

②③ 系統統計量 (Systemation Statistics)
の理論及びその応用

大阪大学理学部数学教員 小川清次郎

目 次

序	論
第1章	推定論
§ 1	正規不偏推定値
§ 2	線形不偏推定値と最小自乗法に関する <i>A. Markoff</i> の定理
§ 3	順序づけ統計量とその極限分布、系統統計量
§ 4	系統統計量の効率
§ 5	系統統計量を用いた場合の正規母集団の平均値と標準偏差の最良線形不偏推定値
§ 6	正規母集団の平均値及び標準偏差を推定するための最良配置の決定
第2章	仮説検定論
§ 7	一般線形仮説の検定
§ 8	系統統計量を用いた場合の正規母集団に関する統計的仮説の検定
§ 9	検定力函数と最適検定を与える配置
第3章	応用
§ 10	枚層死亡率曲線
§ 11	時間死亡率曲線
§ 12	住宅の耐用年限の推定

所謂統計的推定論の根本的な思想は標本の含む未知母数に關する有益な情報 (*Relevant Information*) を最大限に汲み出そうとするものである。⁽¹⁾ その上限を与えるものが報知高 (*Amount of Information*) である。そしてこのためには有効推定値⁽²⁾ (*Efficient Estimate*) が用いられる。このような立場の基礎は標本の大きさを増す費用が計算の費用に比較して著しく大なる場合であつて、競争試験における資料とか医学における臨床的例を取り扱う様な場合である。

しかし現実には吾々の岩会う場合には、これと反対の事情のことも屢々ある。例之は教育統計ほどの場合には、標本を増やすことが非常に簡単である。このような場合には推定値自身は有効推定値ではなくとも、標本の大きさが必要な丈大とすることによつて、推定精度を高めることが出来る。又非常に膨大な資料があるとき、その平均値は、標準偏差は、或程度粗くともよいから迅速に知り度いということもある。

このような場合現今では分類法 (*Counting Soughter*) が利用出来るから如何に膨大な資料といへども簡単に順序づけが出来るという点は着目して順序づけ統計量又は、その函数である系統統計量 (*Systematic Statistics*) の利用を提唱したのは *Frederick Mosteller* であつた。

Mosteller はその學位論文⁽³⁾で正規母集団の平均値、標準偏差、相関係数の系統統計量による推定を考察してその相対効率を最大はらしめるような順序づけ統計量の決定を向題とした。其後山内二郎教授⁽⁴⁾は正規母集団の平均値及び標準偏差の順序づけ統計量の一次適合による推定を取り扱ひ *Mosteller* よりも著しく高い効率を与えた。

本論文の目的は正規母集団の平均値及び標準偏差の推定はもとこれらに關する統計的假説の検定を系統統計量を用いて行う場合を最も一般的立場から考察することである。

更にその応用として数量死亡率曲線 (Gosage Mortality Curve) 及び時間死亡率曲線 (Time-Mortality Curve) における母数の推定及び仮説検定について述べ、最後に住宅の平均耐用年限の推定について述べる。

本論文を草するに当つて、亦6.1. 6.2. 6.3. 6.4. 6.5. 6.6 表の計算を担当されたのは宮本良雄氏、著者は有益な助言を寄せられた山内二郎教授、増山元三郎博士、大阪市立大学の大沢清氏、統数研の鍋谷清治氏及び文献の筆字に当られた統数研の諸氏特に塩原由郎、藤本悠の両氏に深く感謝する。

第 1 章 推 定 論

本章では系統統計量を用いた場合の正規母集団の母数の推定について述べるのであるが、§1及び§2では統計的推定の一般論からの結果で後に必要なものを摘録しておく。

§1. 正規不偏推定値

説明を簡単ならしめるため、考える母集団分布は連続型（連続な密度函数をもつ）としておくが、以下に述べる試論は必要は修正を加えれば離散型分布の母集団にも適用されることは勿論である。

推定するべき母数が一つの場合と二つの場合を考える（三つ以上の場合も二つの場合と平行に論じられるが吾々は今これを必要としぬ）

1. 推定するべき未知母数 α が一つの場合

母集団の密度函数を $f(x; \alpha)$ とし、この函数型は既知とする。未知母数 α の考察範囲はある区間 A とする。

この母集団から無作為に抽出された大きさ n の任意標本 x_1, x_2, \dots, x_n から計算される統計量

$$\alpha^* = \alpha^*(x_1, x_2, \dots, x_n)$$

が以下に述べる条件 1° 2° を満たすとき、これを α の正規推定値 (Regular Estimate) とする。

1° 変数変換

$$\begin{aligned} \alpha^* &= \alpha^*(x_1, x_2, \dots, x_n) \\ \xi_i &= \xi_i(x_1, x_2, \dots, x_n) \end{aligned} \quad (1.1)$$

$$\xi_{n-1} = \xi_{n-1}(x_1, x_2, \dots, x_n)$$

が次の条件 (a), (b) を満たすように新しい変数 $\alpha^*, \xi_1, \dots, \xi_{n-1}$ を選ぶことが出来る。

(a) $\alpha^*(x_1, \dots, x_n), \xi_1(x_1, \dots, x_n), \dots, \xi_{n-1}(x_1, \dots, x_n)$ は到一任意連続な函数で、又殆んど別

$$\frac{\partial \alpha^*}{\partial x_i}, \frac{\partial \xi_j}{\partial x_i}; \quad i = 1, 2, \dots, n; j = 1, 2, \dots, n-1$$

が存在して且連続である。

(b) 変換 (1.1) は殆んど到 への値向きにも一意的である。

よって変換 (1.1) の Jacobian を

$$J = \frac{\partial(x_1, x_2, \dots, x_n)}{\partial(\alpha^*, \xi_1, \dots, \xi_{m-1})}$$

とすれば、それは殆んど到 での 0 でない。

$$\begin{aligned} & f(x_1; \alpha) \dots f(x_n; \alpha) dx_1 \dots dx_n \\ &= f(x_1; \alpha) \dots f(x_n; \alpha) |J| d\alpha^* d\xi_1 \dots d\xi_{m-1} \end{aligned} \quad (1.2)$$

であるが、今ここで、 α^* の周辺分布の密度を $g(\alpha^*; \alpha)$ 、 α^* を固定し
はときの ξ_1, \dots, ξ_{m-1} の条件付分布の密度を $h(\xi_1, \dots, \xi_{m-1} | \alpha^*; \alpha)$

とすれば

$$\begin{aligned} & f(x_1; \alpha) \dots f(x_n; \alpha) dx_1 \dots dx_n \\ &= g(\alpha^*; \alpha) h(\xi_1, \dots, \xi_{m-1} | \alpha^*; \alpha) d\alpha^* d\xi_1 \dots d\xi_{m-1} \end{aligned} \quad (1.3)$$

(1.2) と (1.3) から

$$f(x_1; \alpha) \dots f(x_n; \alpha) |J| = g(\alpha^*; \alpha) h(\xi_1, \dots, \xi_{m-1} | \alpha^*; \alpha) \quad (1.4)$$

が殆んどすべての (x_1, \dots, x_n) 、 α^* 、 ξ_1, \dots, ξ_{m-1} に対して区
間 A の各点 α で

$$\frac{\partial f}{\partial \alpha}, \quad \frac{\partial g}{\partial \alpha}, \quad \frac{\partial h}{\partial \alpha}$$

が存在して、且つ、

$$\left| \frac{\partial f}{\partial \alpha} \right| < F_0(x), \quad \left| \frac{\partial g}{\partial \alpha} \right| < G_0(\alpha^*), \quad \left| \frac{\partial h}{\partial \alpha} \right| < H_0(\xi_1, \dots, \xi_{m-1} | \alpha^*) \quad (1.5)$$

ここで

$$F_0(x), G_0(\alpha^*), \alpha^* G_0(\alpha^*), H_0(\xi_1, \dots, \xi_{m-1} | \alpha^*)$$

は α に無関係で夫々 $x, \alpha^*, \xi_1, \dots, \xi_{m-1}$ についてそれらの全区
間で積分可能である。

これは例えば、

$$\frac{\partial}{\partial \alpha} \int_{-\infty}^{\infty} f(x; \alpha) dx = \int_{-\infty}^{\infty} \frac{\partial}{\partial \alpha} f(x; \alpha) dx$$

を保證する条件である。

以下考える推定値はすべて正則なものに限るのであるが特に各々

が必要なのは不偏推定値 (Unbiased Estimate) である。これは

$$\int_{-\infty}^{\infty} \alpha^* g(\alpha^*; \alpha) d\alpha^* = \alpha \quad (1.6)$$

がすべての α について成立つようなものである。

正則性条件から

$$\int_{-\infty}^{\infty} \alpha^* \frac{\partial g(\alpha^*; \alpha)}{\partial \alpha} d\alpha^* = 1 \quad (1.7)$$

又勿論

$$\int_{-\infty}^{\infty} g(\alpha^*; \alpha) d\alpha^* = 1$$

であるから

$$\int_{-\infty}^{\infty} \frac{\partial g(\alpha^*; \alpha)}{\partial \alpha} d\alpha^* = 0 \quad (1.8)$$

(1.7) と (1.8) から

$$\int_{-\infty}^{\infty} (\alpha^* - \alpha) \frac{\partial g(\alpha^*; \alpha)}{\partial \alpha} d\alpha^* = 1$$

又は

$$\int_{-\infty}^{\infty} (\alpha^* - \alpha) \sqrt{g(\alpha^*; \alpha)} \cdot \frac{1}{\sqrt{g(\alpha^*; \alpha)}} \frac{\partial g(\alpha^*; \alpha)}{\partial \alpha} d\alpha^* = 1$$

として Schwarz の不等式を用いると

$$1 \leq D^2(\alpha^*) \cdot E \left(\frac{\partial \log g(\alpha^*; \alpha)}{\partial \alpha} \right)^2$$

よつて

$$D^2(\alpha^*) \geq \frac{1}{E \left(\frac{\partial \log g(\alpha^*; \alpha)}{\partial \alpha} \right)^2} \quad (1.9)$$

を得るが、更に (1.4) から

$$n E \left(\frac{\partial \log f(x; \alpha)}{\partial \alpha} \right)^2 = E \left(\frac{\partial \log g}{\partial \alpha} \right)^2 + E \left(\frac{\partial \log h}{\partial \alpha} \right)^2 \quad (1.10)$$

であるから不偏推定値については

$$D^2(\alpha^*) \geq \frac{1}{n E \left(\frac{\partial \log f}{\partial \alpha} \right)^2} \quad (1.11)$$

を得る.

若し更に $\int_{-\infty}^{\infty} \frac{\partial f}{\partial \alpha} dx = 0$ が積分記号下で積分出来るならば

$$\int_{-\infty}^{\infty} \frac{\partial^2 f}{\partial \alpha^2} dx = 0$$

だから

$$E\left(\frac{\partial^2 \log f}{\partial \alpha^2}\right) = E\left(-\frac{1}{f^2} \left(\frac{\partial f}{\partial \alpha}\right)^2 + \frac{1}{f} \frac{\partial^2 f}{\partial \alpha^2}\right) = -E\left(\frac{\partial \log f}{\partial \alpha}\right)^2$$

であるから (1.11) は

$$D^2(\alpha^*) \geq \frac{1}{-E\left(\frac{\partial^2 \log f}{\partial \alpha^2}\right)} \quad (1.11')$$

としてよい.

吾々は H. Cramér に従って、任意の不偏推定値 α^* の効率 (Efficiency) $e(\alpha^*)$ を

$$e(\alpha^*) = \frac{1}{D^2(\alpha^*) \cdot mE\left(\frac{\partial \log f}{\partial \alpha}\right)^2} \quad (1.12)$$

で定義し、特に $e(\alpha^*) = 1$ のとき α^* を α の 有効推定値 (Efficient Estimate) と名づける.

$D^2(\alpha^*)$ が存在しはしむとき、若し $n \rightarrow \infty$ のときは $D(\alpha^*)$ の $\frac{c}{\sqrt{n}}$ はらば

$$e_0(\alpha^*) = \frac{1}{c^2 E\left(\frac{\partial \log f}{\partial \alpha}\right)^2} \quad (1.13)$$

によつて α^* の 漸近的効率 (Asymptotic Efficiency) を定義し、

$e_0(\alpha^*) = 1$ のとき α^* は α の 漸近的有効推定値 (Asymptotically Efficient Estimate) とする.

$mE\left(\frac{\partial \log f}{\partial \alpha}\right)^2$ を 報知量 (Amount of Information) と名づける、これは f の函数型が与えられる限り母数 α に関する情報の限度を与之ねものである.

正規母集団

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

のときは

$$\frac{\partial \log f}{\partial m} = x - m$$

であるから、 μ の報知高は

$$nE\left(\frac{\partial \log f}{\partial \mu}\right)^2 = n \quad (1.14)$$

よって不偏推定値の分散の下限は

$$\frac{1}{n}$$

であるから $\alpha^* = \bar{x}$ は有効推定値である。

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

のときは

$$\begin{aligned} \frac{\partial \log f}{\partial \sigma} &= -\frac{1}{\sigma} + \frac{x^2}{\sigma^3} \\ E\left(\frac{\partial \log f}{\partial \sigma}\right)^2 &= \frac{1}{\sigma^2} - \alpha \frac{1}{\sigma^4} E(x^2) + \frac{1}{\sigma^6} E(x^4) \\ &= \frac{1}{\sigma^2} \end{aligned}$$

であるから報知高は

$$\frac{2n\sigma^2}{\sigma^2}$$

(1.15)

よって不偏推定値の分散の下限は

$$\frac{\sigma^2}{2n}$$

である。今

$$S_0^2 = \frac{1}{n} \sum_{i=1}^n x_i^2$$

とすれば nS_0^2/σ^2 は自由度 n の χ^2 分布に従うから

$$\frac{n^{\frac{n}{2}}}{2^{\frac{n-2}{2}} \sigma^n \Gamma(\frac{n}{2})} e^{-\frac{nS_0^2}{2\sigma^2}} S_0^{n-1} dS_0$$

よって

$$\sigma^* = \sqrt{\frac{n}{2}} \frac{\Gamma(\frac{n}{2})}{\Gamma(\frac{n+1}{2})} S_0$$

は σ の不偏推定値であるが、このときは

$$D^2(\sigma^*) = \left(\frac{n}{2} \frac{\Gamma^2(\frac{n}{2})}{\Gamma^2(\frac{n+1}{2})} - 1 \right) \sigma^2 = \frac{\sigma^2}{2n} + O\left(\frac{1}{n^2}\right)$$

よって σ^* は σ の漸近的に有効推定値である。

□ 推定すべき未知母数が \$n\$ の場合. 母集団の密度関数を \$f(x; \alpha, \beta)\$ とし \$f\$ の函数型は既知とする.

大きさ \$n\$ の任意標本 \$x_1, x_2, \dots, x_n\$ から計算される \$\alpha, \beta\$ の推定値 \$\alpha^*(x_1, \dots, x_n), \beta^*(x_1, \dots, x_n)\$ が次の条件 1°, 2° を満たすとき、これを正則推定値という.

1°, \$m-2\$ 箇の変数 \$\xi_1(x_1, \dots, x_n), \dots, \xi_{m-2}(x_1, \dots, x_n)\$ を適当に選べば変換

$$\begin{aligned} \alpha^* &= \alpha^*(x_1, \dots, x_n) \\ \beta^* &= \beta^*(x_1, \dots, x_n) \\ \xi_1 &= \xi_1(x_1, \dots, x_n) \\ &\dots \\ \xi_{m-2} &= \xi_{m-2}(x_1, \dots, x_n) \end{aligned}$$

は到る処一意的連続で、又殆んど到処で

$$\frac{\partial \alpha^*}{\partial x_i}, \frac{\partial \beta^*}{\partial x_i}, \frac{\partial \xi_j}{\partial x_i}, \quad i=1, 2, \dots, n; \quad j=1, 2, \dots, m-2$$

が存在して連続である。又変換 (1.16) は殆んど到処で逆用可能で一意的である。

よって Jacobian

$$J = \frac{\partial(x_1, x_2, \dots, x_n)}{\partial(\alpha^*, \beta^*, \xi_1, \dots, \xi_{m-2})}$$

は殆んど到処で 0 にはならないから

$$\begin{aligned} &\prod_{i=1}^n f(x_i; \alpha, \beta) \cdot dx_1 \dots dx_n \\ &= \prod_{i=1}^n f(x_i; \alpha, \beta) \cdot |J| d\alpha^* d\beta^* d\xi_1 \dots d\xi_{m-2} \quad (1.17) \\ &\equiv g(\alpha^*, \beta^*; \alpha, \beta) h(\xi_1, \dots, \xi_{m-2} | \alpha^*, \beta^*; \alpha, \beta) d\alpha^* d\beta^* d\xi_1 \dots d\xi_{m-2} \end{aligned}$$

但しここで \$g(\alpha^*, \beta^*; \alpha, \beta)\$ は \$\alpha^*, \beta^*\$ の同時分布の密度関数で、\$h(\xi_1, \dots, \xi_{m-2} | \alpha^*, \beta^*; \alpha, \beta)\$ は \$\alpha^*, \beta^*\$ を固定したときの \$\xi_1, \dots, \xi_{m-2}\$ の条件付分布の密度関数である。

2°. 殆んどすべての \$x_1, x_2, \dots, x_n, \alpha^*, \beta^*, \xi_1, \dots, \xi_{m-2}\$ に対し

を考ふるすべしとの α, β に対して

$$\frac{\partial f}{\partial \alpha}, \frac{\partial f}{\partial \beta}, \frac{\partial g}{\partial \alpha}, \frac{\partial g}{\partial \beta}, \frac{\partial h}{\partial \alpha}, \frac{\partial h}{\partial \beta}$$

が存在して且つ

$$\left| \frac{\partial f}{\partial \alpha} \right| < F_1(x), \quad \left| \frac{\partial f}{\partial \beta} \right| < F_2(x)$$

$$\left| \frac{\partial g}{\partial \alpha} \right| < G_1(\alpha^*, \beta^*), \quad \left| \frac{\partial g}{\partial \beta} \right| < G_2(\alpha^*, \beta^*)$$

$$\left| \frac{\partial h}{\partial \alpha} \right| < H_1(\xi_1, \dots, \xi_{n-2} | \alpha^*, \beta^*), \quad \left| \frac{\partial h}{\partial \beta} \right| < H_2(\xi_1, \dots, \xi_{n-2} | \alpha^*, \beta^*)$$

であつて

$$F_1(x), F_2(x)$$

$$G_1(\alpha^*, \beta^*), G_2(\alpha^*, \beta^*)$$

$$\alpha^* G_1, \beta^* G_1, \alpha^* G_2, \beta^* G_2$$

$$H_1(\xi_1, \dots, \xi_{n-2} | \alpha^*, \beta^*), H_2(\xi_1, \dots, \xi_{n-2} | \alpha^*, \beta^*)$$

は α, β に無関係で、その変数の全空間で積分可能である。

この場合大切な結果は次の通りである。

α, β の同時的不偏推定値 α^*, β^* の集中度楕円 (Ellipse Concentration)

$$\frac{1}{1-\rho^2} \left\{ \frac{(u-\alpha)^2}{\sigma_1^2} - 2\rho \frac{(u-\alpha)(v-\beta)}{\sigma_1 \sigma_2} + \frac{(v-\beta)^2}{\sigma_2^2} \right\} = 4 \quad (1.18)$$

$$\sigma_1^2 \equiv D^2(\alpha^*), \sigma_2^2 \equiv D^2(\beta^*), \sigma_1 \sigma_2 \rho \equiv E(\alpha^* - \alpha)(\beta^* - \beta)$$

はつねに定楕円

$$m \left[E \left(\frac{\partial \log f}{\partial \alpha} \right)^2 (u-\alpha)^2 + 2E \left(\frac{\partial \log f}{\partial \alpha}, \frac{\partial \log f}{\partial \beta} \right) (u-\alpha)(v-\beta) + E \left(\frac{\partial \log f}{\partial \beta} \right)^2 (v-\beta)^2 \right] = 4 \quad (1.19)$$

と其内部を含む

よつて

$$m \left[E \left(\frac{\partial \log f}{\partial \alpha} \right)^2 (u-\alpha)^2 + 2E \left(\frac{\partial \log f}{\partial \alpha}, \frac{\partial \log f}{\partial \beta} \right) (u-\alpha)(v-\beta) + E \left(\frac{\partial \log f}{\partial \beta} \right)^2 (v-\beta)^2 \right]$$

$$\geq \frac{1}{1-\rho^2} \left[\frac{(u-\alpha)^2}{\sigma_1^2} - 2\rho \frac{(u-\alpha)(v-\beta)}{\sigma_1\sigma_2} + \frac{(v-\beta)^2}{\sigma_2^2} \right] \quad (1.20)$$

よつて面積を比較して

$$\Delta \equiv E \left(\frac{\partial \log f}{\partial \alpha} \right)^2 E \left(\frac{\partial \log f}{\partial \beta} \right)^2 - E^2 \left(\frac{\partial \log f}{\partial \alpha} \frac{\partial \log f}{\partial \beta} \right)$$

とすれば

$$n^2 \Delta \geq \frac{1}{\sigma_1^2 \sigma_2^2 (1-\rho^2)}$$

であるが、 α^*, β^* の効率を

$$e(\alpha^*, \beta^*) = \frac{1}{n^2 \Delta \sigma_1^2 \sigma_2^2 (1-\rho^2)} \quad (1.21)$$

で定義する。今度は (1.20) で等号の成立するとき α^*, β^* は α, β の同時的有効推定値 (Jointly Efficient Estimate) といふこのときは勿論

$$e(\alpha^*, \beta^*) = 1$$

である。

今 α_0^*, β_0^* を α, β の一組の同時的有効推定値とすれば、定義より、

$$D^2(\alpha_0^*) = \frac{1}{n\Delta} E \left(\frac{\partial \log f}{\partial \alpha} \right)^2, \quad D^2(\beta_0^*) = \frac{1}{n\Delta} E \left(\frac{\partial \log f}{\partial \beta} \right)^2 \quad (1.22)$$

$$\rho(\alpha_0^*, \beta_0^*) = E \left(\frac{\partial \log f}{\partial \alpha} \frac{\partial \log f}{\partial \beta} \right) / \sqrt{E \left(\frac{\partial \log f}{\partial \alpha} \right)^2 E \left(\frac{\partial \log f}{\partial \beta} \right)^2}$$

よつて

$$D^2(\alpha_0^*) = \frac{1}{1-\rho^2(\alpha_0^*, \beta_0^*)} \frac{1}{nE \left(\frac{\partial \log f}{\partial \alpha} \right)^2} \quad (1.23)$$

(1.23) から判ることは $\rho(\alpha_0^*, \beta_0^*) \neq 0$ なる限り、同時的有効推定値の分散は、例えば α のみ未知母数である場合の有効推定値の分散より大である。

然らば一組の不偏推定値 α^*, β^* をとつて β^* の精度は u くらゐくともよ u から、 α^* の精度を α_0^* のそれより良くすることが出来るかといふのは不可能である。何者 (1.20) は任意の不偏推定値に対して成り立つから

$$D^2(\alpha^*) \equiv \sigma_1^2 \geq \frac{1}{n\Delta} E \left(\frac{\partial \log f}{\partial \alpha} \right)^2 \equiv D^2(\alpha_0^*)$$

きあるから

以上では x_1, \dots, x_n を任意標本として話ししたのであるが x_1, \dots, x_n の同時分布の密度函数が

$$f(x_1, \dots, x_n; \alpha, \beta) = f(x_1, \dots, x_n; \alpha, \beta)$$

のときにも同様の理論が成立つ。

例えば $f(x_1, \dots, x_n; \alpha)$ のときは

$$D^2(\alpha^*) \geq \frac{1}{E\left(\frac{\partial \log f}{\partial \alpha}\right)^2} \quad (1.24)$$

とほつて n がはくはる式である。

正規分布

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

のときは

$$\begin{aligned} \frac{\partial \log f}{\partial m} &= \frac{1}{\sigma^2}(x-m) \\ \frac{\partial \log f}{\partial \sigma} &= \frac{1}{\sigma} - \frac{(x-m)^2}{\sigma^3} \end{aligned}$$

よつて

$$E\left(\frac{\partial \log f}{\partial m}\right)^2 = \frac{1}{\sigma^2} \quad E\left(\frac{\partial \log f}{\partial \sigma}\right)^2 = \frac{2}{\sigma^2}$$

$$E\left(\frac{\partial \log f}{\partial m} \cdot \frac{\partial \log f}{\partial \sigma}\right) = 0$$

$$\Delta = \frac{2}{\sigma^4}$$

従つて Δ のときの告知高は

$$\frac{2m^2}{\sigma^4}$$

(1.25)

$$m^* = \bar{x} \quad \sigma^* = \sqrt{\frac{n}{2}} \frac{\Gamma\left(\frac{n-1}{2}\right)}{\Gamma\left(\frac{n}{2}\right)} s$$

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

とおくと

$$D^2(m^*) = \frac{\sigma^2}{n} \quad D^2(\sigma^*) = \left(\frac{n-1}{2} \frac{\Gamma^2\left(\frac{n-1}{2}\right)}{\Gamma^2\left(\frac{n}{2}\right)} - 1\right) \sigma^2$$

$$\rho(m^*, \sigma^*) = 0 = \frac{\sigma^2}{2n} + O\left(\frac{1}{n^2}\right)$$

であるから $n \rightarrow \infty$ のとき

$$e(m^*, \sigma^*) \rightarrow 1$$

即ち m^*, σ^* は m, σ の漸近的に有効推定値である。

§ 2. 最良線型不偏推定値と最小自乗法に関する *a. Markoff* の定理

母数 α の推定値 $\alpha^*(x_1, \dots, x_n)$ が次の三条件を満たすものを、吾々は *J. Neyman* に従って、 α の最良線型不偏推定値 (*The Best Linear Unbiased Estimate*) と名づける。

(1) $\alpha^*(x_1, \dots, x_n)$ は任意標本 x_1, \dots, x_n の一次形式である。

(2) $\alpha^*(x_1, \dots, x_n)$ は α の不偏推定値である。即ち

$$E(\alpha^*) = \alpha$$

(3) $\alpha^*(x_1, \dots, x_n)$ は (1) 及び (2) を満たすものの中で最小の分散をもつ。

このような推定値 $\alpha^*(x_1, \dots, x_n)$ は計算が簡便である上に、 n が充分大なるときは中心極限定理によつて漸近的に正規分布に従うのでよく用いられるものである。

このような最良線型不偏推定値を求める方法を提供するものとして *a. Markoff* の定理がある。

定理 2.1 (*J. Neyman* 及び *F. N. David* による拡張)

(i) x_1, x_2, \dots, x_n は互に独立の確率変数とする。

(ii) x_1, x_2, \dots, x_n の平均値は夫々約 ($\leq n$) 箇の未知定数 $\theta_1, \theta_2, \dots, \theta_s$ の一次形式である。

$$E(x_i) \equiv m_i = a_{i1}\theta_1 + a_{i2}\theta_2 + \dots + a_{is}\theta_s \quad i=1, 2, \dots, n \quad (2.1)$$

ここで係数 a_{ij} は既知定数である。

(iii) 係数行列

$$A = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1s} \\ a_{21} & a_{22} & \dots & a_{2s} \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{ns} \end{pmatrix} \quad (2.2)$$

の階数は s である。

(iv) 分散はついでに

$$D^2(x_i) \equiv \sigma_i^2 = \frac{\sigma^2}{\rho_i}, \quad i=1, 2, \dots, n \quad (2.3)$$

で、 ρ_i は既知、 σ^2 は未知の定数である。

以上の4条件の下で未知量

$$b_1\theta_1 + b_2\theta_2 + \dots + b_s\theta_s \quad \text{但し } b_i \text{ は既知} \quad (2.4)$$

の最良線型不偏推定値 F は次のようにして求められる。

今、

$$S = \sum_{i=1}^n \rho_i (x_i - a_{i1}\theta_1 - a_{i2}\theta_2 - \dots - a_{is}\theta_s)^2 \quad (2.5)$$

として、 x_1, x_2, \dots, x_n は与えられたとし S を最小にする $\theta_1, \theta_2, \dots, \theta_s$ の値を夫々

$$\theta_1^0(x_1, \dots, x_n), \quad \theta_s^0(x_1, \dots, x_n)$$

とすれば

$$F = b_1\theta_1^0 + b_2\theta_2^0 + \dots + b_s\theta_s^0 \quad (2.6)$$

である。

更に S の最小値を S_0 とすれば

$$S_0 = \sum_{i=1}^n \rho_i (x_i - a_{i1}\theta_1^0 - a_{i2}\theta_2^0 - \dots - a_{is}\theta_s^0)^2 \quad (2.7)$$

であるが

$$\frac{S_0}{n-s} \quad (2.8)$$

が、 σ^2 の不偏推定値になる。

後に吾々が用いる便宜のためには、これをもう少し拡張して次の形に返しておく方がよい。

定理 2.2 (増山による拡張)

(i) x_1, x_2, \dots, x_n は平均値が夫々 $\mu_1, \mu_2, \dots, \mu_m$ で、その Variance-Covariance Matrix が

$$(\sigma^2 d_{ij}), \quad i, j = 1, 2, \dots, m \quad (2.9)$$

なる Non-Singular な m 次元分布に従うものとする。但し、 d_{ij} は既知で、 σ^2 は未知な定数とする。

(ii) 平均値 $\mu_i, i=1, 2, \dots, m$ は夫々 s ($\leq m$) 種の未知定数 $\theta_1, \theta_2, \dots, \theta_s$ の一次形式で

$$\mu_i = a_{i1}\theta_1 + a_{i2}\theta_2 + \dots + a_{is}\theta_s, \quad i=1, 2, \dots, n. \quad (2.10)$$

2.1 で係数 a_{ij} は既知定数である。

(iii) 係数行列 $A = (a_{ij})$ の階数は s である。

$$(iv) \quad (d_{ij})^{-1} = (D_{ij})$$

以上の 4 条件の下で未知量 (2.4) の最良線型不偏推定値 (2.6) は次のように求められる。

$$S = \sum_{i=1}^n \sum_{j=1}^m \left(D_{ij} \left(x_{ij} - \sum_{\alpha=1}^s a_{i\alpha} \theta_{\alpha} \right) \left(x_{ij} - \sum_{\beta=1}^s a_{j\beta} \theta_{\beta} \right) \right) \quad (2.11)$$

として、 S を最小はらしめる θ_i の値を θ_i^0 としてこれを用いて (2.6) を作ればよい。

そして S の最小値を S_0 とするとき

$$\frac{S_0}{n-s}$$

が θ_i^0 の不偏推定値はける。

§ 3. 順序つけ統計量とその極限分布. 系統統計量

任意標本を x_1, x_2, \dots, x_n とかきこれを大きさの順に並べた順序つけ統計量を小さい方から始めて $x(1), x(2), \dots, x(n)$ と書くとする。

考える母集団の確率分布は連続型として、その密度函数を $g(x)$ とする。

さて任意に与えられる実数

$$0 < \lambda < 1$$

に対して

$$\int_{-\infty}^{x_{\lambda}} g(t) dt = \lambda \quad (3.1)$$

となる点 x_{λ} を母集団の λ -分点、又は 100λ% 点 と名づける。

$\lambda = 0.5$ はら $x_{0.5}$ は即ち中央値 (Median) である。

簡単のためは $n\lambda$ は整数ではうとして、

$$Z_{\lambda} = x([n\lambda] + 1) \quad (3.2)$$

を標本の λ 分点と名づける、但し $[n\lambda]$ は Gauss の記号である。

とし $g(x)$ が $x=x_i$ の近傍で微分可能を要す

$$g(x_i) = 0 \quad (3.3)$$

ならば、次の定理が成り立つ:

定理 3.1 統計量

$$\sqrt{\frac{n}{\lambda(1-\lambda)}} \cdot g(x_i) \cdot (Z_i - x_i) \quad (3.4)$$

は $n \rightarrow \infty$ のとき漸近的に標準正規分布 $N(0, 1)$ に従う。即ち $n \rightarrow \infty$ のとき Z_i の極限分布の密度函数は

$$\sqrt{\frac{n}{2\pi\lambda(1-\lambda)}} \cdot g(x_i) \exp\left\{-\frac{n}{2\lambda(1-\lambda)} g^2(x_i)(Z_i - x_i)^2\right\} \quad (3.5)$$

となる。

これを拡張して次の定理が成立す

定理 3.2 (Frederick Mosteller) k 箇の累積

$$0 < \lambda_1 < \lambda_2 < \dots < \lambda_k < 1$$

が与えられるとき母集団の λ_i 分層を x_i とする。

$$\int_{-\infty}^{x_i} g(t) dt = \lambda_i \quad i=1, 2, \dots, k \quad (3.6)$$

母集団の密度函数 $g(x)$ は $x=x_i$ の近傍で微分可能を要す

$$g_i = g(x_i) \neq 0 \quad i=1, 2, \dots, k \quad (3.7)$$

とする。このとき

$$m_i = [n\lambda_i] + 1 \quad i=1, 2, \dots, k$$

とすれば、 k 箇の順序づけ統計量 $X(m_1), X(m_2), \dots, X(m_k)$ の同時分布は $n \rightarrow \infty$ のとき、平均が夫々 x_1, x_2, \dots, x_k であるその

Variance-Covariance Matrix が

$$\begin{bmatrix} \frac{\lambda_1(1-\lambda_1)}{ng_1^2} & \frac{\lambda_1(1-\lambda_2)}{ng_1g_2} & \frac{\lambda_1(1-\lambda_k)}{ng_1g_k} \\ \frac{\lambda_1(1-\lambda_1)}{ng_1g_2} & \frac{\lambda_2(1-\lambda_2)}{ng_2^2} & \frac{\lambda_2(1-\lambda_k)}{ng_2g_k} \\ \frac{\lambda_1(1-\lambda_k)}{ng_1g_k} & \frac{\lambda_2(1-\lambda_k)}{ng_2g_k} & \frac{\lambda_k(1-\lambda_k)}{ng_k^2} \end{bmatrix} \quad (3.8)$$

なる多元正規分布に漸近する。従つて極限分布の密度は

$$\begin{aligned}
 & (2\pi)^{-\frac{k}{2}} g_1 \cdots g_k [\lambda_1(\lambda_2 - \lambda_1) \cdots (1 - \lambda_k)]^{-\frac{1}{2}} m^{\frac{k}{2}} \\
 & \exp \left\{ -\frac{\pi}{2} \left[\sum_{i=1}^k \frac{\lambda_{i+1} - \lambda_{i-1}}{(\lambda_{i+1} - \lambda_i)(\lambda_i - \lambda_{i-1})} g_i^2 (x(n_i) - \lambda_i)^2 \right. \right. \\
 & \quad \left. \left. - 2 \sum_{i=2}^k \frac{g_i g_{i-1}}{\lambda_i - \lambda_{i-1}} (x(n_i) - \lambda_i)(x(n_{i-1}) - \lambda_{i-1}) \right] \right\} \quad (3.9)
 \end{aligned}$$

とほる.

特に母集団が正規母集団 $N(m, \sigma)$ ときは

$$g(x) = (2\pi\sigma^2)^{-\frac{1}{2}} \exp \left\{ -\frac{(x-m)^2}{2\sigma^2} \right\} \quad (3.10)$$

標準正規分布の密度函数を

$$f(x) \equiv (2\pi)^{-\frac{1}{2}} \exp \left\{ -\frac{x^2}{2} \right\} \quad (3.11)$$

とおく. 標準正規母集団の λ_i 分点を u_i との点の Ordinate を f_i とする即ち

$$\begin{aligned}
 & \int_{-\infty}^{u_i} f(t) dt = \lambda_i \\
 & f(u_i) \equiv f_i \quad i=1, 2, \dots, k \quad (3.12)
 \end{aligned}$$

(3.6) は

$$\int_{-\infty}^{\frac{x_i - m}{\sigma}} f(t) dt = \lambda_i$$

と書きかえるから (3.12) と比較して

$$x_i = m + u_i \sigma \quad i=1, 2, \dots, k \quad (3.13)$$

よつて, z の場合には, $x(n_1), x(n_2), \dots, x(n_k)$ の極限分布の密度函数は,

$$\begin{aligned}
 & h(x(n_1), \dots, x(n_k); m, \sigma) \equiv \\
 & (2\pi\sigma^2)^{-\frac{k}{2}} f_1 \cdots f_k [\lambda_1(\lambda_2 - \lambda_1) \cdots (1 - \lambda_k)]^{-\frac{1}{2}} m^{\frac{k}{2}} \\
 & \exp \left\{ -\frac{\pi}{2\sigma^2} \left[\sum_{i=1}^k \frac{\lambda_{i+1} - \lambda_{i-1}}{(\lambda_{i+1} - \lambda_i)(\lambda_i - \lambda_{i-1})} f_i^2 (x(n_i) - m - u_i \sigma)^2 \right. \right. \\
 & \quad \left. \left. - 2 \sum_{i=2}^k \frac{f_i f_{i-1}}{\lambda_i - \lambda_{i-1}} (x(n_i) - m - u_i \sigma)(x(n_{i-1}) - m - u_{i-1} \sigma) \right] \right\} \quad (3.14)
 \end{aligned}$$

とほる.

J. Mosteller は一般に順序づけ統計量 $x(1), x(2), \dots, x(n)$ の函数である統計量を系統統計量 (Systematic Statistics) と名づけた。吾々が以下で用いようというのは $x(m_1), x(m_2), \dots, x(m_k)$ の函数としての系統統計量である。

§ 4. 系統統計量の効率

吾々は以下では大標本理論を考へ、目づき集団は正規母集団とするから $x(m_1), x(m_2), \dots, x(m_k)$ の同時分布の密度はつねに (3.14) で与えられるものとする。

本節では系統統計量を用いて m, σ を推定する場合の効率を考えよう。先づ系統統計量を用いる場合の m, σ の報知高を求めよう。

1. σ が既知の場合

$$S = \sum_{i=1}^k \frac{\lambda_{i+1} - \lambda_{i-1}}{(\lambda_{i+1} - \lambda_i)(\lambda_i - \lambda_{i-1})} \delta_i^2 (x(m_i) - m - u_i \sigma)^2 - 2 \sum_{i=2}^k \frac{f_i f_{i-1}}{\lambda_i - \lambda_{i-1}} (x(m_i) - m - u_i \sigma)(x(m_{i-1}) - m - u_{i-1} \sigma) \quad (4.1)$$

とおくと

$$\log h = -\frac{n}{2\sigma^2} S + (m \text{ を含まぬ項})$$

であるから

$$-\frac{\partial^2 \log h}{\partial m^2} = \frac{n}{2\sigma^2} \frac{\partial^2 S}{\partial m^2} = \frac{n}{\sigma^2} K_1 \quad (4.2)$$

ここで、 K_1 は $\lambda_0 = 0, \lambda_{k+1} = 1, f_0 = f_{k+1} = 0$ とし

$$K_1 = \sum_{i=1}^{k+1} \frac{(f_i - f_{i-1})^2}{\lambda_i - \lambda_{i-1}} \quad (4.3)$$

よつて系統統計量を用いたときの m の推定に関する効率は

$$e_m = -E \left(\frac{\partial^2 \log h}{\partial m^2} \right) = K_1 \quad (4.4)$$

である。

2. m が既知の場合

この場合では、

$$\log h = -k \log \sigma - \frac{n}{2\sigma} S + (\sigma \text{ を含まぬ項})$$

であるから

$$\frac{\partial^2 \log h}{\partial \sigma^2} = \frac{k}{\sigma^2} - \frac{3n}{\sigma^3} S + \frac{2n}{\sigma^3} \frac{\partial S}{\partial \sigma} - \frac{n}{2\sigma^2} \frac{\partial^2 S}{\partial \sigma^2}$$

2) の節と同様に $\lambda_0 = 0, \lambda_{k+1} = 1, f_0 = f_{k+1} = 0$ とし

$$K_2 \equiv \sum_{i=1}^{k+1} \frac{(f_i u_i - f_{i-1} u_{i-1})^2}{n_i - n_{i-1}} \quad (4.5)$$

とおくと

$$\frac{\partial^2 S}{\partial \sigma^2} = K_2 \quad E\left(\frac{\partial S}{\partial \sigma}\right) = 0, \quad E(S) = \frac{\sigma^2}{n} k$$

はる σ とを用いる、 σ は関する観測値は

$$-E\left(\frac{\partial^2 \log h}{\partial \sigma^2}\right) = \frac{2k}{\sigma^2} - \frac{n}{\sigma^3} K_2 = \frac{n}{\sigma^2} K_2 \left(1 + 2 \frac{k}{n} R_2^{-1}\right) \quad (4.5)$$

であるが、 k は n に比して小さいから

$$\frac{k}{n} \approx 0$$

よって

$$-E\left(\frac{\partial^2 \log h}{\partial \sigma^2}\right) \approx \frac{n}{\sigma^2} K_2 \quad (4.5)$$

従って σ は関する系統統計量の効率 η_0 は

$$\eta_0 = \frac{n}{\sigma^2} K_2 / \frac{2n}{\sigma} = \frac{1}{2} K_2 \quad (4.6)$$

(3) m, σ は未知の場合

このときは、

$$\log h = -m \log \sigma - \frac{n}{2\sigma} S + (m, \sigma \text{ を含む項})$$

であるから

$$K_3 \equiv \sum_{i=1}^{k+1} \frac{(f_i - f_{i-1})(f_i u_i - f_{i-1} u_{i-1})}{n_i - n_{i-1}} \quad (4.7)$$

$$\Delta \equiv K_1 K_2 - K_3^2 \quad (4.8)$$

とおくと、 m, σ の同時推定については系統統計量の報知高は

$$\begin{aligned} E\left(\frac{\partial^2 \log h}{\partial m^2}\right) E\left(\frac{\partial^2 \log h}{\partial \sigma^2}\right) - E^2\left(\frac{\partial^2 \log h}{m \partial \sigma}\right) \\ = \frac{n^2}{\sigma^4} \Delta + \frac{2nR}{\sigma^4} K_1 \end{aligned} \quad (4.9)$$

よつてこのときの系統統計量の効率 γ は

$$\begin{aligned} \gamma &= \frac{\frac{n^2}{\sigma^4} \Delta - \frac{2nR}{\sigma^4} K_1}{\frac{2n^2}{\sigma^4}} \\ &= \frac{1}{2} \Delta + \frac{R}{n} K_1 \doteq \frac{1}{2} \Delta \end{aligned} \quad (4.10)$$

§ 5. 系統統計量を用いた場合の正規母集団の平均値と標準偏差の最良線型不偏推定値

このとき基礎にはる $X(m_1), X(m_2), \dots, X(m_R)$ の分布密度は (3.14) の $h(X(m_1), \dots, X(m_R); m, \sigma)$ で与えられる。よつて m, σ の最良線型不偏推定値を求めるには $\alpha, Markoff$ の定理 2.2 を用ひればよいが、このときは (2.11) の二次形式としては (4.1) の S をとればよい。

先づ m, σ の何れか一方が既知の場合を調べ、最後に m, σ 共に未知の場合を調べよう。

Case I. σ が既知の場合 このとき m の最良線型不偏推定値を \hat{m}_0 とすれば、それは

$$\frac{\partial S}{\partial m} \Big|_{m=\hat{m}_0} = 0$$

から求められる。よつて

$$\hat{m}_0 K_1 = \sum_{i=1}^R \left(\frac{f_i - f_{i-1}}{\lambda_i - \lambda_{i-1}} - \frac{f_{i+1} - f_i}{\lambda_{i+1} - \lambda_i} \right) f_i (X(m_i) - \lambda_i \sigma) \quad (5.1)$$

今 X で

$$X \equiv \sum_{i=1}^{R+1} \frac{(f_i - f_{i-1})(f_i X(m_i) - f_{i-1} X(m_{i-1}))}{\lambda_i - \lambda_{i-1}} \quad (5.2)$$

とおくと (5.1) は

$$\hat{m}_0 \cdot K_1 = X - \sigma \cdot K_3 \quad (5.1')$$

とほるから

$$\hat{m}_0 = \frac{1}{K_1} X - \sigma \frac{K_3}{K_1} \quad (5.2)$$

\hat{m}_0 の分散 $D^2(\hat{m}_0)$ を計算すると

$$D^2(\hat{m}_0) = \frac{1}{K_1^2} D^2(X)$$

とさるが

$$D^2(X) = K_1 \frac{\sigma^2}{n} \quad (5.4)$$

であるから

$$D^2(\hat{m}_0) = \frac{\sigma^2}{n K_1} \quad (5.5)$$

よってこの場合には、 \hat{m}_0 は系統統計量を用いる限り、有効推定値であることが判る。

Case II m が既知の場合 このときの σ の最良線型不偏推定値を $\hat{\sigma}_0$ とすれば、それは

$$\frac{\partial S}{\partial \sigma} \Big|_{\sigma = \hat{\sigma}_0} = 0$$

から求められる。よって

$$\hat{\sigma}_0 \cdot K_2 = \sum_{i=1}^k \left(\frac{f_i u_i - f_{i-1} u_{i-1}}{\lambda_i - \lambda_{i-1}} - \frac{f_{i+1} u_{i+1} - f_i u_i}{\lambda_{i+1} - \lambda_i} \right) f_i (X(m_i) - m) \quad (5.6)$$

より

$$Y = \sum_{i=1}^{k+1} \frac{(f_i u_i - f_{i-1} u_{i-1})(f_i X(m_i) - f_{i-1} X(m_{i-1}))}{\lambda_i - \lambda_{i-1}} \quad (5.7)$$

とおくと (5.6) は

$$\hat{\sigma}_0 \cdot K_2 = Y - m \cdot K_3 \quad (5.6')$$

とかけるから

$$\hat{\sigma}_0 = \frac{1}{K_2} Y - m \frac{K_3}{K_2} \quad (5.8)$$

よって

$$D^2(\hat{\sigma}_0) = \frac{1}{K_2^2} D^2(Y)$$

で

$$D^2(Y) = \frac{\sigma^2}{n} K_2 \quad (5.9)$$

であるから

$$D^2(\hat{\sigma}_0) = \frac{\sigma^2}{n K_2} \quad (5.10)$$

よって $\hat{\sigma}_0$ も亦系統統計量を用いる限り $\hat{\mu}$ の有効推定値と考えるよ
 う。

Case III m, σ 共に未知の場合 このときの m, σ の最良線
 型不偏推定値を夫々 $\hat{m}, \hat{\sigma}$ とすれば、それは、

$$\frac{\partial S}{\partial m} \Big|_{\substack{m=\hat{m} \\ \sigma=\hat{\sigma}}} = 0 \quad \frac{\partial S}{\partial \sigma} \Big|_{\substack{m=\hat{m} \\ \sigma=\hat{\sigma}}} = 0$$

から求めらる。 (4.3), (4.5), (4.7), (5.2), (5.7) の記号を用いる
 と、

$$\begin{aligned} \hat{m} \cdot K_1 + \hat{\sigma} \cdot K_3 &= X \\ \hat{m} \cdot K_3 + \hat{\sigma} \cdot K_2 &= Y \end{aligned} \quad (5.11)$$

と解る。よつて、

$$\begin{aligned} \hat{m} &= \frac{1}{\Delta} (K_2 \cdot X - K_3 \cdot Y) \\ \hat{\sigma} &= \frac{1}{\Delta} (-K_3 \cdot X + K_1 \cdot Y) \end{aligned} \quad (5.12)$$

$\hat{m}, \hat{\sigma}$ の分散、共変分散を計算しよう。

$$\begin{aligned} D^2(\hat{m}) &= \frac{1}{\Delta^2} (K_2^2 \cdot D^2(X) - 2K_2K_3 \cdot C(XY) + K_3^2 \cdot D^2(Y)) \\ D^2(\hat{\sigma}) &= \frac{1}{\Delta^2} (K_3^2 \cdot D^2(X) - 2K_1K_3 \cdot C(XY) + K_1^2 \cdot D^2(Y)) \\ C(\hat{m}, \hat{\sigma}) &= \frac{1}{\Delta^2} (-K_2K_3 \cdot D^2(X) + (K_1K_2 + K_3^2) \cdot C(X, Y) \\ &\quad - K_1K_3 \cdot D^2(Y)) \end{aligned}$$

であるから (5.4) (5.9) 及び

$$C(X, Y) = \frac{\sigma^2}{n} K_3 \quad (5.13)$$

を用いて

$$D^2(\hat{m}) = \frac{\sigma^2}{n} \frac{K_2^2}{\Delta}, \quad D^2(\hat{\sigma}) = \frac{\sigma^2}{n} \frac{K_1}{\Delta}, \quad C(\hat{m}, \hat{\sigma}) = -\frac{\sigma^2}{n} \frac{K_3}{\Delta} \quad (5.14)$$

よつて

$$D^2(\hat{m}) D^2(\hat{\sigma}) - C^2(\hat{m}, \hat{\sigma}) = \frac{\sigma^4}{n^2} \frac{1}{\Delta} \quad (5.15)$$

よつて、 $\hat{m}, \hat{\sigma}$ も亦系統統計量を用いる限り、 m, σ の同時的は有効
 推定値と考えるように及ぶ。

帯は n_i の間

$$n_i + n_{k-i+1} = n$$

又は λ_i でいへば

$$\lambda_i + \lambda_{k-i+1} = 1$$

はる関係があるとき $x(m_1) \dots x(m_k)$ は対称配置 (Symmetric Spacing) であるというが、このときは、

$$u_i + u_{k-i+1} = 0$$

であるから

$$k_3 = 0 \quad (3.17)$$

で、このときは

$$D^2(\hat{m}) = \frac{\sigma^2}{nk_1} \quad D^2(\hat{\sigma}) = \frac{\sigma^2}{nk_2}$$

となつて Case I. II に一致する、これは Mosteller 及び山内が主として考えた場合である。

§ 6. 正規母集団の平均値及び標準偏差を推定するための最良配置の決定

吾々は与つて $\lambda_1, \lambda_2, \dots, \lambda_k$ が与えられる限り、 $\hat{m}_0, \hat{\sigma}_0$ 及び $\hat{m}, \hat{\sigma}$ は有効推定値であるを知つたのであるが、 λ_i を適当に取ることはつて、それらの効率を更に高めることができる。それらの最大効率を与えるものは $\lambda_1, \lambda_2, \dots, \lambda_k$ を最良配置 (Optimum Spacing) と呼ぶ。

本節では Optimum Spacing の決定について述べる。

Case I σ が既知の場合 このときの最良配置は、

$$\eta_m = k_1$$

を最大はらしむるものである。

$$\frac{df_i}{du_i} = -u_i f_i, \quad \frac{d\lambda_i}{du_i} = f_i \quad i=1, 2, \dots, k$$

を用いて、 k_1 を u_i で偏微分すると

$$\frac{\partial k_1}{\partial u_i} = f_i \left(\frac{f_{i+1} - f_i}{\lambda_{i+1} - \lambda_i} - \frac{f_i - f_{i-1}}{\lambda_i - \lambda_{i-1}} \right) \left(2u_i + \frac{f_i - f_{i-1}}{\lambda_i - \lambda_{i-1}} - \frac{f_{i+1} - f_i}{\lambda_{i+1} - \lambda_i} \right) \quad i=1, 2, \dots, k$$

よつて最良配置の条件として


$$\frac{f_i - f_{i-1}}{\lambda_i - \lambda_{i-1}} = \frac{f_{i+1} - f_i}{\lambda_{i+1} - \lambda_i}, \quad i=1, 2, \dots, k \quad (6.1)$$

$$2u_i + \frac{f_i - f_{i-1}}{\lambda_i - \lambda_{i-1}} + \frac{f_{i+1} - f_i}{\lambda_{i+1} - \lambda_i} = 0, \quad i=1, 2, \dots, K \quad (6.2)$$

を得るが、 f を λ の函数と考えると、この式 6.1 図から見るように、これは上方に凸であるから、 f_{i-1}, f_i, f_{i+1} の何れか二が一致しない限り (6.1) は成立しないので、吾々は (6.2) 式を考えればよい。

$i \geq 2$ のとき (6.2) はる条件を満たす u_1, u_2, \dots, u_K は原係に
関して対象、即ち

Fig 6.1 Graph of The Ordinate f as a Function of λ



$$u_i + u_{K-i+1} = 0$$

はることを予想してゐるが、この証明は未だ発表してゐない。

そこで吾々は対称配置 (6.3) を假定して $k=1, 2, 3, \dots, 10$ に対して (6.2) を数値的に解いて \hat{m}_0 の最高効率 (γ_m の最大値) を計算して次の表 6.1 を得た。

片側率配置 ($\lambda_{i+1} - \lambda_i = \lambda_i - \lambda_{i-1}$) 及び $\lambda_i = (i - \frac{1}{2})/K$ はる配置に對する γ_m を最良配置の γ_m と比較したのが表 6.2 である。

表 6.1 表 \hat{m}_0 の最高効率を与える対称配置

	$K=1$	$K=2$	$K=3$	$K=4$	$K=5$	$K=6$	$K=7$	$K=8$	$K=9$	$K=10$
λ_1	0.500	0.270	0.163	0.107	0.074	0.055	0.040	0.031	0.024	0.020
u_1	0.000	-0.613	-0.982	-1.243	-1.447	-1.598	-1.751	-1.866	-1.977	-2.054
λ_2		0.730	0.500	0.351	0.255	0.195	0.147	0.115	0.092	0.076
u_2		0.613	0.000	-0.383	-0.659	-0.860	-1.049	-1.200	-1.329	-1.433
λ_3			0.837	0.649	0.500	0.395	0.308	0.247	0.202	0.167
u_3			0.982	0.383	0.000	-0.266	-0.502	-0.684	-0.834	-0.966
λ_4				0.893	0.745	0.605	0.500	0.412	0.343	0.288
u_4				1.242	0.659	0.266	0.000	-0.222	-0.404	-0.559
λ_5					0.926	0.805	0.642	0.588	0.500	0.427
u_5					1.447	0.860	0.502	0.222	0.000	-0.184
λ_6						0.945	0.853	0.753	0.657	0.573
u_6						1.598	1.049	0.684	0.404	0.184
λ_7							0.960	0.885	0.798	0.712
u_7							1.751	1.200	0.834	0.559
λ_8								0.969	0.908	0.833
u_8								1.866	1.329	0.966
λ_9									0.976	0.924
u_9									1.977	1.433
λ_{10}										0.980
u_{10}										2.054
K_1	0.6366	0.8097	0.8800	0.9342	0.9420	0.9559	0.9654	0.9722	0.9771	0.9808
$\frac{1}{2}K_2$	0	0.3303	0.5326	0.6566	0.7392	0.7902	0.8516	0.8620	0.8858	0.9016
K_3	0	0	0	0	0	0	0	0	0	0
$\frac{1}{2}A$	0	0.267	0.469	0.614	0.696	0.754	0.822	0.838	0.866	0.884

表 6.2 種々の配置に対する \hat{m}_0 の効率の比較

	最良配置	等確率配置	$\lambda_i = \frac{i-\frac{1}{2}}{k}$
$k=1$	0.6366	0.6366	0.637
$k=2$	0.8097	0.7926	0.808
$k=3$	0.8800	0.8606	0.878
$k=4$	0.9342	0.8969	0.913
$k=5$	0.9420	0.9172	0.937
$k=6$	0.9559	0.9352	0.948
$k=7$	0.9654	0.9450	0.957
$k=8$	0.9722	0.9521	0.963
$k=9$	0.9771	0.9591	0.969
$k=10$	0.9808	0.9634	0.973

又最良配置に対する \hat{m}_0 の計算式を示したものが表 6.3 表である。

Case II m が既知の場合。このときは

$$\eta_0 = \frac{1}{2} K_2$$

を最大はらしめる配置を求めればよい。

Case I の場合と同様 K_2 を u_i で偏微分して

$$\frac{\partial K_2}{\partial u_i} = f_i \left(\frac{f_{i+1} u_{i+1} - f_i u_i}{\lambda_{i+1} - \lambda_i} - \frac{f_i u_i - f_{i-1} u_{i-1}}{\lambda_i - \lambda_{i-1}} \right) \\ \left(2u_i^2 - 2 + \frac{f_i u_i - f_{i-1} u_{i-1}}{\lambda_i - \lambda_{i-1}} + \frac{f_{i+1} u_{i+1} - f_i u_i}{\lambda_{i+1} - \lambda_i} \right) \\ i=1, 2, \dots, k$$

これから最良配置の条件として次式を得る

$$\frac{f_i u_i - f_{i-1} u_{i-1}}{\lambda_i - \lambda_{i-1}} = \frac{f_{i+1} u_{i+1} - f_i u_i}{\lambda_{i+1} - \lambda_i} \quad i=1, 2, \dots, k \quad (6.4)$$

$$2u_i^2 - 2 + \frac{f_i u_i - f_{i-1} u_{i-1}}{\lambda_i - \lambda_{i-1}} + \frac{f_{i+1} u_{i+1} - f_i u_i}{\lambda_{i+1} - \lambda_i} = 0 \quad i=1, 2, \dots, k \quad (6.5)$$




表 5.4 様 $\hat{\mu}_0$ の最高相対効率とその為の最良配置

	$k=1$	$k=2$		$k=3$	$k=4$
λ_1	0.058	0.069	0.903	0.029	0.025
u_1	-1.572	-1.483	-1.299	-1.896	-1.960
λ_2		0.931	0.981	0.136	0.136
u_2		1.483	2.054	-1.098	-1.098
λ_3			0.815	0.815	0.864
u_3			0.896	0.896	1.098
λ_4				0.975	0.975
u_4				1.960	1.960
λ'_1	0.442		0.019	0.185	
u'_1	1.572		-2.054	-0.896	
λ'_2			0.097	0.864	
u'_2			-1.299	1.098	
λ'_3			0.971	0.971	
u'_3			1.896	1.896	
λ'_4					
u'_4					
$\frac{1}{2}K_0$	0.3040	0.653	0.396*	0.657	0.825

註* これは $k=2$ のときの (5.8) の非対称な解であるが、これは最良配置ではない。

Table 6.3 The Expressions of The Best Linear Unbiased Estimate $\hat{\mu}_0$ For The Optimum Spacing

$$\begin{aligned}
 k=1 & \quad \chi(0.500 \cdot n) \\
 k=2 & \quad \frac{1}{2} (\chi(0.270 \cdot n) + \chi(0.730 \cdot n)) \\
 k=3 & \quad 0.297 (\chi(0.163 \cdot n) + \chi(0.837 \cdot n)) + 0.407 \chi(0.500 \cdot n)
 \end{aligned}$$


$$\begin{aligned}
k=4 & 0.197(\chi(0.107 \cdot n) + \chi(0.893 \cdot n)) \\
& \quad + 0.303(\chi(0.351 \cdot n) + \chi(0.649 \cdot n)) \\
k=5 & 0.133(\chi(0.074 \cdot n) + \chi(0.926 \cdot n)) + 0.233(\chi(0.255 \cdot n) \\
& \quad + \chi(0.745 \cdot n)) + 0.269 \cdot \chi(0.500 \cdot n) \\
k=6 & 0.099(\chi(0.055 \cdot n) + \chi(0.945 \cdot n)) + 0.181(\chi(0.195 \cdot n) \\
& \quad + \chi(0.805 \cdot n)) + 0.220(\chi(0.395 \cdot n) + \chi(0.605 \cdot n)) \\
k=7 & 0.071(\chi(0.040 \cdot n) + \chi(0.960 \cdot n)) + 0.140(\chi(0.147 \cdot n) + \chi(0.853 \cdot n)) \\
& \quad + 0.186(\chi(0.308 \cdot n) + \chi(0.692 \cdot n)) + 0.203 \cdot \chi(0.500 \cdot n) \\
k=8 & 0.049(\chi(0.031 \cdot n) + \chi(0.969 \cdot n)) + 0.111(\chi(0.115 \cdot n) + \chi(0.885 \cdot n)) \\
& \quad + 0.155(\chi(0.247 \cdot n) + \chi(0.753 \cdot n)) + 0.178(\chi(0.412 \cdot n) + \chi(0.588 \cdot n)) \\
k=9 & 0.044(\chi(0.024 \cdot n) + \chi(0.976 \cdot n)) + 0.091(\chi(0.092 \cdot n) + \chi(0.908 \cdot n)) \\
& \quad + 0.130(\chi(0.202 \cdot n) + \chi(0.798 \cdot n)) + 0.155(\chi(0.343 \cdot n) + \chi(0.657 \cdot n)) \\
& \quad + 0.163 \cdot \chi(0.500 \cdot n) \\
k=10 & 0.036(\chi(0.020 \cdot n) + \chi(0.980 \cdot n)) + 0.075(\chi(0.076 \cdot n) + \\
& \quad \chi(0.924 \cdot n)) + 0.109(\chi(0.167 \cdot n) + \chi(0.833 \cdot n)) \\
& \quad + 0.133(\chi(0.288 \cdot n) + \chi(0.712 \cdot n)) + 0.147(\chi(0.427 \cdot n) \\
& \quad + \chi(0.573 \cdot n))
\end{aligned}$$

但し n は Sample Size である。

今度は f_u を λ の函数と考えるとそのグラフは上の $k=2$ 図のようになる。

k が偶数のとき λ の対称配置を仮定すれば、(6.5)のみ考えればよい。たゞ k が偶数のときでも (6.5) は対称ではない解をもつが次の $k=4$ 表で見るようにそれは最大効率とは与へない。

$k=1, 2, 3, 4$ に対し (6.5) を解いて最良配置を求め、それは対応する $\frac{1}{2}k_2$ の最大値を求めたのが $k=4$ 表であり、これと等確率配置及び $\lambda_2 = (i - \frac{1}{2})/k$ なる配置とその効率を比較したのが $k=5$ 表で、最良配置のときの $\hat{\mu}$ の計算式を示したのが $k=6$ 表である。



为 6.4 表 $\hat{\sigma}_0$ の最高効率を与える配置

	$k=1$	$k=2$		$k=3$		$k=4$	
λ_1	0.058	0.942	0.669, 0.903*	0.019*	0.029	0.185	0.025
u_1	-1.572	1.572	-1.483, 1.299, -2.054	-1.896	-0.896	-1.960	
		λ_2	0.931	0.981, 0.097	0.136	0.864	0.136
		u_2	1.483	2.054, -1.299	-1.098	1.098	-1.098
			λ_3		0.815	0.971	0.864
			λ_3		0.896	1.896	1.098
					λ_4		0.975
					u_4		1.960
$\frac{1}{2}K_2$	0.3040		0.653	0.379		0.657	0.825
K_1	0.246	0.512	0.347	0.756		0.933	
K_3	0.387	0	0.481	0.235		0	
$\frac{1}{2}\Delta$	0	0.334	0.014	0.469		0.770	

表 6.4 系の註 * **) は Symmetric で は い (5.7) の 解 で あ る が
 これ は 上 に 関 係 よ う に Max. Efficiency で は ば ら い。

表 6.5 表 $\hat{\sigma}_0$ の 相 対 効 率 の 比 較

k	最 良 配 置	等 確 率 配 置	$\hat{\sigma}_0$
1	0.3040	0.000	0.000
2	0.653	0.321	0.413
3	0.657	0.368	0.526
4	0.825	0.563	0.619

表 6.6 表 最 良 配 置 の 場 合 の $\hat{\sigma}_0$

$k=1$	$0.636(x(m_4) - m_1)$
$k=2$	$0.674(x(m_2) - x(m_1))$
$k=3$	$0.065m - 0.164x(m_1) - 0.293x(m_2) + 0.388x(m_3)$ $- 0.065m - 0.388x(m_1) + 0.293x(m_2) + 0.164x(m_3)$
$k=4$	$0.202(x(m_4) - x(m_1)) + 0.236(x(m_3) - x(m_2))$

Case III m, σ 共 に 未 知 の 場 合 σ の と き は

$$\gamma = \frac{1}{2}\Delta = \frac{1}{2}(K_1 K_2 - K_3^2)$$

を 最 大 と し て 配 置 を 求 め る こ と は ば ら ば ら い。

Δ を u_i で 偏 微 分 し て

$$\frac{\partial K_1}{\partial u_i} K_2 + K_1 \frac{\partial K_2}{\partial u_i} = 2K_3 \frac{\partial K_3}{\partial u_i} \quad , i=1, 2, \dots, k$$

こ の 条 件 を 満 た す 配 置 を 求 め る こ と は 困 難 で あ る。

初 め か ら 好 機 配 置 に 限 る と は $K_3=0$ で あ る か ら

$$K_1 \frac{\partial K_2}{\partial u_i} + K_2 \frac{\partial K_1}{\partial u_i} = 0 \quad , i=1, 2, \dots, k \quad (6.5)$$

と なる が、こ れ も Numerical に 解 く こ と は 簡 単 で は い。

特に $\lambda=2$ とすれば、この場合

$$K_1 = 2 \frac{f_1^2}{\lambda_1}, \quad K_2 = 2 \frac{f_1^2 u_1^2}{\lambda_1(1-2\lambda_1)}$$

であるから

$$\eta = 2 \frac{f_1^2 u_1^2}{\lambda_1^2(1-2\lambda_1)}$$

で (6.6) は

$$2u_1 - \frac{1}{u_1} + \frac{f_1}{\lambda_1} - \frac{f_1}{1-2\lambda_1} = 0 \quad (6.7)$$

となる。これを数値的に解いて

$$\lambda_1 = 0.134, \quad u_1 = -1.10768, \quad f_1 = 0.21601$$

$$\lambda_2 = 0.866, \quad u_2 = 1.10768, \quad f_2 = 0.21601$$

$$\eta = \frac{1}{2} \Delta = 0.4066$$

を得る。

x_1, x_2, \dots, x_n の同時分布の密度は

$$(2\pi\sigma^2)^{-\frac{n}{2}} \exp -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - a_{i1}\theta_1 - a_{i2}\theta_2 - \dots - a_{is}\theta_s)^2$$

であるが、今

$$S = \sum_{i=1}^n (x_i - a_{i1}\theta_1 - a_{i2}\theta_2 - \dots - a_{is}\theta_s)^2 \quad (7.6)$$

とおく、 $\theta_1, \dots, \theta_s$ の最尤推定値を $\hat{\theta}_1, \dots, \hat{\theta}_s$ とすれば S の最小値

$$S_0 = \sum_{i=1}^n (x_i - a_{i1}\hat{\theta}_1 - a_{i2}\hat{\theta}_2 - \dots - a_{is}\hat{\theta}_s)^2 \quad (7.7)$$

と $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_s$ は統計的に独立であつて勿論 $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_s$ の同時分布は s 次元正規分布であるが、 $\frac{1}{\sigma^2} S_0$ は自由度 $(n-s)$ の χ^2 分布に従う。これは仮説の如何に拘らずつねに成立つのである。

次に仮説 H_0 が正しうとすれば、このときの x_1, x_2, \dots, x_n の分布密度は

$$(2\pi\sigma^2)^{-\frac{n}{2}} \exp -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - a_{i1}\theta_1^0 - \dots - a_{ir}\theta_r^0 - a_{i,r+1}\theta_{r+1}^0 - \dots - a_{is}\theta_s^0)^2$$

となり、このときの $\theta_{r+1}^0, \dots, \theta_s^0$ の最尤推定値を夫々 $\hat{\theta}_{r+1}^*, \dots, \hat{\theta}_s^*$ とする。

$$S' = \sum_{i=1}^n (x_i - a_{i1}\theta_1^0 - \dots - a_{ir}\theta_r^0 - a_{i,r+1}\theta_{r+1}^0 - \dots - a_{is}\theta_s^0)^2 \quad (7.8)$$

とおくと、 S' の最小値

$$S'_0 = \sum_{i=1}^n (x_i - a_{i1}\theta_1^0 - \dots - a_{ir}\theta_r^0 - a_{i,r+1}\hat{\theta}_{r+1}^* - \dots - a_{is}\hat{\theta}_s^*)^2 \quad (7.9)$$

と $\hat{\theta}_{r+1}^*, \dots, \hat{\theta}_s^*$ とは独立で $\frac{1}{\sigma^2} S'_0$ は自由度 $(n-s-r)$ の χ^2 分布に従うよつて再び仮説 H_0 が正しうならば

$$S'_0 - S_0$$

は S_0 とは独立であつて $\frac{1}{\sigma^2} (S'_0 - S_0)$ は自由度 r の χ^2 分布に従う。

即ち仮説 H_0 の下では

$$F_{m-s}^r = \frac{m-s}{r} \frac{S'_0 - S_0}{S_0} \quad (7.10)$$

なる統計量は自由度が $(r, m-s)$ なる Snedecor の F 分布に従うのである。

線型仮説 (7.5) を検定するためには、統計量 (7.10) を用いることが最強な検定方式であるということも知られている。

以上では、 x_1, x_2, \dots, x_m は互に独立としておいたのであるが、 x_1, x_2, \dots, x_m の同時分布が Non-Singular は m 次元正規分布に従うときも同様のことが成立つのである。

§ 8 S 統計量を用いた場合の正規母集団に関する統計的仮説の検定

考える母集団は正規母集団 $N(m, \sigma)$ として、各値の順序付け統計量 $x(m_1), x(m_2), \dots, x(m_k)$ を用いたときの母数 m, σ に関する統計的仮説の検定について考えよう。

正規母集団 $N(m, \sigma)$ のときの $x(m_1), x(m_2), \dots, x(m_k)$ の極限分布の密度は (3.15) にまつて与えられる。再録すれば：

$$f(x(m_1), x(m_2), \dots, x(m_k)) = (2\pi)^{-\frac{k}{2}} f_1 f_2 \dots f_k \sigma^{-k} (\lambda_1 (\lambda_2 - \lambda_1) (\lambda_3 - \lambda_2) \dots (1 - \lambda_k))^{-\frac{1}{2}} m^{\frac{k}{2}} \times \exp \left\{ -\frac{m}{2\sigma^2} \left[\sum_{i=1}^k \frac{\lambda_{i+1} - \lambda_i}{(\lambda_{i+1} - \lambda_i)(\lambda_i - \lambda_{i-1})} f_i^2 (x(m_i) - m - u_i \sigma)^2 - 2 \sum_{i=2}^k \frac{f_i f_{i-1}}{\lambda_i - \lambda_{i-1}} (x(m_i) - m - u_i \sigma)(x(m_{i-1}) - m - u_{i-1} \sigma) \right] \right\} \quad (8.1)$$

Case I 先づ Student 仮説

$$H_1: m = m_0 \quad (8.2)$$

の検定から考えよう。

$$S = \sum_{i=1}^k \frac{\lambda_{i+1} - \lambda_i}{(\lambda_{i+1} - \lambda_i)(\lambda_i - \lambda_{i-1})} f_i^2 (x(m_i) - m - u_i \sigma)^2 - 2 \sum_{i=2}^k \frac{f_i f_{i-1}}{\lambda_i - \lambda_{i-1}} (x(m_i) - m - u_i \sigma)(x(m_{i-1}) - m - u_{i-1} \sigma) \quad (8.3)$$

とおいて

$$\frac{\partial S}{\partial m} \Big|_{m=\hat{m}, \sigma=\hat{\sigma}} = 0 \quad \frac{\partial S}{\partial \sigma} \Big|_{m=\hat{m}, \sigma=\hat{\sigma}} = 0$$

$$K_1 \hat{m} + K_3 \hat{\sigma} = \sum_{i=1}^{k+1} \frac{(f_i - f_{i-1})(f_i \chi(m_i) - f_{i-1} \chi(m_{i-1}))}{\lambda_i - \lambda_{i-1}} \quad (8.4)$$

$$K_3 \hat{m} + K_2 \hat{\sigma} = \sum_{i=1}^{k+1} \frac{(f_i u_i - f_{i-1} u_{i-1})(f_i \chi(m_i) - f_{i-1} \chi(m_{i-1}))}{\lambda_i - \lambda_{i-1}}$$

よつて \hat{m} , $\hat{\sigma}$ を定めると、これは (4.17) で与えられる。このときの S の最小値を S_0 とすれば

$$\begin{aligned} S_0 &= \sum_{i=1}^k \frac{\lambda_{i+1} - \lambda_{i-1}}{(\lambda_{i+1} - \lambda_i)(\lambda_i - \lambda_{i-1})} f_i^2 (\chi(m_i) - \hat{m} - u_i \hat{\sigma})^2 \\ &\quad - 2 \sum_{i=2}^k \frac{f_i f_{i-1}}{\lambda_i - \lambda_{i-1}} (\chi(m_i) - \hat{m} - u_i \hat{\sigma})(\chi(m_{i-1}) - \hat{m} - u_{i-1} \hat{\sigma}) \\ &= \sum_{i=1}^{k+1} \frac{(f_i \chi(m_i) - f_{i-1} \chi(m_{i-1}))^2}{\lambda_i - \lambda_{i-1}} - \hat{m} (K_1 \hat{m} + K_3 \hat{\sigma}) \\ &\quad - \hat{\sigma} (K_3 \hat{m} + K_2 \hat{\sigma}) \\ &= \sum_{i=1}^{k+1} \frac{(f_i \chi(m_i) - f_{i-1} \chi(m_{i-1}))^2}{\lambda_i - \lambda_{i-1}} - K_1 \hat{m}^2 - 2 K_3 \hat{m} \hat{\sigma} - K_2 \hat{\sigma}^2 \quad (8.5) \end{aligned}$$

であつて、これは \hat{m} , $\hat{\sigma}$ とは独立で、目づ $\frac{1}{2} S_0$ は自由 ($k-2$) の χ^2 分布に従う。このことは仮説 H_1 とは無関係に成り立つことである。

仮説 H_1 が正しいときは

$$\begin{aligned} S' &= \sum_{i=1}^k \frac{\lambda_{i+1} - \lambda_{i-1}}{(\lambda_{i+1} - \lambda_i)(\lambda_i - \lambda_{i-1})} f_i^2 (\chi(m_i) - m_0 - u_i \sigma)^2 \\ &\quad - 2 \sum_{i=2}^k \frac{f_i f_{i-1}}{\lambda_i - \lambda_{i-1}} (\chi(m_i) - m_0 - u_i \sigma)(\chi(m_{i-1}) - m_0 - u_{i-1} \sigma) \quad (8.6) \end{aligned}$$

とよんで

$$\left. \frac{\partial S'}{\partial \sigma} \right|_{\sigma = \hat{\sigma}^*} = 0$$

即ち

$$K_2 \hat{\sigma}^* + K_3 m_0 = \sum_{i=1}^{k+1} \frac{(f_i u_i - f_{i-1} u_{i-1})(f_i \chi(m_i) - f_{i-1} \chi(m_{i-1}))}{\lambda_i - \lambda_{i-1}} \quad (8.7)$$

によつて、 $\hat{\sigma}^*$ を定めれば、 S' の最小値 S'_0 は

$$\begin{aligned}
S'_0 &= \sum_{i=1}^k \frac{\lambda_{i+1} - \lambda_{i-1}}{(\lambda_{i+1} - \lambda_i)(\lambda_i - \lambda_{i-1})} f_i^2 (\chi(m_i) - m_0 - u_i \hat{\sigma}^*)^2 \\
&\quad - 2 \sum_{i=2}^k \frac{f_i f_{i-1}}{\lambda_i - \lambda_{i-1}} (\chi(m_i) - m_0 - u_i \hat{\sigma}^*) (\chi(m_{i-1}) - m_0 - u_{i-1} \hat{\sigma}^*) \\
&= \sum_{i=1}^{k+1} \frac{(f_i \chi(m_i) - f_{i-1} \chi(m_{i-1}))^2}{\lambda_i - \lambda_{i-1}} - 2m_0 \cdot (K_1 \hat{m} + K_2 \hat{\sigma}) \\
&\quad - \frac{\{K_1(\hat{m} - m_0) + K_2 \hat{\sigma}\}^2}{K_2} + m_0^2 \cdot K_1 \tag{8.8}
\end{aligned}$$

これらは $\hat{\sigma}^*$ と独立で $\frac{1}{\sigma_0^2} S'_0$ は自由度 $(k-1)$ の χ^2 分布に従うが、更には §7 の一般論に従って $S'_0 - S_0$ は S_0 と独立で、 $\frac{1}{\sigma_0^2} (S'_0 - S_0)$ は自由度 1 の χ^2 分布に従う

$$S'_0 - S_0 = \frac{\Delta}{K_2} (\hat{m} - m_0)^2 \tag{8.9}$$

であるから、仮説 H_0 が正しいならば

$$t = \sqrt{k-2} \cdot \sqrt{\frac{S'_0 - S_0}{S_0}} = \sqrt{\frac{(k-2) \cdot \Delta}{K_2}} \frac{\hat{m} - m_0}{\sqrt{S_0}} \tag{8.10}$$

は自由度 $(k-2)$ の Student の t -分布に従う。

特に $\lambda_1, \lambda_2, \dots, \lambda_k$ の配置が対称ならば $K_3 = 0$ であるから

$$t = \sqrt{(k-2) \cdot K_1} \frac{\hat{m} - m_0}{\sqrt{S_0}} \tag{8.11}$$

となる。

Case II. 次には一般化された Student 仮説の検定について考えよう。

今、 Δ 箇の正規母集団 $N(m_\alpha, \sigma)$ $\alpha = 1, 2, 3, \dots, \Delta$ があって、母標準偏差 σ は共通であるが未知とする。このとき、各母集団から一定の大きさ n の標本を抽出して、大きさの順に並べて

$$\chi^{(1)}(1), \chi^{(2)}(2), \dots, \chi^{(\alpha)}(n) \quad \alpha = 1, 2, 3, \dots, \Delta$$

とする。 n は充分大であるとして、

$$\frac{n_i}{n} = \lambda_i \quad i = 1, 2, \dots, k$$

として、

$$\chi^{(1)}(n_1), \chi^{(2)}(n_2), \dots, \chi^{(\alpha)}(n_\alpha)$$

を用いるものとする。

検定すべき仮説は母平均の均一性

$$H_2: \mu_1 = \mu_2 = \dots = \mu_s \quad (8.12)$$

である。

このときは

$$S = \sum_{\alpha=1}^s \left\{ \sum_{i=1}^{k_\alpha} \frac{\lambda_{i+1} - \lambda_{i-1}}{(\lambda_{i+1} - \lambda_i)(\lambda_i - \lambda_{i-1})} f_i^2 (X^{(\alpha)}(m_i) - \mu_\alpha - u_i \sigma)^2 - \sum_{i=2}^{k_\alpha} \frac{f_i f_{i-1}}{\lambda_i - \lambda_{i-1}} (X^{(\alpha)}(m_i) - \mu_\alpha - u_i \sigma)(X^{(\alpha)}(m_{i-1}) - \mu_\alpha - u_{i-1} \sigma) \right\} \quad (8.13)$$

とし

$$\frac{\partial S}{\partial m_\alpha} \Big|_{m_i = \hat{m}_i, \sigma = \hat{\sigma}} = 0 \quad \alpha = 1, 2, \dots, s, \quad \frac{\partial S}{\partial \sigma} \Big|_{m_i = \hat{m}_i, \sigma = \hat{\sigma}} = 0$$

例 5

$$\left. \begin{aligned} K_1 \hat{m}_1 + K_2 \hat{\sigma} &= X_1 \\ K_1 \hat{m}_2 + K_3 \hat{\sigma} &= X_2 \\ &\dots \\ K_1 \hat{m}_s + K_2 \hat{\sigma} &= X_s \\ K_1 \hat{m}_1 + K_2 \hat{m}_2 + \dots + K_3 \hat{m}_s + S \cdot K_4 \hat{\sigma} &= Y_1 + Y_2 + \dots + Y_s \end{aligned} \right\} \quad (8.14)$$

但し、Z1で

$$X_\alpha = \sum_{i=1}^{k_\alpha+1} \frac{(f_i - f_{i-1})(f_i X^{(\alpha)}(m_i) - f_{i-1} X^{(\alpha)}(m_{i-1}))}{\lambda_i - \lambda_{i-1}} \quad \alpha = 1, 2, \dots, s$$

$$Y_\alpha = \sum_{i=1}^{k_\alpha+1} \frac{(f_i u_i - f_{i-1} u_{i-1})(f_i X^{(\alpha)}(m_i) - f_{i-1} X^{(\alpha)}(m_{i-1}))}{\lambda_i - \lambda_{i-1}}$$

(8.14)によつて定められた $\hat{m}_\alpha, \hat{\sigma}$ を用いると

$$S_0 = \sum_{\alpha=1}^s \left\{ \sum_{i=1}^{k_\alpha} \frac{\lambda_{i+1} - \lambda_{i-1}}{(\lambda_{i+1} - \lambda_i)(\lambda_i - \lambda_{i-1})} f_i^2 (X^{(\alpha)}(m_i) - \hat{m}_\alpha - u_i \hat{\sigma})^2 - 2 \sum_{i=2}^{k_\alpha} \frac{f_i f_{i-1}}{\lambda_i - \lambda_{i-1}} (X^{(\alpha)}(m_i) - \hat{m}_\alpha - u_i \hat{\sigma})(X^{(\alpha)}(m_{i-1}) - \hat{m}_\alpha - u_{i-1} \hat{\sigma}) \right\} \quad (8.15)$$

は $\hat{m}_\alpha, \hat{\sigma}$ と独立で、 $\frac{1}{\hat{\sigma}^2} S_0$ は自由度 $(\sum k_\alpha - s - 1)$ の χ^2 分布に従う。

このことは仮説 H_2 は無関係に成り立つことである。

仮説 H_0 が正しいときは

$$m_1 = m_2 = m_3 = \dots = m_s = m$$

とす。

$$S' = \sum_{\alpha=1}^s \left\{ \sum_{i=1}^k \frac{\lambda_{i+1} - \lambda_{i-1}}{(\lambda_{i+1} - \lambda_i)(\lambda_i - \lambda_{i-1})} f_i^2(x^{(\alpha)}(m_i) - m - u_i \sigma)^2 - 2 \sum_{i=2}^k \frac{f_i f_{i-1}}{\lambda_i - \lambda_{i-1}} (x^{(\alpha)}(m_i) - m - u_i \sigma)(x^{(\alpha)}(m_{i-1}) - m - u_{i-1} \sigma) \right\} \quad (8.16)$$

とす

$$\frac{\partial S'}{\partial m} \Big|_{m=\hat{m}^*, \sigma=\hat{\sigma}^*} = 0 \quad \frac{\partial S'}{\partial \sigma} \Big|_{m=\hat{m}^*, \sigma=\hat{\sigma}^*} = 0$$

即ち

$$\left. \begin{aligned} \delta K_1 \hat{m}^* + \delta K_3 \hat{\sigma}^* &= X_1 + \dots + X_s \\ \delta K_3 \hat{m}^* + \delta K_2 \hat{\sigma}^* &= Y_1 + \dots + Y_s \end{aligned} \right\} \quad (8.17)$$

で $\hat{m}^*, \hat{\sigma}^*$ を定めると

$$S_0' = \sum_{\alpha=1}^s \left\{ \sum_{i=1}^k \frac{\lambda_{i+1} - \lambda_{i-1}}{(\lambda_{i+1} - \lambda_i)(\lambda_i - \lambda_{i-1})} f_i^2(x^{(\alpha)}(m_i) - \hat{m}^* - u_i \hat{\sigma}^*)^2 - 2 \sum_{i=2}^k \frac{f_i f_{i-1}}{\lambda_i - \lambda_{i-1}} (x^{(\alpha)}(m_i) - \hat{m}^* - u_i \hat{\sigma}^*)(x^{(\alpha)}(m_{i-1}) - \hat{m}^* - u_{i-1} \hat{\sigma}^*) \right\} \quad (8.18)$$

は $\hat{m}^*, \hat{\sigma}^*$ と独立であつて $\frac{1}{\sigma} S_0'$ は自由度 $(sR-2)$ の χ^2 分布に従ふ。更に $S_0' - S_0$ は S_0 と独立であつて $\frac{1}{\sigma} (S_0' - S_0)$ は自由度 $(s-1)$ の χ^2 分布に従ふから

$$F_{sR-s-1}^{s-1} \equiv \frac{sR-s-1}{s-1} \frac{S_0' - S_0}{S_0} \quad (8.18)$$

は自由度 $(s-1, sR-s-1)$ の Smedecor の F-分布に従ふ。特に $s=2$ とすれば

$$t = \sqrt{2k-3} \sqrt{\frac{S_0' - S_0}{S_0}} \quad (8.19)$$

は自由度 $(2k-3)$ の Student t の分布に従ふことが判る。

$S=2$ のとき (8.14), (8.17) をかくと、

$$\left. \begin{aligned} K_1 \hat{m}_1 & & + K_3 \hat{\sigma} &= X_1 \\ & K_1 \hat{m}_2 & + K_3 \hat{\sigma} &= X_2 \\ K_3 (\hat{m}_1 + \hat{m}_2) + 2K_2 \hat{\sigma} & & &= Y_1 + Y_2 \end{aligned} \right\} \quad (8.14)$$

$$\left. \begin{aligned} K_1 \hat{m} + K_2 \hat{\sigma}^* &= \frac{1}{2} (X_1 + X_2) \\ K_3 \hat{m}^* + K_4 \hat{\sigma}^* &= \frac{1}{2} (Y_1 + Y_2) \end{aligned} \right\} \quad (8.19)$$

これから直ちに

$$\hat{m}^* = \frac{1}{2} (\hat{m}_1 + \hat{m}_2), \quad \hat{\sigma}^* = \hat{\sigma} \quad (8.20)$$

よって

$$Z_\alpha \equiv \sum_{i=1}^{k+1} \frac{(f_i \cdot X^{(i)}(m_i) - f_{i-1} \cdot X^{(i)}(m_{i-1}))^2}{n_i - n_{i-1}}, \quad \alpha = 1, 2$$

とおくと

$$\begin{aligned} S_0' &= Z_1 + Z_2 - 2(K_1 \hat{m}^{*2} + 2K_3 \hat{m}^* \hat{\sigma}^* + K_4 \hat{\sigma}^{*2}) \\ &= Z_1 + Z_2 - \frac{1}{2} K_1 (\hat{m}_1 + \hat{m}_2)^2 - 2K_3 (\hat{m}_1 + \hat{m}_2) \hat{\sigma} - 2K_4 \hat{\sigma}^2 \end{aligned} \quad (8.21)$$

と同様にして

$$S_0 = \sum_{\alpha=1}^2 (Z_\alpha - \hat{m}_\alpha X_\alpha - \hat{\sigma}_\alpha Y_\alpha) \quad (8.22)$$

(8.20), (8.21), (8.22) より

$$S_2' - S_0 = \frac{K_1}{2} (\hat{m}_1 - \hat{m}_2)^2 \quad (8.23)$$

よって (8.19) より

$$t = \sqrt{\frac{2k-3}{2}} K_1 \frac{(\hat{m}_1 - \hat{m}_2)}{\sqrt{S_0}} \quad (8.24)$$

§ 9. 検定力函数

本節では (8.10) 又は (8.24) の検定の検定力について考えよう。

又、 Z は $N(0, 1)$ に従い W は自由度 f の χ^2 分布に従って Z と W が互に独立のとき

$$t = \frac{Z + \delta}{\sqrt{W/f}} \quad (9.1)$$

の分布は所謂 Non-Central t 分布であつて、その密度は

$$\frac{\left(\frac{f}{2}\right)^{\frac{f}{2}} e^{-\frac{\delta^2}{2}}}{\sqrt{2\pi} P\left(\frac{f}{2}\right)} \sum_{\nu=0}^{\infty} \frac{\Gamma\left(\frac{1}{2}(f+\nu+1)\right)}{\nu!} (\delta t)^\nu \left(\frac{2}{f+t^2}\right)^{\frac{f+\nu+1}{2}} \quad (9.2)$$

で与えられるがその無限級数は項別積分可能であるから

$$P(-t_\alpha \leq t \leq t_\alpha) = e^{-\frac{\delta^2}{2}} \sum_{\nu=0}^{\infty} \frac{\left(\frac{\delta^2}{2}\right)^\nu}{\nu!} I\left(\frac{\nu+1}{2}, \frac{f}{2}, \frac{t_\alpha^2}{f+t_\alpha^2}\right) \quad (9.3)$$

但しここで $I\left(\frac{\nu+1}{2}, \frac{f}{2}, \frac{t_\alpha^2}{f+t_\alpha^2}\right)$ は K. Pearson の *Incomplete Beta* - 函数である。

(8.10) で考えると、仮説 H_0 が「正しい」ならば t の分布は自由度 $(k-2)$ の Student t - 分布であるが、今、 H_0 のある対立仮説 H_1 ($m = m' (\neq m_0)$) が正しいとすれば

$$\sqrt{\frac{\Delta}{K_2}} (\hat{m} - m_0) = \sqrt{\frac{\Delta}{K_2}} (\hat{m} - m') + \sqrt{\frac{\Delta}{K_2}} (m' - m_0)$$

として、

$$\delta \equiv \sqrt{\frac{\Delta}{K_2}} \frac{m' - m_0}{\sigma} \quad (9.4)$$

とすれば

$$t = \frac{\sqrt{\frac{\Delta}{K_2}} (\hat{m} - \hat{m}') - \sqrt{\frac{\Delta}{K_2}} \frac{(m' - m_0)}{\sigma}}{\sqrt{\frac{S_0}{(k-2)\sigma^2}}} \quad (9.5)$$

は自由度 $(k-2)$ の *Non-Central t - 分布* に従う。よって (8.10) による検定の検定力は

$$P(|t| \geq t_\alpha) = 1 - P(|t| \leq t_\alpha) \\ = 1 - e^{-\frac{\delta^2}{2}} \sum_{\nu=0}^{\infty} \frac{\left(\frac{\delta^2}{2}\right)^\nu}{\nu!} I\left(\frac{\nu+1}{2}, \frac{k+2}{2}, \frac{t_\alpha^2}{k-2+t_\alpha^2}\right) \quad (9.6)$$

これはよく知られたように δ の増加函数である。

このことから直ちに判ることは、最強力の検定を与える $\lambda_1, \lambda_2, \dots, \lambda_k$ の配置は $\frac{\Delta}{K_2}$ 従つて対称配置ならば K_1 を最大はらしめるようなものである。

註及び参考文献

(1) 例之は、R. A. Fisher: *On the Mathematical Foundations of Theoretical Statistics*, *Philosophical Transactions of the Royal Society of London. Series A*, Vol 222 pp 309-368 1922

R. A. Fisher: *Theory of Statistical Estimation*, *Proceedings of the Cambridge Philosophical Society*, Vol XXII Pt 5, pp. 700-725 1925

H. Cramér: *Mathematical Methods of Statistics* Chapt 32, 33

(2) H. Cramér: *loc cit*, Chapt 32

(3) Frederick Mosteller: *On Some Useful "Inefficient" Statistics* *Annals of Mathematical Statistics*, Vol XVII No 4 December, 1946 pp 377-408

(4) 山内二郎: 標本平均値と標準偏差の推定の計算」について、統計数理研究 Vol 3 No 1~2 pp 52~57 (1949)

(5) これについては大天清: 集団の生理-刺激-反応現象の統計的解析一; 生物の集団と環境、岩波科文献抄 23, pp 24-40 及びその引用文献参照

(6) Columbia University: *Statistical Research Group* 編: *Selected Techniques of Statistical Analysis for Scientific and Industrial Research and Production and Management Engineering* の Chapt 11, By Milton Friedman: *Planning an Experiment For Estimating The Mean and Standard Deviation of a Normal Distribution From Observations on The Cumulative Distribution* (pp 341-352) を参照せる。

(7) この参照について、H Cramér, *loc cit*, Chapt 32, を見よ

(8) この照会の道すじは次の通り (1.11) の対数をとつて、これの α, β について全微分をとつて、両辺を平方し、この各辺は (1.10) の各辺を乗じて積分すれば

$$m \int_{-\infty}^{\infty} \left(\frac{\partial \log f}{\partial \alpha} d\alpha + \frac{\partial \log f}{\partial \beta} d\beta \right)^2 dx \geq \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \left(\frac{\partial \log g}{\partial \alpha} d\alpha + \frac{\partial \log g}{\partial \beta} d\beta \right)^2 g d\alpha^* d\beta^* \quad (1)$$

2.1 の等号が成立するのは

$$\frac{\partial h}{\partial \alpha} = \frac{\partial h}{\partial \beta} = 0$$

即ち

$$h(\xi_1, \dots, \xi_{m+1}; \alpha^*, \beta^*; \alpha, \beta)$$

が α, β に無関係のときに限る

(1) の $d\alpha, d\beta$ を不定元 u, v でおきかえると

$$m \left[E \left(\frac{\partial \log f}{\partial \alpha} \right)^2 v^2 + 2 E \left(\frac{\partial \log f}{\partial \alpha} \frac{\partial \log f}{\partial \beta} \right) uv + E \left(\frac{\partial \log f}{\partial \beta} \right)^2 u^2 \right] \\ \geq E \left(\frac{\partial \log g}{\partial \alpha} \right)^2 v^2 + 2 E \left(\frac{\partial \log g}{\partial \alpha} \frac{\partial \log g}{\partial \beta} \right) uv + E \left(\frac{\partial \log g}{\partial \beta} \right)^2 u^2 \quad (2)$$

すなわち α^*, β^* は夫々 α, β の不偏推定値であるから

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \alpha^* g(\alpha^*, \beta^*; \alpha, \beta) d\alpha^* d\beta^* = \alpha \quad (3)$$

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \beta^* g(\alpha^*, \beta^*; \alpha, \beta) d\alpha^* d\beta^* = \beta \quad (4)$$

$g(\alpha^*, \beta^*; \alpha, \beta)$ は α^*, β^* の同時分布の密度函数であるから勿論

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(\alpha^*, \beta^*; \alpha, \beta) d\alpha^* d\beta^* = 1 \quad (5)$$

(3)(4) の全微分をとると正則性条件から

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \alpha^* \left(\frac{\partial \log g}{\partial \alpha} d\alpha - \frac{\partial \log g}{\partial \beta} d\beta \right) g d\alpha^* d\beta^* = d\alpha \quad (6)$$

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \beta^* \left(\frac{\partial \log g}{\partial \alpha} d\alpha - \frac{\partial \log g}{\partial \beta} d\beta \right) g d\alpha^* d\beta^* = d\beta \quad (7)$$

が全ての $d\alpha, d\beta$ に対して同時に成立つ。 $d\alpha, d\beta$ を夫々 u, v とし、

(6), (7) に夫々不定元 ξ, η をかけて加えて、

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} [\xi(\alpha^* - \alpha) + \eta(\beta^* - \beta)] \left(\frac{\partial \log g}{\partial \alpha} u - \frac{\partial \log g}{\partial \beta} v \right) g d\alpha^* d\beta^* \\ = (\xi u + \eta v) \quad (8)$$

(8) は Schwarz の不等式を用いて.

$$(\xi u + \eta v)^2 \leq [\xi^2 E(\alpha^* \alpha) + 2\xi\eta E(\alpha^* \alpha)(\beta^* \beta) + \eta^2 E(\beta^* \beta)^2] \\ \times \left[E\left(\frac{\partial \log g}{\partial \alpha}\right)^2 u^2 + 2E\left(\frac{\partial \log g}{\partial \alpha} \frac{\partial \log g}{\partial \beta}\right) uv + E\left(\frac{\partial \log g}{\partial \beta}\right)^2 v^2 \right] \quad (9)$$

(9) で等号が成立つのは

$$\frac{\partial \log g}{\partial \alpha} \alpha - \frac{\partial \log g}{\partial \beta} \beta = \xi(\alpha^* \alpha) + \eta(\beta^* \beta)$$

のときに限る.

2. 次の代数的補題定理を証明しよう.

補題定理 A, B は共に 2 次の positive-definite は対称行列として
二つの二次形式 $A(\xi, \eta)$, $B(u, v)$ はついで不等式

$$A(\xi, \eta) B(u, v) \geq (\xi u + \eta v)^2 \quad (10)$$

が任意の ξ, η, u, v について成立つならば

$$A(\xi, \eta) \geq B^{-1}(\xi, \eta) \quad (11)$$

である.

証明、適当は直交変換

$$u = p_{11} u' + p_{12} v' \quad v = p_{21} u' + p_{22} v' \quad (12)$$

で, $B(u, v)$ を対角線型に変換する. B の固有値を $\lambda_1 > 0, \lambda_2 > 0$ とし

$$A(\xi, \eta) (\lambda_1 u'^2 + \lambda_2 v'^2) \geq \{ (p_{11} u' + p_{12} v') \xi + (p_{21} u' + p_{22} v') \eta \}^2 \quad (12)$$

(12) を u', v' についての二次形式と考えると.

$$\{ \lambda_1 A(\xi, \eta) - (p_{11} \xi + p_{21} \eta)^2 \} u'^2 - 2(p_{11} \xi + p_{21} \eta)(p_{12} \xi + p_{22} \eta) u' v' \\ + \{ \lambda_2 A(\xi, \eta) - (p_{12} \xi + p_{22} \eta)^2 \} v'^2 \geq 0$$

つまり、行列.

$$\begin{vmatrix} \lambda_1 A(\xi, \eta) - (p_{11} \xi + p_{21} \eta)^2 & -(p_{11} \xi + p_{21} \eta)(p_{12} \xi + p_{22} \eta) \\ -(p_{11} \xi + p_{21} \eta)(p_{12} \xi + p_{22} \eta) & \lambda_2 A(\xi, \eta) - (p_{12} \xi + p_{22} \eta)^2 \end{vmatrix}$$

は任意の ξ, η について positive-definite である. よって.

$$A(\xi, \eta) \geq \frac{1}{\lambda_1} (p_{11} \xi + p_{21} \eta)^2 + \frac{1}{\lambda_2} (p_{12} \xi + p_{22} \eta)^2$$

即ち

$$A(\xi, \eta) \geq \left(\frac{p_{11}^2}{\lambda_1} - \frac{p_{12}^2}{\lambda_2} \right) \xi^2 - 2 \left(\frac{p_{11} p_{21}}{\lambda_1} - \frac{p_{12} p_{22}}{\lambda_2} \right) \xi \eta \\ + \left(\frac{p_{21}^2}{\lambda_1} - \frac{p_{22}^2}{\lambda_2} \right) \eta^2 \quad (13)$$

この右辺の二次形式の行列は

$$\begin{bmatrix} \frac{P_{11}^2}{\lambda_1} + \frac{P_{22}^2}{\lambda_2} & \frac{P_{11}P_{12}}{\lambda_1} + \frac{P_{21}P_{22}}{\lambda_2} \\ \frac{P_{11}P_{12}}{\lambda_1} + \frac{P_{21}P_{22}}{\lambda_2} & \frac{P_{12}^2}{\lambda_1} + \frac{P_{22}^2}{\lambda_2} \end{bmatrix} = \begin{bmatrix} P_{11} & P_{12} \\ P_{21} & P_{22} \end{bmatrix} \begin{bmatrix} \frac{1}{\lambda_1} & 0 \\ 0 & \frac{1}{\lambda_2} \end{bmatrix} \begin{bmatrix} P_{11} & P_{21} \\ P_{12} & P_{22} \end{bmatrix}$$

$$= \begin{bmatrix} P_{11} & P_{12} \\ P_{21} & P_{22} \end{bmatrix} \left[\begin{bmatrix} P_{11} & P_{21} \\ P_{12} & P_{22} \end{bmatrix} B \begin{bmatrix} P_{11} & P_{12} \\ P_{21} & P_{22} \end{bmatrix} \right]^{-1} \begin{bmatrix} P_{11} & P_{21} \\ P_{12} & P_{22} \end{bmatrix} = B^{-1}$$

よって

$$A(\xi, \eta) \geq B^{-1}(\xi, \eta)$$

この補助定理を(4)に適用して

$$\frac{1}{1-\rho^2} \left(\frac{u^2}{\sigma_1^2} - 2\rho \frac{uv}{\sigma_1\sigma_2} - \frac{v^2}{\sigma_2^2} \right) \leq E \left(\frac{\partial \log g}{\partial \alpha} \right)^2 u^2 + 2E \left(\frac{\partial \log g}{\partial \alpha} \frac{\partial \log g}{\partial \beta} \right) uv + E \left(\frac{\partial \log g}{\partial \beta} \right)^2 v^2 \quad (14)$$

(14)と(2)から(1.14)が出る。

(9) F. N. David and J. Neyman: Extension of the Markoff Theorem on Least Squares. Statistical Research Memoirs Vol. 1. p. 105

J. Ogawa: Note on the Markoff's Theorem on Least Squares. Osaka Mathematical Journal Vol. 2 No. 2 November. 1950

(10) H. Cramér loc cit p. 368

(11)

(12) (5.3) の下で K_i を計算するには次のようにすればよい。
 (5.3) より

$$2u_i f_i + \frac{f_i^2 - f_i f_{i-1}}{\lambda_i - \lambda_{i-1}} - \frac{f_{i+1} f_i - f_i^2}{\lambda_{i+1} - \lambda_i} = 0$$

$$2u_{i+1} f_{i-1} + \frac{f_{i-1}^2 - f_{i-1} f_{i-2}}{\lambda_{i-1} - \lambda_{i-2}} - \frac{f_i f_{i-1} - f_{i-1}^2}{\lambda_i - \lambda_{i-1}} = 0$$

から

$$2u_i f_i - 2u_{i+1} f_{i-1} + \frac{(f_i - f_{i-1})^2}{\lambda_i - \lambda_{i-1}} + \frac{f_{i+1} f_i - f_i^2}{\lambda_{i+1} - \lambda_i} - \frac{f_{i-1}^2 - f_{i-1} f_{i-2}}{\lambda_{i-1} - \lambda_{i-2}} = 0$$

また $i=1, 2, 3, \dots, k+1$ について加えると

$$K_1 = \frac{f_k^2}{1 - \lambda_k}$$

第 3 章 応 用

本章ではカ、ス章で述べた理論の適用について述べる。

§ 10 投量死亡率曲線 (Dosage Mortality Curve)

或る特性 (Characteristic) の母集団分布の型は判つてゐるが、一つの個体の特性値は際理的に観測不能であつて、ただ累積度数しか観測出来ぬという型の問題がある。

その典型的な例は毒物の動物に対する致死効果を見る場合である。

或る毒物の動物に対する致死量 (Lethal Dose) とは、それより強ければその動物は死ぬが、それより弱ければ死なぬという限界に於ける毒物の強さのことである。致死量には勿論個体差があつて各動物毎に変動するが、過去の研究に依れば毒物の強さを、その濃度 C の自然対数 $x \equiv \log C$ で測るならば、致死量の母集団分布が正規分布をなすことは一般的に認められてゐる。

即ち考える動物に関する致死量の母集団で致死量が $x - \frac{1}{2}dx$ と、 $x + \frac{1}{2}dx$ の間にある確率は

$$(2\pi\sigma^2)^{-1/2} \exp\left\{-\frac{(x-m)^2}{2\sigma^2}\right\} dx \quad (10.1)$$

で与えられる。

2.1 の曲線

$$y = \int_{-\infty}^x (2\pi\sigma^2)^{-1/2} \exp\left\{-\frac{(x-m)^2}{2\sigma^2}\right\} dx \quad (10.2)$$

を投量死亡率曲線又は投量反応率曲線 (Dosage Response Curve) と名づける。母平均 m とその毒物の半致死量 半数致死量 といい LD_{50} とかく。

或毒物の或種類の動物に対する致死効果を知るといふことは、それに対する投量死亡率曲線 (10.2) を知るといふことであつて、結局 LD_{50} の m 及び標準偏差 σ を知ればよいのである。

(10.2) を書直すと、

$$y = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\frac{x-m}{\sigma}} \exp\left\{-\frac{t^2}{2}\right\} dt$$

と作るから、今

$$\alpha \equiv -m/\sigma, \quad \beta \equiv 1/\sigma \quad (10.4)$$

とおくと

$$y = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\alpha+\beta x} \exp\left(-\frac{t^2}{2}\right) dt$$

母数 m, σ の代りに α, β を知つても曲線を描くことが出来る。

今何匹かの動物を用いて実験して、その何々の動物の致死量を知る事が出来るならば良く知られた普通の推定理論によつて、 m, σ を推定すればよいのであるが、何々の動物の致死量というものは、原理的に観測不可能である。何君、今一定の強さ α の毒物を投与するならばその致死量が α 以下である動物は皆死んでしまうからである。又一匹の動物はその強さの弱いものから段々に強い毒物を投与して行くという方策でも、その累積効果の機構が明らかでない限り夫張り致死量は判らぬ。

同様の事情は物理的実験で、例えば Radu の Proximity Fuse の Sensitivity を測定する場合にも生ずることから Milton Friedman によつて指摘された。

このような場合の実験は普通次のように行はれる。供試動物の数を毒物の強さの水率 x_1, x_2, \dots, x_k に対して夫々 M_1, M_2, \dots, M_k とする。各水率における生残数を夫々 s_1, s_2, \dots, s_k 、従つて死亡数は夫々 $M_1 - s_1, M_2 - s_2, \dots, M_k - s_k$ であるとする。

死亡水率における母集団の死亡率は

$$P_i = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\alpha+\beta x_i} \exp\left(-\frac{t^2}{2}\right) dt, \quad i=1, 2, \dots, k \quad (10.6)$$

母集団生残率は

$$Q_i \equiv 1 - P_i = \frac{1}{\sqrt{2\pi}} \int_{\alpha+\beta x_i}^{\infty} \exp\left(-\frac{t^2}{2}\right) dt, \quad i=1, 2, \dots, k \quad (10.7)$$

であるから死亡水率で s_i 匹生残する確率は

$$\binom{M_i}{s_i} P_i^{s_i} Q_i^{M_i - s_i}, \quad i=1, 2, \dots, k$$

である。

ここで各々は各毒物水率における供試動物数 M_i が充分大として大標本理論を考えよう。

標本死亡率

$$p_i = \frac{n_i \cdot d_i}{n_i} \quad i=1, 2, \dots, R$$

は母集団死亡率 P_i の観測値であつて、 n_i が充分大ならば近似的に

$$P_i \sim N\left(P_i, \sqrt{\frac{P_i Q_i}{n_i}}\right) \quad i=1, 2, \dots, R$$

に従ふことは良く知られてゐる。

今変換

$$P_i = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\frac{y_i - m}{\sigma}} \exp\left\{-\frac{t^2}{2}\right\} dt \quad i=1, 2, \dots, R \quad (10.8)$$

$$Z_i \equiv \frac{y_i - m}{\sigma} \quad i=1, 2, \dots, R \quad (10.9)$$

によつて新変数 Z_i を導入すると、 $M_i \rightarrow \infty$ のとき、 Z_i の極限分布の密度は

$$\sqrt{\frac{n_i}{2\pi P_i Q_i}} f_i \exp\left\{-\frac{n f_i^2}{2 P_i Q_i} (Z_i - \alpha - \beta x_i)^2\right\} \quad (10.10)$$

となる。但し、

$$i=1, 2, \dots, R$$

$$f_i = \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{1}{2}(\alpha + \beta x_i)^2\right\} \quad i=1, 2, \dots, R \quad (10.11)$$

毒物の各水準の実験が全く独立ならば、 Z_1, Z_2, \dots, Z_R の同時分布の密度は

$$\prod_{i=1}^R \sqrt{\frac{n_i}{2\pi P_i Q_i}} f_i \exp\left\{-\frac{1}{2} S\right\} \quad (10.12)$$

但し、

$$S \equiv \sum_{i=1}^R \frac{n_i f_i^2}{P_i Q_i} (Z_i - \alpha - \beta x_i)^2 \quad (10.13)$$

となる。

そこで (10.13) の P_i, Q_i は (10.6)(10.7) から見るように未知母数 α, β を含むから、本ノ章と全く同様に α, β を推定するわけは行かぬ。

考1. 平均値で考えると $E(\phi_i) = P_i$ だから

$E(y_i) = x_i$ となるべきだから (10.9) は

$$E(Z_i) = \frac{x_i - m}{\sigma} = \alpha + \beta x_i \quad i=1, 2, \dots, R$$

と知る。つまり、 Z_i の平均値は α, β 平面上の一直線上にある。よつてこれらも一種の直線の当てめと考えることが出来るが、その各点で分散が異なるのである。

よつて $(X_i, Z_i), i=1, 2, \dots, K$ を平面上にプロットしては Free Hand で直線を当てめて、 α, β の近似値 α', β' を求める。

$$Z_i - \alpha' - \beta' X_i = Z_i - \alpha_1 - \beta_1 X_i - (\alpha - \alpha_1) - (\beta - \beta_1) X_i$$

であるから

$$Z_i' = Z_i - \alpha_1 - \beta_1 X_i \quad i=1, 2, \dots, K$$

$$\alpha' = \alpha - \alpha_1, \quad \beta' = \beta - \beta_1$$

として (10.13) の代りは

$$P_i' = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\alpha' - \beta' X_i} \exp -\frac{t^2}{2} dt \quad i=1, 2, \dots, K$$

$$Q_i' = 1 - P_i'$$

として

$$S' = \sum_{i=1}^K \frac{n_i f_i'^2}{P_i' Q_i'} (Z_i' - \alpha' - \beta' X_i)^2 \quad (10.14)$$

これから a. Markoff の定理によつて α', β' の最良線型不偏推定値 $\hat{\alpha}', \hat{\beta}'$ を求めて α, β の推定値として

$$\hat{\alpha} = \alpha_1 + \hat{\alpha}', \quad \hat{\beta} = \beta_1 + \hat{\beta}' \quad (10.15)$$

をとる。そして (10.15) の $\hat{\alpha}', \hat{\beta}'$ を α, β の代りに用いて上と同様の方法を繰返して行つて、 α, β の推定値を求めると言うのが、

Fisher-Blaiz の方法なのである。

若し、 α, β の推定値 $\hat{\alpha}, \hat{\beta}$ が求まるならば

$$\hat{m} = -\hat{\alpha}/\hat{\beta}, \quad \hat{\sigma} = 1/\hat{\beta} \quad (10.16)$$

で、 m, σ の推定値とするならば、大標本のときはこれらは漸近的に不偏で

$$D^2(\hat{m}) = \sigma^2 D^2(\hat{\alpha}) + 2\sigma^2 m C(\hat{\alpha}, \hat{\beta}) + \sigma^2 m^2 D^2(\hat{\beta}) \\ = \sigma^2 \{ D^2(\hat{\alpha}) + 2m C(\hat{\alpha}, \hat{\beta}) + m^2 D^2(\hat{\beta}) \}$$

$$D^2(\hat{\alpha}) = \sigma^2 D^2(\hat{\beta})$$

仮りに $\hat{\alpha}, \hat{\beta}$ として (10.15) をとれば

$$H_1 = \sum_{i=1}^k m_i f_i'^2 / R_i' Q_i' \quad H_2 = \sum_{i=1}^k m_i f_i'^2 X_i^2 / P_i' Q_i'$$

$$H_3 = \sum_{i=1}^k m_i f_i'^2 X_i / P_i' Q_i'$$

よやくと、

$$D^2(\hat{\alpha}) = H_2 / (H_1 H_2 - H_3^2)$$

$$D^2(\hat{\beta}) = H_1 / (H_1 H_2 - H_3^2)$$

$$C(\hat{\alpha}, \hat{\beta}) = -H_3 / (H_1 H_2 - H_3^2)$$

よつて、

$$D^2(\hat{m}) = \frac{1}{H_1 H_2 - H_3^2} (m^2 H_1 - 2m H_3 + H_2)$$

$$= \frac{1}{H_1 H_2 - H_3^2} \sum_{i=1}^k m_i f_i'^2 (m - X_i)^2 / R_i' Q_i' \quad (10.17)$$

$$D^2(\hat{\sigma}^2) = \frac{\sigma^2}{H_1 H_2 - H_3^2} \quad H_1 = \frac{\sigma^2}{H_1 H_2 - H_3^2} \sum_{i=1}^k m_i f_i'^2 / R_i' Q_i'$$

次に二種類の動物に対して同一毒物の又は一種類の動物に対して二種類の毒物の致死効果を調べる場合にはその数量死亡率曲線を夫々

$$y_v = \frac{1}{\sqrt{2\pi} \sigma_v} \int_{-\infty}^{x_i} \exp\left\{-\frac{(t - m_v)^2}{2\sigma_v^2}\right\} dt \quad v=1, 2 \quad (10.18)$$

として標本死亡率を $P_i^{(v)}$ 又は


$$P_i^{(v)} = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\frac{y_i^{(v)} - m_v}{\sigma_v}} \exp\left\{-\frac{t^2}{2}\right\} dt \quad i=1, 2, \dots, k$$

$$Z_i^{(v)} = (y_i^{(v)} - m_v) / \sigma_v$$

とするとき理論的には $\sigma = \sigma_2$ であると考えられる。それは

$$E(Z_i^{(v)}) = \frac{y_i - m_v}{\sigma_v} \quad v=1, 2.$$

はる二直線が差し交はれば、ある点 $x=d$ を境にして、その前後で致死効果の逆転をみるからである。



実際のデータに基づいて $\sigma_1 = \sigma_2$ 即ち仮説

$$H_0: \beta_1^{(1)} = \beta_2^{(2)}$$

を検定するには (10.14) の S' を用いて 第 2 章 § 8 の試験を適用すればよい。