

**ŠTATISTICKÉ VLASTNOSTI MNS - ODHADOV VARIANČNÝCH KOMPONENTOV  
V ZMIEŠANOM LINEÁRNOHOM MODELI**

Júlia Volaufová, Viktor Witkovský

Zmiešaný lineárny model je všeobecne uvádzaný v literatúre v nasledujúcom tvare

$$Y = X\beta + U_1\xi_1 + \dots + U_{p-1}\xi_{p-1} + \varepsilon,$$

kde  $Y$  je  $n$ -rozmerný vektor pozorovaní,  $\beta$  je  $k$ -rozmerný neznámy vektorový parameter;  $\xi_i$   $i=1, \dots, p-1$  sú  $n_i$  rozmerné náhodné vektory (náhodné efekty), ktoré spĺňajú predpoklad

$$E(\xi_i) = 0, \quad E(\xi_i \xi_i') = \sigma_i^2 I_{n_i} \quad i=1, \dots, p-1$$

$\varepsilon$  je  $n$ -rozmerný vektor chýb, pre ktorý platí rovnako  $E(\varepsilon) = 0$ ,  $E(\varepsilon \varepsilon') = \sigma_p^2 I_p$ . Matice  $X, U_1, \dots, U_{p-1}$  sú známe nenáhodné matice a  $\sigma_1^2, \dots, \sigma_p^2$  sú neznáme konštantné parametre. Vo všeobecnosti je to model s variančno - kovariančnými komponentami v tvare

$$(1) \quad (Y, X\beta, \sum_{i=1}^p \theta_i V_i), \text{ pričom}$$

cieľ je odhadnúť lineárnu funkciu parametra  $\theta = (\theta_1, \dots, \theta_p)'$ :

$$f(\theta) = f' \theta = \sum_{i=1}^p f_i \theta_i.$$

Tento problém je historicky nie nový a na jeho riešenie existuje niekoľko rôznych prístupov. Najznámejší je klasický prístup - vytvoriť kvadratický odhad  $Y'AY$ , môže spĺňať rôzne požiadavky, ako sú nevychýlenosť, invariantnosť, lokálne najlepší nevychýlený odhad (v zmysle minimálnej disperzie) alebo odhady typu MINQUE. Uvedené metódy je možné nájsť napr. v Rao (1971, 1972), Rao, Kleffe (1980), Kubáček (1985), Rao, Kleffe (1988) a v mnohých ďalších publikáciách.

Zaujímavý je prípad založený na lineárnom modeli v závislej premennej  $\text{vec } YY'$  - vektore vytvorenom zo stĺpcov symetrickej matice  $YY'$  ich usporiadaním pod seba. (Pozri napr. Verdooren (1979, 1988)).

Model má tvar:

$$(2) \quad E(\text{vec } YY') = (X \otimes X, \text{vec } V_1, \dots, \text{vec } V_p) \begin{bmatrix} \text{vec } \beta\beta' \\ \theta_1 \\ \vdots \\ \theta_p \end{bmatrix} = Z\xi$$

Operácia " $\otimes$ " je Kroneckerov súčin matic; matice  $Z$  je známa matice typu  $n^2 \times (k^2 + p)$ . Parameter  $\xi$  je  $k^2 + p$  rozmerný, kde  $\text{vec } \beta\beta'$  považujeme za rušivý. Keďže odhadujeme lineárnu funkciu parametrov druhého rádu, je prirodzené požadovať, aby odhad bol invariantný vzhľadom na posun v strednej hodnote. Odhad  $T(Y)$  je invariantný práve vtedy, keď  $T(Y) = T(Y + X\beta)$  pre všetky  $\beta \in R^k$ . Maximálnym invariantom, t.j. štatistika založená na vektore  $Y$  je vektor  $MY$ , kde  $M = I - P_X$  je projektor na ortogonálny komplement stĺpcového priestoru matice  $X$ ,  $P_X = X(X'X)^{-1}X'$ . Vytvoríme transformovateľný model, založený na vektore  $M \otimes M \text{vec } YY'$  v tvare:

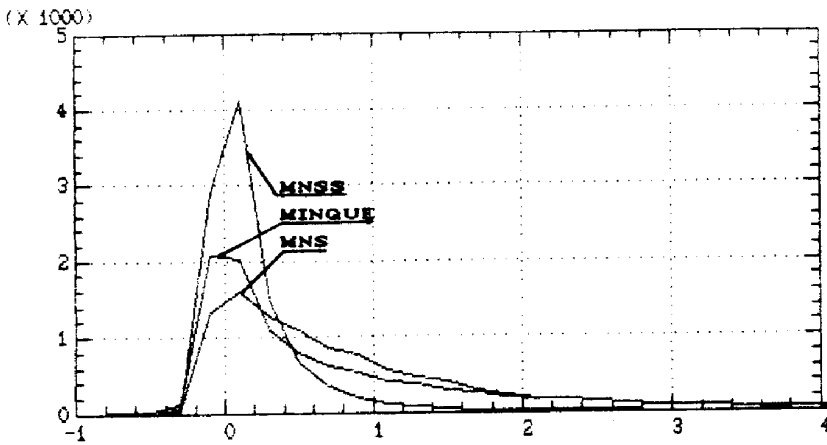
$$(3) \quad E(M \otimes M \text{vec } YY') = ( \text{vec } MV_1M, \dots, \text{vec } MV_pM ) \theta = Q\theta.$$

V modeli (3) sa stratila závislosť na rušivom parametri  $\text{vec } \beta\beta'$ . Odhady založené na vektore  $M \otimes M \text{vec } YY'$  sú invariantné. Z teórie lineárnych modelov je známe, že nutná a postačujúca podmienka pre nevychýlenú odhadnuteľnosť funkcie  $f' \theta$  je  $f \in RC(Q'Q)$ , kde  $RC(\cdot)$  je stĺpcový priestor matice  $Q'Q$ .


$(Q'Q)_{ij} = \text{tr } MV_i MV_j'$ , čo je totožné s nutnou a postačujúcou podmienkou pre nevychýlenú invariantnú a kvadratickú odhadnuteľnosť funkcie  $f' \theta$ .

Nevychýlený a invariantný MNS odhad má tvar:


$$(4) \quad f' \theta = f'(Q'Q)^+ Q' M \otimes M \text{vec } YY' = \sum_{i=1}^p \alpha_i Y' MV_i MY, \text{ kde } Q'Q \alpha = f.$$



Obr. 1. Model 1, odhadovaný parameter  $\theta_1 = 0.81$ , MINQUE-odhadnuteľnú funkciu normálne rozdelenie.



Obr. 2. Model 1, odhadovaný parameter  $\theta_1 = 0.81$ , transformované Studentovo rozdelenie.



Obr. 3. Model 1, odhadovaný parameter  $\theta_1 = 0.81$ , transformované gama rozdelenie.

Odhad (4) vo všeobecnosti nemá žiadne vlastnosti optimality (v zmysle minimálnej disperzie) je však veľmi jednoduchý vzhľadom na výpočtovú náročnosť a nezávisí od vopred zvolenej hodnoty neznámeho parametra  $\theta$  tak, ako odhad typu MINQUE.

MINQUE odhad (Minimum Norm Quadratic Unbiased Estimator), ktorý je invariantný, je pre  $f'(\theta)$  tvaru:

(5)

$$f'(\theta) = \sum_{i=1}^p \tau_i Y' (C V_0 D)^+ V_i (C V_0 D)^+ Y,$$

kde  $V_0 = V(\theta_0) = \sum_{i=1}^p \theta_{i0} V_i$  pre vopred zvolenú hodnotu  $\theta_0 = (\theta_{10}, \dots, \theta_{p0})'$  a "+" je Moore-Penroseova inverzia matice. Zároveň platí, funkcia  $f'(\theta)$  je MINQUE odhadnuteľná práve vtedy, ak  $f \in R(C'W'W)$ , kde  $(C'W'W)_{ij} = \text{tr}(C V_0 D)^+ V_i (C V_0 D)^+ V_j$ , z čoho ďalej platí  $W'W\tau = f$ .

Odhady (4) a (5) sú oba nevychýlené a invariantné, zároveň odhad (5) je v prípade normálneho rozdelenia vektora  $Y$  lokálne najlepší v bode  $\theta_0$ .

Okrem predchádzajúcich dvoch Štulajter (1989) navrhol iný prístup k odvodeniu odhadu. Utvoril najprv MNS-odhad parametra  $\beta$ :

$\hat{\beta} = (X'X)^{-1}X'Y$  a na základe  $\hat{\beta}$  položil

$$(6) \quad V = (Y - X\hat{\beta})(Y - X\hat{\beta})',$$

teda  $V$  je "prirodzený" odhad celej kovariančnej matice  $V(\theta)$ . Štruktúra kovariančnej matice  $V(\theta)$  je však známa, preto je prirodzené za odhad  $\hat{V}(\theta)$  považovať projekciu matice  $V$  do lineárneho priestoru

vytvoreného množinou

$\mathcal{V} = \{ V(\theta), \theta \in \Theta \}$ . Z uvedenej myšlienky dostávame

$$(7) \quad f' \theta = \sum_{i=1}^p \alpha_i Y' M V_i M Y, \text{ kde}$$

$G\alpha = f$ , pričom  $(G)_{ij} = \text{tr } V_i V_j$ .

Odhad (7) na rozdiel od odhadov (4) a (5) nie je nevychýlený, len invariantný. V špeciálnom prípade, keď matice  $V_i$  sú navzájom ortogonálne Štulajter dokázal konzistenciu odhadu (7).

Je prirodzené položiť si otázku, ako sa tieto odhady (4), (5) a (7) chovajú navzájom, aké majú štatistické vlastnosti, vzhľadom na jednoduchosť výpočtov odhadov (5) a (7).

V našej simulačnej štúdii sme porovnali uvedené odhady v nasledujúcich situáciách. V dvoch rôznych modeloch sa simulovalo 10 000 realizácií vektora  $Y$  pre normálne rozdelenie, transformované Studentovo a gama rozdelenie s parametrami:

1. MODEL

$$Y = X\beta + U_1 \xi_1 + U_2 \xi_2 + \varepsilon, \text{ kde}$$

$Y$  je  $n=24$  -rozmerný vektor, matice  $X_{(24 \times 4)}$ ,  $U_{1, (24 \times 2)}$ ,  $U_{2, (24 \times 6)}$  a vektor  $\beta_{(4)}$  sú dané. Skutočná hodnota parametra  $\theta_{(3)}$ , použitá pri generovaní je  $\theta = (0.81, 0.64, 0.36)'$ .

Pre generované vektory  $\xi_{1, (2)}$ ,  $\xi_{2, (6)}$ ,  $\varepsilon_{(24)}$  platí:

$$E(\xi_i) = 0, \quad i=1,2; \quad E(\varepsilon) = 0,$$

$$\text{Var}(\xi_i) = \theta_i I, \quad i=1,2 \quad \text{Var}(\varepsilon) = \theta_3 I.$$


2. MODEL

$$Y = X\beta + \sum_{i=1}^{p-1} U_i \xi_i + \varepsilon, \text{ kde}$$


$Y$  je  $n=12$  -rozmerný vektor, matice  $X_{(12 \times 3)}$ ,  $U_{i, (12 \times n_i)}$  a vektor  $\beta_{(3)}$  sú dané, pričom

$$n_1=2, \quad n_2=3, \quad n_3=4, \quad n_4=5, \quad n_5=6,$$


Skutočná hodnota para-




Obr. 4. Model1, odhadovaný parameter  $\theta_2=0.64$ , normálne rozdelenie.



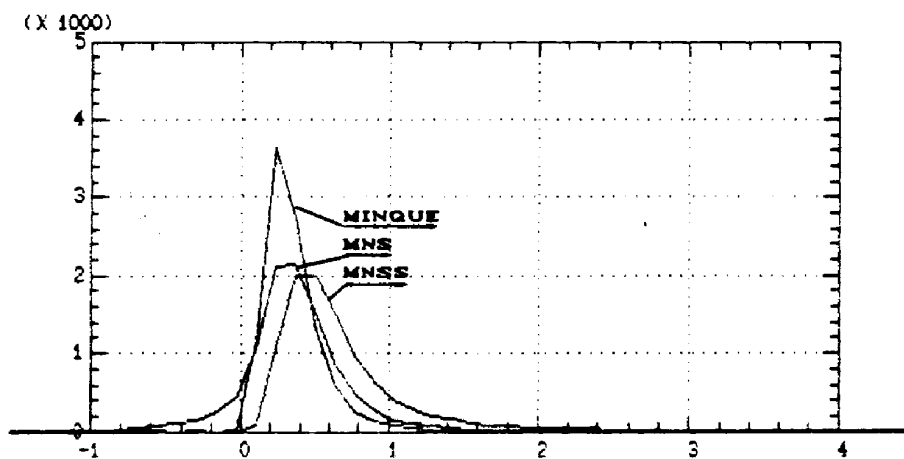
Obr. 5. Model1, odhadovaný parameter  $\theta_2=0.64$ , transformované Studentovo rozdelenie.




Obr. 6. Model1, odhadovaný parameter  $\theta_2=0.64$ , transformované gama rozdelenie.



Obr. 7. Model 1, odhadovaný parameter  $\theta_3 = 0.36$ , normálne rozdelenie.



Obr. 8. Model 1, odhadovaný parameter  $\theta_3 = 0.36$ , transformované Studentovo rozdelenie.



Obr. 9. Model 1, odhadovaný parameter  $\theta_3 = 0.36$ , transformované gama rozdelenie.

metra  $\theta_{(5)}$  pre generovanie je  $\theta = (0.25, 0.81, 1, 0.49, 0.36, 0.09)$ .  
Pre generované vektory  $\xi_{i, (n)}$ ,

$\epsilon_{(12)}$  platí:

$$E(\xi_i) = 0, \text{Var}(\xi_i) = \theta I_{i, (n)}$$

pre  $i = 1, \dots, 5$  a pre  $\epsilon$  platí

$$E(\epsilon) = 0, \text{Var}(\epsilon) = \theta I_{\epsilon_{(12)}}$$

Na obrázkoch 1. - 12. sú znázornené polygóny pre jednotlivé odhady: MINQUE, MNS, MNSS je odhad navrhnutý Stulajterom. Vo väčšine prípadov, okrem obr. 7. - 9. sa ukázalo, že napriek vychýlenosti MNSS odhad má výrazne menšiu strednú kvadratickú chybu (MSE) než MINQUE a MNS-odhad, ktoré sú nevychýlené. Vo všeobecnosti rozdelenie MINQUE ani iných kvadratických odhadov nie je známe, len v niektorých špeciálnych prípadoch a za predpokladu normality vektora  $Y$ . Z obrázkov je možné vidieť, že rozdelenia MINQUE a MNS sú si blízke v zmysle podobnosti polygónov.

Ukázalo sa tiež, že rozdelenia odhadov sú si blízke v uvedenom zmysle aj pre rôzne typy rozdelenia (symetrické, napr. Studentovo aj nesymetrické, napr. gama rozdelenie).

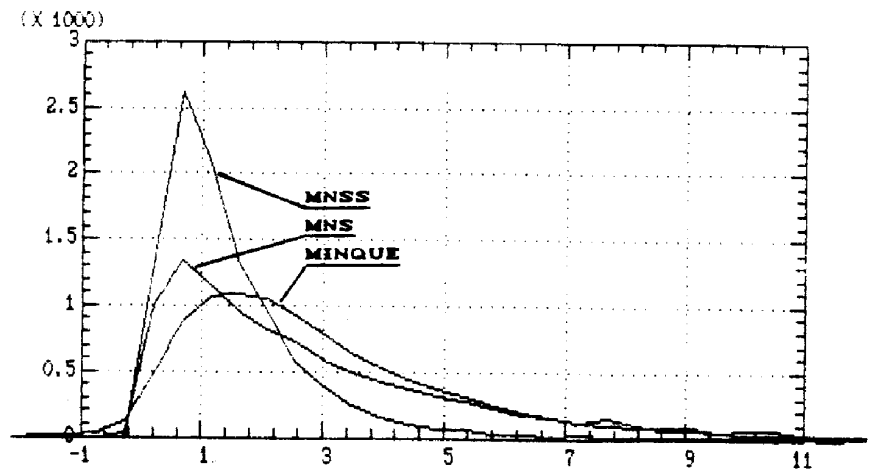
V tabuľkách 1. - 3. sú uvedené výberové priemery, disperzie a stredná kvadratická chyba odhadov parametrov  $\theta_1, \theta_2$  a  $\theta_3$ . V tabuľke 4 je to isté pre odhad funkcie  $f(\theta) = \sigma = \sum_{i=1}^5 \theta_i = 3.0$ .

Ako uzáver je možno povedať, že v situáciách, keď výpočtová náročnosť MINQUE odhadu je veľká (výpočet matice  $(MYM)^+$ ), je lepšie uprednostniť MNS alebo MNSS odhad, a to v závislosti od typu úlohy,


najmä v prípade odhadu lineárnej funkcie parametra  $\theta$ .

## L I T E R A T Ú R A

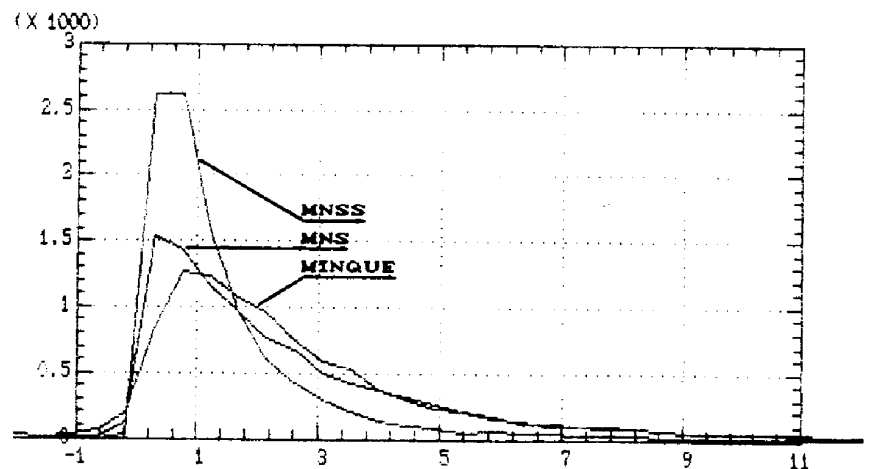
- [1] Kubáček, L.: Locally best quadratic estimators. Math. Slovaca 35, (1985), No. 4, pp. 393-408.
- [2] Rao, C. R.: Estimation of variance and covariance components-MINQUE theory. J. Multivar. Anal. 1, (1971), pp. 257-275.
- [3] Rao, C. R.: Estimation of variance and covariance components in linear models. JASA 67, (1972), pp. 112-115.
- [4] Rao, C. R., Kleffe, J.: Estimation of variance components. Handbook of Statistics, Vol. 1, P. R. Krishnaiah, ed., North Holland Pub. Comp., (1980) pp. 1-40.
- [5] Rao, C. R., Kleffe, J.: Estimation of variance components and applications. North Holland (1988) New York.
- [6] Verdooren, L. R.: Practical aspects of variance component estimation. Invited lecture for the 4th International Summer School on Problems of Model Choice and Parameter Estimation in Regression Analysis. 7th - 16th May 1979, Mulhausen, GDR.
- [7] Verdooren, L. R.: Least squares estimators and non-negative estimators of variance components. Commun. Statist.-Theory Meth., 17(4), (1988), pp. 1027-1051.



Obr.10. Model 2, odhadovaný parameter  $\theta=3.0$ , normálne rozdelenie.



Obr.11. Model 2, odhadovaný parameter  $\theta=3.0$ , transformované Studentovo rozdelenie.



Obr.12. Model 2, odhadovaný parameter  $\theta=3.0$ , transformované gama rozdelenie.

Parameter	Rozdelenie	Odhad	Priemer	Disperzia	MSE
$\theta_1 = 0.81$	Normálne	MI NQUE	0.8198	0.99417	0.4913
		MNŠ	0.8127	1.5680	
		MNŠŠ	0.1732	0.0858	
	Studentovo	MI NQUE	0.8027	20.0972	1.1627
		MNŠ	0.7630	13.3103	
		MNŠŠ	0.1613	0.7419	
Gama	MI NQUE	0.8115	4.0910	0.8030	
	MNŠ	0.8084	7.1408		
	MNŠŠ	0.1717	0.3956		

Tab. 1.

Parameter	Rozdelenie	Odhad	Priemer	Disperzia	MSE
$\theta_2 = 0.64$	Normálne	MI NQUE	0.6464	0.3736	0.4304
		MNŠ	0.6562	0.9082	
		MNŠŠ	0.0819	0.1189	
	Studentovo	MI NQUE	0.6309	0.9142	1.2337
		MNŠ	0.6240	1.9894	
		MNŠŠ	0.0667	0.9050	
Gama	MI NQUE	0.6250	0.9547	0.6268	
	MNŠ	0.6357	1.6542		
	MNŠŠ	0.0762	0.3089		

Tab. 2.

Parameter	Rozdelenie	Odhad	Priemer	Disperzia	MSE
$\theta_3 = 0.36$	Normálne	MI NQUE	0.3571	0.0191	0.4174
		MNŠ	0.3581	0.1425	
		MNŠŠ	0.7929	0.2300	
	Studentovo	MI NQUE	0.3573	0.0508	4.3214
		MNŠ	0.3578	0.1894	
		MNŠŠ	0.7883	4.1380	
Gama	MI NQUE	0.3642	0.0662	1.4828	
	MNŠ	0.3667	0.2026		
	MNŠŠ	0.8100	1.2803		

Tab. 3.

Parameter	Rozdelenie	Odhad	Priemer	Disperzia	MSE
$\theta = 3.0$	Normálne	MI NQUE	3.0082	5.7118	3.7999
		MNŠ	3.0288	8.9197	
		MNŠŠ	1.4540	1.4098	
	Studentovo	MI NQUE	2.9655	10.8945	5.8600
		MNŠ	2.9474	13.2648	
		MNŠŠ	1.4075	3.3239	
Gama	MI NQUE	2.9918	11.3257	5.0605	
	MNŠ	2.9698	14.0818		
	MNŠŠ	1.4339	2.6078		

Tab. 4.