

# M9750 Robustní a neparametrické statistické metody

# Statistické modely

- $\mathbf{X} = (X_1, \dots, X_n)'$  je vektor pozorování.
- Parametrický model -  $\mathbf{X}$  má sdruženou distribuční funkci  $F(\mathbf{x}, \theta)$ ,  $F$  známe až na hodnotu neznámého parametru  $\theta$ .
- Neparametrický model - nepředpokládá žádný specifický tvar rozdělení, neznámý parametr je nekonečněrozměrný.
- Semiparametrický model - model má parametrickou i neparametrickou složku s konečně i nekonečněrozměrným parametrem.

# Robustní postupy

## Robustní metody

- nejsou citlivé na porušení předpokladů modelu (normalita, odlehlá pozorování, apod.).
- zachovávají si eficienci, pokud předpoklady porušeny nejsou.

Odlehlá pozorování (outliers). Proč je hned neodstraníme z dat?

- Jsme líní. Neodhalíme je.
- Nejsme líní, ale neodhalíme je (typicky ve vyšších dimenzích).
- Máme málo pozorování, nehceme ztratit informaci obsaženou v datech.
- Odstraněním podhodnotíme odhad rozptylu.

# Normalita

**Poincaré (1912):** Všichni věří v normální rozdělení chyb.

Experimentátoři proto, že je pokládají za matematický teorém, a matematikové proto, že je pokládají za experimentální fakt.

# Ověřování normality

Obecně mluvíme o metodách pro ověření shody teoretického a empirického rozdělení = vyhovují data naší představě (našemu modelu)?  
Dále se budeme zabývat ověřováním předpokladu normality dat.

## Grafické metody:

- histogram
- jádrový odhad hustoty
- boxplot
- Q-Q plot
- P-P plot

# Statistické testy sloužící k ověřování normality

- regresní testy: Shapirův - Wilkův test
- testy založené na empirických distribučních funkcích: Kolmogorovův - Smirnovův test
- testy dobré shody: Pearsonův  $\chi^2$  test

Matematický model:

- $X_1, \dots, X_n$  je náhodný výběr z rozdělení s distribuční funkcí  $F$ .
- $H_0$ :  $F$  je distribuční funkce (nějakého) normálního rozdělení.
- $H_1$ :  $F$  není distribuční funkce normálního rozdělení.

# Shapirův - Wilkův test

- je založen na porovnání dvou odhadů rozptylu  $\sigma^2$  – výběrového rozptylu  $S^2$  a nejlepšího odhadu získaného metodou nejmenších čtverců za předpokladu normality.
- Testová statistika:

$$W = \frac{\left(\sum_{i=1}^n a_i X_{(i)}\right)^2}{\sum_{i=1}^n (X_i - \bar{X})^2},$$

- $(a_1, \dots, a_n)^T = \frac{\mathbf{m}^T \mathbf{V}^{-1}}{(\mathbf{m}^T \mathbf{V}^{-1} \mathbf{V}^{-1} \mathbf{m})^{1/2}},$
- $\mathbf{m} = (m_1, \dots, m_n)^T, m_i = \mathbb{E} Y_{(i)},$
- $\mathbf{V} = (v_{ij})_{i,j=1}^n, v_{ij} = C(Y_{(i)}, Y_{(j)}),$
- $Y_1, \dots, Y_n$  je náhodný výběr z normovaného normálního rozdělení  $\mathcal{N}(0, 1)$ .
- $W \leq 1$  a pro alternativu svědčí malé hodnoty  $W$ .
- Rozdělení  $W$  za  $H_0$  je tabelováno.
- Test se hodí pro malé rozsahy výběru ( $n \leq 50$ ).

# Kolmogorovův - Smirnovův test

- Nulová hypotéza  $H_0: F = F^*$ , kde  $F^*$  je distribuční funkce  $\mathcal{N}(\mu, \sigma^2)$  s  $\mu$  a  $\sigma^2$  známými.
- Definujme empirickou distribuční funkci

$$\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{I}_{\{X_i \leq x\}}.$$

- Testová statistika  $D_n = \max_{x \in \mathbb{R}} \{|\hat{F}_n(x) - F^*(x)|\}$ .
- Za platnosti  $H_0$  má  $\sqrt{n}D_n$  asymptotické rozdělení stejné jako  $\sup_{t \in [0,1]} |B(t)|$ , kde  $B(t)$  je Brownův most v  $\mathcal{C}(0, 1)$ .
- Test se dá použít jen, když  $\mu$  a  $\sigma^2$  jsou známé.

# Lillieforsova modifikace Kolmogorovova - Smirnovova testu

- Nulová hypotéza  $H_0$ :  $F$  je distribuční funkce (nějakého) normálního rozdělení.
- Upravená testová statistika  $D_n^* = \max_{i=1,\dots,n} \left\{ \left| \frac{i}{n} - \Phi \left( \frac{x_{(i)} - \hat{\mu}}{\hat{\sigma}} \right) \right| \right\}$ .
- Asymptotické rozdělení  $\sqrt{n}D_n^*$  je jiné než  $\sqrt{n}D_n$ .
- Proto se používají upravené kvantily (kritické hodnoty).

# Pearsonův $\chi^2$ test dobré shody

- Nulová hypotéza  $H_0: F = F^*$ , kde  $F^*$  je distribuční funkce  $\mathcal{N}(\mu, \sigma^2)$  s  $\mu$  a  $\sigma^2$  známými.
- Definujme si intervaly  $(b_{i-1}, b_i]$ ,  $i = 1, \dots, k$ , kde  $b_0 = -\infty$ ,  $b_k = \infty$ .
- Označme  $Y_i$  počet pozorování, které padnou do intervalu  $(b_{i-1}, b_i]$  pro  $i = 1, \dots, k$ .
- Určíme očekávaný počet pozorování, které by měly padnout do intervalu  $(b_{i-1}, b_i]$ :

$$np_i = np_i(\mu, \sigma^2) = nP(X_1 \in (b_{i-1}, b_i]) = n \int_{b_{i-1}}^{b_i} f(x, \mu, \sigma^2) dx.$$

- Testová statistika

$$\chi^2 = \sum_{i=1}^k \frac{(Y_i - np_i(\mu, \sigma^2))^2}{np_i(\mu, \sigma^2)}.$$

- $\chi^2$  má za platnosti nulové hypotézy asymptoticky  $\chi^2$  rozdělení s  $k - 1$  stupni volnosti.

# Modifikace Pearsonova $\chi^2$ testu dobré shody

- Nulová hypotéza  $H_0$ :  $F$  je distribuční funkce (nějakého) normálního rozdělení.
- Testová statistika

$$\tilde{\chi}^2 = \sum_{i=1}^k \frac{(Y_i - np_i(\hat{\mu}, \hat{\sigma}^2))^2}{np_i(\hat{\mu}, \hat{\sigma}^2)}.$$

- $\tilde{\chi}^2$  má za platnosti nulové hypotézy asymptoticky  $\chi^2$  rozdělení s  $k - 3$  stupni volnosti.

Volba tříd:

- $p_i(\hat{\mu}, \hat{\sigma}^2) = \frac{1}{k}$ .
- Heuristická pravidla pro počet tříd –  $k \doteq 2n^{2/5}$ , nebo  $k \doteq 15(n/100)^{2/5}$ .

# Matematické nástroje robustnosti

- Model:  $X_1, \dots, X_n$  je náhodný výběr;  $X_i$  má rozdělení rozdělení pravděpodobnosti  $P = P_{\theta}$ , kde  $\theta \in \Theta \subset \mathbb{R}^p$ .
- Neznámý parametr  $\theta$  budeme chápat jako nějaký funkcionál daného rozdělení pravděpodobnosti, tj.  $\theta = T(P)$ .
- Jeho přirozeným (empirickým) odhadem je funkcionál  $T(P_n)$ , kde  $P_n$  je empirické rozdělení pravděpodobnosti náhodných veličin  $X_1, \dots, X_n$ .
- $P_n$  je diskrétní rovnoměrné rozdělení na množině  $\{X_1, \dots, X_n\}$  a jeho příslušná distribuční funkce je empirická distribuční funkce.

# Matematické nástroje robustnosti

## Definition

Nechť  $\mathcal{P}$  je množina všech pravděpodobnostních rozdělení na  $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ .

Nechť  $P, Q \in \mathcal{P}$  a  $0 \leq t \leq 1$ . Rozdělení pravděpodobnosti

$P_t(Q) = (1 - t)P + tQ$  nazveme kontaminací  $P$  rozdělením  $Q$  v poměru  $t$ .

## Definition

Nechť  $T$  je funkcionál na  $\mathcal{P}$ . Řekneme, že  $T$  je diferencovatelný (v Gâteauxově smyslu) podle  $P$  ve směru  $Q$ , jestliže existuje limita

$$T'_Q(P) = \lim_{t \rightarrow 0_+} \frac{T((1 - t)P + tQ) - T(P)}{t}.$$

$T'_Q(P)$  se nazývá Gâteauxova derivace  $T$  podle  $P$  ve směru  $Q$ .

# Taylorův rozvoj

- Taylorův rozvoj funkcionálu  $T$ :  $T(Q) = T(P) + T'_Q(P) + o_P(1)$ .
- Nyní zvolme  $Q = P_n = \frac{1}{n} \sum_{i=1}^n \delta_{x_i}$ , kde  $\delta_x$  je Diracova míra v  $x$ , tj.  $\delta_x(x) = 1$ ,  $\delta_x(y) = 0$  jinak.
- 

$$\begin{aligned} T(P_n) - T(P) &= T'_{P_n}(P) + o_P(1) = \frac{1}{n} \sum_{i=1}^n T'_{\delta_{x_i}}(P) + o_P(1) \\ &= \frac{1}{n} \sum_{i=1}^n T'_{x_i}(P) + o_P(1). \end{aligned}$$

- $\frac{1}{n} \sum_{i=1}^n T'_{x_i}(P)$  je (přibližně) chyba odhadu  $T(P_n)$ .
- Člen  $T'_{x_i}(P)$  je příspěvek  $X_i$  k této chybě.

# Influenční funkce

## Definition

Influenční funkcí funkcionálu  $T$  v bodě  $P$  nazveme derivaci  $T$  podle  $P$  ve směru  $\delta_x$ ,  $x \in \mathbb{R}$ , tj.

$$IF(x, T, P) = T'_x(P) = \lim_{t \rightarrow 0_+} \frac{T((1-t)P + t\delta_x) - T(P)}{t}.$$

- Influenční funkce popisuje efekt kontaminace našeho rozdělení jedním bodem  $x$  na na odhad, který hledáme.
- Má-li být odhad robustní, influenční funkce by měla být omezená.

# Kvantitativní charakteristiky robustnosti

- Globální citlivost funkcionálu  $T$  pro rozdělení pravděpodobnosti  $P$ :  
 $\gamma^* = \sup_{x \in \mathbb{R}} |IF(x, T, P)|.$
- Lokální citlivost funkcionálu  $T$  pro rozdělení pravděpodobnosti  $P$ :  
$$\lambda^* = \sup_{x, y \in \mathbb{R}, x \neq y} \left| \frac{IF(y, T, P) - IF(x, T, P)}{y - x} \right|.$$
- Bod selhání  $\epsilon^*$ .
- A další...

# Bod selhání

- Označme  $\mathbf{x}^0$  počáteční realizaci náhodného výběru a příslušný funkcionál  $T_n(\mathbf{x}^0)$ .
- Dále v  $\mathbf{x}^0$  nahradíme  $m$  jeho složek co nejnepříznivějšími hodnotami ( $i + -\infty$ ), označme jej  $\mathbf{x}^{(m)}$  a příslušný funkcionál  $T_n(\mathbf{x}^{(m)})$ .
- Bod selhání odhadu  $T_n$  ve výběru  $\mathbf{x}^0$  nazveme číslo  $\epsilon_n^*(T_n, \mathbf{x}^0) = \frac{m^*(\mathbf{x}^0)}{n}$ , kde  $m^*(\mathbf{x}^0)$  je nejmenší celé číslo, pro které  $\sup_{\mathbf{x}^{(m)}} |T_n(\mathbf{x}^{(m)}) - T_n(\mathbf{x}^0)| = \infty$ .
- Pokud  $\epsilon_n^*(T_n, \mathbf{x}^0)$  nezávisí na  $\mathbf{x}^0$  definujeme bod selhání odhadu  $T_n$  jako  $\epsilon^* = \lim_{n \rightarrow \infty} \epsilon_n^*(T_n, \mathbf{x}^0)$ .

# M-odhady jednorozměrného parametru $\theta$

- M-odhad parametru  $\theta$  je definován jako  
 $\hat{\theta} = \arg \min_{\theta \in \Theta} \sum_{i=1}^n \rho(X_i, \theta)$ , kde  $\rho$  je nějaká, vhodně zvolená funkce.
- Existuje-li derivace  $\psi(\cdot, \theta) = \frac{d\rho(\cdot, \theta)}{d\theta}$  a je spojitá, pak  $\hat{\theta}$  je (jedním z) řešení rovnice  $\sum_{i=1}^n \psi(X_i, \theta) = 0$ .
- Influenční funkce M-odhadu je

$$IF(x, T, P) = - \frac{\psi(x, T(P))}{\int_{\mathbb{R}} \frac{d\rho(y, \theta)}{d\theta} \Big|_{\theta=T(P)} dP(y)}.$$

- Má-li být M-odhad robustní, měl by mít omezenou funkci  $\psi$ .

# M-odhad parametru polohy (posunutí)

- Model polohy:  $X_i$  mají distribuční funkci  $F(x - \theta)$ , kde  $F$  je symetrická kolem bodu  $\theta$ .
- Ekvivalentně:  $X_i = \theta + \epsilon_i$ , kde  $\epsilon_i$  mají distibuční funkci  $F$ , symetrickou kolem 0.
- M-odhad parametru polohy  $\theta$  je definován jako  $\hat{\theta} = \arg \min_{\theta \in \Theta} \sum_{i=1}^n \rho(X_i - \theta)$ , kde  $\rho$  je nějaká, vhodně zvolená funkce.
- Existuje-li derivace  $\psi(y) = \rho'(y)$  a je spojitá, pak  $\hat{\theta}$  je (jedním z) řešení rovnice  $\sum_{i=1}^n \psi(X_i - \theta) = 0$ .
- Influenční funkce M-odhadu pro parametr polohy je

$$IF(x, T, P) = \frac{\psi(x - T(P))}{\int_{\mathbb{R}} \psi'(y) dP(y)}.$$

## M-odhad parametru polohy - volba funkce $\psi$

- $\rho(x) = x^2, \psi(x) = x$  ... výběrový průměr - není robustní.
- $\rho(x) = |x|, \psi(x) = \text{sign}(x)$  ... výběrový medián.
- $\psi_H(x) = \begin{cases} x, & |x| \leq k, \\ k \cdot \text{sign}(x), & |x| > k \end{cases}$ , kde  $k > 0$  je pevně zvolená konstanta ... Huberův odhad.
- $\psi(x) = \frac{2x}{1+x}$  ... věrohodnostní funkce Cauchyho rozdělení.
- $\psi_T(x) = \begin{cases} x \left[ 1 - \left( \frac{x}{k} \right)^2 \right], & |x| \leq k, \\ 0, & |x| > k \end{cases}$ , kde  $k > 0$  je pevně zvolená konstanta ... Tukeyho biweight.
- $\psi_A(x) = \begin{cases} \sin \left( \frac{x}{k} \right), & |x| \leq k\pi, \\ 0, & |x| > k\pi \end{cases}$ , kde  $k > 0$  je pevně zvolená konstanta ... Andrewsova sinusová funkce.

## M-odhad parametru polohy - volba funkce $\psi$ - pokrač.

- $\psi(x) = \begin{cases} |x| \cdot \text{sign}(x), & |x| \leq a, \\ a \cdot \text{sign}(x), & a < |x| \leq b, \\ a \frac{c-|x|}{c-b} \cdot \text{sign}(x), & b < |x| \leq c, \\ 0, & |x| > c \end{cases}$ , kde  $0 < a < b < c$  jsou pevně zvolené konstanty ... Hampel.
- $\psi(x) = \begin{cases} x, & |x| \leq k, \\ 0, & |x| > k \end{cases}$ , kde  $k > 0$  je pevně zvolená konstanta ... skipped mean.
- $\psi(x) = \begin{cases} \text{sign}(x), & |x| \leq k, \\ 0, & |x| > k \end{cases}$ , kde  $k > 0$  je pevně zvolená konstanta ... skipped median.

# L-odhad parametru polohy

- Označme  $X_{(1)} \leq \dots \leq X_{(n)}$  pořádkové statistiky (uspořádaný náhodný výběr) pro náhodný výběr  $X_1, \dots, X_n$ .
- L-odhad parametru polohy je definován jako  $T_n = \sum_{i=1}^n c_i h(X_{(i)})$ , kde  $h$  je nějaká funkce a  $c_i$  jsou vhodné konstanty.
- Pro odvozování teoretických vlastností se předpokládá, že

$$c_i = \int_{\frac{i-1}{n}}^{\frac{i}{n}} J(s) ds,$$

kde  $J : [0, 1] \rightarrow \mathbb{R}$  je nějaká funkce.

# L-odhad parametru polohy - příklady

- Výběrový průměr  $\bar{X}$ .
- Výběrový medián  $\tilde{X}$ .
- Střed rozpětí  $\frac{X_{(1)} + X_{(n)}}{2}$ .
- $\alpha$  - useknutý průměr

$$\bar{X}_{\alpha}^u = \frac{1}{n - 2\lfloor n\alpha \rfloor} \sum_{i=\lfloor n\alpha \rfloor + 1}^{n - \lfloor n\alpha \rfloor} X_{(i)}.$$

- $\alpha$  - winsorizovaný průměr

$$\bar{X}_{\alpha}^w = \frac{1}{n} \left\{ \lfloor n\alpha \rfloor X_{\lfloor n\alpha \rfloor} + \sum_{i=\lfloor n\alpha \rfloor + 1}^{n - \lfloor n\alpha \rfloor} X_{(i)} + \lfloor n\alpha \rfloor X_{(n - \lfloor n\alpha \rfloor)} \right\}.$$

# R-odhad parametru polohy

- Jsou inverzí pořadových testů o parametru polohy  $\theta$ .
- Testujme hypotézu  $H_0 : \theta = \theta_0$ , kde  $\theta_0$  je známá hodnota, pomocí pořadového testu.
- Testová statistika je  $S_n(\theta_0) = \sum_{i=1}^n \text{sign}(X_i - \theta_0) a_n(R_i^+(\theta_0))$ .
- $R_i^+(\theta_0)$  je pořadí  $|X_i - \theta_0|$  mezi  $|X_1 - \theta_0|, \dots, |X_n - \theta_0|$  a  $a_n : \{1, \dots, n\} \rightarrow \mathbb{R}$  je nějaká funkce pořadí.
- Za platnosti nulové hypotézy platí  $\mathbb{E}S_n(\theta_0) = 0$ .
- To nás vede k tomu, hledat odhad  $\theta$  jako řešení rovnice  $S_n(\theta_0) = 0$ .
- $S_n(\theta_0)$  je nerostoucí, schodovitá funkce - řešení nemusí existovat.
- R-odhad parametru  $\theta$  tedy definujeme jako  $T_n = \frac{1}{2}(T_n^+ + T_n^-)$ , kde  $T_n^+ = \inf\{t : S_n(t) > 0\}$  a  $T_n^- = \sup\{t : S_n(t) < 0\}$ .

## R-odhad parametru polohy - příklady

- $a_n(1) = \dots = a_n(n) = 1$ , pak  $T_n = \tilde{X}$  je výběrový medián (inverze znaménkového testu).
- $a_n(i) = i$ , pak  $T_n = \text{med} \left\{ \frac{X_i + X_j}{2}, 1 \leq i \leq j \leq n \right\}$  je Hodgesův - Lehmannův odhad (inverze Wilcoxonova testu).
- $a_n(i) = \Phi^{-1} \left( \frac{i}{n+1} \right)$ , pak  $T_n$  je inverzí van der Waerdenova testu; musí být počítán numericky.

# Odhady parametru polohy ve více dimenzích

- Bud' nyní  $\theta$  neznámý  $p$ -rozměrný parametr polohy. Označme jeho odhad  $\hat{\theta}$ .
- Uvažujme kvadratickou ztrátovou funkci  $L(\hat{\theta}, \theta) = \|\hat{\theta} - \theta\|^2$ .
- Riziko odhadu  $\hat{\theta}$  definujeme jako  $R(\hat{\theta}, \theta) = \mathbb{E}L(\hat{\theta}, \theta)$ .

## Definition

Bud'te  $\hat{\theta}_1, \hat{\theta}_2$  dva odhady parametru  $\theta$ . Řekneme, že  $\hat{\theta}_1$  dominuje  $\hat{\theta}_2$ , jestliže  $R(\hat{\theta}_1, \theta) \leq R(\hat{\theta}_2, \theta)$  pro všechny hodnoty  $\theta$  a existuje  $\theta_0$  tak, že  $R(\hat{\theta}_1, \theta_0) < R(\hat{\theta}_2, \theta_0)$ .

## Definition

Odhad  $\hat{\theta}$  parametru  $\theta$  je přípustný (admissible), jestliže neexistuje žádný jiný odhad parametru  $\theta$ , který by jej dominoval.

## Jamesův - Steinův odhad

- Nechť  $\mathbf{X}_1, \dots, \mathbf{X}_n$  je náhodný výběr z  $p$ -rozměrného normálního rozdělení  $\mathcal{N}_p(\boldsymbol{\theta}, \sigma^2 \mathbf{I}_p)$ , kde  $\sigma^2 > 0$  je známé.
- Je-li  $p \geq 3$ , pak výběrový průměr  $\bar{\mathbf{X}}$  není přípustný odhad parametru  $\boldsymbol{\theta}$ .
- Dominuje jej mj. Jamesův - Steinův odhad  $\hat{\boldsymbol{\theta}}_{JS} = \left(1 - \frac{(p-2)\sigma^2}{n\|\bar{\mathbf{X}}\|^2}\right) \bar{\mathbf{X}}$ .
- Tento odhad také není přípustný, dominuje jej mj. positive rule Jamesův - Steinův odhad  $\hat{\boldsymbol{\theta}}_{JS}^+ = \left(1 - \frac{(p-2)\sigma^2}{n\|\bar{\mathbf{X}}\|^2}\right)_+ \bar{\mathbf{X}}$ .