigma_i T_i)^{-1} \sigma_i = \frac{V_i}{N_i} = S_i$$

よって  $T_i = \frac{1}{2}(\sigma_i^{-1} - S_i^{-1})$ , (26), (27)を得た。

これを(25)式に代入すると

$$t_i' (\bar{x}_i - \mu_i) = n_i (\bar{x}_i - \mu_i)' \sigma_i^{-1} \quad (\sigma_i \text{ は symmetric だから})$$

$$\begin{aligned} \frac{1}{2} t_i' \frac{\sigma_i}{n} t_i &= \frac{1}{2} [n_i (\bar{x}_i - \mu_i)' \sigma_i^{-1}] \frac{\sigma_i}{n_i} [n_i \sigma_i^{-1} (\bar{x}_i - \mu_i)] \\ &= \frac{1}{2} n_i (\bar{x}_i - \mu_i)' \sigma_i^{-1} (\bar{x}_i - \mu_i) \end{aligned}$$

$$\begin{aligned} t_r' T_i V_i &= t_r' [(\frac{1}{2} \sigma_i^{-1} - \frac{1}{2} S_i^{-1}) N_i S_i] \\ &= t_r' [\frac{1}{2} N_i (\sigma_i^{-1} S_i - I)] \\ &= \frac{1}{2} N_i (t_r' \sigma_i^{-1} S_i - k) \end{aligned}$$

$$\begin{aligned} I - 2 \sigma_i T_i &= I - 2 \sigma_i (\frac{1}{2} \sigma_i^{-1} - \frac{1}{2} S_i^{-1}) \\ &= I - I + \sigma_i S_i^{-1} = \sigma_i S_i^{-1} \end{aligned}$$

$$\log |I - 2 \sigma_i T_i| = \log |\sigma_i S_i^{-1}| = \log \frac{|\sigma_i|}{|S_i|}$$

これらより (28) 式を得ることが出来る。(終)

いよいよ等平均仮説検定の問題にうつろう。

### 定理 3

$$H_2: \mu_1 = \mu_2 = \dots = \mu_r (= \mu)$$

$$\sigma_1, \sigma_2, \dots, \sigma_r$$

と仮説をたてたとき

$I^*(\mu, \sigma_1, \sigma_2, \dots, \sigma_r)$  の *Mim.* を与えるものは

$$(31) \quad \begin{cases} \hat{\mu} = \left( \sum_{i=1}^r n_i S_i^{-1} \right)^{-1} \left( \sum n_i S_i^{-1} \bar{x}_i \right) \\ \hat{\sigma}_i = S_i \end{cases}$$

かつ、その値  $\hat{I}$  は

$$(32) \quad \begin{aligned} \hat{I} &= I^*(\hat{\mu}, \hat{\sigma}_1, \dots, \hat{\sigma}_r) \\ &= \frac{1}{2} \sum n_i (\bar{x}_i - \bar{x})' S_i^{-1} (\bar{x}_i - \bar{x}) \end{aligned}$$

ただし  $\bar{x} = \left( \sum n_i S_i^{-1} \right)^{-1} \left( \sum n_i S_i^{-1} \bar{x}_i \right)$  とす

証明  $I^*(\mu, \sigma_1, \dots, \sigma_r)$



(22)

$$(33) \quad \dots = \sum \frac{n_i}{2} (\bar{x}_i - \mu)' \sigma_i^{-1} (x_i - \mu) + \sum \frac{N_i}{2} \left( \log \frac{|\sigma_i|}{|S_i|} - k + t_r \sigma_i^{-1} S_i \right)$$

今  $\sigma_i$  について minimize するものは容易に分るように  $\hat{\sigma}_i = S_i$

又  $\mu$  につき  $0 = \delta I^* = \sum n_i S_i^{-1} (\bar{x}_i - \mu) = \sum n_i S_i^{-1} \bar{x}_i - \mu \sum n_i S_i^{-1}$

ゆえに  $\mu = (\sum n_i S_i^{-1})^{-1} (\sum n_i S_i^{-1} \bar{x}_i)$

$\hat{I}$  は代入すれば求められる. (終)

次は, 等分散仮説の場合である.

#### 定理 4

$H_2: \sigma_1 = \sigma_2 = \dots = \sigma_r (= \sigma), \mu_1, \dots, \mu_r$

$I^*(\mu_1, \mu_2, \dots, \mu_r, \sigma)$  を Min. ならしめるものは

$$(35) \quad \dots \begin{cases} \hat{\mu}_i = \bar{x}_i \\ \hat{\sigma} = \frac{1}{\sum N_i} \left( \sum_{i=1}^r N_i S_i \right) = \frac{1}{N} \left( \sum N_i S_i \right) = S \end{cases}$$

(  $\sum N_i S_i = NS$  とすれば )

又その値  $\hat{I}$  は

$$(36) \quad \dots \hat{I} = I^*(\hat{\mu}_1, \dots, \hat{\mu}_r, \hat{\sigma})$$

$$= \frac{1}{2} \sum N_i \log \frac{|S|}{|S_i|}$$

#### 証明

$I^*(\mu_1, \dots, \mu_r, \sigma)$  は

$$= \sum \frac{n_i}{2} (\bar{x}_i - \mu_i)' \sigma^{-1} (\bar{x}_i - \mu_i) + \sum \frac{N_i}{2} \left( \log \frac{|\sigma|}{|S_i|} - k + t_r \sigma^{-1} S_i \right)$$

$\delta$  をとると  $\mu_i$  につき

$$(37) \quad \dots 0 = \delta I^* = n_i \sigma^{-1} (\bar{x}_i - \mu_i) = 0 \quad \text{ゆえに } \mu_i = \bar{x}_i$$

$\sigma$  について

$$(38) \quad \dots 0 = \delta I^* = \sum -\frac{n_i}{2} (\bar{x}_i - \mu_i)' (\sigma^{-1}) (\delta \sigma) (\sigma^{-1}) (\bar{x}_i - \mu_i)$$

$$+ \sum \frac{N_i}{2} t_r \sigma^{-1} (\delta \sigma) - \sum \frac{N_i}{2} t_r S_i \sigma^{-1} (\delta \sigma) \sigma^{-1}$$

ゆえに

$$\sum N_i \sigma = \sum N_i S_i, \quad N\sigma = \sum N_i S_i, \quad \text{ゆえに } \sigma = \frac{1}{N} \sum N_i S_i$$

次に  $I^*(\mu_1, \dots, \mu_r, \sigma)$  に  $\hat{\mu}_1, \dots, \hat{\mu}_r, \hat{\sigma}$  を入れると

$$\begin{aligned}
I^*(\hat{\mu}_1, \dots, \hat{\mu}_r, \hat{\sigma}) &= \frac{1}{2} \sum N_i \left\{ \log \frac{|S|}{|S_i|} - k + \text{tr} (S^{-1} S_i) \right\} \\
&= \frac{1}{2} \sum N_i \log \frac{|S|}{|S_i|} - \frac{1}{2} k \sum N_i + \frac{1}{2} \text{tr} S^{-1} \sum N_i S_i \\
&= \frac{1}{2} \sum N_i \log \frac{|S|}{|S_i|} - \frac{k}{2} N + \frac{1}{2} \text{tr} S^{-1} N S \\
&= \frac{1}{2} \sum N_i \log \frac{|S|}{|S_i|} - \frac{k}{2} N + \frac{1}{2} N k \\
&= \frac{1}{2} \sum N_i \log \frac{|S|}{|S_i|} \quad (\text{証終})
\end{aligned}$$

## 系 4, 1

定理 4 の  $I^*$  に対する  $J^*$  の Min. の値は

$$\begin{aligned}
(39) \quad \hat{J} &= J^*(\hat{\mu}_1, \dots, \hat{\mu}_r, \hat{\sigma}) \\
&= \sum_{i>j} \frac{N_i N_j}{2N} (\text{tr} S_i S_j^{-1} + \text{tr} S_j S_i^{-1} - 2k)
\end{aligned}$$

## 証明

$$\begin{aligned}
\hat{J} &= \sum \frac{N_i}{2} (\text{tr} S_i S^{-1} + \text{tr} S S_i^{-1}) - kN \\
&= \text{tr} \left( \sum \frac{N_i}{2} S_i \right) S^{-1} + \sum \frac{N_i}{2} \text{tr} S S_i^{-1} - kN \\
&= \text{tr} \left[ \frac{1}{2} (NS) S^{-1} \right] + \sum \frac{N_i}{2} \text{tr} S S_i^{-1} - kN \\
&= \sum \frac{N_i}{2} \text{tr} S S_i^{-1} - \frac{k}{2} N \\
&= \sum \frac{N_i}{2} \text{tr} \left( \sum \frac{1}{N} N_j S_j \right) S_i^{-1} - \frac{k}{2} N \\
&= \frac{1}{2N} \sum_{i>j} N_i N_j (\text{tr} S_j S_i^{-1}) - \frac{k}{2} N \\
&= \sum_{i>j} \frac{N_i N_j}{2N} \left\{ \text{tr} S_j S_i^{-1} + \text{tr} S_i S_j^{-1} - 2k \right\} \quad (\text{終})
\end{aligned}$$

この定理を用いてつぎに  $\pi_1, \pi_2$  二つの正規母集団の判別函数を求めて見よう。

定理 5  $\pi_1, \pi_2$  の判別函数  $y = \alpha' x = \sum_{i=1}^k \alpha_i x_i$  は  $S_1, S_2$  を夫々  $\pi_1, \pi_2$  からの  $N_1, N_2$  個 sample の unbiased variance and covariance としたとき  $S_1 \alpha = \lambda S_2 \alpha$  を満足する  $\alpha$  である。ただし  $\lambda$  は  $\det |S_1 - \lambda S_2| = 0$  の最大根又は最小根である。

## 証明

(24)

定理4において  $r=2$  の場合を考えると

$$(40) \quad \hat{J} = \frac{M_1 M_2}{2N} (tr S_1 S_2^{-1} + tr S_2 S_1^{-1} - 2k)$$

ここでは  $y$  についての  $\hat{J}$  即ち  $\hat{J}(y)$  を考えるわけである。  $y$  は正規分布をするから  $E_1(y) = \alpha E_1(x)$ ,  $E_2(y) = \alpha E_2(x)$ ,  $\sigma_1^2(y) = \alpha' \sigma_1 \alpha$ ,  $\sigma_2^2(y) = \alpha' \sigma_2 \alpha$  又  $\hat{\sigma}_1 = S_1$ ,  $\hat{\sigma}_2 = S_2$  を用い, 一次元のことに注意すれば

$$(41) \quad \hat{J}'(y) = \frac{M_1 M_2}{2N} \left( \frac{\alpha' S_1 \alpha}{\alpha' S_2 \alpha} + \frac{\alpha' S_2 \alpha}{\alpha' S_1 \alpha} - 2 \right)$$

を得る。これを最大ならしむるには  $S_1 \alpha = \lambda S_2 \alpha$  なる  $\alpha$  をとれば良い。

そこで  $|S_1 - \lambda S_2| = 0$  の決定方程式の根を求めるとよい。それを  $\lambda_1, \dots, \lambda_k$  その一つを  $\lambda_i$  とすれば

$$\hat{J}'(y, \lambda_i) = \frac{M_1 M_2}{2N} \left( \lambda_i + \frac{1}{\lambda_i} - 2 \right)$$

よって, もし  $\lambda_1 \lambda_k < 1$  なら  $\lambda_i = \lambda_1$  をとればよいし,  $\lambda_1 \lambda_k > 1$  なら  $\lambda_i = \lambda_k$  即ち最小根をとればよい。 (証終)

系 5. 1 判別函数に求めるときに出た  $\hat{J}, \hat{J}'(y, \lambda_i)$  について

$$(42) \quad \hat{J} = \sum_{i=1}^k \hat{J}'(y, \lambda_i)$$

証明  $tr S_1 S_2^{-1} = \sum_{i=1}^k \lambda_i, \quad tr S_2 S_1^{-1} = \sum_{i=1}^k \frac{1}{\lambda_i}$

なることを注意すればよい。

§ 4. 次に線型回帰の問題を扱って見よう。

#### 補題 4

$$(43) \quad Z_{(i)} = Y_{(i)} - B X_{(i)} \quad i = 1, \dots, n$$

ここで  $Z_{(i)}$  は  $k_2$  変数正規分布 (平均 = 0, covariance matrix は皆  $\sigma$ ) とする。

$$\left. \begin{aligned} X'_{(i)} &= (x_{1i}, \dots, x_{k_1 i}) \\ Y'_{(i)} &= (y_{1i}, \dots, y_{k_2 i}) \end{aligned} \right\} \quad k_1 \geq k_2, \quad B = (b_{rs}) \quad \begin{cases} 1 \leq r \leq k_2 \\ 1 \leq s \leq k_1 \end{cases}$$

更に  $X' = (X_{(1)}, \dots, X_{(n)})$

$Y' = (Y_{(1)}, \dots, Y_{(n)})$  .

$\Rightarrow B$  の unbiased estimate  $\hat{B}$  は

$$(44) \quad \hat{B} = (Y'X)(X'X)^{-1}, \text{ 又 } \sigma \text{ の estimate } \hat{\sigma} \text{ は } (n-k_1)\hat{\sigma}^2 = (Y'Y) - (Y'X)(X'X)^{-1}(X'Y)$$

証明 以下 Matrix の行数, 列数を明らかにするために  $p$  行  $q$  列の matrix  $A$  を  $A(p, q)$  で表わす.

$$Z(n, k_2) = Y(n, k_2) - X(n, k_1)B'(k_1, k_2) \text{ から}$$

$$B(k_2, k_1)X'(k_1, n) = Y'(k_2, n) - Z'(k_2, n) \quad \text{両辺に } X(n, k_1) \text{ を乗ずる}$$

$$\hat{B}(k_2, k_1)X'(k_1, n)X(n, k_1) = [Y'(k_2, n) - Z'(k_2, n)]X(n, k_1)$$

$X'X$  は  $(k_1, k_1)$  だから inverse 存在するから

$$B(k_2, k_1) = Y'(k_2, n)X(n, k_1)(X'X)^{-1} - Z'(k_2, n)X(n, k_1)(X'X)^{-1}$$

$B$  の unbiased estimate は  $E(Z) = 0$  だから

$$\hat{B}(k_2, k_1) = Y'(k_2, n)X(n, k_1)(X'X)^{-1}$$

$$\text{即ち } \hat{B} = (Y'X)(X'X)^{-1}$$

次に  $\sigma$  については

$$(n-k_1)\hat{\sigma}^2 = Z'Z \text{ より 今の } \hat{B} \text{ を代入すれば}$$

$$= Y'Y - (Y'X)(X'X)^{-1}(X'Y) \quad (\text{終})$$

### 定理 6

$Z_{(i)} = Y_{(i)} - BX_{(i)}$  において

$$(45) \quad \begin{cases} H_1: E(Y_{(i)}) = BX_{(i)} & i=1, \dots, n \\ H_2: E(Y_{(i)}) = 0 & i, e \quad B=0 \end{cases}$$

$$\Rightarrow J(1, 2) = 2I(1, 2)$$

$$(46) \quad = (n-k_1) \left( \frac{r_1^2}{1-r_1^2} + \dots + \frac{r_{k_2}^2}{1-r_{k_2}^2} \right)$$

ただし  $r_1, \dots, r_{k_2}$  は canonical correlation coefficient とする.

### 証明

$$J(1, 2) = \delta' \sigma^{-1} \delta \quad (\sigma \text{ は共通だから})$$

$$= (X'_{(1)} B', \dots, X'_{(n)} B') \begin{pmatrix} \sigma^{-1} & & \\ & \ddots & \\ & & \sigma^{-1} \end{pmatrix} \begin{pmatrix} BX_{(1)} \\ \vdots \\ BX_{(n)} \end{pmatrix}$$

$$= \sum X'_{(i)} B' \sigma^{-1} BX_{(i)}$$

ここで  $X'_{(i)} B'$  は  $(1, k_2)$  型の matrix

$\sigma^{-1} BX_{(i)}$  は  $(k_2, 1)$  型の matrix

(26)

よって  $Q(1, k_2) P(k_2, 1) = \text{tr } PQ$  の事実により上は  $\Sigma$  の中は  $\text{tr } \sigma^{-1} B X_{(i)} \cdot X'_{(i)} B'$  にひとし

故に 上式は

$$\begin{aligned}
&= \Sigma \text{tr } \sigma^{-1} B X_{(i)} \cdot X'_{(i)} B' \\
&= \text{tr } \sigma^{-1} \Sigma B X_{(i)} X'_{(i)} B' \\
&= \text{tr } \sigma^{-1} B (\Sigma X_{(i)} X'_{(i)}) B' \\
&= \text{tr } \sigma^{-1} B X' X B'
\end{aligned}$$

こゝで  $\sigma, B$  の上の lemma の estimate を代入し

$$\begin{aligned}
\hat{J}(1, 2) &= \text{tr } \hat{\sigma}^{-1} \hat{B} X X' \hat{B}' \text{ を計算すると} \\
&= (n - k_1) \text{tr } [Y Y' - (Y' X)(X' X)^{-1}(X' Y)]^{-1} \\
&\quad X(Y' X)(X' X)^{-1}(X' Y)
\end{aligned}$$

こゝで  $X' X, X' Y, Y' X, Y' Y$  を夫々  $n S_{11}, n S_{12}, n S_{21}, n S_{22}$  で表わすと

$$\hat{J}(1, 2) = (n - k_1) \text{tr } S_{22,1}^{-1} S_{21} S_{11}^{-1} S_{12}$$

こゝで  $S_{22,1} = S_{22} - S_{21} S_{11}^{-1} S_{12}$  とす.

$\det |l S_{22,1} - S_{21} S_{11}^{-1} S_{12}| = 0$  の根を  $l_1, l_2, \dots, l_{k_2}$  とすれば

$$(47) \quad \hat{J}(1, 2) = (n - k_1) (l_1 + l_2 + \dots + l_{k_2})$$

$\det |r^2 S_{22} - S_{21} S_{11}^{-1} S_{12}| = 0$  の根  $r$  と前の根  $l$  の関係は  $l = \frac{r^2}{1-r^2}$  ゆえに

$$\hat{J}(1, 2) = (n - k_1) \left( \frac{r_1^2}{1-r_1^2} + \dots + \frac{r_{k_2}^2}{1-r_{k_2}^2} \right)$$

よって  $\hat{J}(1, 2)$  が canonical correlation coefficient を用いて表わされた.

(証終)

系 6. 1 定理 6 の場合の判別函数  $\alpha_1 Y_{i1} + \alpha_2 Y_{i2} + \dots + \alpha_{k_2} Y_{i k_2}$  は

$$(48) \quad \det |B X' X B - l \sigma| = 0 \text{ の根に対応するものである.}$$

証明 は前の定理 5 のときと同様である.

**結び** information の考えで実験計画法, 線型計画法にも応用する理論が作れると思われる.

○

註 1. S. Kullback は定理 4 に相当するところにおいて

$$I(1, 2) = \Sigma \frac{N_i}{2} \left( \log \frac{|\sigma_i|}{|\sigma_i|} + \text{tr } \sigma_i \sigma_i^{-1} \right) - \frac{k}{2} N$$

と出しているが  $\sigma_i = \sigma$  を入れると  $I(1, 2) = 0$  になるから不十分と思う。

$$\hat{\sigma}_i = S_i, \hat{\sigma} = S \text{ を代入して } \hat{I}(1, 2) = \sum \frac{N_i}{2} \left( \log \frac{|S_i|}{|S_i|} + \text{tr } S_i S^{-1} \right) - \frac{k}{2} N \\ = \sum \frac{N_i}{2} \log \frac{|S_i|}{|S_i|} \text{ と出している。}$$

## 註 2

定理 3 の  $2\hat{I}$  は *asymptotically* に  $\chi^2$  分布自由度  $(r-1)k$  とし

定理 4 の  $2\hat{I}$  は  $(r-1)k(k+1)/2$  の自由度の  $\chi^2$  分布をする

定理 5 の  $\hat{J}$  については  $\chi^2$  分布の予想がたてられている

定理 6 の  $\hat{J}$  については  $k_1, k_2$  の自由度の  $\chi^2$  分布をする

ことが S. Kullback の論文 1956 年の最後の章に出ている。

---

## 参 考 文 献

- [1] H. Chernoff, "A measure of asymptotic efficiency for tests of a hypothesis based on the sum of observations." *AMS*, 23 (1952).
  - [2] " " "Large sample theory: Parametric case" *AMS*, 27 (1956).
  - [3] R. A. Fisher "Contributions to Mathematical Statistics" 1950.
  - [4] H. Hotelling, "A generalized T test and measure of multivariate dispersion." Second Berkeley Symposium, Univ. of California Press 1951, pp. 23-41.
  - [5] S. Kullback, "An application of information theory of multivariate analysis." *A.M.S.*, 25 (1954).
  - [6] " " "Certain inequalities in information theory and the Cramér-Rao inequality." *A.M.S.*, 25 (1954).
  - [7] " " "An application of information theory to multivariate analysis II." *A.M.S.*, 27 (1956).
  - [8] S. Kullback and R. A. Leibler, "On information and sufficiency." *A.M.S.*, 22 (1951).
  - [9] S. S. Wilks, "Mathematical Statistics." 1943.
-