

# ROBUSTNÍ ODHADY BAYESOVSKÉHO TYPU

Jan Hanousek, MFF UK

## 1. ÚVOD

V poslední době, hlavně díky automatickému zpracování dat, se stále častěji používají robustní metody. Bohužel, dosavadní typy robustních odhadů nevyužívají předchozích poznatků v datech. Na druhé straně bayesovské odhady nejsou robustní. Cílem tohoto článku je spojit vhodné vlastnosti obou tříd odhadů (robustnost a využití apriorní informace) a vytvořit třídu robustních odhadů bayesovského typu.

Nechť  $x_1, x_2, \dots, x_n$  jsou nezávislé stejně rozdelené náhodné veličiny se společnou hustotou  $f(x-\theta)$  (vzhledem k Lebesgueově mítě), kde  $\theta \in \Theta \subset \mathbb{R}$ . Budeme předpokládat, že parametrický prostor  $\Theta$  je otevřený interval a "skutečnou" hodnotu parametru  $\theta$  budeme označovat  $\theta_0$ .

### Definice 1.1.

Odhad parametru polohy  $\theta_0$ , který je definován vztahem

$$(1.1) \quad T_n = \frac{\int t \cdot \exp\left\{-\sum_{i=1}^n (\varphi(x_i-t)\right\} \pi(t) dt}{\int \exp\left\{-\sum_{i=1}^n (\varphi(x_i-t)\right\} \pi(t) dt},$$

pokud oba integrály existují, budeme nazývat  $\theta$ -odhadem generovaným funkcí  $\varphi$ .

Všimněme si blíže zavedení  $\theta$ -odhadů. Vidíme, že  $\theta$ -odhad generovaný funkcí  $\varphi$  je vlastně bayesovská aposteriorní střední hodnota náhodné veličiny  $\theta$  mající apriorní hustotu  $\pi(y)$  v případě, že hustota pozorování  $f(x) = c \cdot \exp(-\varphi(x))$ . Můžeme proto očekávat, že za určitých podmínek budou  $\theta$ -a  $M$ -odhady asymptoticky ekvivalentní a že při vhodné volbě funkce  $\varphi$  (tj. takové, která se užívá v  $M$ -odhadech) získáme odhad bayesovského typu s dobrými robustními vlastnostmi. Tuto úvahu potvrzuje věta 2.1. Její důkaz je založen na kombinaci asymptotické linearity s výsledky Ibragimova a Chasminského (1972, 1973). Pro lepší orientaci uvedeme jejich předpoklady upravené na náš model:

## I.

(I.1) Rozdelení  $P_g$  náhodných veličin  $x_i$  je absolutně spojité vzhledem k Lebesguově mítě v definované na  $\sigma$ -algebře podmnožin  $\mathbb{R}^1$ ; označme  $g(x-\theta) = dP_g/dy$ .

(I.2) Parametrický prostor  $\Theta$  je otevřený interval (omezený nebo neomezený) v  $\mathbb{R}^1$ .

(I.3) Hustota  $g(x-\theta)$  je měřitelná vzhledem k  $\mathcal{E} \times \mathcal{E}$ , kde  $\mathcal{E}$  je  $\sigma$ -algebra měřitelných množin reálné přímky.

(I.4) Je-li  $\theta \neq \theta'$ , potom

$$\int_{\mathbb{R}^1} |g(x-\theta) - g(x-\theta')| dx > 0.$$

## II.

(II.1)  $I = \int \psi^2(x) g(x) dx < \infty$ .

III.

(III.1) Existuje  $\delta > 0$  tak, že

$$\sup_{\Theta} |\theta - \theta_0|^\delta \cdot \int \sqrt{(g(x-\theta) \cdot g(x-\theta_0))} dx < \infty .$$

IV.

(IV.1) Funkce  $\pi(\theta)$  je měřitelná funkce  $\theta \in \mathbb{R}^1$ , nulová vně  $\Theta^c$ .

(IV.2) Existuje nezáporné číslo  $p_0$  tak, že

$$\sup_{\Theta} (1 + |\theta|^{p_0})^{-1} \cdot \pi(\theta) < \infty .$$

(IV.3) Funkce  $\pi(\theta)$  je spojitá v okolí  $\theta_0$  a  $\pi(\theta_0) \neq 0$ .

V následující kapitole jsou studovány asymptotické vlastnosti B-odhadů v modelu polohy a v lineárním modelu. Za určitých podmínek kladených na apriorní rozdělení, na rozdělení chyb a na funkci  $\varphi$ , je odvozena asymptotická reprezentace a asymptotické rozdělení B-odhadů a je ukázáno, že B- a M-odhady jsou asymptoticky ekvivalentní.

Třetí kapitola je věnována bodu selhání B-odhadů, v závěrečné části je provedena numerická ilustrace vlastností B-odhadů, ve které jsou hodnoty B-odhadů vypočteny numerickou integrací pomocí Gaussových kvadraturních vzorců.

## 2. ASYMPTOTICKÁ REPREZENTACE B-ODHADŮ

### A. Odhad parametru polohy

Uvažujme model polohy z předcházející části a předpokládejme, že  $f$  má absolutně spojitou sudou hustotu  $f$  a konečnou Fisherovu informaci. Nechť  $\psi(x) : \mathbb{R} \rightarrow \mathbb{R}$  je funkce vyhovující následující skupině podmínek:

$$(A.1) \quad \psi(x) = \partial \varphi(x) / \partial x,$$

$$(A.2) \quad \begin{aligned} \psi &\text{ je neklesající spojitá funkce, která má ohrazenou derivaci pro } x \in (a; b) \\ &\text{ a } \psi(x) \text{ je konstantní pro } x < a \text{ a } x > b (-\infty < a < b < \infty). \end{aligned}$$

Označme

$$g(x) = c \cdot \exp(-\varphi(x)),$$

kde

$$(2.1) \quad c = 1 / \int_R \exp(-\varphi(x)) dx.$$

Předpokládejme, že existuje konstanta  $p > 1$  taková, že

$$(B.1) \quad \int_R f(x)^p \cdot g(x)^{1-p} dx \leq 1.$$

### Poznámky:

(i) Postačující podmínkou pro (B.1) je, aby  $\chi^p$ -divergence hustot  $f(x)$  a  $g(x)$  byla menší nebo rovna 1, tj. aby

$$\int |f(x)/g(x)-1|^p g(x) dx \leq 1.$$

(definice  $\chi$ -divergence - viz např. Vajda).

Tato podmínka může být nahrazena jakoukoli podmínkou implikující kontinuitu  $\{P_n\}$  a  $\{Q_n\}$ .

(ii) Při důkazech asymptotických vlastností B-odhadů budeme vycházet z toho, že B-odhad je bayesovský odhad v případě, že  $g(x)$  je hustota pozorování. Podmínka (B.1) je přirozená; tříká, jak moc se může naše "hypotetická" hustota  $g(x)$  lišit od  $f(x)$ . Jak dále uvidíme, podmínka (B.1) požaduje, aby chvasty  $f(x)$  nebyly těžší než chvasty  $g(x)$  při  $x \rightarrow \pm \infty$ .

### Věta 2.1.

Nechť  $T_n$  a  $M_n$  jsou po řadě B- a M-odhad generovaný funkciemi  $\varphi$ . Nechť funkce  $g(x)$  definovaná v (2.1) a apriorní hustota  $\pi(\theta)$  splňují výše uvedené podmínky a podmínky I-IV.

Potom pro  $n \rightarrow \infty$  platí

$$(2.2) \quad T_n - M_n = o_p(n^{-1/2})$$

a

$$(2.3) \quad T_n - \theta_0 + n^{-1} \cdot f^{-1} \cdot \sum_{i=1}^n \psi(x_i - \theta_0) + o_p(n^{-1/2}),$$

kde

$$f = \int \psi(x) dF(x).$$

Všimněme si, že asymptotická reprezentace B-odhadů nezávisí na počátečním rozdělení  $\pi(\theta)$ . Je to přirozené, protože informace o parametru  $\theta$  obsažená v pozorováních asymptoticky převýší počáteční informaci obsaženou v apriorním rozdělení. Věta 2.1 se dá dokázat stejným způsobem i pro širší třídu funkcí  $\psi$  a  $\varphi$ . Podmínkou je, aby pro funkci platila asymptotická linearita a aby funkce  $g$  a  $\pi$  splňovaly předpoklady I-IV a (B.1).

### Důkaz věty 2.1.

Nejprve si uvědomme, že podmínky věty (2.1) zaručují asymptotickou linearitu funkce a asymptotickou reprezentaci M-odhadu  $M_n$  ve tvaru

$$M_n = \theta_0 + n^{-1} \cdot f^{-1} \cdot \sum_{i=1}^n \psi(x_i - \theta_0) + o_p(n^{-1}).$$

Stačí proto dokázat pouze tvrzení (2.3).

Podle věty 2.1 Jurečková (1980) konverguje proces

$$M(t) = \left\{ \sum_{i=1}^n [\psi(x_i - n^{-1/2}t - \theta_0) - \psi(x_i - \theta_0)] + n^{1/2}f \cdot t : |t| \leq M \right\}$$

slabě k procesu  $\{t \cdot X : |t| \leq M\}$ , kde  $X \sim N(0; \sigma^2)$ .

Podle Prochorovovy věty spojité zobrazení  $M(t)$  (ve Skorochadové topologii) konverguje slabě ke spojitému zobrazení limitního procesu. Tedy platí, že

$$\int_0^s \left( \sum_{i=1}^n [\psi(x_i - n^{-1/2}t - \theta_0) - \psi(x_i - \theta_0)] + n^{1/2}t \cdot f \right) dt \rightarrow \int_0^s t \cdot X dt$$

pro  $0 \leq s \leq M$ .  $X$  opět značí náhodnou veličinu s normálním rozdělením  $N(0; \sigma^2)$ . Analogický vztah získáme pro  $-M \leq s \leq 0$ . integrací obou vztahů obdržíme, že proces

$$\left\{ n^{1/2} \sum_{i=1}^n [\varphi(x_i - \theta_0) - \varphi(x_i - \theta_0 - n^{-1/2}s)] - s \sum_{i=1}^n \psi(x_i - \theta_0) + n^{1/2}f \cdot \frac{s^2}{2} : |s| \leq M \right\}$$

konverguje slabě k procesu  $\left\{ \frac{s^2}{2} \cdot X : 0 \leq s \leq M \right\}$ .

Odtud zřejmě plyne vztah

$$(2.4) \sup_{|t| \leq M} \left| \sum_{i=1}^n [\varphi(x_i - \theta_0) - \varphi(x_i - \theta_0 - n^{-1/2}t)] - n^{-1/2}t \cdot \sum_{i=1}^n \gamma(x_i - \theta_0) + \frac{t^2}{2} \right| = o_p(n^{-1/2}).$$

Na druhé straně z definice  $\theta$ -odhadu po jednoduché substituci  $s = \theta_0 + n^{-1/2}t$  získáme rovnost

$$T_n = \theta_0 + n^{-1/2} \cdot \frac{\int t \exp\left\{ \sum_{i=1}^n [\varphi(x_i - \theta_0) - \varphi(x_i - n^{-1/2}t - \theta_0)] \right\} \pi(\theta_0 + n^{-1/2}t) dt}{\int \exp\left\{ \sum_{i=1}^n [\varphi(x_i - \theta_0) - \varphi(x_i - n^{-1/2}t - \theta_0)] \right\} \pi(\theta_0 + n^{-1/2}t) dt}.$$

Je-li funkce  $g$  společná hustota pozorování, potom z důkazu věty 3.1 (Ibragimov, Chasminskij (1973)) plyne, že

$$(2.5) T_n = \theta_0 + n^{-1/2} \cdot \frac{\int_0^\infty t \exp\left\{ \sum_{i=1}^n [\varphi(x_i - \theta_0) - \varphi(x_i - n^{-1/2}t - \theta_0)] \right\} \pi(\theta_0 + n^{-1/2}t) dt}{\int_0^\infty \exp\left\{ \sum_{i=1}^n [\varphi(x_i - \theta_0) - \varphi(x_i - n^{-1/2}t - \theta_0)] \right\} \pi(\theta_0 + n^{-1/2}t) dt} + o_p(n^{-1/2})$$

kde  $D > 0$  je konstanta nezávislá na  $n$ .

Označme

$$g_n(x_1, x_2, \dots, x_n) = \prod_{i=1}^n g(x_i)$$

$$f_n(x_1, x_2, \dots, x_n) = \prod_{i=1}^n f(x_i).$$

Nechť  $Q_n$  resp.  $P_n$  jsou pravděpodobnostní míry s hustotami  $g_n$  resp.  $f_n$  vzhledem k Lebesgueově mítě.

Dále označme

$$A_n = \left[ \left| n^{1/2}(T_n - \theta_0) - \frac{\int_0^\infty t \exp\{ \dots \} \pi(\theta_0 + n^{-1/2}t) dt}{\int_0^\infty \exp\{ \dots \} \pi(\theta_0 + n^{-1/2}t) dt} \right| > \varepsilon \right],$$

kde  $\varepsilon > 0$ .

Potřebujeme dokázat, že vztah (2.5) platí i v případě, že hustota pozorování je  $f(x)$ , tedy že platí

$$Q_n(A_n) \rightarrow 0 \Rightarrow P_n(A_n) \rightarrow 0.$$

Stačí tedy dokázat, že míry  $P_n$  jsou kontiguitní vzhledem ke  $Q_n$ . Postačující podmínkou pro kontiguitu mér je (viz lemma 3.5 Jurečková (1969)), aby pro každé  $\varepsilon > 0$  existovalo  $\delta > 0$  a  $n_0 \in \mathbb{N}$  tak, že pro  $n \geq n_0$  platí

$$Q_n(A_n) < \delta \Rightarrow P_n(A_n) < \varepsilon.$$

Nechť  $p > 1$ . Využijeme Schwarzovu nerovnost s podmínkou (B.1). Dostáváme

$$P_n(A_n) = \int \prod_{i=1}^n \frac{f(x_i)}{g(x_i)} \cdot \prod_{i=1}^n g(x_i) \cdot I_{A_n}(x_1, \dots, x_n) dx_1 \dots dx_n$$

$$\leq (\int f(x) P_g(x)^{1-p} dx)^{\frac{n}{p}} \cdot (Q_n(A_n))^{\frac{p-1}{p}}.$$

Míry  $P_n$  jsou tedy kontignitní vzhledem ke  $Q_n$  (stačí volit  $\delta = \varepsilon^{p(p-1)}$ ) a vztah (2.5) platí i v případě, že hustota pozorování je  $f(x)$ .

Vzhledem k tomu, že konstanta  $D > 0$  je nezávislá na  $n$ , můžeme použít společně (2.4) a (2.5).

Obdržíme vztah

$$T_n = \theta_0 + n^{-1/2} \frac{\int_0^D t \cdot \exp\left\{n^{-1/2}t \sum_{i=1}^n \psi(x_i - \theta_0) - \frac{1}{2}t^2\right\} \cdot \pi(\theta_0 + n^{-1/2}t) dt}{\int_{-D}^D \exp\left\{n^{-1/2}t \sum_{i=1}^n \psi(x_i - \theta_0) - \frac{1}{2}t^2\right\} \cdot \pi(\theta_0 + n^{-1/2}t) dt} + o_p(n^{-1/2}).$$

Označme

$$C_n = n^{-1/2} \int_{-D}^D \psi(x_i - \theta_0) dt.$$

Substitucí  $s = t - C_n$  dostáváme

$$(2.6) \quad T_n = \theta_0 + n^{-1/2} \int_{-D-C_n}^{D-C_n} \frac{t \cdot \exp(-\frac{1}{2}t^2) \pi(*) dt}{\int_{-D-C_n}^{D-C_n} \exp(-\frac{1}{2}t^2) \pi(*) dt} + o_p(n^{-1/2}).$$

$$* = \theta_0 + n^{-1/2}(t + C_n)$$

protože konstanta  $D > 0$  je nezávislá na  $n$ , je posloupnost  $\{D_m\}_{m=1}^\infty$ , kde  $D_m = m \cdot D$ ,  $m = 1, 2, \dots$  také nezávislá na  $n$ .

Dále, z centrální limitní věty plyne, že  $C_n = O_p(1)$ . Tyto skutečnosti společně s podmínkami IV. (spojitost a nenulovost  $\pi(y)$  v okolí  $\theta_0$ ) zaručují, že třetí člen na pravé straně výrazu (2.6) bude též  $O_p(n^{-1/2})$ . Tím je věta 2.1 dokázána.

### Důsledek 2.1

Za podmínek věty 2.1, při  $n \rightarrow \infty$ , má  $n^{-1/2}(T_n - \theta_0)$  asymptoticky normální rozdělení s nulovou střední hodnotou a s rozptylem

$$\sigma^2 = E \psi^2 \cdot J^{-2},$$

kde

$$J = \int \psi'(x) dF(x).$$

Nyní se zaměříme na rozšíření těchto výsledků na lineární model.

### B. Lineární model

Nechť  $Y_1, \dots, Y_n$  jsou nezávislé náhodné veličiny s distribučními funkcemi  $F_1, F_2, \dots, F_n$  pro které platí

$$F_i(y) = F(y - x_i \theta), \quad i = 1, 2, \dots, n,$$

kde  $\theta = (\theta_1, \dots, \theta_p)'$  je vektor neznámých parametrů;  $x_i$ ,  $i=1, \dots, n$  jsou známé vektory regresních konstant a distribuční funkce  $F$  je absolutně spojitá a symetrická kolem  $0$ . Tedy budeme předpokládat, že pro náhodný vektor pozorování  $\tilde{y} = (Y_1, Y_2, \dots, Y_n)'$  platí

$$\tilde{y} = x\theta + \varepsilon,$$

kde  $X = (x_{i,j})$  je známá (design) matice  $n \times p$  s plnou hodností,  $\theta = (\theta_1, \dots, \theta_p)'$  je vektor neznámých parametrů a  $\varepsilon = (\varepsilon_1, \dots, \varepsilon_n)'$  je vektor chyb, které jsou nezávislé, stejně rozdělené se soudou hustotou  $f(x)$ .

Budeme uvažovat případ, kdy matice  $X$  má speciální tvar; máme  $p$  lineárně nezávislých vektorů  $x'_1, \dots, x'_p$  a  $i$ -tý vektor (řádek) se v matici  $X$   $n_i$ -krát opakuje  $i=1, \dots, p$  a platí  $\sum_{i=1}^p n_i = n$ .

Dostáváme analogii jednoduchého třídění - model, který můžeme zapsat ve tvaru

$$(2.7) \quad Y_{ij} = x'_i \theta + \varepsilon_{ij}, \quad j=1, \dots, n_i, \\ i=1, \dots, p.$$

Označíme-li

$$\beta_i = x'_i \theta, \quad i=1, \dots, p$$

je situace obdobná jako v modelu polohy. Máme  $p$  nezávislých výběrů z rozdělení  $f(x-\theta_1), \dots, f(x-\theta_p)$ . Každé  $\beta_i$  je tedy parametrem polohy  $i$ -tého výběru  $Y_{i1}, \dots, Y_{in}$ . Toho využijeme pro odhad neznámých parametrů  $\theta_1, \dots, \theta_p$  ev. pro odhad lineární funkce těchto parametrů  $\beta'_i \theta$ .

Označme

$$\tilde{x}^* = \begin{bmatrix} x'_1 \\ \vdots \\ x'_p \end{bmatrix}$$

regulérní matici  $p \times p$ .

Je-li  $\hat{\theta}$  libovolný odhad neznámého vektoru  $\theta$  (tedy i  $\theta$ -resp.  $M$ -odhad) potom pro odhady  $\hat{\beta}_i$  a  $\hat{\beta}' \cdot \hat{\theta}$  platí

$$\hat{\beta}_i = \tilde{x}^{*-1} \cdot \hat{\theta}$$

a

$$\hat{\beta}' \cdot \hat{\theta} = \hat{\beta}' \cdot \tilde{x}^{*-1} \cdot \hat{\theta}.$$

$\theta$ -odhad vektoru  $\theta$  generovaný funkcí  $\varphi$ , který budeme označovat  $\tilde{\theta}^\theta = (\tilde{\theta}_1^\theta, \dots, \tilde{\theta}_p^\theta)'$  je definován vztahem

$$\tilde{\theta}^\theta = \tilde{x}^{*-1} \cdot \tilde{\tau}^\theta,$$

kde  $\tilde{\tau}^\theta = (\tilde{\tau}_1^\theta, \dots, \tilde{\tau}_p^\theta)'$  je  $\theta$ -odhad vektoru  $\beta$ , který vznikl sdružením jednotlivých  $\theta$ -odhadů parametru polohy. To znamená, že

$$(2.8) \quad \tilde{\tau}_i^\theta = \frac{\int t \cdot \exp \left\{ - \sum_{j=1}^{n_i} \varphi(Y_{ij}-t) \right\} \cdot \pi_i(t) dt}{\int \exp \left\{ - \sum_{j=1}^{n_i} \varphi(Y_{ij}-t) \right\} \cdot \pi_i(t) dt}$$

Pokud oba integrály existují,  $\pi_i(y)$  zde značí apriorní hustotu náhodné veličiny  $x'_i \theta$ .

Můžeme tedy stejným způsobem dokázat asymptotickou reprezentaci B-odhadů v tomto jednoduchém lineárním modelu.

### Věta 2.2

Nechť  $Y_{ij}$ ,  $j=1, \dots, n_i$ ;  $i=1, \dots, p$  jsou nezávislé náhodné veličiny splňující model (2.7).  
Předpokládejme, že pro  $n \rightarrow \infty$  platí

$$(2.9) \quad \frac{n_i}{n} \rightarrow \lambda_i \quad , \quad 0 < \lambda_i < 1 \quad , \quad i=1, \dots, p$$

$$\sum_{i=1}^p \lambda_i = 1 \quad .$$

Označme  $T_n^k = (T_1^k, \dots, T_p^k)'$  B-odhad vektoru  $\beta$ , který vznikl sdružením jednotlivých B-odhadů parametrů polohy  $\beta_i$ .

Potom za předpokladů věty 2.1 platí pro  $n \rightarrow \infty$

$$T_i^k = \beta_i + n^{-1} \cdot \lambda_i^{-1} f^{-1} \cdot \sum_{i=1}^{n_i} \gamma(Y_{ij} - \beta_i) + o_p(n^{-1/2}), \quad i=1, \dots, p.$$

Důkaz: Ztejmy důsledek věty 2.1

Označime-li  $\beta_n^0 = (T_1^0, \dots, T_p^0)'$  B-odhad vektoru neznámých parametrů  $\beta$ ,

$$\xi = \begin{pmatrix} \underbrace{\lambda_1^{-1}, \dots, \lambda_1^{-1}}_{n_1\text{-krát}}, 0 \dots & \dots 0 \\ 0, \dots, 0, \underbrace{\lambda_2^{-1}, \dots, \lambda_2^{-1}}_{n_2\text{-krát}}, 0 \dots & \dots 0 \\ 0, \dots & \dots, 0 \underbrace{\lambda_p^{-1}, \dots, \lambda_p^{-1}}_{n_p\text{-krát}} \end{pmatrix}$$

matici rádu  $p \times n$  a

$$g = (\gamma(Y_{11} - \beta_1), \dots, \gamma(Y_{1n_1} - \beta_1), \dots, \gamma(Y_{p1} - \beta_p), \dots, \gamma(Y_{pn_p} - \beta_p))'$$

vektor délky  $n$ , potom dostáváme asymptotickou reprezentaci ve tvaru

$$(2.10) \quad T_n^0 = \beta + n^{-1} f^{-1} x^{*-1} \cdot \xi \cdot g + o_p(n^{-1/2}).$$

### Důsledek 2.2.

Za podmínek věty 2.2, při  $n \rightarrow \infty$ , má  $n^{1/2}(T_n^0 - \beta)$  asymptoticky normální rozdělení s vektorem střední hodnoty 0 a s rozptylovou varianční maticí

$$S = E \gamma^2 \cdot f^{-2} \tilde{x}^{*-1} \cdot \text{diag} \{ \lambda_1, \dots, \lambda_p \} \cdot (\tilde{x}^{*-1})' ,$$

kde

$$f = \int \gamma'(x) dF(x).$$

### Poznámka:

Stejně jako v modelu polohy, asymptotická reprezentace B-odhadu implikuje vztah

$$T_n^0 - \beta_n^0 = o_p(n^{-1/2}),$$

kde  $M_n^B$  je M-odhad  $B$ , který vznikl způsobem popsaným na začátku.

### 3. BOD SELHÁNÍ B-ODHADU

#### A. Parametr polohy

##### Věta 3.1

Nechť  $\varphi$  je sudá a konvexní,  $0 < \lim_{|x| \rightarrow \infty} \varphi(x)/|x| = c < \infty$ .  
Je-li  $\int y \cdot \pi(y) dy < \infty$ , potom bod selhání B-odhadu (1.1) je  $\varepsilon^* = (n+1)/(2n+1)$ , v opačném případě  $\varepsilon^* = 1/2$ .

##### Věta 3.2

Předpokládejme nyní, že  $\varphi$  je sudá,  $\varphi(0) = 0$  a že  $\varphi$  je neklesající na obou stranách ( $x \rightarrow \pm \infty$ ). Nechť

$$\lim_{|x| \rightarrow \infty} \varphi(x) = +\infty,$$

ale

$$\lim_{|x| \rightarrow \infty} \varphi(x)/|x| = 0.$$

Předpokládejme, že  $\psi = \varphi'$  je spojitá a že existuje  $x_0$  takové, že  $\psi$  je neklesající pro  $0 < x < x_0$  a nerostoucí pro  $x_0 < x < \infty$ . Nechť existuje konstanta  $k > 0$  taková, že

$$\int |t| \cdot \exp\{-k \cdot \varphi(t)\} \cdot \pi(t) dt < \infty.$$

Potom bod selhání B-odhadu (1.1) splňuje  $\varepsilon^* > (n-k)/(2n-k)$ , je-li  $k \leq 1$ , pak  $\varepsilon^* = 1/2$ .

##### Důkaz vět 3.1 a 3.2

Důkaz lze provést analogicky (jde o jednoduché zobecnění) jako důkazy vět 5.2 a 6.1 v Huber (1984), proto ho ponecháváme čtenáři.

Vzhledem k asymptotické equivalenci B-a M-odhadů očekáváme, že i bod selhání odpovídajícíct B- a M-odhadů bude stejný. Situace je trochu jiná, díky vlivu apriorního rozdělení. Všimněme si, že funkce  $\pi(y)$  obsažená v obou integrálech nemůže změnit bod selhání B-odhadu vzhledem k odpovídajícímu P-odhadu ( $\pi(y) \equiv 1$ ).

Je to logické, protože zde funkce  $\pi(y)$  slouží jako váhová funkce, která (vzhledem k odpovídajícímu P-odhadu) dává odlehlym pozorováním malou váhu (menší nebo rovnou 1). Všimněme si, že informace  $\int t \cdot \pi(t) dt < \infty$  je ekvivalentní (z hlediska selhání odhadu) jednomu pozorování. Ve speciálním případě, má-li funkce  $\pi(y)$  kompaktní nosič, je bod selhání roven 1, neboť informace o parametru  $\theta$  obsažená v  $\pi(y)$  je z hlediska selhání velmi "silná" a k vlastnímu selhání B-odhadu vůbec nedojde. Ovšem taková situace je okrajová a může být snadno samostatně prozkoumána.

#### 8. Lineární model

Vzhledem k našemu modelu (2.4) je situace podobná jako v předchozí části, s tím, že máme p-modelu polohy, každý s  $n_i$  pozorováními ( $n_i \geq 1$ ) a předpokládáme, že pro  $n \rightarrow \infty$

$$n_i/n \rightarrow \lambda_i, \quad i=1, \dots, p, \quad \lambda_i > 0$$

$$\sum_{i=1}^p \lambda_i = 1.$$

Vidíme, že odhad selže, pokud selže odhad v alespoň jednom modelu polohy. Označme

$$\lambda^* = \min_{1 \leq i \leq p} \lambda_i.$$

Dostáváme snadné důsledky vět 3.1 a 3.2.

### Věta 3.3

Nechť jsou splněny předpoklady věty 3.1.

Je-li  $\int t \cdot \pi(t)dt < \infty$ , potom bod selhání  $\theta$ -odhadu (2.8) je  $\varepsilon^* = \frac{\lambda^* + 1/n}{1 + \lambda^* + 1/n}$ ,

v opačném případě  $\varepsilon^* = \frac{\lambda^*}{1 + \lambda^*}$ .

### Věta 3.4

Nechť jsou splněny předpoklady věty 3.2.

Potom bod selhání  $\theta$ -odhadu (2.8) splňuje  $\varepsilon^* > \frac{\lambda^* - k/n}{1 + \lambda^* - k/n}$ , je-li  $k \leq 1$ , potom

$$\varepsilon^* = \frac{\lambda^*}{1 + \lambda^*}.$$

Oprát, jako v předcházející části neuvažujeme případ, že  $\pi(y)$  má kompaktní nosič.

Všimněme si ale, že je-li náš model "vyvážený", tj.  $n_i = \frac{n}{p}$  (v každé skupině provádíme stejný počet pozorování), je bod selhání  $\varepsilon^* = \frac{1}{p+1}$  resp.  $\frac{1+1/n}{1+p+p/n}$  resp. je větší než  $\frac{1+pk/n}{1+p+pk/n}$ .

### Použitá literatura

- 1 Andrews D.R. et al: Robust Estimates of Location. Survey and Advances. Princeton University Press, 1972.
- 2 Billingsley P.: Convergence of Probability Measures. New York, John Wiley, 1968.
- 3 Hanousek J.: Asymptotic relation of M-and P-estimators of location, Comp.Statist. and Data Anal. 6(1988), 277-284.
- 4 Hanousek J.: Robust Bayesian type estimators and their asymptotic representation. Submitted (1988).
- 5 Huber P.J.: Robust Statistics. New York, John Wiley, 1981.
- 6 Huber P.J.: Finite sample breakdown of M- and P- estimators. The Annals of Statistics, 1984, Vol. 12, No. 1, 119-126.
- 7 Ibragimov I.A., Chasminskij R.Z.: Asimptotičeskie pověděníje některých statistických ocenek I. Teoriya věrojatnostej i její priměnění, 1972, 17, 3, 469-486.
- 8 Ibragimov I.A., Chasminskij R.Z.: Asimptotičeskie pověděníje některých statistických ocenek II. Teoriya věrojatnostej i její priměnění, 1973, 18, 1, 78-93.
- 9 Johns M.V.: Robust Pitman-like estimators. Robustness in Statistics, 49-60, New York, Academic Press, 1979.
- 10 Jurečková J.: Asymptotic representation of M-estimators of location. Math. Operationsforschung und Statistik, Ser. Statistik, 1980, 11, 61-73.
- 11 Jurečková J.: Asymptotic linearity of rank statistic in regression parameter. The Annals of Mathematical Statistics, 1969, 40, 6, 1889-1900.
- 12 Krylov V.I.: Approximate Calculation of Integrals. MacMillan, New York-London, 1962.
- 13 Serfling R.J.: Approximation Theorems of Mathematical Statistics. New York, John Wiley, 1980.
- 14 Vajda I.: Teória informácie a štatistického rozhodovania, Alfa, Bratislava 1982.