

離散分布の場合のノンパラメトリックな ある 2-標本問題

統計数理研究所 藤 本 熙

(1980 年 4 月 受付)

On Some Non-parametric Two-sample Problems in the Case of Discrete Distributions

Hirosi Hudimoto

(The Institute of Statistical Mathematics)

The use of statistics of Mann-Whitney type in the case of discrete distributions will be considered for two-sample problems.

In Sections 4 and 5, it is assumed that each individual in the given population π belongs to either one of two sub-populations π_1 and π_2 and that π_1 and π_2 are mixed in proportions w_1 and w_2 of individuals of π . But, w_1 and w_2 are unknown. Let $f_i(x)$ be the probability function in π_i ($i=1, 2$). Denoting by $L_{(\xi)}$ the ξ th value of the likelihood ratio $L(x) = f_2(x)/f_1(x)$ arranged in ascending order, let $g_i(\xi)$ be $f_i(x)$ arranged in the order based on $L_{(\xi)}$. Then, $G_i(y) = \sum_{\xi \leq y} g_i(\xi)$.

Now, suppose that a random sample of the size n is obtained from π . Let (Y_1, Y_2, \dots, Y_n) be a sample from π transformed into the rank order defined above. Consider the statistic

$\hat{h} = (\hat{p}_1 + \hat{p}_2)/2$, where $\hat{p}_i = \frac{1}{n} \sum_{k=1}^n \left\{ G_i(Y_k) - \frac{1}{2} g_i(Y_k) \right\}$, $i = 1, 2$. Then, we have

$$\hat{w}_1 = \frac{1}{2} - \left(\hat{h} - \frac{1}{2} \right) \Delta_{12}^{-1}, \quad \hat{w}_2 = \frac{1}{2} + \left(\hat{h} - \frac{1}{2} \right) \Delta_{12}^{-1}$$

for unbiased estimates of w_1 and w_2 , where $\Delta_{12} = \frac{1}{2} \sum_v (G_1(y_v)g_2(y_v) - G_2(y_v)g_1(y_v))$.

When our decision is to classify an individual with the observed value x obtained from π to either one of π_1 and π_2 , denote the probability of deciding an individual as coming from π_1 by $\delta^{(1)}(x)$. Then, a randomized decision rule can be denoted by $\delta(x) = (\delta^{(1)}(x), 1 - \delta^{(1)}(x))$. Our decision rule is that $\delta_{\hat{w}}^{(1)}(x) = 1$ if $D_{\hat{w}}(x) \geq 0$ or $= 0$ if $D_{\hat{w}}(x) < 0$, where $D_{\hat{w}}(x) = \hat{w}_1 f_1(x) - \hat{w}_2 f_2(x)$. Denote the expected risk of $\delta_{\hat{w}}(x) = (\delta_{\hat{w}}^{(1)}(x), 1 - \delta_{\hat{w}}^{(1)}(x))$ with respect to $w = (w_1, w_2)'$ by $B(w, \delta_{\hat{w}})$. Denote the Bayes risk by $B(w) = B(w, \delta_w)$. When it is assumed that the loss is 0 for correct decision and 1 for incorrect decision, $P \left\{ B(w, \delta_{\hat{w}}) - B(w) < 2 \sqrt{\frac{1}{2n \Delta_{12}^2} \log \frac{2}{\alpha}} \right\} > 1 - \alpha$ is obtained for pre-assigned $\alpha > 0$.

In Section 6, we deal with a two-sample problem. Two samples $(X_1^{(1)}, X_2^{(1)}, \dots, X_{n_1}^{(1)})$ and $(X_1^{(2)}, X_2^{(2)}, \dots, X_{n_2}^{(2)})$ are obtained from $f_1(x)$ and $f_2(x)$, respectively. Then, an unbiased estimate \hat{p}_{12} for $p_{12} = \frac{1}{2} + \frac{1}{2} \sum_v \{ F_1(x_v) f_2(x_v) - F_2(x_v) f_1(x_v) \}$ defined in Section 3 is considered. The variance of \hat{p}_{12} is

$$\sigma^2(\hat{p}_{12}) = \frac{1}{n_1 n_2} \left\{ p_{12} - \frac{1}{4} \sum_v f_1(x_v) f_2(x_v) + (n_1 - 1)A + (n_2 - 1)B - (n_1 + n_2 - 1) p_{12}^2 \right\},$$

where

$$A = \sum_v \left(F_1(x_v) - \frac{1}{2} f_1(x_v) \right)^2 f_2(x_v),$$

and

$$B = \sum_v \left(1 - F_2(x_v) + \frac{1}{2} f_2(x_v) \right)^2 f_1(x_v).$$

In the case that $F_1(x) = F_2(x)$ for all x , it seems that $\sigma^2(\hat{p}_{12}) \leq (n_1 + n_2 - 1) / 12n_1n_2$.

1. 結 言

離散変量の場合について、Mann-Whitney 型統計量を使った 2-標本検定と、2 群への判別に対する経験的ベイズ決定の方法が扱われる。つまり、タイ (tie) のある場合の扱い方が問題になる。

第3節で与えられる p_{12} に対する、2-標本の場合における、不偏推定量が第6節の \hat{p}_{12} である。その節では、 \hat{p}_{12} の分散を求めている。

第4節の一般的な場合が、第2節に与えられるが、第4節では、混合の割合 w_1, w_2 の推定量の分散を、なるべく小さくするために、尤度比の使用を考える。第2節は [1], [2], [3] で述べた事柄の一部の要約である。

尤度比による順位に変換して考えた p_{12} の、1-標本の場合の、不偏推定量が $\hat{p}_i (i=1, 2)$ のどちらかであるが、第4節では、 (X_1, X_2, \dots, X_n) を複合分布 $w_1 f_1(x) + w_2 f_2(x)$ からのランダム標本と考えるから、 \hat{p}_1, \hat{p}_2 から混合の割合 w_1, w_2 の推定が考えられる。

2. 一般的な議論

r 個の部分母集団 $\pi_1, \pi_2, \dots, \pi_r$ からなる複合母集団 π を考える。つまり、 π に属する個体は、 r 種類の範疇に類別される。更に π_i に属する π の個体の割合を $w_i (i=1, 2, \dots, r)$ とする。ただし w_i は未知である。またその観測結果が π_i に属する個体のものであるような変量 X の分布関数を、 $F_i(x)$ で示す。このとき、 π から大きさ n のランダム標本 (X_1, X_2, \dots, X_n) を得て、 w_i を推定することを考える。

π_i からの個体であるという条件のもとでの確率を、 $P(\cdot | \pi_i)$ で示すと、

$$(2.1) \quad F_i(x) = P(X \leq x | \pi_i), \quad i = 1, 2, \dots, r$$

であって、 (X_1, X_2, \dots, X_n) は、

$$(2.2) \quad F(x) = \sum_{i=1}^r w_i F_i(x)$$

からのランダム標本である。

$$(2.3) \quad \hat{p}_i = \frac{1}{n} \sum_{k=1}^n F_i(X_k)$$

を考え、 $F_i(x)$ は連続とする。

$$(2.4) \quad A_{ij} = \int F_i(x) dF_j(x) - \frac{1}{2} \quad i, j = 1, 2, \dots, r$$

として、

$$(2.5) \quad \mathbf{w} = \begin{pmatrix} w_1 \\ w_2 \\ \vdots \\ w_r \end{pmatrix}, \quad \hat{\mathbf{p}} = \begin{pmatrix} \hat{p}_1 \\ \hat{p}_2 \\ \vdots \\ \hat{p}_r \end{pmatrix}$$

$$(2.5) \quad \mathbf{A}^{(1)} = \begin{pmatrix} \frac{1}{2} & \frac{1}{2} + A_{12} \cdots \frac{1}{2} + A_{1r} \\ \frac{1}{2} + A_{21} & \frac{1}{2} & & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \frac{1}{2} + A_{r1} & \frac{1}{2} + A_{r2} \cdots \frac{1}{2} \end{pmatrix}$$

とおくと、 $|\mathbf{A}^{(1)}| \neq 0$ ならば、

$$(2.6) \quad \hat{\mathbf{w}}^{(1)} = (\mathbf{A}^{(1)})^{-1} \hat{\mathbf{p}}$$

は \mathbf{w} の不偏且一致推定量である。ただし $|\mathbf{A}^{(1)}|$ 及び $(\mathbf{A}^{(1)})^{-1}$ は $\mathbf{A}^{(1)}$ の行列式及び逆行列である。

$$(2.7) \quad \mathbf{A}^{(2)} = \begin{pmatrix} 0 & A_{12} & \cdots & A_{1r} \\ A_{21} & 0 & \cdots & A_{2r} \\ \vdots & \vdots & \ddots & \vdots \\ A_{r1} & A_{r2} & \cdots & 0 \end{pmatrix}, \quad \mathbf{E} = \begin{pmatrix} 1 & 1 & \cdots & 1 \\ 1 & 1 & \cdots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \cdots & 1 \end{pmatrix}$$

と、 $r \times r$ 行列 $\mathbf{A}^{(2)}$, \mathbf{E} を考えると、

$$(2.8) \quad \mathbf{A}^{(1)} = \mathbf{A}^{(2)} + \frac{1}{2} \mathbf{E}.$$

$\mathbf{A}^{(2)}$ は歪対称行列であるから、 r が奇数であれば、 $|\mathbf{A}^{(2)}| = 0$ 、 r が偶数ならば、 $|\mathbf{A}^{(1)}| = |\mathbf{A}^{(2)}|$ である。そこで、 r が偶数のときに、 $|\mathbf{A}^{(2)}| \neq 0$ であれば、 \mathbf{w} の不偏且一致推定量として、

$$(2.9) \quad \hat{\mathbf{w}}^{(2)} = (\mathbf{A}^{(2)})^{-1} \left(\hat{\mathbf{p}} - \frac{1}{2} \mathbf{J} \right)$$

が得られる。ここに、 $\mathbf{J}' = (1, 1, \dots, 1)$ 、 $'$ はベクトルの転置を示す。

次に X が離散変量の場合を考える。 X の確率関数を、

$$(2.10) \quad f_i(x_v) = P(X = x_v | \pi_i), \quad v = 1, 2, \dots, s$$

とする。このとき、(2.3)を、

$$(2.11) \quad \hat{p}_i = \frac{1}{n} \sum_{k=1}^n \left\{ F_i(X_k) - \frac{1}{2} f_i(X_k) \right\}$$

に、(2.4)を

$$(2.12) \quad A_{ij} = \frac{1}{2} \sum_{v=1}^s \{ F_i(x_v) f_j(x_v) - F_j(x_v) f_i(x_v) \}$$

に変えれば、 X が離散変量の場合にも、今迄の結果は、そのまま成立つ。

以降では、 $r=2$ の場合を、 X が離散変量の場合について考える。

3. $\hat{p}_{12} = \frac{1}{2} + A_{12}$ について

$X^{(i)}$ ($i=1, 2$) は、確率関数 $f_i(x)$ をもつ次のような離散変量とする：

$$(3.1) \quad P(X^{(i)} = x_v) = f_i(x_v), \quad v = 1, 2, \dots, s.$$

またその分布関数を

$$(3.2) \quad F_i(x) = \sum_{x_v \leq x} f_i(x_v), \quad i = 1, 2$$

で示す.

このとき、独立な $X^{(1)}, X^{(2)}$ に対し、 $X^{(1)} < X^{(2)}$ の確率 $P(X^{(1)} < X^{(2)})$ は、

$$\begin{aligned} P(X^{(1)} < X^{(2)}) &= \sum_{v=1}^s (F_1(x_v) - f_1(x_v)) f_2(x_v) \\ &= \sum_{v=1}^s (1 - F_2(x_v)) f_1(x_v). \end{aligned}$$

これから、

$$(3.3) \quad P(X^{(1)} < X^{(2)}) = \frac{1}{2} + A_{12} - \frac{1}{2} \sum_{v=1}^s f_1(x_v) f_2(x_v),$$

$$(3.4) \quad A_{12} = \frac{1}{2} \sum_{v=1}^s (F_1(x_v) f_2(x_v) - F_2(x_v) f_1(x_v)).$$

ところで、 $F_1 \equiv F_2$ のとき、 $F_i(x)$ ($i=1, 2$) が連続ならば、 $P(X^{(1)} < X^{(2)}) = \frac{1}{2}$ であるが、ここでは、 $\sum f_1(x_v) f_2(x_v) = \sum f_i^2(x_v) > 0$ であるから、 $P(X^{(1)} < X^{(2)}) < \frac{1}{2}$ であって、その大きさは、 $\sum f_i^2(x_v)$ の値によるので、 $F_1 \equiv F_2$ を帰無仮説とする 2-標本検定の場合など不便がある。しかし、 A_{12} は、

$$-\frac{1}{2} \leq A_{12} \leq \frac{1}{2}$$

であるから、 $P(X^{(1)} < X^{(2)})$ の替りに

$$(3.5) \quad p_{12} = \frac{1}{2} + A_{12}$$

を使うことにすると、

$$0 \leq p_{12} \leq 1$$

であって、 $p_{12}=0$ または $p_{12}=1$ となるような極端な場合を考えるのは容易であって、 p_{12} を $P(X^{(1)} < X^{(2)})$ の替りに使うのが適当であることがわかる。

4. 混合の割合の推定 ($r=2$ の場合)

(X_1, X_2, \dots, X_n) を $w_1 f_1(x) + w_2 f_2(x)$ からのランダム標本とする。つまり、 w_1, w_2 の割合で $f_1(x), f_2(x)$ からの標本が混合しているのである。 $0 \leq w_i \leq 1, w_1 + w_2 = 1$ である。

ここでは、 w_1, w_2 は未知であるが、 $f_1(x), f_2(x)$ は既知として、 w_1, w_2 の推定を考える。

まず尤度比 $L(x) = f_2(x) / f_1(x)$ を考え、この値の順序に配列した $L(x)$ の k -番目を $L_{(k)}$ とする。

$$0 \leq L_{(1)} \leq \dots \leq L_{(k)} \leq \dots \leq L_{(s)} \leq \infty$$

である。

今 $f_1(x), f_2(x)$ を上の順序に配列し直して, $g_1(\xi), g_2(\xi)$ で示し,

$$(4.1) \quad G_i(y) = \sum_{\xi \leq y} g_i(\xi)$$

とする. 更に (X_1, X_2, \dots, X_n) を $L(\xi)$ にもとづく順位に変換して, (Y_1, Y_2, \dots, Y_n) とする. ここで,

$$(4.2) \quad \begin{aligned} \hat{p}_i &= \frac{1}{n} \sum_{k=1}^n \left\{ G_i(Y_k) - \frac{1}{2} g_i(Y_k) \right\}, \quad i = 1, 2 \\ A_{12} &= \frac{1}{2} \sum_{\nu} \{ G_1(y_\nu) g_2(y_\nu) - G_2(y_\nu) g_1(y_\nu) \} \end{aligned}$$

とすれば, (2.9) に対応する w_1, w_2 の推定量は,

$$(4.3) \quad \hat{w}_1^{(2)} = \frac{1}{A_{12}} \left(\frac{1}{2} - \hat{p}_2 \right), \quad \hat{w}_2^{(2)} = \frac{1}{A_{12}} \left(\hat{p}_1 - \frac{1}{2} \right).$$

尤度比を使って $G_i(y)$ をつくったのは, この $\hat{w}_1^{(2)}, \hat{w}_2^{(2)}$ の分散をなるべく小さくするためである. $\hat{w}_1^{(2)}$ と $\hat{w}_2^{(2)}$ の和は 1 になるとはかぎらない. また,

$$(4.4) \quad \bar{w}_1^{(2)} = \frac{\frac{1}{2} - \hat{p}_2}{\hat{p}_1 - \hat{p}_2}, \quad \bar{w}_2^{(2)} = \frac{\hat{p}_1 - \frac{1}{2}}{\hat{p}_1 - \hat{p}_2}$$

は, $\bar{w}_1^{(2)} + \bar{w}_2^{(2)} = 1$ ではあるが, 不偏ではない.

その和が 1 で不偏なものは,

$$\hat{h} = \frac{1}{2} (\hat{p}_1 + \hat{p}_2)$$

を考えると, 共通の確率関数

$$(4.5) \quad g(\xi) = w_1 g_1(\xi) + w_2 g_2(\xi)$$

をもつ Y_1, Y_2, \dots, Y_n の同時分布に関する \hat{h} の期待値は,

$$\begin{aligned} \mathcal{E}_{g^n} \{ \hat{h} \} &= \frac{1}{2} + (w_2 - w_1) \frac{A_{12}}{2} \\ &= \frac{1}{2} + \frac{A_{12}}{2} - w_1 A_{12} \\ &= \frac{1}{2} - \frac{A_{12}}{2} + w_2 A_{12} \end{aligned}$$

である. 従ってこれから, w_1, w_2 の不偏推定量は,

$$(4.6) \quad \begin{aligned} \hat{w}_1 &= \frac{1}{2} - \left(\hat{h} - \frac{1}{2} \right) \frac{1}{A_{12}}, \\ \hat{w}_2 &= \frac{1}{2} + \left(\hat{h} - \frac{1}{2} \right) \frac{1}{A_{12}}. \end{aligned}$$

勿論 $\hat{w}_1 + \hat{w}_2 = 1$. 又尤度比 $f_2(x)/f_1(x)$ にもとづき, $G(y)$ をつくったここでは,

$$(4.7) \quad 0 \leq A_{12} \leq \frac{1}{2}$$

であることが示される.

更にまた、 $|\hat{w}_i - w_i|$ について、次の確率不等式が成立する、[1]: 予め与えた $\alpha > 0$ に対して

$$(4.8) \quad \begin{aligned} & P \left\{ \left| \hat{h} - \frac{1}{2} - (w_2 - w_1) \frac{A_{12}}{2} \right| < \sqrt{\frac{1}{2n} \log \frac{2}{\alpha}} \right\} \\ & = P \left\{ |\hat{w}_i - w_i| < \sqrt{\frac{1}{2n A_{12}^2} \log \frac{2}{\alpha}} \right\} > 1 - \alpha. \end{aligned}$$

\hat{w}_i は w_i の不偏推定量であるから、 \hat{w}_i の値が負であることがある。しかしながら、 $w_1 = 0$ ならば、

$$P \left\{ \frac{1}{2} + \frac{A_{12}}{2} - \sqrt{\frac{1}{2n} \log \frac{1}{\alpha}} \geq \hat{h} \right\} \leq \alpha,$$

また $w_2 = 0$ ならば、

$$P \left\{ \frac{1}{2} - \frac{A_{12}}{2} + \sqrt{\frac{1}{2n} \log \frac{1}{\alpha}} \leq \hat{h} \right\} \leq \alpha$$

であるので、予め与えた小さな値 $\alpha > 0$ に対して、

$$\hat{h} \leq \frac{1}{2} + \frac{A_{12}}{2} - \sqrt{\frac{1}{2n} \log \frac{1}{\alpha}}$$

であれば、 $w_1 = 0$ と考えて処理し、

$$\hat{h} \geq \frac{1}{2} - \frac{A_{12}}{2} + \sqrt{\frac{1}{2n} \log \frac{1}{\alpha}}$$

ならば、 $w_2 = 0$ と考えて処理することが考えられる。

5. 判別に対する経験的ベイズ法則 ($r=2$ の場合)

2つの部分母集団 π_1, π_2 からなる π を考える。このとき、 π からの個体を、 X の観測値によって、なるべく正しく、 π_1 か π_2 へ判別することを考える。そこで、 X の値 x から、個体を π_1 からのものと決定する確率を $\delta^{(1)}(x)$ とすると、確率化決定関数は、 $\delta(x) = (\delta^{(1)}(x), 1 - \delta^{(1)}(x))$ で示される。

今 π からの大きさ n のランダム標本により、(4.6) から得られる \hat{w}_1, \hat{w}_2 を使って、次のような決定法則をつくる:

$$(5.1) \quad \delta_{\hat{w}}^{(1)}(x) = \begin{cases} 1 & (D_{\hat{w}}(x) \geq 0 \text{ のとき}), \\ 0 & (D_{\hat{w}}(x) < 0 \text{ のとき}), \end{cases}$$

ただし、

$$(5.2) \quad D_{\hat{w}}(x) = \hat{w}_1 f_1(x) - \hat{w}_2 f_2(x)$$

である。

このとき、 $\delta_{\hat{w}}(x) = (\delta_{\hat{w}}^{(1)}(x), 1 - \delta_{\hat{w}}^{(1)}(x))$ の $\mathbf{w} = (w_1, w_2)'$ に関する期待危険度を $B(\mathbf{w}, \delta_{\hat{w}})$ で示し、そのときのベイズ危険度を $B(\mathbf{w}) = B(\mathbf{w}, \delta_{\hat{w}})$ で示す。ここで簡単に、正しい決定(判別)に値0を、誤った決定に値1を与えるような損失関数を与えることにすると、

$$(5.3) \quad 0 \leq B(\mathbf{w}, \delta_{\hat{w}}) - B(\mathbf{w}) \leq \sum_{i=1}^2 |\hat{w}_i - w_i|.$$

である。それ故、(4.8) から、

$$(5.4) \quad P \left\{ B(\mathbf{w}, \delta_{\hat{\mathbf{w}}}) - B(\mathbf{w}) < 2 \sqrt{\frac{1}{2n A_{12}^2} \log \frac{2}{\alpha}} \right\} > 1 - \alpha$$

が予め与えた $\alpha > 0$ に対していえる.

6. p_{12} の不偏推定量の分散

第 3 節で扱った p_{12} の不偏推定量 \hat{p}_{12} と, その分散を考える.

$$(X_1^{(1)}, X_2^{(1)}, \dots, X_{n_1}^{(1)}), \quad (X_1^{(2)}, X_2^{(2)}, \dots, X_{n_2}^{(2)})$$

は, それぞれ, $f_1(x)$ 及び $f_2(x)$ からのランダム標本とする. ただし $f_i(x)$ ($i=1, 2$) は, (3.1) で与えられる.

$$(6.1) \quad Z_{ij} = \begin{cases} 1 & (X_i^{(1)} < X_j^{(2)} \text{ のとき}) \\ 0 & (\text{その他のとき}) \end{cases}$$

及び

$$(6.2) \quad z_{ij} = \begin{cases} 1 & (X_i^{(1)} = X_j^{(2)} \text{ のとき}) \\ 0 & (\text{その他のとき}) \end{cases}$$

とすると,

$$(6.3) \quad \hat{p}_{12} = \frac{1}{n_1 n_2} U_{12} = \frac{1}{n_1 n_2} \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} \left\{ Z_{ij} + \frac{1}{2} z_{ij} \right\}$$

をつくれば, \hat{p}_{12} の期待値は,

$$\mathcal{E} \hat{p}_{12} = P(X^{(1)} < X^{(2)}) + \frac{1}{2} \sum_{v=1}^s f_1(x_v) f_2(x_v) = p_{12}.$$

\hat{p}_{12} の分散を求めるために, まず, U_{12}^2 の期待値を計算する.

$$(6.4) \quad \begin{aligned} \mathcal{E} U_{12}^2 &= \mathcal{E} \left\{ \sum_i^{n_1} \sum_j^{n_2} \left(Z_{ij} + \frac{1}{2} z_{ij} \right) \right\}^2 \\ &= \sum_i^{n_1} \sum_j^{n_2} \mathcal{E} \left(Z_{ij} + \frac{1}{2} z_{ij} \right)^2 + \sum_{i \neq \lambda}^{n_1} \sum_j^{n_2} \mathcal{E} \left(Z_{ij} + \frac{1}{2} z_{ij} \right) \left(Z_{\lambda j} + \frac{1}{2} z_{\lambda j} \right) \\ &\quad + \sum_i^{n_1} \sum_{j \neq \mu}^{n_2} \mathcal{E} \left(Z_{ij} + \frac{1}{2} z_{ij} \right) \left(Z_{i\mu} + \frac{1}{2} z_{i\mu} \right) \\ &\quad + \sum_{i \neq \lambda}^{n_1} \sum_{j \neq \mu}^{n_2} \mathcal{E} \left(Z_{ij} + \frac{1}{2} z_{ij} \right) \left(Z_{\lambda\mu} + \frac{1}{2} z_{\lambda\mu} \right). \end{aligned}$$

$$\begin{aligned} \mathcal{E} \left(Z_{ij} + \frac{1}{2} z_{ij} \right)^2 &= \mathcal{E} \left(Z_{ij}^2 + Z_{ij} z_{ij} + \frac{1}{4} z_{ij}^2 \right) \\ &= P(X_i^{(1)} < X_j^{(2)}) + \frac{1}{4} P(X_i^{(1)} = X_j^{(2)}) \\ &= p_{12} - \frac{1}{4} \sum_v f_1(x_v) f_2(x_v). \end{aligned}$$

$$\begin{aligned}
& \mathcal{E} \left(Z_{ij} + \frac{1}{2} z_{ij} \right) \left(Z_{\lambda j} + \frac{1}{2} z_{\lambda j} \right) \\
&= \mathcal{E} \left(Z_{ij} Z_{\lambda j} + \frac{1}{2} z_{ij} Z_{\lambda j} + \frac{1}{2} Z_{ij} z_{\lambda j} + \frac{1}{4} z_{ij} z_{\lambda j} \right) \\
&= \mathbf{P}(X_i^{(1)} < X_j^{(2)}, X_\lambda^{(1)} < X_j^{(2)}) + \mathbf{P}(X_i^{(1)} < X_j^{(2)}, X_\lambda^{(1)} = X_j^{(2)}) \\
&\quad + \frac{1}{4} \mathbf{P}(X_i^{(1)} = X_j^{(2)}, X_\lambda^{(1)} = X_j^{(2)}) \\
&= \sum_{\nu} (F_1(x_\nu) - f_1(x_\nu))^2 f_2(x_\nu) + \sum_{\nu} (F_1(x_\nu) - f_1(x_\nu)) f_1(x_\nu) f_2(x_\nu) \\
&\quad + \frac{1}{4} \sum_{\nu} f_1^2(x_\nu) f_2(x_\nu) \\
&= \sum_{\nu} \left(F_1(x_\nu) - \frac{1}{2} f_1(x_\nu) \right)^2 f_2(x_\nu). \\
& \mathcal{E} \left(Z_{ij} + \frac{1}{2} z_{ij} \right) \left(Z_{i\mu} + \frac{1}{2} z_{i\mu} \right) \\
&= \sum_{\nu} \left(1 - F_2(x_\nu) + \frac{1}{2} f_2(x_\nu) \right)^2 f_1(x_\nu).
\end{aligned}$$

それ故,

$$\begin{aligned}
A &= \sum_{\nu} \left(F_1(x_\nu) - \frac{1}{2} f_1(x_\nu) \right)^2 f_2(x_\nu), \\
B &= \sum_{\nu} \left(1 - F_2(x_\nu) + \frac{1}{2} f_2(x_\nu) \right)^2 f_1(x_\nu)
\end{aligned}$$

とおくと,

$$\begin{aligned}
\mathcal{E} U_{12}^2 &= n_1 n_2 \left(\hat{p}_{12} - \frac{1}{4} \sum_{\nu} f_1(x_\nu) f_2(x_\nu) \right) \\
&\quad + n_1(n_1-1)n_2 A + n_1 n_2 (n_2-1) B \\
&\quad + n_1(n_1-1)n_2(n_2-1) \hat{p}_{12}^2.
\end{aligned}$$

よって,

$$\begin{aligned}
& \mathcal{E} U_{12}^2 - (\mathcal{E} U_{12})^2 \\
&= n_1 n_2 \left\{ \hat{p}_{12} - \frac{1}{4} \sum_{\nu} f_1(x_\nu) f_2(x_\nu) + (n_1-1)A + (n_2-1)B \right. \\
&\quad \left. - (n_1+n_2-1) \hat{p}_{12}^2 \right\}.
\end{aligned}$$

かくして, $\hat{p}_{12} = \frac{U_{12}}{n_1 n_2}$ の分散は,

$$\begin{aligned}
(6.5) \quad \sigma^2(\hat{p}_{12}) &= \frac{1}{n_1 n_2} \left\{ \hat{p}_{12} - \frac{1}{4} \sum_{\nu} f_1(x_\nu) f_2(x_\nu) + (n_1-1)A \right. \\
&\quad \left. + (n_2-1)B - (n_1+n_2-1) \hat{p}_{12}^2 \right\}.
\end{aligned}$$

$F_i(x)$ ($i=1, 2$) が連続のときには,

$$A_1 = \int_{-\infty}^{\infty} F_1^2(x) dF_1(x) = \frac{1}{3},$$

$$B_1 = \int (1-F_1(x))^2 dF_2(x) = \frac{1}{3}$$

であるから, すべての x に対して, $F_1(x) = F_2(x)$ であれば,

$$\sigma^2(\hat{p}_{12}) = \frac{n_1+n_2-1}{12n_1n_2}$$

であるが, ここで考えている離散変量の場合には, 実際に数値例で当てみると,

$$A_1 = \sum_v \left(F_1(x_v) - \frac{1}{2} f_1(x_v) \right) f_1(x_v) \leq \frac{1}{3}$$

$$B_1 = \sum_v \left(1 - F_1(x_v) + \frac{1}{2} f_1(x_v) \right) f_1(x_v) \leq \frac{1}{3}$$

となる. そこで

$$(6.6) \quad \sigma^2(\hat{p}_{12}) \leq \frac{n_1+n_2-1}{12n_1n_2}$$

であるようにみえる.

順序統計量を扱うときに, タイを避けるために, 通常連続な分布関数 $F(x)$ を考える. 連続な $F(x)$ からの, 大きさ n のランダム標本による経験分布関数を $\hat{F}_n(x)$ とするとき, $F(x)$ と $\hat{F}_n(x)$ の差や, 差の絶対値についての確率的な評価は, 離散分布の場合には, 幾分控え目なものになるので, そのまゝ使っても差し支えない. このことはよく知られていることであるが, これと同じようなことが, ここでの場合にもあるのではないかと思われる.

7. 適用例

第 6 節で述べた事柄は, この節で扱おうとしている適用例の為に必要になったのである.

データは, 日本大学歯学部小児歯科学教室の赤坂守人氏の得たものであって, 幼児の歯の齲蝕の有様が, 約 4 ヶ月毎に 7 回, 経時的に調べられてある.

第 1 図, 前歯群の 0 型とあるのは, 齲蝕のない幼児であって, 86 名ある. また I 型とあるのは, 4 回目から 7 回目の調査の間で, 左上 (\overline{AB}) 前歯に 1~2 面齲蝕の生じている幼児であって, 52 名ある. つまり, 第 1 図の 6 つの図では, 横軸に調査回数, 縦軸に齲蝕の生じた歯の面の数が示してある. したがって, II, III, IV, V 型それぞれ図示のような齲蝕の傾向をもつ幼児であって, 39 名, 18 名, 22 名, 19 名がそれぞれの頻度である.

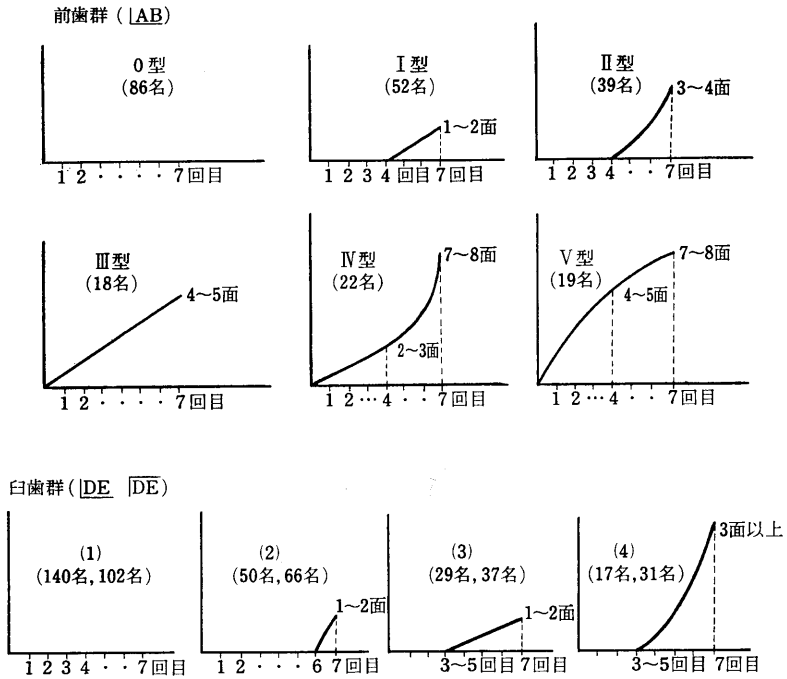
又臼歯群 (\overline{DE} , \overline{DE}) については, (1) とあるのが, 齲蝕のない幼児, (2), (3), (4) は, それぞれ図示のような齲蝕の傾向をもつ幼児を示している.

ところで, ここで分析しようとしているのは, 前歯に生じた齲蝕の臼歯への関連である.

前歯では, 0, I, II, III, IV, V の順序で, 臼歯では, (1), (2), (3), (4) の順序で齲蝕が進行しているとみられ, 前歯は臼歯より早く生える傾向があるから, まず, 0, I~V の隣合った 2 つをとり, (1)~(4) を齲蝕の順位と見做して, $\hat{p}_{\alpha\beta}$ ($\alpha, \beta=0, I, \dots, V$) を計算してみる.

はじめに, 左上 (\overline{DE}) の臼歯についてみると,

$$\hat{p}_{0I} = 0.58, \quad \hat{p}_{II} = 0.65, \quad \hat{p}_{III} = 0.47, \quad \hat{p}_{IIIIV} = 0.64, \quad \hat{p}_{IVV} = 0.58$$



第1図 齧蝕の時間的経緯パターン

第1表 前歯群と臼歯群の同時頻度分布

臼歯群 頻度		DE				DE				計
		(1)	(2)	(3)	(4)	(1)	(2)	(3)	(4)	
前歯群 AB	0	(0.83) 71	(0.14) 12	(0.02) 2	(0.01) 1	(0.64) 55	(0.25) 21	(0.09) 8	(0.02) 2	86
	I	(0.67) 35	(0.25) 13	(0.04) 2	(0.04) 2	(0.44) 23	(0.29) 15	(0.15) 8	(0.12) 6	52
	II	(0.41) 16	(0.31) 12	(0.20) 8	(0.08) 3	(0.39) 15	(0.28) 11	(0.13) 5	(0.20) 8	39
	III	(0.50) 9	(0.22) 4	(0.17) 3	(0.11) 2	(0.17) 3	(0.28) 5	(0.28) 5	(0.28) 5	18
	IV	(0.27) 6	(0.23) 5	(0.32) 7	(0.18) 4	(0.18) 4	(0.36) 8	(0.32) 7	(0.14) 3	22
	V	(0.16) 3	(0.21) 4	(0.37) 7	(0.26) 5	(0.11) 2	(0.31) 6	(0.21) 4	(0.37) 7	19
		140	50	29	17	102	66	37	31	236

であって、0~Vの隣合った順位の (α, β) については、 $p_{\alpha\beta}=0.5$ は棄却できそうにない。試みに、(6.6)の右辺 $(n_1+n_2-1)/12n_1n_2$ を求めてみると、

(0, I) の場合: $0.0026 \approx (0.050)^2$,

(I, II) の場合: $0.0037 \approx (0.061)^2$,

(II, III) の場合: $0.0066 \doteq (0.082)^2$,

(III, IV) の場合: $0.0082 \doteq (0.091)^2$,

(IV, V) の場合: $0.0080 \doteq (0.089)^2$.

このように, 0~V の隣合うものでは, 傾向にずれがみえないとみて, III, IV, V を合併して, 0 と合併したものを $\underline{\text{III V}}$ との間でみると,

$$\hat{p}_{0 \underline{\text{III V}}} = 0.79$$

であって, $(n_1+n_2-1)/12n_1n_2=144/12 \times 86 \times 59=0.0024 \doteq (0.049)^2$. これから, 前歯の齧蝕が臼歯の齧蝕に幾許か関連をもつものと考えられる.

この傾向は, 左下 ($\overline{\text{DE}}$) の臼歯についてみても同様であって, 念のために計算してみると,

$$\hat{p}_{0 \text{I}} = 0.62, \hat{p}_{\text{I II}} = 0.55, \hat{p}_{\text{II III}} = 0.63, \hat{p}_{\text{III IV}} = 0.43, \hat{p}_{\text{IV V}} = 0.62.$$

又, 0 と III, IV, V を合併したものについては,

$$\hat{p}_{0 \underline{\text{III V}}} = 0.80.$$

参 考 文 献

- [1] Hoeffding, W. (1963). Probability inequalities for sums of bounded random variables, *J. Amer. Statist. Ass.*, **53**, 13-30.
- [2] Hudimoto, H. (1968). On the empirical Bayes procedure (1), *Ann. Inst. Statist. Math.*, **20**, 169-185.
- [3] Hudimoto, H. (1976). On the empirical Bayes approach to classification problems, *Essays in Probability and Statistics*, The Committee for Publishing the Birthday Volume in Honor of Prof. Ogawa.
- [4] 藤本 熙, 松原 望 (1976). 決定の数理, 筑摩書房.
- [5] Hudimoto, H. (1979). On the empirical Bayes approach to classification in the case of discrete multivariate distribution having only finite mass points, *Ann. Inst. Statist. Math.*, **31**, A, 1-7.
- [6] Hudimoto, H. (1980). Empirical Bayes two-way decision in the case of discrete distributions, *Recent Developments in Statistical Inference and Data Analysis* (ed. K. Matusita), North-Holland Publishing Company, Amsterdam · New York · Oxford.
- [7] Klotz, J. (1966). The Wilcoxon, ties and the computer, *J. Amer. Statist. Ass.*, **61**, 772-787.
- [8] Putter, J. (1955). The treatment of ties in some nonparametric tests, *Ann. Math. Statist.*, **26**, 368-386.