

ODHADY PARAMETRU TUKEYHO A ZOBEČNĚNÉHO TUKEYHO SYSTÉMU ROZDĚLENÍ

Marie Hušková, MFF UK

0. ÚVOD

Tukey (1960) zavedl systém jednoparametrických rozdělení s kvantilovou funkcí

$$(1) \quad F^{-1}(u; \lambda) = (u^{\lambda} - (1-u)^{\lambda}) / \lambda \quad u \in (0,1), \quad \lambda \in \mathbb{R}_+$$

V literatuře se pro něj ujal název Tukeyův systém rozdělení.

Rasberg a Schmeiser (1974) zavedli systém rozdělení závisející na čtyřech parametrech $(\lambda_1, \lambda_2, \lambda_3, \lambda_4)$ s kvantilovou funkcí

$$(2) \quad F^{-1}(u; \lambda_1, \lambda_2, \lambda_3, \lambda_4) = \lambda_1 + (u^{\lambda_2} - (1-u)^{\lambda_2}) \lambda_4 \quad u \in (0,1),$$

kde $\lambda_i \in \mathbb{R}$, je parametr polohy, $|\lambda_4|$ je parametr měřítka a λ_2, λ_3 jsou parametry charakterizující chování chvostů, $(\lambda_2, \lambda_3, \lambda_4) \in \Lambda = \{ \lambda_i > 0, i = 2,3,4 \} \cup \{ \lambda_3 < 0, i = 2,3,4 \} \cup \{ \lambda_2 < -1, \lambda_3 > 0, \lambda_4 < 0 \} \cup \{ \lambda_2 > 0, \lambda_3 < -1, \lambda_4 < 0 \} \cup \{ \lambda_2 = 0, \lambda_3 \lambda_4 > 0 \} \cup \{ \lambda_3 = 0, \lambda_2 \lambda_4 > 0 \}$.

Systém rozdělení tvořený rozdělením s kvantilovou funkcí (2) s $\lambda_i \in \mathbb{R}$, a $(\lambda_2, \lambda_3, \lambda_4) \in \Lambda$ se nazývají zobecněný Tukeyův systém rozdělení.

Tyto systémy zahrnují řadu běžně používaných rozdělení popř. jejich approximace. V práci bude pojednáno o vlastnostech těchto systémů a odhadech jejich parametrů.


1. NĚKTERÉ VLASTNOSTI SYSTÉMU ROZDĚLENÍ

Tukeyův systém rozdělení zahrnuje symetrické rozdělení s tzv. těžkými chvosty ($\lambda < 0$), i lenkými chvosty ($\lambda > 0$). Při $\lambda < 1$ nebo $\lambda > 2$ jde o rozdělení unimodální jednovrcholové a při $1 < \lambda < 2$ má rozdělení tzv. U-tvar, Cauchyovo rozdělení, pro $\lambda = 0$ logistiké a při $\lambda = 1$ nebo 2 rozdělení rovnosárné. Při $\lambda = 0,08$ obdržíme rozumnou approximaci pro dvojitě exponenciální rozdělení, při $\lambda = 0,14$ pro normální. Tento systém poskytuje také dobrou approximaci pro t-rozdělení.


Zobecněný Tukeyův systém rozdělení zahrnuje některé asymetrické rozdělení. Poskytuje dobrou approximaci např. pro exponenciální rozdělení.

Na obrázcích 1,2,3,4 jsou uvedeny grafy hustot několika rozdělení náležejících do těchto systémů. ($\alpha_i = E(X - EX)^i (E(X - EX)^2)^{-1/2} \quad i = 3,4$).


Uvědomíme-li si fakt, že má-li náhodná veličina U rovnosárné rozdělení na $(0,1)$ a F je nějaká distribuční funkce, pak $F^{-1}(U)$ má rozdělení s distribuční funkcí F , lze uvedené systémy rozdělení výhodně využít při různých simulačních studiích. Navíc se oba systémy ukázaly velmi užitečné při reprezentaci dat, jestliže model není znám.




Obr. 3.1 Grafy hustot pro
 $\alpha_3 = 0, \alpha_4 = 3, 5, 9$



Obr. 3.2 Grafy hustot pro
 $\alpha_3 = 1, \alpha_4 = 4, 6, 9$



Obr. 3.3 Grafy hustot pro
 $\alpha_3 = 0, 0.5, 1; \alpha_4 = 4$



Obr. 3.4 Grafy hustot
s tvaru U - tvarem

Obeecně neexistuje explicitní vyjádření distribuční funkce nebo hustoty. Momenty lze vyjádřit následovně (pro systém (2)):

$$(3) \quad EX = \alpha_1 + \alpha_4 ((\alpha_2 + 1)^{-1} - (\alpha_3 + 1)^{-1}) \quad \text{pro } \alpha_2 > -1, \alpha_3 > -1,$$

$$(4) \quad E(X - \alpha_1)^k = \alpha_4^k \sum_{j=0}^k \binom{k}{j} (-1)^j B(\alpha_2(k-j) + 1, \alpha_3 j + 1) \quad \text{pro } \alpha_2 k > -1, \alpha_3 k > -1,$$

kde $B(\alpha_2, \alpha_3)$ je beta funkce.


Pro momenty náhodné veličiny X s kvantilovou funkcí (1) platí

$$(6) \quad EX = 0 \quad \text{pro } \alpha_2 > -1,$$

$$(7) \quad EX^k = \alpha_4^{-k} \sum_{j=0}^k \binom{k}{j} (-1)^j B(\alpha_2(k-j) + 1, \alpha_3 j + 1) \quad \text{pro } \alpha_2 k > -1,$$

v žádce Ramberg a kol. (1979) jsou tabulovány hodnoty $\alpha_1, \alpha_2, \alpha_3, \alpha_4$ pro $EX = 0$, $EX^2 = 1$, $\alpha_3 = 0(0.05)2$, $\alpha_4 = 1.8(0.2)9$, $\alpha_3 = E(X-EX)^3$, $\alpha_4 = E(X-EX)^4$.

Tabulka č. 5 obsahuje přehled o konečnosti momentů a kladné či záporné šikmosti $(E(X-EX)^3 > 0$ resp. < 0).



Obr. 5 Některé vlastnosti rozdělení v závislosti na α_2, α_3 .

Poznamenejme, že Fisherova míra informace vzhledem k parametru posunutí je konečná pro $\alpha_2, \alpha_3, \alpha_4 \in \langle 1/2, 2 \rangle$.

2. ODHADY PARAMETRŮ $\alpha_1, \alpha_2, \alpha_3, \alpha_4$

Pozornost soustředíme hlavně na systém (2), neboť (1) je speciálním případem (2).

Nechť X_1, \dots, X_n je náhodný výběr z rozdělení s kvantilovou funkcí (2) a $X_{(1)}, \dots, X_{(n)}$ je příslušný uspořádený výběr. V dalším bude $X_{(a)}$ značit $[a]$ -tou pořadkovou statistiku, kde $[a]$ je celá část a .

Za předpokladu konečnosti 4. momentu můžeme odhadnout parametry $\alpha_1, \alpha_2, \alpha_3, \alpha_4$ metodou momentů, t.j. za odhady vezmeme řešení rovnic:

$$(8) \quad EX^k = \frac{1}{n} \sum_{i=1}^n X_i^k \quad k = 1, 2, 3, 4.$$

Explicitní řešení obecně neexistuje. Můžeme však využít tabulky Ramberga a kol. (79) zmíněné výše. Podobně můžeme odhad parametru α_1 můžeme využít řešení rovnice (dle 7):

$$(9) \quad EX^3 = \frac{1}{n} \sum_{i=1}^n X_i^3,$$

při jejichž řešení můžeme využít tabulky Ramberga a kol. (79).

Můžeme však ič použít velice jednoduché odhady založené na pořadkových statistikách. Je-li $\alpha_2 < 1$, pak můžeme pro α_2 použít odhad

$$(10) \quad \hat{\alpha}_2(M, n, b, s) = \frac{1}{\log s^{-1}} \log \frac{X_{(bm)} - X_{(bm)}}{X_{(nsM)} - X_{(bm)}},$$

kde $M, a, b, s > 0$, $s \neq 1$, $a \neq b$, $\max(a, b, as, bs) < n/2$. Podobně, je-li $A_3 < 1$, lze A_3 odhadnout

$$(11) \quad \hat{A}_3(M, a, b, s) = \frac{1}{\log s} \log \frac{\chi_{(n-sM)} - \chi_{(n-bM)}}{\chi_{(n-asM)} - \chi_{(n-bsM)}}.$$

Oba tyto odhady jsou konsistentní, pro $n \rightarrow \infty$, $M \rightarrow \infty$, $M/n \rightarrow 0$ (a, b, s jsou pevné) platí

$$(12) \quad \begin{aligned} \hat{A}_i(M, a, b, s) &= A_i + o_p(\max(M^{-1/2}, (M/n)^{1-i})) && \text{pro } A_i < 1 \\ &= 1 + o_p(1) && \text{pro } A_i > 1, \end{aligned}$$

i = 2, 3. Pro praktické účely je vhodné např. volba $s = 1/2$, $a = 4$, $b = 2$, dostaneme pak

$$\hat{A}_2(M, 4, 2, 1/2) = \frac{1}{\log 2} \log \frac{\chi_{(4M)} - \chi_{(2M)}}{\chi_{(2M)} - \chi_{(M)}}$$

a M volime podle rozsahu výběru $0,02n - 0,05n$.

Další typ odhadů parametrů (A_2, A_3) získáme řešením následujících transcendentních rovnic:

$$(13) \quad \frac{\chi_{(a_i n)} - \chi_{(b_i n)}}{\chi_{(c_i n)} - \chi_{(d_i n)}} = \frac{\frac{A_2}{a_i} - \frac{A_3}{-(1-a_i)} - \frac{b_i}{c_i} + \frac{(1-b_i)}{c_i}}{\frac{A_2}{c_i} - \frac{A_3}{(1-c_i)} - \frac{d_i}{c_i} + \frac{(1-d_i)}{c_i}}, \quad i = 1, 2$$

kde $1 > a_i, b_i, c_i, d_i > 0$, $(a_i, b_i) \neq (c_i, d_i)$, (c_i, c_i) , $i = 1, 2$,

$(a_1, b_1, c_1, d_1) \neq (a_2, b_2, c_2, d_2)$, (c_2, d_2, a_2, b_2) , $a_i \neq b_i$, $c_i \neq d_i$.

Získané odhady (ozn. $(\tilde{A}_2, \tilde{A}_3)$) jsou konsistentní pro $n \rightarrow \infty$ a a_i, b_i, c_i, d_i , $i = 1, 2$, pevné platí

$$(14) \quad \tilde{A}_i = A_i + o_p(n^{-1/2}) \quad i = 2, 3.$$

Parametr měřítka A_4 můžeme odhadnout buď

$$(15) \quad \hat{A}_4(M, N) = (\chi_{(n-M)} - \chi_{(N)})/2, \quad \text{je-li } A_2 > 0, \quad A_3 > 0,$$

nebo

$$(16) \quad \tilde{A}_4(a, b) = \frac{\chi_{(an)} - \chi_{(bn)}}{a^2 - (1-a) \frac{A_2}{A_3} - b \frac{A_2}{A_3} + (1-b) \frac{A_2}{A_3}},$$

kde $M, N < n/2$, $a \neq b \in (0, 1)$, \tilde{A}_2, \tilde{A}_3 jsou odhady získané řešením rovnic (13). Oba odhady jsou za jistých předpokladů konsistentní.

Pro $n \rightarrow \infty$ a, b pevné platí

$$(17) \quad \tilde{A}_4(a, b) = A_4 + o_p(n^{-1/2}).$$

Jestliže navíc $M/n \rightarrow 0$, $N/n \rightarrow 0$ M, N mohou být pevné nebo konvergovat k nekonečnu, $A_i > 0$ $i = 2, 3$, pak lze uvažovat platnost

$$(18) \quad \hat{A}_4(M, N) = A_4 + 0_p(\max\left(\frac{M}{n}, \left(\frac{M}{n}\right)^{A_2}, \frac{N}{n}, \left(\frac{N}{n}\right)^{A_3}\right)).$$

Parametr A_1 můžeme odhadnout buď

$$(19) \quad \tilde{A}_1(M, N) = (x_{(n-M)} + x_{(N)})/2, \quad \text{je-li } A_2 > 0, A_3 > 0,$$

nebo

$$(20) \quad \tilde{A}_1(a, b) = (x_{(an)} + x_{(bn)})/2 - \tilde{A}_2(a^{\tilde{A}_2} - (1-a)^{\tilde{A}_3} + b^{\tilde{A}_2} - (1-b)^{\tilde{A}_3})/2$$

kde $a \neq b \in (0, 1)$, $M, N < n/2$. Odhady mají vlastnosti analogické $\hat{A}_4(M, N)$ respective, $\tilde{A}_4(a, b)$.

Fodívejme se nyní na odhad parametru λ Tukeyova systému rozdělení. Nabízejí se dva typy (ve shodě s předchozím) jednak

$$(21) \quad \hat{A}(\lambda, a, b, s) = (\hat{A}_2(\lambda, a, b, s) + \hat{A}_3(\lambda, a, b, s))/2, \quad \text{pro } \lambda < 1$$

kde $\hat{A}_i(\lambda, a, b, s)$, $i=2, 3$ jsou definovány (10) respective, (11) jednak řešení rovnice

$$\frac{x_{(an)} - x_{(1-a)n}}{x_{(cn)} - x_{(1-c)n}} = \frac{a^{\lambda} - (1-a)^{\lambda}}{c^{\lambda} - (1-c)^{\lambda}},$$

kde $a \neq c \in (0, 1)$.

Odhady parametrů A_2, A_3 popř. λ můžeme velmi výhodně využít např. při konstrukci asymptoticky optimálních odhadů v následujících dvou typických úlohách neparametrických metod.

a) Nechť X_1, \dots, X_n jsou nezávislé náhodné veličiny, X_i má distribuční funkci $F(x-\theta c_i)$, kde (c_1, \dots, c_n) jsou známé regresní konstanty, θ je neznámý parametr, který chceme odhadnout. Asymptoticky optimální R-odhad je generován skórovou funkcí

$$\psi_f(u) = - \frac{f'(F^{-1}(u))}{f(F^{-1}(u))}, \quad u \in (0, 1)$$

kde f a f' jsou hustota a její derivace příslušné F , F^{-1} je kvantilová funkce. Jestliže distribuční funkce F náleží do základního Tukeyova systému pak platí (pro $A_2, A_3 \in \langle 1/2, 2 \rangle$):

$$\psi_f(u) = - \frac{A_2(A_2-1) u^{A_2-2} - A_3(A_3-1)(1-u)^{A_3-2}}{A_4(A_2 u^{A_2-1} + A_3(1-u)^{A_3-1})^2}, \quad u \in (0, 1).$$

Tedy optimální skórovou funkcí známe až na parametry A_2, A_3, A_4 , nahradíme-li je odhady množenými výše, pak R-odhad generovaný takto vzniklou skórovou funkcí je asymptoticky optimální (ovšem za předpokladu, že F náleží do základního Tukeyova systému).

b) Nechť (X_1, \dots, X_n) je náhodný výběr z rozdělení s distribuční $F(X-\theta)$, kde θ je neznámý parametr, který chceme odhadnout a F je symetrická distribuční funkce. Asymptoticky optimální L-odhad je generován funkcí

$$J_F(u) = \psi'_{\varphi}(u) f(F^{-1}(u)) \left(\int \psi'_{\varphi}(y) f(F^{-1}(y)) dy \right)^{-1}. \quad u \in (0, 1).$$

Jestliže F náleží do Tukeyova systému, známe J_p až na parametr λ . Nahradíme-li λ některým z odhadů navržených výše, pak L-odhad, generovaný takto vzniklou funkcí J_p , je asymptoticky optimální (za předpokladu, že F náleží do Tukeyova systému). Další podrobnosti může čtenář nalézt v citované literatuře.

LITERATURA

- Chan, L. K. and Rhodin, L. S. (1980): Robust estimation of location using optimally chosen sample quantiles. *Technometrics* 22, 225-237.
- Filliben, J. J. (1969). Simple and robust estimation of the location parameter of a symmetric distribution. Ph. D. dissertation, Princeton University, Princeton, N. Y.
- Hušková, M. (1986). Simple estimators of the parameters of generalized Tukey's family, vyjde CMUC.
- Hušková, M. (1986). Adaptive estimators of parameters generalized Tukey's family, zaslánc k otištění.
- Joiner, B. L. and Rosenblatt, J. R. (1971). Some properties of the range in samples from Tukey's symmetric λ -distributions. *J. Amer. Statist. Assoc.*, 66, 394-399.
- Jones, D. H. (1979). An efficient adaptive distribution-free test for location, *J. Amer. Statist. Assoc.*, 74, 822-828.
- Ramberg, J. S. and Schmeiser, B. W. (1972). An approximate method for generating symmetric random variables, *Comm. of the ACM*, 15, 987-990.
- Ramberg, J. S. and Schmeiser, B. W. (1974). An approximative method for generating asymmetric random variables. *Comm. of the ACM*, 17, 78-82.
- Ramberg, J. S., Tadikamalla, P. R., Dudewicz, E. J. and Mykytka, E. F. (1979). A probability distribution and its uses in fitting data. *Technometrics* 21, 201-214.
- Tukey, J. W. (1960). The practical relationship between the common transformations of percentages or counts and of amounts. Technical Report 36, Statistical Research Group, Princeton University, Princeton, N. Y.