

ESTYMACJA PARAMETRÓW W MODELACH LOSOWYCH I MIESZANYCH

1. Wstęp

W niniejszej pracy podajemy metody estymacji parametrów dla następujących modeli

$$(1) \quad y = \sum_{i=1}^k X_i b_i,$$

gdzie X_i są znanymi n - wierszowymi macierzami, a b_i , z wyjątkiem b_1 , wektorami losowymi. Zakładamy ponadto, że $X_k = I$ jest macierzą jednostkową. Dla $i=2, \dots, k$ wektory losowe b_i mają wielowymiarowe rozkłady normalne $N(0, \sigma_i^2 V_i)$, gdzie V_i są znanymi macierzami, natomiast $\sigma_i^2 > 0$. Ponadto zakładamy, że $V_k = I$ oraz, że wektory b_i są parami nieskorelowane. W przypadku gdy $X_1(1, \dots, 1)' = \mathbb{1}$, modele o wyżej opisanej strukturze noszą nazwę modeli losowych, a $\sigma_2^2, \dots, \sigma_k^2$ noszą nazwę komponentów wariancyjnych. Natomiast gdy X_1 ma dwie lub więcej kolumn modele te nazywają się modelami mieszanymi.

W pracy podane są metody estymacji nieznanymi parametrów. Estymatory dla b_1 są liniowymi funkcjami wektora y . Natomiast $\sigma_2^2, \dots, \sigma_k^2$ estymuje się formami kwadratowymi tzn. są postaci $y' Ay$, gdzie A jest macierzą symetryczną. Własności optymalne tych estymatorów można znaleźć w pracach [1] - [4].

2. Estymatory dla składowych wektora b_1 .

Estymatory dla parametrów b_i , które oznaczać będziemy symbolem \hat{b}_i otrzymuje się metodą najmniejszych kwadratów, tzn.

$$(2) \quad \hat{b}_i = (X'X)^{-1} X'y,$$

gdzie $(X'X)^{-1}$ jest dowolną uogólnioną macierzą odwrotną macierzy $X'X$. W przypadku modelu losowego b_1 jest liczbą, a \hat{b}_1 średnią arytmetyczną składowych wektora obserwacji.

Estymację $\sigma_2^2, \dots, \sigma_k^2$ rozważać będziemy oddzielnie dla modeli losowych i mieszanych. W modelu losowym dla wygody przyjmujemy $\sigma_1^2 = b_1^2$.

3. Estymacja komponentów wariancyjnych w modelach losowych.

Niech $\sigma = (\sigma_1^2, \dots, \sigma_k^2)'$ będzie wektorem kolumnowym złożonym z b_1^2 i z kolejnych komponentów wariancyjnych. Obliczamy najpierw $W_1 = 11'$ oraz macierze $W_i = X_i V_i X_i'$ dla $i=2, \dots, k$. Następnie tworzymy macierz symetryczną $T = [t_{ij}]$ wymiaru $k \times k$, gdzie $t_{ij} = \text{tr}(W_i W_j)$. Tutaj i w dalszej pracy $\text{tr}(A)$ oznacza ślad macierzy A tzn. sumę elementów na głównej przekątnej. W dalszym kroku obliczamy wektor kolumnę $z = (z_1, \dots, z_k)'$, gdzie $z_i = y' W_i y$. Estymatorem dla σ jest $\hat{\sigma} = T^{-1} z$.

4. Estymacja komponentów wariacyjnych w modelach mieszanych

W przypadku modeli mieszanych postępujemy inaczej. Najpierw obliczamy $P=X(X'X)^{-1}X'$ tzn. macierz rzutu na przestrzeń generowaną przez kolumny macierzy X . Następnie obliczamy W_i dla $i=2, \dots, k$ tak samo jak dla modeli losowych, a potem $U_{i-1}=W_i-PW_iP$. Elementy macierzy $T=[t_{ij}]$ wymiaru $(k-1) \times (k-1)$ liczymy według wzoru $t_{ij}=\text{tr}(U_i U_j)$. Estymatorem dla $\sigma=(\sigma_2^2, \dots, \sigma_k^2)$ jest $\hat{\sigma}=T^{-1}z$, gdzie $z=(z_1, \dots, z_{k-1})'$ jest wektorem $(k-1) \times 1$, którego i -ta składowa $z_i=y'U_i y$.

W przypadku, gdy PW_i jest macierzą symetryczną łatwo można wykazać, że $PW_i P=PW_i$.

Przykłady. 1. Rozważmy model losowy dla dwukierunkowej klasyfikacji krzyżowej z jedną obserwacją w podklasie. Niech

$$(1) \quad X_{ij} = \mu + a_i + b_j + e_{ij}, \quad \begin{array}{l} i=1, \dots, r, \\ j=1, \dots, s, \end{array}$$

gdzie μ jest średnią ogólną, natomiast a_i, b_j, e_{ij} są niezależnymi zmiennymi losowymi o rozkładach normalnych z wartościami oczekiwanymi zero i wariancjami σ_a^2, σ_b^2 i σ_e^2 odpowiednio. Przyjmując

$$\begin{aligned} Y &= (y_{11}, y_{12}, \dots, y_{1s}, y_{21}, \dots, y_{2s}, \dots, y_{rs})' \\ e &= (e_{11}, e_{12}, \dots, e_{1s}, e_{21}, \dots, e_{2s}, \dots, e_{rs})' \\ \beta_2 &= (a_1, \dots, a_r)' \\ \beta_3 &= (b_1, \dots, b_s)' \end{aligned}$$

równania (1) można zapisać wektorowo w następujący sposób

$$y = \mu \mathbb{1} + X_2 \beta_2 + X_3 \beta_3 + e,$$

gdzie $\mathbb{1}$ jest wektorem $n \times 1$ jedynek, ($n = r \cdot s$), $X_2 = [x_{ij}]$ jest macierzą $n \times r$ przy czym

$$x_{ij} = \begin{cases} 1 & \text{dla } (s-1)j+1 \leq i \leq sj \\ 0 & \text{w pozostałym przypadku, natomiast } X_3 \end{cases}$$

jest macierzą blokową złożoną z r macierzy jednostkowych I każda wymiaru $s \times s$ tzn.

$$X_3 = \begin{bmatrix} I \\ I \\ \vdots \\ I \end{bmatrix}.$$

Ponieważ zmienne losowe a_i, b_j, e_{ij} są niezależne, więc

$W_2 = X_2 X_2'$, $W_3 = X_3 X_3'$ i $W_4 = I$. Macierz $W_1 = \mathbb{1}\mathbb{1}'$ jest macierzą jedynek wymiaru $n \times n$.

Łatwo sprawdzić, że macierz T jest następująca

$$\begin{bmatrix} n^2 & sn & rn & n \\ sn & sn & n & n \\ rn & n & rn & n \\ n & n & n & n \end{bmatrix}.$$

Wektor z ma składowe

$$z_1 = y_{..}^2, \quad z_2 = \sum_{i=1}^r y_{i.}^2, \quad z_3 = \sum_{j=1}^s y_{.j}^2, \quad z_4 = \sum_{i=1}^r \sum_{j=1}^s y_{ij}^2.$$

Kropka zamiast wskaźnika oznacza sumę po tym wskaźniku.

Dla $r \geq 2$ i $s \geq 2$ równanie $Tz = \sigma$ ma następujące jednoznaczne rozwiązanie

$$\hat{\sigma}_e^2 = \overline{SS}_e,$$

$$\hat{\sigma}_a^2 = \frac{1}{s} (SS_a - SS_e),$$

$$\hat{\sigma}_b^2 = \frac{1}{r} (SS_b - SS_e),$$

$$\hat{\sigma}^2 = \frac{1}{n} (z_4 - \hat{\sigma}_a^2 - \hat{\sigma}_b^2 - \hat{\sigma}_e^2),$$

gdzie

$$\overline{SS}_e = \frac{1}{(r-1)(s-1)} (z_4 - \frac{1}{s} z_3 - \frac{1}{s} z_2 + \frac{1}{n} z_1),$$

$$\overline{SS}_a = \frac{1}{(r-1)} (\frac{1}{s} z_2 - \frac{1}{n} z_1),$$

$$\overline{SS}_b = \frac{1}{s-1} (\frac{1}{r} z_3 - \frac{1}{n} z_1).$$

Przykład 2. Rozważmy model mieszany dla dwukierunkowej klasyfikacji z jedną obserwacją w podklasie, przyjmując, że a_i są efektami stałymi. Z uwagi na to, że wektor $\underline{1}$ jest sumą kolumn macierzy X_2 w przykładzie pierwszym, więc macierz $P = X_2(X_2'X_2)^{-1}X_2' = \frac{1}{s} X_2X_2' = \frac{1}{s} V_2$.

Macierz PV_3 jest symetryczna, zatem

$$W_1 = (I - \frac{1}{S} V_2) V_3$$

$$W_2 = I - \frac{1}{S} V_2.$$

W tym przypadku macierz

$$T = r(s-1) \begin{pmatrix} r & 1 \\ 1 & 1 \end{pmatrix},$$

podczas, gdy

$$z_1 = \sum_{j=1}^s y_{.j}^2 - \frac{1}{S} y_{..}^2.$$

i

$$z_2 = \sum_{i=1}^r \sum_{j=1}^s y_{ij}^2 - \frac{1}{S} \sum_{i=1}^r y_{i.}^2.$$

Równanie $T\beta = z$ ma jedno rozwiązanie wtedy i tylko wtedy, gdy $s > 2$, $r > 2$. Łatwo sprawdzić, że $\hat{\sigma}_b^2$ i $\hat{\sigma}_e^2$ są takie same jak w modelu losowym.

Referencje

- [1] S.Gnot, W.Klonecki and R.Zmyślony, Best linear plus quadratic unbiased estimation of parameters in mixed linear models, *Zastosowania Matematyki* 15,4 (1977), 455-462.
- [2] R.Zmyślony, Estimation of variance components in random models, *Zastosowania Matematyki* 13, 4(1973), 521-527.
- [3] R.Zmyślony, Kwadratowo dopuszczalne estymatory w modelach losowych, *Matematyka Stosowana* 7, (1976), 117-122
- [4] R.Zmyślony, On estimation of parameters in linear Models, *Zastosowania Matematyki* 15, 3(1976), 271-276.