

APLIKÁCIA KVADRATICKÝCH ODHADOV V METROLOGII

LUBOMÍR KUBÁČEK

Matematický ústav SAV

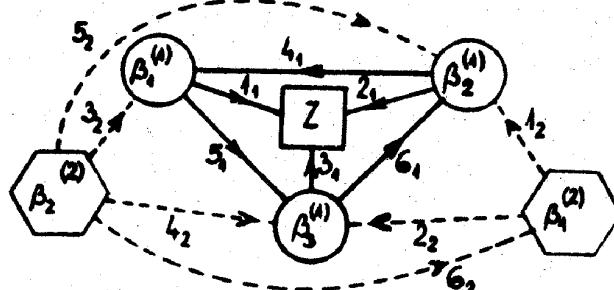
814 73 Bratislava, Obrancov mieru 49

1. Úvod

Vznik špeciálnej štruktúry (dvojetapovej a zmiešanej) regresného modelu ukazuje nasledovný problém.

Nech Z označuje hodnotu etalónu nejakej fyzikálnej veličiny, ktorá je prijatá konvenciou, t.zn. je bezchybná. S týmto etalónom Z porovnáme etalóny $\beta_1^{(1)}, \beta_2^{(1)}, \beta_3^{(1)}$ (prvá etapa) v súlade s grafom na obr.1.

Obr.1



Orientovaná hrana grafu je priradená náhodnej veličine, realizáciou ktorej vznikne údaj "zmeraný rozdiel medzi hodnotou etalónu na konci hrany a hodnotou etalónu na začiatku hrany". Ak pre stredné hodnoty $E(Y)$ týchto náhodných veličín $Y_i^{(1)}, i=1, \dots, 6$, pletí (t.zn., že v meraní nepôsobili systematické vplyvy):

$$E \begin{bmatrix} Y_1^{(1)} - Z \\ Y_2^{(1)} - Z \\ Y_3^{(1)} - Z \\ Y_4^{(1)} \\ Y_5^{(1)} \\ Y_6^{(1)} \end{bmatrix} = \begin{bmatrix} -1 & 0 & 0 \\ 0 & -1 & 0 \\ 0 & 0 & -1 \\ 1 & -1 & 0 \\ -1 & 0 & 1 \\ 0 & 1 & -1 \end{bmatrix} \begin{bmatrix} \beta_1^{(1)} \\ \beta_2^{(1)} \\ \beta_3^{(1)} \end{bmatrix}$$

(posledný vzťah zapíšeme v ďalšom $E(Y^{(1)}) = X^{(1)}\beta^{(1)}$) a pre kovariančnú maticu $\text{Var}(Y^{(1)})$ náhodného vektora $Y^{(1)}$ platí $\text{Var}(Y^{(1)}) = \sigma^2 I$ (I označuje identickú maticu), potom najlepší lineárny nevychýlený odhad parametra $\beta^{(1)}$ založený na vektoru $Y^{(1)}$ je $\hat{\beta}^{(1)}(Y^{(1)}) = (X^{(1)} X^{(1)})^{-1} X^{(1)} Y^{(1)}$. Nech ďalej etalóny druhej etapy $\beta_1^{(2)}, \beta_2^{(2)}$ boli porovnané s etalonmi prvej etapy tak, že sa opäť zmerali rozdiely hodnôt etalónov podľa grafu na obr.1. Nech (podobne ako v prvej etape) platí

$$E \begin{bmatrix} Y_1^{(2)} \\ Y_2^{(2)} \\ Y_3^{(2)} \\ Y_4^{(2)} \\ Y_5^{(2)} \\ Y_6^{(2)} \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} \beta_1^{(1)} \\ \beta_2^{(1)} \\ \beta_3^{(1)} \end{bmatrix} + \begin{bmatrix} -1 & 0 \\ -1 & 0 \\ 0 & -1 \\ 0 & -1 \\ 0 & -1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} \beta_1^{(2)} \\ \beta_2^{(2)} \end{bmatrix}$$

(posledný vzťah zapíšeme v ďalšom $E(Y^{(2)}) = C_{21}\beta^{(1)} + X^{(2)}\beta^{(2)}$) a $\text{Var}(Y^{(2)}) = \sigma^2 I$, pričom vektoru $Y^{(1)}$ a $Y^{(2)}$ sú stochasticky nezávislé.

Podmienkou teraz je, že vektor $Y^{(2)}$ druhej etapy môžeme použiť pre odhad parametrov druhej etapy, ale hodnoty odhadu $\hat{\beta}^{(1)}(Y^{(1)})$ nesmiem meniť. Môžeme teda hľadať odhad $\hat{\beta}^{(2)}(Y^{(1)}, Y^{(2)})$ založený na vektoroch $Y^{(1)}, Y^{(2)}$, alebo odhad $\tilde{\beta}^{(2)}(Y^{(2)}, \hat{\beta}^{(1)})$.

založený na vektoroch $\hat{\beta}^{(1)}(Y^{(1)})$, $\hat{\beta}^{(2)}(Y^{(2)})$. V druhom prípade na pr. dostávame:

$$\mathbb{E}(Y^{(2)} - c_{21}\hat{\beta}^{(1)}(Y^{(1)})) = X^{(2)}\beta^{(2)}$$

$$\text{Var}(Y^{(2)} - c_{21}\hat{\beta}^{(1)}) = \sigma_1^2 c_{21} (X^{(1)} X^{(1)})^{-1} c_{21}' + \sigma_2^2 I.$$

(Tu je potrebné si všimnúť, že kovariančná matica má štruktúru $\sigma_1^2 H_1 + \sigma_2^2 H_2$, kde H_1 a H_2 sú známe matice, avšak σ_1^2, σ_2^2 známe byť nemusia.) Obidve etapy (súčasne) sú charakterizované modelom

$$(+)\quad \begin{aligned} \mathbb{E}\begin{pmatrix} Y^{(1)} \\ Y^{(2)} \end{pmatrix} &= \begin{pmatrix} X^{(1)} & 0 \\ 0 & X^{(2)} \end{pmatrix} \begin{pmatrix} \beta^{(1)} \\ \beta^{(2)} \end{pmatrix}, & \text{Var}\begin{pmatrix} Y^{(1)} \\ Y^{(2)} \end{pmatrix} &= \sigma_1^2 \begin{pmatrix} I & 0 \\ 0 & 0 \end{pmatrix} + \sigma_2^2 \begin{pmatrix} 0 & 0 \\ 0 & I \end{pmatrix} \end{aligned}$$

(opäť kovariančná matica má už spomínanú štruktúru), pričom $\mathcal{M}(c_{21}') \in \mathcal{M}(X_j')$ ($\mathcal{M}(.)$ označuje stĺpcový priestor matice v zátvorkách).

V prípade, že hodnoty $\sigma_1^2, \sigma_2^2, \sigma_1^2/\sigma_2^2$ sú a priori neznáme, vzniká problém ako odhadovať parametre druhej etapy $\beta^{(2)}$, prípadne ako odhadovať hodnoty σ_1^2, σ_2^2 .

Tu je potrebné poznamenať, že štruktúra (+) regresného modelu vzniká na pr. v geodézii, geofyzike a ľiných odboroch, tukže užitočnosť štúdia štruktúry (+) nie je obmedzená na jedinú aplikáciu oblast.

V ďalšom je uvedený prehľad základných poznatkov o tejto problematike a niektoré novšie výsledky.

2. Definície a formulácia problému

Definícia 2.1. Regresný model $(Y, X\beta, \Sigma)$ nazveme prvečkovým ak pre maticu plánu X a pre kovariančnú maticu Σ platí:

$$X = \begin{bmatrix} X_1 & 0 & \cdots & 0 \\ C_{1,1} X_2 & \cdots & \cdots & 0 \\ \vdots & \ddots & \ddots & \vdots \\ C_{p,1} & C_{p,2} & \cdots & C_{p,p-1} & X_p \end{bmatrix}, \quad \Sigma = \begin{bmatrix} \Sigma_{1,1} & 0 & \cdots & 0 \\ 0 & \Sigma_{2,2} & \cdots & 0 \\ \vdots & \ddots & \ddots & \vdots \\ 0 & 0 & \cdots & \Sigma_{p,p} \end{bmatrix},$$

$$\mathcal{M}(C_{i,j}') \subset \mathcal{M}(X_j'), \quad i=2, \dots, p, \quad j=1, \dots, p, \quad i \geq j.$$

Definícia 2.2. Regresný model nazveme zmiešaným ak pre jeho kovariančnú maticu Σ platí $\Sigma = \sum_{i=1}^p \psi_i V_i$, $p \geq 2$, pričom V_i sú známe symetrické matice a ψ_i sú neznáme parametre (variančné komponenty).

Definícia 2.3. Regresný model $(Y, X\beta, \Sigma)$ nazveme replikovaným, ak $X = 1 \otimes X$, $1 = (1, \dots, 1)'$, $\Sigma = I \otimes \Sigma$.

Poznámka 2.1. Z uvedených definícii je zrejmé, akú štruktúru bude mať na pr. replikovaný zmiešaný model, p-čiapočný zmiešaný replikovaný model a pod.

V ďalšom si všimnime postupy pre odhad parametrov β a ψ v nereplikovanom modeli a postupy pre odhad parametrov ψ v replikovanom zmiešanom modeli.

Problémy určenia týchto odhadov v nereplikovaných modeloch sa doteraz študovali najmä v troch základných polohách a to: a) odhad β [1], [4], [12], b) odhad ψ [5], [6], [11], [13], [15], [16] a c) simultánny odhad β a ψ [1], [9], [16]; v replikovaných modeloch sa zatiaľ pozornosť sústreduje na odhad ψ [2], [5], [6], [15], výnimco ne na β [12], [4].

Poznámka 2.2. V [15] je uvedený značný počet citácií prác, ktoré sa zaoberajú problematikou odhadu ψ .

3. Odhad parametra β

Teorema 3.1. V 2-čiapočnom regresnom modeli so znáomou kovariančnou maticou a s odhadnuteľnými parametrami prvej aj druhej etapy platí:

$$\hat{\beta}^{(2)}(Y^{(1)}, Y^{(2)}) = \hat{\beta}^{(2)}(Y^{(2)}, \hat{\beta}^{(1)}(Y^{(1)})),$$

kde $\hat{\beta}^{(2)}(Y^{(1)}, Y^{(2)})$ je najlepší lineárny odhad založený na vektoroch $Y^{(1)}$ a $Y^{(2)}$ a $\hat{\beta}^{(2)}(Y^{(2)}, \hat{\beta}^{(1)}(Y^{(1)}))$ je najlepší lineárny odhad založený na vektoroch $Y^{(2)}$ a

$\hat{\beta}^{(1)}(Y^{(1)})$ (nejlepší lineárny odhad vektoru $\beta^{(1)}$) založený na vektoru $Y^{(1)}$.

Dôkaz. Pozri teoremu 3.1 v [10].

Teorema 3.2. V p-etalovom ($p > 2$) regresnom modeli so známou kovariančnou maticou Σ a s odhadnuteľnými parametrami β vo všetkých etapách platí:

$$\hat{\beta}^{(1)}(Y^{(1)}, \dots, Y^{(i)}) = \hat{\beta}^{(1)}\{Y^{(1)}, \hat{\beta}^{(1)}(Y^{(1)}), \dots, \hat{\beta}^{(i-1)}(Y^{(i-1)}), \hat{\beta}^{(i-2)}[Y^{(i-2)}, \\ \hat{\beta}^{(i-3)}(Y^{(i-3)}, \hat{\beta}^{(i-4)}(\dots)), \dots, \hat{\beta}^{(1)}(Y^{(1)})]\},$$

$i=1, \dots, p$, práve vtedy, ak $C_{L,j} = 0 \Leftrightarrow i-j \geq 2$, $i=1, \dots, p$, $j=1, \dots, i-1$.

Dôkaz. Pozri teoremu 3.2 v [10].

Teorema 3.3. Nech v replikovanom modeli $(Y = (Y'_1, Y'_2, \dots, Y'_{f+1})'$, $(I \otimes X)$, $I \otimes \Sigma$) je náhodný vektor Y normálne rozdelený. Pri označení

$$S = (1/f) \sum_{i=1}^{f+1} (Y_i - \bar{Y})(Y_i - \bar{Y})', \quad \bar{Y} = [1/(f+1)] \sum_{i=1}^{f+1} Y_i$$

a na predpokladu $f \geq R(\Sigma)$ (hodnosť), platí:

$$(1) \quad \{X[(X')_{m(S)}^{-1}]' \bar{Y}\}^{(p)} \sim N(X\beta, 1 + \frac{1}{f} T_2'(Z' S Z)^{-1} T_2 \Lambda_{11.2}),$$

kie

$$M(Z) = \text{Ker}(X'), \quad T_2 = Z' \bar{Y},$$

$$\Lambda = \begin{bmatrix} X X' \Sigma (X')' X' / (f+1) & X X' \Sigma Z / (f+1) \\ Z' \Sigma (X')' X' / (f+1) & Z' \Sigma Z / (f+1) \end{bmatrix} = \begin{bmatrix} \hat{\Lambda}_{11} & \hat{\Lambda}_{12} \\ \hat{\Lambda}_{21} & \hat{\Lambda}_{22} \end{bmatrix},$$

$$\hat{\Lambda}_{11.2} = \hat{\Lambda}_{11} - \hat{\Lambda}_{12} \hat{\Lambda}_{22}^{-1} \hat{\Lambda}_{21}, \quad (X')_{m(S)}^{-1} \text{ je minimum } S\text{-seminorm g-inverzia matice } X' \text{ a (p) označuje } (T_2, \hat{\Lambda}_{22} = Z' S Z / (f+1))\text{-podmienenosť;}$$

(2) ak označíme $X[(X')_{m(S)}^{-1}]' \bar{Y} = \hat{X}\hat{\beta}$, potom $f(\bar{Y} - \hat{X}\hat{\beta})' S^{-1}(\bar{Y} - \hat{X}\hat{\beta})$ je náhodná premenná s rozdelením pravdepodobnosti $[f(C - v_1)/(v_1 + f - C + 1)]$.

$$\cdot F_{f(C-v_1), (v_1+f-C+1)}, \text{ kde } C = R(\Sigma), v_1 = R\left(\left[\Sigma / (f+1)\right] \left\{ [\Sigma / (f+1)] + X X'\right\}^{-1} X\right);$$

(3) náhodná premenná $\langle (\hat{X}\hat{\beta} - X\beta)' \{X[(X')_{m(S)}^{-1}]' S\}^{-1} (\hat{X}\hat{\beta} - X\beta) / (1 + \frac{1}{f} \hat{V}' S^{-1} \hat{V}) \rangle$.
• $[f - (C - v_1)]/f$ má rozdelenie pravdepodobnosti

$$[f - (C - v_1)] \frac{1}{f - C + 1} F_{v_1, f-C+1},$$

pričom $\hat{V} = \bar{Y} - \hat{X}\hat{\beta}$;

$$(4) \quad \text{Var}(\hat{X}\hat{\beta}) = X[(X')_{m(S)}^{-1}]' \Sigma \frac{1}{f+1} \frac{f-1}{v_1 + f - C - 1}.$$

Dôkaz. Pozri lemu 2.1, lemu 2.2, teoremu 2.1, teoremu 2.2, lemu 2.3 a teoremu

2.3 v [4].

Poznámka 3.1. Predchádzajúcu teoremu možno využiť pre všetky v praxi sa vyskytujúce regulárne verzie regresného modelu ([3] str.127-138). Na pr. v modeli (5.model v [3] str.126): $E(\tilde{\xi}) = A_{n,k} \otimes$, $\Sigma \tilde{\xi} = \sigma^2 H_{n,n}/(f+1)$, $b + B_{q,n} \otimes = 0$, kde $R(A) = k \leq n$,

$R(H) = n$, $R(B) = q \leq k$, platí

$$\hat{\beta} = \{(A'S^{-1}A)^{-1} - (A'S^{-1}A)^{-1}B' [B(A'S^{-1}A)^{-1}B']^{-1} B(A'S^{-1}A)^{-1}\} A'S^{-1} \tilde{\xi} - \\ - (A'S^{-1}A)^{-1}B [B(A'S^{-1}A)^{-1}B']^{-1} b$$

$$\text{Var}(\hat{\beta}) = \{(A'S^{-1}A)^{-1} - (A'S^{-1}A)^{-1}B' [B(A'S^{-1}A)^{-1}B']^{-1} B(A'S^{-1}A)^{-1}\} \cdot \\ \cdot \frac{1}{f+1} \frac{f-1}{f - (n - k + q) - 1}.$$

Poznámka 3.2. Ak v zmiešanom regresnom modeli $(Y, X\beta, \Sigma = \sum_{i=1}^p \lambda_i V_i)$ parametre $\lambda_1, \dots, \lambda_p$ ($p \geq 2$) nepoznáme, môžeme na základe vektora Y vo všeobecnosti určiť len λ_0 -lokálne najlepší odhad vektora $X\beta$ vzťahom

$$\widehat{X\beta} = X \left[(X')^{-1} \sum_{i=1}^p \lambda_i v_i \right] Y.$$

Pre niektoré funkcionály $f(\cdot) : \mathbb{R}^k \rightarrow \mathbb{R}$, $f(\beta) = f' \beta$, však môže existovať Σ -rovnomerne najlepší odhad (t.zn. rovnomerne najlepší vzhľadom k triede

$$\underline{\Sigma} = \left\{ \Sigma : \Sigma = \sum_{i=1}^p \lambda_i v_i v_i' \right\}.$$

Theorema 3.4. Nech $E(Y) = X\beta$, $\text{Var}(Y) = \Sigma \in \underline{\Sigma} = \left\{ \Sigma : \Sigma = \sum_{i=1}^p \lambda_i v_i v_i', \lambda \in \mathbb{R}^p \right\}$.

$\beta \in \mathbb{R}^k$. Nech ďalej Σ_0 je matica s vlastnosťou

$\forall \{\Sigma \in \underline{\Sigma}\} \mu(\Sigma) \subset \mu(\Sigma_0) \& \forall \{\Sigma_1 : \Sigma_1 \text{ je pozitívne semidefinitná matica s vlastnosťou } \mu(\Sigma) \subset \mu(\Sigma_1), \Sigma \in \underline{\Sigma}\} \mu(\Sigma_0) \subset \mu(\Sigma_1)$.

Potom platí: Ak $a \in \mu(W)$, kde $W = \Sigma_0 + XX'$, tak $a'Y$ je Σ -rovnomerne najlepší lineárny odhad funkcie $f(\beta) = a'X\beta$, $\beta \in \mathbb{R}^k$, práve vtedy ak

$$a \in \mu\left(W^+ X \text{ Ker}\left[X' W^{-1} \sum_{i=1}^p v_i M v_i W^{-1} X\right]\right),$$

kde $M = I - X(X'X)^{-1}X'$. (Tu W^+ je Mooreova-Penroseova inverzia matice W a $(X'X)^{-1}$ je g-inverzia matice $X'X$.)

Dôkaz. Pozri [17].

Poznámka 3.3. Pri odhadovaní funkcie $f(\beta) = f' \beta$, $\beta \in \mathbb{R}^k$, kde $f \in \mu(X')$ sa stačí obmedziť na odhady $a'Y$, kde $a \in \mu(W)$.

Theorema 3.5. Nech $E(Y) = X\beta$, $\beta \in \mathbb{R}^k$, $\text{Var}(Y) = \Sigma \in \underline{\Sigma} = \left\{ \sum_{i=1}^p \lambda_i v_i v_i', \lambda \in \mathbb{R}^p \right\}$. Pre funkciu $f(\beta) = c'\beta$, $\beta \in \mathbb{R}^k$, existuje Σ -rovnomerne najlepší lineárny odhad práve vtedy, ak

$$c \in \mu\left(X' W^{-1} X \text{ Ker}\left[X' W^{-1} \sum_{i=1}^p v_i M v_i W^{-1} X\right]\right)$$

(symbol W je definovaný v teóreme 3.4).

Dôkaz. Pozri [17].

4. Odhad parametrov ϑ

Theorema 4.1. V zmicšanom regresnom modeli $E(Y) = X\beta$, $\beta \in \mathbb{R}^k$, $\text{Var}(Y) = \Sigma \in \underline{\Sigma} = \left\{ \sum_{i=1}^p \lambda_i v_i v_i', \lambda \in \mathbb{R}^p \right\}$ je funkcia $g(\vartheta) = g'\vartheta$, $\vartheta \in \mathbb{R}^p$, nevyhýlene odhadnuteľná práve vtedy, ak $g \in \mu(K_0)$, kde $\{K_0\}_{i,j} = \text{Tr}(V_i V_j - P V_i P V_j)$, $i, j = 1, \dots, p$, $P = X(X'X)^{-1}X'$.

Dôkaz. Pozri v [15].

Definícia 4.1. V zmicšanom regresnom modeli odhad $Y'A Y$ nazveme invariantným, ak $\forall \{\delta \in \mathbb{R}^k\} (Y - X\delta)' A (Y - X\delta) = Y'A Y$.

Lema 4.1. Nech Y je náhodný vektor s danou distribučnou funkciou, $E(Y) \in \mu(X)$, kde X je daná matica a $\text{Var}(Y) = \Sigma$. Nech ďalej

$$\mathcal{T}_1 = \left\{ Y'A Y : A = A', X'A X = 0, X'A \Sigma = 0 \right\}$$

$$\mathcal{T}_2 = \left\{ Y'A Y : A = A', X'A = 0 \right\}.$$

Potom pre každú náhodnú premennú $Y'A_1 Y \in \mathcal{T}_1$ existuje náhodná premenná $Y'A_2 Y \in \mathcal{T}_2$, pre ktorú platí $P\{Y'A_1 Y = Y'A_2 Y\} = 1$.

Dôkaz. Zrejmé $\mathcal{T}_2 \subset \mathcal{T}_1$. Nech $Y'A_1 Y \in \mathcal{T}_1$. Potom $Y'MA_1 MY \in \mathcal{T}_2$ ($M = I - X(X'X)^{-1}X'$). Cznačme $\epsilon = Y - E(Y)$. Pre ϵ platí: $P\{\epsilon \in \mu(\Sigma)\} = 1$. Pre náhodnú premennú $Y'A_1 Y$ teda platí

$$Y'A_1 Y = \epsilon'A_1 \epsilon \quad \text{skoro iste (s.i.)},$$

protože

$$\epsilon'A_1 E(Y) = 0 \quad \text{s.i.}$$

$$E(Y')A_1 \epsilon = 0 \quad \text{s.i.}$$

$$E(Y')AE(Y) = 0 \quad \text{s.i.}.$$

Pre náhodnú premennú $Y'MA_1 MY$ platí

$\mathbf{Y}' \mathbf{M} \mathbf{A}_1 \mathbf{M} \mathbf{Y} = \mathbf{E}' \mathbf{M} \mathbf{A}_1 \mathbf{M} \mathbf{E} = \mathbf{E}' (\mathbf{I} - \mathbf{P}) \mathbf{A}_1 (\mathbf{I} - \mathbf{P}) \mathbf{E} = \mathbf{E}' \mathbf{A}_1 \mathbf{E}$ s.i.,
protože $\mathbf{E}' \mathbf{P} \mathbf{A}_1 \mathbf{E} = 0$ s.i., $\mathbf{E}' \mathbf{A}_1 \mathbf{P} \mathbf{E} = 0$ s.i., $\mathbf{E}' \mathbf{P} \mathbf{A}_1 \mathbf{P} \mathbf{E} = 0$ s.i.. (Tu $\mathbf{P} = \mathbf{X}(\mathbf{X}' \mathbf{X})^{-1} \mathbf{X}'$.)

Teda

$$\mathbf{Y}' \mathbf{A}_1 \mathbf{Y} \stackrel{s.i.}{=} \mathbf{Y}' \mathbf{M} \mathbf{A}_1 \mathbf{M} \mathbf{Y} \in \mathcal{T}_2.$$

Pomocou lemy 4.1 možno dokázať nasledujúcu teorému.

Teoréma 4.2. V zmiešanom regresnom modeli je funkcia $g(\mathbf{J}) = g' \mathbf{J}$, $\mathbf{J} \in \mathcal{J}$, nevyčílené a invariantne odhadnuteľné práve vtedy, ak $g \in \mathcal{U}(K_0^{(I)})$, kde $\{K_0^{(I)}\}_{i,j} =$
 $= \text{Tr}(\mathbf{M} \mathbf{V}_i \mathbf{M} \mathbf{V}_j)$, $i, j = 1, \dots, p$.

Teoréma 4.3. V zmiešanom regresnom modeli pre \mathbf{J}_0 -lokálne najlepší nevyčílený a invariantný odhad funkcie $g(\mathbf{J}) = g' \mathbf{J}$, $\mathbf{J} \in \mathcal{J}$, kde $g \in \mathcal{U}(K_0^{(I)})$ a $\Sigma_0 = \sum_{i=1}^p \mathbf{J}_i \mathbf{V}_i$ je regulárna, v prípade normality vektoru \mathbf{Y} , je

$$\widehat{g' \mathbf{J}} = \mathbf{Y}' \sum_{i=1}^p \lambda_i [\Sigma_0^{-1} - \Sigma_0^{-1} \mathbf{X} (\mathbf{X}' \Sigma_0^{-1} \mathbf{X})^{-1} \mathbf{X}' \Sigma_0^{-1}] \mathbf{V}_i [\Sigma_0^{-1} - \Sigma_0^{-1} \mathbf{X} (\mathbf{X}' \Sigma_0^{-1} \mathbf{X})^{-1} \mathbf{X}' \Sigma_0^{-1}] \mathbf{Y}.$$

Koeficienty $\lambda_1, \dots, \lambda_p$ sú riešením systému

$$S_{(M \Sigma_0 M)^+} \lambda = g,$$

kde

$$\left\{ S_{(M \Sigma_0 M)^+} \right\}_{i,j} = \text{Tr} [(M \Sigma_0 M)^+ \mathbf{V}_i (M \Sigma_0 M)^+ \mathbf{V}_j], \quad i, j = 1, \dots, p,$$

a

$$(M \Sigma_0 M)^+ = \Sigma_0^{-1} - \Sigma_0^{-1} \mathbf{X} (\mathbf{X}' \Sigma_0^{-1} \mathbf{X})^{-1} \mathbf{X}' \Sigma_0^{-1}.$$

Dôkaz. Pozri [1].

Teoréma 4.4. V zmiešanom regresnom modeli (β_0, \mathbf{J}_0) -lokálne najlepší nevyčílený odhad funkcie $g(\mathbf{J}) = g' \mathbf{J}$, $\mathbf{J} \in \mathcal{J}$, kde $g \in \mathcal{U}(K_0)$ a $\Sigma_0 = \sum_{i=1}^p \mathbf{J}_i \mathbf{V}_i$ je regulárna, je

$$\widehat{g' \mathbf{J}} = (\mathbf{Y} - \mathbf{X} \beta_0)' \sum_{i=1}^p \lambda_i A_i (\mathbf{Y} - \mathbf{X} \beta_0),$$

$A_i = \Sigma_0^{-1} \mathbf{V}_i \Sigma_0^{-1} - \Sigma_0^{-1} \mathbf{X} (\mathbf{X}' \Sigma_0^{-1} \mathbf{X})^{-1} \mathbf{X}' \Sigma_0^{-1} \mathbf{V}_i \Sigma_0^{-1} \mathbf{X} (\mathbf{X}' \Sigma_0^{-1} \mathbf{X})^{-1} \mathbf{X}' \Sigma_0^{-1}$, $i = 1, \dots, p$ a koeficienty $\lambda_1, \dots, \lambda_p$ sú riešením sústavy

$$\sum_{i=1}^p \lambda_i \text{Tr}(A_i \mathbf{V}_j) = g_j, \quad j = 1, \dots, p.$$

Poznámka 4.1. Pretože $\mathcal{U}(K_0^{(I)}) \subset \mathcal{U}(K_0)$ môže byť nevyčílený odhad funkcie $g(\cdot)$

lepší než invariantný a nevyčílený odhad. Ďalej môže nastať prípad, že nevyčílený odhad existuje, hoci nevyčílený a invariantný odhad neexistuje. Je preto potrebné uvážiť volbu odhadu v konkrétnej situácii.

Podmienky pre existenciu (β, \mathbf{J}) -rovnomerne najlepších nevyčílených odhadov sú pomerne zložité. Ukažuje to nasledujúca teoréma.

Teoréma 4.5. V zmiešanom regresnom modeli $(\mathbf{Y}, \mathbf{X} \beta, \Sigma = \sum_{i=1}^p \mathbf{J}_i \mathbf{V}_i)$ označme $\mathcal{V} = \text{span}\{\mathbf{V}_1, \dots, \mathbf{V}_p\}$; ďalej pre libovoľné $\mathbf{V}_0 \in \mathcal{V}$, kde \mathbf{V}_0 je pozitívne definitná definujme:

$$\mathcal{A} = \left\{ d \in \mathcal{U}(\mathbf{X}) : \mathbf{V} \mathbf{V}_0^{-1} d \in \mathcal{U}(\mathbf{X}), \mathbf{V} \in \mathcal{V} \right\}$$

a lineárny podpriestor \mathcal{L} priestoru symetrických matíc $\mathcal{P}_n = \{A : A = A'$, A je typu $n \times n\}$

$$\mathcal{L} = \{G : \forall \{\mathbf{V} \in \mathcal{V}\} \exists \{G_V \in \mathcal{V}\} \quad \mathbf{M} \mathbf{V} \mathbf{M} (\mathbf{M} \mathbf{V}_0 \mathbf{M})^+ G (\mathbf{M} \mathbf{V}_0 \mathbf{M})^+ \mathbf{M} \mathbf{V} \mathbf{M} = \mathbf{M} G_V \mathbf{M} \quad \& \quad \mathbf{M} G_V \mathbf{V}^{-1} \mathbf{X} = 0\}.$$

Potom $a' \mathbf{Y} + \mathbf{Y}' \mathbf{A} \mathbf{Y}$, kde $a = \mathbf{V}_0^{-1} d$, $d \in \mathcal{A}$ a $\mathbf{A} = (\mathbf{M} \mathbf{V}_0 \mathbf{M})^+ G (\mathbf{M} \mathbf{V}_0 \mathbf{M})^+$, $G \in \mathcal{L}$, je (β, \mathbf{J}) -rovnomerne najlepší nevyčílený odhad svojej strednej hodnoty

$$E(a' \mathbf{Y} + \mathbf{Y}' \mathbf{A} \mathbf{Y}) = a' \mathbf{X} \beta + \sum_{i=1}^p \mathbf{J}_i \text{Tr}(A \mathbf{V}_i).$$

Dôkaz. Pozri [1] teorema 2.5.

Teoréma 4.6. Nech v replikovanom zmiešanom regresnom modeli $\mathbf{Y} = (Y'_1, \dots, Y'_{k+1})' \sim \sim_{N(k+1)m}[(1 \otimes \mathbf{X}) \beta, I \otimes \Sigma]$ platí: $\Sigma = \sum_{i=1}^m \mathbf{V}_i \mathbf{V}_i'$, $(\mathbf{V}_1, \dots, \mathbf{V}_m)' = \mathbf{V} \in \mathcal{V}_*$ $\subset \mathbb{R}^m$, pričom

existuje uzavretá guľa vnorená do \mathcal{V}_s , $\beta \in \mathbb{R}^s$ a matica $V^{(\tau)} = \sum_{i=1}^m \tau_i V_i$ je pre uvažovaný bod $\tau \in \mathcal{V}_s$ regulárna. Označme

$$S = (1/k) \sum_{j=1}^{k+1} (Y_j - \bar{Y})(Y_j - \bar{Y})', \quad \bar{Y} = [1/(k+1) \sum_{j=1}^{k+1} Y_j], \quad \{M^{(\tau)}\}_{i,j} = \text{Tr}(V_i [V^{(\tau)}]^{-1} V_j [V^{(\tau)}]^{-1})$$

$i, j = 1, \dots, m$.

Potom platí

(1) Pre funkciu $g(\cdot) : \mathcal{V}_s \rightarrow \mathbb{R}^1$, kde $g(v) = \lambda' v$, $v \in \mathcal{V}_s$, existuje v triede $\mathcal{A} = \{\text{Tr}(AS) : A \in \mathcal{P}_n\}$ nevychýlený odhad práve vtedy, ak $\lambda \in \mathcal{U}(M^{(\tau)}) = \mathcal{U}(K)$, kde $\{K\}_{i,j} = \text{Tr}(V_i V_j)$, $i, j = 1, \dots, m$.

(2) Ak v triede \mathcal{A} existuje nevychýlený odhad pre funkciu $g(\cdot)$, potom τ -lokálne najlepší odhad v tejto triede je

$$\tilde{\tau}_g(S) = \text{Tr} \left(\sum_{j=1}^m \alpha_j [V^{(\tau)}]^{-1} V_j [V^{(\tau)}]^{-1} S \right),$$

kde vektor $\alpha = (\alpha_1, \dots, \alpha_m)'$ je riešením sústavy

$$M^{(\tau)} \alpha = \lambda.$$

(3) Disperzia odhadu $\tilde{\tau}_g(S)$ obsahuje v bode τ dolnú Raovu-Cramérovu hranicu

$$\mathcal{D}[\tilde{\tau}_g(S)] = (2/k) \text{Tr} \left(\sum_{i=1}^m \alpha_i [V^{(\tau)}]^{-1} V_i [V^{(\tau)}]^{-1} \sum_{j=1}^m \alpha_j [V^{(\tau)}]^{-1} V_j [V^{(\tau)}]^{-1} V_i \right) = \\ = (2/k)^2 \alpha' F(\tau) \alpha = \lambda' F^{-1}(\tau) \lambda,$$

$$\text{kde } \{F(\tau)\}_{i,j} = (k/2) \text{Tr}([V^{(\tau)}]^{-1} V_i [V^{(\tau)}]^{-1} V_j) = (k/2) \{M^{(\tau)}\}_{i,j}.$$

Dôkaz. Pozri v [5].

Teóra 4.7. Nech v replikovanom zmiešanom regresnom modeli $Y = (Y'_1, \dots, Y'_m)' \sim \sim \mathcal{N}_{nm}[(I \otimes X)\beta, \Sigma = I \otimes \Sigma = \sum_{i=1}^p \mathfrak{J}_i(I \otimes V_i)]$ je $V = \sum_{i=1}^p \mathfrak{J}_{i0} V_i$ regulárna a $S = [1/(m-1)] \sum_{i=1}^m (Y_i - \bar{Y})(Y_i - \bar{Y})'$, $\bar{Y} = (1/m) \sum_{j=1}^m Y_j$. Potom \mathfrak{J}_0 -lokálne najlepší invariantný a nevychýlený odhad (založený na vektore Y) funkcie $g(\mathfrak{J}) = f' \mathfrak{J}$, $\mathfrak{J} \in \mathfrak{J}$, kde $g(\cdot)$ je nevychýlene a invariantne odhadnuteľná, má tvar

$$\tilde{\tau}_g(Y) = \sum_{i=1}^p \lambda_i \left\{ (m-1) \text{Tr}(V^{-1} V_i V^{-1} S) + m \bar{Y}' (MVM)^+ V_i (MVM)^+ \bar{Y} \right\},$$

pričom vektor $\lambda = (\lambda_1, \dots, \lambda_p)'$ je riešením sústavy

$$[(m-1)S_{V^{-1}} + S_{(MVM)^+}] \lambda = f,$$

$$\{S_{V^{-1}}\}_{i,j} = \text{Tr}(V^{-1} V_i V^{-1} V_j), \quad i, j = 1, \dots, p, \quad \{S_{(MVM)^+}\}_{i,j} = \text{Tr}[(MVM)^+ V_i (MVM)^+ V_j], \quad i, j = 1, \dots, p.$$

Dôkaz. Pozri [1].

Poznámka 4.2. Vztah medzi odhadmi z posledných dvoch teorém je analyzovaný v [7].

LITERATÚRA

- [1] Kleffe, J.: Simultaneous estimation of expectation and covariance matrix in linear models. *Math. Oper. Statist. Ser. Statist.* 9, 1978, 443-478.
- [2] Kleffe, J.: C.R. Rao's MINQUE for replicated and multivariate observations. *Tech. Rept. Zimm der AdW der DDR* 1979, Berlin.
- [3] Kubáček, L.: Základy teórie odhadu. Bratislava, Veda 1983.
- [4] Kubáček, L.: Regression model with estimated covariance matrix. *Math. Slovaca* 33, 1983, 395-408.

- [5] Kubáček, L.: Repeated regression experiment and estimation of variance components. Math.Slovaca 34, 1984, 103-114.
- [6] Kubáček, L.: Estimation of covariance components in a repeated regression experiment. Math.Slovaca 34, 1984, 155-164.
- [7] Kubáček, L.: Note to C.R.Rao's MINQUE for replicated observations. Math.Slovaca (v tlači).
- [8] Kubáček, L.: Reliability of calculations in the linear estimation and some problems of the analysis of a multistage regression experiment. In: Compstat '84, Proceedings in computational statistics, str.214-224, Wien, Physica Verlag 1984.
- [9] Kubáček, L.: Locally best quadratic estimators. Math.Slovaca (v tlači).
- [10] Kubáček, L.: Multistage regression model (zaslané do Aplikace matematiky).
- [11] Pincus, R.: Estimability of parameters of the covariance matrix and variance components. Math.Oper.Statist.5, 1974, 245-248.
- [12] Rao, C.R.: Least squares theory using an estimated dispersion matrix and its application to measurement of signals. In: Proc. Fifth Berkeley Symposium, Vol.I., 1967, 355-372.
- [13] Rao, C.R.: Estimation of variance and covariance components. J.Multivariate Anal. 1, 1871, 257-275.
- [14] Rao, C.R., Mitra, S.K.: Generalized Inverse of Matrices and Its Applications. N.York, J.Wiley 1972.
- [15] Rao, C.R., Kleffe, J.: Estimation of variance components. In: Krisnaiah, P.R., ed. Handbook of Statistics, Vol.I., str.1-40, N.York, North Holland 1980.
- [16] Volaufová, J., Kubáček, L.: Locally and uniformly best estimators in replicated regression model. Aplikace matematiky 28, 1983, 386-390.
- [17] Zmyšlony, R.: A characterization of best linear unbiased estimators in the general linear model. Institut of Mathematics, Polish Academy of Sciences, 1978, Preprint 159.