

⑱ 或るDISCRIMINATIONについて

(普通の最小二乗法が使えない場合の一例)

樋口 伊佐夫

弾性の歪と応力と関係や、有機化合物の熱分解に於ける、*initial pressure* と *reaction rate* との関係の様に、或る量 X と他の量 Z との函数関係が Z の或る値 Z_0 (弾性に於ける *limit of linear elasticity* の如きもの) を境にして異なる場合がある。

その場合、種々の (Controlable な) Z の値に対する X の測定値から、 Z_0 の値を推定することが、屢々必要になる。殊に他の実験から、直接又は間接に Z_0 を測定することが出来ない場合、重要性をもつ。

こういう問題を数理統計学的に取扱つたものが、ちよつと見当らなかつたので、考へてみた。未だ十分満足なものではないが、或程の方法を提示しておく。

近い将来にもつとすぐれた方法のみつかることを、期待するものである。

1. 折線の場合の点推定法


折線の場合は、最も単純で、典型的であるから、先づ述べて置く。

X と Z との眞の関係が

$$Z \leq Z_0 \text{ で } X = a_1 + b_1 Z$$

$$Z > Z_0 \text{ で } X = a_2 + b_2 Z$$

$$\text{但し } Z_0 = - \frac{a_1 - a_2}{b_1 - b_2} \text{ ----- (1)}$$



(Fig. 1)

であるとする。 a_1, a_2, b_1, b_2 及び Z_0 は未知の常数。

今 Z を確定変数と考え、 X を $Z \leq Z_0$ で $N(a_1 + b_1 Z, \sigma^2)$ 、 $Z \geq Z_0$ で $N(a_2 + b_2 Z, \sigma^2)$ に従う variates と考える。

又 Z の異なる点に於ける X は互いに独立に分布するものとする。

$Z_1, Z_2, \dots, Z_{n_1}, Z_1, Z_2, \dots, Z_{n_2}$ なる $n (= n_1 + n_2)$ 個の点

に於ける X の測定値を夫々 $x_1, x_2, \dots, x_{n_1}, x_1, x_2, \dots, x_{n_2}$ とする。但し、 $Z_i \equiv Z_{i+1} \equiv Z_0$ ($i=1, \dots, n_1-1$)

$Z_i \geq Z_{i+1} \geq Z_0$ ($i=1, 2, \dots, n_2$)

n_1 (従つて n_2) が既知である場合は問題ないが、一般に n_1 が未知であるため、回帰折線を推定するには、如何にすべきかという問題が起る。

この場合の標本分布は

$$(2\pi\sigma^2)^{-\frac{n}{2}} \exp \left\{ (-2\sigma^2)^{-1} \left[\sum_{i=1}^{n_1} (x_i - a_1 - b_1 Z_i)^2 + \sum_{i=1}^{n_2} (x_i - a_2 - b_2 Z_i)^2 \right] \right\}$$

であるから、最尤法の精神によると、尤度

$$L = -\frac{n}{2} \log(2\pi\sigma^2) + (2\sigma^2)^{-1} \left\{ \sum_{i=1}^{n_1} (x_i - a_1 - b_1 Z_i)^2 + \sum_{i=1}^{n_2} (x_i - a_2 - b_2 Z_i)^2 \right\}$$

を最大ならしめる様に、すればよい。

n_1 を固定したとき L を最大ならしめる a_1, a_2, b_1, b_2 及び σ^2 は

$$\left. \begin{aligned} \hat{a}_v &= \bar{x}_v - \hat{b}_v \bar{Z}_v \\ \hat{b}_v &= \frac{\sum_{i=1}^{n_v} (x_i - \bar{x}_v)(Z_i - \bar{Z}_v)}{\sum_{i=1}^{n_v} (Z_i - \bar{Z}_v)^2} \end{aligned} \right\} \dots (1.2) \quad (v=1, 2)$$

$$\left. \begin{aligned} \text{但し } \bar{x}_v &= \frac{1}{n_v} \sum_{i=1}^{n_v} x_{vi} & \bar{z}_v &= \frac{1}{n_v} \sum_{i=1}^{n_v} z_{vi} \\ \hat{\sigma}^2 &= \frac{1}{n} \sum_{v=1}^L \sum_{i=1}^{n_v} (x_{vi} - \hat{a}_v - \hat{b}_v z_{vi})^2 \end{aligned} \right\}$$

と求まるから、種々の n_v に対するこれらの組のうち、 L を最大ならしめるものは、 $-\frac{n}{2} \log(2\pi \hat{\sigma}^2)$ を最大ならしめるもの、即ち $\hat{\sigma}^2$ を最小ならしめるものである。 σ^2 を計算すると、

$$\sum_{v=1}^L \left\{ \sum_{i=1}^{n_v} (x_{vi} - \bar{x}_v)^2 - \frac{\left[\sum_{i=1}^{n_v} (x_{vi} - \bar{x}_v)(z_{vi} - \bar{z}_v) \right]^2}{\sum_{i=1}^{n_v} (z_{vi} - \bar{z}_v)^2} \right\} \quad (1.3)$$

となるから、先づこれを最小にする n_v を求め、その n_v を用いて \hat{a}_v, \hat{b}_v を (1.2) の式から計算し、それを用いて

$$\hat{z}_0 = - \frac{\hat{a}_1 - \hat{a}_2}{\hat{b}_1 - \hat{b}_2}$$

と推定すればよい。この方法による \hat{z}_0 の分布は求めにくく、この estimator の性質をしらべることはむづかしいが、次の様な discrimination の考案を用いた、区間推定法によれば、或種の statistical inference が可能である。

2. Z_0 の区間推定法 (折線の場合)

$$\text{令, } z_1 \leq z_2 \leq \dots \leq z_{m_1} \leq z_{m_1+1} \leq \dots \leq z_{n_1} \leq z_0$$

$$z_0 \leq z_{n_2} \leq z_{n_2-1} \leq \dots \leq z_{m_2} \leq z_{m_2-1} \leq \dots \leq z_2 \leq z_1$$

としてこれ等に対応する測定値 x_{vi} のうち、 $x_{11}, x_{12}, \dots, x_{1m_1}$ は、 $a_1 + b_1 z_{vi}$ の測定値であることは確かであり、 $x_{2m_2}, x_{2m_2-1}, \dots, x_{21}$ は、 $a_2 + b_2 z_{vi}$ の測定値であることが確のであるとする。 \hat{a}_v, \hat{b}_v 及び $\hat{\sigma}^2$ を、(1.2) に於ける n_v をすべて m_v で置きかえ、 n の代りに $m_1 + m_2$ と置いたものとする。

m_1, m_2 は既知であるから、これ等の量は、見本から計算出来る。

Z_0 の何れ側の側にあるかがはっきりしているところの測定値だけを用いて inference を行うのである。

$$\begin{aligned} \text{今、 } T_1 &\equiv (\hat{a} - a) / \sigma, & T_2 &\equiv (\hat{b} - b) / \sigma \quad (v=1, 2) \\ T_3 &\equiv (m_1 + m_2) \hat{\sigma}^2 / \sigma^2 \end{aligned}$$

なる量を考えると、 T_1, T_2, T_3 の同時積率母関数 $m(t_1, t_2, t_3)$ は

$$\begin{aligned} &\underbrace{\int \dots \int}_{m_1} \left(\frac{1}{2\pi\sigma^2} \right)^{\frac{m_1}{2}} \exp \left\{ \frac{\hat{a}-a}{\sigma} t_1 + \frac{\hat{b}-b}{\sigma} t_2 \right. \\ &\quad \left. + \frac{1}{\sigma^2} \sum_{i=1}^{m_1} (x_i - \hat{a} - \hat{b} Z_i)^2 t_3 - \frac{1}{2\sigma^2} \sum_{i=1}^{m_1} (x_i - a - b Z_i)^2 \right\} \prod_{i=1}^{m_1} dx_i \\ &\times \underbrace{\int \dots \int}_{m_2} \left(\frac{1}{2\pi\sigma^2} \right)^{\frac{m_2}{2}} \exp \left\{ \frac{\hat{a}-a}{\sigma} t_1 + \frac{\hat{b}-b}{\sigma} t_2 \right. \\ &\quad \left. + \frac{1}{\sigma^2} \sum_{i=1}^{m_2} (x_i - \hat{a} - \hat{b} Z_i)^2 t_3 - \frac{1}{2\sigma^2} \sum_{i=1}^{m_2} (x_i - a - b Z_i)^2 \right\} \prod_{i=1}^{m_2} dx_i \end{aligned}$$

と二つの積分の積になり、各々は普通の linear regression の場合の式であるから

$$\frac{1}{\prod_{v=1}^2} \frac{\exp \left\{ \left[2 \sum_{i=1}^{m_v} (Z_i - \bar{Z})^2 \right]^{-1} \left(t_v \frac{1}{m_v} \sum_{i=1}^{m_v} Z_i^2 - 2 \bar{Z} t_v t_1 + t_v^2 \right) \right\}}{(1 - 2 t_3)^{\frac{(m_v - 2)}{2}}} \dots (2.1)$$

となることを知る。分母の積は $(1 - 2 t_3)^{\frac{(m_1 + m_2 - 4)}{2}}$ とあるから、これから、 T_1, T_2 は平均値 0 の正規分布、 T_3 は T_1 及 T_2 とは独立に自由度 $m_1 + m_2 - 4$ の Chi-square 分布に従うことがわかる。次に

$$v \equiv (\hat{a} - a) + (\hat{b} - b) Z_0$$

なる変数を考えると、これは正規変数の一次結合であるから、や

は正規分布に従う。これも亦、 Z_0 とは独立であることは言までもない。又この平均は(1.7)より

$$E(v) = E(\hat{a}_1 - a_1) + E(a_2 - \hat{a}_2) + Z_0 E(\hat{b}_1 - b_1) + Z_0 E(\hat{b}_2 - b_2) \\ + a_1 + b_1 Z_0 - (a_2 + b_2 Z_0) = 0$$

であるから、

$$\frac{\sqrt{m_1 + m_2 - 4} \ v / \sqrt{\text{var } v}}{\sqrt{(m_1 + m_2) \hat{\sigma}^2 / \sigma^2}} \equiv t$$

は自由度 $m_1 + m_2 - 4$ の Student's t 分布に従う。

これから Z_0 の信頼区間が求まるわけである。

極、(2.1)を利用すれば

$$\text{var } v = E\left[\left\{\left(\hat{a}_1 - a_1\right) + \left(\hat{b}_1 - b_1\right) Z_0 - \left(\hat{a}_2 - a_2\right) + \left(\hat{b}_2 - b_2\right) Z_0\right\}^2\right] \\ = \sum_{v=1}^2 \left\{ E\left[\left(\hat{a}_v - a_v\right)^2\right] + 2 Z_0 E\left[\left(\hat{a}_v - a_v\right)\left(\hat{b}_v - b_v\right)\right] + Z_0^2 E\left[\left(\hat{b}_v - b_v\right)^2\right] \right\} \\ = \sigma^2 \sum_{v=1}^2 \frac{1}{\sum_{i=1}^{m_v} \left(Z_{vi} - \bar{Z}_v\right)^2} \left\{ \frac{1}{m_v} \sum_{i=1}^{m_v} Z_{vi}^2 - 2 Z_0 \bar{Z}_v + Z_0^2 \right\}$$

そこで

$$\sum_{v=1}^2 \frac{1}{\sum_{i=1}^{m_v} \left(Z_{vi} - \bar{Z}_v\right)^2} \equiv A \quad - \sum_{v=1}^2 \frac{\bar{Z}_v}{\sum_{i=1}^{m_v} \left(Z_{vi} - \bar{Z}_v\right)^2} \equiv B$$

$$\sum_{v=1}^2 \frac{\frac{1}{m_v} \sum_{i=1}^{m_v} Z_{vi}^2}{\sum_{i=1}^{m_v} \left(Z_{vi} - \bar{Z}_v\right)^2} \equiv C$$

とおくと

$$\text{var } v = \sigma^2 (A Z_0^2 + 2 B Z_0 + C) \quad \text{となるから}$$

$$t = \left[\frac{(m_1 + m_2 - 4) \left\{ \left(\hat{a}_1 - a_1\right) + \left(\hat{b}_1 - b_1\right) Z_0 \right\}^2}{(m_1 + m_2) \hat{\sigma}^2 (A Z_0 + 2 B Z_0 + C)} \right]^{\frac{1}{2}}$$

とする。自由度 $m_1 + m_2 - 4$ の F 分布の $100\alpha\%$ point を t_α とする。即ち

$$Pr(|t| > t_\alpha) = \alpha$$

とすれば、 $Pr(t^2 \leq t_\alpha^2) = 1 - \alpha$ 依つて

$$\begin{aligned} Pr\left\{(m_1 + m_2 - 4)\left[(\hat{a}_1 - \hat{a}_2) + (\hat{b}_1 - \hat{b}_2)Z_0\right]^2 - (m_1 + m_2)t_\alpha^2 \hat{\sigma}^2(AZ_0^2 + 2BZ_0 + C) \leq 0\right\} \\ = 1 - \alpha \end{aligned}$$

今

$$\frac{1}{t_\alpha} \sqrt{1 - \frac{4}{m_1 + m_2}} = K \quad (2.2)$$


とおけば、 $\sqrt{m_1 + m_2} t_\alpha > 0$ 故に、上式は

$$\begin{aligned} Pr\left\{K^2(\hat{b}_1 - \hat{b}_2)^2 - \hat{\sigma}^2 A\right\} Z_0^2 + 2\left[K^2(\hat{a}_1 - \hat{a}_2)(\hat{b}_1 - \hat{b}_2) - \hat{\sigma}^2 B\right] Z_0 \\ + \left[K^2(\hat{a}_1 - \hat{a}_2)^2 - \hat{\sigma}^2 C\right] \leq 0\right\} = 1 - \alpha \quad (2.3) \end{aligned}$$

となり、 Z_0 以外は見本から計算出来るから、 Z_0 の二次式を頭に
する範囲を求めれば、それが Z_0 の $100(1-\alpha)\%$ 信頼区間である。

注意 見本(実現値)によつては、そういう範囲が普通
数学で用いる言葉の意味での区間(interval)にならない場
合がある。然し、A. Mood は random interval が見本によ
つてはいくつかの区間の如に分れたり、半直線になつたり、直線
全体になつたりする様な場合には、Confidence interval と
言う言葉を替つていたので、それに倣ふことにする。後の説明
には区間とするので、こゝで Confidence interval 及び fidu-
cial probability の概念を説明するために A. Mood の入門書
に書いてある初等的な図示法を示そう。(初めて学ぶものにとつ
て非常にわかりやすい説明法だと思われる。) θ の真の値を
推定するため、一定の方式に従つて θ の interval (範囲)
を見本毎に依つてゆく。そうして無限に繰り返せば、 θ を

含む様なもの（印の〇印）が全体のうちで占める割合は次第に、
 $(1-\alpha) \times 100\%$ になる。この一つ一つが θ_0 の $(1-\alpha) \times 100\%$




(Fig 2)

信頼区間である。

故に偶々一つ見本を得て、信頼区間をそれよりつくった時実際はX印のものであるかも知れない。

しかし抽出試行の際そういう見本が得られる確率は α であるから、一つ見本を得てそれから信頼区間

をつくり、「真の値 θ_0 はその中にはある」と言う時、その Aussage が誤りである確率は α である。（勿論見本抽出を試行と考へての確率） $1-\alpha$ をその Aussage の *fiducial probability* と言ふことは周知の通りである。故に区間として得られなくても、次の図の様になる場合も、本質的には何等異なるところはないのみか、実際問題としては適用範囲が増すのである。事實に〇印の様なものだけ得られたら θ_0 がその中にはあるということも、大抵派手で信頼度 $1-\alpha$ を以て主張出来るのに、他の見本をとれば、a印、b印、...の様なものも得られる可能性があるという理由だけで、その推定を放棄するのは何と云つても愚かな話である。



(Fig 3)

くさい様だけれど尚少しつけたしておこう。c印の様なものも得られた場合は θ_0 は存在するといえるだけである。e印の様にも一つだけ得られたら θ_0 は

その点であると推定するのである。大抵の場合そういうことの起る *probability measure* は零であるから問題にしていないのであるが、起った場合は、信頼度 $1-\alpha$ を以てそう主張して差支ないわけである。更に範囲が全然ない場合(空集合), θ_0 は存在しないと推定するのである。普通 θ_0 は母集団分布の *parameter* であるので、こんなことは起らないのであるが、我々の場合の様に交点なら、交点がないということも当然数学的 *scheme* の中には含まれているので、当然こういうことも起るわけである。

危に毎こういう爽つたことが起ろうよも *fiducial probability* を以ていう推論に何ら誤りやあきまりさがあるわけではない。信頼区間という言葉が悪ければ、信頼集合とでもすればよいであろう。あきり言葉にとらわれることは事柄の本質を見失って理論の発産を阻害する様に思われる。信頼区間という言葉は適当でないが別によい言葉がないので假にそれを使わせて頂くことにする。

さて、我々のほしい結果は、眞の Z_0 が含まれていると信じ得る、なるべくせまい一つの区間である。どろいう *sample* が得られたら *Confidence interval* が一つの区間となるかを考えてみることは、強ち無駄なことではなからう。(2.3)の左辺から、先づ Z_0^2 の係数必正でなければならぬ。

即ち、 $A > 0$ だから

$$\frac{K}{\sqrt{A}} > \frac{\sqrt{Z_0^2}}{|\hat{\theta}_1 - \hat{\theta}_2|} \quad (2.4)$$

この場合には実は、(2.3)の二次式を零と置いて出来る方程式は、実根をもつ。判別式を計算してもわかるが、次の様に考えてみよう。

問題の二次式は

$$(1, Z_0) \cdot \left[K^2 \begin{pmatrix} (\hat{\theta}_1 - \hat{\theta}_2)^2 & (\hat{\theta}_1 - \hat{\theta}_2)(\hat{\theta}_1 - \hat{\theta}_2) \\ (\hat{\theta}_1 - \hat{\theta}_2)(\hat{\theta}_1 - \hat{\theta}_2) & (\hat{\theta}_1 - \hat{\theta}_2)^2 \end{pmatrix} - \hat{\sigma}^2 R \right] \cdot \begin{pmatrix} 1 \\ Z_0 \end{pmatrix}$$

となる。これを假りに $f(Z_0)$ とする。こゝに R は

$$R \equiv \begin{pmatrix} C & B \\ B & A \end{pmatrix}$$

(2.4) は $|Z_0|$ が大になるところで $f(Z_0) < 0$ なることを意味するから、 $f(Z_0) \leq 0$ なる様な所があればよい。

所が実は

$$Z_0 = \hat{Z}_0 \equiv - \frac{\hat{\sigma}_1^2 - \hat{\sigma}_2^2}{\hat{\sigma}_1 - \hat{\sigma}_2}$$

に於て $f(\hat{Z}_0) < 0$ となる。なぜなら容易にわかる様は

$$f(\hat{Z}_0) = (-\hat{\sigma}^2)(1, \hat{Z}_0) R \begin{pmatrix} 1 \\ \hat{Z}_0 \end{pmatrix}$$

となるが、 R は実は *positive matrix* である。何 ぞら

$$\frac{1}{\sum_{i=1}^{m_v} (Z_v^i - \bar{Z}_v)^2} \begin{pmatrix} \frac{1}{m_v} \sum_{i=1}^{m_v} Z_v^i & \bar{Z}_v \\ \bar{Z}_v & 1 \end{pmatrix} \equiv R_v \quad (v=1, 2)$$

とすれば、 R は *positive matrices* で $R = R_1 + R_2$ であるからである。依つて $\hat{\sigma}^2 = 0$ の特別な場合を除いて $f(\hat{Z}_0) < 0$ である。probability measure 0 を除いて \hat{Z}_0 は存在するから、(2.3) の Z_0 の二次式は *positive definite* にはならない。故に見本が (2.4) をみたすならば *Confidence interval* は一つの区間になり、 \hat{Z}_0 は常にその区間の中にあることがわかる。

次に α を用いる代りに $\alpha_{1-\alpha}$ (中心に近い方) を用いて

$$P_r(\sigma^2 \geq \sigma_{1-\alpha}^2) = 1 - \alpha$$

により、 $(1-\alpha) \times 100\%$ 信頼区間を求めた場合はどうなるであろうか？ この場合は、(2.2) に於ける α のかわりに $\alpha_{1-\alpha}$ とし左ものを K' とすれば、(2.3) に相当する式は、

$$P_T \{ [\hat{\sigma}^2 A - K^2 (\hat{\beta}_1 - \hat{\beta}_2)^2] Z_0^2 + 2[\hat{\sigma}^2 B - K^2 (\hat{a}_1 - \hat{a}_2)(\hat{\beta}_1 - \hat{\beta}_2)] Z_0 + [\hat{\sigma}^2 C - K^2 (\hat{a}_1 - \hat{a}_2)^2] \leq 0 \} = 1 - \alpha$$

となり、 $\hat{\sigma}^2 A > K^2 (\hat{\beta}_1 - \hat{\beta}_2)^2$ のときには、左辺の括弧の中の二次式が Positive definite になる。

即ちその時は、眞の値 Z_0 はないと推定しなければならない、そうでない時にも、 Z_0 軸全体 (Z_0 は存在するということだけを言える) か、又は、二つの半直線が得られる (Z_0 はある数より大なるか又はある数より小なるか) づれのである、ということだけが言える) か、何れかであつて、我々の利用目的には適しない。

扱、(2.4) がみ反される場合は、(2.3) の左辺から Z_0 に関する二次方程式を解いて、その根 ζ_1, ζ_2 ($\zeta_1 < \zeta_2$) を以て信頼限界と出来るわけである。 (ζ_1, ζ_2) が ($Z_{\frac{1}{2} m_1 + 1}, Z_{\frac{1}{2} m_2}$) の中には含まれているか ($Z_{\frac{1}{2} m_1}, Z_{\frac{1}{2} m_2 + 1}$) の中には含まれている場合は、更に推論を進める。即ち、 $Z_{\frac{1}{2} m_1 + e_1} < \zeta_1, \zeta_2 < Z_{\frac{1}{2} m_2 + e_2}$ とすれば、 $Z_{\frac{1}{2} m_1}, Z_{\frac{1}{2} m_2}, \dots, Z_{\frac{1}{2} m_1 + e_1}, Z_{\frac{1}{2} m_2 + e_2}, Z_{\frac{1}{2} m_2 + e_2 - 1}, \dots, Z_{\frac{1}{2} m_2}, \dots, Z_{\frac{1}{2} m_1}$ に於ける測定値を用いて、再び同じことをやり、その信頼区間が、 $Z_{\frac{1}{2} m_1 + e_1}, Z_{\frac{1}{2} m_2 + e_2}$ の中に入れば、尚狭い幅の推定が出来ることになる。

そしてこの調子で出来るだけくりかえして行けばよい。

但しこの推論の意味を辨えることが必要である。

この方法では推論を進めてゆくことが出来ないのではないかと、小川先生に注意されたが、次の様に考えればよいような気がする。Mood の elementary な説明法で説明する。

我々はこの場合、見本が得られる毎に、次の様行操作を行う。

① 先が見本のうちの一部の測定値を用いて、(即ち ($Z_{\frac{1}{2} m_1}, Z_{\frac{1}{2} m_2}$) の中の Z に於けるものは用いないで) $100(1 - \alpha)\%$ Confidence interval をつくる。(図に於て実線で示したもの)

② 若しもその Confidence interval が ($Z_{\frac{1}{2} m_1}, Z_{\frac{1}{2} m_2}$) の中




Fig 4

に入らないならば (×印又は⊗印のもの)* その interval を採用する。

③ 若しもそうでないならば、もう一度その区間に含まれない出来るだけ多くの Z_1, Z_2 に於ける測定値を用いて $(1-\alpha') \times 100\%$ Confidence interval をつくる。(図に於て破線を示したもの。) そして二つの interval のうちよい方を採用する。

即ち後者の方が前者に含まれているならば後者(破線の方)を採用し、そうでないならば前者(実線の方)を採用する。

こうして一つの見本を得たら採用する区間がきまる。そして「その区間の中に真の値 Z_0 がある」と言う時、その Aussage の fiducial probability は如何程であろうか?

見本を無限にくりかえし取って、その度毎にこういう操作をしていつ反時、採用された区間のうち、 Z_0 を含むものが全体の中に占める割合を勘定すればよい。先づ印の説明をしておく。

- × 印 : 第一回目の区間が $(Z_1 m_1, Z_2 m_2)$ に含まれず且 Z_0 を含まないもの。
- ⊗ 印 : 最初の区間が $(Z_1 m_1, Z_2 m_2)$ に含まれず且 Z_0 を含むもの。
- △ 印 : 最初の区間は $(Z_1 m_1, Z_2 m_2)$ の中に含まれ且つ Z_0 を含まないもの。
- 印 : 最初の区間が $(Z_1 m_1, Z_2 m_2)$ に含まれ且つ Z_0 を含み、二回目のものも Z_0 を含むもの。
- △ 印 : 最初のものが $(Z_1 m_1, Z_2 m_2)$ に含まれ且 Z_0 を含み、二回目のものは最初のものの中に含まれるが Z_0 を含まないもの。
- ⊙ 印 : 最初のものが $(Z_1 m_1, Z_2 m_2)$ に含まれ、且 Z_0 を含み、二回目のものは最初のものの中に含まれず且 Z_0 を含まないもの。

この分類は、排反的で、すべてをつくしている。Aussage が誤る場合は、×印のものか△印のものか⊗印のものかを得られる場合である。×印のものと△印のものとを合すると、全体の α である。故に△印と⊙印とを合せたものの中で、同じ Z_i に対する測定値を用いて破線をつくつたものばかり考之ると、その中で○印は $1-\alpha$ を占める。故に○印と△印と⊙印の全体を考之てもその中で○印は $1-\alpha$ を占める。

即ち○印と△印と⊙印の中で△印のものは α' 以下である。

依つて全体の中で△印は $(1-\alpha)\alpha'$ 以下である。依つて誤つた Aussage をする確率は $\alpha + (1-\alpha)\alpha'$ 以下である。即ち上の方法で一つの区間を得た場合、その中に Z_0 があるということに *fiducial probability* $(1-\alpha)(1-\alpha')$ 以上で言える。

故に、この様にしてだんだん狭くして行くことが出来た場合は、*fiducial probability* は

$$(1-\alpha)(1-\alpha')(1-\alpha'') \dots$$

以上であることが出来る。即ちこの場合 *fiducial probability* についても普通の *Conditional probability* に似てよ

うなことがいえる。

3. 折れた曲線の場合

折線の場合に、考察した方法は、 X が Z の多項式の関係にある場合にも形式的にはすぐ拡張出来る。(勿論 Z_0 の行列で、*linear* な関係にある場合をも含む。) 多項式以外の場合も実際問題としては必要なことも起るのである。

例えば、函数関係が理論的に、*parametric* を除いて分つてい
る場合、多項式で近似しないで、直接理論的函数関係を用いる方法が望ましい。しかし多項式以外の場合についてはまだ考えつかないので、多項式の場合への拡張を述べる。

又実際計算が面倒な割に大し反結果も得られそうもないので、実際問題として三次以上の曲線では役に立つかどうかとも疑問であるが、一応一般の多項式への形式的な拡張が出来ることが簡単に示しておくことにする。

$$Z \cong Z_0 \text{ で } X = a_0 + a_1 Z + a_2 Z^2 + \dots + a_{k_1} Z^{k_1}$$

$$Z \cong Z_0 \text{ で } X = a_0 + a_2 Z + a_2 Z^2 + \dots + a_{k_2} Z^{k_2}$$

$$\text{但し、 } Z_0 \text{ は } \sum_{\lambda=0}^{k_1} a_{\lambda} Z_0^{\lambda} = \sum_{\lambda=0}^{k_2} a_{\lambda} Z_0^{\lambda} \dots \dots \dots (3.1)$$

をみるす或る実数とする。眞の関係がこの様なものであるとする $k = \max(k_1, k_2)$ として

$$k_1 > k_2 \text{ ならば } a_{k_2+1} \equiv a_{k_2+2} \equiv \dots \equiv a_{k_2} (\equiv a_k) \equiv 0$$

$$k_2 > k_1 \text{ ならば } a_{k_1+1} \equiv a_{k_1+2} \equiv \dots \equiv a_{k_1} (\equiv a_k) \equiv 0$$

を用いて記法を簡単にする。次に

\underline{a} は (a_0, a_1, \dots, a_k) なる横 $k+1$ vectors,

\underline{z}_i 等は $(1, z_i, z_i^2, z_i^3, \dots, z_i^k)$ なる横 $k+1$ vectors

z_0 は $(1, z_0, z_0^2, z_0^3, \dots, z_0^k)$ なる横 $k+1$ vector

$\alpha_i^*, \beta_i^*, \gamma_i^*$ 等は夫々の transposed とする. $\alpha_i \cdot \beta_i^*$ 等は内積 $\sum_{\lambda=0}^k \alpha_{i\lambda} \beta_{i\lambda}^*$ 等をあらわすものとする.

そうすれば (3.1) の如きは

$$\alpha_1 \cdot \beta_0^* = \alpha_2 \cdot \beta_0^*$$

と書ける.

Z_0 の両側で σ^2 が異なる場合を考へて, X は $Z \leq Z_0$ で, $N(\alpha_i \cdot \beta_i^*, w_i \sigma^2)$ に従ひ, $Z \geq Z_0$ では $N(\alpha_i \cdot \beta_i^*, w_i \sigma^2)$ に従ひ, Z の異なる点では互いに独立に分布する variate とする. ここで w_1, w_2 は known weight で $w_i > 0$.

先づ (1) で考へた様な点推定を行う. 今,

$$R_v^{-1} \equiv \begin{pmatrix} n_v & \sum z_i & \sum z_i^2 & \sum z_i^3 & \dots & \sum z_i^{k_v} \\ \sum z_i & \sum z_i^2 & \sum z_i^3 & \sum z_i^4 & \dots & \sum z_i^{k_v+1} \\ \sum z_i^2 & \sum z_i^3 & \sum z_i^4 & \sum z_i^5 & \dots & \sum z_i^{k_v+2} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ \sum z_i^{k_v} & \sum z_i^{k_v+1} & \sum z_i^{k_v+2} & \sum z_i^{k_v+3} & \dots & \sum z_i^{2k_v} \end{pmatrix} \quad (v=1,2)$$

(但し各 \sum は $\sum_{i=1}^{n_v}$ の意義である)

とする. よく知られてゐるよりに R_v^{-1} は positive definite symmetric matrix であるから, R_v は存在し,

$$y_{\nu} \equiv (y_{\nu 0}, y_{\nu 1}, \dots, y_{\nu k}) \quad y_{\nu} = \sum_{i=1}^{n_1} x_i \frac{z_i^{\nu}}{z_i^{\lambda}}$$

$$\hat{\alpha}_{\nu} \equiv (\hat{\alpha}_{\nu 0}, \hat{\alpha}_{\nu 1}, \dots, \hat{\alpha}_{\nu k}) \equiv \sum_{\nu} \tilde{R}_{\nu}$$

$$\hat{\sigma}^2 = \frac{\sum_{\nu=1}^2 \frac{1}{w_{\nu}} \sum_{i=1}^{n_{\nu}} (x_i - \hat{\alpha}_{\nu} \cdot z_i^*)^2}{\frac{n_1}{w_1} + \frac{n_2}{w_2}}$$

(但し \tilde{R} は R_{ν} の右下外側に 0-element を適当に反てけて $(k+1, k+1)$ matrices に拡大したものと) として,

$$\sum_{\nu=1}^2 n_{\nu} \log(w_{\nu} \hat{\sigma}^2)$$

を最小にする様は $\hat{\alpha}_{\nu}$ を決定することになる。

$$w_1 = w_2 \text{ の時には上の場合の様に } \sum_{i=1}^2 \sum_{j=1}^{n_j} (x_i - \hat{\alpha}_{\nu} \cdot z_i^*)^2$$

を最小にする様に、 $\hat{\alpha}_{\nu}$ を決定することになる。然しこの場合も、 \sum_{ν} の推定子がどんな性質をもつか分らない。これは最尤法の精神から言えば、標本が與えられた時、そういう標本が最も得られやすいところの、 k_1 次と、 k_2 次の曲線から成る図形を求めようということになる。

次に 2 の時の区間推定法を、この場合には、形式的に拡張することも容易である。

本章の始めからの n_{ν} をすべて m_{ν} でおきかえ、これ迄の notions をそのまま用いることにする。(即ち例えは \sum_{ν}^{λ} 等はすべて $\sum_{\nu}^{m_{\nu}}$ の意味とする。)

$$T \equiv \hat{\sigma}^2 \left(\frac{m_1}{w_1} + \frac{m_2}{w_2} \right) / \sigma^2$$

$$v_{\nu} \equiv (\hat{\alpha}_{\nu} - \alpha_{\nu}) / (\sqrt{w_{\nu}} \sigma) \quad (\nu = 1, 2)$$

とし、 v_{ν} の components と T との $2(k+1) + 1$ 個の量の同時確率密度を考えると、 $\nu=1$ の部分と $\nu=2$ の部分との

積になり、 Γ の方は、一旦分けたものを再び合成すれば、 Γ は平均0, variance-covariance matrixが、 \hat{R}_0 なる正規分布に従い、 ν の異なる値は対するものは互いに独立である。

又これ等とは独立に Γ は、自由度 $(m_1+m_2)-(k_1+k_2+2)$ の、chi-square 分布に従うことがわかる。従つて

$$\nu \equiv (\hat{\sigma}_1^2 - \sigma_1^2) \cdot \beta_0^*$$

を調べれば、(3.1)を注意すれば、これは平均0の正規分布に従い、且つ Γ とは独立に分布するから

$$\frac{\sqrt{m_1+m_2-k_1-k_2-2} (\hat{\sigma}_1^2 - \sigma_1^2) \cdot \beta_0^* / \sqrt{\text{var } \nu}}{\sqrt{\left(\frac{m_1}{w_1} + \frac{m_2}{w_2}\right) \hat{\sigma}^2 / \sigma^2}} \equiv t$$

が自由度、 $m_1+m_2-k_1-k_2-2$ の t 分布をなすことより、 Z_0 の信頼区間をつくること出来る。扱

$$\begin{aligned} \text{var } \nu &= E\{[(\hat{\sigma}_1^2 - \sigma_1^2) \cdot \beta_0^* + (\sigma_1^2 - \hat{\sigma}_1^2) \cdot \beta_0^*]^2\} \\ &= E\{[(\hat{\sigma}_1^2 - \sigma_1^2) \cdot \beta_0^*]^2\} + E\{[(\sigma_1^2 - \hat{\sigma}_1^2) \cdot \beta_0^*]^2\} \\ &= E(\beta_0^* A \beta_0^*) + E(\beta_0^* A \beta_0^*) \end{aligned}$$

ここに A は $(\hat{a}_{\lambda} - a_{\lambda})(\hat{a}_{\mu} - a_{\mu})$ を $(\lambda+1, \mu+1)$ element とする $(k+1, k+1)$ -matrixをあらわす。

$$E(A) = w \sigma^2 \tilde{R} \quad \text{であるから}$$

$$R \equiv w_1 \tilde{R}_1 + w_2 \tilde{R}_2$$

とすれば、 $\text{var } \nu = \beta_0^* R \beta_0^*$ となる。

A が symmetric 故から R も symmetric で、 R が positive matrix であることがわかる。(このことは必

すし、 \hat{R}_1, \hat{R}_2 の両方がともに *positive matrices* であるというわけではない。

$$t^2 = \frac{(m_1 + m_2 - k_1 - k_2 - 2) \{(\hat{\sigma}_1 - \hat{\sigma}_2) \cdot \hat{z}_0^*\}^2}{\left(\frac{m_1}{w_1} + \frac{m_2}{w_2}\right) \hat{\sigma}^2 \hat{z}_0 \cdot R \hat{z}_0^*}$$

であるから、自由度 $(m_1 + m_2 - k_1 - k_2 - 2)$ の t 分布の 100 α % 乗を用いて $\Pr(t_\alpha^2 \geq t^2) = 1 - \alpha$ から信頼区間が求まるわけであるが、今 $(\hat{q}_\lambda - \hat{q}_\mu)(\hat{q}_\lambda - \hat{q}_\mu) \in (\lambda + 1, \mu + 1)$ element とする $(k+1, k+1)$ -matrix を G とし、

$$K \equiv \frac{1}{t_\alpha} \sqrt{(m_1 + m_2 - k_1 - k_2 - 2) / \left(\frac{m_1}{w_1} + \frac{m_2}{w_2}\right)}$$

とすれば、 $t_x^2 \geq t^2$ は

$$\hat{z}_0 \cdot (K^2 G - \hat{\sigma}^2 R) \hat{z}_0^* \leq 0 \quad \text{----- (3.2)}$$

これは $K^2 G - \hat{\sigma}^2 R$ なる matrix の $(k+1, k+1)$ -element が 0 でない限り Z_0 の $2k$ 次不等式である。

Z 軸上で (3.2) がみたされている範囲が、 Z_0 の信頼区間になるわけであるが、帰帰推定曲線の交点即ち $\hat{\sigma}_1 \cdot \hat{z}_0^* = \hat{\sigma}_2 \cdot \hat{z}_0^*$ を満足する \hat{z}_0 は常に信頼区間の中に含まれていることは直ちにわかる。

即ち \hat{z}_0 を $(\hat{\sigma}_1 - \hat{\sigma}_2) \hat{z}_0^* = 0$ をみたすものとする。

$$\hat{z}_0 G = 0 \quad (0 \text{ は } k+1 \text{ 横 } 0 \text{ vector})$$

$$G \hat{z}_0 = 0 \quad (0 \text{ は } k+1 \text{ 縦 } 0 \text{ vector})$$

となるから

$$\hat{z}_0 (K^2 G - \hat{\sigma}^2 R) \hat{z}_0^* = -\hat{\sigma}^2 \hat{z}_0 R \hat{z}_0^*$$

で、 R は *positive matrix* であるからこれは負である。

従つて $\hat{\sigma}_0$ は (3.2) をみたしていることがわかつた。

どんな見本が得られども必ず $\hat{\sigma}_0$ があるなら常に Z 軸上に (3.2) をみたす範囲はあるわけであるが、一般にそのことは言えようもない。




Fig 5.

例之極図の様な場合は、Z₀ は存在しない。

(曲線は交らない) と推定しなければならぬ様な sample が得られる確率は有限になるであろう。故に前に注意した様に信頼区間の定義を拡張して置く必要がある。

最後に問題の本旨からは少し離れるが、見本と、得られる信頼区間の形との間の関係を探らうと試みた。

思わしい結果は得られなかつたが、次の様な事柄だけがわかつたので附加しておく。

即ち、 $K^2G - \hat{\sigma}^2R$ なる matrix は positive matrix になることはない。という事柄である。

しかしこの事は勿論 (3.2) を満足する様な実数 Z₀ が常に存在するということの意味しない。上の事実は次の様にしてわかる。(或いはもつと簡単に證明出来るかも知れない。)

今、G の (λ, μ)-element を $g_{\lambda-1, \mu-1}$ R の (λ, μ)-element を $r_{\lambda-1, \mu-1}$ とあらわす。

$\det(K^2G - \hat{\sigma}^2R)$ を、μ 列が、 K^2G の μ 列か、或いは $-\hat{\sigma}^2R$ の μ 列かの何れかから成る (k+1, k+1)-determinant の和に分解する。即ち、

$$\det \begin{vmatrix} K^2g_{00} & K^2g_{01} & -\hat{\sigma}^2r_{02} & -\hat{\sigma}^2r_{03} & \dots & K^2g_{0k} \\ K^2g_{10} & K^2g_{11} & -\hat{\sigma}^2r_{12} & -\hat{\sigma}^2r_{13} & \dots & K^2g_{1k} \\ K^2g_{20} & K^2g_{21} & -\hat{\sigma}^2r_{22} & -\hat{\sigma}^2r_{23} & \dots & K^2g_{2k} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ K^2g_{k0} & K^2g_{k1} & -\hat{\sigma}^2r_{k2} & -\hat{\sigma}^2r_{k3} & \dots & K^2g_{kk} \end{vmatrix}$$

の様な $\frac{1}{2^{k+1}}$ 個の行列式の和に分解する。

これらのうち、 K^2G からの行が二つ以上のものはすべて0になる。何故なら、 g_{ij} は $(\hat{a}_i - \hat{a}_i)(\hat{a}_j - \hat{a}_j)$ 即ち i を suffix とする数と j を suffix とする数との積であるからである。

故つて残るのは何れか一行が K^2G から取られるもの $(k+1)$ 個と、 $\det(-\hat{\sigma}^2 R)$ とである。

これを、 g_{ij} について展開すると、

$$\det(K^2G - \hat{\sigma}^2 R) = K^2 (-\hat{\sigma}^2)^k \sum_{i=0}^k \sum_{j=0}^k (R \text{に於ける } Y_{ij} \text{のAdjunkte}) g_{ij} + \det(-\hat{\sigma}^2 R)$$

$$= (-\hat{\sigma}^2)^k \left\{ K^2 \sum_{i=0}^k \sum_{j=0}^k (R^{-1} \text{の}(i,j)\text{element}) \det R g_{ij} - \hat{\sigma}^2 \det R \right\}$$

R^{-1} は symmetric であるから

$$= (-\hat{\sigma}^2)^k \left\{ K (\hat{a}_1 - \hat{a}_2) R^{-1} K (\hat{a}_1 - \hat{a}_2)^* - \hat{\sigma}^2 \right\} \det R$$

R^{-1} の $(k+1, k+1)$ -element 即ち $(R \text{の } Y_{k,k} \text{の cofactor}) / \det R$

を $\left\{ (R \text{の } Y_{k,k} \text{の cofactor}) / \det R \right\} - \left[\hat{\sigma}^2 / K^2 (\hat{a}_k - \hat{a}_k)^2 \right]$ で

置きかえ、残りは R^{-1} の element をそのままにし左行列を S とすると上式は

$$\det(K^2G - \hat{\sigma}^2 R) = (-\hat{\sigma}^2)^k \det R \cdot K (\hat{a}_1 - \hat{a}_2) S \left[K (\hat{a}_1 - \hat{a}_2)^* \right]^*$$

となる。ところで S も symmetric であることは明かで、且

$$\det S = \det R^{-1} \frac{\hat{\sigma}^2}{K^2 (\hat{a}_k - \hat{a}_k)^2} \times (\det R^{-1} \text{の}(k+1, k+1)\text{-cofactor})$$

$$= \frac{1}{\det R} \left(1 - \frac{\hat{\sigma}^2 Y_{k,k}}{K^2 (\hat{q}_R - \hat{q}_R^2)^2} \right)$$

$\det R > 0$ であるから、もしも $K^2 (\hat{q}_R - \hat{q}_R^2)^2 > \hat{\sigma}^2 Y_{k,k}$ 即ち $K^2 g_{k,k} - \hat{\sigma}^2 Y_{k,k} > 0$ ならば $\det S > 0$ 、又 R^{-1} は positive matrix であるから $\det S$ の k 以下の Hauptminor は皆正である。従つて S は positive matrix、従つて $K^2 g_{k,k} - \hat{\sigma}^2 Y_{k,k} > 0$ ならば常に ($\hat{\sigma}^2 = 0$ の場合をのぞき) $\text{sign det}(K^2 G - \hat{\sigma}^2 R) = (-1)^k$ となる。

このことは k が奇数のときは $K^2 G - \hat{\sigma}^2 R$ の Hauptminor が同時にすべて正になるということは無いということの意味する。従つて $K^2 G - \hat{\sigma}^2 R$ は positive matrix にほなり得ないことがわかつた。 k が偶数の時は $K^2 G - \hat{\sigma}^2 R$ の $k+1$ 行 $k+1$ 列を除いた (k, k) -matrix を考えれば全く同様にしてそれが positive matrix にほならないことがわかる。

従つて $K^2 G - \hat{\sigma}^2 R$ が positive matrix になることは無いことがわかる。特に $k=1$ のときは

$$(1, Z_0)(K^2 G - \hat{\sigma}^2 R)(1, Z_0)^* \leq 0$$

になる様な実数 Z_0 が存在することを意味し、2に於て言つたことの別証になつてゐる。

以上

後記

原稿を書き終つてから、遠藤氏に、Fisher の本に二つの regression lines の交点を推定する方法が出ていたことを教えていただいた。問題のとらえ方が少し異つてはいるだけで、こゝに書いたものは本質的に全く同じである。しかし或意味に於て、Fisher の本のその部分を読む際の助けにもなると思われるので、全然書き変えないことにする。尚この問題は旧友、早稲田大学燃料化学科宮崎智雄君の実験から考へさせられたものであることを披露し、同君の御健闘を祈るとともに、熱心な御鞭撻を賜つた。阪大小川潤次郎、統計数理遠藤健児両先生に感謝を捧げるものである。

参考書

Alexander Mc Farlane Mood :

Introduction to the Theory of Statistics 1950 ;

Mc Graw Hill Book Company Inc.

Discrimination については 299 頁

Regression については 291 頁より

Confidence intervals については 220 頁より

R. A. Fisher :

Statistical Methods for Research Workers 1948

142 頁より

行列に関しては例えば

高木 貞治 : 代数学講義 : 共立社