

## Aplikovaná statistika I

*Téma 6: Bodové a intervalové odhady*

Veronika Bendová

bendova.veroonika@gmail.com

# Základní pojmy matematické statistiky

- popisná statistika . . . datový soubor → závěry o datovém souboru
- **matematická statistika** . . . náhodný výběr → statistiky → závěry o tvaru rozdělení a parametrech
- $X_1, \dots, X_n$  – náhodné veličiny, které mají všechny stejné rozdělení  $L(\theta)$  → dohromady tvoří **náhodný výběr** rozsahu  $n$  z rozdělení  $L(\theta)$
- číselné realizace  $x_1, \dots, x_n$  náh.výběru  $X_1, \dots, X_n$  tvoří **datový soubor**
- **statistika** = libovolná funkce náhodného výběru:  $T = T(X_1, \dots, X_n)$

## Jednorozměrné statistiky (jeden výběr; jeden znak)

Nechť  $X_1, \dots, X_n$  je náhodný výběr,  $n \geq 2$ .

1. *výběrový průměr*

$$m = \frac{1}{n} \sum_{i=1}^n x_i$$

2. *výběrový rozptyl*

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - m)^2$$

3. *výběrová směrodatná odchylka*

$$s = \sqrt{s^2}$$

4. *výběrový koeficient variace*

$$v = \frac{s}{m}$$

## Dvouozměrné statistiky (jeden výběr; dva znaky)

Nechť  $(X_1, Y_1), \dots, (X_n, Y_n)$  je náhodný výběr z dvouozměrného rozdělení,  $m_1$  a  $m_2$  jsou výběrové průměry a  $s_1^2$  a  $s_2^2$  jsou výběrové rozptyly.

### 1. výběrová kovariance

$$s_{12} = \frac{1}{n-1} \sum_{i=1}^n (x_i - m_1)(y_i - m_2)$$

### 2. výběrový koeficient korelace

$$r_{12} = \frac{s_{12}}{\sqrt{s_1^2 s_2^2}} = \frac{s_{12}}{s_1 s_2}$$

## Douvýběrové statistiky (dva nebo více výběrů; jeden znak)

Nechť  $X_{11}, \dots, X_{1n_1}$  je náhodný výběr,  $X_{21}, \dots, X_{2n_2}$  je na něm nezávislý náhodný výběr,  $\dots, X_{k1}, \dots, X_{kn_k}$ , je náhodný výběr nezávislý na všech předcházejících náhodných výběrech,  $n_1, n_2, \dots, n_k \geq 2$ . Nechť dále  $s_1^2, s_2^2, \dots, s_k^2$  jsou výběrové rozptyly.

### 1. vážený průměr dvou výběrových rozptylů ( $k = 2$ )

$$S_*^2 = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2}$$

### 2. vážený průměr k výběrových rozptylů

$$S_*^2 = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2 + \dots + (n_k - 1)S_k^2}{n_1 + n_2 + \dots + n_k - k}$$

# Bodové a intervalové odhady parametrů

- $X_1 \dots X_n \dots$  náhodný výběr z rozdělení  $L(\theta)$  s parametrem  $\theta$
- $\theta$  neznáme; chceme ho odhadnout
- **bodový odhad parametru  $\theta$**  ... statistika  $T_n = T(X_1 \dots X_n)$
- **intervalový odhad parametru  $\theta$**  ... interval  $(D, H)$ , který s dostatečně velkou pravděpodobností pokrývá hodnotu parametru  $\theta$ ;  $(D, H \dots$  statistiky)

## Bodový odhad parametru $\theta$

- typy bodových odhadů
  - nestranný ... hodnotu param.  $\theta$  ani nepodhodnocuje, ani nenadhadnocuje
  - vychýlený ... není-li odhad nestranný, je vychýlený
  - asymptotický ... s rostoucím  $n$  se přesnost odhadu zvětšuje
- vlastnosti bodových odhadů
  1.  $X \sim N(\mu, \sigma^2)$ 
    - $m$  je nestranným odhadem  $\mu$  (parametr  $\theta$ )
    - $s^2$  je nestranným odhadem  $\sigma^2$  (parametr  $\theta$ )
    - $v$  je nestranným odhadem koeficientu variace  $\frac{\sigma}{\mu}$  (parametr  $\theta$ )
  2.  $(X, Y)^T \sim \mathbf{N}_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ ,  $\boldsymbol{\mu} = (\mu_1, \mu_2)$ ,  $\boldsymbol{\Sigma} = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix} = \begin{pmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{12} & \sigma_2^2 \end{pmatrix}$ 
    - $s_{12}$  je nestranným odhadem  $\sigma_{12}$  (parametr  $\theta$ )
    - $r_{12}$  je asymptoticky nestranným odhadem  $\rho$  (parametr  $\theta$ )

## Dataset: 21-goldman-tigara.csv

Datový soubor 21-goldman-tigara.csv obsahuje osteometrické údaje o délce stehenní kosti (v mm) a acetabulární výšce (v mm) z pravé a levé strany u mužů a žen z aljašské populace z kmene Tigara. Data pochází ze souboru dokumentovaných skeletů (Goldman, 2006).

### Popis proměnných v datasetu:

- sex ... pohlaví jedince (m - muž, f - žena);
- pop ... populace (Tigara = aljašská populace z kmene Tigara);
- femur.LR ... délka stehenní kosti z pravé strany (v mm);
- femur.LL ... délka stehenní kosti z levé strany (v mm);
- acetab.HR ... acetabulární výška z pravé strany (v mm);
- acetab.HL ... acetabulární výška z levé strany (v mm).

### Příklad 6.1. Bodové odhady parametrů $\mu$ a $\sigma^2$ normálního rozdělení

Načtěte datový soubor 21-goldman-tigara.csv. Nechť náhodná veličina  $X$  popisuje délku stehenní kosti (v mm) z pravé strany u mužů z kmene Tigara. Za předpokladu, že náhodná veličina  $X \sim N(\mu, \sigma^2)$ , stanovte nestranný (bodový) odhad (a) střední hodnoty  $\mu$ ; (b) rozptylu  $\sigma^2$ ; (c) směrodatné odchylky  $\sigma$ ; (d) koeficientu variace. Všechny vypočítané hodnoty řádně interpretujte.

### Řešení příkladu 6.1

```

1 data <- read.delim(...) # nacteni datoveho souboru
2 data.M <- data[..., ...] # vyber sloupcu femur.LR a acetab.HR pro muze z kmene Tigara
3 data.M <- na.omit(...) # odstraneni NA udaju
4 femur.LR <- data.M$... # vyber sloupce femur.LR z tabulky data.M
5 acetab.HR <- data.M$... # vyber sloupce acetab.HR z tabulky data.M
6 n <- length(...) # pocet udaju o delce stehenni kosti u muzu z kmene Tigara
7
8 m.LR <- mean() # bodovy odhad stredni hodnoty mu
9 s2.LR <- var() # bodovy odhad rozptylu sigma^2
10 s.LR <- sd() # bodovy odhad sm. odchylky sigma
11 v.LR <- ... # bodovy odhad koef. variace sigma / mu
12 tab <- data.frame(...) # souhrnna tabulka vysledku

```

	m	s2	s	v
1	427.9	539.17	23.22	0.05

13

14

**Interpretace výsledků:** Nestranný odhad střední hodnoty  $\mu$  je ..... mm. Nestranný odhad rozptylu  $\sigma^2$  (resp. směrodatné odchylky  $\sigma$ ) je .....  $\text{mm}^2$  (resp. ..... mm). Nestranný odhad koeficientu variace je ..... Délka stehenní kosti z pravé strany u mužů z kmene Tigara se pohybuje okolo hodnoty ..... mm se směrodatnou odchylkou ..... mm. Směrodatná odchylka představuje ..... % aritmetického průměru.

## Příklad 6.2. Bodové odhady parametrů $\mu$ a $\Sigma$ normálního rozdělení

Načtěte datový soubor 21-goldman-tigara.csv. Nechť náhodná veličina  $X$  popisuje délku stehenní kosti (v mm) z pravé strany a náhodná veličina  $Y$  popisuje acetabulární výšku (v mm) z pravé strany u mužů z kmene Tigara. Za předpokladu, že náhodný vektor  $(X, Y)^T \sim N_2(\mu, \Sigma)$ , stanovte (a) nestranný (bodový) odhad vektoru středních hodnot  $\mu$ ; (b) nestranný (bodový) odhad kovariance  $\sigma_{12}$ ; (c) asymptoticky nestranný (bodový) odhad korelačního koeficientu  $\rho$ ; (d) nestranný (bodový) odhad varianční matice  $\Sigma$ .

### Řešení příkladu 6.2

```
15 m.HR <- ... # bodovy odhad stredni hdonoty
16 s2.HR <- ... # bodovy odhad rozptylu sigma^2
17 s.HR <- ... # bodovy odhad sm. odchylky
18 s12 <- cov(..., ...) # bodovy odhad kovariance sigma12
19 r12 <- cor(..., ...) # bodovy odhad korel. koef. rho
20 s12 <- ... # bodovy odhad kovariance sigma12 (prepis vzorce)
21 r12 <- ... # bodovy odhad korel. koef. rho (prepis vzorce)
22 tab <- data.frame(...) # souhrnnna tabulka vysledku
```

m.LR	m.HR	s2.LR	s2.HR	s.LR	s.HR	s12	r12	
1	427.9	51.93	539.17	9.77	23.22	3.13	42.11	0.58

23

24

m.LR	m.HR	s2.LR	s2.HR	s.LR	s.HR	s12	r12
1	427.9	51.93	539.17	9.77	23.22	3.13	42.11 0.58

25

26

**Interpretace výsledků:** Nestranný odhad vektoru středních hodnot  $\mu = (\dots, \dots)^T$  mm. Nestranný odhad kovariance  $\sigma_{12}$  je ..... Asymptoticky nestranný odhad korelačního koeficientu  $\rho$  je ..... Nestranný odhad varianční matice  $\Sigma = \begin{pmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{12} & \sigma_2^2 \end{pmatrix}$  je matice  $\begin{pmatrix} s_1^2 & s_{12} \\ s_{12} & s_2^2 \end{pmatrix}$ , kde  $s_1^2 = \dots \text{ mm}^2$ ,  $s_2^2 = \dots \text{ mm}^2$  a  $s_{12} = r_{12}s_1s_2 = \dots$ . Délka stehenní kosti z pravé strany mužů z kmene Tigara se pohybuje okolo hodnoty ..... mm se směrodatnou odchylkou ..... mm. Acetabulární výška z pravé strany se pohybuje okolo hodnoty ..... mm se směrodatnou odchylkou ..... mm. Mezi délkou stehenní kosti a acetabulární výškou z pravé strany existuje ..... stupeň ..... závislosti ( $r_{12} = \dots$ ).

### **Dataset: 21-goldman-shells.csv**

Datový soubor 21-goldman-shells.csv obsahuje osteometrické údaje o délce kyčelní kosti z pravé a levé strany u mužů a žen ze tří japonských populací(Tsugumo Shell Mound, Yoshigo Shell Mound a Yasaki Shell Mound). Data pochází ze souboru dokumentovaných skeletů (Goldman, 2006).

### **Popis proměnných v datasetu:**

- sex ... pohlaví jedince (m - muž, f - žena);
- pop ... populace (tsg = Tsugumo Shell Mound, yos = Yoshigo Shell Mound, yas = Yasaki Shell Mound);
- iblade.LR ... délka kyčelní kosti z pravé strany (v mm);
- iblade.LL ... délka kyčelní kosti z levé strany (v mm).

### **Příklad 6.3. Dvouvýběrové statistiky**

Načtěte datový soubor 21-goldman-shells.csv. Vypočítejte vážený průměr výběrových rozptylů délek kyčelních kostí z levé strany u mužů (a) z populací Yoshigo Shell Mound a Yasaki Shell Mound; (b) ze všech tří uvedených populací.

### **Řešení příkladu 6.3**

```

27 data <- read.delim(...) # nacteni datoveho souboru
28 ib.Tg <- data[..., ...] # vyber sloupce iblade.LL pro muze z pop. Tsugumo s.m.
29 ib.Yo <- data[..., ...] # vyber sloupce iblade.LL pro muze z pop. Yoshigo s.m.
30 ib.Ya <- data[..., ...] # vyber sloupce iblade.LL pro muze z pop. Yasaki s.m.
31 ib.Tg <- na.omit(...) # odstraneni NA hodnot z vektoru ib.Tg
32 ib.Yo <- ... # odstraneni NA hodnot z vektoru ib.Yo
33 ib.Ya <- ... # odstraneni NA hodnot z vektoru ib.Ya
34
35 n.Tg <- length(...) # pocet hodnot delek kyccelnich kosti (Tsugumo s.m.)
36 n.Yo <- ... # pocet hodnot delek kyccelnich kosti (Yoshigo s.m.)
37 n.Ya <- ... # pocet hodnot delek kyccelnich kosti (Yasaki s.m.)
38
39 s2.Tg <- var(...) # odhad rozptylu sigma^2 (Tsugumo s.m.)
40 s2.Yo <- ... # odhad rozptylu sigma^2 (Yoshigo s.m.)
41 s2.Ya <- ... # odhad rozptylu sigma^2 (Yasaki s.m.)
42
43 sh.YoYa <- ... # (a) vazeny prumer vyb. rozptylu dvou pop. (prepis vzorce)
44 sh.TgYoYa <- ... # (b) vazeny prumer vyb. rozptylu tri pop. (prepis vzorce)
45 tab <- data.frame(...) # summarizacni tabulka

```

sh.YoYa	sh.TgYoYa
1	16.5
	24.35

46  
47

**Interpretace výsledků:** Vážený průměr výběrových rozptylů délek kyčelních kostí z levé strany mužů z populací Yoshigo Shell Mound a Yasaki Shell Mound  $s_{YoYa*}^2 = \dots \text{ mm}^2$ .  
 Vážený průměr výběrových rozptylů délek kyčelních kostí z levé strany mužů všech tří japonských populací  $s_*^2 = \dots \text{ mm}^2$ .

# Intervalové odhady parametrů

Nechť  $\alpha \in (0, 1)$ ; koeficient  $\alpha$  nazýváme **riziko**; koeficient  $(1 - \alpha)$  nazýváme **spolehlivost**

- Interval  $(D, H) \dots 100(1 - \alpha)\%$  oboustranný IS pro param.  $\theta$
- Interval  $(D, \infty) \dots 100(1 - \alpha)\%$  levostranný IS pro param.  $\theta$
- Interval  $(-\infty, H) \dots 100(1 - \alpha)\%$  pravostranný IS pro param.  $\theta$

Tvary intervalů spolehlivosti pro  $X \sim N(\mu, \sigma^2)$

1. IS pro  $\mu$ , když  $\sigma^2$  známe

a. Oboustranný:

$$(d, h) = \left(m - \frac{\sigma}{\sqrt{n}} u_{1-\alpha/2}, m + \frac{\sigma}{\sqrt{n}} u_{\alpha/2}\right)$$

b. Levostranný:

$$(d, \infty) = \left(m - \frac{\sigma}{\sqrt{n}} u_{1-\alpha}, \infty\right)$$

c. Pravostranný:

$$(-\infty, h) = \left(-\infty, m - \frac{\sigma}{\sqrt{n}} u_{\alpha}\right)$$

$u_{\alpha}$  je  $\alpha$  kvantil standardizovaného normálního rozložení ... `qnorm(alpha, 0, 1)`.

2. IS pro  $\mu$ , když  $\sigma^2$  neznáme

a. Oboustranný:

$$(d, h) = \left( m - \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1), m - \frac{s}{\sqrt{n}} t_{\alpha/2}(n-1) \right)$$

b. Levostranný:

$$(d, \infty) = \left( m - \frac{s}{\sqrt{n}} t_{1-\alpha}(n-1), \infty \right)$$

c. Pravostranný:

$$(-\infty, h) = \left( -\infty, m - \frac{s}{\sqrt{n}} t_{\alpha}(n-1) \right)$$

$t_{\alpha}(n-1)$  je  $\alpha$  kvantil studentova rozdělení o  $n-1$  stupních volnosti ... qt(alpha, n-1).

3. IS pro  $\sigma^2$ , když  $\mu$  neznáme

a. Oboustranný:

$$(d, h) = \left( \frac{(n-1)s^2}{\chi^2_{1-\alpha/2}(n-1)}, \frac{(n-1)s^2}{\chi^2_{\alpha/2}(n-1)} \right)$$

b. Levostranný:

$$(d, \infty) = \left( \frac{(n-1)s^2}{\chi^2_{1-\alpha}(n-1)}, \infty \right)$$

c. Pravostranný:

$$(-\infty, h) = \left( -\infty, \frac{(n-1)s^2}{\chi^2_{\alpha}(n-1)} \right)$$

$\chi^2_{\alpha}(n-1)$  je  $\alpha$  kvantil  $\chi^2$  rozdělení o  $n-1$  stupních volnosti... qchisq(alpha,n-1).

4. IS pro  $\sigma^2$ , když  $\mu$  známe

- existuje, ale neprobíráme ho, neboť není příliš využitelný v praxi

### Tvary intervalů spolehlivosti pro $X \sim \text{Alt}(p)$

a. Oboustranný:

$$(d, h) = \left( \hat{p} - u_{1-\alpha/2} \sqrt{\hat{p}(1-\hat{p})/N} ; \hat{p} + u_{\alpha/2} \sqrt{\hat{p}(1-\hat{p})/N} \right),$$

b. Levostranný:

$$(d, \infty) = \left( \hat{p} - u_{1-\alpha} \sqrt{\hat{p}(1-\hat{p})/N} ; \infty \right),$$

c. Pravostranný:

$$(-\infty, h) = \left( -\infty, ; \hat{p} + u_{\alpha} \sqrt{\hat{p}(1-\hat{p})/N} \right),$$

$u_{\alpha}$  je  $\alpha$  kvantil standardizovaného normálního rozložení ... qnorm(alpha,0,1).

### Příklad 6.4. Intervalové odhady parametrů normálního rozdělení

Načtěte datový soubor 21-goldman-tigara.csv. Nechť náhodná veličina  $X$  popisuje délku stehenní kosti (v mm) z pravé strany u mužů z kmene Tigara. Za předpokladu, že náhodná veličina  $X \sim N(\mu, \sigma^2)$ , stanovte (a) 95% intervalový odhad střední hodnoty  $\mu$ ; (c) 99% levostranný intervalový odhad rozptylu  $\sigma^2$ ; (c) 90% pravostranný intervalový odhad směrodatné odchylky  $\sigma$ .

### Řešení příkladu 6.4.

```

48 alpha <- ... # koeficient alpha pro (a)
49 dh.mu <- ... # dolni hranice 95% IS pro par. mu (prepis vzorce)
50 hh.mu <- ... # horni hranice 95% IS pro par. mu (prepis vzorce)
51
52 alpha <- ... # koeficient alpha pro (b)
53 D.sig2 <- ... # dolni hranice 99% levostro. IS pro par. sigma^2 (prepis vzorce)
54
55 alpha <- ... # koeficient alpha pro (c)
56 H.sig2 <- ... # horni hranice 90% pravostro. IS pro par. sigma^2 (prepis vzorce)
57 H.sig <- sqrt(...) # odmocneni h. hranice pro sigma^2 -> h. hranice pro sigma
58 tab <- data.frame(...) # souhrnnna tabulka vysledku

```

dh.mu	hh.mu	D.mu	H.sig
1 418.09	437.7	297.83	28.9

59

60

**Interpretace výsledků:** 95% empirický interval spolehlivosti pro střední hodnotu  $\mu$  má tvar ..... To znamená, že .....  $< \mu <$  ..... s pravděpodobností 95 %. V 95 případech ze sta bude střední hodnota délky stehenní kosti z pravé strany u mužů z kmene Tigara nabývat hodnoty z intervalu ..... mm.

99% levostranný empirický interval spolehlivosti pro rozptyl  $\sigma^2$  má tvar ..... To znamená, že  $\sigma^2 >$  ..... s pravděpodobnosti 99 %. V 99 případech ze sta bude rozptyl délky stehenní kosti z pravé strany u mužů z kmene Tigara větší / menší než ..... mm<sup>2</sup>.

90% pravostranný empirický interval spolehlivosti pro směrodatnou odchylku  $\sigma$  má tvar ..... To znamená, že  $\sigma <$  ..... s pravděpodobnosti 90 %. V 90 případech ze sta bude směrodatná odchylka délky stehenní kosti z pravé strany u mužů z kmene Tigara větší / menší než ..... mm.

### Příklad 6.5. Bodový a intervalový odhad parametru $p$ alternativního rozdělení

Načtěte datový soubor 17-anova-newborns-2.txt. Mějme náhodnou veličinu  $X$  popisující ženské pohlaví novorozenců. Za předpokladu, že náhodná veličina  $X \sim \text{Alt}(p)$ , kde  $p$  je pravděpodobnost narození holčičky, stanovte (a) bodový odhad parametru  $p$ ; (b) 95% intervalový odhad parametru  $p$ .

### Řešení příkladu 6.5

```
61 data <- read.delim(...) # nacteni datoveho souboru
62 data <- na.omit(...) # odstraneni NA hodnot
63 sex <- ... # vyber sloupce sex.C z datove tabulky
64 N <- length(...) # pocet udaju o pohlavi
65 p <- ... # bodovy odhad parametru p
66 alpha <- ... # koeficient alpha
67 dh.p <- ... # dolni hranice 95% IS pro parametr p (prepis vzorce)
68 hh.p <- ... # horni hranice 95% IS pro parametr p (prepis vzorce)
69 tab <- data.frame(...) # summarizacni tabulka vysledku
```

	p	dh.p	hh.p
1	0.4794	0.453	0.5057

70

71

**Interpretace výsledků:** Bodový odhad pravděpodobnosti narození holčičky je .....

K narození holčičky dojde s pravděpodobností ..... %. 95% empirický IS pro

pravděpodobnost narození holčičky  $p$  má tvar ..... To znamená, že

.....  $< p <$  ..... s pravděpodobností 95 %. Pravděpodobnost narození holčičky

se pohybuje v rozmezí ..... % – ..... % s pravděpodobností 95 %.