

Multiple Ascertainment π 가 存在할 때 分離確率母數 θ 值의 尤度推定值로서 統計模型 의 構成과 遺傳病에 感染된 出生兒의 豫測

申 漢 豊*

序 論

遺傳的 질환이 있는 家系에서 出生하는 子女中에서 遺傳的인 질환을 保有할 수 있는 確率을 豫測하는 方法의 하나로서 尤度推定值(likelihood estimator)를 사용하는 것은 分離分析(segregation analysis)에서 중요한 역할을 하고 있다. Elston과 Stewart(1971)는 이러한 분석방법의 일반적인 통제모형을 定立하였으며 筆者(1974)와 Morton등(1974)은 complex segregation이 될 때에 분석되는 4가지의 統計模型을 주장하였다.

본 연구의 목적은 multiple ascertainment π 가 존재하는 경우 分離確率母數(segregation parameter) θ 의 尤度推定值를 구하고 둘째로 oligogenic special case에 대한 理論的인 배경을 究明하고자 한다.

理 論

1. 최우추정법(maximum likelihood estimator of θ)

數學的 模型을 最尤推定量(maximum likelihood estimator)으로 檢定하려면 式 (1)을(부록 1)참조)

$$P_{r,s}(\theta) = \frac{\binom{s}{r} \theta^r (1-\theta)^{s-r} [1 - (1-\pi)^r]}{1 - (1-\pi\theta)^s} \quad (1)$$

多項分布(multinomial distribution)로 變換하여

* 高麗大學校 統計學科 教授. 本研究은 1976年度 產學協同財團 研究費에 의하여 이루어진 것임을 밝힌다.

$$\begin{aligned}
 P_r \{a_{1s}, a_{2s}, \dots, a_{ss}; \theta\} &= \frac{n_s!}{a_{1s}! a_{2s}! \dots a_{ss}!} P_{1s}^{a_{1s}}(\theta) \dots P_{ss}^{a_{ss}}(\theta) \\
 &= n_s! \prod_{r=1}^s \frac{P_{rs}^{a_{rs}}(\theta)}{a_{rs}!}
 \end{aligned} \tag{2}$$

式 (2)는 θ 의 函數로 되어 尤度(likelihood), $L_s(\theta)$ 가 된다.

$$\text{즉 } L_s(\theta) = \frac{n_s!}{\prod_{r=1}^s a_{rs}!} \prod_{r=1}^s \left\{ [1 - (1-\pi)^r] \binom{s}{r} \frac{\theta^r (1-\theta)^{s-r}}{1 - (1-\pi\theta)^s} \right\}^{a_{rs}} \tag{3}$$

式 (3)의 $L_s(\theta)$ 에 log를 取하면

$$\log L_s(\theta) = \text{const} + \sum_{r=1}^s \{r \log \theta + (s-r) \log(1-\theta) - \log[1 - (1-\pi\theta)^s]\} a_{rs} \tag{4}$$

式 (4)를 미분하여 $L_s(\theta)$ 를 $U_s(\theta)$ 로 바꾸면

$$\begin{aligned}
 \frac{\partial \log L_s(\theta)}{\partial \theta} &= U_s(\theta) = \sum_{r=1}^s \left[\frac{r}{\theta} - \frac{(s-r)}{1-\theta} - \frac{\pi s (1-\pi\theta)^{s-1}}{1 - (1-\pi\theta)^s} \right] a_{rs} \\
 &= \sum_{r=1}^s \left[\frac{r}{\theta(1-\theta)} - \frac{s}{1-\theta} - \frac{\pi s (1-\pi\theta)^{s-1}}{1 - (1-\pi\theta)^s} \right] a_{rs} \\
 &= \frac{1}{\theta(1-\theta)} \sum_{r=1}^s r a_{rs} - \frac{s}{1-\theta} \sum_{r=1}^s a_{rs} - \frac{\pi s (1-\pi\theta)^{s-1}}{1 - (1-\pi\theta)^s} \sum_{r=1}^s a_{rs} \\
 &= \frac{r_s}{\theta(1-\theta)} - \frac{S n_s}{1-\theta} - \frac{\pi S n_s (1-\pi\theta)^{s-1}}{1 - (1-\pi\theta)^s} \\
 &= \frac{r_s}{\theta(1-\theta)} - \frac{S n_s [1 - (1-\pi\theta)^s - \pi(1-\theta)(1-\pi\theta)^{s-1}]}{(1-\theta)[1 - (1-\pi\theta)^s]} \\
 &= \frac{1}{1-\theta} \left[\frac{r_s}{\theta} - \frac{1 - (1-\pi)(1-\pi\theta)^{s-1}}{1 - (1-\pi\theta)^s} t_s \right]
 \end{aligned} \tag{5}$$

全體 標本에 대한 $U(\theta)$ 의 값은

$$U(\theta) = \sum_{s=1}^S U_s(\theta) = \frac{1}{1-\theta} \left[\frac{R}{\theta} - \sum_{s=1}^S \frac{1 - (1-\pi)(1-\pi\theta)^{s-1}}{1 - (1-\pi\theta)^s} t_s \right] \tag{6}$$

θ 의 ML 推定値를 求하면

$$\frac{R}{\theta} = \sum_{s=1}^S \frac{1 - (1-\pi)(1-\pi\theta)^{s-1}}{1 - (1-\pi\theta)^s} t_s \tag{7}$$

$V_{ar}(\hat{\theta})$ 을 計算하기 위하여 a_{rs} 의 期待値를 求하면

$$E(a_{rs}) = n_s P_{rs}(\theta), \quad r=1, 2, \dots, s \text{ 에 式 (1)을 代入}$$

$$E(a_{r,s}) = n_s \frac{\binom{s}{r} \theta^r (1-\theta)^{s-r} [1 - (1-\pi)^r]}{1 - (1-\pi\theta)^s}, \quad r=1, 2, \dots, s \quad (8)$$

r_s 의 期待値는

$$\begin{aligned} E(r_s) &= \sum_{r=1}^s r E(a_{r,s}) \\ &= \frac{n_s}{1 - (1-\pi\theta)^s} \left\{ \sum_{r=1}^s r \binom{s}{r} \theta^r (1-\theta)^{s-r} - \sum_{r=1}^s r \binom{s}{r} [(1-\pi)\theta]^r (1-\theta)^{s-r} \right\} \quad (9) \end{aligned}$$

式(9)의 대괄호안의 첫째 項이 二項分布의 平均이 된다.

$$\text{즉 } \sum_{r=1}^s r \binom{s}{r} \theta^r (1-\theta)^{s-r} = s\theta \quad (10)$$

式(9)의 두번째 項을 展開하면

$$\begin{aligned} r \binom{s}{r} &= s \binom{s-1}{r-1} \\ \sum_{r=1}^s r \binom{s}{r} [(1-\pi)\theta]^r (1-\theta)^{s-r} &= s(1-\pi)\theta \sum_{r=1}^s \binom{s-1}{r-1} [(1-\pi)\theta]^{r-1} (1-\theta)^{s-r} \\ &= s\theta(1-\pi)(1-\pi\theta)^{s-1} \quad (11) \end{aligned}$$

式(9)에 (10)과 (11)을 代入하면

$$E(r_s) = \frac{s\theta n_s}{1 - (1-\pi\theta)^s} [1 - (1-\pi)(1-\pi\theta)^{s-1}] \quad (12)$$

期待情報量(the expected amount of information) $I(\theta)$ 와 分散 $V_{a_r}(\hat{\theta})$ 은

$$\frac{\partial \log L_s(\theta)}{\partial \theta} = U_s(\theta) = \frac{r_s}{\theta(1-\theta)} - \frac{Sn_s}{1-\theta} - \frac{\pi Sn_s(1-\pi\theta)^{s-1}}{1 - (1-\pi\theta)^s} \quad (13)$$

따라서

$$\begin{aligned} -\frac{\partial^2 \log L_s(\theta)}{\partial \theta^2} &= -\frac{\partial U_s(\theta)}{\partial \theta} \\ &= -\frac{r_s(2\theta-1)}{\theta^2(1-\theta)^2} + \frac{Sn_s}{(1-\theta)^2} \\ &\quad - \frac{\pi^2 Sn_s(s-1)(1-\pi\theta)^{s-2}[1 - (1-\pi\theta)^s]}{[1 - (1-\pi\theta)^s]^2} \\ &\quad - \frac{\pi^2 Sn_s(1-\pi\theta)^{s-1}(1-\pi\theta)^{s-1}}{[1 - (1-\pi\theta)^s]^2} \\ &= -\frac{r_s(2\theta-1)}{\theta^2(1-\theta)^2} + \frac{Sn_s}{(1-\theta)^2} \\ &\quad - \frac{\pi^2 Sn_s(1-\pi\theta)^{s-2}}{[1 - (1-\pi\theta)^s]^2} \{s - [1 - (1-\pi\theta)^s]\} \quad (14) \end{aligned}$$

즉 $I_s(\theta)$, 期待情報量은 式(14)에 (12)을 代入하여 求한다.

$$I_s(\theta) = -\frac{\theta s n_s [1 - (1 - \pi)(1 - \pi\theta)^{s-1}](2\theta - 1)}{[1 - (1 - \pi\theta)^s] \theta^2 (1 - \theta)^2} + \frac{s n_s}{(1 - \theta)^2} - \frac{\pi^2 S n_s (1 - \pi\theta)^{s-2}}{[1 - (1 - \pi\theta)^s]^2} \{s - [1 - (1 - \pi\theta)^s]\} \quad (15)$$

그리고 total expected amount of information, $I(\theta)$ 는

$$I(\theta) = \sum_{s=1}^s I_s(\theta) \quad (16)$$

그러므로 $\hat{\theta}$ 의 分散인 $V_{ar}(\hat{\theta})$ 은

$$V_{ar}(\hat{\theta}) = \frac{1}{I(\theta)} \quad (17)$$

2. Oligogenic 確率模型에 관한 尤度

i 번째 개체에 대하여 관찰된 b_{ii} 의 尤度は 다음과 같이 표현할 수 있다(〈부록 2〉참조).

$$\alpha(z_i, b_{ii}) = [\pi_i(z_i)]^{b_{ii}} [1 - \pi_i(z_i)]^{1 - b_{ii}}$$

$$\begin{aligned} \text{여기서 } \alpha(z_i, b_{ii}) &= \pi_i(z_i) & b_{ii} &= 1 \text{ 이면} \\ &= 1 - \pi_i(z_i) & b_{ii} &= 0 \text{ 이면} \end{aligned}$$

만약 r 개의 독립적인 ascertainment 방법을 생각하면 다음과 같다.

$$\alpha(\underline{z}, \underline{b}) = \prod_{i=1}^r \alpha(z_i, b_{0i}) \prod_{i=1}^d \alpha(z_e, b_{ei}) \prod_{j=1}^{n_e} \alpha(z_{ej}, b_{eji})$$

위의 식을 두 세대(2-generational family)의 尤도로 표현하면

$$\frac{\alpha(\underline{z}, \underline{b}) \sum_{s=1}^{k_{h0}} \psi_{hos} g_{hos}(z_o) \prod_{e=1}^d \left\{ \sum_{t=1}^{k_{ht}} \psi_{het/s} g_{het}(z_e) \prod_{j=1}^{n_e} \left[\sum_{u=1}^{k_{htj}} p_{stuh_{ej}} g^{h_{ej}}(z_{ej}) \right] \right\}}{1 - \beta(g, \pi)} \quad (18)$$

여기서 $\beta(g, \pi) =$ 임의로 추출한 家系의 확률(proband가 없는 경우)

1) 正規表現型分布(normal phenotypic distribution)

μ_{hiu} 가 정규표현형분포의 평균이고 분산이 σ^2 인 경우

$$g_{hiu}(z_i) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left[-\frac{1}{2} \left(\frac{z_i - \mu_{hiu}}{\sigma}\right)^2\right] = \phi(z_i - \mu_{hiu}, \sigma^2) \quad (19)$$

z_i 대신에 만약 i 번째의 개체에 대하여 $z_{i_1}, z_{i_2}, \dots, z_{i_v}$ 의 관측치 벡터를 갖는다면 $P_{n_i}(z_{ij})$ 가 polynomial인 $Z_i = P_{n_1}(z_{i_1}) + P_{n_2}(z_{i_2}) + \dots + P_{n_v}(z_{i_v})$ 가 된다. 따라서 $g_{hiu}(Z_i)$ 도 式(19)와 같이 一變數正規分布(univariate normal distribution)가 된다. 특별히 나이를 관측치로 하는 경우에는 polynomial regression에 의한 age correction이 된다.

2) 베르누이 表現型分布(Bernoulli phenotypic distribution)

正常(normal)과 非正常(affected)을 0과 1로 놓으면

$$g_{hiu}(z_i) = (f_{hiu})^{z_i} (1 - f_{hiu})^{(1-z_i)} \quad (20)$$

여기서 f_{hiu} 는 sex h_i 와 因子型(genotype) u 가 갖는 表現型(phenotype) z_i 의 확률이다.

3) 정규분포의 평균과 분산이 因子型에 의하여 구해지므로 密度函數 $\phi(a_i - \mu_{hiu}, \sigma^2_{hiu})$ 로 표현할 수 있다. 非正常인 경우에 a_i 는 age of onset이 되고 a_i' 은 current age가 된다. 그러면 $g_{hiu}(z_i, a_i', a_i)$ 인 表現型分布는 다음과 같이 표시된다.

$$g_{hiu}(1, a_i', a_i) = \gamma_{hiu} \phi(a - \mu_{hiu}, \sigma^2_{hiu})$$

$$g_{hiu}(0, a_i', a_i) = 1 - \gamma_{hiu} \phi\left(\frac{a_i - \mu_{hiu}}{\sigma_{hiu}}\right), \quad (21)$$

$$\text{여기서 } \phi(a) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x \exp\left(-\frac{t^2}{2}\right) dt \quad (22)$$

위의 식에서 母數 γ 는 f 와 類似하며 f 가 penetrance인데 비하여 γ 는 susceptibility를 측정하는 것이 된다.

3) Ascertainment 函數

ascertainment 函數 α 가 $\pi_i(z_i)$ 의 확률로서 계산되고 $\pi_i(z_i)$ 에 대하여 3가지의 확률모형이 있다.

a) Threshold Model

$$\pi_i(z_i) = \pi_i \quad z_i \geq T \text{ 이면}$$

$$= 0 \quad z_i < T \text{ 이면} \quad (23)$$

여기서 z_i 가 Bernoulli variable이며 $T=1$ 이면 ascertainment모형이 된다. 이 경우에 $\pi \rightarrow 0$ 이면 single selection, $0 < \pi < 1$ 이면 multiple selection, $\pi=1$ 이면 complete selection이 된다.

$B_{iT} = \sum b_{iT}$ 과 $B_{iL} = \sum (1 - b_{iL})$ 로 놓으면 먼저 정의한 $\alpha(z, b)$ 를 다음과 같이 표현할 수 있다.

$$\alpha(z, b) = \prod_{i=1}^r \pi_i^{B_{iT}} (1 - \pi_i)^{B_{iL}}$$

이 식은 계산이 편리한 점이 있다.

b) Exponential Model

연속형의 자료에 대한 모형으로서 다음과 같이 定義된다.

$$\pi_i(z_i) = \min[\exp(k_0 + k_1 z_i + k_2 z_i^2), 1] \quad (24)$$

여기서 $k_2=0$ 이거나 또는 $k_2 < 0$ 그리고 $k_1^2 \leq 4k_0 k_2$

c) Age of Onset-Dependent Threshold Model

proband가 되는 확률을 $\pi_i(z_i, a_i)$ 로 놓으면

$$\pi_i(z_i, a_i) = \min[\exp(k_0 + k_1 a_i + k_2 a_i^2), 1]$$

if $z_i=1$ and either $k_2=0$, or $k_2<0$ and $k_1^2\leq 4k_0k_2$ (25)

4) Sampling Correction

式(18)의 尤度の z_i 에 대한 重積分 또는 合計는 β 로서 sampling correction이다. 計算의 편의상 순서를 바꾸면

$$\sum_{s=1}^{k_{h_0}} \phi_{h_{0s}} \zeta_{h_{0s}} \prod_{e=1}^d \left[\sum_{t=1}^{k_{h_e}} \phi_{h_{et}} \zeta_{h_{et}} \prod_{j=1}^{n_e} \left(\sum_{u=1}^{k_{h_{ej}}} p_{stuh_{ej}} \zeta_{h_{ej}u} \right) \right]$$

여기서 $\zeta_{h_{iu}}$ 는 모든 z_i 에 대한 積分 또는 合計임.

$$\prod_{i=1}^r \alpha(z_i, 0) g_{h_{iu}}(z_i) = \prod_{i=1}^r [1 - \pi_i(z_i)] g_{h_{iu}}(z_i) \quad (26)$$

$\zeta_{h_{iu}}$ 는 因子型 u 를 갖는 h_i 의 확률로서 proband가 되지않고 또한 이 확률은 g 와 π 가 결정됨에 따라 값이 결정된다. 이것을 誘導하여 보면 다음과 같다.

$$\begin{aligned} & \frac{1}{\sqrt{2\pi\sigma}} \int_{-\infty}^{a'} \exp\left[-\frac{1}{2}\left(\frac{z-\mu}{\sigma}\right)^2 + k_0 + k_1z + k_2z^2\right] dz \\ &= \frac{1}{\sqrt{2\pi\sigma}} \int_{-\infty}^{a'} \exp\left\{-\frac{1}{2\sigma^2}[(1-2k_2\sigma^2)z^2 - 2(\mu+k_1\sigma^2)z + \mu^2 - 2k_0\sigma^2]\right\} dz \\ &= \frac{1}{\sqrt{2\pi\sigma}} \int_{-\infty}^{a'} \exp\left[-\frac{1-2k_2\sigma^2}{2\sigma^2}\left(z - \frac{\mu+k_1\sigma^2}{1-2k_2\sigma^2}\right)^2\right] dz \cdot \exp\left[k_0 - \frac{\mu^2}{2\sigma^2} + \frac{(\mu+k_1\sigma^2)^2}{2\sigma^2(1-2k_2\sigma^2)}\right] \\ &= (1-2k_2\sigma^2)^{-\frac{1}{2}} \phi\left[\frac{1}{\sigma}\left(a' \sqrt{1-2k_2\sigma^2} - \frac{\mu+k_1\sigma^2}{\sqrt{1-2k_2\sigma^2}}\right)\right] \\ & \quad \cdot \exp\left\{\frac{1}{2\sigma^2}\left[2k_0\sigma^2 - \mu^2 + \frac{(\mu+k_1\sigma^2)^2}{1-2k_2\sigma^2}\right]\right\} \end{aligned} \quad (27)$$

여기서 $k_2=0$ 이면

$$\phi\left(\frac{a' - \frac{\mu - k_1\sigma^2}{\sigma}}{\sigma}\right) \exp\left(k_0 + \mu k_1 + \frac{1}{2} k_1^2 \sigma^2\right) \quad (28)$$

표현형 분포(phenotypic distribution)와 ascertainment함수에서 논의하였던 g 와 π 에 관한것을 ζ 로서 유도하여 보면

a) Normal g and Threshold Model for π

式(26), (19), (23)을 사용하여

$$\begin{aligned} \zeta_{h_{iu}} &= \int_{-\infty}^{\infty} \prod_{i=1}^r [1 - \pi_i(z)] g_{h_{iu}}(z) dz \\ &= \int_T \prod_{i=1}^r (1 - \pi_i) \phi(z - \mu_{h_{iu}}, \sigma^2) dz + \int_{-\infty}^T \prod_{i=1}^r (1) \phi(z - \mu_{h_{iu}}, \sigma^2) dz \end{aligned}$$

式(22)에서

$$\zeta_{h_{iu}} = \left[1 - \phi\left(\frac{T - \mu_{h_{iu}}}{\sigma}\right)\right] \prod_{i=1}^r (1 - \pi_i) + \phi\left(\frac{T - \mu_{h_{iu}}}{\sigma}\right)$$

b) Normal g and Exponential Model for π ($r=1$)

式(26), (19) 및 (24)에서 $\exp(k_0+k_1z)=1$ 이 $z=k_0/k_1$ 과 equivalent하므로

i) If $k_2=0$ and $k_1>0$,

$$\zeta_{htu} = \int_{-\infty}^{-k_0/k_1} \phi(z - \mu_{htu}, \sigma^2) [1 - \exp(k_0 + k_1z)] dz$$

ii) If $k_2=0$ and $k_1<0$,

$$\zeta_{htu} = \int_{-k_0/k_1}^{\infty} \phi(z - \mu_{htu}, \sigma^2) [1 - \exp(k_0 + k_1z)] dz$$

iii) If $k_2<0$ and $k_1 \leq 4k_0k_2$,

式(22), (27), (28)에 의하여

$$i) \zeta_{htu} = \Phi\left(-\frac{k_0/k_1 + \mu_{htu}}{\sigma}\right) - \exp\left(k_0 + \mu_{htu}k_1 + \frac{1}{2}\sigma^2k_1^2\right) \cdot \Phi\left(-\frac{k_0/k_1 + \mu_{htu} + \sigma^2k_1}{\sigma}\right),$$

$$ii) \zeta_{htu} = \Phi\left(\frac{k_0/k_1 + \mu_{htu}}{\sigma}\right) - \exp\left(k_0 + \mu_{htu}k_1 + \frac{1}{2}\sigma^2k_1^2\right) \cdot \Phi\left(\frac{k_0/k_1 + \mu_{htu} + \sigma^2k_1}{\sigma}\right),$$

$$iii) \zeta_{htu} = 1 - (1 - 2k_2\sigma^2)^{-\frac{1}{2}} \exp\left\{\frac{1}{2\sigma^2}\left[2k_0\sigma^2 - \mu_{htu}^2 + \frac{(\mu_{htu} + k_1\sigma^2)^2}{1 - 2k_2\sigma^2}\right]\right\}$$

c) Bernoulli g and Threshold Model for π

式(26)에서 $z=1$ 과 $z=0$ 으로 놓고 式(20)과 (23)을 $T=1$ 로 놓으면

$$\zeta_{htu} = f_{htu} \prod_{i=1}^r (1 - \pi_i) + 1 - f_{htu}$$

3. 討議 및 結論

筆者(1974)와 Morton 및 Maclean(1974)이 유전적인 가설검정을 위한 방법으로 3가지의 통계모형을 제시하였고 Elston과 Stewart(1971)가 또한 Ascertainment 函數에서 3종류의 확률모형을 제시함과 동시에 수집된 家系의 자료에 응용한 바 있다. North Carolina 대학의 Elston 등의 GENSEG 컴퓨터 프로그램은 하와이 대학 Morton 등의 COMSEG 프로그램보다 缺測值(missing value)를 補完하고 자료를 다시 배열하는 데에는 장점이 있으나 CONSEG에 비하여 각 모델에 관한 separate program의 效率(efficiency)이 낮다. 두 프로그램의 공통점은 Newton-Raphson의 반복법(iteration)을 사용하지 않고 最尤副프로그램(maximum-likelihood subroutine)을 이용하여 尤度を 극대화한 점이다.

one-locus model에서의 分離比(segregation ratios)의 검정은 확률의 벡터 $T' = (T_1, T_2, T_3)$ 의 값이 $(1 \frac{1}{2} 0)$ 으로 제한되었을 때 maximum likelihood를 비교하게 된다. 동일한 가설에 대한 검

정으로서 본연구는 $T, T_0' = (1 \frac{1}{2} 0)$ 의 最尤推定値인 \hat{T} 를 다음과 같은 통계량 $(\hat{T} - T_0)' V^{-1} (\hat{T} - T_0)$ 으로서 계산을 시도하였으며 컴퓨터 프로그램을 變形하였다. 여기서 V 는 \hat{T} 의 분산-공분산행렬 (variance-covariance matrix)의 一致推定値를 의미하며 이 통계량은 尤度比判定 (likelihood-ratio criterion)에 漸近的으로 同一 (asymptotically identical)하고 동일한 수의 자유도를 갖는 χ^2 분포와 비교될 수 있다. Hardy-Weinberg equilibrium를 검정하기 위하여 Elandt-Johnson (1970, 1971)과 Murphy (1967) 등이 연구한 분리분석 (segregation analysis)의 일반적인 방법에 대한 특별한 경우가 된다. 이 방법은 母數 (parameter)가 많을 때 동시에 추정하기 어려운 경우에 V 값과 \hat{T} 값을 쉽게 구할 수 있는 것이다.

본 연구에서 논의한 模型은 oligogenic한 경우를 이론적으로 검토하면서 특히 multiple ascertainment가 존재할 때 最尤推定値에 관한 이론과 oligogenic model에 관하여 Elston 등 (1974), Morton 등 (1974)과 筆者 (1974)의 연구를 이론적으로 종합 검토 하였다. 결과적으로 분리분석에 관한 다수의 이론적 모형이 발표되었으나 대개의 경우 일반적인 방법에 대한 특수한 경우인 것이다. 두 방법 모두 장단점이 있으며 장차의 분리분석에 관한 연구는 monogenic, polygenenic, oligogenic, megaphenic, environmental effect 등에 관한 각 要素 (factor)의 연관성을 구명하는 것이 중요한 연구과제가 될 것이다.

産學協同財團에 제출한 연구계획에는 家系資料 (family-pedigree data)를 분석키로 되었으나, 불행하게도 현재 한국에 있는 종합병원에 자료가 없으므로 실제 분석을 시도 못한 것이 유감스럽다.

(부록 1) 上記式(1)—(17)의 부호 설명

s = the family size (즉 the size of the sibship)

S = the maximal family size in the sample

r = the number of affected children in the sibship of size s ($r=1, 2, \dots, s$)

$a_{r,s}$ = the recorded number of families of size s , each with r affected children

$n_s = \sum_{r=1}^s a_{r,s}$ = the total number of recorded families of size s . (n_s 가 fixed 되었다고 가정)

$N = \sum_{s=1}^S n_s = \sum_{r=1}^S \sum_{s=1}^s a_{r,s}$ = the total number of recorded families of all sizes, that is, the sam-

ple size which is fixed, together with fixed S

$r_s = \sum_{r=1}^s r a_{r,s}$ = the number of affected children in all n_s families

$R = \sum_{s=1}^S r_s = \sum_{s=1}^S \sum_{r=1}^s r a_{r,s}$ = the total number of affected children in the whole sample

$t_s = S n_s$ = the number of recorded children in all n_s families

$T = \sum_{s=1}^S t_s = \sum_{s=1}^S S n_s$ = the total number of recorded children in the whole sample

(부록 2) 上記式(18)—(28)의 부호 설명 (oligogenic 確率模型)

h_i = i 번째의 性(sex)

h_0 = 동일한 부모의 性

h_e = 재혼한 경우 남편이나 아내의 性

Z = phenotypic trait의 측도(測度)

Z_0 = common parent의 측도

Z_e = e 번째의 배우자의 측도

$Z_{e,j}$ = e 번째 배우자에 의한 j 번째 자녀의 측도

$h_i = 1$ 이면 i 번째 자녀가 남성을 의미하고

$h_i = 2$ 이면 i 번째 자녀가 여성을 의미한다.

$g_{hiu}(z)$ = 因子型 u 와 性 h_i 를 가진 子女에 대한 表現型에 관한 확률밀도 함수

k_{hi} = 性 h_i 에 대한 다른 因子型の 數

P_{st}^{hi} = 父母의 因子型이 s 와 t 일때 性 h_i 가 갖는 因子型 u 의 확률

ψ_{h_0s} = h_0 가 갖는 확률(父系의 集團의 因子型이 s 일때)

$\psi_{h_e t/s}$ = h_e 가 갖는 확률(h_e 의 因子型은 t 이고 배우자의 因子型은 s 일때)

d = 결혼의 회수($e=1, 2, \dots, d$)

n_e = n 번째 결혼에서 생기는 자녀수($j=1, 2, \dots, n_e$)

b_{il} = l 번째 ascertainment방법에 의해 결정된 i 번째에 관한 proband의 상태

$\alpha(z, b)$ = 全體家系에 관한 ascertainment 함수

參 考 文 獻

- [1] Elandt-Johnson, R. C., "Segregation Analysis for Complex Modes of Inheritance," *Am. J. Hum. Genet.*, Vol. 22(1970), pp.129-140.
- [2] Elandt-Johnson, R. C., "Complex Segregation Analysis II, Multiple Classification," *Am. J. Hum. Genet.* Vol., 23(1971), pp.17-32.
- [3] Elston, R. C. and Stewart, J., "A General Model for the Genetic Analysis of Pedigree Data," *Hum. Hered.*, Vol. 23(1971), pp.523-542.
- [4] Kaplan, E. B. and Elston, R. C., "A Subroutine Package for Maximum-likelihood Estimation (MAXLIK)," Univ. of North Carolina, Institute of Statistics, Mimeo Series, No. 823, 1972.
- [5] Morton, N. E., "Segregation Analysis," in *Computer Application in Genetics*, edited by N. E., Morton, Univ. of Hawaii Press, 1969.
- [6] Morton, N. E. and Maclean C. J., "Analysis of Family Resemblance III, Complex Segregation of Quantitative Traits," *Am. J. Hum., Genet.* Vol. 26 (1974), pp.489~503.
- [7] Murphy, E.A. and Bolling, D.R., "Testing of Single-locus hypothesis where There is Incomplete Separation of the Phenotypes," *Am. J. Hum., Genet.*, Vol. 19(1967), pp.322-344.
- [8] Shin, Han P., "Complex Segregation Analysis," *Jour. Korean Stat. Soc.*, Vol. 3, No. 2(1974), pp.103-115.

〈ABSTRACT〉

Maximum Likelihood Estimator of the Segregation
Parameter under Multiple Ascertainment ($0 < \pi < 1$)
with Known π

Han Poong Shin*

Theoretical details are considered of maximum likelihood estimator of segregation parameter and of several oligogenic models for segregation analysis.

For a one-locus model, the maximum likelihood obtained when the vector of transmission probabilities $\underline{T}' = (T_1 \ T_2 \ T_3)$ is estimated is compared to the maximum likelihood obtained under the restriction $\underline{T}' = (1 \ \frac{1}{2} \ 0)$. Another method of testing the same hypothesis is to compute the statistic $(\hat{\underline{T}} - \underline{T}_0)' V^{-1} (\hat{\underline{T}} - \underline{T}_0)$, where $\hat{\underline{T}}$ is the maximum-likelihood estimate of \underline{T} , $\underline{T}_0' = (1 \ \frac{1}{2} \ 0)$, and V is a consistent estimate of the variance-covariance matrix of $\hat{\underline{T}}$, this statistic is asymptotically identical to the likelihood-ratio criterion and so is compared to a χ^2 distribution with the same number of degrees of freedom.

* Professor, Department of Statistics, Korea University.