

## Estimationの問題について

古屋, 茂  
中央航空研究所

<https://hdl.handle.net/2324/12893>

---

出版情報 : 統計数理研究. 1 (2), pp.12-32, 1942-03-15. Research Association of Statistical Sciences

バージョン :

権利関係 :

# Estimation の問題について

會員 古 屋 茂 (中央航研)

(昭和十六年七月十八日受理)

Estimation の問題は統計數學に於ける重要な問題の一つであつて 1920 年以後發達して來た。その理論は主として R.A.Fisher に負ふものである。ここでその大要を紹介しよう。この理論の出発點は次の問題である。

**問題:**  $p$  個のパラメーター  $m_1, m_2, \dots, m_p$  を含む確率密度分布  $f(x; m_1, m_2, \dots, m_p)$  が與へられたとする。この分布に關して  $n (\geq p)$  回の觀測を行つて、 $(x_1, x_2, \dots, x_n)$  なる一組の値——之を size  $n$  の sample といふ——を得たとき、この觀測結果より未知常數  $m_1, \dots, m_p$  を如何に定めるべきか？

$(m_1, \dots, m_p)$  を觀測結果  $(x_1, \dots, x_n)$  の函數として定める方法は種々あり、それ等は各々の立場に於て夫々の意味をもつものであるが、以下に於て確率論的にこの問題が如何に取扱はれるか、又未知常數を如何に定めるのが妥當であるかを説明しよう。

先づ注意すべきことは、 $m_1, \dots, m_p$  は各々一つの値——それが未知であるが——をとるのであつて、種々の値を夫々の確率でとるのではないことである。従つて所謂 a posteriori の確率を與へる Bayes の定理をそのまま使用することは出来ない。

以下 I に於てはパラメーターの値を一ヶの値によつて推定する方法を述べ、II に於ては區間によつてパラメーターの値を推定する方法を述べる。

## I. 一ヶの値による推定法

sample  $(x_1, \dots, x_n)$  に於て各  $x_i$  は、その確率密度分布として  $f(x; m_1, \dots, m_p)$  を有する確率變數 (240頁, 定義 2.1)\* と考へられるが、當分は  $n$  個の確率變數  $x_1, \dots, x_n$  が相互に獨立 (247頁, § 1.2.) であると假定する。更に、特に斷らない限り集合  $(x; f(x; m_1, \dots, m_p) > 0)$  ——之を  $f$  の range といふ——は  $(m_1, \dots, m_p)$  に無關係なものと假定する。

### § 1. Method of Moments, Statistic, Consistent Statistic

上記問題の一つの解法としてよく使用されるものに method of moments がある。それは分布自身の moments と sample moments とを等しいとおいてえられる  $p$  個の等式

$$(1.01) \quad \frac{1}{n} \sum_{i=1}^n x_i^k = \int x^k f(x; m_1, m_2, \dots, m_p) dx \quad (k=1, 2, \dots, p)$$

より  $m_1, m_2, \dots, m_p$  を定める方法である。これは  $n$  が大きければ大きい程正確な方法といふ事が出来よう。その理由は

$$(1.02) \quad E(X^k) = \int x^k f(x; m_1, m_2, \dots, m_p) dx$$

が存在するならば、 $n \rightarrow \infty$  のとき (1.01) の左邊は  $E(X^k)$  に法則收斂、及び概收斂 (法則收斂、概收斂については 244頁, § 4.1 参照) するからである。この方法の長所は計算の實行が容易な點にあ

る。K. Pearson は通常よく現はれる確率密度分布を 7 種の型に分類したが、その際にこの方法を使用した。又最初の問題で「 $p$  ケのパラメーターを含む」といふ代りに「可附番  $q$  ケのパラメーターを含む」といふ事にすれば、estimation の問題といふよりもむしろ curve fitting の問題となるが、その場合にも method of moments が便利である。例へば

$$(1.03) \quad \frac{d^n}{dx^n} \left( \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \right) = \sqrt{n!} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} p_n(x)$$

から定まる多項式  $p_n(x)$  に依つて展開される確率密度分布  $f(x)$  を考へる：

$$(1.04) \quad f(x; a_1, a_2, \dots, a_n, \dots) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} (1 + a_1 p_1(x) + a_2 p_2(x) + \dots + a_n p_n(x) + \dots)$$

然るに

$$(1.05) \quad \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} p_n(x) p_m(x) dx = \delta_{m,n}$$

なる故

$$(1.06) \quad E(p_i(x)) = a_i.$$

従つて sample  $(x_1, x_2, \dots, x_n)$  より  $\sum_{j=1}^n p_i(x_j)/n$  を作ればそれは  $a_i$  に概収斂するのである。

次に  $E(X^k)$  の存在が保證されて居ない場合はどうであらうか。今  $p=1$  として

$$(1.07) \quad \sum_{i=1}^n x_i/n$$

が常數  $a$  に法則収斂する爲の必要且十分な條件を求めよう。以下、(1.07) 即ち sample mean を  $\bar{x}$  で表はすことにする。

$f(x; m)$  の特性函數 (241 頁, § 3.2) を  $\varphi(t, m)$  とおけば、確率變數 (1.06) の分布の特性函數は  $\varphi(\frac{t}{n}, m)$ . (251 頁, 定理 2.5.) 従つて  $\psi(t, m) = \log \varphi(t, m)$  とかけば求める條件は、 $n \rightarrow \infty$  の時  $n\psi(\frac{t}{n}, m) \rightarrow ia$  である。(251 頁, 定理 2.5) 換言すれば  $\psi(t, m)$  が  $t=0$  で微分可能でその微係數が  $ia$  に等しいことである。平均値  $E(x)$  が存在するときは上記  $\psi(t, m)$  は  $t=0$  で微分可能で、その微係數は  $iE(x)$  に等しい。この逆が必ずしも成立しないこと—— $\psi(t)$  の原點に於ける微分可能性から  $E(x)$  の存在は出ないこと——は例へば  $a < 1$  として

$$(1.08) \quad f(x) = \begin{cases} \frac{K}{x^2(\log|x|)^a} & [|x| > 2 \text{ のとき}] \\ 0 & [|x| \leq 2 \text{ のとき}] \end{cases}$$

——但し茲に

$$(1.09) \quad \frac{1}{K} = \int_{|x|>2} \frac{dx}{x^2(\log|x|)^a}$$

とする——により容易に分る。

結局  $\psi(t, m)$  が  $t=0$  で微分不可能の場合には  $\bar{x}$  を作つても何等の効果のない事が分つた。

例として Cauchy の分布

$$(1.10) \quad f(x, m) = \frac{1}{\pi\{1+(x-m)^2\}}$$

をとる。その特性函数は  $e^{-t+im}$  なる故、 $\bar{x}$  の分布の特性函数も亦  $e^{-t+im}$ 。よつて  $\bar{x}$  の分布も亦  $f(x, m)$  となる。それでこの場合  $m$  を推定する爲に sample の平均値をとる事は  $n=2$  としても  $n=100$  としても更に  $n$  が何であつても全く同様に無意味な事である。method of moments は以上の如き缺點を持つてゐる。しかしその他にも種々の方法がある。

**定義 1.** sample  $(x_1, x_2, \dots, x_n)$  の一價可測函数  $T_n(x_1, \dots, x_n)$  が或パラメーターの値  $g(m)$  を推定するものとして使用される時、 $T_n$  を statistic, 又は  $g(m)$  の estimate といふ。 $T_n$  は確率變數であるが  $n \rightarrow \infty$  のとき  $g(m)$  に法則収斂するならば、 $T_n$  を consistent statistic, 又は  $g(m)$  の consistent estimate といふ。statistic  $T_n$  の平均値  $E(T_n)$  が  $g(m)$  ならば、 $T_n$  を  $g(m)$  の unbiased estimate と呼ぶ。

次に二三の例、 $g(m)$ ,  $\sigma(m)$ ,  $s^2$  を次の様に定める。

$$(1.11) \quad g(m) = \int x f(x, m) dx,$$

$$(1.12) \quad \sigma^2(m) = \int (x - g(m))^2 f(x, m) dx,$$

$$(1.13) \quad s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2.$$

**例 1.** (1.11) が存在するときには、 $\bar{x}$  は  $g(m)$  の consistent estimate であり、unbiased estimate である。

**例 2.** (1.12) が存在するとき  $s^2$  は  $\sigma^2(m)$  の consistent estimate である事は明白であるが、unbiased estimate ではない。何者：

$$(1.14) \quad \begin{aligned} E(s^2) &= E\left(\frac{1}{n} \sum_{i=1}^n x_i^2 - \frac{1}{n^2} \left(\sum_{i=1}^n x_i\right)^2\right) = \frac{1}{n} \sum_{i=1}^n E(x_i^2) - \frac{1}{n^2} \sum_{i=1}^n E(x_i^2) - \frac{1}{n^2} \sum_{i \neq j} E(x_i x_j) \\ &= \frac{n-1}{n} E(x^2) - \frac{n-1}{n} E^2(x) = \frac{n-1}{n} (E(x^2) - E^2(x)) = \frac{n-1}{n} \sigma^2(m). \end{aligned}$$

故に  $\sigma^2(m)$  の unbiased estimate は  $ns^2/(n-1)$  である。

**例 3.**  $f(x, m)$  は  $|x-m|$  の函数であつて  $f(m, m) \neq 0$  とする。 $m$  がこの分布の中央値 (242頁, 定義 3.1) であるが、 $f(m, m) \neq 0$  なる故他に中央値はない。このとき sample  $(x_1, x_2, \dots, x_{2s+1})$  の中央値  $\mu$  は  $m$  の consistent estimate である。何者  $\mu$  の密度分布を  $p_{2s+1}$  と記せば

$$(1.15) \quad \begin{cases} p_{2s+1}(x) = \frac{(2s+1)!}{s! s!} \frac{1}{2^{2s}} \left(1 - 4 \left(\int_m^x f(x, m) dx\right)^2\right)^s f(x, m). \\ \lim_{s \rightarrow \infty} p_{2s+1}(x) = \lim_{s \rightarrow \infty} \frac{2s+1}{\sqrt{s} \sqrt{\pi}} \left(1 - 4 \left(\int_m^x f(x, m) dx\right)^2\right)^s f(x, m). \end{cases}$$

従つて  $\lim_{s \rightarrow \infty} p_{2s+1}(m) = \infty$ ,  $x \neq m$  ならば  $\lim_{s \rightarrow \infty} p_{2s+1}(x) = 0$ .

## § 2. Method of Maximum Likelihood

次に問題となるのは確率密度分布  $f(x; m)$  が與へられたとき、consistent statistic は存在するか、もし存在すれば如何にしてそれを見出すかといふことである。この問題に解決を與へるものは次に述べる method of maximum likelihood である。

定義 2.  $p$  個のパラメーター  $m_1, m_2, \dots, m_p$  を含む確率密度分布  $f(x; m_1, \dots, m_p)$  が與へられたとし、それからえられた sample を  $(x_1, x_2, \dots, x_n)$  とする ( $n \geq p$ ) この sample の生ずる確率は  $\prod_{i=1}^n f(x_i; m_1, \dots, m_p)$  であるが、今それを最大ならしめる  $m_i = L_i^{(1)}, 1 \leq i \leq p$  をとつて  $(L_1^{(1)}, \dots, L_p^{(1)})$  を  $(m_1, \dots, m_p)$  の maximum likelihood estimate といふ。パラメーターの値をその maximum likelihood estimate によつて推定する方法を method of maximum likelihood といふ。

例 4. 正規型分布

$$(N) \quad f(x; m, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-m)^2}{2\sigma^2}}$$

に於いて  $(m, \sigma^2)$  の maximum likelihood estimate を  $(L^{(1)}, L^{(2)})$  とすれば

$$(2.01) \quad L^{(1)} = \bar{x}, \quad L^{(2)} = s^2$$

である。何者

$$(2.02) \quad \phi \equiv \log \prod_{i=1}^n f(x_i, m, \sigma) = \sum_{i=1}^n \left( -\frac{(x_i - m)^2}{2\sigma^2} - \log(\sqrt{2\pi}\sigma) \right)$$

とおき

$$(2.03) \quad \frac{\partial \phi}{\partial m} = 0, \quad \frac{\partial \phi}{\partial \sigma} = 0$$

なる  $m, \sigma^2$  を未知数とする聯立方程式を解けば、 $m, \sigma^2$  の解が、夫々  $L^{(1)}, L^{(2)}$  に外ならぬわけであつて、容易に (2.01) が得られる。例 2 で述べた如く、 $\sigma^2$  の unbiased estimate は  $ns^2/(n-1)$  であつた。この様に maximum likelihood estimate は、必ずしも unbiased estimate とは一致しない。

定理 1.

(1°)  $f(x, m)$  は確率 0 の  $x$  集合を除いて  $m$  に関して微分可能。

(2°)  $\int \frac{\partial}{\partial m} f(x, m) dx = 0$ .

(3°)  $u(x, m) \equiv \frac{1}{f} \frac{\partial f}{\partial m}(x, m)$  は、 $x$  に一様、 $m$  について連続。

(4°)  $m$  を未知数とする方程式

$$(2.04) \quad \sum_{i=1}^n u(x_i, m) = 0$$

の根  $m = M(x_1, x_2, \dots, x_n)$  は  $n$  が何であつても常に夫々唯一つ存在する。

この四條件の下に於いて  $M_n(x_1, x_2, \dots, x_n)$  は  $m$  の consistent estimate となる。

證明  $n \rightarrow \infty$  のとき

$$(2.05) \quad \sum_{i=1}^n u(x_i, m)/n$$

は

$$(2.06) \quad \int u(x, m) f(x, m) dx = 0$$

に法則収斂する。しかるに (3°), (4°) に依り  $M_n$  が  $m$  の近傍にあることと (2.05) が 0 の近傍にあ

ることと同値となるから、任意の正数  $\epsilon$  に對して

$$(2.07) \quad \lim_{n \rightarrow \infty} P(|M_n - m| > \epsilon) = 0$$

となる。(Q.E.D.)

パラメーターの値を推定するには consistent statistic をとる必要があるから、これからは consistent statistic のみを考へることにするが、同じパラメーターの値を推定するにしてもその consistent estimate は色々にとり得るので、その中で最も効果的なものをえらびたいのである。

例 5. 例 3 に於ける  $f(x, m)$  の二次の moment の存在を假定する。平均値が  $m$  になる事は次式より分る。

$$\int (x-m) f(x, m) dx = \int (x-m) f(|x-m|) dx = 0.$$

標準偏差を  $\sigma$  と書く。次に sample  $(x_1, x_2, \dots, x_n)$  の平均値  $\bar{x}$  を  $m_n$ , 中央値を  $\mu_n$  とすれば、此等は何れも  $m$  の consistent estimate である。今確率變數  $x$  の標準偏差を  $\sigma(x)$  で表せば、 $\sigma^2(m_n) = \sigma^2(x)/n$ ,  $\sigma^2(\mu_n) = 1/4 n f^2(m, m)$ . (前者は明白, 後者は例 3 より計算すればよい) 確率變數  $\sqrt{n}(m_n - m)$  は  $n \rightarrow \infty$  のとき平均値 0 の Gauss 分布に法則收斂する (256 頁, 定理 1.2) が,  $\sqrt{n}(\mu_n - m)$  も亦同じく  $n \rightarrow \infty$  のとき平均値 0 の Gauss 分布に法則收斂する。(例 3 に於ける  $p_n(x)$  より計算すればよい)

今  $f(x; m)$  として特に平均値  $m$ , 標準偏差  $\sigma$  なる Gauss 分布 ( $N$ ) をとる。このとき  $\sigma^2(m_n)$  と  $\sigma^2(\mu_n)$  とを比較すれば,  $\sigma^2(m_n)/\sigma^2(\mu_n) = 2/\pi$  なる故, size 100 の sample より平均値を使用することと, size  $100 \times \frac{\pi}{2} \approx 157$  の sample より中央値を使用することと同程度の精確さをもつことになり, sample が與へられたとき, 中央値よりも平均値を使用した方が効果的であることが分る。

次に  $f(x; m)$  として平均値が  $m$  の Laplace 分布をとる:  $f(x; m) = e^{-|x-m|/2}$  この場合は  $\sigma^2(m_n)/\sigma^2(\mu_n) = 2$  であるから, size 100 の sample から平均値を使用することと, size 50 の sample から中央値を使用することと同程度の精確さをもつことになり, Gauss 分布の場合と反對に平均値よりも中央値をとるべきである。

この例は statistic  $T_n$  について  $\sqrt{n}(T_n - m)$  を作り, それが Gauss 分布へ法則收斂するとき, その Gauss 分布の標準偏差の平方によつて効果の程度を定めたのであつた。  $f(x; m)$  が與へられたとき, 上の意味で最も効果的なものをえらぶには如何にすればよいかといふ疑問が起るが, それも亦後で述べる様に method of maximum likelihood によつて解決される。

補助定理 確率變數列  $\{X_n\}, \{Y_n\}$  が夫々常數  $a \neq 0$ , 確率變數  $Y$  に法則收斂するならば,  $Y_n/X_n$  は  $Y/a$  に法則收斂する。

證明 次の二式から容易に分る:

$$\begin{aligned} P(Y_n \leq t X_n) &= P(Y_n \leq t X_n, |X_n - a| \leq \epsilon) + P(Y_n \leq t X_n, |X_n - a| > \epsilon) \\ &\leq P(Y_n \leq t(a + \epsilon)) + P(|X_n - a| > \epsilon), \end{aligned}$$

$$P(Y_n \leq ta) = P(Y_n \leq ta, |X_n - a| \leq \epsilon) + P(Y_n \leq ta, |X_n - a| > \epsilon) \\ \leq P(Y_n \leq t(X_n + \epsilon)) + P(|X_n - a| > \epsilon).$$

定理 2.

(1°)  $f(x, m)$  は確率 0 の  $x$  集合を除いて  $m$  について二回連続的微分可能.

$$(2^\circ) \int \frac{\partial}{\partial m} f(x, m) dx = \int \frac{\partial^2}{\partial m^2} f(x, m) dx = 0.$$

(3°)  $u(x, m) = \frac{1}{f(x, m)} \frac{\partial f(x, m)}{\partial m}$  及び  $\frac{\partial u(x, m)}{\partial m}$  は,  $x$  に一様に  $m$  について連続.

$$(4^\circ) E(u^2) = \int u^2(x, m) f(x, m) dx < +\infty.$$

この四条件の下に  $\sqrt{n}(L_n - m)$  は平均値 0, 標準偏差  $1/\sqrt{E(u^2)}$  の Gauss 分布へ法則収斂する. 但し  $L_n$  は  $m$  の maximum likelihood estimate とする.

証明:

$$(2.08) \quad g(t) = \sum_{i=1}^n u(x_i, t)/n$$

とおけば,

$$(2.09) \quad g'(t) = \frac{1}{n} \sum_{i=1}^n \left( \frac{1}{f} \frac{\partial^2 f}{\partial m^2} - \left( \frac{1}{f} \frac{\partial f}{\partial m} \right)^2 \right) u(x_i, t)$$

なる故 (2.09) は,  $n \rightarrow \infty$  のときには 次のものに概収斂する:

$$(2.10) \quad -E(u^2(x, m)) + \eta(t).$$

但し茲に

$$(2.11) \quad \lim_{t \rightarrow m} \eta(t) = 0.$$

即ち  $g(t)$  の根  $t = L_n$  は確率 0 を除けば唯一となり, 之は likelihood

$$(2.12) \quad \prod_{i=1}^n f(x_i, t)$$

を極大にするが, 更に定理 1 と同じ様にして  $P(|L_n - m| > \epsilon)$  は,  $n \rightarrow \infty$  のとき, 0 に収斂する.

次に

$$(2.13) \quad 0 = \sum_{i=1}^n u(x_i, L_n) = \sum_{i=1}^n u(x_i, m + L_n - m) \\ = \sum_{i=1}^n u(x_i, m) + (L_n - m) \sum_{i=1}^n \frac{\partial u(x_i, m + a(L_n - m))}{\partial m} \quad (0 < a < 1)$$

故に

$$(2.14) \quad \sqrt{n}(L_n - m) = \frac{1}{\sqrt{n}} \sum_{i=1}^n u(x_i, m) / -\frac{1}{n} \sum_{i=1}^n \frac{\partial u(x_i, m + a(L_n - m))}{\partial m}$$

が出るが, この等式の右邊の分母は,  $n \rightarrow \infty$  のときには,

$$(2.15) \quad -E\left(\frac{\partial u}{\partial m}\right) = E(u^2)$$

へ, 分子は平均値 0, 標準偏差  $\sqrt{E(u^2)}$  なる Gauss 分布へ法則収斂する. こゝで補助定理を使用すれば定理は証明された事になる. (Q.E.D.)

パラメーターの数が 2 個以上の場合にも定理 2 と大體同一の證明法によつて次の定理が證明される。

定理 2.

- (1°)  $\frac{\partial^2}{\partial m_i \partial m_j} f(x; m_1, m_2, \dots, m_p)$  は確率 0 の  $x$  集合を除いては存在して連続。  
 (2°)  $\int \frac{\partial}{\partial m_i} f(x; m_1, m_2, \dots, m_p) dx = \int \frac{\partial^2}{\partial m_i \partial m_j} f(x; m_1, \dots, m_p) dx = 0$ .  
 (3°)  $u_i = \frac{1}{f} \frac{\partial f}{\partial m_i}$  及び  $\frac{\partial}{\partial m_j} u$  は、 $x$  に関して一様に、 $(m_1, m_2, \dots, m_p)$  について連続。  
 (4°)  $E(u_i^2) < +\infty$ .

ここで  $(L_n^{(1)}, L_n^{(2)}, \dots, L_n^{(p)})$  を  $(m_1, m_2, \dots, m_p)$  の maximum likelihood estimate とすれば上記四條件の下に  $p$  次元確率變數

$$(2.16) \quad \sqrt{n} (L_n^{(i)} - m_i) \quad (1 \leq i \leq p)$$

は、 $n \rightarrow \infty$  のとき、 $p$  次元 Gauss 分布

$$(2.17) \quad \frac{\sqrt{|A|}}{(\sqrt{2\pi})^p} e^{-\frac{1}{2} \mathbf{y} A \mathbf{y}}$$

に法則收斂する。但し  $A$  は  $E(u_i u_j)$  を  $(i, j)$  元素とする  $p$  行、 $p$  列の行列、 $\mathbf{y}$  は  $p$  次元ベクトル  $(y_1, y_2, \dots, y_p)$  である。

次に maximum likelihood estimate を sample の函數として表はすことを考へよう。例へば Cauchy 分布に於て

$$(2.18) \quad \sum_{i=1}^n \frac{(x_i - m)}{1 + (x_i - m)^2} = 0$$

より  $m$  を  $(x_1, \dots, x_n)$  の陽函數として表はすことは簡單ではない。しかし consistent estimate が既に見出されてゐる場合には、それから出發して次に述べる様に maximum likelihood estimate の式を近似的に解くことが出来る。

定義 3. 確率變數列  $\{x_n\}$  が 0 に法則收斂するとき  $\lim P(A \leq n^\alpha X_n < B) > 0$ ,  $AB > 0$  なる常數  $A, B$  が存在するならば  $\{x_n\}$  は order  $\alpha$  であるといふ。

0 に法則收斂する確率變數列  $\{x_n\}$  が與へられたとき、常に order が定義されるとは限らない。しかし  $\{x_n\}$  が order  $\alpha$  であつて且つ  $\beta (\neq \alpha)$  であることはない。それは次の様に證明される。 $\beta > \alpha$  とし、確率變數  $n^\alpha X_n$  の分布函數を  $F_n(x)$  としよう： $F_n(x) = P(n^\alpha X_n < x)$ 。  $\{F_n(x)\}$  より適當に部分列をえらび、非減少函數  $G(x)$ —これは必ずしも分布函數とは限らぬ—へ一様收斂させることが出来る。それを改めて  $\{F_n(x)\}$  とかく。(0,  $\varepsilon$ ) で  $G(x)$  が連続とすれば、 $F_n(x)$  は (0,  $\varepsilon$ ) で  $G(x)$  に一様收斂するから  $n$  を適當に大きくとれば  $(F_n(D/n^{\beta-\alpha}) - F_n(C/n^{\beta-\alpha})) - (G(D/n^{\beta-\alpha}) - G(C/n^{\beta-\alpha}))$  を任意に小さくなし得る。従つて  $\lim P(C \leq n^\beta X_n < D) > 0$ ,  $CD > 0$  なる  $C, D$  は存在しない。もし  $G(x)$  の不連続點が 0 を集積點としてゐるならば、不連続點が可附番ケしかないことから  $G(x)$  の連続點  $a_n, b_n$  をとつて、 $a_n \rightarrow 0, b_n \rightarrow 0, b_n > D/n^{\beta-\alpha} > C/n^{\beta-\alpha} > a_n$  とすることが出来る。  $F_n(b_n) - F_n(a_n) \geq F_n(D/n^{\beta-\alpha}) - F_n(C/n^{\beta-\alpha})$  であるからこの場合にも  $\lim P(C \leq n^\beta X_n < D) > 0$ ,



$CD < 0$  なる  $C, D$  は存在しない。(Q.E.D.)

この補助定理を利用する. 今 consistent estimate を  $T_n$ , maximum likelihood estimate を  $L_n$  とすれば

$$(2.19) \quad \sum_{i=1}^n u(x_i, T_n + L_n - T_n) = 0$$

より

$$(2.20) \quad L_n - T_n = \frac{1}{n} \sum_{i=1}^n u(x_i, T_n) / -\frac{1}{n} \sum_{i=1}^n u_m(x_i, T_n + \alpha(L_n - T_n)). \quad (0 < \alpha < 1)$$

然るに  $L_n - T_n$  は 0 に収斂するから右邊の分母は  $\sigma_i^2 = 1/E(u_m)$  に確率収斂し,  $1/2$  以上の order を無視すれば

$$(2.21) \quad L_n = T_n + \frac{\sigma_i^2}{n} \sum_{i=1}^n u(x_i, T_n).$$

例として Cauchy の分布をとれば sample の中央値  $\mu_n$  は  $m$  の consistent estimate である (例 3) から,  $\sigma_i^2 = 1/E(u_m) = 2$  より  $\mu_n + 2 \sum_{i=1}^n u(x_i, \mu_n)/n$  を作ればこれは order  $1/2$  以上の無視の下に maximum likelihood estimate と一致する.

### § 3. Intrinsic Accuracy, Efficiency.

定理 2 によつて,  $m$  の maximum likelihood estimate は或條件の下に標準偏差  $1/\sqrt{-E(u_m)}$  なる Gauss 分布に法則収斂することが分つた. 之を利用して

定義 4. 確率密度分布  $f(x, m)$  が與へられたとき,

$$(3.01) \quad -E\left(\frac{\partial^2}{\partial m^2} \log f(x, m)\right)$$

を  $f(x, m)$  の intrinsic accuracy と云ひ  $I(f)$  とかく.

注意 intrinsic accuracy は次の二つの著しい性質をもつ:

$$(3.02) \quad \begin{aligned} (i) \quad & -E\left(\frac{\partial^2}{\partial m^2} \log f(x, m)\right) = E\left(\left(\frac{\partial}{\partial m} \log f(x, m)\right)^2\right). \\ (ii) \quad & f(x, y, m) = f_1(x, m) f_2(y, m) \quad \text{ならば} \quad I(f) = I(f_1) + I(f_2). \end{aligned}$$

何者—(i) について:

$$(3.03) \quad \text{左邊} = -\int \left\{ \frac{f_{mm}}{f} - \left(\frac{f_m}{f}\right)^2 \right\} f dx = -\int f_{mm} dx + \int \left(\frac{f_m}{f}\right)^2 f dx = \text{右邊}.$$

(ii) については:

$$(3.04) \quad \begin{aligned} I(f) &= -E\left(\frac{\partial^2}{\partial m^2} \log f_1 + \frac{\partial^2}{\partial m^2} \log f_2\right) \\ &= -\iint \left(\frac{\partial^2}{\partial m^2} \log f_1 + \frac{\partial^2}{\partial m^2} \log f_2\right) f_1(x) f_2(y) dx dy \\ &= -\int f_2(y) dy \int \left(\frac{\partial^2}{\partial m^2} \log f_1\right) f_1 dx - \int f_1(x) dx \int \frac{\partial^2}{\partial m^2} (\log f_2) f_2 dy \\ &= I(f_1) + I(f_2). \end{aligned}$$

定理 3. 定理 1 の四条件を満足する確率密度分布  $f(x, m)$  から sample  $(x_1, x_2, \dots, x_n)$  を得たとする.  $T_1$  を  $m$  の estimate とし,  $T_1$  が  $m$  について微分可能なる確率密度分布  $\varphi(T_1; m)$  をもつとすれば  $I(\varphi) \leq nI(f)$ .

証明 適當に  $(n-1)$  ケの一價可測函数  $T_2(x_1, \dots, x_n), T_3(x_1, \dots, x_n), \dots, T_n(x_1, \dots, x_n)$  をとり, 確率 0 を除いて,  $(x_1, \dots, x_n)$  と  $(T_1, \dots, T_n)$  とが一対一に對應する様にする. sample  $(x_1, \dots, x_n)$  の生ずる確率は  $\prod_{i=1}^n f(x_i, m)$  なる故  $\prod_{i=1}^n f(x_i, m) dx_i = \varphi(T_1, m) dT_1 \psi(T_1, T_2, \dots, T_n, m) dT_2 \dots dT_n$  とかき得る. この兩邊の intrinsic accuracy をとれば, 上記注意により

$$(3.05) \quad nE\left(\left(\frac{\partial}{\partial m} \log f\right)^2\right) = E\left(\left(\frac{\partial}{\partial m} \log \varphi\right)^2\right) = E\left(\left(\frac{\partial}{\partial m} \log \psi\right)^2\right)$$

となり, 従つて  $I(\varphi) \leq nI(f)$  が證明された.

定義 5.  $T_1, \varphi$  を定理 3 で述べた通りとすると,  $I(\varphi)/nI(f)$  を  $T_1$  の efficiency といふ.

定理 3 及び定義 5 は, パラメーターの数が二ケ以上の場合にも成立する.

定理 3'.  $p$  ケのパラメーターを含む確率密度分布  $f(x; m_1, m_2, \dots, m_p)$  が定理 2' に於ける四条件を満足するとし,  $(m_1, m_2, \dots, m_p)$  の estimate  $(T_1, T_2, \dots, T_p)$  が  $m_i (1 \leq i \leq p)$  について微分可能な確率密度分布  $\varphi(T_1, T_2, \dots, T_p, m_1, m_2, \dots, m_p)$  をもつとする.  $A, B$  は次の如き  $(i, j = 1, 2, \dots, p)$  なる  $p$  次行列とする.

$$(3.06) \quad A = \left\| \frac{1}{f^2} \frac{\partial f}{\partial m_i} \frac{\partial f}{\partial m_j} \right\|, \quad B = \left\| \frac{1}{n} \frac{1}{\varphi^2} \frac{\partial \varphi}{\partial m_i} \frac{\partial \varphi}{\partial m_j} \right\|.$$

$y$  を  $p$  次元ベクター

$$(3.07) \quad y = (y_1, y_2, \dots, y_p)$$

とすれば, 次の關係が成立つ:

$$(3.08) \quad yAy' \geq yBy'.$$

証明  $(n-p)$  ケの一價可測函数  $T_{p+1}(x_1, \dots, x_n), \dots, T_n(x_1, \dots, x_n)$  を適當にとつて, 確率 0 を除いて  $(x_1, x_2, \dots, x_n)$  と  $(T_1, T_2, \dots, T_n)$  とが一対一の對應をなすとする. 簡單のため  $m = (m_1, m_2, \dots, m_p)$  とかく.

$$(3.09) \quad \prod_{i=1}^n f(x_i; m) = \varphi(T_1, T_2, \dots, T_p; m) \psi(T_1, T_2, \dots, T_n; m)$$

により

$$(3.10) \quad \sum_{i=1}^n \frac{\partial}{\partial m_k} \log f(x_i, m) y_k = \left( \frac{\partial}{\partial m_k} \log \varphi + \frac{\partial}{\partial m_k} \log \psi \right) y_k \quad (1 \leq k \leq p)$$

そこで今

$$(3.11) \quad \frac{\partial}{\partial m_k} \log f(x_i, m) = u_k(x_i), \quad \frac{\partial}{\partial m_k} \log \varphi = g_k, \quad \frac{\partial}{\partial m_k} \log \psi = h_k$$

とかけば, 次の等式を得る:

$$(3.12) \quad E\left\{\left(\sum_{k=1}^p \left(\sum_{i=1}^n u_k(x_i)\right) y_k\right)^2\right\} = E\left\{\left(\sum_{k=1}^p (g_k + h_k) y_k\right)^2\right\}.$$

この等式の左邊は次の如く變形される.

$$(3.13) \quad E \left\{ \sum_{k=1}^p \left( \sum_{i=1}^n u_k(x_i) \right)^2 y_k^2 + \sum_{j \neq k} \left( \sum_{i=1}^n u_j(x_i) \right) \left( \sum_{i=1}^n u_k(x_i) \right) y_j y_k \right\} \\ = \sum_{k=1}^p E \left\{ \left( \sum_{i=1}^n u_k(x_i) \right)^2 \right\} y_k^2 + \sum_{j \neq k} E \left\{ \left( \sum_{i=1}^n u_j(x_i) \right) \left( \sum_{i=1}^n u_k(x_i) \right) \right\} y_j y_k.$$

然るに  $i \neq l$  ならば  $j, k$  の如何に關せず

$$(3.14) \quad E \{ u_j(x_i) u_k(x_l) \} = 0$$

なる故、上式は

$$(3.15) \quad n \left[ \sum_{k=1}^p E \left( u_k^2(x) \right) y_k^2 + \sum_{j \neq k} E \left( u_j(x) u_k(x) \right) y_j y_k \right] = n E \left\{ \left( \sum_{k=1}^p u_k(x) y_k \right)^2 \right\}.$$

次に右邊をかきかへれば

$$(3.16) \quad E \left\{ \left( \sum_{k=1}^p g_k y_k \right)^2 + \left( \sum_{k=1}^p h_k y_k \right)^2 + \left( \sum_{k=1}^p g_k y_k \right) \left( \sum_{l=1}^p h_l y_l \right) \right\} \\ = E \left\{ \left( \sum_{k=1}^p g_k y_k \right)^2 \right\} + E \left\{ \left( \sum_{k=1}^p h_k y_k \right)^2 \right\}.$$

従つて

$$(3.17) \quad \sum_{i,j} E \{ g_i g_j \} y_i y_j \leq n \sum_{i,j} E \{ u_i u_j \} y_i y_j. \quad (Q.E.D.)$$

さて、

$$(3.18) \quad \int_{-\infty}^{\infty} e^{-\frac{1}{2} y A y} dy = \frac{(\sqrt{2\pi})^p}{\sqrt{|A|}}$$

であるから、上の定理により、 $|B| \leq |A|$  となる。依つて次の定義を導入する。

定義 5'.  $(T_1, T_2, \dots, T_p)$  及び  $A, B$  を定理 3' の如く假定するとき、 $|B|/|A|$  を  $(T_1, T_2, \dots, T_p)$  の efficiency といふ。

例 6.  $f(x, m) = e^{-ix-m}/2$  に於いて sample  $(x_1, x_2, \dots, x_n)$  の中央値  $\mu_n$  を  $m$  の estimate とするとき、 $\mu_n$  の efficiency を計算しよう。  $n=2s+1$  とする。  $I(f) = 1$ 。例 3 に於ける  $p$  をとれば

$$(3.19) \quad I(p) = \frac{(s+1)(2s+1)}{s-1} \left( 1 - \frac{(2s)!}{2^{2s-1}(s!)^2} \right).$$

従つて  $\mu_n$  の efficiency は

$$(3.20) \quad \frac{s+1}{s-1} \left( 1 - \frac{(2s)!}{2^{2s-1}(s!)^2} \right).$$

この値を第 1 表について例示しておく。

第 1 表

$s$	1	2	3	4	100	$\infty$
efficiency	0.77	0.75	0.82	0.84	0.91	1

注意 定理 3 に於ける  $T_1$  より  $S_1 = \sqrt{n}(T_1 - m)$  を作る。  $S_1$  が平均値 0、標準偏差  $\sigma$  の Gauss 分布へ二次の平均収斂をすると假定する。このとき  $T_1$  の efficiency として、  $n \rightarrow \infty$  ならば  $\sigma^2(L)/\sigma^2(T_1)$  をとる事が出来る。但し  $L$  は  $m$  の maximum likelihood estimate とする。それ故  $n \rightarrow \infty$

のとき maximum likelihood estimate は efficient である。この様に  $n \rightarrow \infty$  のときの efficiency は簡単に計算される。例 5 に於て Gauss 分布の場合ならば, sample の平均値が  $m$  の maximum likelihood estimate であるから efficiency 1. 中央値の efficiency は  $\frac{2}{\pi}$ . Laplace 分布ならば  $m$  の maximum likelihood estimate は中央値  $(\sum_{i=1}^n |x_i - m|)$  を最小ならしめる  $m$  は  $(x_i)$  の中央値) であるからその efficiency は 1. 平均値の efficiency は  $\frac{1}{2}$  である。

例 7.  $\chi^2$  函数; 観測値と理論値との差の大きさを測るものに  $\chi^2$  函数がある。今  $n$  ケの class の各々にはいる観測値の数を  $a_1, a_2, \dots, a_n$  とし, 理論値の数を  $b_1, b_2, \dots, b_n$  として  $\chi^2 = \sum_{i=1}^n (a_i - b_i)^2 / b_i$  とおく

$$(3.21) \quad P(\chi^2 \leq t) = \frac{1}{2 \Gamma(\frac{n-1}{2})} \int_0^t e^{-\frac{x^2}{2}} \left(\frac{x}{2}\right)^{\frac{n-3}{2}} dx$$

を計算し, その大きさによつて適合の程度を測るのである。

今  $b_i$  がパラメーター  $m$  を含む場合,  $b_i = b_i(m)$  なるとき  $\chi^2(m)$  を最小にする様に  $m$  を定め, それを  $T_x$  とすれば,  $T_x$  は  $m$  の consistent estimate であり,  $\sqrt{n}(T_x - m)$  は Gauss 分布に法則収斂し  $T_x$  の efficiency は 1 であることが證明される。(證明略)

#### § 4. Sufficient Estimate, Closest Estimate.

[1] Sufficient Estimate 例 6 で見た様に  $n$  が小さいときは, maximum likelihood estimate でも efficiency は 1 より小さいことがある。そこで efficiency 1 なる statistic があるかどうか, もしあれば如何にして見出すか等の問題が生ずる。

定義 6. efficiency 1 なる statistic を sufficient といふ。

定理 3' の證明を見れば分る様に,  $\psi$  が  $(m_1, \dots, m_p)$  を含まないこと即ち  $\partial\psi/\partial m_i = 0, 1 \leq i \leq p$  が  $(T_1, \dots, T_p)$  が sufficient となるための必要且つ十分な條件である。この條件は又次の様にもいへる:

「 $T_i(x_1, \dots, x_n) = T_i(x'_1, \dots, x'_n), 1 \leq i \leq p$  ならば  $\prod_{i=1}^n f(x_i; m) / \prod_{i=1}^n f(x'_i; m)$  が  $m$  に無關係である」

定理 4.  $(m_1, \dots, m_p)$  の sufficient estimate  $(T_1, \dots, T_p)$  が存在する爲の必要且つ十分な條件は,

$$(4.01) \quad f(x, m_1, \dots, m_p) = \exp\left(\sum_{k=1}^p M_k X_k + M + X\right)$$

とかかれることである。但し  $M, M_1, \dots, M_p$  は  $(m_1, \dots, m_p)$  の函数,  $X, X_1, \dots, X_p$  は  $x$  の函数であつて

$$(4.02) \quad \sum_{i=1}^n X_k(x_i) = V_k(T_1, \dots, T_p).$$

證明 簡單の爲  $p=1$  とする。  $p \geq 2$  のときも同様な證明法で出来る。十分なことは明白。必要な事は次の如く示される:

$$(4.03) \quad L = \sum_{i=1}^n \log f(x_i; m)$$

とおけば

$$(4.04) \quad \partial L / \partial m = \Phi(T; m).$$

$T$  は勿論  $m$  を含まないから  $m$  を一つ定めれば

$$(4.05) \quad S = \sum_{i=1}^n g(x_i) = \sum_{i=1}^n f_m(x_i)/f(x_i)$$

として  $T = \psi(S)$  とかける。故に

$$(4.06) \quad \frac{\partial L}{\partial m} = H(S, m), \quad \frac{\partial^2 L}{\partial x_i \partial m} = \frac{\partial H}{\partial S} \frac{\partial S}{\partial x_i} = \frac{\partial H}{\partial S} g'(x_i)$$

とかける。そこで  $\partial L / \partial x_i$  は  $(x_i, m)$  の函数であるから  $\partial H / \partial S$  も亦  $(x_i, m)$  の函数となる。しかるに  $S$  は  $(x_1, x_2, \dots, x_n)$  の対称函数であるから  $\partial H(S, m) / \partial S = p(m)$ 。従つて

$$(4.07) \quad H(S, m) = p(m)S + q(m).$$

即ち

$$(4.08) \quad \sum_{i=1}^n \frac{\frac{\partial f}{\partial m}(x_i, m)}{f(x_i, m)} = p(m) \sum_{i=1}^n g(x_i) + q(m).$$

特に  $x = x_i (1 \leq i \leq n)$  を考へれば

$$(4.09) \quad \log f(x, m) = M_1(m)g(x) + M(m) + h(x). \quad (Q.E.D.)$$

例 8. (1°) Gauss の分布

$$(N) \quad f(x; m, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-m)^2}{2\sigma^2}}$$

に於いて  $(m, \sigma)$  が未知のとき、

$$(4.10) \quad \begin{cases} T_1 = \frac{1}{n} \sum_{i=1}^n x_i \quad (= \bar{x}), \\ T_2 = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - T_1)^2} \quad (= s_2) \end{cases}$$

が  $(m, \sigma)$  の sufficient estimate である。その理由は

$$(4.11) \quad \sum_{i=1}^n x_i = \sum_{i=1}^n x_i', \quad \sum_{i=1}^n x_i^2 = \sum_{i=1}^n x_i'^2$$

より次の等式を得るからである：

$$(4.12) \quad L_1 = \sum_{i=1}^n \log \frac{f(x_i, m, \sigma)}{f(x_i', m, \sigma)} = + \frac{1}{2\sigma^2} (\sum x_i'^2 - \sum x_i^2) + 2m(\sum x_i - \sum x_i') = 0.$$

次に  $\sigma$  を既知、 $m$  を未知としよう。このときには

$$(4.13) \quad \sum_{i=1}^n x_i = \sum_{i=1}^n x_i'$$

だけから

$$(4.14) \quad L_1 = \sum (x_i'^2 - x_i^2) / 2\sigma^2$$

となり、これは  $m$  を含まないから  $T_1$  が  $m$  の sufficient estimate である。 $m$  が既知、 $\sigma$  が未知のときには  $T_2$  が  $\sigma$  の sufficient estimate となることは  $L_1$  の形から明白である。

(2°) Pearson Type III.

$$(4.15) \quad f(x; m_1, m_2, m_3) = \frac{1}{m_2 \Gamma(m_3 + 1)} \left( \frac{x - m_1}{m^2} \right)^{m_3} e^{-\frac{x - m_1}{m_2}}$$

に於て、 $m_1$  が既知ならば、 $m_2, m_3$  の兩方或は何れか一方が未知のとき sufficient estimate が存在することは容易に證明される。もし  $m_1$  が未知ならば sufficient estimate は存在しない。何者  $m_1$  の sufficient estimate があれば

$$(4.16) \quad \frac{\partial^2 f}{\partial x \partial m_1} = \sum_{k=1}^q \frac{\partial M_k}{\partial m_1} \frac{dX_k}{dx}.$$

$y = -m_1$  とおけば、この等式の左邊は  $F(x+y)$  の形となる。従つて  $\{A_j(x)\}, 1 \leq j \leq m \leq q$  を一次獨立として次の如くかける。

$$(4.17) \quad F(x+y) = \sum_{k=1}^m A_k(x) B_k(y).$$

これを  $y$  に關して  $m$  回微分して出来る  $(m+1)$  ケの式より  $A_1(x), \dots, A_m(x)$  を消去して  $y=0$  とおけば  $F(x)$  は常數係數の同次線型微分方程式の解となる。それ故  $P_k(x)$  を多項式として

$$(4.18) \quad F(x) = \sum_{k=1}^N P_k(x) e^{a_k x}$$

となる筈であるが、今は  $\partial^2 \log f / \partial x \partial m_1 = m_2 / (x - m_1)^2$  であるから  $F(x) = m_2 / x^2$  となつて結局  $m_1$  の sufficient estimate のないことが分つた。

[2] **Closest Estimate** 同一のパラメーターの値に關する二つの consistent estimate があつたとき何れを採用すべきかについて、以上述べた方法は R. A. Fisher によるものである。Pitman は sufficient estimate を利用して異つた立場から一つの方法を提出したが主定理は未だ證明されてゐない。

**定義 1.**  $T_1, T_2$  を  $g(m)$  の consistent estimate とする。凡ての  $m$  について、 $P(|T_1 - g(m)| \leq |T_2 - g(m)|) > \frac{1}{2}$  ならば  $T_1$  は  $T_2$  より closer であるといふ。 $T_2$  を任意にとつて常に  $T_1$  が  $T_2$  より closer ならば、 $T_1$  を  $g(m)$  の closest estimate といふ。

**注意**  $T_1$  が  $T_2$  より closer,  $T_2$  が  $T_3$  より closer,  $T_3$  が  $T_1$  より closer なることもある。

$m$  の sufficient estimate  $T$  が存在するとき、 $T$  は  $m$  に關して sample の有する性質を最も多く保有せるものと考へられるから、closest estimate が  $T$  より導かれると豫期するのは當然であらう。今次の事實、「確率變數  $X$  の中央値を  $\mu$  とし、 $\nu$  を  $\frac{1}{2}(\mu + \nu)$  が中央値でないようにとれば  $P(|X - \mu| \leq |X - \nu|) > \frac{1}{2}$ 」の成立することを考へれば、closest estimate の中央値が  $m$  に等しい事が望ましい。それ故、sufficient estimate  $T$  の中央値を  $\psi(m)$  とすれば、 $\psi(m)$  が單調函數なるとき  $\psi^{-1}(T)$  は中央値  $m$  の sufficient estimate である。この  $\psi^{-1}(T)$  が  $m$  の closest estimate であるといふのが Pitman の豫想である。

**例 9.** Gauss 分布 ( $N$ ) (例 8) に於いて  $m, \sigma$  を未知とする。size  $n$  の sample  $(x_1, \dots, x_n)$  より (4.10) 及び (4.11) を作れば  $(T_1, T_2/n)$  は  $(m, \sigma^2)$  の sufficient estimate である。(例 8, 1°)  $T_2/\sigma^2$  の密度分布は自由度  $(n-1)$  の  $\chi^2$  分布と同一である：

$$(4.19) \quad P(T_2/\sigma^2 < t) = \frac{1}{2\Gamma\left(\frac{n-1}{2}\right)} \int_0^t e^{-\frac{x^2}{2}} \left(\frac{x}{2}\right)^{\frac{n-3}{2}} dx.$$

この中央値を  $k_{n-1}$  で表せば  $\sigma^2$  の closest estimate は  $T_2/k_{n-1}$  である。但し  $k_{n-1} = n - 2/3 + 0.09/n$ .

$\sigma^2$  の estimate として通常 unbiased estimate  $S^2/n-1$  をとるが、これは  $P(S^2/n-1 < \sigma^2) > 1/2$  なる故小さ過ぎるといふことが出来る。

この例及び他の特別な場合について上記豫想の正しいことが証明されてゐる。(証明略)

### § 5. $f(x; m)$ の range が $m$ に関係する場合

今迄は「 $f(x; m)$  の range は  $m$  に関係しない」といふ假定をおいたがこの § では上の假定を取去つて見る。この場合定理 2, 3 が必ずしも成立しないことは次の簡単な例で分る。

$$(5.01) \quad \int_{-\infty}^m f(x; m) dx = 1, \quad g(m) = \frac{1}{n} \sum_{i=1}^n \log f(x_i; m)$$

とおけば  $n \rightarrow \infty$  のとき  $g'(m) \rightarrow -f(m, m) \leq 0$ 。従つて  $f(m, m) > 0$  と假定すれば  $g'(m) < 0$  であるから  $m = \text{Max}(x_i)$  のとき  $g(m)$  は最大となる。 $L_n = \text{Max}(x_i)$  の分布密度は

$$(5.02) \quad p_n(x) = n \left( \int_{-\infty}^x f(x, m) dx \right)^{n-1} f(x; m).$$

$x = m$  のとき  $p_n \rightarrow \infty$ ,  $x \neq m$  のとき  $p_n \rightarrow 0$ 。従つて  $L_n$  は consistent である。しかし  $\sqrt{n}(L_n - m)$  は Gauss 分布に収斂するとは限らぬ。例へば  $0 \leq x \leq m$  なるとき  $f(x, m) = 1/m$ , その他の場合  $f(x, m) = 0$  とすれば  $n(L_n - m)$  の分布密度は  $e^{\frac{x}{m}} dx/m (-\infty < x < 0)$  に収斂する。即ち order 1 である。このとき  $m_n$  を sample の平均の二倍,  $\mu_n$  を sample の中央値の二倍とすれば  $\sqrt{n}(m_n - m)$ ,  $\sqrt{n}(\mu_n - m)$  は共に Gauss 分布に収斂するが  $\text{Max}(x_i)$  の方が遙かに効果的なことは order を考へれば明白であらう。 $I(f) = 1/m^2$ ,  $I(p) = n^2 m^2$ 。故に  $I(p) > nI(f)$ 。

次に又

$$(5.03) \quad f(x, m) = e^{-(x-m)}, \quad m < x < \infty$$

を考へれば

$$(5.04) \quad E \left\{ \left( \frac{\partial}{\partial m} \log f \right)^2 \right\} = E(1) = 1, \quad E \left\{ \frac{\partial^2}{\partial m^2} \log f \right\} = E(0) = 0.$$

それ故、定義 4, 注意 i) の等式は成立しない。

次に

$$(5.05) \quad \int_a^b f(x, m) dx = 1$$

を  $m$  で微分すれば

$$(5.06) \quad J(f) = \int_a^b \frac{\partial f}{\partial m} dx = a'(m) f(a(m), m) - b'(m) f(b(m), m)$$

となつて一般に  $J(f) \neq 0$ 。然るに  $(x_1, x_2, \dots, x_n)$  の likelihood  $L$  については

$$(5.07) \quad E \left\{ \left( \frac{\partial}{\partial m} \log L \right)^2 \right\} = E \left\{ \left( \frac{\partial}{\partial m} \log (\prod f(x_i, m)) \right)^2 \right\} \\ = n E \left\{ \left( \frac{\partial}{\partial m} \log f(x, m) \right)^2 \right\} + n(n-1) J^2(f).$$

$f(x, m)$  の intrinsic accuracy  $I(f)$  として

$$(5.08) \quad I(f) = E \left\{ \left( \frac{\partial}{\partial m} \log f \right)^2 \right\}$$

をとる事にすれば, sample  $(x_1, x_2, \dots, x_n)$  の intrinsic accuracy は  $nI(f) + n(n-1)J^2(f)$  となる.

他の例として

$$(5.09) \quad f(x, m) = \frac{2x}{2m+1}, \quad (m \leq x \leq m+1)$$

をとれば

$$(5.10) \quad E \left\{ \left( \frac{\partial}{\partial m} \log L \right)^2 \right\} = \frac{4n^2}{(2m+1)^2}$$

$$(5.11) \quad T = \text{Max}_{1 \leq i \leq n} \{x_i\}$$

をとれば, その密度分布は

$$(5.12) \quad p(x, m) = \frac{2nx(x^2 - m^2)^{n-1}}{(2m+1)^n}$$

これより

$$(5.13) \quad E \left\{ \left( \frac{\partial}{\partial m} \log p \right)^2 \right\} > nI + n(n-1)J^2$$

この様に  $f(x, m)$  の range に  $m$  が関係する場合にも有効な intrinsic accuracy の定義は未だ見付からない.

## II. 区間による推定法

以上に於ては常に一ケの値によつてパラメーターの値を推定することを試みた. しかし如何なる estimate を採用しても, その値が丁度パラメーターの値に等しいといふことは先づ不可能である. それでよく行はれてゐるのは estimate  $T$  の標準偏差  $\sigma(T)$  をとつて  $T \pm c\sigma(T)$  ( $c$  は常數) によつてパラメーターの値を表はす方法である. かくしてパラメーターの値を推定するのに一ケの値を使用するのではなく, 区間を使用する試みが問題となる. しかし之は problem of estimation といふよりむしろ所謂 problem of testing statistical hypothesis に密接な關係を有するものである故, 簡単に紹介することとするが, それは主として Neyman の理論である.

sample の空間  $S$ —その點即ち sample  $(x_1, \dots, x_n)$  を  $x$  で表はす—には  $p$  ケのパラメーター  $m = (m_1, \dots, m_p)$  を含む確率分布  $P(A; m)$ ,  $A \subset S$  が與へられてゐるとする. 更に  $P$  は密度  $f(x; m)$  を有するとする. 今 sample  $(x_1, \dots, x_n)$  が得られたとし, 之から一ケのパラメーター  $m_1$  を推定する方法を述べよう. ここでは  $x_1, \dots, x_n$  が相互に獨立であることは假定してないし, 又  $f(x, m)$  の range も—それが考へられる場合—に必ずしもパラメーターに無關係ではないことは注意を要する.

定義 1.  $0 \leq a \leq 1$  が與へられたとし,  $S$  で定義され實數値をとる二つの一價函數  $m_1(x) \leq \bar{m}_1(x)$  を適當に定めて,  $m_2, \dots, m_p$  に無關係に等式  $P([x; m_1(x) \leq m_1 \leq \bar{m}_1(x)]; m) = a$  が成立したとする. このとき  $m_1(x)$ ,  $\bar{m}_1(x)$  を夫々  $m_1$  の lower, upper confidence limit,  $a$  を confidence coefficient といひ, 區間  $[m_1(x), \bar{m}_1(x)]$  を  $a$  に對する confidence interval といつて  $\sigma(x)$  とか.

定義 2.  $0 \leq a \leq 1$  とする.  $m_1$  を任意に與へたとき  $A(m_1) \subset S$  が次の四條件を満足する様にとれるとする.



- (i). 任意の  $x$  に対して  $x \in A(m_1)$  なる如き  $m_1$  が存在する。  
(ii).  $P(A(m_1); m)$  が凡ての  $(m_1, m)$  について定義されその値は  $\alpha$  に等しい。  
(iii).  $m_1^{(1)} < m_1^{(2)} < m_1^{(3)}$  ならば  $A(m_1^{(1)}) \cdot A(m_1^{(3)}) \subset A(m_1^{(2)})$ .  
(iv).  $\prod_{m_1^{(1)} < m_1 < m_1^{(2)}} A(m_1) \subset A(m_1^{(1)}) A(m_1^{(2)})$ .

このとき  $A(m_1)$  を  $\alpha$  に對する  $m_1$  の region of acceptance といふ。

定理 1.  $0 \leq \alpha \leq 1$  を與へたとき、凡ての  $x \in S$  について  $\alpha$  に對する confidence limit ( $\underline{m}_1(x), \bar{m}_1(x)$ ) を作ることに凡ての  $m_1$  について  $\alpha$  に對する region of acceptance  $A(m_1)$  を作ることは同等である。

證明  $A(m_1) = [x; \underline{m}_1(x) \leq m_1 \leq \bar{m}_1(x)]; \underline{m}_1(x) = \inf.[m_1; x \in A(m_1)], \bar{m}_1(x) = \sup.[m_1; x \in A(m_1)]$  より容易に證明される。

例 1. sample の空間を二次元とし、與へられた確率密度を「 $p(x_1, x_2; m) = m^{-2}, 0 < x_1, x_2 < m; p(x_1, x_2; m) = 0$ , その他の場合」とする。confidence intervals を定めて見よう。前定理によつて regions of acceptance を定めればよいがそのとり方には色々ある。そこで  $A_1(m), A_2(m), A_3(m)$  を次の様に定める。 $A_1(m) = [(x_1, x_2); \beta m \leq x_1, x_2 \leq m], 0 < \beta < 1$ .  $A_2(m) = [(x_1, x_2); r \leq x_1 + x_2 \leq m + r], 0 < r < m$ .  $A_3(m) = [(x_1, x_2); \Delta m \leq \text{Max}(x_1, x_2) \leq m], 0 < \Delta < 1$ . 先づ  $A_1(m)$ : これが region of acceptance とならない事は、點  $(x_1, x_2)$ ,  $x_2 < \beta x_1$  に対しては如何に  $m$  をとつても  $\beta m \leq x_1, x_2 \leq m$  が成立しないことから分る。次に  $A_2(m)$ : これが region of acceptance になることはすぐ分る。confidence coefficient を  $\alpha$  とすれば  $(m^2 - r^2)/m^2 = \alpha$  なる故  $r = \sqrt{1 - \alpha} m$ . 従つて  $\underline{m}(x) = (x_1 + x_2)/(1 + \sqrt{1 - \alpha}), \bar{m}(x) = (x_1 + x_2)/\sqrt{1 - \alpha}$ . confidence interval の長さは  $(x_1 + x_2)/\sqrt{1 - \alpha}(1 + \sqrt{1 - \alpha})$ . 終りに  $A_3(m)$ : これも region of acceptance なる事は容易に分る。 $\Delta = \sqrt{1 - \alpha}$ ,  $\underline{m}(x) = \text{Max}(x_1, x_2), \bar{m}(x) = \text{Max}(x_1, x_2)/\sqrt{1 - \alpha}$ , confidence interval の長さは  $(1 - \sqrt{1 - \alpha}) \text{Max}(x_1, x_2)/\sqrt{1 - \alpha}$ . 上の二つの confidence interval の長さを比較すれば  $(x_1 + x_2)/\sqrt{1 - \alpha}(1 + \sqrt{1 - \alpha}) > (x_1 + x_2)(1 - \sqrt{1 - \alpha})/\alpha\sqrt{1 - \alpha} \leq (1 - \sqrt{1 - \alpha}) \text{Max}(x_1, x_2)/\sqrt{1 - \alpha}$ . 故に  $A_2(m)$  をとるより  $A_3(m)$  をとつた方がよい。

上例ではパラメーターが一ケであつたが二ケ以上になると confidence interval の作り方は非常に難くなる。それは  $A(m_1)$  を  $m_2, \dots, m_p$  に無關係に定めなくてはならないからである。しかし次の定理が成立するときは後例で見る如く簡単に region of acceptance を作る事が出来る。

定理 2.

(i).  $x$  について  $S (< n)$  ケの一價可測函數  $T_1(x), \dots, T_s(x)$  が獨立である。

(ii).  $p(x; m) = p(T_1, \dots, T_s; m) f(x; m_1)$ . 但し  $p(T_1, \dots, T_s; m) = p([x; T_1(x) = T_1, \dots, T_s(x) = T_s]; m)$ .

この二條件の下に次の結果が生ずる。

(1°)  $B = [x; T_1(x) = c_1, \dots, T_s(x) = c_s], C \subset B$  とするとき  $P_B(C; m) = P(C; m)/P(B; m)$  は  $m_2, \dots, m_p$  に無關係である。

(2°)  $0 \leq \alpha \leq 1$  が與へられたとし、 $m_1 = m_1^0$  を定めて  $P_B(C; m_1^0, m_2, \dots, m_p) = \alpha$  なる如く  $C$  を

とれば  $P[C \times (T_1, \dots, T_p); m_1^0, m_2, \dots, m_p] = \alpha$ .

説明 容易に出来る. 省略する.

例 2. 「 $0 \leq x_1 + x_2 \leq m_1$ ,  $0 \leq x_1, x_2 \leq m_1$  ならば  $f(x_1, x_2; m_1, m_2) = 2/m_1^2 - m_1 m_2 + 3 m_2 x_1$ . 他の場合  $f(x_1, x_2; m_1, m_2) = 0$ 」なる確率分布が與へられてゐるとき region of acceptance を見出さう.  $0 \leq x_1 \leq m_1$  のとき  $f(x_1) = \int_0^{m_1-x_1} f(x_1, x_2; m_1, m_2) dx_2 = f(x_1, x_2; m_1, m_2) (m_1 - x_1)$ . その他の場合  $f(x_1) = 0$ . 従つて  $0 \leq x_1, x_2 \leq m_1$ , 且  $0 \leq x_1 + x_2 \leq m_1$  なるとき  $f(x|m_1) = (m_1 - x_1)^{-1}$ . その他のとき  $f(x|m_1) = 0$  とすれば  $p(x; m) = p(x_1; m) f(x|m_1)$ . それ故  $m_1$  の値を一つ定め定理 2 に於ける  $C(x_1)$  を見出せばよいがそれは簡単である. 實際  $0 \leq x_2 \leq m_1 - x_1$  ならば  $p_{x_1}(x_2; m) = p(x_2; m)/p(x_1; m) = (m_1 - x_1)^{-1}$ . その他のとき  $p_{x_1}(x_2; m) = 0$ . 即ち  $x_1$  を與へたならば  $x_2$  の確率分布は一樣であるから  $C(x_1) = [x_2; b(m_1 - x_1) \leq x_2 \leq (b+a)(m_1 - x_1)]$ ,  $b \leq 1 - a$  とすればよい. それ故  $A_2(m_1) = [x; b(m_1 - x_1) \leq x_2 \leq (b+a)(m_1 - x_1)]$  とおけば, これが region of acceptance になることは明白である. confidence limits は,  $\underline{m}_1(x) = x_1 + x_2(b+a)$ ,  $\overline{m}_1(x) = x_1 + x_2/b$ . confidence interval の長さは  $ax_2/b(b+a)$ . これは  $b=1-a$  のとき最短で従つて最も効果的である.  $C(x_2)$  のとり方は勿論他にもある. 例へば  $0 \leq x_1 < m_1/2$  ならば  $C(x_1) = [(x_1, x_2); (1-a)(m_1 - x_1) \leq x_2 \leq m_1 - x_1]$ ,  $x_2 = m_1/2$  のとき  $C(x_1) = [(x_1, x_2); 0 \leq x_1 \leq x_2]$ ,  $m_1/2 < x_1 \leq m_1$  ならば  $C(x_1) = [(x_1, x_2); 0 \leq x_2 \leq a(m_1 - x_1)]$ . 次に  $A_3(m_1) = [(x_1, x_2); 0 \leq x_1 \leq m_1, x_2 \in C(x_1)]$  とすれば  $A_3(m_1)$  は  $a \leq 1/2$  のとき region of acceptance となる.  $a < 1/2$  のときにさうでない事は  $a < x_1/x_2 < 1-a$  なる  $(x_1, x_2)$  をとればすぐ分る.  $a > 1/2$  のときの confidence limits は:  $x_1 \leq x_2$  ならば  $\underline{m}_1(x) = x_1 + x_2$ ,  $\overline{m}_1(x) = x_1 + x_2/(1-a)$ ;  $ax_1 \leq x_2 \leq x_1$  ならば  $\underline{m}_1(x) = 2x_1$ ,  $\overline{m}_1(x) = x_1 + x_2/(1-a)$ ;  $(1-a)x_1 \leq x_2 \leq ax_1$  ならば  $\underline{m}_1(x) = x_1 + x_2/a$ ,  $\overline{m}_1(x) = x_1 + x_2/(1-a)$ ,  $x_2 \leq (1-a)x_1$  ならば  $\underline{m}_1(x) = x_1 + x_2/a$ ,  $\overline{m}_1(x) = 2x_1$ . これより confidence interval の長さもすぐ計算出来るが, 特別の場合として,  $ax_1 = x_2$  のときは  $(2a-1)/a(1-a)$  となつて  $A_2(m)$  より短いが  $qx_1 = x_2$ ,  $0 < q < a(1-a)/(1-a+a_2)$  のときは  $x_1 - x_2/a > ax_2/(1-a)$  となつて  $A_2(m)$  より長い.

定義 3.  $\delta_1 = [\delta_1(x); x \in S]$  を  $0 \leq \alpha \leq 1$  に對する system of confidence intervals とする. 他の任意の system of confidence intervals  $\delta_2$  について,  $(m, m')$  の如何に拘らず  $P([x; m_1 \in \delta_1(x)]; m_1') \leq P([x; m_1 \in \delta_2(x)]; m_1')$  となるとき  $\delta_1$  を shortest system of confidence intervals といふ.

shortest system of confidence intervals の構成法は:

(1°).  $m_1$  の一つの値  $m_1^0$  に對し  $A(m_1^0)$  を  $m_2, \dots, m_p$  に無關係に, 且  $P(A(m_1^0); m_1^0, m_2, \dots, m_p) = \alpha$  ( $\alpha$  は  $0 \leq \alpha \leq 1$  なる常數) となる様に定める.

(2°).  $\overline{m}_1$  を 1° を満足する凡ての  $A(m_1^0)$  の中で  $m_1^0 \neq \overline{m}_1$  なるとき  $P(A(m_1^0); \overline{m}_1)$  が最小となる様に  $A_0(m_1^0)$  をえらふ.

(3°). 上記  $A_0(m_1^0)$  が  $\overline{m}_1$  を動かしても尙  $P(A(m_1^0); \overline{m}_1)$  を最小にして居り, 且  $m_1^0$  を動かしても  $\alpha$  に對する region of acceptance になつてゐるとする.

かく定められた  $\{A_0(m_1^0)\}$  は system of regions of acceptance であつてそれより作つた system of confidence intervals が shortest なることは明白である。上記 (1°), (2°) は肯定的に解かれるが, (1°), (2°) を満足するものが必ずしも (3°) を満足しないのである。即ち  $P(A_0(m_1^0); \bar{m}_1)$  を最小にする  $A_0(m_1^0)$  は  $\bar{m}_1$  をかへるととき一般にはこの性質を保有しないのである。

補助定理 「 $\int_A p(x, m) dx = \text{一定}$ 」なる条件の下に  $\int_A p(x, m') dx$  を極小ならしめるための必要十分条件は  $A = [x; p(x, m') \leq cp(x, m)]$  とかけることである。

証明 (省略)。

定理 3.

(1°). 一ケのパラメーターを含む確率密度分布  $p(x; m)$  が次の三条件を満足する。

- (i). sample の空間  $S$  に於て微分可能。
- (ii).  $\partial p(x; m)/\partial m$  が存在して連続, 且  $\neq 0$ 。
- (iii).  $\int_S \partial p(x; m)/\partial m dx = 0$ 。

(2°).  $m$  の二ケの定つた値  $m_1, m_2$  に關し,  $P(A(m_1); m_1) = P(A; m_1) = a$ ,  $P(A(m_1); m_2) \leq P(A; m_2)$  を満足する  $A, A(m_1) \subset S$  が存在する。

(3°).  $A(m_1)$  の境界上の少くとも一點に於て  $p(x; m_1) \neq 0$ 。

(1°), (2°), (3°) なる条件の下に次の結果が成立する。 $m$  の値を適當にとり——之を  $m_3$  とする——更に  $B \subset S$  を適當に定めて  $P(B; m_1) = a$ ,  $P(A(m_1); m_3) > P(B; m_3)$  とすることが出来る。

証明  $P(B; m_3) = a$  なる任意の  $B \subset S$  及び任意の  $m_3$  について常に  $P(A(m_1); m_3) \leq P(B; m_3)$  が成立すると假定しよう。補助定理により  $x$  が  $A(m_1)$  の夫々内點・境界點・外點なるとき  $p(x; m) \leq k(m)p(x; m_1)$  を満足する  $k(m)$  の存在が分る。次に  $A(m_1)$  の境界上の一點  $x_0$  を  $p(x; m_1) > 0$  となる様にとれば  $k(m) = p(x_0; m)/p(x_0; m_1)$ 。書直せば  $k(m) = 1 + (m - m_1)p_m(x_0, m_1 + \theta(m - m_1))/p(x_0; m_1)$ ,  $0 < \theta < 1$ 。一方  $x_1 \in A(m_1)$  に対して  $p(x_1; m) \leq k(m)p(x_1; m_1)$ 。或は  $(m - m_1)(p_m(x_1; m_1 + r(m - m_1)) - p_m(x_0; m_1 + \theta(m - m_1)))/p(x_1; m_1) \leq 0$ ,  $0 < r < 1$ 。故に  $p_m(x_1; m_1) - p(x_1; m_1)/p(x_0; m_1) = 0$ 。(もし左邊  $\neq 0$  ならば, これは  $p_m(x; m)$  の連続性により  $m$  が  $m_1$  に十分近いとき一定符號をもつ。しかるに  $m - m_1$  は正にも負にもなり得るから不合理。) 同様にしてこの等式は  $x_1 \in A(m_1)$  でも成立し従つて任意の  $x$  について  $p_m(x; m_1) = p_m(x_0; m_1)p(x; m_1)/p(x_0; m_1)$ 。又假定 (1°), (iii) 及び

$$(1.01) \quad \int_S p_m(x, m_1) dx = \frac{p_m(x_0, m_1)}{p(x_0, m_1)}$$

によつて  $p_m(x_0; m_1) = 0$  となつて不合理である。

この定理で分る様に  $p_m(x; m)$  が十分正則な性質をもてば 'shortest system of confidence intervals' は存在しないのである。それで最も効果的と考へられる system of confidence intervals の特徴を如何に云表はすかといふことが問題となる。

定義 4.  $0 \leq a \leq 1$  に對する system of confidence intervals の集合  $\{\delta(x)\}$  に於いて,  $\partial P([x; m_1 \in \delta(x)], m)/\partial m_1 = 0$  を満足するものの中,  $\partial^2 P([x; m_1 \in \delta(x)], m)/\partial m^2$  を極小にするものを

short unbiased system of confidence intervals といふ。

以後パラメーターの数を一ケとし、 $p(x; m)$  は次の四条件を満足するものと假定する。

- (1°).  $p(x, m)$  は  $m$  について微分可能。  
 (2°).  $\frac{\partial}{\partial m} \log p$  は  $m$  を如何に定めても  $S$  で恒等的に 0 となることはない。  
 (3°).  $\int_S \left( \frac{\partial}{\partial m} \log p \right)^2 p(x, m) dx < \infty$ .  
 (4°).  $\frac{\partial^2}{\partial m^2} \log p = u(m) + v(m) \frac{\partial}{\partial m} \log p$ .

注意 (4°) は  $x_1, \dots, x_n$  が独立なるとき sufficient estimate が存在するための必要且十分条件である：實際

$$(1.03) \quad p(x; m) = \prod_{i=1}^n f(x_i; m)$$

とおけば  $\partial^2(\log f(x; m))/\partial m^2 = u_0(m) + v_0(m) \partial(\log f(x; m))/\partial m$ .  $\partial(\log f)/\partial m = g$  とかけば  $g_m = u_0 + v_0 g$ .  $\therefore (g_x)_m = v_0 g_x \rightarrow \partial(\log g_x)/\partial m = v_0 \rightarrow g_x = MX \rightarrow g = M_1 X_1 + N_1 \rightarrow \log f = M_1 X_1 + M_2 + X_2 \rightarrow f = \exp(M_1 X_1 + M_2 + X_2) \rightarrow \partial^2 \log f / \partial m^2 = u(m) + v(m) \partial(\log f) / \partial m$ .

次に short unbiased system of confidence intervals の条件は、上の  $p(x; m)$  を使用し次の如くおく。

$$(1.04) \quad \varphi = \left( \frac{\partial}{\partial m} \log p(x; m) \right)_{m=m_1}, \quad \varphi' = \left( \frac{\partial^2}{\partial m^2} \log p(x; m) \right)_{m=m_1}$$

そのとき

- (i).  $\int_{A(m_1)} p(x; m_1) dx = a$ ,  
 (ii).  $\int_{A(m_1)} \varphi p(x; m_1) dx = 0$ ,  
 (iii).  $\int_{A(m_1)} (\varphi' + \varphi^2) p(x; m_1) dx = \text{極小}$  と表はされる。

故に補助定理により  $A(m_1) = [x; \varphi' + \varphi^2 \leq a\varphi + b]$  となる。ここで  $a, b$  は (i), (ii) より定まる常数である。任意の  $m_1$  について上の条件を満足する  $A(m_1)$  が作られたとし、更に  $\sum_{m_1} A(m_1) = S$  が成立したとすれば、これは region of acceptance であり、従つて short unbiased system of confidence intervals が構成されたことになる。

定理 4. 任意の  $m_1$  に対して適當に常数  $a, b$  をとれば  $A(m_1) = [x; \varphi' + \varphi^2 \leq a\varphi + b]$  としたとき

$$(1.05) \quad \int_{A(m_1)} p(x; m_1) dx = a, \quad \int_{A(m_1)} \varphi p(x; m_1) dx = 0$$

證明  $p(x; m) = \exp(M_1(m) + M_2(m) t(x) + S(x))$  とかけば  $\varphi = M_1'(m_1) + M_2'(m_1) t(x)$ . 次に

$$(1.06) \quad \int_S p(x; m) dx = 1$$

の兩邊を  $m$  で微分する。

$$(1.07) \quad \frac{d}{dm} \int_S p(x; m) dx = M_1'(m) + M_2'(m) \int_S t(x) p(x; m) dx = 0$$

もし  $M_2'(m) = 0$  ならば  $M_1'(m) = 0$ . 即ち  $\varphi(x; m) = 0$ . これは假定に反する。故に  $M_2'(m) \neq 0$ . 従つて  $\varphi' + \varphi^2 \leq a\varphi + b$  は  $t \leq a_1 t + b_1$  又は  $t_1 \leq t \leq t_2$  と同値になる。結局  $p(x; m) = p(t; m)$  として

$$(1.08) \quad \int_{t_1}^{t_2} p_1(t, m_1) dt = a, \quad \frac{1}{a} \int_{t_1}^{t_2} t p_1(t, m_1) dt = -\frac{M_1'(m_1)}{M_2'(m_1)}$$

なる様に  $t_1, t_2$  を定めればよいのである。

定理 5.  $A(m_1)$  を定理 4 の如くにとる。

$$(1.09) \quad \int_{B(m_1)} p(x; m_1) dx = a, \quad \int_{B(m_1)} \varphi p(x; m_1) dx = 0$$

を満足する領域  $B(m_1)$  を如何にとつても任意の  $m$  に對して、

$$(1.10) \quad \int_{A(m_1)} p(x; m) dx \leq \int_{B(m_1)} p(x; m) dx.$$

證明

$$(1.11) \quad \int_{B(m_1)} p(x; m) dx = a, \quad \int_{B(m_1)} \varphi p(x; m) dx = 0$$

なる條件の下に

$$(1.12) \quad \int_{B(m_1)} p(x; m) dx$$

を最小ならしめる  $B(m_1)$  即ち  $A(m_1)$  を見出すことが問題であるが、上の二條件を満足する様に常數  $c, d$  を定めて、 $A(m_1) = [x; p(x, m) \leq (c\varphi + d)p(x, m_1)]$  とかければよいことは補助定理から分る。  $P = M_1(m) - M_1(m_1)$ ,  $Q = M_2(m) - M_2(m_1)$  として  $p(x; m) \leq (c\varphi + d)p(x, m_1)$  をかきかへれば  $e^{P+Q(x)} \leq c\varphi + d = c_1(m_1)t(x) + d_1(m_1)$ .  $c, d$  を定めることと  $c_1, d_1$  を定めることは同値なる故、 $(t_1, t_2)$  を定理 4 の如く定めて  $e^{P+Q_1} = c_1 t_1 + d_1$ ,  $e^{P+Q_2} = c_1 t_2 + d_1$  より  $c_1, d_1$  を決定すればよい。しかるに  $y(t) = e^{P+Q} - c_1 t - d_1$  とおけば  $y''(t) = Q^2 e^{P+Q} > 0$ . 従つて  $y(t)$  は  $t_1 < t < t_2$  のとき負となる。(Q.E.D.)

この定理は簡単にいへば short unbiased system of confidence intervals が適當な條件の下では或る意味で shortest なることを主張するものである。適當な條件とは  $\sum_{m_1} A(m_1) = S$  が成立することであり、或る意味で shortest とは

$$(1.12) \quad \int_{B(m_1)} p_m(x; m_1) dx = 0$$

を満足する領域  $B(m_1)$  の中で shortest といふことである。  $\sum_m A(m) = S$  の一つの十分條件を與へるものとして

定理 6. 任意に  $x$  を與へたとき  $M_1'(m_1) + M_2'(m_1)t(x) = 0$  を満足する  $m_1(x)$  が存在するならば  $\sum_m A(m) = S$ .

證明  $x \in S$  に對して上の様に  $m_1$  を定め、 $A(m_1)$  を作れば  $x \in A(m_1)$  となる。それは  $t_1 \leq t(x) \leq t_2$  より明白である。

注意 上定理で定めた  $m_1(x)$  が maximum likelihood estimate である。何者：

$$(1.13) \quad \frac{\partial}{\partial m} p(x; m) = (M_1' + M_2't) p, \quad \frac{\partial^2}{\partial m^2} p = (M_1'' + M_2''t + (M_1' + M_2't)^2) p.$$

故に上定理の  $m_1$  を代入すれば

$$(1.14) \quad \left[ \frac{\partial}{\partial m} p(x, m) \right]_{m=m_1} = 0, \quad \left[ \frac{\partial^2}{\partial m^2} p(x, m) \right]_{m=m_1} = \frac{M_2'' M_2' - M_1' M_2''}{M_2'} < 0.$$

(この関係は  $\int_S (M_1' + M_2' t)^2 p \, dx = -\frac{M_1'' M_2 - M_1' M_2''}{M_2'}$  より出る)

注意  $a$  を如何に與へても  $p(x; m)$  を最大にする様な  $m$  が常に  $\delta(x)$  に含まれることが分る.

---

脚 註

\* 北川敏男：独立確率變數の理論，日本數學物理學會誌，第14卷，240頁，定義 2.1 を参照．以下も同じ形式で上記論文を参照する．