

②③ 最小自來法に関する Markoff の定理を  
續つて (其の一)

著者 小川 潤次郎

筆者はさきに本著究録第三巻第7号に於て同じ表題で書いたのであるが其の後増山元三郎博士よりの注意に依つて、*Statistical Research Memorirs, Volume II, Department of Statistics University of London, University College* に J. Neyman と F. N. David の論文のあることを知り、又 P. L. Hsu の論文を読む機会があつたので、此の機会に之等二つの論文を紹介しておくことにする。

F. N. David and J. Neyman : Extension  
of The Markoff Theorem on Least Squares  
P. L. Hsu : On The Best Unbiased Quadratic  
Estimate of The Variance

§1  $n$ 個の母集団  $\pi_1, \pi_2, \dots, \pi_n$  があつて各母集団より丁度一つづつの個体が抽出されるとする。それらの抽出は互に独立に存されるものと假定する。今ある性質に着目するとして、それを表す値を  $x_1, x_2, \dots, x_n$  とする。 $\theta$  は  $\pi_1, \pi_2, \dots, \pi_n$  のある collective character とする。

定義 I, 或函数  $f(x_1, x_2, \dots, x_n)$  があつて母集団  $\pi_1, \pi_2, \dots, \pi_n$  の性質の如何に拘らず  $f(x_1, x_2, \dots,$

$x_2$ )の数学的期望値が恒等的に $\theta$ に等しい。

$$E[f(x_1, x_2, \dots, x_n)] \equiv \theta \quad (7)$$

のとき、 $f(x_1, x_2, \dots, x_n)$ は $\theta$ の不偏推定値であると云ふ。

かやうな不偏推定値の内、特に線形であるものを線形不偏推定値と云ふ。collective character  
 $\theta$ の線形不偏推定値は一般には羣山あるが、それ等の中でその標準偏差の小さいもの程良い推定値であるとする。

定義II、 $X$ の一次函数 $F$ が次の性質を有するとき、 $F$ は $\theta$ の最良線形不偏推定値又は簡単に最良推定値と云ふ。

$$E(F) \equiv \theta \quad (2)$$

$$E(F - \theta)^2 = \text{最小} \quad (3)$$

これ又定義して拡張されたMarkoffの定理を述べると次の如くなる。

### 拡張されたMarkoffの定理

(a)  $x_1, x_2, \dots, x_n$  はすべて独立である。

(b)  $x_i$  ( $i=1, 2, \dots, n$ )の平均値は $S$ 個の未知  
常数 $p_j$  ( $j=1, 2, \dots, S$ )の一次形式である。

$$E(x_i) = a_{i1}p_1 + a_{i2}p_2 + \dots + a_{iS}p_S \quad (4)$$

値し係数 $a_{ij}$  ( $j=1, 2, \dots, S$ )は既知である。

(c) 与ふる $n$ 個の方程式から少くとも一組の $S$ 個の方程式を取れば $p_j$ に関して解ける即ち行列

$$M = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1s} \\ a_{21} & a_{22} & \cdots & a_{2s} \\ \cdots & \cdots & \cdots & \cdots \\ a_{n1} & a_{n2} & \cdots & a_{ns} \end{pmatrix} \quad (5)$$

の階数は  $s$  である。

(d)  $x_i$  の分散  $\sigma_i^2$  については

$$\sigma_i^2 = \frac{\sigma^2}{P_i} \quad (i=1, 2, \dots, s) \quad (6)$$

で  $\sigma$  は未知でもよいが  $P_i$  はある既知の正数であるとす。

以上の (a), (b), (c), (d) なる 4 条件の下に次の (e) (f) なる二つの結論が出る。

(e)  $b_1, b_2, \dots, b_s$  は既知の常数として,  $P_1, P_2, \dots, P_s$  の一次函数

$$\theta = b_1 P_1 + b_2 P_2 + \cdots + b_s P_s \quad (7)$$

の最良線形不偏推定値は次の如くして得られる。

即ち

$$S = \sum_{i=1}^n (x_i - a_{i1} g_1 - a_{i2} g_2 - \cdots - a_{is} g_s)^2 P_i \quad (8)$$

を最小ならしめる  $g_1, g_2, \dots, g_s$  の値を  $g_1^0, g_2^0, \dots, g_s^0$  として、これを (7) の  $P_1, P_2, \dots, P_s$  に代入すればよい。

$$F = b_1 g_1^0 + b_2 g_2^0 + \cdots + b_s g_s^0 \quad (9)$$

(f)  $F$  の分散の推定値は

$$\mu_F^2 = \frac{S_0}{n-s} \sum_{i=1}^s \frac{\lambda_i^2}{P_i} \quad (10)$$

(154)

であられる、但し  $S_0$  は  $S$  の最小値

$$S_0 = \sum_{i=1}^n (x_i - a_i) q_i^0 - a_2 z q_2^0 - \dots - a_s z q_s^0 \quad (11)$$

${}^2P_i$

で、又  $\lambda_i$  は (9) 式の  $x_i$  の係数である。

(α) の証明：方針は最良線形不偏推定値の定義から得られる  $F$  の式と (α) の方法で得られる (9) とを比較して、その一致することを示す。

$$F = \sum_{i=1}^n \lambda_i x_i \quad (12)$$

として、 $\mathcal{E}(F) \equiv \theta$  が  $P$  に関して恒等的に成立つと云ふ条件を書いて見ると、

$$\mathcal{E}(F) = \sum_{i=1}^n \lambda_i \mathcal{E}(x_i) = \sum_{j=1}^s p_j \sum_{i=1}^n \lambda_i a_{ij} \quad (13)$$

であるから次の  $s$  個の式が成立つ。

$$\sum_{i=1}^n \lambda_i a_{ij} = b_j \quad (j=1, 2, \dots, s) \quad (14)$$

$s \leq n$  であるから、(14) を満足する  $\lambda_1, \lambda_2, \dots, \lambda_n$  の組は一般には無数にある。それらの内で

$$\sigma_F^2 = \sum_{i=1}^n \sigma_i^2 \lambda_i^2 = \sigma^2 = \sum_{i=1}^n \frac{\lambda_i^2}{P_i} \quad (15)$$

を最小にする如き  $\lambda$  を求めよう。その為

$$\phi = \sum_{i=1}^n \frac{\lambda_i^2}{P_i} - 2 \sum_{k=1}^s d_k \sum_{i=1}^n \lambda_i a_{ik} \quad (16)$$

として

$$\frac{\partial \phi}{\partial \lambda_i} = \frac{2\lambda_i}{P_i} - 2 \sum_{k=1}^s d_k a_{ik} = 0. \quad (17)$$

$$\lambda_i = P_i \sum_{k=1}^s \alpha_k a_{ik} \quad (i=1, 2, \dots, n) \quad (98)$$

(98) を (14) に代入して整理すれば

$$d_1 \sum_{i=1}^n P_i a_{ij} a_{i1} + d_2 \sum_{i=1}^n P_i a_{ij} a_{i2} + \dots + d_s \sum_{i=1}^n P_i a_{ij} a_{is} = b_j \quad (j=1, 2, \dots, s) \quad (99)$$

そこで今

$$G_{jk} = \sum_{i=1}^n P_i a_{ij} a_{ik} \quad (20)$$

$$\Delta = \begin{vmatrix} G_{11} & G_{12} & \dots & G_{1s} \\ G_{21} & G_{22} & \dots & G_{2s} \\ \dots & \dots & \dots & \dots \\ G_{s1} & G_{s2} & \dots & G_{ss} \end{vmatrix} \quad (21)$$

とおけば  $\Delta$  は

$$M' = \begin{vmatrix} \sqrt{P_1} a_{11} & \sqrt{P_1} a_{12} & \dots & \sqrt{P_1} a_{1s} \\ \sqrt{P_2} a_{21} & \sqrt{P_2} a_{22} & \dots & \sqrt{P_2} a_{2s} \\ \dots & \dots & \dots & \dots \\ \sqrt{P_n} a_{n1} & \sqrt{P_n} a_{n2} & \dots & \sqrt{P_n} a_{ns} \end{vmatrix} \quad (22)$$

とすれば  $\Delta = M'^2$  であつて、 $P_i$  はすべての正であるから  $M'$  は  $M$  と同様の性質を有す。即ち  $M'$  の階数は  $s$  であるから、 $M'$  の  $s$  次の小行列式の内には必ずとも一つ  $0$  でないものがある。而して  $\Delta$  は  $M'$  の  $s$  次の小行列式の積和であるから、<sup>(1)</sup> 確かに  $0$  でない。従つて (9) なる聯立方程式は Cramer の (註 (1) 藤原松三郎：行列及び行列式、29 頁、定理 11 参照)

公式に依つて次の如く解かれる。 $\Delta$  に代ける  $G_{jk}$  の

係因子を  $\Delta_{jk}$  として

$$d_k = \frac{1}{\Delta} \sum_{j=1}^s b_j \Delta_{jk} \quad (23)$$

(23) を (18) に代入して

$$\lambda_i = P_i \sum_{k=1}^s a_{ik} \frac{1}{\Delta} \sum_{j=1}^s b_j \Delta_{jk} \quad (i=1, 2, \dots, n) \quad (24)$$

かかる  $\lambda$  の値に対して  $\sigma^2$  は条件 (14) の下に極値を有する訳であるが、 $\sigma^2$  は non-negative であり、何程でも大なる値を取り得るから、結局 (24) なる  $\lambda$  の値に対しては最小値を取る。(24) の  $\lambda$  の値を (12) 式に代入して、the best linear estimation として

$$F = \sum_{i=1}^n P_i X_i \sum_{k=1}^s a_{ik} \frac{1}{\Delta} \sum_{j=1}^s b_j \Delta_{jk} \quad (25)$$

を得る之を書面して

$$F = \sum_{j=1}^s b_j \sum_{k=1}^s \frac{\Delta_{jk}}{\Delta} \sum_{i=1}^n P_i X_i a_{ik} \quad (26)$$

次に吾々は (2) 方法に依つて  $F$  の形を求めて見よう。(8) の  $S$  を最小ならしめる  $g_1^0, g_2^0, \dots, g_s^0$  は  $S$  を  $g_j$  で偏微分して

$$g_1^0 \sum_{i=1}^n P_i a_{i1} a_{ij} + g_2^0 \sum_{i=1}^n P_i a_{i2} a_{ij} + \dots + g_s^0 \sum_{i=1}^n P_i a_{is} a_{ij} = \sum_{i=1}^n P_i X_i a_{ij} \quad (j=1, 2, \dots, s) \quad (27)$$

から求められる。而してこれは (26) の記号を用ひれば

$$G_j^0 g_1^0 + G_j^0 g_2^0 + \dots + G_j^0 g_s^0 = \sum_{i=1}^n P_i X_i a_{ij} \quad (27')$$

であるから

$$g_k^0 = \frac{1}{\Delta} \sum_{j=1}^S \Delta_j k \sum_{i=1}^n P_i x_i a_{ij} \quad (k=1, 2, \dots, S) \quad (28)$$

従つてこの  $g_k^0$  の値を(9)式に代入して

$$F_1 = \frac{1}{\Delta} \sum_{j=1}^S \Delta_j k \sum_{i=1}^n P_i x_i a_{ij} \quad (29)$$

となつてこれは(26)式の  $F$  と一致する。こゝで(2)は証明出来たことになる。

(β) の証明

$$\mu_F^2 = \frac{S_0}{n-s} \sum_{i=1}^n \frac{d_i^2}{P_i} \quad (30)$$

が  $\sigma_F^2$  の unbiased estimate である爲には

$$E(S_0) \equiv (n-s) \sigma^2 \quad (31)$$

であることが必要にして且つ充分である。

$$S_Z = \sum_{i=1}^n (Z x_i - a_{i1} g_1 - a_{i2} g_2 - \dots - a_{iS} g_S) \quad (32)$$

とすれば、 $Z=1$  のとき  $S_1 \equiv S$  である。併し  $S_Z$  は、 $Z, g_1, g_2, \dots, g_S$  に関する二次の齊次多項式であるから Euler の公式に依つて

$$S_Z = \frac{1}{2} \left( \frac{\partial S_Z}{\partial Z} Z + \frac{\partial S_Z}{\partial g_1} g_1 + \dots + \frac{\partial S_Z}{\partial g_S} g_S \right) \quad (33)$$

である。併し  $g_1^0, \dots, g_S^0$  は  $\frac{\partial S}{\partial g_i} = 0$  の根であることに注意すれば

$$S_0 = \frac{1}{2} \left( \frac{\partial S_Z}{\partial Z} \right)_{Z=1} \quad (34)$$

$$g_j^0 = g_j^0 \quad (j=1, 2, \dots, S)$$

$$\begin{aligned}
&= \sum_{i=1}^n (x_i - a_{i1}g_1^0 - a_{i2}g_2^0 - \dots - a_{is}g_s^0) P_i x_i \\
&= \sum_{i=1}^n P_i x_i^2 - g_1^0 \sum_{i=1}^n P_i x_i a_{i1} - g_2^0 \sum_{i=1}^n P_i x_i a_{i2} \dots \\
&\quad \dots - g_s^0 \sum_{i=1}^n P_i x_i a_{is} \tag{35}
\end{aligned}$$

扱てこゝで

$$\xi_i = x_i - a_{i1}P_1 - a_{i2}P_2 - \dots - a_{is}P_s \tag{36}$$

$$\eta_i = g_i - P_i \tag{37}$$

とおけば

$$S = \sum_{i=1}^n (\xi_i - a_{i1}\eta_1 - a_{i2}\eta_2 - \dots - a_{is}\eta_s)^2 P_i \tag{38}$$

となる。これを(32)式と比較して

$$\eta_i^0 = g_i^0 - P_i \tag{39}$$

とすれば前と同様の計算に依つて

$$\begin{aligned}
S_0 &= \sum_{i=1}^n P_i \xi_i^2 - \eta_1^0 \sum_{i=1}^n P_i \xi_i a_{i1} - \eta_2^0 \sum_{i=1}^n P_i \xi_i a_{i2} - \dots \\
&\quad \dots - \eta_s^0 \sum_{i=1}^n P_i \xi_i a_{is} \tag{40}
\end{aligned}$$

斯くして

$$E(\xi_i^2) = E((x_i - E(x_i))^2) = \sigma_i^2 = \frac{\sigma^2}{P_i} \tag{41}$$

$$E(\xi_i \xi_j) = E((x_i - E(x_i))(x_j - E(x_j))) = 0 \tag{42}$$

(38), (39) を用いて

$$\eta_k^0 = \frac{1}{\Delta} \sum_{l=1}^s \Delta_{lk} \sum_{j=1}^n P_j \xi_j a_{jl} \tag{43}$$

従つて(41), (42) を用いて

$$E(\eta_k^0 \xi_i) = \frac{1}{\Delta} \sum_{l=1}^s \Delta_{lk} \sum_{j=1}^n P_j E(\xi_j \xi_i) a_{jl} \tag{459}$$



$$\begin{aligned}
 &= \frac{1}{\Delta} \sum_{\ell=1}^S \Delta_{\ell k} P_{\ell} \frac{\sigma^2}{P_{\ell}} a_{\ell e} \\
 &= \frac{\sigma^2}{\Delta} \sum_{\ell=1}^S \Delta_{\ell k} a_{\ell e} \quad (44)
 \end{aligned}$$

従つて

$$\begin{aligned}
 \mathcal{E}(S_0) &= n\sigma^2 - \frac{\sigma^2}{\Delta} \left[ \sum_{\ell=1}^S P_{\ell} a_{\ell 1} \sum_{\ell=1}^S \Delta_{\ell 1} a_{\ell e} + \sum_{\ell=1}^n P_{\ell} a_{\ell 2} \right. \\
 &\quad \left. \sum_{\ell=1}^S \Delta_{\ell 2} a_{\ell e} + \dots + \sum_{\ell=1}^n P_{\ell} a_{\ell s} \sum_{\ell=1}^S \Delta_{\ell s} a_{\ell e} \right] \\
 &= \sigma^2 \left\{ n - \frac{1}{\Delta} \left[ \sum_{\ell=1}^S \Delta_{\ell 1} G_{\ell 1} + \sum_{\ell=1}^S \Delta_{\ell 2} G_{\ell 2} + \dots + \sum_{\ell=1}^S \Delta_{\ell s} G_{\ell s} \right] \right\} \quad (45)
 \end{aligned}$$

併で

$$\sum_{\ell=1}^S \Delta_{\ell j} G_{\ell j} = \Delta \quad (j=1, 2, \dots, S) \quad (46)$$

であるから

$$\mathcal{E}(S_0) = \sigma^2 (n - S) \quad (47)$$

これで (β) の証明が終る。

次に  $K, F, S_0$  及び  $\sum_{\ell=1}^n \frac{1_{\ell}^2}{P_{\ell}}$  を行列式で表はすことを考へよう。

$$H_j = \sum_{\ell=1}^n P_{\ell} x_{\ell} a_{\ell j} \quad (48)$$

とおくと

$$F = \frac{1}{\Delta} \sum_{k=1}^S b_k \sum_{j=1}^S \Delta_{jk} H_j \quad (49)$$

$$= - \frac{\Delta_{\theta}}{\Delta} \quad (50)$$

但し

$$\Delta_0 = \begin{vmatrix} 0 & b_1 & b_2 & \dots & b_s \\ H_1 & G_{11} & G_{12} & \dots & G_{1s} \\ H_2 & G_{21} & G_{22} & \dots & G_{2s} \\ \dots & \dots & \dots & \dots & \dots \\ H_s & G_{s1} & G_{s2} & \dots & G_{ss} \end{vmatrix} \quad (51)$$

$$\text{又} \quad H_0 = \sum_{i=1}^n P_i \chi_i^2 \quad (52)$$

とすれば

$$S_0 = \frac{1}{\Delta} \left\{ H_0 \Delta - H_1 \sum_{j=1}^s \Delta_{j1} H_j - H_2 \sum_{j=1}^s \Delta_{j2} H_j - \dots - H_s \sum_{j=1}^s \Delta_{js} H_j \right\} = \frac{\Delta_0}{\Delta} \quad (53)$$

但し

$$\Delta_0 = \begin{vmatrix} H_0 & H_1 & H_2 & \dots & H_s \\ H_1 & G_{11} & G_{12} & \dots & G_{1s} \\ H_2 & G_{21} & G_{22} & \dots & G_{2s} \\ \dots & \dots & \dots & \dots & \dots \\ H_s & G_{s1} & G_{s2} & \dots & G_{ss} \end{vmatrix} \quad (54)$$

次に (24) の  $\lambda_i$  の値を用いて

$$\sum_{i=1}^n \frac{\lambda_i^2}{P_i} = \frac{1}{\Delta^2} \sum_{i=1}^n P_i \left( \sum_{k=1}^s a_{ik} \sum_{j=1}^s b_j \Delta_{jk} \right)^2 \quad (55)$$

$$\sum_{i=1}^n \frac{\lambda_i^2}{P_i} = \frac{1}{\Delta^2} \sum_{i=1}^n P_i \left\{ \left[ \sum_{j=1}^s b_j \sum_{k=1}^s \Delta_{jk} a_{ik} \right] \left[ \sum_{l=1}^s b_l \sum_{m=1}^s \Delta_{lm} a_{im} \right] \right\} \quad (56)$$

$$\sum_{i=1}^n \frac{\lambda_i^2}{P_i} = \frac{1}{\Delta^2} \sum_{j=1}^s b_j \sum_{k=1}^s b_k \sum_{l=1}^s \Delta_{jk} \sum_{m=1}^s \Delta_{lm} \sum_{i=1}^n P_i a_{ik} a_{im}$$

$$= \frac{1}{\Delta^2} \sum_{j=1}^s b_j \sum_{l=1}^s b_l \sum_{k=1}^s \Delta_{jkl} \sum_{n=1}^s \Delta_{nl} G_{nkl} \quad (57)$$

$$\sum_{n=1}^s \Delta_{nl} G_{nkl} = \begin{cases} 0, & k \neq l \\ \Delta, & k = l \end{cases} \quad (58)$$

よであるから

$$\begin{aligned} \sum_{i=1}^n \frac{\lambda_i^2}{P_i} &= \frac{1}{\Delta} \sum_{j=1}^s b_j \sum_{k=1}^s b_k \Delta_{jk} \\ &= -\frac{\Delta_1}{\Delta} \end{aligned} \quad (59)$$

$$\Delta_1 = \begin{vmatrix} 0 & b_1 & b_2 & \cdots & b_s \\ b_1 & G_{11} & G_{12} & \cdots & G_{1s} \\ b_2 & G_{21} & G_{22} & \cdots & G_{2s} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ b_s & G_{s1} & G_{s2} & \cdots & G_{ss} \end{vmatrix} \quad (60)$$

依つて分散の推定値は

$$\mu_F^2 = -\frac{\Delta_0 \Delta_1}{(n-s)\Delta^2} \quad (61)$$

## §2. 上述の Markoff の定理の応用例

ある一つの確率変数  $y$  が他の確率変数  $x$  と相関し、 $y$  の  $x$  に関する regression は linear であり、且つ  $x$  を変へたときの  $y$  の分散は未知であるが有限でそれは  $x$  の値に無関係に  $\sigma^2$  であるとする。そのとき  $x = X$  のときの  $Y(X)$  を estimate しようとするのである。大切なことは  $y$  が正規分布すると仮定しないと成り立たない点である。

先づ  $x$  の値例へば

$$x_1, x_2, \dots, x_n \quad (1)$$

に対して  $y$  の値が測定され、これらの測定値は互に独立であるとする。吾々の問題は次の三点である。  
 (a)  $Y(x)$  の best linear estimate  $F(x)$  を求め、(b)  $F(x)$  の分散の estimate  $\mu_{F^2(x)}$  を求め、次に (c)  $x_1, x_2, \dots, x_n$  の如何なる系に対して  $F(x)$  が最も大なる正確度を有するか。

これに対して、Markoff の定理が直接に適用出来る様に問題を formulate しよう。(a) の各  $x$  に対して独立に測定された  $y$  の値を

$$y_1, y_2, \dots, y_n \quad (2)$$

とすれば、これが明かに前節の  $x_1, \dots, x_n$  の役をするから定理の条件 (a) は満たされる。次に

$$E(y_i) = P_1 + P_2 x_i \quad (3)$$

であるから  $P_1, P_2$  が unknown parameter で  $d = 2$  である。定理のときと比較して

$$a_{i1} = 1, a_{i2} = x_i \quad (4)$$

であるから、行列 (5) は  $x_1, x_2, \dots, x_n$  が皆等しくなければ階数 2 である。即ち定理の条件 (b) (c) は満足される。

次に  $y_i$  の分散  $\sigma_i^2$  とすれば

$$\sigma_i^2 = \frac{\sigma^2}{P_i} \quad (5)$$

でこのときは  $P_i = 1, i = 1, 2, \dots, n$  であるから (4) もより。

最後に調べることは  $Y(x)$  が  $P_1, P_2$  の linear な

函数であるかと云ふことだがそれは  $Y(X)$  は  $x = X$  のときの平均値であるから

$$\theta = Y(X) = \beta_1 + \beta_2 X \quad (6)$$

で  $b_1 = 1$ ,  $b_2 = X$  である。依つて Markoff の定理が適用出来るのである。

$$G_{11} = n, \quad G_{12} = \sum_{i=1}^n x_i = G_{21}, \quad G_{22} = \sum_{i=1}^n x_i^2 \quad (7)$$

$$\Delta = \begin{vmatrix} G_{11} & G_{12} \\ G_{21} & G_{22} \end{vmatrix} = n \sum_{i=1}^n x_i^2 - \left( \sum_{i=1}^n x_i \right)^2 = n \sigma_x^2 \quad (8)$$

又  $K$  又

$$H_1 = \sum_{i=1}^n y_i, \quad H_2 = \sum_{i=1}^n x_i y_i \quad (9)$$

であるから

$$\Delta_{\theta} = \begin{vmatrix} 0 & 1 & X \\ H_1 & G_{11} & G_{12} \\ H_2 & G_{21} & G_{22} \end{vmatrix}$$

$$= -(H_1 G_{22} - H_2 G_{12}) + X(H_1 G_{21} - H_2 G_{11}) \quad (10)$$

$$= -n^2 \left\{ \sigma_x^2 \bar{y} + (X - \bar{x}) \left( \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \bar{y} \right) \right\}$$

依つて

$$F(X) = \bar{y} + \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{n \sigma_x^2} (X - \bar{x}) \quad (11)$$

ニ  $\mu$  はよく知られた regression の方程式である。

次に  $\mu_{F(X)}^2$  を計算しよう。

$$H_0 = \sum_{i=1}^n y_i^2 \quad (12)$$

(162)

$$\Delta_0 = \begin{vmatrix} \sum y^2 & \sum y & \sum xy \\ \sum y & n & \sum x \\ \sum xy & \sum x & \sum x^2 \end{vmatrix} \quad (13)$$

$x, y$  の標本相関係数  $r$ ,  $n\sigma_y^2 = \sum_{i=1}^n (y_i - \bar{y})^2$  とし (13) の行列式で第二行を  $\bar{y}$  倍して、第一行から引き次に第三行を  $\bar{x}$  倍して第三行から引くと

$$\Delta_0 = \begin{vmatrix} n\sigma_y^2 & 0 & n r \sigma_x \sigma_y \\ \sum y & n & \sum x \\ n r \sigma_x \sigma_y & 0 & n\sigma_x^2 \end{vmatrix} = n^3 \sigma_x^2 \sigma_y^2 (1 - r^2) \quad (14)$$

又

$$\begin{vmatrix} 0 & 1 & X \\ 1 & n & \sum x \\ X & \sum x & \sum x^2 \end{vmatrix} = 2X \sum x - nX^2 - \sum x^2 \quad (15)$$

$$= -n \left\{ \sigma_x^2 + (X - \bar{x})^2 \right\} \quad (16)$$

故に

$$\mu_{F(x)}^2 = -\frac{\Delta_0 \Delta_1}{(n-2)\Delta^2} = \frac{\sigma_y^2 (1-r^2)}{n-2} \left\{ 1 + \frac{(X-\bar{x})^2}{\sigma_x^2} \right\} \quad (17)$$

(17) 式に依つて (c) の答も出る。即ち  $X = \bar{x}$  となし得ない場合には、 $\sigma_x$  が最大のとき  $\mu_{F(x)}^2$  が最小になる。