

KONSISTENCE M-ODHADŮ

Jana Jurečková, MFF UK Praha

I. Model polohy.

Nechť x_1, x_2, \dots je posloupnost nezávislých pozorování z populace s distribuční funkcí $F(x-\theta)$; distribuční funkce (d.f.) F je obecně neznámá, pouze předpokládáme, že patří do třídy \mathcal{F} distribučních funkcí symetrických kolem 0. Chceme odhadnout parametr θ na základě pozorování x_1, \dots, x_n .

Jednu z rozsáhlých tříd robustních odhadů parametru polohy tvorí M-odhady zavedené Huberem (1964). Definujme M-odhad M_n parametru θ jako globální minimum statistiky

$$(1.1) R_n(t) = \sum_{i=1}^n \varrho\left(\frac{x_i-t}{ks_n}\right) = \min$$

vzhledem k $t \in \mathbb{R}^1$, kde $s_n = s_n(x_1, \dots, x_n)$ je škálová statistika vyhovující podmírkám

$$(1.2) s_n(x_1+c, \dots, x_n+c) = s_n(x_1, \dots, x_n)+c$$

$$s_n(cx_1, \dots, cx_n) = c s_n(x_1, \dots, x_n), \quad c \in \mathbb{R}^1$$

a $k > 0$ je volitelná konstanta. O statistice s_n dále předpokládáme, že

$$(1.3) s_n \xrightarrow{P} G' = G'(F) > 0 \quad \text{při } n \rightarrow \infty$$

kde $G(F)$ je nějaký kladný funkcionál d.f.F. Řada autorů doporučuje volit konstantu k tak, aby získaný odhad byl vydatný pro nějakou speciální distribuční funkci F , většinou pro normální rozdělení.

Odhad, definovaný pomocí (1.1), je ekvivariantní vzhledem ke změně měřítka, tj.

$$(1.4) M_n(cx_1, \dots, cx_n) = c M_n(x_1, \dots, x_n), \quad c > 0.$$

Často se též volí $s_n = 1$; pak posloupnost s_n ovšem nevyhovuje (1.2) a výsledný odhad není ekvivariantní ve smyslu (1.4). Nejčastější robustní volbou s_n je buď mezikvartilová odchylka

$$(1.5) s_n = x_{n:}\left[\frac{3}{4}n\right] - x_{n:}\left[\frac{1}{4}n\right]$$

kde $x_{n:1} \leq \dots \leq x_{n:n}$ jsou pořadkové statistiky příslušné x_1, \dots, x_n (pak $G'(F) = F^{-1}(\frac{3}{4}) - F^{-1}(\frac{1}{4})$) nebo mediánová absolutní odchylka (MAD)

$$(1.6) s_n = \text{med}_{1 \leq i \leq n} |x_i - \tilde{x}_n|$$

kde \tilde{x}_n je medián x_1, \dots, x_n (pak $G'(F) = F^{-1}(3/4)$ pro symetrickou F).

Jestliže ϱ je konvexní funkce symetrická kolem 0, a tedy $\psi(x) = \frac{d\varrho}{dx}$ je neklesající antisymetrická funkce, lze M-odhad určit jednoznačně ve tvaru

$$M_n = \frac{M_n^-}{n} + \frac{M_n^+}{n}$$

$$(1.7) M_n^- = \sup \left\{ t : \sum_{i=1}^n \psi\left(\frac{x_i-t}{ks_n}\right) > 0 \right\}$$

$$M_n^+ = \inf \left\{ t : \sum_{i=1}^n \psi\left(\frac{x_i-t}{ks_n}\right) < 0 \right\}.$$

Jestliže navíc $\int \varrho(x-t) dF(x)$ má jediné minimum v $t=0$, pak M_n konverguje k θ v pravdě-

podobnosti i skoro jistě při $n \rightarrow \infty$ (Huber (1981)). V téže Huberové knize můžeme najít i obecnější podmínky pro konsistenci posloupnosti M_n . Speciálně, jestliže Ψ není nutně konvexní, ale je to absolutně spojitá, zdola ohrazená nekonstantní funkce symetrická kolem 0 a taková, že je neklesající na $[0, \infty)$, pak pro konsistenci M_n stačí, že F má silně unimodální hustotu f (tj. f je rostoucí pro $x < 0$ a klesající pro $x > 0$) [viz např. Freedman and Diaconis (1981, 1982)].

Nyní uvažujme, co se stane, když funkce

$$(1.8) \quad h(t) = \int \Psi(x-t) dF(x)$$

nemá globální minimum v bodě $t=0$. Pak platí následující tvrzení (Freedman and Diaconis (1982)):

Tvrzení 1. Nechť funkce Ψ je symetrická kolem 0 a má ohrazenou spojitou derivaci Ψ' . Nechť x_1, x_2, \dots jsou nezávislá pozorování se společnou distribuční funkcí $F(x-\theta)$, kde F je spojitá, symetrická kolem 0 a taková, že funkce $h(t)$, definovaná v (1.8), je ohrazená a nemá globální minimum v bodě $t=0$. Pak existuje $\epsilon > 0$ tak, že s pravděpodobností 1 statistika

$$(1.9) \quad R_n(t) = \sum_{i=1}^n \Psi(x_i - t)$$

pro dostatečně velká n nemá své globální minimum v intervalu $[-\epsilon, \epsilon]$. Speciálně, M-odhad definovaný jako globální minimum $R_n(t)$ není konsistentním odhadem θ .

Důkaz. Bez újmy obecnosti můžeme položit $\theta = 0$. Pak můžeme psát

$$n^{-1}R_n(t) = h(t) + \int \Psi(x-t) d(F_n(x) - F(x)) = h(t) - \int (F_n(x) - F(x)) \Psi(x-t) dx$$

kde $F_n(x)$ je empirická distribuční funkce příslušná x_1, \dots, x_n , tj. $F_n(x) = n^{-1} \sum_{i=1}^n I[x_i \leq x]$.

Pak tedy k libovolnému $\eta > 0$ existuje n_0 a pro $n \geq n_0$ platí

$$(1.10) \quad |n^{-1}R_n(t) - h(t)| \leq \eta.$$

Protože h nenabývá globálního minima v bodě $t=0$, existuje $t_0 \neq 0$ tak, že $h(t) > h(t_0)$.

Zvolme $\epsilon > 0$ a $m > 0$ tak, že $h(t) \geq h(t_0) + 3m$ pro $|t| \leq \epsilon$. Pak pro $|t| \leq \epsilon$ plyně z (1.10)

$$n^{-1}R_n(t) \geq h(t_0) + 2m$$

a

$$n^{-1}R_n(t_0) \leq h(t_0) + m$$

a tedy

$$n^{-1}R_n(t) \geq n^{-1}R_n(t_0) + m$$

pro $|t| \leq \epsilon$, odkud plyně tvrzení.

Rada autorů (viz např. Hampel, Ronchetti, Rousseeuw and Stahel (1985)), doporučuje užívat tzv. redescentní M-odhady, jimž příslušná funkce $\Psi(-\Phi)$ je buď rovna 0 pro $|x| \geq c$ nebo konverguje k 0 pro $|x| \rightarrow \infty$. Hlavním argumentem pro použití těchto funkcí je, že zcela potlačují vliv odlehlych pozorování na výsledný odhad. Taková funkce Ψ samozřejmě není neklesající a příslušná Φ není konvexní, a mohou tedy vést k M-odhadům, které nejsou konsistentní pro některá rozdělení pravděpodobnosti.

Uvedeme si některé příklady.

$$(a) \quad \Psi(x) = \log(1+x)^2$$

$$\Phi(x) = 2x/(1+x)^2$$

(Funkce Ψ je věrohodnostní funkci Cauchyho rozdělení).

$$(b) \quad \begin{cases} -(1-x^2)^3 & \dots |x| \leq 1 \\ 0 & \dots |x| > 1 \end{cases}$$

$$\varphi(x) = \begin{cases} 6x(1-x^2)^3 & \dots |x| \leq 1 \\ 0 & \dots |x| > 1 \end{cases}$$

(tzv. Tukey biweight)

$$(c) \quad \begin{cases} -(1-x^2)^2 & \dots |x| \leq 1 \\ 0 & \dots |x| > 1 \end{cases}$$

$$\varphi(x) = \begin{cases} 3x(1-x^2) & \dots |x| \leq 1 \\ 0 & \dots |x| > 1 \end{cases}$$

$$(d) \quad \begin{cases} x^2 & \dots |x| \leq 1 \\ 1 & \dots |x| > 1 \end{cases}$$

$$\varphi(x) = \begin{cases} x & \dots |x| \leq 1 \\ 0 & \dots |x| > 1. \end{cases}$$

\bar{x} -odhad, vytvořený těmito funkcemi, se v knize Andrews a kol. (1972) nazývá "skipped mean".

$$(e) \quad \begin{cases} \frac{1}{2} & \dots |x| \leq 1 \\ 1 & \dots |x| > 1 \end{cases}$$

$$\varphi(x) = \begin{cases} \text{sign } x & \dots |x| \leq 1 \\ 0 & \dots |x| > 1. \end{cases}$$

Příslušný odhad je v literatuře nazýván "skipped median".

Právě k některé z těchto funkcí může existovat distribuční funkce F , absolutně spojitá a symetrická, ale taková, že funkce (1.8) nahýdá v bodě $t=0$ nekoli minima, ale maxima. Pocházejí-li pozorování z rozdělení $f(x-\theta)$, znamená to, že globální minimum $R_n(t)$ (1.9) není konsistentním odhadem θ . Někdy je autorem doporučují jako odhad parametru θ to řešení rovnice $\sum_{i=1}^n \varphi(x_i - t) = 0$, které je ovšem ižde nějakému konsistentnímu počátečnímu odhadu, např. mediánu. V situaci, kterou jsme naznačili, by takový odhad $\hat{\theta}$ mohl být konsistentním odhadem, ale konverguje k bodu maxima funkce $h(t)$ (speciálně, u funkce(a) bychom tedy dostali "minimálně výrohodný odhad").

Friedman a Diaconis (1981, 1982) ukázali, že taková distribuční funkce (a hustoty) skutečně mohou existovat. Příklady naznačí moží multimodálními hustotami s ohraničeným nosičem. Popíšeme některé z jiných příkladů.

(i) $\varphi(x) = 1+x^2$, $x \in \mathbb{R}^1$ (výrohodnost funkce Cauchyho rozdělení) a $\varphi_h(x) \varphi(\frac{x}{h})$.
Pak

$$\psi^*(x) = (1-x^2)/(1+x^2)^2$$

Položme $x_0 = \sqrt{\sqrt{32} - 5} \approx 0.81$; zvolme libovolné k z intervalu $(1, 1/x_0)$ a x_1 z intervalu $(x_0, 1/k)$. Nechť Z je náhodná veličina, která nabývá hodnot $\pm kx_1$ a $\pm k\sqrt{3}$, každé s pravděpodobností $1/4$. Pak

$$E \Psi_k(Z) = E \left\{ k^{-2} \psi^*(Z/k) \right\} < 0$$

a funkce $E \{\Psi_k(Z)\}$ nabývá maxima v bodě $t=0$.

Nechť nyní Y je náhodná veličina ze symetrickou hladkou hustotou g , kladnou na $(-1, 1)$ a rovnou 0 jinak. Pak, pro dostatečně velká m , náhodná veličina

$Z_m^* = \frac{Z}{m} + \frac{Y}{m}$ má hladkou symetrickou multimodální hustotu na nosiči $[-2, 2]$ a funkce $E \{\Psi_k(Z_m^*-t)\}$ nabývá maxima v bodě $t=0$. Podle tvrzení i odtud plynne, že mají-li $X_1=0$, $X_2=0, \dots$ stejné rozdělení jako Z_m^* , je M-odhad vytvořený funkcí Ψ_k nekonsistentní.

V tomto případě můžeme dokonce dokázat:

a) Rovnice $\sum_{i=1}^n \psi_k(x_i-t)=0$ má tři kořeny, M_{-n}, M_{0n}, M_{+n} . Výraz $R_n(t) = \sum_{i=1}^n \Psi_k(x_i-t)$ má lokální maximum v $t=M_{0n}$ a lokální minima v bodě $t=M_{+n}, M_{-n}$. Jeden z bodů M_{+n}, M_{-n} je zároveň globálním minimem, a tedy M-odhadem 0. Existuje $\gamma = \gamma(F) > 0$, tak, že $M_{-n} \rightarrow -\gamma, M_{0n} \rightarrow 0$ a $M_{+n} \rightarrow \gamma$ s pravděpodobností 1 při $n \rightarrow \infty$. Dále existují podposloupnosti n_{+j} a n_{-j} přirozených čísel tak, že $R_{n_{+j}}(t)$ má globální minimum v $t=M_{+n_{+j}}$ a $R_{n_{-j}}(t)$ má globální minimum v $t=M_{-n_{-j}}$. Tedy M-odhad nekonečně mnohokrát osciluje mezi $-\gamma$ a γ a nemůže být silně konsistentní.

(ii) Uvažujme Tukeyho funkci (b). Pak, podobně jako v předcházejícím příkladě, položme-li $x_0 = \sqrt{3} - \sqrt{8} / \sqrt{5} \approx 0.185$ a zvolme k v intervalu $(\sqrt{5/3}, 1/x_0)$, můžeme najít hladkou symetrickou multimodální hustotu s ohrazeným nosičem tak, že odhad vytvořený funkcí ψ_k je nekonsistentní. Z numerických hodnot se ukazuje, že pro $k > 1/x_0 \approx 5.41$ je M-odhad patrně již konsistentní (Tukey navrhuje volit $k=6$).

(iii) Uvažujme funkci Ψ z příkladu (c) a libovolné $k > 1$. Pak existuje symetrická hladká hustota na ohrazeném nosiči taková, že třídi-li se pozorování touto hustotou, je M-odhad nekonsistentní.

Z těchto konstrukcí nemůžeme vyslovit jednoznačný závěr, spíše několik poznámek:

M-odhad je konstruovaný tak, aby omezil vliv odlehčích pozorování a rozdělení s těžkými chvosty. Použijeme-li však redescenčních M-odhadů, riskujeme, že odhad nebude konsistentní v případě rozdělení s lehkými chvosty, ke kterým typicky patří useknutá rozdělení a jiná rozdělení s ohrazeným nosičem. Pokud z povahy měření dat víme, že rozdělení je useknuté, jsme opatrní při použití redescenčních M-odhadů. Vzhledem k uvedeným protipříkladům je vhodné nejprve porovnat výběrové rozpětí s výběrovou mediánovou odchylkou: pokud je rozpětí menší než čtyřnásobek mediánové odchylky, nepoužijeme Cauchyho věrohodnostní funkci s hodnotou k blízkou 1; a funkci Ψ z příkladu (b) použijeme jen pro $k \geq 6$.

II. Lineární regresní model

Uvažujme klasický lineární regresní model

$$Y = X\beta + \epsilon$$

kde $\mathbf{y} = (y_1, \dots, y_n)'$ je vektor pozorování, $\mathbf{x} = x_n$ je daná regresní matici rádu $n \times p$, $\beta = (\beta_1, \dots, \beta_p)'$ je parametr a $\varepsilon = (e_1, \dots, e_n)'$ je vektor nezávislých chyb, stejně rozdělených s distribuční funkcí F . M-odhad (nestudentizovaný) definujeme jako řešení minimalizace

$$(2.1) \sum_{i=1}^n \Psi(y_i - x_i' \beta) := \min, \quad \beta \in \mathbb{R}^p$$

kde x_i' je i-tý řádek matice \mathbf{x} . Jestliže Ψ je konvexní funkce, je (2.1) ekvivalentní řešení soustavy rovnic

$$(2.2) \sum_{i=1}^n z_i \Psi'(y_i - x_i' \beta) = 0, \quad \Psi' = \psi'$$

Jestliže obecně Ψ není konvexní a funkce $h(t) = \int \Psi(x-t)dF(x)$ nemá minimum v bodě $t=0$, můžeme vyslovit týto závěry jako u modelu polohy, a tedy pro některá rozdělení chyb může být řešení (2.1) nekonsistentním odhadem β .

Všimněme si tedy podrobnější situace, kdy funkce Ψ a rozdělení F jsou takové, že Ψ je absolutně spojitá s derivací ψ a platí

$$(2.3) \gamma = \int \psi(x)dF(x) > 0.$$

Za tohoto předpokladu a za některých dalších podmínek regularity na posloupnost $\{x_n\}$ existuje řešení soustavy (2.2), které je konsistentním odhadem β a pro dostatečně velká n je řešením minimalizace (2.1). Jestliže navíc je Ψ konvexní funkce, je toto řešení určeno jednoznačně. Tímto případem se zabýval Portnoy (1984) a za více omezujících podmínek Yohai a Maronna (1979); tito autori dokonce připomínají situaci, že $\beta_n \rightarrow \infty$ při $n \rightarrow \infty$. Portnoy ve svém důkazu zajímavě použil vět z obecné teorie nelineárních rovnic, založených na větách o pevném bodě (viz Ortega a Rheinboldt(1970)). Podstatné pro použití těchto vět je, že levá strana rovnice (2.2) je spojitou funkcií t .

Nevyřešenou dosud zůstává otázka M-odhadu, vytvořeného funkcemi Ψ z příkladu (d) a (e) (skipped mean a skipped median u parametru polohy) a dalšími funkcemi, které nemají absolutně spojitou derivaci. Za předpokladu, že funkce Ψ je zdola ohrazená a funkce $h(t) = \int \Psi(x-t)dF(x)$ je ryze konvexní v bodě $t=0$, studovala tuto otázku Jurečková(1988). Za určitých podmínek regularity na posloupnost $\{x_n\}$ a na chování distribuční funkce v okolí bodu nespojitosti funkce Ψ ukázala, že minimalizace (2.1) je asymptoticky ekvivalentní minimalizaci konvexní kvadratické funkce, a že tedy existuje M-odhad, konsistentní vzhledem ke konvergenci v pravděpodobnosti a asymptoticky normální. Podstatný je však předpoklad, že $h(t)$ je ryze konvexní v bodě $t=0$ který, stejně jako v části I, nelze zaručit při neznámé distribuční funkci F .

Literatura

- Andrews, D.F., Bickel, P.J., Hampel, F.R., Huber, P.J., Rogers, W.H. and Tukey, J.W. (1972). Robust Estimates of Location. Survey and Advances. Princeton University Press.
- Freedman, D.A. and Diaconis, P. (1981). On inconsistent M-estimates. Technical Report No 170, Department of Statistics, Stanford University.
- Freedman, D.A., and Diaconis, P. (1982). On inconsistent M-estimators. Ann. Statist. 10, 454-461.
- Hampel, F.R., Ronchetti, E.M., Rousseeuw, P.J. and Stahel, W.A. (1985). Robust Statistics. The Approach Based on Influence Functions. J. Wiley, New York.
- Huber, P.J. (1964). Robust estimation of a location parameter. Ann. Math. Statist. 35, 73-101.
- Huber, P.J. (1981). Robust Statistics. J. Wiley, New York.
- Jurečková, J. (1988). Consistency of M-estimators in linear model generated by non-monotone and discontinuous Ψ -functions. Probability and Math. Statist. 1.
- Ortega, J.M. and Rheinboldt, W.C. (1970). Iterative Solution of Nonlinear Equations in Several Variables. Academic Press, New York.
- Portnoy, S. (1984). Asymptotic behavior of M-estimators of p regression parameters when p^2/n is large. I. Consistency. Ann. Statist. 12, 1298-1309.
- Yohai, V.J. and Maronna, R.A. (1979). Asymptotic behavior of M-estimators for the linear model. Ann. Statist. 7, 258-268.