

TESTY PRE REGRESNÉ KVANTILY ZALOŽENÉ NA METÓDE SEDLOVÉHO BODU

RADKA SABOLOVÁ

KPMS MFF UK

SABOLOVA@KARLIN.MFF.CUNI.CZ

ABSTRAKT

Metóda sedlového bodu poskytuje presné aproximácie hustoty odhadov aj pre malé rozsahy výberov. V príspievku sa budeme zaoberať testovou štatistikou, ktorá je založená na výraze v exponente v approximácii hustoty pre M-odhad. Vďaka tvaru funkcie ψ pre regresné kvantily získame explicitný vzorec pre testovú štatistiku. Odvodené testy sú asymptoticky ekvivalentné s klasickými testami založenými na vierochnosti, no ich relatívna chyba je iba rádu $O(n^{-1})$. Správanie navrhnutých parametrických i neparametrických testov pri rôznych rozsahoch výberov a rozdeleniach bude ilustrované v simulačnej štúdi.

REGRESNÉ KVANTILY

Nech Y_1, \dots, Y_n sú pozorovania spĺňajúce model

$$Y_i = \mathbf{X}_i^T \boldsymbol{\beta} + u_i, \quad i = 1, \dots, n,$$

kde $\boldsymbol{\beta} \in \mathbb{R}^p$, $u_i \sim \frac{1}{\sigma} g(\cdot)$ a (Y_i, \mathbf{X}_i) sú i.i.d. s hustotou $\frac{1}{\sigma} g\left(\frac{y_i - \mathbf{x}_i^T \boldsymbol{\beta}}{\sigma}\right) k(\mathbf{x}_i)$, kde $k(\mathbf{x}_i)$ je hustota \mathbf{X}_i .

Regresný kvantil je riešením minimalizačnej úlohy

$$\boldsymbol{\beta}_\alpha = \arg \min \{E\rho_\alpha(Y - \mathbf{X}\mathbf{t}) : \mathbf{t} \in \mathbb{R}^p\},$$

kde

$$\rho_\alpha(x) = |x| \{(1 - \alpha) I[x < 0] + \alpha I[x > 0]\}.$$

Výberový regresný kvantil je definovaný ako riešenie úlohy

$$\hat{\boldsymbol{\beta}}_\alpha = \arg \min_{\boldsymbol{\beta}_\alpha} \sum_{i=1}^n \rho_\alpha(Y_i - \mathbf{x}_i^T \mathbf{t})$$

a je konzistentným odhadom vektora

$$(\beta_1 + G^{-1}(\alpha), \beta_2, \dots, \beta_p).$$

Testujeme jednoduchú hypotézu

$$H_0 : \boldsymbol{\beta}_\alpha = \boldsymbol{\beta}_{\alpha 0}.$$

Použijeme postup pre M-odhad uvedený v [1].

PARAMETRICKÝ TEST

Ak je rozdelenie (Y_i, \mathbf{X}_i) známe, je potrebné vypočítať kumulatívnu vytvárajúcu funkciu pre skóry $\psi(Y_i, \boldsymbol{\beta})$

$$K_\psi(\boldsymbol{\lambda}, \boldsymbol{\beta}_\alpha) = \log \int \left\{ e^{\alpha \boldsymbol{\lambda}^T \mathbf{x}_i} k(\mathbf{x}_i) \left(e^{-\boldsymbol{\lambda}^T \mathbf{x}_i} G\left(\frac{\mathbf{x}_i^T (\boldsymbol{\beta}_\alpha - \boldsymbol{\beta})}{\sigma}\right) \right. \right. \\ \left. \left. + 1 - G\left(\frac{\mathbf{x}_i^T (\boldsymbol{\beta}_\alpha - \boldsymbol{\beta})}{\sigma}\right) \right) \right\} d\mathbf{x}_i.$$

Zderivovaním $K_\psi(\boldsymbol{\lambda}, \boldsymbol{\beta}_\alpha)$ a položením rovno nule získame funkcie sedlového bodu

$$\boldsymbol{\lambda}(\hat{\boldsymbol{\beta}}_\alpha)^T \mathbf{x}_i = -\log \left\{ \frac{\alpha}{1-\alpha} \frac{1-G\left(\frac{\mathbf{x}_i^T (\hat{\boldsymbol{\beta}}_\alpha - \boldsymbol{\beta})}{\sigma}\right)}{G\left(\frac{\mathbf{x}_i^T (\hat{\boldsymbol{\beta}}_\alpha - \boldsymbol{\beta})}{\sigma}\right)} \right\}, \quad i = 1, \dots, n,$$

ktoré sa následne dosadia do štatistiky

$$h(\hat{\boldsymbol{\beta}}_\alpha) = \sup_{\boldsymbol{\lambda}} \{-K_\psi(\boldsymbol{\lambda}, t)\} = -K_\psi(\boldsymbol{\lambda}(\hat{\boldsymbol{\beta}}_\alpha), \hat{\boldsymbol{\beta}}_\alpha)$$

a za H_0 platí

$$-2n \log \int \left(\frac{G\left(\frac{\mathbf{x}_i^T (\hat{\boldsymbol{\beta}}_\alpha - \boldsymbol{\beta})}{\sigma}\right)}{\alpha} \right)^\alpha \left(\frac{1-G\left(\frac{\mathbf{x}_i^T (\hat{\boldsymbol{\beta}}_\alpha - \boldsymbol{\beta})}{\sigma}\right)}{1-\alpha} \right)^{1-\alpha} k(\mathbf{x}_i) d\mathbf{x}_i \\ \xrightarrow[n \rightarrow \infty]{\mathcal{D}} \chi_p^2.$$

NEPARAMETRICKÝ TEST

Ak je rozdelenie (Y_i, \mathbf{X}_i) neznáme, je potrebné pracovať s reziduami r_i a ich empirickou distribučnou funkciou (vid' [2])

$$r_i = y_i - \mathbf{x}_i^T \hat{\boldsymbol{\beta}}_\alpha, \quad I_i = I[r_i < 0], \quad i = 1, \dots, n, \\ I_{ij}(\boldsymbol{\beta}) = I[r_i + \mathbf{x}_i^T (\hat{\boldsymbol{\beta}}_\alpha - \boldsymbol{\beta}) < 0], \quad i, j = 1, \dots, n, \\ G_n^j(\boldsymbol{\beta}) = \frac{1}{n} \sum_{i=1}^n I_{ij}(\boldsymbol{\beta}) \quad i, j = 1, \dots, n.$$

Prvým krokom bude nájdenie empirických distribučných funkcií, ktoré spĺňajú hypotézu a zároveň minimalizujú Kullback-Leiblerovu vzdialenosť od $(1/n, \dots, 1/n)$. Pre regresné kvantily majú tieto váhy tvar

$$w_{ij} = \frac{\left(\frac{\alpha}{1-\alpha} \frac{1-G_n^j(\boldsymbol{\beta}_{\alpha 0})}{G_n^j(\boldsymbol{\beta}_{\alpha 0})}\right)^{I_{ij}(\boldsymbol{\beta}_{\alpha 0})}}{\sum_{k=1}^n \left(\frac{\alpha}{1-\alpha} \frac{1-G_n^j(\boldsymbol{\beta}_{\alpha 0})}{G_n^j(\boldsymbol{\beta}_{\alpha 0})}\right)^{I_{kj}(\boldsymbol{\beta}_{\alpha 0})}}, \quad i, j = 1, \dots, n.$$

Potom

$$K(\boldsymbol{\lambda}(\hat{\boldsymbol{\beta}}_\alpha), \hat{\boldsymbol{\beta}}_\alpha) = \frac{1}{n} \sum_{j=1}^n K^j(\boldsymbol{\lambda}(\hat{\boldsymbol{\beta}}_\alpha), \hat{\boldsymbol{\beta}}_\alpha) \\ K^j(\boldsymbol{\lambda}(\hat{\boldsymbol{\beta}}_\alpha), \hat{\boldsymbol{\beta}}_\alpha) = \log \left\{ \left(\frac{\sum_{i=1}^n w_{ij} I_i}{\alpha} \right)^\alpha \left(\frac{\sum_{i=1}^n w_{ij}(1-I_i)}{1-\alpha} \right)^{1-\alpha} \right\}$$

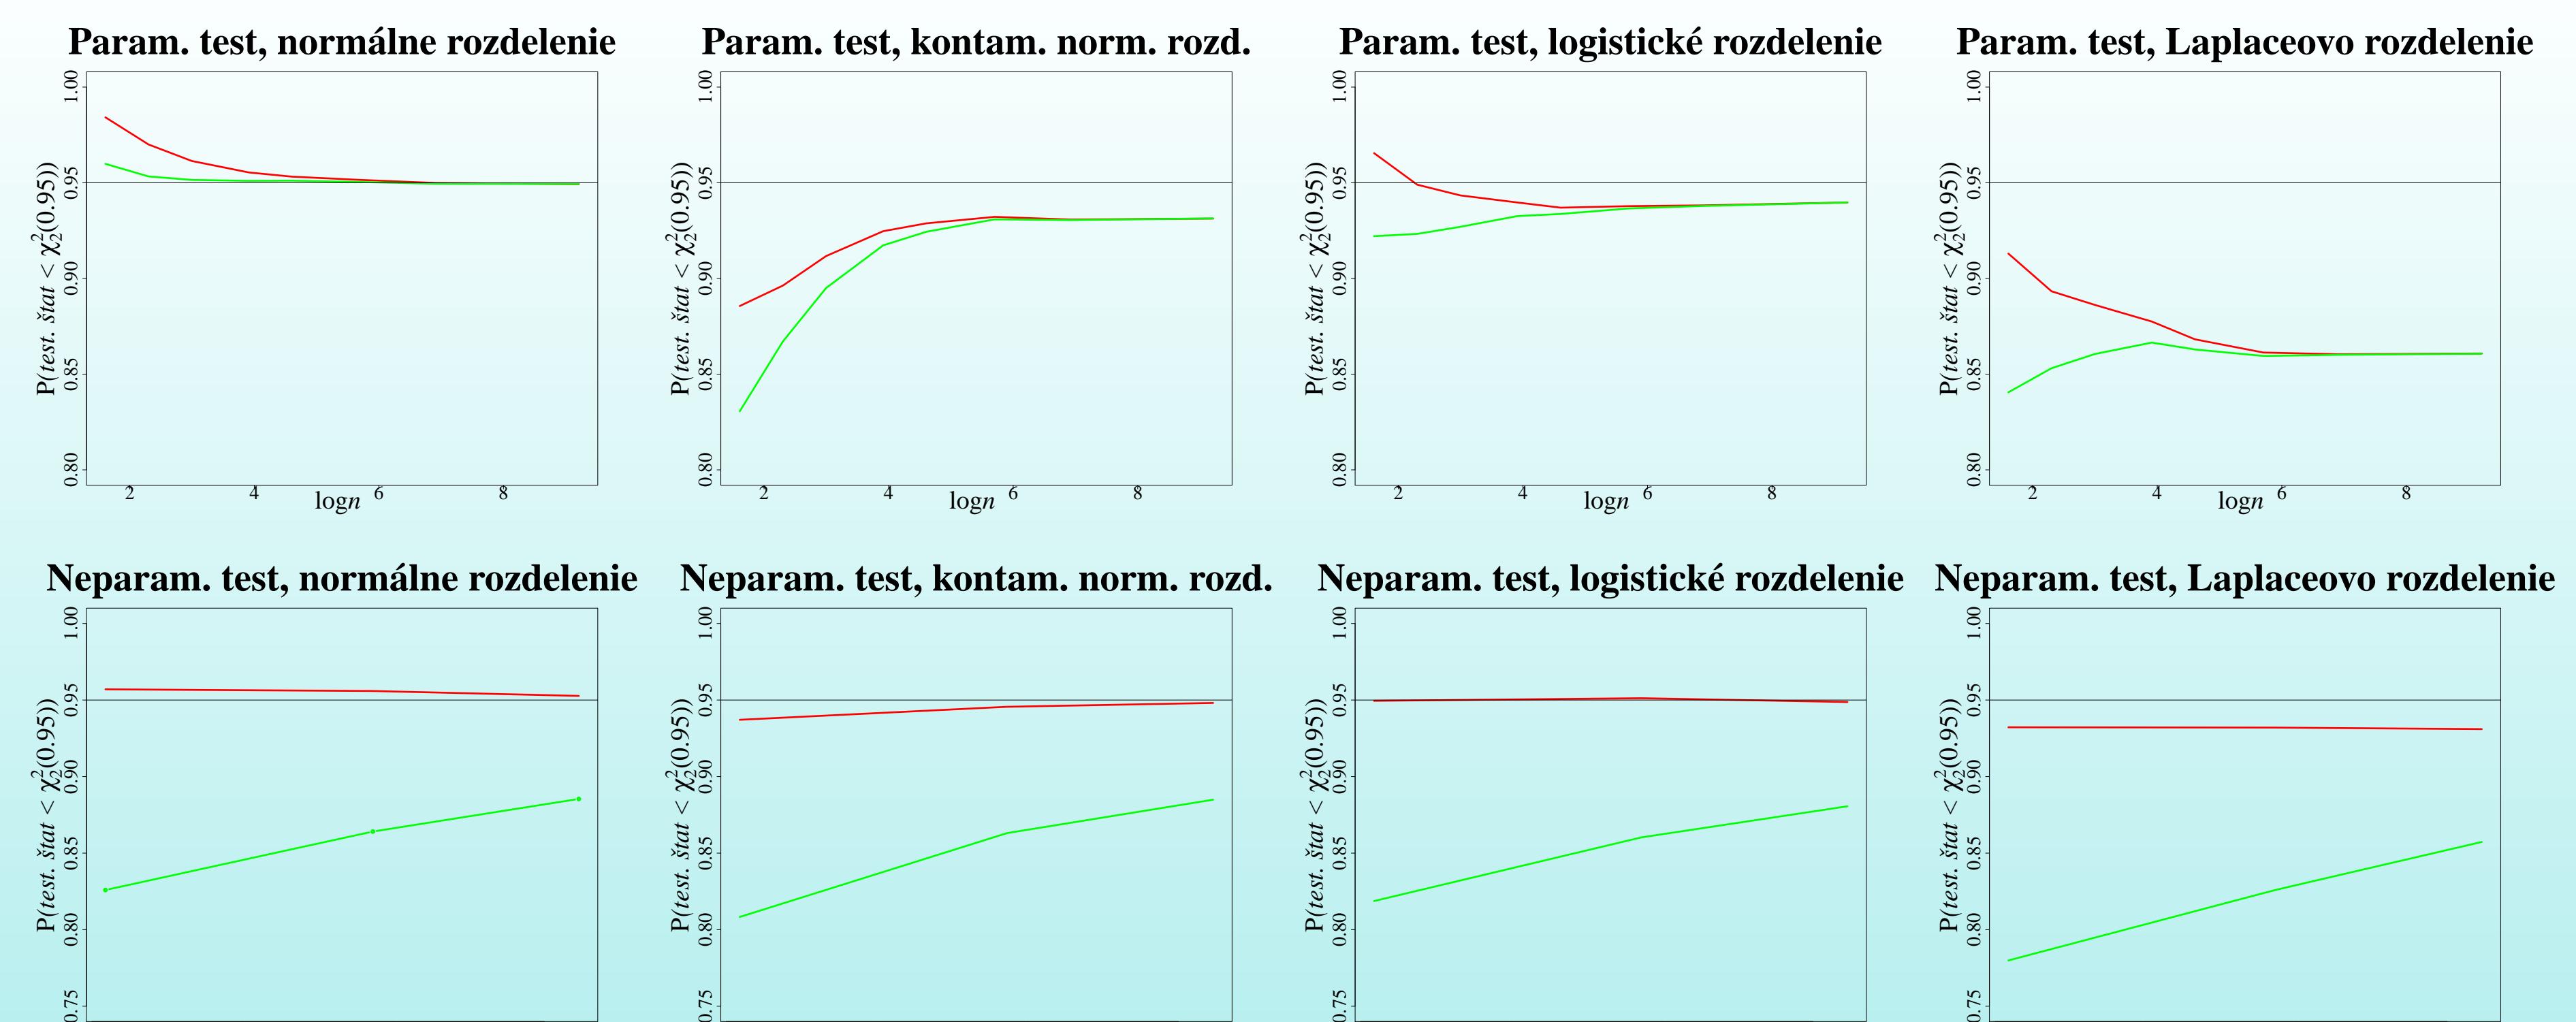
a za H_0 platí

$$-2 \sum_{j=1}^n \log \left\{ \left(\frac{\sum_{i=1}^n w_{ij} I_i}{\alpha} \right)^\alpha \left(\frac{\sum_{i=1}^n w_{ij}(1-I_i)}{1-\alpha} \right)^{1-\alpha} \right\} \xrightarrow[n \rightarrow \infty]{\mathcal{D}} \chi_p^2.$$

SIMULÁCIE

Navrhnuté testy pre regresné kvantily (v grafoch červenou farbou) porovnáme s Waldovým testom (zelenou). Zvolili sme $\mathbf{x}_i^T = (1, \frac{i-1}{n})$. Nasledujúce obrázky porovnávajú rýchlosť konvergencie rozdelenia testových štatistik ku χ^2_2 rozdeleniu za platnosti H_0 a v parametrickom prípade ilustrujú robustnosť testov. Použité rozdelenia boli: normálne, kontaminované normálne, Laplaceovo, logistické.

Pri použití parametrických testov sa predpokladalo normálne rozdelenie u_i , je zrejmé, že navrhnutý test je najmä pre menšie rozsahy výberov robustnejší než Waldov test. Pri neparametrických testoch je approximácia testovej štatistiky χ^2 rozdelením pre testy založené na metóde sedlového bodu omnoho presnejšia než pre Waldov test. Vidíme, že táto approximácia funguje veľmi dobre už aj pre malé výbery.



LITERATÚRA

- [1] Ronchetti E, Robinson J, Young GA (2003): Saddlepoint Approximations and Tests Based on Multivariate M-estimates, *The Annals of Statistics* 31: 1154–1169
- [2] Ronchetti E, Welsh AH (1994): Empirical Saddlepoint Approximations for Multivariate M-estimators, *Journal of the Royal Statistical Society* 56, no.2: 313–326

PODPORA

Tento výstup vznikol v rámci projektu SVV 265 315.