

## 《講 座》

## 統計的推論 (3)

——計量データでの平均値を主とした扱い，直線のあてはめを中心とした最小2乗法，非線形モデルでの最小2乗法（コンパートメント説を例にして）

佐 久 間 昭\*

## 15. 不 偏 分 散

計量データ  $x \in \Pi\{\mu, \sigma^2\} \rightarrow O_n\{x_i\}$  につき，節 5 では， $\sigma^2$  が既知であるとして， $\mu$  について推論し，検定や推定につき，

$$t_0 = \frac{|\bar{x} - \mu_0|}{\sigma} \sqrt{n} \quad (59)$$

$$\mu_L^U = \bar{x} \pm t_{\alpha}[\infty] \frac{\sigma}{\sqrt{n}}$$

を求めた ( $y \in \Pi\{\eta, \sigma^2\} \rightarrow O_n\{y_i\}$  の表記を用いた)。

現実には， $\sigma^2$  が未知というのが普通で，標本の値だけで， $\sigma^2$  に代わるものを求める必要がある。

$$V = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} \quad (60)$$

を求めると， $E\{V\} = \sigma^2$ ，つまり  $V$  を平均的にみれば  $\sigma^2$  になる性質があるので， $V$  を**不偏分散推定量**といい，具体的に求めた値を**不偏分散推定値**という。単に**不偏分散**とか**分散**ということも多い。 $E\{x\} = \mu$ ， $V\{x\} = \sigma^2$  といった演算子が<sup>2</sup>，しばしば使われ，それぞれ，平均値と分散を示す。

直観的には，

$$V^* = \frac{\sum (x_i - \bar{x})^2}{n}$$

がよさそうであるが<sup>3</sup>， $E\{V^*\} < \sigma^2$  となり，小さく偏っている。

$V$  の分子は展開するとわかるが<sup>4</sup>， $\sum (x_i - \bar{x})^2$  を直接に求めないで，

$$\begin{aligned} S_{xx} &= \sum_{i=1}^n x_i^2 - \frac{\left(\sum_{i=1}^n x_i\right)^2}{n} \\ &= \sum_{i=1}^n x_i^2 - n\bar{x}^2 \end{aligned} \quad (61)$$

として求める方がよい。 $S_{xx}$  を(偏差)平方和と呼んで， $(\sum x_i)^2/n = n\bar{x}^2$  を**修正項 CF**という。 $S_{xx}$  の脚符  $xx$  は， $x$  の2乗の感じを示すものである。 $\sum x_i^2$  では大きすぎるので，平均値に関して  $n\bar{x}^2$  の修正を加えているため，修正項の名がある。 $V$  の分母の  $(n-1)$  は**自由度**と呼ばれ，2乗の項がいくつあるか，つまり， $\sum x_i^2$  が  $n$  個，これから  $n\bar{x}^2$  を引いて  $(n-1)$  個あることを示すと考えておくとよい。

対になったデータ  $(x_i, y_i)$  について，(偏差)積和として，

$$\begin{aligned} S_{xy} &= \sum (x_i - \bar{x})(y_i - \bar{y}) \\ &= \sum x_i y_i - \frac{(\sum x_i)(\sum y_i)}{n} \\ &= \sum x_i y_i - n\bar{x}\bar{y} \end{aligned} \quad (62)$$

が定義されているが， $x_i = y_i$  となった特殊なケースが式 (61) の  $S_{xx}$  である。 $S_{xy}$  は， $x_i$  と  $y_i$  との，かわり，もう少し正確に言えば，直線的なかわりを示す量で，これを規準化すると，

$$r = \frac{S_{xy}}{\sqrt{S_{xx}S_{yy}}} \quad (63)$$

で，(単)相関係数という。 $x_i = y_i$  では  $r = 1$  である。 $S_{xx}, S_{yy}$  は平方和のとおり，負にはならないが<sup>5</sup>， $S_{xy}$  したがって  $r$  は負にもなる。 $x_i = -y_i$  では， $r = -1$  となる ( $\rightarrow$  節 21)。

\* 東京医科歯科大学難治疾患研究所臨床薬理学部門

**【例 12】**

$O_3\{4, 7, 9, 11, 14\}$  について,  $\bar{x} = 45/5 = 9.0$ ,  
 $\sum x_i^2 = 463$  である.

$$S_{xx} = 463 - 5 \times 81 = 58$$

$x_i^* = x_i - 10$  とすれば,  $O_3^*\{-6, -3, -1, 1, 4\}$  で,  
 $\bar{x}^* = -5/5 = -1$ ,  $\sum x_i^{*2} = 63$  で,

$$S_{x^*x^*} = 63 - 5 \times (-1)^2 = 58$$

となる. 一般に,  $x_i^* = ax_i \pm b$  とおくと,

$$S_{x^*x^*} = a^2 S_{xx}$$

となり,  $b$  は関係しない.

分散  $\sigma^2$  未知の場合には, 少し手間がかかるが,  
 $O_n\{x_i\}$  の標本の値だけから  $V$  を求めたうえ, 式  
 (59) の  $\sigma$  には  $\sqrt{V}$  を用いることができる. しかし,  
 $S/N$  比について,

$$t_0 = \frac{|\bar{x} - \mu_0|}{\sqrt{V}} \sqrt{n} \quad (64)$$

をつくると,  $H_0: \mu = \mu_0$  の条件下に,  $t_0$  は  $t \in N[0, 1^2]$  の実現値にはならない.

$x \in N[\mu, \sigma^2] \rightarrow O_n\{x_i\}$  の標本に関して,  $H_0: \mu = \mu_0$  のもとに, 式 (64) の  $t_0$  は, 自由度  $[n-1]$  の **Student の t 分布** の実現値となる. このため, 式 (64) の扱いにあたり, つぎのような注意が必要になる. すなわち, 平均値の議論にあたっては,

1)  $x \in \Pi\{\mu, \sigma^2\}$  と, 正規分布にしたがわない場合, 分布がほぼ対称であれば,  $n$  が 5~10 をこえるあたりから, 分布がやや歪んでいるならば,  $n$  が 15~30 をこえるあたりからは,  $x \in N[\mu, \sigma^2]$  の正規分布での議論が利用できる.

2) 分散未知の場合,  $O_n\{x_i\}$  で求めた  $V = S_{xx}/(n-1)$  を  $\sigma^2$  の代わりに用いると, 正規偏位  $t_a[\infty]$  に関する議論を, **Student の t 分布** での限界値  $t_a[n-1]( > t_a[\infty])$  に関する議論におきかえることができる.

**16. 平均値の推論**

$x \in \Pi\{\mu, \sigma^2\} \rightarrow O_n\{x_i\}$  につき,  $n$  がある程度の

大きさであれば,  $H_0: \mu = \mu_0$ ,  $H_1: \mu = \mu_1 \neq \mu_0$  の検定にあたり,

$$\begin{aligned} S_{xx} &= \sum x_i^2 - \frac{(\sum x_i)^2}{n} = \sum x_i^2 - n\bar{x}^2 \\ V &= \frac{S_{xx}}{n-1} \\ t_0 &= \frac{|\bar{x} - \mu_0|}{\sqrt{V}} \sqrt{n} \end{aligned} \quad (65)$$

を求め, 自由度  $[n-1]$  の  $t$  分布での限界値と比べて  $t_0 \geq t_a[n-1]$  となれば, 水準  $\alpha$  で有意とし,  $H_0$  を捨てて,  $H_1$  を採用する.

平均値の  $100(1-\alpha)\%$  の信頼限界は,

$$\mu_L^U = \bar{x} \pm t_a[n-1] \sqrt{\frac{V}{n}} \quad (66)$$

となる.

いずれの場合も,  $\sigma$  を  $\sqrt{V}$  で置きかえ,  $t_a[\infty]$  を  $t_a[n-1]$  でおきかえて, 形式的には分散既知の節 5 の議論が利用できる.

$x \in \Pi\{\mu, \sigma^2\}$  の分布型に問題がある場合, **ノンパラメトリック手法**, **ノンパラ手法**を用いることが多い. これには, いくつかの方法があるが, 代表的なものをあげておく.

まず,  $O_n\{x_i\}$  を  $x_{(1)} < x_{(2)} < \dots < x_{(i)} < \dots < x_{(n)}$  と大きさの順に並べ, 順位をつける. ときに同位  $x_{(i)} = x_{(i+1)} = \dots = x_{(i+t-1)}$  があれば, これらには平均順位,

$$\bar{r} = (i-1) + \frac{t+1}{2} \quad (67)$$

を与える. つまり, 第  $i$  から始まる  $t$  個の同位には, すべて  $\bar{r}$  を与える. これによって全体の順位和  $T_G$  は  $n(n+1)/2$  に保たれる. この辺は節 14 の式 (56) と同じ要領である.

つぎに,

$$m = \frac{n+1}{2}$$

を求め,  $\bar{x}' = x_{(m)}$  とする. つまり, 第  $m$  番目のデータを  $\bar{x}'$  とし, これを**中央値 median** とするが, 母集団でちょうど真中に位置する  $\mu'$  の推定値に

なる。分布が対称ならば  $\mu = \mu'$  であるが、歪んだ分布では、 $\mu'$  の方が代表性の意味が強いだらう。

(i)  $n$  が奇数ならば  $\bar{x}' = x_{(m)}$  が直ちに求まるが、(ii)  $n$  が偶数ならば  $\bar{x}' = (x_{(m-0.5)} + x_{(m+0.5)})/2$  と約束する。

中央値の信頼限界を求めるには、

$$r = \frac{n+1}{2} - \frac{t_{\alpha}[\infty]}{2} \sqrt{n} \quad (68)$$

を計算し、 $r$  は整数または整数  $+0.5$  と半整数に切り捨てた値とする。95%信頼係数では、 $r = m - \sqrt{n}$  としてよからう。そのうえで、小さい方、大きい方から  $r$  番目の値を探し、

$$\mu_L^U = x_{(r)}; x_{(n+1-r)} \quad (69)$$

を信頼限界とする。

$H_0: \mu' = \mu'_0$ ,  $H_1: \mu' = \mu'_1 \neq \mu'_0$  の中心位置のずれの検定に相当するものに、Wilcoxon の 1 標本検定、符号つき順位検定がある。まず  $O_n\{x_i\}$  につき、 $(x_i - \mu'_0)$  をつくり、0 のものを除いて、あらためて  $n$  を定める。絶対値  $|x_i - \mu'_0|$  に関して順位づけを行ない、同位があれば平均順位を与える。そのうえで、正のものと負のものに分けて順位和  $T_+$ ,  $T_-$  をとり、 $T_+ + T_- = T_G = n(n+1)/2$  を確かめる。

$$\begin{aligned} A &= \frac{1}{2} T_G, \quad K = 2n(n+1)(2n+1) \\ \kappa &= 1 - \frac{\sum (t^3 - t)}{K} \\ t_0 &= \frac{|T - A| - 0.5}{\sqrt{\frac{\kappa}{48} K}} \end{aligned} \quad (70)$$

を計算するが、 $\kappa$  の  $\sum (t^3 - t)$  は、同位のグループが、あちらこちらにあれば、それぞれにつき  $(t^3 - t) = (t-1)t(t+1)$  を求めて加える。 $t_0$  の  $T$  は、 $T_+$ ,  $T_-$  のどちらを用いてもよい。 $t_0 \geq t_{\alpha}[\infty]$  のとき水準  $\alpha$  で有意とし、中心位置のずれを認める。 $t_0 > 2$  のときには、分子の 0.5 を省いて計算しなおして  $t_0^*$  とすれば、実質水準をみる場合に、 $t_0^*$  の方が近似がよい。 $\kappa$  は、同位によって、ノイズが小さ

くなるための修正を意味し、同位がなければ  $\kappa = 1$  となる。

### 【例 13】

$O_{11}\{1, -1, 2, 3, 0, 1, 2, 1, 3, 2, 1\}$  につき  $\bar{x} = 15/11 = 1.3636$ ,  $\sum x_i^2 = 35$ ,  $S_{xx} = 14.5455$ ,  $V = 1.4545$ ,  $SD = \sqrt{V} = 1.2060$ ,  $SE\{\bar{x}\} = \sqrt{V/n} = 0.3636$  などとなる。

$H_0: \mu = \mu_0 = 0$ ,  $H_1: \mu = \mu_1 \neq 0$  の検定は、

$$t_0 = \frac{1.3636 - 0}{0.3636} = 3.750 > t_{0.05}[10] = 2.228$$

で有意となる。95% 信頼限界は、

$$\mu_L^U = 1.3636 \pm 2.228 \times 0.3636 = 0.554; 2.174$$

Wilcoxon の 1 標本検定では、 $\mu_0 = 0$  を引いても  $O_n\{x_i\}$  はそのままであるが、 $x = 0$  を除いた 10 個につき、絶対値に順位づけをし、

$$R_{10}\{3, 3, 3, 3, 3, 7, 7, 7, 9.5, 9.5\}$$

で  $T_- = 3$ ,  $T_+ = 52$ ,  $T_G = 55 = 10 \times 11/2$ ,  $t = 5$ ,  $t = 3$ ,  $t = 2$  の同位が 1 組ずつあることに注意して、 $A = 27.5$ ,  $K = 4620$ ,  $\kappa = 0.9675$ .

$$\begin{aligned} t_0 &= \frac{|3 - 27.5| - 0.5}{\sqrt{\frac{0.9675}{48} \times 4620}} \\ &= 2.487 > t_{0.05}[\infty] = 1.960 \\ t_0^* &= 2.539 \end{aligned}$$

となり、5% 水準で有意となり、母集団の中心位置は  $\mu_0 = 0$  からずれており、大きい。

もとの  $n = 11$  につき、 $m = 12/2 = 6$  で、第 6 番目の値を中央値  $\bar{x}' = 1$  とする。95% 信頼限界を求めるため、 $r = 6 - \sqrt{11} = 2.5$  と切りすてて、 $\mu_L^U = (0+1)/2 = 0.5$ ;  $\mu_U^U = (2+3)/2 = 2.5$  を得る。

一般に、 $x \in N\{\mu, \sigma^2\}$  と正規性がある場合にノンパラ手法を用いるとき効率、感度がおちる。Wilcoxon の 1 標本検定は、しかし、 $t$  分布を用いたいわゆる  $t$  検定に比べて、それほど感度は悪くない。ここで用いた中央値の信頼限界の推定法は、信頼間幅が、 $t$  分布の利用の場合よりも少し広く



なるが、 $n$  が小さいときには、それほど感度はおちない。

### 17. 2つの平均値

対応のない2群データ、 $O_m\{x_i\}$ ,  $O_n\{y_i\}$  について、母平均値  $\mu, \eta$  の比較にあたり、

$$V_x = \frac{S_{xx}}{m-1}, \quad V_y = \frac{S_{yy}}{n-1}$$

を求め、 $V_x \geq V_y$  とする。  $V_x < V_y$  となったなら、 $x$  と  $y$  を交換して扱う。  $F$  分布を利用し、

$$F_0 = \frac{V_x}{V_y} < F_{0.025}[m-1, n-1] \quad (71)$$

となれば、消極的に両群の分散は等しいとして、以下の手法が利用できる。  $F_0$  は、等分散のときには、1 よりもひどく大きくはならない性質の、2乗の形式の  $S/N$  比である。分子と分母につき、それぞれ第1, 第2自由度であるが、その水準2.5%の限界値と  $F_0$  を比べる。

不等分散のとき、 $\bar{x}$  なり  $\bar{y}$  なりの平均値によって分散  $V_x, V_y$  が変化するという場合がある。分散が  $k\mu$  の傾向のときには、 $\sqrt{x+0.25}; k\mu^2$  の傾向のときには  $\log x$  ないし  $\log(x+1)$  などに変換して扱うとほぼ等分散になるが、この変換値での差の意味を、あらためて考える必要がある。

**等分散の場合**、共通の分散を求めなおして、平均値の差を吟味するが、検定の  $S/N$  比である  $t_0$  なり、信頼限界の係数  $t_\alpha$  なりは、自由度  $[m+n-2]$  で考える。つまり、共通の分散  $V$  の分子は、 $(m-1)+(n-1)$  の2乗項からできている。

$$V = \frac{S_{xx} + S_{yy}}{m+n-2} = \frac{\sum x_i^2 - n\bar{x}^2 + \sum y_j^2 - n\bar{y}^2}{m+n-2}$$

$$t_0 = \frac{|\bar{x} - \bar{y}| - \delta_0}{\sqrt{V\left(\frac{1}{m} + \frac{1}{n}\right)}} \quad (72)$$

$$\delta_L^U = (\bar{x} - \bar{y}) \pm t_\alpha[m+n-2] \sqrt{V\left(\frac{1}{m} + \frac{1}{n}\right)}$$

$t_0, \delta_L^U$  の  $\sqrt{V(1/m+1/n)}$  は、差  $(\bar{x} - \bar{y})$  のノイズ  $SE\{\bar{x} - \bar{y}\}$  である。  $t_0$  は、 $H_0: \mu - \eta = \delta = \delta_0$  に

ついて書いたもので、2群に差ありや、の場合には  $H_0: \mu = \eta, \delta_0 = 0$  となるので、 $t_0$  の  $\delta_0$  を省略することになる。

なお、2標本  $t$  検定で、水準0.05の付近では、節5の式(19)にあたる、検定特性の式は、近似的に、

$$\lambda = \frac{\delta}{\sigma} \div \sqrt{\frac{m+n-2}{(m-1)(n-1)}} (t_\alpha[\infty] + t_\beta[\infty]) \quad (73)$$

となる。

ノンパラ手法で、対応のない2群の中央値の差の推定を行なうには、各群の中央値  $\bar{x}', \bar{y}'$  を求めたうえ、点推定を  $d' = \bar{x}' - \bar{y}'$  とする。ついで、近似的な区間推定では、

$$w = \frac{t_\alpha[\infty]}{2} \sqrt{\frac{mn}{m+n}}, \quad w = \sqrt{\frac{mn}{m+n}} (95\%) \quad (74)$$

を求め、 $O_m$  で  $(m+1)/2 \pm w = r_1; r_2$ ,  $O_n$  で  $(n+1)/2 \pm w = s_1; s_2$  を求めたうえ、

$$\delta'_L{}^U = x_{(r_1)} - y_{(s_1)}; x_{(r_2)} - y_{(s_2)} \quad (75)$$

とすればよい。

効率のよい2標本検定として、**Wilcoxonの2標本検定**があるが、まず、両群をこみにして順位づけをしたうえ、各群の順位和を求めて  $S/N$  をつくるものであるが、節14の後半に記した。この方法は、平均値というよりも、中心位置の比較であり、データの分布についての注文は少ない。

### 【例 14】

$O_6\{48, 54, 51, 42, 46, 49, \}$ ,  $O_5\{47, 59, 55, 53, 58\}$  につき  $\bar{x} = 48.3333$ ,  $S_{xx} = 85.3333$ ,  $V_x = 17.0667$ ,  $\bar{y} = 54.4000$ ,  $S_{yy} = 91.2000$ ,  $V_y = 22.8000$ .  $F_0 = V_y/V_x < F_{0.025}[4, 5] = 7.388$  で等分散とみて、

$$SE\{\bar{x} - \bar{y}\} = \sqrt{19.6148\left(\frac{11}{30}\right)} = 2.682$$

$$t_0 = \frac{|48.3333 - 54.4000|}{2.682} = \frac{6.0667}{2.682}$$

で、 $t_{0.05}[9] = 2.262$  と同じく、ちょうど5%で有意。引き算を  $\bar{y} - \bar{x}$  とおきなとし、



$$\delta_L^U = 6.0667 \pm 2.262 \times 2.682 = 0; 12.133$$


検定と推定が裏腹になっている。

中央値は  $\bar{x}'=48.5$ ,  $\bar{y}'=55$  で, 差は  $d'=-6.5$  となる.  $w=\sqrt{30/11}=1.65$  であるから,  $r_1=1.5$ ,  $r_2=5$ ;  $s_1=4.5$ ,  $s_2=1$  としたうえ,

$$\begin{aligned}\delta_L^U &= 44-58.5; 51-47 \\ &= -14.5; 4\end{aligned}$$

となるが,  $\bar{y}'-\bar{x}'$  の差では  $6.5(-4; 14.5)$  となり, 信頼間幅は, かなり広い。

両群のデータを, タテ軸の左右にプロットして順位をつける。



$R_6\{1, 2, 4, 5, 6, 8\}$ ,  $R_5\{3, 7, 9, 10, 11\}$  の順位データとなるが, 同位はない.  $T_6=26$ ,  $T_5=40$ ,  $T_6=66=11 \times 12/2$  である.  $T_6$  に着目して, 式 (57) から  $n_1, n_2$  を  $m, n$  と読みかえたうえ,  $A=66 \times 6/11=36$  を用い,

$$t_0 = \frac{|26-36|-0.5}{\sqrt{\frac{1}{6} \times 5 \times 36}} = 1.734 < t_{0.05}[\infty] = 1.960$$

で, 5% 水準で有意ではなく, 両群の中心位置にずれがあるとは言いかねる.  $t_0=1.734$  の実質水準は  $P=0.083$  である. 組み合わせの議論から直接に確率計算をすると,  $P=0.0823$  となり,  $t_0$  の近似はよい。

2 標本 t 検定では 5% で有意となったが, Wilcoxon の 2 標本検定では有意にならない. 一つには, 順位検定の検出力が劣っていたことによるのであろうが, 5% ぎりぎり有意であったので, より強い確信を求めるには, 再試験を必要とする

であろう。

$\lambda=1.5$  程度を現実的に意味のある差と考えていたとすれば, 式 (73) から,

$$\begin{aligned}1.5 &= \sqrt{0.45(1.960)} + t_{2\beta}[\infty] \\ t_{2\beta} &= 0.276\end{aligned}$$

となり,  $\beta \approx 0.4$  で, この例数設計では, 検出力 60% となり, そもそも, 少なすぎた. 本来  $1.5\sigma$  程度の差を 90% で検出するには, 各群とも 9~10 例を用いることが手堅かったといえる。

式 (71) で, 不等分散と判断されたときには, 2 標本 t 検定の手法は利用できなくなる.  $m=n$  のときには, 形式的に等分散としての式 (72) を用いるが,  $t_0 \geq t_{\alpha}[n-1]$  のとき有意とする。

$m < n$  と例数が不揃いのときには

$$t_0 = \frac{|\bar{x} - \bar{y}| - \delta_0}{\sqrt{\frac{V_x}{m} + \frac{V_y}{n}}} \quad (76)$$

を求めたうえ,

- (1)  $t_0 < t_{\alpha}[m+n-2]$  では有意ではない,
- (2)  $t_0 > t_{\alpha}[m-1]$  では有意である,
- (3) 以上で未決定なら,  $t_0$  を重みづけをした

$$t_{\alpha}^* = \frac{\frac{V_x}{m} t_{\alpha}[m-1] + \frac{V_y}{n} t_{\alpha}[n-1]}{\frac{V_x}{m} + \frac{V_y}{n}} \quad (77)$$

と比べて判断する. この方法は Cochran によるものであるが, 他にも方法がある。

ときに,  $\eta/\mu$  の比に関心をもつことがあろう. 等分散の扱いができるときには,

$$\begin{aligned}g &= \left\{ \frac{t_{\alpha}[m+n-2]}{\bar{x}} \right\}^2 \frac{V}{m} \\ \rho_L^U &= \frac{1}{1-g} \left\{ \left( \frac{\bar{y}}{\bar{x}} \right) \pm \frac{\bar{x}}{t_{\alpha}[m+n-2]} \times \right. \\ &\quad \left. \sqrt{V \left[ \left( \frac{\bar{y}}{\bar{x}} \right)^2 \frac{1}{m} + \frac{1-g}{n} \right]} \right\} \quad (78)\end{aligned}$$

によって比の信頼限界が与えられるが,  $g < 0.1$  では  $g=0$  とおいてよいとされる. 式 (78) は, Fieller

の式と呼ばれるものの一つである。

### 【例 15】

例14の  $O_5\{x_i\}$ ,  $O_5\{y_j\}$  のデータでは  $r=\bar{y}/\bar{x}=1.1255$  となる。  $g=0.0072$  であるが、これを省略しないで式 (78) を用いると、

$$\rho_L^V = \frac{1}{0.9928} [1.1255 \pm 0.1327] = 1.000; 1.267$$

となる。比が1は差が0に対応する。

## 18. 実験計画法

観測値  $y$  が、いくつかの原因系で左右され、また、確率的なゆらぎに影響されるという考えのもとに、節7では、モデルをつくって考察した。モデルを一般的に書けば、

$$y_i = \beta_0 + \beta_1 x_{i1} + \cdots + \beta_j x_{ij} + \cdots + \beta_p x_{ip} + \varepsilon_i \quad (79)$$

といかめしくなるが、**線形モデル**と呼ばれるものになる。

対応のない2群比較で、 $O_m\{x_i\}$ ,  $O_n\{y_j\}$  としたが、これらを一括して  $O_{m+n}\{y_i\}$  と表現し、 $y_i$  が第1群なら  $x_{i1}$  は1,  $x_{i2}$  は0となり、 $y_i$  が第2群なら  $x_{i1}$  は0,  $x_{i2}$  は1となる約束をおけば、

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \varepsilon_i \quad (80)$$

のモデルになり、第1群、第2群の母平均値は  $(\beta_0 + \beta_1)$ ,  $(\beta_0 + \beta_2)$  となる。 $\beta_0$  を全体の平均値とすれば、 $\beta_1, \beta_2$  は、この  $\beta_0$  からのずれになり、両群の平均値の差が  $\delta$  なら、 $\beta_1, \beta_2$  は  $\pm \delta/2$  となる。

一方、ある個体の特性、たとえば年齢  $x_1$  が  $y_1$  に直接的に影響するなら、これを共変数、説明変数といい、 $y_1$  を目的変数という。

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad (81)$$

が、この際のモデルになり、 $P_i\{x_i, y_i\}$  のプロットに直線を通したときの切片が  $\beta_0$ 、勾配が  $\beta_1$  になる。これも式 (79) の特殊な場合とみられる。

線形モデル式 (79) は一貫して、最小2乗法の原理で処理できるが、実際上は、 $x_{ij}$  の性質によっ

て区別して扱う習慣がある。

1) 分散分析 ANOVA では、 $x_{ij}$  は本質的に1か0をとり、 $\beta_j$  が  $y_i$  の変動の原因系になっているか、いないかの指標となる。

2) 回帰分析 REGAN では、 $x_{ij}$  は独立変数的であり、目的変数  $y_i$  の変動を説明している性格になる。普通は  $x_{ij}$  を留めて、 $y_i$  を変量として扱う。

3) 共分散分析 ANOCVA では、 $x_{ij}$  の一部は指標的、一部は独立変数的であり、この共変数の影響を除いて  $y_i$  の議論をしたり、また共変数そのものの性質を検討したりの場合に利用される。

こうした線形モデルの性質を基盤に、転がりこんでくるデータを待つという態度よりも、積極的に現場に働きかけて、データを取りにいくという態度を重視して組み立てられたものが、**実験計画法**と呼ばれている体系であり、R. A. Fisher の思想の上に発展した。

実質科学的に重要な原因系のいくつかを因子として取りあげ、これを因子水準として小わけし、観測特性との関係において、水準間の比較、因子相互のかかわりなどを、実施可能な範囲で、経済的に、正しく、感度よく捉えることをねらう。

- (1) 観測特性、必要なら共変数を指定し、観測条件、方法を明確にする。
- (2) 観測の単位を定め、必要に応じて、反応性の類似した単位の集合をブロックとする。
- (3) 必要な因子を定め、定量的、半定量的、定性的な水準を設けるが、研究目的の因子、偏り防止の因子、誤差制御の因子、手法上のダミー因子などが区別される。
- (4) 因子水準そのもの、異なった因子間の水準の組合わせを処理といい、具体的に取りあげる処理を定め、これと観測単位との対応、割りつけを合理的に決める。
- (5) こうして、正当な推論を行なうにふさわしい解析方法、例数と実施可能性を検討し、必要なら、(1)に戻って再吟味する。

## 19. 分散分析

対応のない2群比較を多群に拡張し、 $\alpha$ 水準の

処理  $A_1, \dots, A_i, \dots, A_a$  につき, それぞれ  $r$  回の同数観測を行なう. ただし,  $n=ar$  の観測単位に,  $A_1, \dots, A_a$  を無作為に割りつけるものとする.

$A_1$	$y_{11} \cdots y_{1j} \cdots y_{1r}$	$T_1$
$\vdots$	$\vdots$	$\vdots$
$A_i$	$y_{i1} \cdots y_{ij} \cdots y_{ir}$	$T_i$
$\vdots$	$\vdots$	$\vdots$
$A_a$	$y_{a1} \cdots y_{aj} \cdots y_{ar}$	$T_a$

$$T_G = \sum_{i=1}^a T_i$$

$$y = \frac{T_G}{ar}$$

この形式のデータは, 1 因子完全無作為化法によるものであるが,  $A$  という因子で分類されている観点から一元配置のデータと呼んでいることが多い.

$y_{ij}$  は, 第  $i$  水準  $A_i$  のたまたま第  $j$  番目の観測値である. 各水準での和  $T_i$  は,  $r\bar{y}_i$  で,  $A_i$  の効果の平均値を反映するシグナルである. 各  $A_i$  内でのデータは等分散であるとすれば, これらのばらつきをプールしたものは, 同じ処理でのばらつきであるから, ノイズにほかならない. そこで,  $T_i=r\bar{y}_i$  間のばらつきをシグナルとしてまとめ,  $S/N$  比にもっていこうというのが, 一元配置の解析方針である.

第  $i$  処理のデータについては,

$$y_{ij} = (\beta_0 + \beta_i) + \varepsilon_{ij}$$

で,  $x_{ij}=1$  であるが, 他の  $\beta_1, \dots, \beta_a$  に関する指標変数は, すべて 0 となっている.

計算手順から示すと,

$$CF = \frac{T_G^2}{ar}$$

$$S_{AR} = \sum_i \sum_j y_{ij}^2 - CF \quad [ar-1]$$

$$S_A = \frac{1}{r} \sum T_i^2 - CF \quad [a-1] \quad (82)$$

$$S_{R(A)} = S_{AR} - S_A \quad [a(r-1)]$$

ここに,  $S_{AR}$  は全体,  $S_A$  は処理,  $S_{R(A)}$  は誤差相当の残差に関する平方和であり,

$$\sum_i \sum_j (y_{ij} - \bar{y})^2 = r \sum_i (\bar{y}_i - \bar{y})^2 + \sum_i \sum_j (y_{ij} - \bar{y}_i)^2$$

のそれぞれに対応しているが, 式 (82) の計算法が

簡単である. ここで重要なことは, 平方和と, それに対する自由度の双方に, 加法的,

$$S_{AR} = S_A + S_{R(A)} \quad (83)$$

$$[ar-1] = [a-1] + [r(a-1)]$$

が成立する点にある.

ついで,  $V_A = S_A/(a-1)$ ,  $V_{R(A)} = S_{R(A)}/(ar-a)$  と, 平方和/自由度として, 分散を求めたとき,  $V_{R(A)}$  は, 各処理群内のばらつき  $\varepsilon$  に関係した誤差分散  $\sigma^2$  を推定するが,  $V_A$  は,  $\sigma^2$  と各処理群間のばらつきに関係した  $\sigma_A^2$  の 2 つの要素から成る.

$H_0: A_1, \dots, A_a$  の処理効果は一樣,  $H_1$ : 少なくとも一つは他と異なる, とおいたとき,  $H_0$  が正しいなら  $\sigma_A^2=0$  となるから,

$$F_0 = \frac{V_A}{V_{R(A)}} \quad (84)$$

の分散比は, 本質的には  $\sigma^2/\sigma^2$  で, 1 を大きくこえることはあるまい. 100 回のうち, たかだか 5 回程度はこえるかもしれないという,  $F_0$  の限界値が,  $F_{0.05}[(a-1), (ar-r)]$  である. そこで,  $F_0$  がこれより大になれば, 5% 水準で有意とし,  $H_0$ : 効果の一樣性をすてて,  $\sigma_A^2 \neq 0$  と考え,  $H_1$ : 少なくとも 1 つの処理は他と異なると考える.

式 (82) の値は, 分散分析表として整理されるが,  $Ms$  は平均平方和で, 分散を指す.

要因	SS	Df	Ms	$F_0$
A: 処理	$S_A$	$a-1$	$V_A$	$V_A/V_{R(A)}$
R(A): 残差	$S_{R(A)}$	$ar-a$	$V_{R(A)}$	—
AR: 全体	$S_{AR}$	$ar-1$	—	—

一元配置で, 各処理群の反復数が等しいとき, 一般に都合がよいが,  $r_1 \neq r_1'$  と異なるとき,  $n = \sum r_i$  を全例数とし,  $S_A = \sum T_i^2/r_i - CF$ , 残差自由度を  $[n-ar]$  と変更すればよい.

観測単位が, 互いに類似した  $b$  グループに分かれるとき, これらを  $B_1, \dots, B_j, \dots, B_b$  のブロックとして,  $n=ab$  に無作為に  $A_1, \dots, A_i, \dots, A_a$  を割りつける代わりに, 各ブロック  $B_j$  ごとに  $a$  水準の処理を無作為化する. これを, 乱塊法とい



うが、A と B の2 因子でデータが分類されているので、**二元配置**と呼んでいることが多い。

$$y_{ij} = \eta + \alpha_i + \beta_j + \varepsilon_{ij}$$

のモデルを考えるわけで、データは、2 方向で押えられる。

	B <sub>1</sub> ... B <sub>j</sub> ... B <sub>b</sub>	
A <sub>1</sub>	y <sub>11</sub> ..... y <sub>ab</sub>	T <sub>A1</sub>
⋮	⋮	⋮
A <sub>i</sub>	⋮ y <sub>ij</sub> ⋮	T <sub>Ai</sub>
⋮	⋮	⋮
A <sub>a</sub>	y <sub>a1</sub> ..... y <sub>ab</sub>	T <sub>Aa</sub>
	T <sub>B1</sub> ... T <sub>Bj</sub> ... T <sub>Bb</sub>	T <sub>G</sub>

一元配置の場合と類似の方法で、

$$\begin{aligned} CF &= \frac{T_G^2}{ab} \\ S_{AB} &= \sum_i \sum_j y_{ij}^2 - CF \quad [ab-1] \\ S_A &= \frac{1}{b} \sum_i T_{Ai}^2 - CF \quad [a-1] \\ S_B &= \frac{1}{a} \sum_j T_{Bj}^2 - CF \quad [b-1] \\ S_{A \times B} &= S_{AB} - S_A - S_B \quad [(a-1)(b-1)] \end{aligned} \quad (85)$$

ここに  $S_{A \times B}$  は、誤差項であるが、形式上は  $A \times B$  を交互作用といい、特別な  $A_i$  と  $B_j$  の出あいでは、 $y_{ij} = \eta + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ij}$  と特別な効果  $(\alpha\beta)_{ij}$  が加わることの表現である。この二元配置のモデルでは、 $S_{A \times B}$  を流用して誤差相当の残差を示すが、本質的な交互作用は存在しないものとする。

式 (85) の値から、分散分析表は、

要因	SS	Df	Ms	F <sub>0</sub>
A	S <sub>A</sub>	a-1	V <sub>A</sub>	V <sub>A</sub> /V <sub>A×B</sub>
B	S <sub>B</sub>	b-1	V <sub>B</sub>	V <sub>B</sub> /V <sub>A×B</sub>
A×B	S <sub>A×B</sub>	(a-1)(b-1)	V <sub>A×B</sub>	—
AB	S <sub>AB</sub>	ab-1	—	—

Ms は、平方和／自由度の分散である。F<sub>0</sub> は A と B について求められ、普通は処理効果の比較に関

心があり、 $F_0(A) = V_A/V_{A \times B} \geq F_{\alpha}[(a-1), (a-1) \times (b-1)]$  のとき有意とする。ブロックの一様性をみるには、第 1 自由度を  $(b-1)$  とする。

対応のない 2 群比較のデータは  $a=2$  の一元配置として扱うと、 $t_0^2 = F_0$  となり、まったく同義になる。対応のある 2 群比較のデータの場合、差として、1 標本 t 検定を行なうと、これは、 $a=2$  の二元配置と同義になる。

### 【例 16】

二元配置のデータがある。

	B <sub>1</sub>	B <sub>2</sub>	B <sub>3</sub>	B <sub>4</sub>	
A <sub>1</sub>	5	10	5	6	26
A <sub>2</sub>	6	9	7	7	29
A <sub>3</sub>	9	13	11	12	45
	20	32	23	25	100

まず、本来は正しくないが、ブロックを無視した一元配置で考えると、

$$\begin{aligned} CF &= \frac{100^2}{3 \times 4} = 833.333 \\ S_{AR} &= 916 - CF = 82.6667 \\ S_A &= \frac{1}{4} \times 3542 - CF = 52.1667 \quad [2] \\ S_{R(A)} &= 82.6667 - 52.1667 = 30.50000 \quad [9] \\ V_A &= \frac{S_A}{2} = 26.0834 \\ V_{R(A)} &= \frac{S_{R(A)}}{6} = 6.1000 \quad SD = \sqrt{6.1000} \\ F_0 &= \frac{26.0834}{6.1000} = 4.276 \end{aligned}$$

F<sub>0</sub> は  $F_{0.05}[2, 9] = 4.256$  より大きく、5% 水準で有意である。SD =  $\sqrt{V_{R(A)}} = 2.470$  である。

二元配置としては、 $S_{AB} = S_{AR} = 82.6667$  であり、 $S_B = 2574/3 - CF = 26.000$  を求め、 $S_{A \times B} = S_A - S_B = 4.5500$  となる。

誤差ないし残差に含まれていた B を取り出したので、一元配置と比べて、 $F_0(A) = 34.397$  と非常に大きくなり、SD =  $\sqrt{V_{A \times B}} = 0.871$  となり、いず

要因	SS	Df	Ms	F <sub>0</sub>
A	52.1667	2	26.0834	34.397
B	26.0000	3	8.6667	11.429
A × B	4.5500	6	0.7583	—
AB	82.6667	11	—	—

れの処理平均値でも  $SE=0.871/\sqrt{4}=0.436$ .

一元配置でも二元配置でも、処理 A が有意となった段階では、どれとどれとが異なるかは、はっきりしない。これを明らかにするには、節 9 で述べた多重比較の手法が必要となる。

乱塊法で、各ブロックごとに順位づけをしたうえ、各処理ごとに和をとり、 $T_i$  としたとき、同位の組の修正を行ない、

$$K = 1 - \frac{\sum (t^3 - t)}{b(a^3 - a)} \quad (86)$$

$$z_0^2 = \frac{6}{\kappa} \left\{ \frac{1}{T_G} \sum T_i^2 - \frac{1}{a} T_G \right\} \geq z_{\alpha}^2 [a-1]$$

のとき有意で、処理効果の一様性を否定する方法がある。これは **Freedman の検定** であるが、効率はあまりよくない。上の例では同位なしで、 $\kappa=1$ ,  $z_0^2=6.500 > z_{0.05}^2[2]=5.991$  で有意となる。

## 20. 最小 2 乗法

線形モデルについては節 18 に紹介したが、 $O_n \{x_i, y_i\}$  のデータに直線回帰モデル、

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad (87)$$

をあてはめることを例に、最小 2 乗法を整理してみる。ベクトルや行列の扱いが盛んに出てくるが、まず、2 つのベクトル、

$$\mathbf{a} = \begin{bmatrix} a_1 \\ \vdots \\ a_i \\ \vdots \\ a_n \end{bmatrix} \quad \mathbf{b} = \begin{bmatrix} b_1 \\ \vdots \\ b_i \\ \vdots \\ b_n \end{bmatrix}$$

が角度  $\theta$  を挟むとき、スカラー積、内積、

$$\begin{aligned} \mathbf{a}'\mathbf{b} &= [\mathbf{a}'\mathbf{b}]' = \mathbf{b}'\mathbf{a} = \sum_{i=1}^n a_i b_i \\ &= \|\mathbf{a}\| \cdot \|\mathbf{b}\| \cos \theta \end{aligned}$$

が定義され、要素の積和になる。 $\mathbf{a}'$  は転置、 $\|\mathbf{a}\|$  はノルムを示し、

$$\mathbf{a}' = \begin{bmatrix} a_1 & \vdots & a_i & \vdots & a_n \end{bmatrix}' = [a_1 \cdots a_i \cdots a_n]$$

$$\|\mathbf{a}\| = \sqrt{\mathbf{a}'\mathbf{a}} = \sqrt{\sum_{i=1}^n a_i^2}$$

である。

このスカラー積の約束で、式 (87) は、

$$y_i = [1, x_i] \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} + \varepsilon_i$$

となる。 $\mathbf{y}=[y_1 \cdots y_n]'$ ,  $\mathbf{j}=[1 \cdots 1]'$ ,  $\mathbf{x}=[x_1 \cdots x_n]'$ ,  $\boldsymbol{\varepsilon}=[\varepsilon_1 \cdots \varepsilon_n]'$  と  $(n \times 1)$  のタテベクトルと回帰係数ベクトル  $\boldsymbol{\beta}=[\beta_0 \beta_1]'$ , さらに  $(n \times 2)$  の行列  $\mathbf{X}=[\mathbf{j} \mathbf{x}]$  を用意し、全データを、

$$\mathbf{y} = [\mathbf{j} \mathbf{x}] \boldsymbol{\beta} + \boldsymbol{\varepsilon} = \mathbf{X} \boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad (88)$$

と書く。 $\mathbf{X}$  の転置はタテの列をヨコの行に並べかえて、 $(n \times 2)$  を  $(2 \times n)$  に変えることで、

$$\mathbf{X}' = [\mathbf{j} \mathbf{x}]' = \begin{bmatrix} \mathbf{j}' \\ \mathbf{x}' \end{bmatrix}$$

誤差項について、(i)  $E\{\varepsilon_i\}=0$  の不偏性、(ii)  $V\{\varepsilon_i\}=\sigma^2$  の等分散性、(iii)  $C\{\varepsilon_i, \varepsilon_l\}=0$  の独立性のもとに、 $Q=\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon}=\sum \varepsilon_i^2$  を最小にする  $\hat{\boldsymbol{\beta}}=[\hat{\beta}_0 \hat{\beta}_1]'$  を求めるのが**最小 2 乗法**でこの解には統計的に好ましい性質 (BLUE) がある。さらに (iv)  $\varepsilon_i \in N\{0, \sigma^2\}$  の正規性があれば、検定や区間推定が容易に行なえる。 $E\{*\}$ ,  $V\{*\}$ ,  $C\{*\}$  は、平均値、分散、共分散を示す。

$$\begin{aligned} Q &= \boldsymbol{\varepsilon}'\boldsymbol{\varepsilon} = [\mathbf{y} - \mathbf{X}\boldsymbol{\beta}]'[\mathbf{y} - \mathbf{X}\boldsymbol{\beta}] \\ &= \mathbf{y}'\mathbf{y} - 2\boldsymbol{\beta}'\mathbf{X}'\mathbf{y} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \end{aligned} \quad (89)$$

を最小化するが、 $[\mathbf{y}'\mathbf{X}\boldsymbol{\beta}]' = \boldsymbol{\beta}'\mathbf{X}'\mathbf{y}$  である。

$$\frac{\partial Q}{\partial \boldsymbol{\beta}} = -2\mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \quad (90)$$

と微分し、これを  $\mathbf{0}$  とおくが、 $[\mathbf{X}'\mathbf{X}]' = \mathbf{X}'\mathbf{X}$  とこ

の  $(2 \times 2)$  の行列は対称で、さらにその行列式が  $|X'X| \neq 0$  であれば、

$$[X'X]^{-1}[X'X] = I = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \quad (91)$$

となる逆行列  $[X'X]^{-1}$  が存在するから、式 (90) から  $X'X\hat{\beta} = X'y$  の正規方程式と呼ばれるものをつくり、これに  $[X'X]^{-1}$  を前から乗じて、

$$\hat{\beta} = [X'X]^{-1}X'y \quad (92)$$

の最小 2 乗解  $\hat{\beta} = [\hat{\beta}_0 \hat{\beta}_1]'$  を得る。I はベクトルや行列においてはスカラーの 1 にあたる単位行列である。

$\hat{\beta}$  を式 (89) に代入し、最小の Q は、

$$\begin{aligned} Q\{\hat{\beta}\} &= y'y - 2\hat{\beta}'X'y + \hat{\beta}'X'X[X'X]^{-1}X'y \\ &= y'y - \hat{\beta}'X'y \end{aligned} \quad (93)$$

となる。これは残差平方和と呼ばれる。

誤差自由度は、n 個のデータから 2 個のパラメータを推定したから  $[n-2]$  で誤差相当の残差分散は、

$$V_R = \frac{Q\{\hat{\beta}\}}{n-2}, \quad E\{V_R\} = \sigma^2 \quad (94)$$

パラメータの分散と共分散は、

$$V\{\hat{\beta}\} = \begin{bmatrix} V\{\hat{\beta}_0\} & C\{\hat{\beta}_0, \hat{\beta}_1\} \\ C\{\hat{\beta}_0, \hat{\beta}_1\} & V\{\hat{\beta}_1\} \end{bmatrix} = \sigma^2[X'X]^{-1} \quad (95)$$

となる。

以上の議論は、より一般的な線形モデル、

$$y_i = \beta_0 + \beta_1 x_{i1} + \cdots + \beta_j x_{ij} + \cdots + \beta_p x_{ip} + \varepsilon_i \quad (96)$$

にも拡張できるが、 $X = [x_1 \cdots x_p]$  で  $[X'X]$  は  $\{(p+1) \times (p+1)\}$  と大きくなり、 $V_R$  の自由度も  $[n-p-1]$  と変わるが、 $n > (p+1)$  としておく。

式 (96) で、 $y_i$  が第 i 例での全般重症度であり、 $x_{i1}, \cdots, x_{ip}$  が標的症状ごとの重症度であれば、 $O_n\{(x_{i1}, \cdots, x_{ip}), y_i\}$  の多特性データについて求めた  $\hat{\beta} = [\hat{\beta}_0 \hat{\beta}_1 \cdots \hat{\beta}_p]'$  は、ある意味で、各標的症

状の重要性を示している。各症状間に関連があれば、一定の規準によって、重要なものだけを選び出す手法も用意され、こうしたものは重回帰分析と呼ばれる。

目的変数  $y_i$  が大きな値では信頼性が低いという事情があれば、 $w_i = 1/y_i, 1/\hat{y}_i$ , とか  $w_i = 1/y_i^2, 1/\hat{y}_i^2$  などの重みづけをして扱うこともある。この重みを要素とした対角行列、

$$W = \begin{bmatrix} w_1 & & & 0 \\ & \ddots & & \\ & & w_i & \\ 0 & & & \ddots \\ & & & & w_n \end{bmatrix},$$

$$W^{1/2} = \begin{bmatrix} \sqrt{w_1} & & & 0 \\ & \ddots & & \\ & & \sqrt{w_i} & \\ 0 & & & \ddots \\ & & & & \sqrt{w_n} \end{bmatrix}$$

を約束したうへ、式 (96) に  $\sqrt{w_i}$  を乗じ、

$$\sqrt{w_i} y_i = \sqrt{w_i} (\beta_0 + \beta_1 x_{i1} + \cdots + \beta_p x_{ip}) + \sqrt{w_i} \varepsilon_i$$

$$W^{1/2}y = [W^{1/2}X]\beta + W^{1/2}\varepsilon$$

とし、式 (89) 以下に準じて、

$$\begin{aligned} [X'W^{1/2}W^{1/2}X]\hat{\beta} &= X'W^{1/2}W^{1/2}y \\ \hat{\beta} &= [X'WX]^{-1}X'Wy \\ Q\{\hat{\beta}\} &= y'Wy - \hat{\beta}'X'Wy \\ V\{\hat{\beta}\} &= \sigma^2[X'WX]^{-1} \end{aligned} \quad (97)$$

となる。

パラメータ  $\hat{\beta}$  を用いて、 $y$  の予測値  $\hat{y} = X\hat{\beta}$  を得るが、 $X$  の第 i 行  $x_{i\cdot}' = [x_{i1} \cdots x_{ip}]$  を用いると、

$$\begin{aligned} \hat{y}_i &= x_{i\cdot}'\hat{\beta} \\ V\{\hat{y}_i\} &= \sigma^2 x_{i\cdot}'[X'X]^{-1}x_{i\cdot}, \quad \text{ないし}, \\ &= \sigma^2 x_{i\cdot}'[X'WX]^{-1}x_{i\cdot}. \end{aligned} \quad (98)$$

となる。重みなしでは  $I=W$  とおいたことに相当する。



## 21. 直線回帰

$O_n\{x_i, y_i\}$  に直線をあてはめるにあたり,  $y_i$  は  $x_i$  と関係なく, 平均値  $\eta$  のまわりにばらつくというモデルを並べると,

$$\begin{cases} \omega: y_i = \eta + \varepsilon_i \\ \Omega: y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \end{cases} \quad (99)$$

となる.  $\varepsilon_i$  はそれぞれで意味が異なる.  $\Omega$  では, いわば平均値  $(\beta_0 + \beta_1 x_i)$  のまわりに  $y_i$  がばらついているとみられる.

モデル  $\omega$  は単純な線形モデルで, 式 (88) の表現では,  $\mathbf{X}$  が  $\mathbf{j}$  に退化し,

$$\mathbf{y} = \mathbf{j}\eta + \boldsymbol{\varepsilon} = \eta\mathbf{j} + \boldsymbol{\varepsilon} \quad (100)$$

となる. 式 (92) 以下を用い,  $\mathbf{j}\mathbf{j} = \sum 1 \times 1 = n$ ,  $\mathbf{j}'\mathbf{y} = \sum 1 \times y_i$ ,  $\mathbf{y}'\mathbf{y} = \sum y_i^2$  などに注意し,

$$\begin{aligned} \hat{\eta} &= [\mathbf{j}'\mathbf{j}]^{-1}\mathbf{j}'\mathbf{y} = n^{-1} \sum y_i = \bar{y} \\ Q\{\hat{\eta}\} &= \mathbf{y}'\mathbf{y} - \hat{\eta}\mathbf{j}'\mathbf{y} = \sum y_i^2 - n\bar{y}^2 = S_{yy} \\ V_R &= \frac{Q\{\hat{\eta}\}}{n-1} = \frac{S_{yy}}{n-1} = V \\ V\{\hat{\eta}\} &= V\{\bar{y}\} = \sigma^2[\mathbf{j}'\mathbf{j}]^{-1} = \frac{\sigma^2}{n} = SE\{\bar{y}\} \end{aligned} \quad (101)$$

などを得る. いずれも, これまでに何回も利用した性質である.

モデル式 (99) の  $\Omega$  では少々ややこしいが,

$$\begin{aligned} [\mathbf{X}'\mathbf{X}]^{-1} &= \begin{bmatrix} \mathbf{j}'\mathbf{j} & \mathbf{j}'\mathbf{x} \\ \mathbf{x}'\mathbf{j} & \mathbf{x}'\mathbf{x} \end{bmatrix}^{-1} = \begin{bmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{bmatrix}^{-1} \\ &= \begin{bmatrix} \frac{1}{n} + \frac{\bar{x}}{S_{xx}} & -\frac{\bar{x}}{S_{xx}} \\ -\frac{\bar{x}}{S_{xx}} & \frac{1}{S_{xx}} \end{bmatrix} \\ [\mathbf{X}'\mathbf{y}] &= \begin{bmatrix} \mathbf{j}' \\ \mathbf{x}' \end{bmatrix} \mathbf{y} = \begin{bmatrix} \sum y_i \\ \sum x_i y_i \end{bmatrix} \end{aligned} \quad (102)$$

としたうえ, 式 (62) で,  $x$  と  $y$  との直線的なかわり, 共変動を,

$$S_{xy} = \sum x_i y_i - n\bar{x}\bar{y} = \sum x_i y_i - \frac{(\sum x_i)(\sum y_i)}{n}$$

と定義したことを用いると,  $\hat{\boldsymbol{\beta}} = [\mathbf{X}'\mathbf{X}]^{-1}\mathbf{X}'\mathbf{y}$  の具

体的な値は,

$$\boldsymbol{\beta} = \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{bmatrix} = \begin{bmatrix} \bar{y} - \frac{S_{xy}}{S_{xx}} \bar{x} \\ \frac{S_{xy}}{S_{xx}} \end{bmatrix} \quad (103)$$

となる. 切片  $\hat{\beta}_0$  を勾配  $\hat{\beta}_1 = S_{xy}/S_{xx}$  で表現し,

$$\hat{y} = \bar{y} - \hat{\beta}_1 \bar{x} + \hat{\beta}_1 x \quad (104)$$

の直線回帰式を得る.

式 (93) の最小の残差平方和は,

$$\begin{aligned} Q\{\hat{\boldsymbol{\beta}}\} &= \sum y_i^2 - (n\bar{y}\hat{\beta}_0 + \hat{\beta}_1 \sum x_i y_i) \\ &= \sum y_i^2 - (n\bar{y}^2 - \hat{\beta}_1 n\bar{x}\bar{y} + \hat{\beta}_1 \sum x_i y_i) \\ &= S_{yy} - \hat{\beta}_1 S_{xy} \end{aligned} \quad (105)$$

となる.


図 5 に示すように,  $\mathbf{y}, \mathbf{j}, \mathbf{x}$  をとり,  $\mathbf{y}$  から  $\mathbf{j}$  上に垂線をおろした点が  $\hat{\eta}\mathbf{j}$  であり,  $\mathbf{y}$  から  $[\mathbf{j} \ \mathbf{x}]$  で定まる平面上に垂線をおろした点が  $\mathbf{X}\hat{\boldsymbol{\beta}}$  である. したがって,  $[\mathbf{j}'\mathbf{j}]^{-1}\mathbf{j}'$  および  $\mathbf{X}[\mathbf{X}'\mathbf{X}]^{-1}\mathbf{X}'$  は,  $\mathbf{y}$  を  $\mathbf{j}$  上および  $[\mathbf{j} \ \mathbf{x}]$  上に正射影する働きをもつ ( $n \times n$ ) の行列である. いずれも対称で, 2 乗しても同じである (べき等) という性質をもっている.  $\|\mathbf{y}\|^2 = \|\hat{\eta}\mathbf{j}\|^2 + Q\{\hat{\eta}\}$  のピタゴラスの定理は,  $\sum y_i^2 = n\bar{y}^2 + Q\{\hat{\eta}\}$  で, 式 (101) の  $Q\{\hat{\eta}\} = S_{yy}$  を意味する.

$\Omega$  では,  $\{y_i\}$  のばらつきは,  $\beta_1 x_i$  と表現される,  $x_i$  につられて動く部分と, 誤差項  $\varepsilon_i$  による部分から成る.  $\omega$  では  $\{y_i\}$  のばらつきは, すべて誤差項  $\varepsilon_i$  とした. それぞれの残差平方和は, 式 (101), (105) から,

$$\begin{cases} \omega: Q\{\hat{\eta}\} = S_{yy} & [n-1] \\ \Omega: Q\{\hat{\boldsymbol{\beta}}\} = S_{yy} - \frac{S_{xy}^2}{S_{xx}} & [n-2] \end{cases} \quad (106)$$

であるが,  $S_{xy}^2/S_{xx} \geq 0$  で,  $\omega$  に  $\beta_1 x_i$  を加えた  $\Omega$  では残差平方和が一般に小さくなり, この減少分  $S_{xy}^2/S_{xx}$  が勾配  $\beta_1$  の手柄になり,  $S_{yy}$  のうち  $x$  の直線的影響で説明できる部分が減少分とみられる. 図 5 の  $\hat{\eta}\mathbf{j}$  から  $\mathbf{X}\hat{\boldsymbol{\beta}}$  までの長さの 2 乗がこれにあたる.

$Q\{\hat{\boldsymbol{\beta}}\}$  は  $S_{yy} - S_{xy}^2/S_{xx}$  として求めたうえ, 以上をまとめると,

図 5  $\omega$  と  $\Omega$  のモデル

要因	SS	Df	Ms
直線性 L	$S_{xy}^2/S_{xx}$	1	$V_L = S_{xy}^2/S_{xx}$
残 差 R	$Q\{\hat{\beta}\}$	$n-2$	$V_R = Q\{\hat{\beta}\}/(n-2)$
全 体 Y	$S_{yy}$	$n-1$	—

$H_0: \beta_1=0, H_1: \beta_1 \neq 0$  の検定は,

$$F_0 = \frac{V_L}{V_R} \geq F_{\alpha}[1, n-2] = \{t_{\alpha}[n-2]\}^2 \quad (107)$$

のときに有意で、直線性を認める。もう少し厳密に“直線性”を扱うには、2次、3次、…の項が無視できることを検討する。

式 (95) から  $V\{\hat{\beta}_1\} = \sigma^2/S_{xx}$  であるから、 $\hat{\beta}_1$  のノイズを  $SE\{\hat{\beta}_1\} = \sqrt{V_R/S_{xx}}$  として、

$$t_0 = \frac{|\hat{\beta}_1 - 0|}{\sqrt{V_R}} \sqrt{S_{xx}} \quad (108)$$

$$\beta_{1L}^U = \hat{\beta}_1 \pm t_{\alpha}[n-2] \sqrt{\frac{V_R}{S_{xx}}}$$

$t_0 \geq t_{\alpha}[n-2]$  で有意ならば、 $[\beta_{1L}, \beta_{1U}]$  はゼロを含まない。 $t_0^2$  は式 (107) の  $F_0$  と完全に一致するはず。

形式的に、 $x$  と  $y$  と交換して、

$$\hat{x}_i = \beta_0' + \beta_1' y_i + \varepsilon_i'$$

と  $y$  に対する  $x$  の回帰式が考えられる、これについての  $F$  検定、 $\hat{\beta}_1'$  の  $t$  検定も、上述とまったく同じ結果になるが、一般に  $\hat{\beta}_1 \neq \hat{\beta}_1'$  である。

$\{y_i\}$  のばらつきを変動  $S_{yy}$  で表現すると、その一部は直線性で説明できる。その割合を関与率または、 $x$  で決定されるという意味で決定係数といい、

$$r^2 = \frac{S_{xy}^2}{S_{xx}S_{yy}} = \hat{\beta}_1 \hat{\beta}_1' \quad (109)$$

とする。形式上は、 $\{x_i\}$  のばらつきのうち、 $y$  で決定される部分の割合とも考えられる。

回帰式では、独立変数  $x$  で従属変数  $y$  を説明しているが、 $x$  と  $y$  の直線的な相互関連性を示すのに、(単)相関係数ないし Pearson の積率相関係数、

$$r = \frac{S_{xy}^2}{\sqrt{S_{xx}S_{yy}}} \quad (110)$$

が用いられ、 $H_0: \rho=0, H_1: \rho \neq 0$  を無相関の検定といい、

$$t_0 = |r| \sqrt{\frac{n-2}{1-r^2}} \geq t_{\alpha}[n-2] \quad (111)$$

のとき有意である。この  $t_0$  は式 (108) の  $t_0$  と同じになる。式 (111) をみればすぐわかるように、 $|r|$  が小さくても、 $n$  が大きくなると、容易に有意になるので、直線性あり、とか相関性あり、とかの結論は、現実的にはあまり意味がなく、むしろ  $r^2$  について考えた方がよいと思われる。

対応のない2群のデータをヨコ軸の 0, 1 の座標にそれぞれプロットして、形式的に直線、をあてはめ、式 (108), (111) の  $t_0$  を求めると、平均値

の比較の  $t$  検定の式 (72) の  $t_0$  と正確に一致する。

### 【例 17】

$O_{11}\{x_i, y_i\}$  のデータがある。

x	1	2	2	3	4	4	5	6	6	7	8	48
y	2	1	4	6	4	5	7	7	9	9	9	63

$\bar{x} = 4.3636$ ,  $\bar{y} = 5.7273$ ,  $S_{xx} = 50.5454$ ,  $S_{yy} = 78.1818$ ,  $S_{xy} = 57.0909$ ,  $\hat{\beta}_1 = 1.1295$  などを得る。  
これらから、

要因	SS	Df	Ms	$F_0$
L	64.4840	1	64.4840**	42.368
R	13.6978	9	1.5220	—
Y	78.1818	10	—	—

$t_{0.05}[9] = 2.262$  で、式 (108) から、

$$\begin{aligned}\beta_{1L}^U &= 1.1295 \pm 2.262 \sqrt{\frac{1.5220}{50.5454}} \\ &= 0.737; 1.522\end{aligned}$$

また、 $t_0 = 6.509$  で、 $t_0^2 = 42.368 = F_0$  である。

$$r^2 = \frac{57.0909^2}{50.5454 \times 78.1818} = 0.8248$$

で、 $y$  の変動の 82.5% は直線性で説明される。無相関の検定では、

$$t_0 = \sqrt{0.8248} \cdot \sqrt{\frac{9}{1-0.8248}} = 6.509$$

回帰式は、 $\bar{y} - \hat{\beta}_1 \bar{x} = 0.799$  を計算し、

$$y = 0.799 + 1.130x$$

ここで、ある値  $x^*$  を指定したとき、そこでの予測値  $\hat{y}^*$  の  $100(1-\alpha)\%$  信頼限界は、式 (98) の考え方に沿って、

$$\begin{aligned}\eta_{L^*}^U &= \hat{y} + \hat{\beta}_1(x^* - \bar{x}) \\ &\pm t_\alpha[n-2] \sqrt{V_R \left\{ \frac{1}{n} + \frac{(x - \bar{x})^2}{S_{xx}} \right\}} \quad (112)\end{aligned}$$

となる。 $\hat{y}^*$  のまわりの個体に関しては、根号内が  $[V_R \{1 + 1/n + (x^* - \bar{x})^2/S_{xx}\}]$  となる。いずれにしても  $x^* = \bar{x}$  のとき区間幅が最小になる。

散点図と、 $x^*$  の断面について 95% の信頼係数を保証したときの 2 種類の信頼域を図 6 に示す。




図 6 直線回帰

式 (110) に、なまデータではなしに、 $x$  と  $y$  それぞれでの順位を用いた場合、Spearman の順位相関係数 ( $\rho$ ) となる。順位づけをして、対応するペアの差  $d_i$  をとると  $\sum d_i = 0$  となる。各群内の同位のそれぞれにつき、

$$\tau = \sum (t^3 - t)$$

を求めてプールしたものを  $\tau_x, \tau_y$  とする。

$$\begin{aligned}D &= 6 \sum d_i^2, \quad A = n^3 - n \\ r_s &= \frac{A - 0.5(\tau_x + \tau_y) - D}{\sqrt{(A - \tau_x)(A - \tau_y)}} \quad (113) \\ &= 1 - \frac{D}{A} \quad (\text{同位なし})\end{aligned}$$

無相関の検定には式 (111) を用いる。

上のデータでは  $\sum d_i^2 = 17$ ,  $\tau_x = 3 \times 6 = 18$ ,  $\tau_y = 2 \times 6 + 24 = 36$ ,  $A = 1320$  で、Spearman の相関係数は、 $r_s = 0.9211$  となる。

## 22. 非線形モデル

ある関数が、

$$f(\mu x + \zeta z) = \mu f(x) + \zeta f(z) \quad (114)$$



と書けるとき線形というが、これまでに扱ったモデルは線形である。

$$y = \exp \{ \alpha x + \beta x^2 + \varepsilon \}$$

は、 $Y = \ln y$  とおけば、

$$Y = \alpha x + \beta x^2 + \varepsilon = \alpha X_1 + \beta X_2 + \varepsilon$$

となり、本質的には線形である。

$$y = \exp \{ \alpha x + \beta x^2 \} + \varepsilon$$

$$y = A e^{-\alpha x} + B e^{-\beta x} + \varepsilon$$

$$y = \frac{\alpha}{1 + (\beta/x)} + \varepsilon$$

などは、いずれも非線形である。

線形モデル式 (96) は、

$$y_i = f(\mathbf{x}_i; \boldsymbol{\beta}) + \varepsilon_i = f_i(\boldsymbol{\beta}) + \varepsilon_i$$

$$y = f(\boldsymbol{\beta}) + \varepsilon$$

と書くと、 $f(\boldsymbol{\beta})$  は  $f_i(\boldsymbol{\beta})$  を要素としたベクトルで、最小2乗解は、

$$Q\{\boldsymbol{\beta}\} = [y - f(\boldsymbol{\beta})]'[y - f(\boldsymbol{\beta})]$$

を最小にするパラメーター、

$$\hat{\boldsymbol{\beta}} = [X'X]^{-1}X'y$$

として与えられる。

ところが、 $f_i(\boldsymbol{\beta})$  が非線形のときには、このように調子よくはいかない。いま2つのパラメーターをもつ非線形式  $f_i(\beta_1, \beta_2)$  について、 $\beta_1, \beta_2$  を指定すれば、 $f_i(\boldsymbol{\beta})$  が定まり、

$$Q\{\boldsymbol{\beta}\} = \sum_{i=1}^n \{y_i - f_i(\boldsymbol{\beta})\}^2 \quad (115)$$

が計算できる。さまざまな  $\{\beta_1, \beta_2\}$  の組み合わせにつき式 (115) を計算し、最小値を含む領域について、図7のような“地形”ができる。

$\{\beta_1, \beta_2\}$  を、あらゆる組合わせで計算するのも大変であるから、まず、適当な  $\boldsymbol{\beta}_0$  を定めて、 $Q\{\boldsymbol{\beta}_0\}$  を求め、ここで  $\beta_2$  を留めて、 $\beta_1$  を変え  $Q\{\boldsymbol{\beta}\} < Q\{\boldsymbol{\beta}_0\}$  かつ最小となる  $\beta_1$  を探す。ついで、 $\beta_1$  をそこに留めて、 $\beta_2$  を変えて  $Q\{\boldsymbol{\beta}\}$  がさらに小さく、

もっとも小さくなる  $\beta_2$  を探す。こうして軸ごとに探索して、すり鉢状の盆地の底に達したなら、そこを  $\hat{\boldsymbol{\beta}}$  とする。

出発点  $\boldsymbol{\beta}_0$  が図7のように“運のいい”場所であれば右側にみるように、 $\beta_1$  を動かして真西に探索すれば、1回でほとんど盆地の中心に達することができるが、 $\boldsymbol{\beta}_0$  の選び方がまずいと、かなり手間はかかる。




図7  $Q\{\boldsymbol{\beta}\}$  の探索

もう少し一般的に、 $\boldsymbol{\beta}_0$  に立ったとき東西と南北の方向にとらわれず、もっとも急な勾配に沿って下ることが考えられる。 $Q\{\boldsymbol{\beta}\}$  を、 $\partial Q\{\boldsymbol{\beta}\} / \partial \beta_1$  と微分し、 $\beta_{1k}$  を代入することを  $\partial Q_k / \partial \beta_1$  と書けば、

$$\nabla Q_k = \begin{bmatrix} \frac{\partial Q}{\partial \beta_1} \\ \frac{\partial Q}{\partial \beta_2} \end{bmatrix}_{\boldsymbol{\beta}=\boldsymbol{\beta}_k} = \begin{bmatrix} \frac{\partial Q_k}{\partial \beta_1} \\ \frac{\partial Q_k}{\partial \beta_2} \end{bmatrix} = \mathbf{g}_k \quad (116)$$

となる。 $\nabla Q_k$  はグラジエントと呼ばれるもので、 $\boldsymbol{\beta}_k$  での傾斜であるが、 $\mathbf{d}_k = -\mathbf{g}_k$  の方向が最急降下方向になる。実際は差分を用い、

$$\frac{\partial Q_k}{\partial \beta_1} \doteq \frac{Q(\beta_{1k} + \Delta, \beta_{2k}) - Q(\beta_{1k}, \beta_{2k})}{\Delta} \quad (117)$$

とするが、 $\Delta$  は  $\beta_{1k}$  の  $10^{-3} \sim 10^{-6}$  といった値である。つまり、 $\{\beta_{1k} + \Delta, \beta_{2k}\}$  と  $\{\beta_{1k}, \beta_{2k}\}$  について  $Q\{\boldsymbol{\beta}\}$  を計算し、その差を  $\Delta$  で割って、これを  $\partial Q_k / \partial \beta_1$  として用いる。

最急降下で  $\boldsymbol{\beta}_k$  から  $\mathbf{d}_k$  方向に探索した最小値が  $Q\{\boldsymbol{\beta}_k + \lambda_k \mathbf{d}_k\}$  であれば、 $\boldsymbol{\beta}_{k+1} = \boldsymbol{\beta}_k + \lambda_k \mathbf{d}_k$  をつぎの出発点とし、そこでの最急降下を行なう。 $\mathbf{g}_k \doteq 0$  とかきざみ  $\lambda_k \doteq 0$  とかですでに盆地の底に

達したと考える。最急降下法は、局所的には良い方法であるが、 $Q\{\beta\}$  の地形が細長い谷状になると、なかなか底まで下れないこともあるので、さらに工夫をこらした方法もある。

他の方法一般についてえるが、出発点  $\beta_0$  の選び方が悪いと、隣の浅い窪地で終わったり、現実に  $\beta$  がとり得ない  $\hat{\beta}$  に達したりするほか、かなり大量の計算を必要とするなど非線形モデルでの最小 2 乗法には、厄介な問題が少なくない。いずれにしても、手計算は無理であろう。

### 23. 線形化の方法

非線形モデルで  $f_i(\beta)$  を真の解の付近の  $\beta_k$  について展開して高次項を省略し、

$$f_i(\beta) \doteq f_i(\beta_k) + \left[ \frac{\partial f_i}{\partial \beta_1} \cdots \frac{\partial f_i}{\partial \beta_p} \right] \beta = \beta_k [\beta - \beta_k]$$

とおけることが多い。パラメーターは  $p$  個ある。

$[pf_i(\beta_k)]'$  を行の成分とした  $(n \times p)$  の行列、

$$J(\beta_k) = J_k = \begin{bmatrix} \frac{\partial f_1}{\partial \beta_1} & \cdots & \frac{\partial f_1}{\partial \beta_p} \\ \vdots & & \vdots \\ \frac{\partial f_n}{\partial \beta_1} & \cdots & \frac{\partial f_n}{\partial \beta_p} \end{bmatrix} \beta = \beta_k \quad (118)$$

をヤコビの行列というが、これと  $f_i(\beta_k)$  を要素としたベクトル  $f_k$  を用いると、

$$y \doteq f_k + J_k[\beta - \beta_k] + \epsilon \quad (119)$$

と書ける。これから、

$$y - f_k + J_k \beta_k \doteq J_k \beta + \epsilon$$

と、式 (88) の形式におけば、最小 2 乗解は、

$$\hat{\beta} \doteq [J_k' J_k]^{-1} J_k' [y - f_k] + \beta_k$$

$$V\{\hat{\beta}\} \doteq \sigma^2 [J_k' J_k]^{-1}$$

となる。式 (119) で、 $d_k = [\beta - \beta_k]$  とおけば、

$$\hat{d}_k \doteq [J_k' J_k]^{-1} J_k' [y - f_k] \quad (120)$$

となる。 $\hat{d}_k$  を  $\beta_k$  での降下ベクトルとみて、最小の  $Q\{\hat{\beta}\}$  をあたえる解を、

$$\hat{\beta} \doteq \beta_{k+1} = \beta_k + \hat{d}_k \quad (121)$$

とすることで、反復法が組み立てられるが、これが **Gauss 法** (Gauss-Newton 法) である。重みを用いて、式 (97) の形式で扱ってもよい。

理論的に  $\hat{d}_k$  は下降方向ではあるが、さまざまな条件で式 (121) の反復が収束しなかったり、計算できなかったりすることがある。

$$\beta_{k+1} = \beta_k + \lambda_k \hat{d}_k$$

として、最小値を与える  $\lambda_k$  を求める方法や、式 (120) に加工して、

$$\hat{d}_k = [J_k' J_k + \mu I]^{-1} J_k' [y - f_k] \quad (122)$$

とし、 $[J_k' J_k]$  の対角要素に  $\mu > 0$  を加えて計算する方法がある (Levenberg-Marquardt の原理)、 $\mu$  を非常に大きくすると収束は遅くなるが、 $d_k$  は  $\beta_k$  での最急降下の方向に近づくという性質がある。どのくらいの  $\mu$  が良いかは、むしろ経験的に定められるが、 $\mu = 0$  の本来の Gauss 法で不都合なとき、大きな  $\mu$  をのせて反復し、しだいに  $\mu$  を減らし、十分に収束したら  $\mu = 0$  として成功することがある。

考え方を変えて、 $Q\{\beta\}$  の展開を行ない、 $(n \times p)$  のヘッセの行列

$$H(\beta_k) = H_k = \begin{bmatrix} \frac{\partial^2 f_1}{\partial \beta_1 \partial \beta_1} & \cdots & \frac{\partial^2 f_1}{\partial \beta_1 \partial \beta_p} \\ \vdots & & \vdots \\ \frac{\partial^2 f}{\partial \beta_p \partial \beta_1} & \cdots & \frac{\partial^2 f}{\partial \beta_p \partial \beta_p} \end{bmatrix} \beta = \beta_k \quad (123)$$

を用いて、

$$Q\{\beta\} \doteq Q\{\beta_k\} + d_k' \nabla Q_k + \frac{1}{2} d_k' H_k d_k$$

$$\frac{\partial Q}{\partial \beta} \doteq \nabla Q_k + H_k d_k$$

$$\hat{d}_k = -H_k^{-1} \nabla Q_k = H_k^{-1} (-g_k)$$

によって下降ベクトルが求められる。最急勾配は式 (116) で  $g_k$  としたが、最急降下法では  $d_k = -g_k$  を選んだ。この式 (124) では  $H_k^{-1}$  が、各軸での計量単位を修飾する姿でかわり、一種の最急降下方の加速になっている。これが **Newton 法**

(Newton-Raphson 法) と呼ばれる。収束が悪いときには、Gauss 法で用いたような変法が利用される。

### 【例 18】

ラットに Hippuran  $^{125}\text{I}$  を静注し、連続的に頭部でモニターし、5 分ごとの計測を行なった。

i	1	2	3	4	5	6
分	5	10	15	20	25	30
cpm	1,000	626	440	315	235	173

i	7	8	9	10	11	12
分	35	40	45	50	55	60
cpm	148	124	103	93	83	73

まず、 $y(\text{cmp})$  を  $\ln y$  としてプロットすると図 8(1) の○を得る。

$$y_i = \sum \text{Me}^{-\mu_i t} + \varepsilon_i$$

の区画モデルを考え、第 6 (30 分)～第 12 (60 分) の  $\ln y$  に直線式

$$\ln y_B = \ln B - \beta t \doteq \ln 400 - 0.03 t$$

をあてはめ、いわゆる  $\beta$  相を、

$$y_B = \text{Be}^{-\beta t} \doteq 400\text{e}^{-0.03t}$$

とする。ついで、第 1 (5 分)～第 5 (25 分) の、もとの  $y$  から  $y_B$  の計算値を引き、

$$y_A = y - y_B = \text{Ae}^{-\alpha t}$$

とし、あらためて  $\ln y_A$  をプロットし、●を得るが、ほぼ直線的で、

$$\ln y_A = \ln A - \alpha t \doteq \ln 1322 - 0.14 t$$

となる。もしも  $\ln y_A$  が直線でなければ、第 5 (25 分) のデータ側から直線をあてはめ、上記の要領で“皮むき”を続け、区画数を増す。このデータでは 2 区画モデル、

$$y = y_A + y_B + \varepsilon = \text{Ae}^{-\alpha t} + \text{Be}^{-\beta t} + \varepsilon \quad (125)$$

でよさそうである。

初期値を  $\beta_0 = [1322 \ 0.14 \ 400 \ 0.03]'$  とおいて Gauss 法を用いると、 $Q\{\beta_0\} = 996.2734$  で、3 回の反復でかなり安定し、 $\hat{\beta} = \beta_4$  で終了し、 $Q\{\hat{\beta}\} = 432.5302$  となる。

あてはめのずれを誤差相当と考え、

$$V_R = \frac{Q\{\hat{\beta}\}}{12-4} = 54.0666$$

$[\mathbf{J}_4' \mathbf{J}_4]^{-1}$  の対角要素をひろい、これに  $V_R$  を乗じ




図 8



て各パラメーターの分散とし、その平方根をとれば  $SE\{\hat{\beta}\}$ ,  $\beta=\hat{A}, \hat{\alpha}, \hat{B}, \hat{\beta}$ , となる.

つぎに  $w_i=1/y_i$ , および  $1/y_i^2$  として同じ計算を行なうと、かなり様子がちがってくる.

	A	$\alpha$	B	$\beta$	$w_i$
$\hat{\beta}$	1315.2	0.1198	310.4	0.02503	1
$SE\{\hat{\beta}\}$	48.22	0.008759	67.9	0.004408	
$\hat{\beta}$	1342.8	0.1099	239.5	0.02025	$\frac{1}{y_i}$
$SE\{\hat{\beta}\}$	34.58	0.006508	44.84	0.003380	$\frac{1}{y_i}$
$\hat{\beta}$	1341.6	0.1059	215.0	0.01842	$\frac{1}{y_i^2}$
$SE\{\hat{\beta}\}$	42.9	0.006195	34.91	0.002735	$\frac{1}{y_i^2}$

$y$  の分布にもよるが、 $SE\{\beta\}$  からみると、 $1/y_i$ ,  $1/y_i^2$  の重みがよさそうである. どのような重みがよいかは、こうした吟味と、経験によって決められるであろう.  $y_i$  の誤差分散がわかっており、 $\sigma_i^2$  であれば、 $w_i=1/\sigma_i^2$  ないし、 $k/\sigma_i^2$  と、分散の逆数に比例した重みを用いると、誤差は等分散になる. また  $1/\hat{y}_i$ ,  $1/\hat{y}_i^2$  なども用いられる.

#### 24. パラメーターの比較

線形モデルあるいは線形化したモデルでの Gauss 法によるパラメーター、たとえば、 $\hat{\beta}_1, \hat{\beta}_2$ , を得たとき、それぞれの分散を  $V_1, V_2$ , 誤差自由度を  $\nu_1, \nu_2$  とする.

$H_0: \beta_1=\beta_2$ ,  $H_1: \beta_1 \neq \beta_2$  の検定にあたり、 $\hat{\beta}_1, \hat{\beta}_2$  が同一データから求められたときには、 $\nu=\nu_1=\nu_2$  で、 $|\hat{\beta}_1-\hat{\beta}_2|$  のノイズは、

$$SE\{\hat{\beta}_1-\hat{\beta}_2\} = \sqrt{V_1+V_2-2C}$$

であるが、 $C$  は  $C\{\beta_1, \beta_2\}$  で、 $[X'X]^{-1}$  ないしは  $[J_k'J_k]^{-1}$  などの、第 1 行第 2 列、または第 2 行第 1 列の要素に  $V_R$  を乗じたものになる. 誤差が少なくとも緩い正規性をもつなら、

$$t_0 = \frac{|\hat{\beta}_1-\hat{\beta}_2|}{\sqrt{V_1+V_2-2C}} \geq t_{\alpha}[\nu] \quad (126)$$

のとき有意とし、必要なら反転して区間推定を行なう.

$\hat{\beta}_1, \hat{\beta}_2$  が別個のデータで求められたときは不等分散とした方が安全で、

$$t_0 = \frac{|\hat{\beta}_1-\hat{\beta}_2|}{\sqrt{V_1+V_2}} \quad (127)$$

を求め、節 17 の式 (76) 以下の手続きをふめばよいだろう.  $\nu_1 \leq \nu_2$  として、

(1)  $t_0 < t_{\alpha}[\nu_1+\nu_2]$  では有意ではない.

(2)  $t_0 > t_{\alpha}[\nu_1]$  では有意である.

(3) 以上で未決定なら  $t_0$  を

$$t_{\alpha}^* = \frac{V_1 t_{\alpha}[\nu_1] + V_2 t_{\alpha}[\nu_2]}{V_1 + V_2}$$

と比べる.

#### 【例 19】

例 18 の  $w_i=1$  での計算で得た  $\hat{\alpha}, \hat{\beta}$  につき

	値	分散	共分散
$\hat{\alpha}$	0.1198	0.047672	0.043503
$\hat{\beta}$	0.02503	0.041943	

ただし、0.041 は 0.00001 を示す. 式 (126) から

$$t_0 = \frac{|0.1198-0.02503|}{\sqrt{0.042609}} = 18.554$$

で、 $t_{0.05}[8]=2.306$  より大きく、明らかに  $\alpha \neq \beta$  である.

間接的な連続モニターと同時に、8 時点で採血し、血漿中の Hippurate  $^{125}I$  を測定したデータがある.

i	1	2	3	4	5	6	7	8
分	5	10	20	30	40	45	50	60
cpm	1,867	1,380	907	577	378	334	289	234

これについての 2 区画モデルは  $w_i=1$  ではどうやら結果は出るが、 $w_i=1/y_i$  では、式 (122) の変法で追いつめても、 $\mu=0$  で発散してしまう.  $w_i=1$  では、

$$y = 1365.9e^{-0.08938t} + 1130.6e^{-0.02827t}$$

となる.  $\hat{A}, \hat{\alpha}, \hat{B}, \hat{\beta}$  の SE は、 $\nu=8-4=4$  で、

$$804.26, 0.04686, 902.07, 0.01309$$

と、間接法に比べて、精度が格段に悪い。また  $V\{\hat{\alpha}\}=0.0^2196$ ,  $V\{\hat{\beta}\}=0.0^21715$  である。

Hippuran  $^{125}\text{I}$  は血球にも入るし, cpm/head, cpm/20  $\mu\text{l}$  plasma と単位も異なるので, A や B は直接法と間接法で異なる。しかし, 両者で  $\alpha, \beta$  が等しいならば, 都合がよい。

直接法のデータには少々精度に問題があるが, まず  $\alpha$  について, 前述の間接法でのデータを用いて,

$$t_0 = \frac{|0.1198 - 0.08938|}{\sqrt{0.0^2196 + 0.0^22196}} = 0.638$$

また  $\beta$  について,

$$t_0 = \frac{|0.02503 - 0.02827|}{\sqrt{0.0^21943 + 0.0^21715}} = 0.234$$

いずれも  $t_{0.05}[\nu_1=4]=2.776$  より小さく, さしあたりは,  $\alpha, \beta$  のパラメーターは間接法, 直接法で大きくは変わらないと考えておく。以上の2例のデータは, Am. J. Physiol. **212**, 629, 1967 の論文の図から読みとったものである。