

nuisance parameter をとつて最尤推定の
empirical Bayes 的接近.

九大 理 大 限 彰 道

§1. 序.

最尤推定の漸近的性質については種々の結果が得られているが、ここではパラメータの一部について、その先驗分布が仮定される場合の最尤推定量の漸近的正規性を考える。即ち、確率変数 $X_k, k=1, 2, \dots$ が密度関数 $f_k(x|\theta, \alpha)$ をもち、 α の先驗分布が G であるとする。そのときの個々の観測値 x_1, \dots, x_n に基づく θ の最尤推定量 $\hat{\theta}_n$ の漸近正規性について考える。もちろん $\hat{\theta}_n$ は先驗分布 G に depend する。

§3. では、各 α に対し $f_k(x|\theta, \alpha)$ が Hoadley (AMS vol 42) による漸近正規性の為の条件を満足すれば、 G による mixture $f_{G,k}(x|\theta) = \int f_k(x|\theta, \alpha) dG(\alpha)$ がその条件を満足する事を示す。

又、先驗分布 G が unknown である場合には $\hat{\theta}_n$ は実際の推定量ではない (即ち、 $\hat{\theta}_n$ は unknown G を含む)。そこで $\hat{\theta}_n$ にかわる推定量 $\hat{\theta}_n^*$ を提案する。

§4. $f_k(x|\theta, \alpha)$ が平均ベクトル (θ) , 分散共分散行列が $\begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}$ である二次元正規分布の場合に $\hat{\theta}_n$ が $\tilde{\theta}_n$ と漸近的に同じ分布に従う事を示す。

§2. 記号と仮定.

X_1, X_2, \dots は独立な確率変数の列とし, X_k の密度関数 $f_k(x|\theta, \alpha)$ とする。ここに $\theta \in \Theta \subset R^p$, $\alpha \in \mathcal{A} \subset R^s$ であり, α の先験分布 G とする。又 θ の真の値 θ_0 とし, 次の量 \dot{L}_k を定義する。

$$L_k(x, \theta, \alpha) = \log f_k(x|\theta, \alpha), \quad M_k(x, \theta) = \log f_{G, k}(x|\theta)$$

$$\dot{L}_k^{(i)}(x, \theta, \alpha) = \frac{\partial}{\partial \theta_i} L_k(x, \theta, \alpha), \quad \dot{M}_k^{(i)}(x, \theta) = \frac{\partial}{\partial \theta_i} M_k(x, \theta)$$

$$\dot{L}_k(x, \theta, \alpha) = (\dot{L}_k^{(1)}(x, \theta, \alpha), \dots, \dot{L}_k^{(p)}(x, \theta, \alpha))^t, \quad \dot{M}_k = (\dot{M}_k^{(1)}, \dots, \dot{M}_k^{(p)})^t$$

$$\ddot{L}_k^{(i,j)}(x, \theta, \alpha) = \frac{\partial^2}{\partial \theta_i \partial \theta_j} L_k(x, \theta, \alpha), \quad \ddot{M}_k^{(i,j)} = \frac{\partial^2}{\partial \theta_i \partial \theta_j} M_k(x, \theta)$$

$$\ddot{L}_k(x, \theta, \alpha) = (\ddot{L}_k^{(i,j)}(x, \theta, \alpha)), \quad \ddot{M}_k(x, \theta) = (\ddot{M}_k^{(i,j)}(x, \theta))$$

$$\Gamma_k(\theta, \alpha) = E[\dot{L}_k(X_k, \theta, \alpha) \dot{L}_k(X_k, \theta, \alpha)^t | \alpha]$$

上のよりの記号の下に, 次の仮定を置く。

- (1) 正数 K と δ が存在し, $E[|X_k|^{1+\delta} | \alpha] \leq K$, $k=1, 2, \dots$, a.s. α
- (2) Θ は R^p の開集合である。
- (3) $\tilde{\theta}_n \rightarrow \theta_0$ in prob.
- (4) a.s. (X_k, α) に対し, \dot{L}_k, \ddot{L}_k が存在し, 有界である。
- (5) a.s. (X_k, α) に対し, \ddot{L}_k は k について一様に θ の連続関数である。

$$(6) \quad E[\dot{L}_k(X_k, \theta, \alpha) | \alpha] = 0 \quad \text{a.s. } \alpha.$$

$$(7) \quad T_k(\theta, \alpha) = -E[\ddot{L}_k(X_k, \theta, \alpha) | \alpha] \quad \text{a.s. } \alpha$$

$$(8) \quad \frac{1}{n} \sum_{k=1}^m T_k(\theta, \alpha) \longrightarrow \bar{T}(\theta, \alpha) \quad \text{a.s. } \alpha$$

こゝに、 $E[\bar{T}(\theta, \alpha)] = \bar{T}(\theta)$ は正定値。

(9) 任意の $\xi \in R^p$ に対し

$$n^{-\frac{2+\delta}{2}} \sum_{k=1}^m E[|\xi^t \dot{L}_k(X_k, \theta_0, \alpha)|^{2+\delta} | \alpha] \longrightarrow 0, \quad \text{a.s. } \alpha$$

(10) 正数 ε と確率変数 $Z_{k,i,j} = Z_{k,i,j}(X_k, \alpha)$ が存在し、

$$(i) \quad \sup\{|\ddot{L}_k^{(i,j)}(X_k, t, \alpha)|; \|t - \theta_0\| \leq \varepsilon\} \leq Z_{k,i,j}$$

$$(ii) \quad E[|Z_{k,i,j}| | \alpha] \leq K$$

が a.s. α で成立。

これらの仮定は Hoadley の漸近正規性の仮定 E a.s. α で書きかえらるのである。

§. 3. $\tilde{\theta}_n$ の漸近的正規性.

上に述べた仮定が $f_{G,k}$ により満足される事 ε 示せば $\tilde{\theta}_n$ の漸近正規性は云える。

$E[|X_k|^{1+\delta}] = E[E[|X_k|^{1+\delta} | \alpha]]$ であるから (1) より 1 番目の条件 $E[|X_k|^{1+\delta}] \leq K$ なる定数の存在性は云える。(2), (3) は同じ。

(4) については次の Lemma を示す。

Lemma 1. $\dot{L}_k(X_k, \theta, \alpha)$, $\ddot{L}_k(X_k, \theta, \alpha)$ が存在し且つ有界 a.s. (X_k, α) , であるならば $\dot{M}_k(X_k, \theta)$, $\ddot{M}_k(X_k, \theta)$ も存

存在し、且つ有界 a. s. x_h である。

証明

$$(*) \quad \dot{M}_h^{(j)}(x, \theta) = E[\dot{L}_h^{(j)}(x, \theta, \alpha) | x]$$

であるから $\dot{M}_h(x, \theta)$ は存在して有界。更に、

$$\begin{aligned} \dot{M}_h^{(i,j)}(x, \theta) &= \frac{\partial}{\partial \theta_j} [\dot{M}_h^{(j)}(x, \theta)] \\ &= \int \frac{\dot{L}_h^{(i,j)}(x, \theta, \alpha) f_h(x|\theta, \alpha)}{f_{G,h}(x|\theta)} dG(\alpha) + \int \frac{\dot{L}_h^{(j)}(x, \theta, \alpha) \dot{f}_h^{(j)}(x|\theta, \alpha)}{f_{G,h}(x|\theta)} dG(\alpha) \\ &\quad - \int \frac{\dot{L}_h^{(j)}(x, \theta, \alpha) f_h(x|\theta, \alpha) \dot{f}_{G,h}^{(j)}(x|\theta)}{f_{G,h}(x|\theta)^2} dG(\alpha) \end{aligned}$$

$$(b) \quad \therefore \dot{M}_h^{(i,j)}(x, \theta) = E[\ddot{L}_h^{(i,j)}(x, \theta, \alpha) | x] + E[\dot{L}_h^{(j)}(x, \theta, \alpha) \dot{L}_h^{(i)}(x, \theta, \alpha) | x] \\ - E[\dot{L}_h^{(j)}(x, \theta, \alpha) | x] \cdot E[\dot{L}_h^{(i)}(x, \theta, \alpha) | x]$$

従って \dot{M}_h は存在し且つ有界となる。

更に、(b) を用いて (5) より \dot{M}_h は h について一様に θ の連続関数となる。(b) より明らかに $E[\dot{M}_h^{(j)}(x, \theta)] = 0$ となる。

Lemma 2. (7) を仮定すれば

$$T_{G,h}(\theta) \equiv E[\dot{M}_h(x, \theta) \cdot \dot{M}_h(x, \theta)^t] = -E[\ddot{M}_h(x, \theta)]$$

証明. (7) より

$$\begin{aligned} E[\dot{L}_h^{(i,j)}(x, \theta, \alpha)] &= E[E\{\dot{L}_h^{(i,j)}(x, \theta, \alpha) | \alpha\}] \\ &= E[-E\{\dot{L}_h^{(j)}(x, \theta, \alpha) \dot{L}_h^{(i)}(x, \theta, \alpha) | \alpha\}] \\ &= -E[\dot{L}_h^{(j)}(x, \theta, \alpha) \dot{L}_h^{(i)}(x, \theta, \alpha)] \end{aligned}$$

更に、(*) より

$$E[\dot{M}_h^{(j)}(x, \theta) \cdot \dot{M}_h^{(i)}(x, \theta)] = E[E\{\dot{L}_h^{(j)}(x, \theta, \alpha) | x\} \cdot E\{\dot{L}_h^{(i)}(x, \theta, \alpha) | x\}]$$

故に (b) を用いると

$$E[\dot{M}_h^{\alpha}(\alpha, \theta) \cdot \dot{M}_h^{\alpha}(\alpha, \theta)] = -E[\ddot{M}_h^{\alpha}(\alpha, \theta)]$$

$$\therefore T_{G,h}(\theta) = -E[\ddot{M}_h(\alpha, \theta)]$$

(8), (9), (10) に代入しては α についての期待値を $\bar{\alpha}$ により得られる。例は, (10) の $Z_{b,i,j}$ としては $E[Z_{b,i,j}(X_h, \alpha) | X_h]$ である。

以上, 簡単に述べたように, $f_{G,h}$ に関する Hoadley の条件が (1) ~ (10) の仮定の下に成り立つので $\hat{\theta}_n$ は漸近的正規分布を有する事がいえる。

ここで $\hat{\theta}_n$ の consistency については (3) で仮定 1 が正規性の場合と同様に, $f_h(x|\theta, \alpha)$ について Hoadley の consistency に関する条件が a.s. α で満足されれば $f_{G,h}(x|\theta)$ についても満足されるので, 次節で述べる unknown G に関する $\hat{\theta}_n \xrightarrow{p} \theta_0$ や $\hat{\theta}_n$ の漸近正規性については $f_h(x|\theta, \alpha)$ の各 α に関する, 与えられた条件が満足されているかどうかを調べればよい。

§. 4. Unknown G の場合.

ここでは 2 次元正規分布でその第 2 変数の期待値が unknown な先験分布 G を持つ場合について考える。即ち,

$$f_j(x, y | \theta, \alpha) = f(x, y | \theta, \alpha) = \frac{1}{2\pi\sqrt{1-\rho^2}} \exp\left\{-\frac{1}{2(1-\rho^2)} [(\alpha-\theta)^2 - 2\rho(\alpha-\theta)(y-\alpha) + (y-\alpha)^2]\right\}$$

$$j = 1, 2, \dots$$

こゝに、 ρ は known, 且 $\mathcal{R} \subset \{\alpha: |\alpha| < M\}$ と仮定する。

そのときは \hat{L}, \hat{M} は次の如し。

$$\hat{L}(x, y, \theta, \alpha) = \frac{1}{1-\rho^2} \{x - \theta - \rho(y - \alpha)\}$$

$$\hat{M}(x, y, \theta) = \frac{1}{1-\rho^2} \{x - \theta - \rho(y - E[\alpha | x, y])\}$$

こゝで $E[\alpha | x, y]$ は G, θ に depend している事に注意。

$(\begin{smallmatrix} x_1 \\ y_1 \end{smallmatrix}), \dots, (\begin{smallmatrix} x_n \\ y_n \end{smallmatrix})$ の同時分布は $\prod_{k=1}^n f_G(x_k, y_k | \theta)$ である, 従つて, α の log likelihood の θ に関する微分は。

$$\begin{aligned} (*) \quad \dot{M}_n(\theta) &\equiv \frac{\partial}{\partial \theta} \left\{ \log \left[\prod_{k=1}^n f_G(x_k, y_k | \theta) \right] \right\} = \sum_{k=1}^n \dot{M}(x_k, y_k, \theta) \\ &= \frac{n}{1-\rho^2} \left\{ \bar{x}_n - \theta - \rho \left(\bar{y}_n - \frac{1}{n} \sum_{k=1}^n E[\alpha | x_k, y_k] \right) \right\} \end{aligned}$$

こゝに、 $\bar{x}_n = \frac{1}{n} \sum_{k=1}^n x_k, \bar{y}_n = \frac{1}{n} \sum_{k=1}^n y_k$.

そこで、 $\dot{M}_n(\theta) = 0$ なる θ の値が θ の最尤推定となるが、 $\dot{M}_n(\theta)$ の中に未知な α の先驗分布 G が含まれているので、もっと正確には $E[\alpha | x_k, y_k]$ が G に depend しているのて、この posterior mean を推定する事を考える。まず

$$\frac{\partial}{\partial y} [\log f_G(x, y | \theta)] = \frac{f'_G(x, y | \theta)}{f_G(x, y | \theta)} = \frac{1}{1-\rho^2} \{ \rho(x - \theta) - y + E[\alpha | x, y] \}$$

従つて

$$E[\alpha | x, y] = (1-\rho^2) \frac{f'_G(x, y | \theta)}{f_G(x, y | \theta)} - \rho(x - \theta) + y$$

これを(*)に代入すると

$$\dot{M}_n(\theta) = n \left\{ \bar{x}_n - \theta + \rho \cdot \frac{1}{n} \sum_{k=1}^n \frac{f'_G(x_k, y_k | \theta)}{f_G(x_k, y_k | \theta)} \right\} .$$

そこで、 f'_G, f_G の $(\begin{smallmatrix} x_1 \\ y_1 \end{smallmatrix}), \dots, (\begin{smallmatrix} x_n \\ y_n \end{smallmatrix})$ に基づく推定量 f'_n, f_n を次の如くに与える。

$$p_j(x, y) = \Delta^{-2} K_0 \left(\frac{X_j - x}{\Delta}, \frac{Y_j - y}{\Delta} \right),$$

$$f_n(x, y) = \frac{1}{n-1} \sum_{j=1}^n p_j(x, y)$$

$$g_j(x, y) = \Delta^{-3} \left\{ \frac{1}{2} K_1 \left(\frac{X_j - x}{\Delta}, \frac{Y_j - y}{2\Delta} \right) - K_1 \left(\frac{X_j - x}{\Delta}, \frac{Y_j - y}{\Delta} \right) \right\}$$

$$f'_n(x, y) = \frac{1}{n-1} \sum_{j=1}^n g_j(x, y)$$

ここに, K_0, K_1 は kernel 関数である,

又 $z = z^T M_n(\theta)$ の f_G, f'_G に f_n, f'_n を入れた式 $\varepsilon = 0$ とおいて得られた $\theta \in \hat{\theta}_n$ とする, 即ち

$$\hat{\theta}_n = \bar{x}_n + \beta \frac{1}{n} \sum_{i=1}^n \frac{f'_n(x_i, y_i)}{f_n(x_i, y_i)}$$

これは $(x_1, y_1), \dots, (x_n, y_n)$ に基づく θ の推定量である. unknown 母函数 ε を含む最尤推定量 $\hat{\theta}_n$ と漸近的に同じ分布に従う事を示

す. 証明の本質的箇所は

$$\frac{f'_n(x_n, y_n)}{f_n(x_n, y_n)} - \frac{f'_G(x_n, y_n | \theta_0)}{f_G(x_n, y_n | \theta_0)} \longrightarrow 0 \quad \text{in } L^2$$

を示す事である.