

# M-ODHADY ZA PŘEDPOKLADU NEREGULÁRNÍ HUSTOTY

Jan SVATOŠ

MFF UK, KPMS

**Abstract:** Theory of  $M$ -estimators in linear regression model is well known. One of the classical regularity assumptions in the linear model  $Y = X\beta + E$  is the existence of  $f'$ . This paper studies the case when  $f'$  does not exist in the sense, that  $f(x) = |x - s_j|^{\alpha_j} q_j(x)$ , where  $j = 1, \dots, k$  is finite number of “singular points” of the density  $f$ . It is shown, that in such a case rate of the convergence of  $M$ -estimators depends on the minimum of  $\alpha_j$ .

**Резюме:** Проблематика  $M$ -оценок в линейной регрессии хорошо известна и разработана. В работах, которые интересуются этой проблематикой учитывают, что плотность вектора ошибок  $E$  в модели  $Y = X\beta + E$  регулярна. Это значит, что существует  $f'$ . Моя работа рассматривает ситуацию, когда  $f'$  не существует в том смысле, что  $f(x) = |x - s_j|^{\alpha_j} q_j(x)$ , где  $j = 1, \dots, k$  конечное число сингулярных точек плотности. Можно показать, что в таком случае степень скорости сходимости  $M$ -оценок изменяется в зависимости от минимума  $\alpha_j$ .

Předpokládejme platnost lineárního modelu

$$(1) \quad \mathbf{Y} = \mathbf{X}\beta + \mathbf{E}$$

s podmínkou na matici

$$(2) \quad \sum_1^n \|\mathbf{x}_i\|^4 = O(n),$$

kde  $\|(\cdot)\|$  označuje Euklidovskou normu,  $\mathbf{x}_i$  označuje  $i$ -tý řádek matice a  $\mathbf{E} = (\varepsilon_i)_1^n$ ,  $\varepsilon_i$  iid.  $M$ -odhadem neznámého parametru  $\beta$  je libovolné řešení minimalizace součtu

$$(3) \quad \sum_1^n \varrho(y_i - \mathbf{x}_i' \mathbf{b}) \text{ vzhledem k } \mathbf{b}.$$

Pokud existuje první derivace funkce  $\varrho$  a pokud  $\varrho$  je konvexní, pak lze definici (3) zjednodušit na tvar:

$$(4) \quad \sum_1^n \mathbf{x}_i \psi(y_i - \mathbf{x}'_i \mathbf{b}) \stackrel{!}{=} 0.$$

Uvažujme množinu  $S = \{s_1, s_2, \dots, s_k\}$  kde  $-\infty < s_1 < s_2 < \dots < s_k < \infty$ , a k ní příslušnou množinu  $\alpha_1, \dots, \alpha_k$ , přičemž  $\alpha_l \in (0, 2)$ ,  $l = 1, \dots, k$ . Označme dále  $\alpha_0 = \min_{1 \leq l \leq k} \alpha_l$  jako  $\cdot$ . Nechť hustota chybových složek existuje a nabývá tvaru

$$(5) \quad f(e) = q_l(e) |e - s_l|^{(\alpha_l - 1)}.$$

Pro  $\alpha_l \neq 1$  nechť  $q_l(e)$  splňuje Lipschitzovu podmínku řádu  $\alpha_0/2$ .

Předpoklady na funkci  $\psi$ :  $\psi = \psi_1 + \psi_2$  přičemž  $\psi_1$  je neklesající, absolutně spojitá funkce,  $\psi_2$  je neklesající skoková funkce. Dále předpokládejme splnění jedné ze dvou následujících podmínek:

(i)  $\psi'_1$  je absolutně spojitá a zároveň

$$(6) \quad \psi''_1 \text{ splňuje podmínku } \int_{\mathbb{R}} (\psi''_1(e+t))^2 dF(e) \leq C$$

při  $|t| < \delta$  pro nějaké reálné konstanty  $C, \delta > 0$

(ii)  $\psi_1$  je konstantní mimo omezený interval  $(a, b)$  a zároveň

$\psi'_1, \psi''_1$  jsou omezené uvnitř  $(a, b)$ .

Předpokládejme navíc, že  $\psi_1$  a  $\psi'_1$  jsou obě integrovatelné se čtvercem vzhledem k  $F(e)$ .

Podmínky na  $\psi_2$ :

$$(7) \quad \psi_2(e) = \begin{cases} a_0 & -\infty < e \leq s_1 \\ a_1 & s_1 < e \leq s_2 \\ \dots & \\ a_k & s_k < e < \infty \end{cases}$$

a

$$(8) \quad \sum_{l \in K_0} (a_l - a_{l-1}) q_l(s_l) > 0.$$

kde

$$K_0 = \{l : 1 \leq j \leq k, \alpha_l = \alpha_0\}.$$

Označme

$$(9a) \quad \gamma_1 = \int_{\mathbb{R}} \psi'_1(e) dF(e) > 0.$$

$$(9b) \quad \gamma_2 = \frac{1}{\alpha_0} \sum_{l \in K_0} (a_l - a_{l-1}) q_l(s_l) > 0.$$

Tvrzení dané v tomto článku bude ještě nutno rozšířit na obecnější  $\psi_1$ , konkrétně  $\psi'_1 =$  absolutně spojitá + skoková funkce. Důkaz pro tento případ bude podán v další práci. Problém asymptotického chování  $M$ -odhadu studovala v práci [1] Jurečková pro případ parametru polohy jednorozměrného rozdělení. Vzniká přirozený problém, které techniky důkazů projdou i pro regresní parametr a kdy je nutno zesílit podmínky na rozdělení a na  $\psi$  funkci. Prvním úkolem je zobecnit výsledek Lemmatu 3.1 z [1].

Za výše uvedených podmínek platí:  $\forall \tau \geq \frac{1}{2\alpha_0}$ :

$$\begin{aligned} & \lim_{n \rightarrow \infty} P_0 \left\{ \max_{\|\mathbf{t}\| \leq C} \left\| n^{-\frac{1}{2}} \sum_1^n \mathbf{x}_i [\psi(\varepsilon_i + n^{-\tau} \mathbf{x}'_i \mathbf{t}) - \psi(\varepsilon_i)] \right. \right. \\ & - n^{\frac{1}{2} - \tau \alpha_0} \gamma_2 \frac{1}{n} \sum_1^n \mathbf{x}_i \mathbf{x}'_i (|t_j|^{\alpha_0} \text{sign } t_j)_{j=1}^p \\ & \left. \left. - n^{\frac{1}{2} - \tau} \gamma_1 \frac{1}{n} \sum_1^n \mathbf{x}_i \mathbf{x}'_i \mathbf{t} \right\| \geq \varepsilon \right\} = 0 \quad \forall \varepsilon > 0, C > 0 \end{aligned}$$

Pro pevné  $\mathbf{t}$  důkaz prochází podobně jako v [1]. Za prvé je nutno ukázat, že rozptyl výrazu je asymptoticky zanedbatelný pro spojitou i diskretní část. Za druhé je zapotřebí ukázat, že aproximace střední hodnoty se od skutečné hodnoty liší pro  $n \rightarrow \infty$  pouze zanedbatelně. Pro řadu nerovností a omezení, které budou ukázány, je postačující podmínkou  $\sum \|\mathbf{x}_i\|^4 = O(n)$ , jelikož  $\tau \geq \frac{1}{4}$ . Nechť platí  $n^{-\tau} \mathbf{x}'_i \mathbf{t} > 0$ . Pro případ opačného znaménka platí následující technika stejným způsobem, pouze se prohodí integrační meze a na pravé straně poslední nerovnosti bude výraz  $n^{-\tau} \mathbf{x}'_i \mathbf{t} > 0$  v absolutní hodnotě.

$$\begin{aligned} & \text{var} [\psi_1(\varepsilon_i - n^{-\tau} \mathbf{x}'_i \mathbf{t}) - \psi_1(\varepsilon_i)] \\ & \leq E \left[ \int_0^{n^{-\tau} \mathbf{x}'_i \mathbf{t}} \int_0^{n^{-\tau} \mathbf{x}'_i \mathbf{t}} \psi'_1(\varepsilon_i - u) \psi'_1(\varepsilon_i - v) dudv \right] \\ & \leq \int_0^{n^{-\tau} \mathbf{x}'_i \mathbf{t}} \sqrt{E[\psi'_1(\varepsilon_i - u)]^2 [\psi'_1(\varepsilon_i - v)]^2} dudv = \\ & = \left\{ \int_0^{n^{-\tau} \mathbf{x}'_i \mathbf{t}} \sqrt{E[\psi'_1(\varepsilon_i - u)]^2} du \right\}^2 \\ & \leq n^{-\tau} \mathbf{x}'_i \mathbf{t} \int_0^{n^{-\tau} \mathbf{x}'_i \mathbf{t}} E[\psi'_1(\varepsilon_i - u)]^2 du \leq (n^{-\tau} \mathbf{x}'_i \mathbf{t})^2 \end{aligned}$$

Z toho plyne, že  $\forall j \in \{1, \dots, p\}$  platí:

$$\begin{aligned} & \text{var } n^{-\frac{1}{2}} \sum_i x_{ij} [\psi_1(\varepsilon_i - n^{-\tau} \mathbf{x}'_i \mathbf{t}) - \psi_1(\varepsilon_i)] \\ & \leq \frac{1}{n} \sum_i x_{ij}^2 (n^{-\tau} \mathbf{x}'_i \mathbf{t})^2 \\ & \leq C_1 n^{-2\tau} n^{-1} \|\mathbf{t}\|^2 \sum_i \|\mathbf{x}_i\|^4 \end{aligned}$$

A tedy postačující podmínkou pro konvergenci k nule je v tomto případě  $n^{-\frac{3}{2}+\delta} \sum_i \|\mathbf{x}_i\|^4 = O(1)$ ,  $\delta > 0$ .

Pro diskrétní složku budeme nejprve pracovat s

$$\psi_2(e) = \begin{cases} 0 & e \leq r \\ 1 & e > r \end{cases}$$

Tedy

$$\psi_2(\varepsilon_i - n^{-\tau} \mathbf{x}'_i \mathbf{t}) - \psi_2(\varepsilon_i) = \begin{cases} 1 & r + n^{-\tau} \mathbf{x}'_i \mathbf{t} < \varepsilon_i < r \\ -1 & r + n^{-\tau} \mathbf{x}'_i \mathbf{t} > \varepsilon_i > r \\ 0 & \text{jinak} \end{cases}$$

Nechť  $n^{-\tau} \mathbf{x}'_i \mathbf{t} > 0$ . Pak

$$\begin{aligned} & P(\psi_2(\varepsilon_i - n^{-\tau} \mathbf{x}'_i \mathbf{t}) - \psi_2(\varepsilon_i) = -1) = F(r + n^{-\tau} \mathbf{x}'_i \mathbf{t}) - F(r) \\ & = \int_0^{n^{-\tau} \mathbf{x}'_i \mathbf{t}} f(r+u) du = \int_0^{n^{-\tau} \mathbf{x}'_i \mathbf{t}} q_l(r+u) u^{\alpha_l-1} du \\ & \leq \int_0^{n^{-\tau} \mathbf{x}'_i \mathbf{t}} (|q_l(r+u) - q_l(r)| + |q_l(r)|) u^{\alpha_l-1} du \\ & \leq u^{\varepsilon_l+\alpha_l-1} du + C_l \int_0^{n^{-\tau} \mathbf{x}'_i \mathbf{t}} u^{\alpha_l-1} du \leq K_l^* (n^{-\tau} \mathbf{x}'_i \mathbf{t})^{\alpha_l} \end{aligned}$$

Tedy dostáváme, že platí

$$\begin{aligned} & \text{var } n^{-\frac{1}{2}} \sum_i x_{ij} [\psi_2(\varepsilon_i - n^{-\tau} \mathbf{x}'_i \mathbf{t}) - \psi_2(\varepsilon_i)] \leq K n^{-1} \sum_i x_{ij}^2 n^{-\tau \alpha_l} |(\mathbf{x}'_i \mathbf{t})|^{\alpha_l} \\ & \leq K n^{-\tau \alpha_0} n^{-1} \|\mathbf{t}\|^{\alpha_0} \sum_i x_{ij}^2 \|\mathbf{x}_i\|^{\alpha_0} \leq K_2 n^{-\tau \alpha_0} n^{-1} \sum_i \|\mathbf{x}_i\|^{2+\alpha_0} \end{aligned}$$

Vzhledem k definici  $\tau$  platí  $\frac{\mathbf{x}'_i \mathbf{t}}{n^\tau} \rightarrow 0$ . Nyní je zapotřebí ukázat, jak malé jsou rozdíly mezi středními hodnotami a jejich aproximacemi.

$$\begin{aligned} & n^{-\frac{1}{2}} \sum_i x_{ij} E[\psi_1(\varepsilon_i - n^{-\tau} \mathbf{x}'_i \mathbf{t}) - \psi_1(\varepsilon_i) - n^{-\tau} \gamma_1 \mathbf{x}'_i \mathbf{t}] \\ & \leq K n^{-\frac{1}{2}} \sum_i |x_{ij}| |\mathbf{x}'_i \mathbf{t}|^2 n^{-2\tau} \\ & \leq K n^{-\frac{1}{2}} n^{-2\tau} \|\mathbf{t}\|^2 \sum_i \|\mathbf{x}_i\|^3 \end{aligned}$$

Pro diskrétní složku nabývá rozdíl tvaru:

$$\begin{aligned}
E[\psi_2(\varepsilon_i - n^{-\tau} \mathbf{x}'_i \mathbf{t}) - \psi_2(\varepsilon_i)] &= \text{asymptoticky} \\
&\sum_{j=1}^k (a_j - a_{j-1}) \{F(s_j) - F(s_j - n^{-\tau} \mathbf{x}'_i \mathbf{t})\} \\
&= \sum_{j=1}^k (a_j - a_{j-1}) \int_{-n^{-\tau} \mathbf{x}'_i \mathbf{t}}^0 f(s_j + u) du \\
&= \sum_{j=1}^k (a_j - a_{j-1}) \int_{-n^{-\tau} \mathbf{x}'_i \mathbf{t}}^0 |u|^{\alpha_j - 1} q_j(s_j + u) du
\end{aligned}$$

Poznámka ke slovu "asymptoticky": Střední hodnota na levé straně rovnice ve skutečnosti nabývá hodnoty

$$\sum_k \sum_j (a_j - a_{j-k}) P\{\varepsilon_i + n^{-\tau} \mathbf{x}'_i \mathbf{t} > s_j \& \varepsilon_i < s_{j-k+1}\}$$

Pokud ovšem  $n^{-\tau} \mathbf{x}'_i \mathbf{t} \rightarrow 0$ , což je splněno z podmínky (2) vždy, když  $\tau > 1/4$ , pak  $\exists n_0 : P\{\varepsilon_i + n^{-\tau} \mathbf{x}'_i \mathbf{t} > s_j \& \varepsilon_i < s_{j-k+1}, k \geq 2\} = 0 \forall |t| \leq C, n \geq n_0$  a tedy není nutno uvažovat skoky většího než prvního řádu. Pro  $\tau = 1/4$  však není podmínka (2) postačující ke splnění  $n^{-\tau} \mathbf{x}'_i \mathbf{t} \rightarrow 0$  a musí tedy být zesílena podmínka na matici  $\mathbf{X}$ . Odečtením aproximace na konec dostáváme

$$\begin{aligned}
&\|n^{-\frac{1}{2}} \sum_i \mathbf{x}_i \{E[\psi_2(\varepsilon_i - n^{-\tau} \mathbf{x}'_i \mathbf{t}) - \psi_2(\varepsilon_i)] - \\
&\quad - \frac{1}{\alpha_0} n^{-\tau \alpha_0} \sum_{j \in K_0} (a_j - a_{j-1}) q_j(s_j) (\mathbf{x}'_i \mathbf{t})^{\alpha_0}\}\| \\
&\leq K_1 n^{-\frac{1}{2}} \sum_i \|\mathbf{x}_i\| n^{-\frac{3}{4}} (\mathbf{x}'_i \mathbf{t})^{\alpha_0 + \varepsilon} + \\
&\quad K_2 n^{-\frac{1}{2}} \sum_i \|\mathbf{x}_i\| n^{-\frac{\alpha_1}{2\alpha_0}} (\mathbf{x}'_i \mathbf{t})^{\alpha_1} \\
&\leq K_1 \|\mathbf{t}\|^{\alpha_0 + \varepsilon} n^{-\frac{1}{4}} n^{-1} \sum_i \|\mathbf{x}_i\|^{1 + \alpha_0 + \varepsilon} + \\
&\quad + K_2 \|\mathbf{t}\|^{\alpha_1} n^{-\delta} n^{-1} \sum_i \|\mathbf{x}_i\|^{1 + \alpha_1}
\end{aligned}$$

kde  $\alpha_1 = \min_l \{\alpha_l \neq \alpha_0\}$ .

Pro  $\alpha_0 = \alpha_l \forall l$  druhý člen zmizí. Pro konvergenci celého výrazu k nule je nyní postačující pomínkou (2), protože bez újmy na obecnosti lze brát  $\varepsilon = \alpha_0/2$ .

Toto lemma je užitečným nástrojem pro důkaz hlavní věty, která ukazuje řád konvergence. Věta říká:

$$n^{\frac{1}{2\alpha_0}} \|M_n - \beta\| = O_p(1)$$

přičemž  $M_n$  je  $M$ -odhad definovaný ve (4), hustota splňuje (5) a funkce  $\psi$  vyhovuje podmínkám (6) až (9a,b). Zde nelze přímo použít techniku z práce [1], jelikož problém má obecně více než jeden rozměr. Proto je nutné k důkazu věty použít jiný způsob. Hlavní myšlenka tohoto postupu je ukázána v práci [2]. Nechť  $\psi$  je absolutně spojitá, tedy nechť  $\psi = \psi_1$ . Pak

$$P\left\{ \sup_{\|\mathbf{t}\|=C} \mathbf{t}' \sum_i \mathbf{x}'_i \psi(\varepsilon_i - n^{-1/2\alpha_0} \mathbf{x}'_i \mathbf{t}) \geq 0 \right\} \rightarrow 0$$

dává, že řešení úlohy

$$\sum_i \mathbf{x}_i \psi(\varepsilon_i - n^{-1/2\alpha_0} \mathbf{x}'_i (\mathbf{M}_n - \beta)) \stackrel{!}{=} 0$$

leží v kouli se středem v  $\mathbf{0}$  a poloměrem  $C$ . Pro dokončení důkazu je použita věta 6.3.4. z práce [3]. Konvergence se ukáže pomocí stejnoměrného omezení výrazu

$$P\left\{ \sup_{\|\mathbf{t}\|=C} \mathbf{t}' \sum_i \mathbf{x}'_i \psi(\varepsilon_i - n^{-1/2\alpha_0} \mathbf{x}'_i \mathbf{t}) \geq 0 \right\}.$$

A nyní dostáváme výsledek ze skutečnosti, že řešení výše uvedeného problému je ekvivalentní skutečnosti, že  $\mathbf{M}_n$  je  $M$ -odhad.

#### REFERENCES

1. Jurečková, J., *Asymptotic Behavior of M-estimators of Location in Nonregular Cases*, *Statistics & Decisions* **1** (1983), 323-340.
2. Jurečková, J. and Sen, P.K., *Robust Statistical Procedures: Asymptotics and Interrelations*, 1996.
3. Ortega, J.M. and Rheinboldt, W. C., *Iterativa Solution of Nonlinear Equations in Several Variables*, Academic Press, New York, 1970.