

NMAI059 Pravděpodobnost a statistika 1

10. přednáška

Robert Šámal

Přehled

Statistika – model situace

Statistika – bodové odhady

Statistika – intervalové odhady

Náhodný výběr

- ▶ bez vracení

$\Omega = \{\text{všechny } n\text{-tice obyvatel ČR}\}$

Pro $\omega = (\omega_1, \dots, \omega_n)$ zvolíme $X_i = I(\omega_i \text{ je levák})$.

- ▶ s vracením

$\Omega = \{\text{všechny } n\text{-tice obyvatel ČR, mohou se opakovat}\}$

Pro $\omega = (\omega_1, \dots, \omega_n)$ zvolíme $X_i = I(\omega_i \text{ je levák})$.

- ▶ varianty (stratifikovaný výběr)

Chceme adekvátně reprezentovat různé podmnožiny (dané věkem, bydlištěm, ...).

Nebudeme dále zkoumat.

Statistika – model

- ▶ nezávislá měření – hodnoty n.n.v. $X_1, \dots, X_n \sim F$
náhodný výběr s distribuční funkcí F s rozsahem n
- ▶ neparametrické modely: povolujeme velkou třídu F
- ▶ parametrické modely: $F \in \{F_\vartheta : \vartheta \in \Theta\}$
- ▶ příklady:
 - ▶ $Pois(\lambda)$ (parametr $\vartheta = \lambda, \Theta = \mathbb{R}^+$)
 - ▶ $U(a, b)$ (parametr $\vartheta = (a, b), \Theta = \mathbb{R}^2$)
 - ▶ $N(\mu, \sigma^2)$ (parametr $\vartheta = (\mu, \sigma), \Theta = \mathbb{R} \times \mathbb{R}^+$)
- ▶ „Všechny modely jsou špatné, ale některé jsou užitečné.“
(George Box)

Zkoumané úlohy – cíle konfirmační analýzy (confirmatory data analysis)

- ▶ bodové odhady
 - ▶ intervalové odhady
 - ▶ testování hypotéz
 - ▶ (lineární) regrese
-
- ▶ *statistika* – libovolná funkce náhodného výběru, tj. např. aritmetický průměr, medián, maximum, atd.
Tj. $T = T(X_1, \dots, X_n)$.

Přehled

Statistika – model situace

Statistika – bodové odhady

Statistika – intervalové odhady

Výběrový průměr a rozptyl

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

$$\bar{S}_n = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

$$\hat{S}_n = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

Odhad

Definice

Odhad je libovolná statistika.

Vlastnosti bodových odhadů

Definice

Odhad $\hat{\Theta}_n = \hat{\Theta}_n(X_1, \dots, X_n)$ parametru ϑ je

- ▶ *neustranný (unbiased)* – pokud $\vartheta = \mathbb{E}(\hat{\Theta}_n)$ (pro každé ϑ)
- ▶ *asymptoticky neustranný (asymptotically unbiased)*
– pokud $\vartheta = \lim_{n \rightarrow \infty} \mathbb{E}(\hat{\Theta}_n)$
- ▶ *konzistentní (consistent)* – pokud $\hat{\Theta}_n \xrightarrow{P} \vartheta$.
- ▶ *vychýlení (bias)* $bias_{\vartheta}(\hat{\Theta}_n) := \mathbb{E}(\hat{\Theta}_n) - \vartheta$
- ▶ *střední kvadratická chyba (mean squared error, MSE) je*
 $MSE := \mathbb{E}((\hat{\Theta}_n - \vartheta)^2)$

Věta

$$MSE = bias_{\vartheta}(\hat{\Theta}_n)^2 + var_{\vartheta}(\hat{\Theta}_n)$$

Parametry výběrového momentu a rozptylu

Věta

1. \bar{X}_n je konzistentní nestranný odhad μ
2. \bar{S}_n je konzistentní asymptoticky nestranný odhad μ
3. \hat{S}_n je konzistentní nestranný odhad μ

Metoda momentů

- ▶ $m_r(\vartheta) := \mathbb{E}(X^r)$ pro $X \sim F_\vartheta$... r -tý moment
- ▶ $\widehat{m}_r(\vartheta) := \frac{1}{n} \sum_{i=1}^n X_i^r$ pro náhodný výběr X_1, \dots, X_n z F_ϑ
... r -tý výběrový moment

Věta

$\widehat{m}_r(\vartheta)$ je nestranný konzistentní odhad pro $m_r(\vartheta)$

- ▶ Odhad metodou momentů je řešení soustavy rovnic

$$m_r(\vartheta) = \widehat{m}_r(\vartheta) \quad r = 1, \dots, k.$$

Metoda momentů – příklady

Metoda maximální věrohodnosti (maximal likelihood, ML)

- ▶ náh. výběr $X = (X_1, \dots, X_n)$ z modelu s parametrem ϑ
- ▶ možný výsledek $x = (x_1, \dots, x_n)$
- ▶ ... sdružená pravděpodobnostní funkce $p_X(x; \vartheta)$
- ▶ ... sdružená hustota $f_X(x; \vartheta)$
- ▶ *věrohodnost (likelihood)* $L(x; \vartheta)$ značí p_X nebo f_X
- ▶ normálně: máme pevné ϑ , a $L(x; \vartheta)$ je funkce x
- ▶ teď: máme pevné x a $L(x; \vartheta)$ je funkce ϑ

Metoda MV (ML):

volíme takové ϑ , pro které je $L(x; \vartheta)$ maximální


Metoda maximální věrohodnosti (maximal likelihood, ML)

- ▶ **Metoda MV (ML):**
volíme takové ϑ , pro které je $L(x; \vartheta)$ maximální
- ▶ definujeme také $\ell(x; \vartheta) = \log(L(x; \vartheta))$
- ▶ díky nezávislosti je

$$L(x; \vartheta) =$$

$$\ell(x; \vartheta) =$$

ML – leváci



Přehled

Statistika – model situace

Statistika – bodové odhady

Statistika – intervalové odhady

Intervalové odhady

- ▶ místo jednoho čísla s nejistým významem vypočítáme z dat interval $[\hat{\Theta}^-, \hat{\Theta}^+]$

Definice

Nechť $\hat{\Theta}^-$, $\hat{\Theta}^+$ jsou n.v. které závisí na náhodném výběru $X = (X_1, \dots, X_n)$. Tyto n.v. určují intervalový odhad, též konfidenční interval o spolehlivosti $1 - \alpha$ ($1 - \alpha$ confidence interval), pokud

$$P(\hat{\Theta}^- \leq \vartheta \leq \hat{\Theta}^+) \geq 1 - \alpha.$$

Intervalové odhady normální náhodné veličiny

Věta

X_1, \dots, X_n je náhodný výběr z $N(\vartheta, \sigma^2)$.

σ známe, ϑ chceme určit, $\alpha \in (0, 1)$.

Nechť $\Phi(z_{\alpha/2}) = 1 - \alpha/2$. $\hat{\Theta}_n = \bar{X}_n$.

$$C_n := \left[\hat{\Theta}_n - \frac{z_{\alpha/2}\sigma}{\sqrt{n}}, \hat{\Theta}_n + \frac{z_{\alpha/2}\sigma}{\sqrt{n}} \right]$$

Pak $P(C_n \ni \vartheta) = 1 - \alpha$.

Důkaz.

Intervalové odhady pomocí CLV

Věta

X_1, \dots, X_n je náhodný výběr z rozdělení se střední hodnotou ϑ , rozptylem σ^2 .

σ známe, ϑ chceme určit, $\alpha \in (0, 1)$.

Nechť $\Phi(z_{\alpha/2}) = 1 - \alpha/2$.

$$C_n := \left[\hat{\Theta}_n - \frac{z_{\alpha/2}\sigma}{\sqrt{n}}, \hat{\Theta}_n + \frac{z_{\alpha/2}\sigma}{\sqrt{n}} \right]$$

Pak $P(C_n \ni \vartheta)$ se limitně blíží $1 - \alpha$.

Studentovo rozdělení

- ▶ $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \dots$ výběrový průměr
- ▶ $\hat{S}_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2 \dots$ výběrový rozptyl

▶ Necht' $X_1, \dots, X_n \sim N(\mu, \sigma^2)$

▶ Pak $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$

▶ *Studentovo t-rozdělení s $n - 1$ stupni volnosti je rozdělení n.v.*

$$\frac{\bar{X}_n - \mu}{\hat{S}_n/\sqrt{n}}$$

▶ Distribuční funkce Ψ_{n-1} (v tabulkách ...)

Int. odhady normální n.v. pomocí Studentova t

Věta

X_1, \dots, X_n je náhodný výběr z $N(\vartheta, \sigma^2)$.

ϑ chceme určit, σ neznáme; $\alpha \in (0, 1)$. Necht'

$\Psi_{n-1}(z_{\alpha/2}) = 1 - \alpha/2$. $\hat{\Theta}_n = \bar{X}_n$, $\hat{S}_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$

$$C_n := \left[\hat{\Theta}_n - z_{\alpha/2} \frac{\hat{S}_n}{\sqrt{n}}, \hat{\Theta}_n + z_{\alpha/2} \frac{\hat{S}_n}{\sqrt{n}} \right]$$

Pak $P(C_n \ni \vartheta) = 1 - \alpha$.