

Viacozmerný test o parametroch polohy nevyžadujúci rovnaký typ rozdelení v súboroch

Ján Somorčík

somorcik@fmph.uniba.sk

Katedra aplikovanej matematiky a štatistiky, Univerzita Komenského, Bratislava

Mnohé testy o rovnosti parametrov polohy viacerých rozdelení sú vhodné len pre situáciu, keď sa tieto rozdielenia od seba líšia nanajvýš posunutím. Tu je predstavený pomerne robustný test, ktorý rieši i všeobecnejšiu situáciu, a je porovnaný so svojimi „predkami“ i konkurenciou.

ÚVOD

Uvažujme q náhodných výberov d -rozmerných dát, ktoré pochádzajú z rozdielení s parametrami polohy μ_1, \dots, μ_q . Rozdielenia sa od seba obyčajne líšia iba posunutím a rovnosť parametrov polohy potom znamená totožnosť týchto rozdielení. Na testovanie hypotezy

$$H_0 : \mu_1 = \dots = \mu_q$$

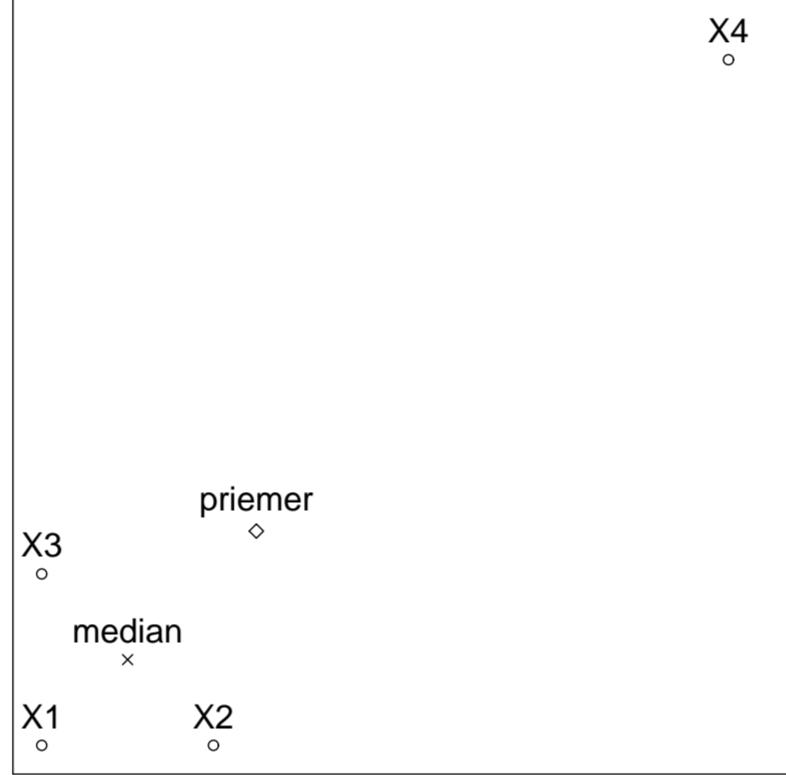
existuje mnoho testov (viac v [1]).

My sme boli inšpirovaní Lawley-Hotellingovou testovacou štatistikou T^2 založenou na aritmetických priemeroch v jednotlivých súboroch. Na jej základe sme v [2] skonštruovali testovacie štatistiky M_1 a M_2 , ktoré namiesto aritmetických priemerov používajú priestorové mediány (priestorový medián dát = bod v priestore, od ktorého je súčet Euklidovských vzdialenosí k jednotlivým dátam najmenší). Dôvodom na použitie priestorových mediánov bola ich väčšia robustnosť voči odľahlým pozorovaniam, ktorú ilustruje obrázok.

Naše testovacie štatistiky majú tvar

$$M_1 := \sum_{a=1}^q n_a (\hat{\mu}_a - [\bar{\mu}])^T \hat{V}^{-1} (\hat{\mu}_a - [\bar{\mu}]),$$

$$M_2 := \sum_{a=1}^q n_a (\hat{\mu}_a - [\hat{\mu}])^T \hat{V}^{-1} (\hat{\mu}_a - [\hat{\mu}]),$$



kde n_a sú počty dát v súboroch a $\hat{\mu}_a$ sú priestorové mediány súborov. \hat{V} je odhad asymptotickej kovariančnej matice V priestorového mediánu, ktorá je rovnaká pre všetky rozdielenia súborov.

M_1 a M_2 sa od seba líšia iba veličinami $\hat{\mu}$ (=medián získaný zo všetkých dát) a $\bar{\mu}$ (=väčšený priemer mediánov v súboroch). Vlastnosti M_1 a M_2 a porovnanie s konkurentmi sú v [2]. Spolu s Lawley-Hotellingovou štatistikou však majú nevýhodu, že na ich použitie sa vyžadujú až na posun rovnaké rozdielenia pravdepodobnosti v súboroch.

NOVÁ TESTOVACIA ŠTATISTIKA

Naším cieľom preto bolo upraviť M_1 resp. M_2 , aby vzniknutá testovacia štatistika bola vhodná aj pre situácie, keď sa rozdielenia jednotlivých súborov líšia aj inak než len parametrom polohy. Problém M_1 a M_2 spočíva v odhade akéhosi „spoločného parametra polohy“ všetkých rozdielení. Zavádzame preto novú testovaciu štatistiku

$$M_3 := \sum_{a=1}^q n_a (\hat{\mu}_a - [\tilde{\mu}])^T \hat{V}_a^{-1} (\hat{\mu}_a - [\tilde{\mu}]),$$

kde odhad spoločného parametra polohy nahrádza

$$\tilde{\mu} := \hat{W}^{-1} \sum_{a=1}^q n_a \hat{V}_a^{-1} \hat{\mu}_a.$$

Je to vážený priemer priestorových mediánov v jednotlivých súboroch. Ako vähy používame počty dát (v „pozitívnom“ zmysle) a odhady asymptotických kovariančných matíc V_a priestorových mediánov $\hat{\mu}_a$ v súboroch (v „negatívnom“ zmysle). Takáto idea váženia sa v inej viacvýberovej situácii objavila napr. v [3].

Vlastnosti M_3

- (I) za platnosti H_0 má asymptoticky rozdielenie $\chi^2_{(q-1)d}$
- (II) za platnosti $H_0 +$ rovnosti rozdielení v súboroch sa M_3 asymptoticky rovná M_1 aj M_2 (v zmysle konvergencie podľa pravdepodobnosti).
- (III) za platnosti $H_0 +$ rovnosti rozdielení v súboroch + sférickej symetrie sa M_3 asymptoticky rovná niektorým štatistikám využívajúcim priestorové znamienka (v zmysle konvergencie podľa pravdepodobnosti).
- (IV) parameter necentrálnosti za platnosti Pitmanových alternatív (t.j. priestorový medián $\mu + \frac{h_a}{\sqrt{n}}$ v a -tom súbore) je $\sum_{a=1}^q p_a h_a^T V_a^{-1} h_a$. Za podmienok bodu (II) je to rovnaká hodnota ako u M_1 a M_2 .

Čo vlastne testuje M_3 ?

Ak sa rozdielenia v súboroch líšia aj inak ako posunutím, tak tážko už hovoriť o parametroch polohy. Test hypotezy H_0 sa stáva iba testom rovnosti priestorových mediánov rozdielení a výsledok testovania tým stráca prirodzenú interpretáciu. Ak však predpokladáme nejaký druh symetrie rozdielení súborov, tak stredy jednotlivých symetrií sú priestorovými mediánmi rozdielení. Pojem *parameter polohy* má tak znova jasný význam. A rovnako výsledok testovania.

MONTE CARLO

Vykonalí sme malú simulačnú štúdiu s $q = 3$ súbormi po $n_1 = n_2 = n_3 = 100$ dátach z \mathbb{R}^3 . Prvý súbor sa generoval z $N_3(\mu_1, I_3)$, zvyšné dva z 3-rozmerného sféricky symetrického Cauchyho rozdielenia. Do simulácií sme zaradili aj štatistiky L_N (založená na pozložkových poradiach) a W_{ϕ_1}, W_{ϕ_2} založené na priestorových znamienkach (detaily v [2]). Z nich iba W_{ϕ_1} nevyžaduje na svoje použitie rovnaké rozdielenia súborov (až na posun). V každej z troch situácií sme vykonali 5 000 opakování. Ak nie je uvedené inak, parametre polohy μ_1, μ_2, μ_3 boli $(0, 0, 0)^T$.

Odhady pravdepodobnosti chyby 1. druhu resp. sily

	M_1	M_2	M_3	T^2	L_N	W_{ϕ_1}	W_{ϕ_2}
H_0 platí	0.060	0.064	0.063	0.029	0.049	0.049	0.057
$\mu_1 = (0.3, 0.3, 0)^T$	0.497	0.500	0.580	0.038	0.421	0.567	0.369
$\mu_2 = (0.3, 0.3, 0)^T$	0.480	0.489	0.485	0.042	0.315	0.456	0.283

- Ak je odchýlka polohy v 1. súbore (s menším rozptýlením), tak M_1 i M_2 silou zaostávajú za M_3 .
- Ak je odchýlka polohy v 2. súbore (s väčším rozptýlením), tak M_1 i M_2 majú silu podobnú ako M_3 .
- Cauchyho rozdielenie spôsobuje, že kvalita Lawley-Hotellingovo testu T^2 je veľmi úbohá.
- Takisto L_N a W_{ϕ_2} svojou silou výrazne zaostávajú za M_3 .

Poďakovanie Autor by chcel poďakovať svojmu školiteľovi Františkovi Rublíkovi za mnohé cenné rady a diskusie. Práca bola podporená grantom VEGA 1/3016/06.

Odkazy

- [1] Um, Y. & Randles, R. H. (1998). Nonparametric tests for the multivariate multi-sample location problem. *Statistica Sinica*, 8, 801–812.
- [2] Somorčík, J. (2006). Tests Using Spatial Median. *Austrian Journal of Statistics*, 35, 331–338.
- [3] Rublík, F. (2001). Tests of some hypotheses on characteristic roots of covariance matrices not requiring normality assumptions, *Kybernetika* 37, 61–78.