

Hodges-Lehmannovská optimálnosť testov pomerom vierohodností.

FRANTIŠEK RUBLÍK
ÚSTAV MERANIA SAV, BRATISLAVA

Nech sú pravdepodobnosti $\{\bar{P}_\gamma; \gamma \in \Xi\}$ definované na (X, \mathcal{F}) pomocou hustôt

$$f(x, \gamma) = \frac{d\bar{P}_\gamma}{d\nu}(x).$$

Predpokladajme, že $n_1^{(u)}, \dots, n_u^{(q)}$, $u = 1, 2, \dots$ sú rozsahy nezávislých výberov, a v tomto zápise

$$y(1, n_u^{(1)}) = (x_1^{(1)}, \dots, x_{n_u^{(1)}}^{(1)}), \dots, y(q, n_u^{(q)}) = (x_1^{(q)}, \dots, x_{n_u^{(q)}}^{(q)})$$

označuje náhodné výbery z q štatistických populácií. Teda

$$x^{(u)} = (y(1, n_u^{(1)}), \dots, y(q, n_u^{(q)})) \quad (1)$$

je združený výber, a v označení

$$\Theta = \Xi^q \quad (2)$$

je $\theta = (\theta_1, \dots, \theta_q) \in \Theta$ parameter, popisujúci celkový stav tých q populácií, t.j. θ_j je parameter j -tej populácie. Cieľom je testovať hypotézu

$$\emptyset \neq \Omega_0 \subset \Theta.$$

Nech v označení

$$n_u = \sum_{j=1}^q n_u^{(j)}, \quad p_u^{(j)} = n_u^{(j)} / n_u \quad (3)$$

platí, že

$$\lim_{u \rightarrow \infty} n_u = +\infty, \quad \lim_{u \rightarrow \infty} p_u^{(j)} = p_j \in (0, 1), \quad j = 1, \dots, q. \quad (4)$$

Ak je test φ_u nulovej hypotézy Ω_0 oproti $\Theta - \Omega_0$ založený na (1) a pre $\beta_u(\theta) = E_\theta(\varphi_u)$ platí, že asymptotická úroveň významnosti

$$\sup \left\{ \lim_{u \rightarrow \infty} \beta_u(\theta^*); \theta^* \in \Omega_0 \right\} = \alpha \in (0, 1), \quad (5)$$

tak pre každý parameter $\theta \in \Theta - \Omega_0$ je rýchlosť konvergencie pravdepodobnosti $1 - \beta_u(\theta)$ chyby druhého druhu ku nule ohraničená zdola, presnejšie

$$\liminf_{u \rightarrow \infty} \frac{1}{n_u} \log[1 - \beta_u(\theta)] \geq -K(\Omega_0, \theta, p), \quad (6)$$

kde $K(\Omega_0, \theta, p)$ Kulback-Leiblerovo informačné číslo; $K(\Omega_0, \theta, p)$ je definované ako

$$K(\Omega_0, \theta, p) = \inf\{K(\theta^*, \theta, p); \theta^* \in \Omega_0\},$$

kde

$$K(\theta^*, \theta, p) = \sum_{j=1}^q p_j K(\theta_j^*, \theta_j)$$

a

$$K(\gamma^*, \gamma) = \int \log \left(\frac{f(x, \gamma^*)}{f(x, \gamma)} \right) f(x, \gamma^*) d\nu(x).$$

Dôkaz tejto nerovnosti možno nájsť napríklad v [4]. V zhode s ňou sa testy $\{\varphi_u\}$ nazývajú Hodges-Lehmannovsky optimálne, ak (4) a (5) implikujú, že

$$\lim_{u \rightarrow \infty} \frac{1}{n_u} \log[1 - \beta_u(\theta)] = -K(\Omega_0, \theta, p).$$

Budeme sa venovať Hodges-Lehmannovskej optimálnosti štatistiky pomeru vierohodností, ktorá je pre testovanie hypotézy Ω_0 definovaná vzorcom

$$T_u(x^{(u)}) = \log \frac{L(x^{(u)}, \Theta)}{L(x^{(u)}, \Omega_0)},$$

kde

$$L(x^{(u)}, A) = \sup \left\{ \prod_{j=1}^q \prod_{i=1}^{n_u^{(j)}} f(x_i^{(j)}, \theta_j); (\theta_1, \dots, \theta_q) \in A \right\}.$$

Ako je dobre známe, test Ω_0 oproti $\Theta - \Omega_0$ sa vykoná podľa pravidla

$$\varphi_u(x^{(u)}) = \begin{cases} 1 & T_u > t_u, \\ 0 & T_u \leq t_u, \end{cases}$$

kde 1 označuje zamietnutie, 0 prijatie hypotézy, a t_u je zvolená kritická konštanta.

Jeden z prístupov ku tejto problematike možno nájsť v [3], kde sa predpokladá, že hustoty $\{f(x, \gamma); \gamma \in \Xi\}$ tvoria exponenciálnu triedu pravdepodobností, t.j. $\Xi \subset R^k$ a

$$f(x, \gamma) = \frac{d\bar{P}_\gamma}{d\nu}(x) = e^{\gamma'x - C(\gamma)}.$$

Ak $\bar{x}_n \in \{E\gamma(x); \gamma \in \Xi\}$, tak pre parameter $\hat{\theta}_n = \hat{\theta}_n(x_1, \dots, x_n) \in \Xi$ určený rovnosťou

$$E_{\hat{\theta}_n}(y) = \bar{x}_n$$

po algebraických úpravách

$$\log L(x_1, \dots, x_n, \gamma) = g_n(x_1, \dots, x_n) - nK(\hat{\theta}_n, \gamma)$$

a $\hat{\theta}_n$ je OMV parametra γ . V [3] sa H-L optimálnosť štatistiky pomerom vierohodností dokazuje za rôznych predpokladov podľa toho, či sa jedná o výber z jednej, alebo z $q > 1$ štatistických populácií.

Jednovýberový prípad $q=1$

Označme $A_n = \{ \gamma \in \Omega_0; K(\gamma, \Omega_0) \leq \frac{t_n}{n} \}$. Ak

$$\bar{x}_n = E_\gamma(x), K(\gamma, \theta) < K(A_n, \theta)$$

tak $\hat{\theta}_n = \gamma \notin A_n$ a teda štatistika pomeru vierohodností

$$T_n(x_1, \dots, x_n) = nK(\hat{\theta}_n, \Omega_0) > \frac{t_n}{n}.$$

Preto

$$\begin{aligned} 1 - \beta_n(\theta) &= P_\theta(T_n(x_1, \dots, x_n) \leq t_n) \leq \\ &\leq P_\theta(\bar{x}_n \notin \{E_\gamma(x); K(\gamma, \theta) < K(A_n, \theta)\}). \end{aligned}$$

Podľa vety 3.2.1 v [2]

$$P_\theta(\bar{x}_n \notin \{E_\gamma(x); K(\gamma, \theta) < d_n\}) = (nd_n)^{\frac{1}{\epsilon}-1} \exp(-nd_n + O(1))$$

pre $n \rightarrow \infty$, ak existuje $\epsilon > 0$ tak, že

$$\frac{\epsilon}{n} \leq d_n \leq \min \left\{ \frac{1}{\epsilon}, K(\theta) \right\},$$

$$K(\theta) = \sup \{ a; \{ \gamma \in \Xi; K(\gamma, \theta) \leq a \} \subset C_a \subset \Xi, C_a \text{ je kompaktná} \}.$$

V [3] sa preto postulujú predpoklad $K(\Omega_0, \theta) < K(\theta)$ a spojitosť funkcie $K(\cdot, \Omega_0)$, čo umožňuje použiť túto vetu 3.2.1 a pomocou nej za predpokladu $t_n = o(n)$ dokázať, že

$$\limsup \frac{1}{n} \log(1 - \beta_n(\theta)) \leq -K(\Omega_0, \theta).$$

Tieto predpoklady sú obmedzením na nulovú hypotézu a treba ich overovať pre jednotlivé hypotézy zvlášť.

Viacvýberový prípad $q > 1$

Analóg vety 3.2.1 z [2] pre viacvýberový prípad nie je známy, a preto sa pre tento prípad v [3] používa iný prístup, ako pre $q = 1$. Postuluje sa predpoklad ktorý je ekvivalentný tomu, že odhad maximálnej vierohodnosti $\hat{\theta}$ existuje s pravdepodobnosťou 1 pre n dostatočne veľké. Potom s pravdepodobnosťou 1

$$\log L(x^{(u)}, \theta^*) = G^{(u)}(x^{(u)}) - n_u K(\hat{\theta}_{(u)}, \theta^*, p_u)$$

čo znamená, že

$$P_{\theta} \left[\log \frac{L(x^{(u)}, \Theta)}{L(x^{(u)}, \Omega_0)} \leq t_u \right] = P_{\theta} [n_u K(\hat{\theta}_{(u)}, \Omega_0, p_u) \leq t_u] = \\ = P_{\theta} [\hat{\theta}_{(u)} \in A_u]$$

kde $A_u = \{ \theta^* \in \Xi^q; K(\theta^*, \Omega_0, p_u) \leq \frac{t_u}{n_u} \}$. Pomocou Herrovej nerovnosti]

$$P_{\theta} [\hat{\theta}_{(u)} \in A_u] \leq P_{\theta} [K(\hat{\theta}_{(u)}, \theta, p_u) \geq K(A_u, \theta, p_u)]$$

sa potom už dá dostať ku situácii, na ktorú možno aplikovať tvrdenia o pravdepodobnosti veľkých odchýlok typu

$$P_{\theta} \left[\log \frac{L(x^{(u)}, \Theta)}{L(x^{(u)}, \theta)} \geq t \right] \leq \exp[-t + H_u(t)],$$

a pomocou postulovanej spojitosti funkcie $K(\cdot, \Omega_0, p)$ dokázať H-L optimálnosť testov pomerom vierohodností. Tento prístup má okrem postulovanej spojitosti $K(\cdot, \Omega_0, p)$ aj tú nevýhodu, že vylučuje Poissonovo a multinomické rozdelenie (presnejšie, systém všetkých pravdepodobností na konečnej množine, vedúci k multinomickému ako k rozdeleniu OMV), lebo tieto po reparametrizácii poskytujú exponenciálne triedy, pre ktoré OMV neexistuje s kladnou pravdepodobnosťou.

Axiomatický prístup v [5] pre dokázanie H-L optimálnosti štatistiky pomeru vierohodností umožňuje vyhnúť sa týmto ťažkostiam. V [5] sa predpokladá, že trieda pravdepodobností je zadaná hustotami $\{f(x, \gamma); \gamma \in \Xi\}$ vzhľadom na mieru ν , a sú splnené nasledujúce predpoklady.

(A I) Existuje σ -kompaktný metrický priestor Ξ_1 taký že Ξ je hustý v Ξ_1 (t.j. $\bar{\Xi} = \Xi_1$), a pôvodný systém $\{f(x, \gamma); \gamma \in \Xi\}$ môže byť rozšírený do systému $\{f(x, \gamma); \gamma \in \Xi_1\}$ hustôt vzhľadom na tú istú mieru ν (rozšírením rozumieme že $f(x, \gamma)$ sa zhoduje s pôvodnou hustotou ak $\gamma \in \Xi$). Navyše, rozšírený systém $\{\bar{P}_{\gamma}; \gamma \in \Xi_1\}$ pozostáva z navzájom rôznych pravdepodobností, Kullback-Leiblerovo informačné číslo $K(\theta^*, \cdot)$ je spojité na Ξ_1 pre každý parameter $\theta^* \in \Xi_1$ (t.j. $\gamma_n^* \rightarrow \gamma^*$ implikuje $K(\theta^*, \gamma_n^*) \rightarrow K(\theta^*, \gamma^*)$), a okrem toho $f(x, \gamma)$ je spojitá na Ξ_1 pre každý prvok $x \in X$.

(A II) Funkcia $K(\cdot, \theta)$ je konečná a spojitá na Ξ_1 pre všetky $\theta \in \Xi$.

(A III) Nech parametre $\{\theta_n^*\}_{n=1}^{\infty}$ patria do Ξ_1 , $\gamma \in \Xi$ a

$$\limsup_{n \rightarrow \infty} K(\theta_n^*, \gamma) < +\infty.$$

(a) Ak $\theta \in \Xi$, tak $\limsup_{n \rightarrow \infty} K(\theta_n^*, \theta) < +\infty$.

(b) Postupnosť $\{\theta_n^*\}_{n=1}^{\infty}$ má v Ξ_1 hromadnú hodnotu, a ak parametre $\{\theta_n^*\}_{n=1}^{\infty}$ patriace do Ξ sú také že $\limsup_{n \rightarrow \infty} K(\theta_n^*, \theta_n) < +\infty$, tak aj postupnosť $\{\theta_n^*\}_{n=1}^{\infty}$ má v Ξ_1 hromadnú hodnotu.

(c) Nech $\lim_{n \rightarrow \infty} \theta_n^* = \theta^*$. Ak $\{\theta_n\}_{n=1}^{\infty}$ je postupnosť parametrov zo Ξ a $\lim_{n \rightarrow \infty} \theta_n = \theta$, tak $\liminf_{n \rightarrow \infty} K(\theta_n^*, \theta_n) \geq K(\theta^*, \theta)$.

(A IV) Existujú merateľné množiny $A_n \subset X^n$, prirodzené číslo N a merateľné zobrazenia $\theta_n : A_n \rightarrow \Xi_1$, $g_n : A_n \rightarrow R$ také, že pre všetky $\gamma \in \Xi$ a $n \geq N$

$$\bar{P}_\gamma(A_n) = 1 \quad (7)$$

a na množine A_n v označení $L(x_1, \dots, x_n, \gamma) = \prod_{i=1}^n f(x_i, \gamma)$ platí rovnosť

$$\log L(x_1, \dots, x_n, \gamma) = g_n(x_1, \dots, x_n) - nK(\hat{\theta}_n, \gamma). \quad (8)$$

(A V) V označení (A 4) a

$$p_u = (p_u^{(1)}, \dots, p_u^{(q)}),$$

pre $\theta = (\theta_1, \dots, \theta_q) \in \Xi^q$ nech

$$K(\hat{\theta}, \theta, p_u) = \sum_{j=1}^q p_u^{(j)} K(\hat{\theta}_{n_u^{(j)}}(y(j, n_u^{(j)})), \theta_j). \quad (9)$$

Ak platí (4), tak pre každý parameter $\theta \in \Xi^q$ a reálne číslo t

$$P_\theta[n_u K(\hat{\theta}, \theta, p_u) \geq t] \leq \exp[-t + h_u(t)] \quad (10)$$

kde funkcia h_u má tú vlastnosť, že

$$\limsup_{u \rightarrow \infty} \frac{h_u(t_u)}{n_u} = 0 \quad (11)$$

ak

$$\limsup_{u \rightarrow \infty} \frac{t_u}{n_u} < +\infty. \quad (12)$$

Tvrdenie o H-L optimálnosti má v [5] nasledujúci tvar.

Veta. Nech trieda pravdpodobností $\{\bar{P}_\gamma; \gamma \in \Xi\}$, určená hustotami $\{f(x, \gamma); \gamma \in \Xi\}$ vzhľadom na mieru ν je taká, že prepoklady (A I) - (A V) sú splnené. Nech

$$\emptyset \neq \Omega_0 \subset \Theta = \Xi^q,$$

$T_u = T_u(x^{(u)})$ je štatistika pomeru vierohodností pre testovanie tejto hypotézy, t.j. testujeme ju testami

$$\varphi_u(x^{(u)}) = \begin{cases} 1 & T_u > t_u, \\ 0 & T_u \leq t_u. \end{cases} \quad (13)$$

Ak z platnosti predpokladov

$$\lim_{u \rightarrow \infty} n_u = +\infty, \quad \lim_{u \rightarrow \infty} p_u^{(j)} = p_j \in (0, 1), \quad j = 1, \dots, q,$$

$$\sup \{ \lim_{u \rightarrow \infty} \beta_u(\theta^*); \theta^* \in \Omega_0 \} = \alpha \in (0, 1),$$

vyplýva, že kritické konštanty t_u v (13) môžu byť vybrané tak, že

$$\limsup_{u \rightarrow \infty} t_u < +\infty, \quad (14)$$

tak testy (13) sú H-L optimálne.

Ak $\{\bar{P}_\gamma; \gamma \in \Xi\}$ sú regulárne normálne rozdelenia, alebo Poissonove rozdelenia, alebo ak $X = \{1, \dots, k\}$ je konečná množina a pravdepodobnosti na nej sú zadané pomocou

$$\Xi = \{ (p_1, \dots, p_k)' \in R^k; \min_i p_i > 0, \sum_{i=1}^k p_i = 1 \}, \quad f(x, p) = p_x$$

tak pomocou predchádzajúcej vety možno dokázať toto tvrdenie.

Veta. Ak Ω_0 je neprázdna podmnožina množiny $\Theta = \Xi^q$ a ak T_u sú štatistiky pomeru vierohodností pre testovanie Ω_0 proti $\Theta - \Omega_0$, tak testy (13) založené na nich sú H-L optimálne pre testovanie Ω_0 oproti $\Theta - \Omega_0$.

CITÁCIE

- [1] W. Hoeffding.: Asymptotically optimal tests for multinomial distributions. *Annals of Mathematical Statistics* 36(1965), 369–408.
- [2] W. C. M. Kallenberg: Asymptotic optimality of likelihood ratio tests. *Mathematisch Centre Tracts* 77, Amsterdam 1978.
- [3] S. Kourouklis: Hodges-Lehmann optimality of the likelihood ratio test in regular exponential families of distributions. Technical Report 73, The Pennsylvania State University, 1987.
- [4] S. Kourouklis: Hodges-Lehmann efficacies of certain tests in multivariate analysis and regression analysis. *The Canadian Journal of Statistics*, 16(1988), 87-95.
- [5] Rublík: On Hodges-Lehmann optimality of LR tests. Prijaté na publikáciu v časopise *Kybernetika*.