

①7 I. Amount of Information

について

渡 辺 壽 夫

I. まへがき

電気通信工学に関する統計的研究に於て, Shannon, Wiener が R. A. Fisher の導入した *amount of information* のある意味での拡張となる量を定義した。

Shannon-Wiener の *amount of information* とは, x_1, \dots, x_n を n 個の観測値, $f(x_1, \dots, x_n)$ をその確率分布密度函数とするとき

$$(1.1) \quad - \int \dots \int \log f(x_1, \dots, x_n; \theta_1^0, \dots, \theta_m^0) \cdot f(x_1, \dots, x_n; \theta_1^0, \dots, \theta_m^0) dx_1 \dots dx_n$$

により定義する。茲に $\theta_1^0, \dots, \theta_m^0$ は補助変数である。

然し, これは, 推定, 検定に関係のない量である。

そこで, Bartlett は新しく *information function*

$$(1.2) \quad - \int \dots \int \log f(x_1, \dots, x_n; \theta_1, \dots, \theta_m) \cdot f(x_1, \dots, x_n; \theta_1^0, \dots, \theta_m^0) dx_1 \dots dx_n$$

を導入した。 $\theta_1^0, \dots, \theta_m^0$ は $\theta_1, \dots, \theta_m$ と異なる量である。

(1.2) を用ひると R. A. Fisher の定義した *amount of information* と類似な性質をもつ。様方量を定義する事が可能である。即ち, 検定規準として用ひ、

$$(1.3) \quad \frac{f(x_1, \dots, x_n; \theta_1^0, \dots, \theta_m^0)}{f(x_1, \dots, x_n; \theta_1, \dots, \theta_m)}$$

を考へる。

勿論同様である。から対数をとる

ことにする。 $\theta_i = \theta_i^0$ ($i = 1, 2, \dots, m$) なる仮定の下での数学的期待値

$$(1.4) \quad I_f(\theta; \theta^0) = \int \dots \int \log \frac{f(x_1, \dots, x_n; \theta_1^0, \dots, \theta_m^0)}{f(x_1, \dots, x_n; \theta_1, \dots, \theta_m)} \cdot f(x_1, \dots, x_n; \theta_1, \dots, \theta_m) dx_1 \dots dx_n$$

を考へる。 $I_f(\theta; \theta^0)$ は、伊藤氏による報知高と全く *analogous* な性質を有つ事わかる。

筆者はそれに従つて Bartlett の精しく述べてない事をきちんとやってみる事にした。

§ 2. $I_f(\theta; \theta^0)$ のいろいろな性質

定理 1 $I_f(\theta; \theta^0) \geq 0$

而も等号の成立するのは $\theta = \theta^0$ のときに限る。

証明 $f(x_1, \dots, x_n; \theta_1, \dots, \theta_m) = g(x_1, \dots, x_n)$ とおく。

そのとき

$$\int \dots \int \log \frac{f}{g} \cdot f \cdot dx_1 \dots dx_n$$

$0 \leq d \leq 1$ に対して、 $g_d = (1-d)f + dg$ も又確率分布密度函数である。

$$-\int \dots \int \log \frac{(1-d)f + dg}{f} \cdot f dx_1 \dots dx_n$$

により、新しく $I'_f(\theta; \theta^0)$ を定義する。

Taylor 展開する事により

$$\begin{aligned}
& - \int \dots \int \log \frac{(1-\alpha)f + \alpha g}{f} \cdot f dx_1, \dots, dx_n \\
& = - \int \dots \int \left(0 - \frac{(g-f)}{f} \alpha + \frac{\left(\frac{g-f}{f}\right)^2}{2\left(1 + \frac{(g-f)}{f} \alpha^*\right)^2} \right) f dx_1, \dots, dx_n
\end{aligned}$$

茲に α^* は $0 \leq \alpha^* = \alpha^*(x_1, \dots, x_n) \leq 1$ なる数である。
従つて、特に $\alpha = 1$ のとき、

$$\begin{aligned}
& - \int \dots \int \log \frac{g}{f} \cdot f dx_1, \dots, dx_n = - \int \dots \int 0 dx_1, \dots, dx_n \\
& - 1 + 1 + \int \dots \int \frac{\frac{(g-f)^2}{(f)}}{2\left(1 + \frac{(g-f)}{f} \alpha^{**}\right)^2} f dx_1, \dots, dx_n \\
& = \int \dots \int \frac{\left(\frac{g-f}{f}\right)^2}{2\left(1 + \frac{(g-f)}{f} \alpha^{**}\right)^2} f dx_1, \dots, dx_n \geq 0.
\end{aligned}$$

故に $I_f(\theta; \theta^0) \geq 0$ となる。

Integrand は $f \neq 0$ のとき $g = f$ のとき 0 となり

$\int \dots \int g dx_1, \dots, dx_n = 1$, $\int \dots \int f dx_1, \dots, dx_n = 1$ なる条件により、 $\int \dots \int (g-f) dx_1, \dots, dx_n = 0$ $g \neq f$ なる (x_1, \dots, x_n) の測度が正なるとき矛盾する。故に $g = f$ (測度 0 を除く) が成り立つ。従つて定理を得る。

定理 2 $(x_1, \dots, x_n), (y_1, \dots, y_n)$ が一対一且、補助変数に無関係に対応する時、

$$\begin{aligned}
& \int \dots \int \log \frac{f(x_1, \dots, x_n; \theta_1^0, \dots, \theta_m^0)}{f(x_1, \dots, x_n; \theta_1, \dots, \theta_m)} \cdot f(x_1, \dots, x_n; \theta_1^0, \dots, \theta_m^0) dx_1, \dots, dx_n \\
& = \int \dots \int \log \frac{g(y_1, \dots, y_n; \theta_1^0, \dots, \theta_m^0)}{g(y_1, \dots, y_n; \theta_1, \dots, \theta_m)} \cdot g(y_1, \dots, y_n; \theta_1^0, \dots, \theta_m^0) dy_1, \dots, dy_n
\end{aligned}$$

茲に $g(y_1, \dots, y_n; \theta_1^0, \dots, \theta_m^0)$ は (y_1, \dots, y_n) の分布密度とする。

証明

$$y_N = \varphi_N(x_1, \dots, x_n), \quad (N=1, 2, \dots, n) \text{ と}$$

する。 $\varphi_1, \dots, \varphi_n$ の函数行列式を Φ とする。

そのとき

$$\begin{aligned} g(\varphi_1(x_1, \dots, x_n), \varphi_2(x_1, \dots, x_n), \dots, \varphi_n(x_1, \dots, x_n); \theta_1, \dots, \theta_m) \Phi(x_1, \dots, x_n) \\ = f(x_1, \dots, x_n; \theta_1, \dots, \theta_m) \end{aligned}$$

$$\begin{aligned} \int \dots \int \log \frac{f(x_1, \dots, x_n; \theta_1^0, \dots, \theta_m^0)}{f(x_1, \dots, x_n; \theta_1, \dots, \theta_m)} \cdot f(x_1, \dots, x_n; \theta_1^0, \dots, \theta_m^0) dx_1, \dots, dx_n \\ = \int \dots \int \log \frac{g(\varphi_1(x_1, \dots, x_n), \varphi_2(x_1, \dots, x_n), \dots, \varphi_n(x_1, \dots, x_n)); \theta_1^0, \dots, \theta_m^0)}{g(\varphi_1(x_1, \dots, x_n), \varphi_2(x_1, \dots, x_n), \dots, \varphi_n(x_1, \dots, x_n)); \theta_1, \dots, \theta_m)} \\ \times g(\varphi_1(x_1, \dots, x_n), \dots, \varphi_n(x_1, \dots, x_n); \theta_1^0, \dots, \theta_m^0) \Phi(x_1, \dots, x_n) dx_1, \dots, dx_n \end{aligned}$$

そこで $\Phi(x_1, \dots, x_n)$ は変換の *Jacobian* であるから、

$$\Phi(x_1, \dots, x_n) dx_1, \dots, dx_n = dy_1, \dots, dy_n$$

故に、 $(x_1, \dots, x_n) \rightarrow (y_1, \dots, y_n)$ により

$$\int \dots \int \log \frac{g(y_1, \dots, y_n; \theta_1^0, \dots, \theta_m^0)}{g(y_1, \dots, y_n; \theta_1, \dots, \theta_m)} \cdot g(y_1, \dots, y_n; \theta_1^0, \dots, \theta_m^0) dy_1, \dots, dy_n$$

となる。これより定理をうる。

x_1, \dots, x_ℓ の確率分布密度を $f(\sigma_1, \dots, \sigma_\ell; \theta_1, \dots, \theta_m)$

x_1, \dots, x_k の確率分布密度を $g(\sigma_1, \dots, \sigma_k; \theta_1, \dots, \theta_m)$ とするとするとき

$$h(\sigma_1, \dots, \sigma_\ell; \theta_1, \dots, \theta_m) d\sigma_{k+1}, \dots, d\sigma_\ell = \frac{f(\sigma_1, \dots, \sigma_\ell; \theta_1, \dots, \theta_m)}{g(\sigma_1, \dots, \sigma_k; \theta_1, \dots, \theta_m)} d\sigma_{k+1}, \dots, d\sigma_\ell$$

は $x_k = \sigma_k$ $k = 1, 2, \dots, k$ なる条件の下での x_{k+1}, \dots, x_e の確率分布密度である。

そのとき次の定理が成り立つ。

定理 3.

$$I_f(\theta; \theta^0) = I_g(\theta; \theta^0) + \int \dots \int I_h(\theta; \theta^0) g(\sigma_1, \dots, \sigma_k; \theta_1^0, \dots, \theta_m^0) d\sigma_1, \dots, d\sigma_k \\ \geq I_g(\theta; \theta^0)$$

等号の成り立つのは、 $h(\sigma_1, \dots, \sigma_k; \theta_1, \dots, \theta_m)$ が θ に無関係なるときである。

証明

$m = 1$ のとき証明する。

$$\int \dots \int \log \left(\frac{f(\sigma_1, \dots, \sigma_e; \theta^0)}{f(\sigma_1, \dots, \sigma_e; \theta)} \right) f(\sigma_1, \dots, \sigma_e; \theta^0) d\sigma_1, \dots, d\sigma_e \\ = \int \dots \int \log \frac{g(\sigma_1, \dots, \sigma_k; \theta^0)}{g(\sigma_1, \dots, \sigma_k; \theta)} f(\sigma_1, \dots, \sigma_e; \theta^0) d\sigma_1, \dots, d\sigma_e \\ + \int \dots \int \log \frac{h(\sigma_1, \dots, \sigma_k; \theta^0)}{h(\sigma_1, \dots, \sigma_k; \theta)} f(\sigma_1, \dots, \sigma_k; \theta^0) d\sigma_1, \dots, d\sigma_k \\ = I_g(\theta; \theta^0) + \int \dots \int g(\sigma_1, \dots, \sigma_k; \theta^0) d\sigma_1, \dots, d\sigma_k \int \dots \int \log \left(\frac{h(\sigma_1, \dots, \sigma_k; \theta^0)}{h(\sigma_1, \dots, \sigma_k; \theta)} \right) h(\sigma_1, \dots, \sigma_k; \theta^0) \\ \mathcal{R}+1 \dots d\sigma_e \\ \geq I_g(\theta; \theta^0)$$

となる。

茲に第二項が 0 となるのは、 $h(\sigma_1, \dots, \sigma_k; \theta)$ が θ に無関係なる時に限る事が定理 1 より分る。

従つて定理をうる。定理の意味は報知高と同様である。

定理 4. (x_1, \dots, x_k) と (x_{k+1}, \dots, x_r) とが互に独立な観測値とする時

$$I_f(\theta; \theta^0) = I_g(\theta; \theta^0) + I_h(\theta; \theta^0)$$

が成り立つ。

証明 定理 3 より, 明らかである。

§ 3. 充足統計量

X_1, X_2, \dots, X_n と n 個の確率変数とし, t_1, \dots, t_k をこれより導かれた互に函数関係のない統計量とする。

且つその確率密度を $g(t_1, \dots, t_k; \theta_1, \dots, \theta_m)$ とする。

そのとき次の定理が成り立つ。

定理 1

$$I_g(\theta; \theta^0) \leq I_f(\theta; \theta^0)$$

特に等号の成り立つのは, t_1, t_2, \dots, t_k が定まった場合の x_1, \dots, x_n の分布法則が補助変数 $\theta_1, \dots, \theta_m$ に無関係な事である。

証明 $m=1$ の場合に証明する事にする。

t_1, \dots, t_m に t_{m+1}, \dots, t_n なる変数を補って (t_1, \dots, t_n) と (x_1, \dots, x_n) とが補助変数 $\theta_1, \dots, \theta_m$ に無関係な対応で互一対一ならしめる。そのとき前節の定理 2, 3 により,

$$\begin{aligned} & \int \dots \int \log \frac{f(x_1, \dots, x_n; \theta^0)}{f(x_1, \dots, x_n; \theta)} f(x_1, \dots, x_n; \theta^0) dx_1 \dots dx_n \\ &= \int \dots \int \log \frac{h(t_1, \dots, t_n; \theta^0)}{h(t_1, \dots, t_n; \theta)} h(t_1, \dots, t_n; \theta^0) dt_1 \dots dt_n \end{aligned}$$

$$\geq \int \dots \int \log \frac{g(t_1, \dots, t_m; \theta^0)}{g(t_1, \dots, t_m; \theta)} \cdot g(t_1, \dots, t_m; \theta^0) dt_1 \dots dt_m$$

茲で t_1, \dots, t_m の確率分布密度函数を $h(t_1, \dots, t_m; \theta^0)$ とする。

これで前半を生ずる §2. 定理3により等号の成り立つのは、 t_1, \dots, t_m が定まった場合の t_1, t_2, \dots, t_m の分布法則が $\theta_1, \dots, \theta_m$ に無関係な場合であるが、 (t_1, \dots, t_m) と (x_1, \dots, x_n) とが補助変数 $\theta_1, \dots, \theta_m$ に無関係な対応で一対一に対応する事から、 t_1, \dots, t_m が定まった場合に於ける x_1, \dots, x_n の分布法則が補助変数を含まない場合といふ事が出来る。

定理1より

$$0 \leq \frac{I_g(\theta; \theta^0)}{I_f(\theta; \theta^0)} \leq 1$$

が一般に成り立つ事がわかる。

而も、等号の成り立つのは充足統計量系の場合である事が次の定理により保証される。

定理 2. t_1, t_2, \dots, t_m が $\theta_1, \dots, \theta_m$ の充足統計量系である事の必要且つ充分なる條件は、観測値 x_1, \dots, x_n の分布密度を $f(\xi_1, \dots, \xi_n, \theta_1, \dots, \theta_m)$ が $f(x_1, \dots, x_n, \theta_1, \dots, \theta_m) = g(t_1, \dots, t_m, \theta_1, \dots, \theta_m) h(x_1, \dots, x_n)$ なる形になる事である。

従って、 $I_f(\theta; \theta^0) = I_g(\theta; \theta^0)$ が成り立つのは f が上の様な函数形のとときに限る事を示せばよい。

証明. (1) 充分なる事 (t_1, \dots, t_m) に (t_{m+1}, \dots, t_n) なる統計量を補って、 (t_1, \dots, t_m) と (x_1, \dots, x_n) とが補助変数に無関係な対応で一対一に対応する様にする。

そのとき $(t_1, \dots, t_n), (t_1, \dots, t_m)$ の分布密度を夫々 $p(t_1, \dots, t_n; \theta_1, \dots, \theta_m), k(t_1, \dots, t_m; \theta_1, \dots, \theta_m)$ とする。

そこで t_1, \dots, t_m が定まった場合の t_1, \dots, t_n の分布法則が $\theta_1, \dots, \theta_m$ に無関係なる事を証明すればよい。

$$P_{t_1, \dots, t_m}(t_1, \dots, t_n; \theta_1, \dots, \theta_m) = \frac{p(t_1, \dots, t_n; \theta_1, \dots, \theta_m)}{R(t_1, \dots, t_m; \theta_1, \dots, \theta_m)} \quad \text{とする。}$$

又初めに述べた事より

$$f(x_1, \dots, x_n; \theta_1, \dots, \theta_m) = P(t_1, \dots, t_n; \theta_1, \dots, \theta_m) \bar{\Phi}(x_1, \dots, x_n)$$

$$\bar{\Phi}(x_1, \dots, x_n) = \frac{\partial(t_1, \dots, t_n)}{\partial(x_1, \dots, x_n)} \quad \text{で} \quad \bar{\Phi}(x_1, \dots, x_n) \text{ は } \theta_1, \dots, \theta_m$$

に無関係である。

一方, $t_\mu = \varphi_\mu(t_1, \dots, t_m) \quad \mu = 1, 2, \dots, m$ とする。

先の分布密度の形が與えられた様であれば

$$\begin{aligned} g(t_1, \dots, t_m; \theta_1, \dots, \theta_m) d\tau_1, \dots, d\tau_m &= \int \dots \int f(\xi_1, \dots, \xi_n; \theta_1, \dots, \theta_m) d\xi_1, \dots, d\xi_n \\ &\quad \tau_\mu < \varphi_\mu(\xi_1, \dots, \xi_n) < \tau_\mu + d\tau_\mu \\ &\quad \mu = 1, 2, \dots, m \\ &= g(\tau_1, \dots, \tau_m; \theta_1, \dots, \theta_m) \int \dots \int h(\xi_1, \dots, \xi_n) d\xi_1, \dots, d\xi_n \\ &\quad (\tau_\mu < \varphi_\mu(\xi_1, \dots, \xi_n) < \tau_\mu + d\tau_\mu) \\ &\quad \mu = 1, 2, \dots, m \\ &= g(\tau_1, \dots, \tau_m; \theta_1, \dots, \theta_m) S(\tau_1, \dots, \tau_m) d\tau_1, \dots, d\tau_m \end{aligned}$$

故に

$$f(x_1, \dots, x_n; \theta_1, \dots, \theta_m) = h(t_1, \dots, t_m; \theta_1, \dots, \theta_m) \frac{h(x_1, \dots, x_n)}{S(t_1, \dots, t_m)}$$

故に

$$P_{t_1, \dots, t_m}(t_1, \dots, t_n; \theta_1, \dots, \theta_m) = \frac{S(t_1, \dots, t_m)}{h(x_1, \dots, x_n) \bar{\Phi}(x_1, \dots, x_n)}$$

従つて, $\theta_1, \dots, \theta_m$ を含まない事がわかる。

故に,

$$\int \dots \int \log \frac{f(x_1, \dots, x_n; \theta_1^0, \dots, \theta_m^0)}{f(x_1, \dots, x_n; \theta_1, \dots, \theta_m)} f(x_1, \dots, x_n; \theta_1^0, \dots, \theta_m^0) dx_1 \dots dx_n$$

$$= \int \dots \int \log \frac{k(t_1, \dots, t_m; \theta_1^0, \dots, \theta_m^0)}{k(t_1, \dots, t_m; \theta_1, \dots, \theta_m)} k(t_1, \dots, t_m; \theta_1^0, \dots, \theta_m^0) dt_1 \dots dt_m$$

が成り立つ。

(ロ) 次に必要なる事を証明する。

今 t_1, \dots, t_m が充足統計量系とする。 t_1, \dots, t_m に t_{m+1}, \dots, t_n を付け加えて, (x_1, \dots, x_n) と (t_1, \dots, t_n) とが一対一に対応する様にする。 そうすれば, 假定により,

$$I_f(\theta; \theta^0) = I_g(\theta; \theta^0)$$

である。 又 (x_1, \dots, x_n) と (t_1, \dots, t_n) とが一対一の対応をする事より,

$$I_f(\theta; \theta^0) = I_p(\theta; \theta^0)$$

但し, $(t_1, \dots, t_n), (t_1, \dots, t_m)$ の分布密度を夫々, $p(t_1, \dots, t_n; \theta_1, \dots, \theta_m)$ $g(t_1, \dots, t_m; \theta_1, \dots, \theta_m)$ とする。

(x_1, \dots, x_n) と (t_1, \dots, t_n) とが一対一に対応する事より,

$$f(x_1, \dots, x_n; \theta_1, \dots, \theta_m) = p(t_1, \dots, t_n; \theta_1, \dots, \theta_m) \Phi(x_1, \dots, x_n)$$

$$\Phi(x_1, \dots, x_n) = \frac{\partial(t_1, \dots, t_n)}{\partial(x_1, \dots, x_n)}$$

次に $t_1 = \tau_1, \dots, t_m = \tau_m$ といふ条件の下に於ける (t_{m+1}, \dots, t_n) の分布法則は $\theta_1, \dots, \theta_m$ に無関係である。(§3, 定理1)

従って

$$\frac{p(t_1, \dots, t_m; \theta_1, \dots, \theta_m)}{g(\tau_1, \dots, \tau_m; \theta_1, \dots, \theta_m)} = \Phi(\tau_1, \dots, \tau_m)$$

故に

$$\begin{aligned} f(x_1, \dots, x_n; \theta_1, \dots, \theta_m) &= g(t_1, \dots, t_m; \theta_1, \dots, \theta_m) \bar{\Phi}(x_1, \dots, x_n) \bar{\Phi}(t_1, \dots, t_m) \\ &= g(t_1, \dots, t_m; \theta_1, \dots, \theta_m) h(x_1, \dots, x_n) \end{aligned}$$

$$h(x_1, \dots, x_n) = \bar{\Phi}(x_1, \dots, x_n) \bar{\Phi}(t_1, \dots, t_m), \quad \text{証明終り}$$

以上の事より $I_f(\theta; \theta^0)$ を maximum にするものは充足統計量系に限る事の証明されしわけである。

II. 尤度比函数の積率母函数について.

- 1). 分布函数の集まり $\{F\} = \Omega$ に対して、次の様な假設をもうける。 Ω の各要素は測度 m に関して絶対連続であるとする。 即ち

$$F(E) = \int_E f(x) dm$$

と表はされんとする。

假設 H_0 の下で Ω の一つの分布函数 F_0 を假設 H_1 の下で Ω の一つの分布函数 F_1 をとるものとする。

このとき、尤度比函数は $\frac{f_0(x)}{f_1(x)}$ により表はされる。

対数をとって、 $\log \frac{f_0(x)}{f_1(x)}$ を考える。 その假設 H_0, H_1 の下での積率母函数を夫々 $M_0(t), M_1(t)$ で表はす。 即ち、

$$M_0(t) = \int \left(\frac{f_0(x)}{f_1(x)} \right)^t f_0(x) dm$$

$$M_1(t) = \int \left(\frac{f_0(x)}{f_1(x)} \right)^t f_1(x) dm$$

である。 上の式より、 $M_0(t) = M_1(t-1)$ が成り立つ事がわかる。

$M_1(t)$ に関して次の定理が成り立つ。

定理 1

$m\{x | f_0(x) \neq f_1(x)\} > 0$ なるとき $M_1(t)$ は $0 < t < 1$ なるすべての t に対して存在し、而も、 $M_1(t^*) < M_1(t)$ で $0 < t^* < 1$ なる t^* が一つ定まる。

証明 i). Minkowski の定理により、

$$M_1(t) = \int f_0(x)^t (f_1(x))^{1-t} dm \leq \left(\int f_0(x)^t \right)^{\frac{1}{t}} \left(\int f_1(x)^{1-t} \right)^{\frac{1}{1-t}} = 1$$

$$ii) \quad M_1(s) = \int f_0(x)^s f_1(x)^{1-s} dm \quad \text{とする。}$$

$$M_1\left(\frac{s+t}{2}\right) \leq (M_1(s)M_1(t))^{\frac{1}{2}}$$

が Schwarz の不等式を用ひて証明される。

$$M_1(s), M_1(t) \text{ は非負の函数であるから } (M_1(s)M_1(t))^{\frac{1}{2}} \leq \frac{M_1(s)+M_1(t)}{2}$$

が成り立つ。従つて、 $M_1\left(\frac{s+t}{2}\right) \leq \frac{M_1(s)+M_1(t)}{2}$ が $0 < s, t < 1$

の任意の s, t に対して成り立つ。故に、 $M_1(s)$ は $0 \leq t \leq 1$ で下に凸の函数であることがわかる。

而も $M_1(t)$ は連続な函数なる事がわかるから $M_1(t^*) < M_1(t)$ なる $0 < t^* < 1$ が存在する。

$f_0(x) = f_1(x)$ a. e. なるとき、 $M_1(t) = 1$ である。

$$\text{ここで } \inf M_1(t) = \inf \int f_0(x)^t (f_1(x))^{1-t} dm = M_1(t^*) = \rho(F_0, F_1)$$

と定義すると上の定理により $m\{x | f_0(x) \neq f_1(x)\} > 0$ のとき

$\rho < 1$ が成り立ち $\rho = 1$ が成り立つのは

$$m\{x | f_0(x) = f_1(x)\} = 1$$

のときである。この $\rho(F_0, F_1)$ は仮設の間のある意味での割合になつてゐる。これは、Herman Chernoff (1) による尤度比検定の index と呼ばれるものである。この ρ は松下嘉米男氏の affinity と類似な量である。従つて、全く同様にして次の定理

が成り立つ。

定理 2

ρ を上に定義した数とする。 ε を任意の正数とすると、適当に $\rho^k(\varepsilon)$ をとり、 $\rho^k < \varepsilon$ ならしめる。

今

$$E_0 = \{ (x_1, x_2, \dots, x_R) \mid f_0(x_1) \dots f_0(x_R) \geq f_1(x_1) \dots f_1(x_R) \}$$

を R 次元ユークリッド空間上の点集合とする。

$E_1 = E_0^c$ とする。 そのとき、

$$F_0^{(R)}(E_1) > 1 - \varepsilon, \quad F_1^{(R)}(E_2) > 1 - \varepsilon$$

が成り立つ。 茲で $F_0^{(R)}, F_1^{(R)}$ は夫々 F_0, F_1 の R 次元上の分布関数である。

証明

$$\begin{aligned} F_0^{(R)}(E_0) &= \int_{E_0} f_0(x_1) \dots f_0(x_R) dm \dots dm = 1 - \int_{E_1} f_0(x_1) \dots f_0(x_R) dm \dots dm \\ &\geq 1 - \int_{E_1} (f_0(x_1) \dots f_0(x_R))^{t^*} (f_1(x_1) \dots f_1(x_R))^{1-t^*} dm \dots dm \\ &= 1 - \left(\int_{E_1} f_0(x)^{t^*} f_1(x)^{1-t^*} dm \right)^R \\ &= 1 - \rho^R > 1 - \varepsilon \end{aligned}$$

$F_1^{(R)}(E_1) > 1 - \varepsilon$ についても全く同様にして証明される。

上の定理により、標本 (x_1, \dots, x_R) が E_0 にあるとき、 F_0 、 E_1 にあるとき F_1 をとる事にすれば、 (x_1, \dots, x_R) が F_0 からの標本でないとき F_1 であるとする 過誤、 F_1 の標本であるとき、 F_0 であるとする過誤を夫々 ε より小さくしうる事が示される。
(参照 Kameo Matsusita(3))

2) (2) によれば $t = \frac{1}{2}$ としてあるけれども、実は $t = \frac{1}{2}$ とする事が此の様な立場からでも実際に非常によい事が多くの場合に示される。

例 1. 母分散が等しく、平均のみ異なる正規分布の場合、

$$f_0(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x-m_0)^2}, \quad f_2(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x-m_1)^2}$$

とするとき、

$$\rho(F_0, F_1) = \inf_{0 < t < 1} \int_{-\infty}^{\infty} \left(\frac{1}{\sqrt{2\pi}\sigma} \right) e^{-\frac{1}{2\sigma^2}t(x-m_0)^2 - \frac{1}{2\sigma^2}(x-m_1)^2(1-t)} dx = e^{-\frac{1}{8\sigma^2}(m_0-m_1)^2}$$

となり $t = \frac{1}{2}$ とする時と一致する。

例 2. 補助変数の異なるポアソン分布の場合。

$$f_0(x) = \frac{\eta_0^x}{x!} e^{-\eta_0}, \quad f_1(x) = \frac{\eta_1^x}{x!} e^{-\eta_1} \quad (x=0, 1, 2, \dots)$$

とするとき、

$$\begin{aligned} \rho(F_0, F_1) &= \inf_{0 < t < 1} \sum_{x=0}^{\infty} \frac{\eta_0^{xt} e^{-\eta_0 t} \eta_1^{x(1-t)} e^{-\eta_1(1-t)}}{x!} \\ &= \inf_{0 < t < 1} e^{-\eta_0 t - \eta_1(1-t) + \eta_0 t - \eta_1(1-t)} \end{aligned}$$

t の値は次の式を満足する。

$$-\eta_0 + \eta_1 + \eta_0^t \eta_1^{(1-t)} (\log \eta_0 - \log \eta_1) = 0$$

$$\frac{\eta_0}{\eta_1} = \alpha \quad \text{とするとき}$$

$$t = \frac{\log \frac{1-\alpha}{\log \alpha}}{\log \alpha} = \frac{\log \frac{\log \alpha}{1-\alpha}}{\log \frac{1}{\alpha}}$$

$\alpha \rightarrow 0$ のとき $t \rightarrow 1$ $\alpha \rightarrow 1$ のとき $t = \frac{1}{2}$ である。

例へば $\alpha = \frac{1}{2}$ のとき,

$$t = 1 + \frac{\log \log 2}{\log 2} = 1 - \frac{0.159}{0.301} \doteq 0.47$$

となり $\frac{1}{2}$ に非常に近い事がわかる。

例3. 補助変数の一つのみが異なる一般の χ^2 -分布に対して,

$$f_0(x) = \frac{d_0^\lambda}{P(\lambda)} x^{\lambda-1} e^{-d_0 x} \quad f_1(x) = \frac{d_1^\lambda}{P(\lambda)} x^{\lambda-1} e^{-d_1 x}$$

とすると,

$$\begin{aligned} \rho(F_0, F_1) &= \inf_{0 < t < 1} \int_0^\infty \frac{x^{\lambda-1}}{P(\lambda)} e^{-(d_0 t + d_1(1-t))x} \frac{d_0^{\lambda t} d_1^{\lambda(1-t)}}{d_0^{\lambda t} d_1^{\lambda(1-t)}} dx \\ &= \inf_{0 < t < 1} \left(\frac{d_0^t d_1^{(1-t)}}{d_0 t + d_1(1-t)} \right)^\lambda \end{aligned}$$

これを満足するときは poisson-分布の場合と同様である。

あとがき

前半については, kullback heiler(2)参照)更に一般的に論じてある事を知った。けれども一応もとのまゝで出す事にいたしました。此の小文を書くにあたって, 随分御面倒を鍋谷さんにおかけしました。御礼を申し上げます。

参 考 文 献

- (1) M. S. Bartlett. *The Statistical approach to the analysis of Time-series*
- (2) 伊藤 清. 報知高 統計数理研究所 講究録
- (3) C. E. Shannon *The mathematical theory of Communication*
- (4) N. Wiener. *Cybernetics*

後半については

- (1) Herman Chernoff. *A measure of Asymptotic Efficiency for Tests of a Hypothesis Based on the Sum of Observations.* (*Annals of Mathematical Statistics* Vol. 28. No. 4)
- (2) S. Kullback. *An application of Information Theory to Multivariate Analysis*
(*Annals of Mathematical Statistics* Vol. 23. No. 1)
- (3) Kameo Matsushita and Hirotugu Akaike .
Note on the decision problem
(*Annals of Institute of Statistical mathematics*
Vol. IV. No. 1)