

## 7 Základní pojmy matematické statistiky

- popisná statistika ... datový soubor → závěry o datovém souboru
- matematická statistika ... náhodný výběr → statistiky → závěry o tvaru rozdělení a parametrech
- $X_1, \dots, X_n$  – stoch.nezáv.náh.veličiny, které mají všechny stejné rozložení  $L(\theta)$  →  $X_1, \dots, X_n$  ... 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:  $T = T(X_1, \dots, X_n)$
- Statistiky – jednovýběrové:  
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. Výběrová distribuční funkce  $F_n(x)$  ... průměrný počet těch veličin  $X_i$ , pro něž platí  $X_i \geq x$ .

- Statistiky – dvouvýběrové:  
Nechť  $(X_1, Y_1), \dots, (X_n, Y_n)$  je náhodný výběr z dvouozměrného rozdělení.  $M_1 = \frac{1}{n} \sum_{i=1}^n X_i$  a  $M_2 = \frac{1}{n} \sum_{i=1}^n Y_i$ .

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

$$R_{12} = \frac{S_{12}}{S_1 S_2}$$

### 7.1 Bodové a intervalové odhady parametrů

- $X_1 \dots X_n$  ... náhodný výběr z rozdělení  $L(\theta)$  s parametrem  $\theta$ .
- param.  $\theta$  neznáme; chceme ho odhadnout pomocí náh. výběru
- bodovým odhadem parametru  $\theta$  je nějaká vhodná statistika  $T_n = T(X_1 \dots X_n)$
- intervalovým odhadem parametru  $\theta$  je interval  $(D, H)$ , kde  $D, H$  jsou fce náh.výběru  $D = D(X_1 \dots X_n)$ ,  $H = H(X_1 \dots X_n)$  a který s dostatečně velkou pravděpodobností pokrývá hodnotu parametru  $\theta$
- typy bodových odhadů
  1. nestranný ... hodnotu param.  $\theta$  ani nepodhodnocuje, ani nenadhadnocuje ...  $E T_n = \theta$

- 2. vychýlený ... není-li odhad nestranný, je vychýlený
- 3. asymptotický ... s rostoucím  $n$  se jeho přesnost zvětšuje
- vlastnosti bodových odhadů
- $X_1, \dots, X_n$  ... náh. výběr se střední hodnotou  $\mu$ , rozptylem  $\sigma^2$ .
  1.  $M$  je nestranný odhadem  $\mu$  ...  $EM = \mu$
  2.  $DM = \frac{\sigma^2}{n}$
  3.  $S^2$  je nestranným odhadem  $\sigma^2$  ...  $ES^2 = \sigma^2$
- $(X_1, Y_1), \dots, (X_n, Y_n)$  ... náhodný výběr z dvourozměrného rozložení s kovariancí  $\sigma_{12}$  a koeficientem korelace  $\rho$ .
  1.  $E(S_{12})$  je nestranným odhadem  $\sigma_{12}$  ...  $E(S_{12}) = \sigma_{12}$
  2.  $ER_{12}$  je asymptoticky nestranným odhadem  $\rho$  ...  $ER_{12} \approx \rho$

**Příklad 7.1.** Ve 12-ti náhodně vybraných internetových obchodech byly zjištěny následující ceny deskripitoru artefaktů (v Kč): 102, 99, 106, 103, 96, 98, 100, 105, 103, 98, 104, 107. Těchto 12 hodnot považujeme za realizace náhodného výběru  $X_1, \dots, X_{12}$  z rozdělení, které má střední hodnotu  $\mu$  a rozptyl  $\sigma^2$ .

- Určete nestranné bodové odhady neznámé střední hodnoty  $\mu$  a neznámého rozptylu  $\sigma^2$ .
- Najděte výběrovou distribuční funkci  $F_{12}(x)$  a nakreslete její graf.
- Vypočteme realizaci výběrového průměru

$$m = \frac{1}{12}(102 + 99 + \dots + 107) = 101.75 \text{ Kč}$$

Vypočteme realizaci výběrového rozptylu:

$$s^2 = \frac{1}{11} [(102 - 101.75)^2 + (99 - 101.75)^2 + \dots + (107 - 101.75)^2] = 12.39 \text{ Kč}^2$$

```

x <- c(96, 98, 98, 99, 100, 102, 103, 103, 104, 105, 106, 107)
n <- length(x)
(m <- mean(x))
(s2 <- var(x))

# Vyberova distribucni funkce
t <- unique(sort(x))
y <- sort(x)
nt <- length(t)

cetnost <- NULL
for(i in 1:nt){
  cetnost[i] <- sum(y<=t[i])}
Fx <- cetnost/n
t(round(Fx, digits=4))

# graf vyberove distribucni funkce
x <- c(min(t)-1,t, max(t)+1)
y <- c(0,Fx,1)
plot(x, y, type='n', xlab='x', ylab='F(x)', 
     main='Vyberova distribucni funkce')
abline(h=seq(0,1,by=0.1), col='grey85')
abline(v=seq(95, 108, by=2), col='grey85')
lines(x,y, type='s', col='red', lwd=2)
arrows(96,0,95,0, col='red', lwd=2, length=0.1)
arrows(107,1,108,1, col='red', lwd=2, length=0.1)

```

**Příklad 7.2.** Přírůstky cen akcií v % na burze v New Yorku u 10 náhodně vybraných společností dosáhly těchto hodnot: 10, 16, 5, 10, 12, 8, 4, 6, 5, 4.

- Odhadněte střední hodnotu, rozptyl a směrodatnou odchylku růstu cen akcií.
- Odhadněte pravděpodobnost růstu cen akcií aspoň o 8.5 %.

```
x <- c(10, 16, 5, 10, 12, 8, 4, 6, 5, 4)
x <- sort(x)
n <- length(x)
s2 <- var(x)
s <- sd(x)
Tab <- data.frame(m=m, s2=s2, s=s, row.names='akcie')
round(Tab, digits=2)

# P(X>=8.5)
pst <- sum(x>=8.5)/length(x)
pst <- 1-sum(x<8.5)/length(x)
round(pst,4)
```

**Příklad 7.3.** Bylo zkoumáno 9 vzorků půdy s různým obsahem fosforu (veličina  $X$ ). Hodnoty veličiny  $Y$  označují obsah fosforu v obilných klíčcích (po 38 dnech), jež vyrostly na těchto vzorcích půdy.

číslo vzorku	1	2	3	4	5	6	7	8	9
X	1	4	5	9	11	13	23	23	28
Y	64	71	54	81	76	93	77	95	109

Těchto 9 dvojic hodnot považujeme za realizace náhodného výběru  $(X_1, Y_1), \dots, (X_9, Y_9)$  z dvourozměrného rozdělení s kovariancí  $\sigma_{12}$  a koeficientem korelace  $\rho$ . Najděte bodové odhady kovariance  $\sigma_{12}$  a koeficientu korelace  $\rho$ .

```
x <- c(1, 4, 5, 9, 11, 13, 23, 23, 28)
y <- c(64, 71, 54, 81, 76, 93, 77, 95, 109)
cov(x,y)
cor(x,y)
```

### 7.1.1 INTERVALY SPOLEHLIVOSTI

- $X_1 \dots X_n \dots$  náh.výběr z rozdělení  $L(\theta)$ ,  $\theta$  je parametr,  $\alpha \in (0, 1)$
- interval  $(D, H)$ 
  - $100(1 - \alpha)\%$  oboustranný IS pro param.  $\theta$
  - pro každé  $\theta : P(D < \theta < H) = 1 - \alpha$
- interval  $(D, \infty)$ 
  - $100(1 - \alpha)\%$  levostranný IS pro param.  $\theta$
  - pro každé  $\theta : P(D < \theta) = 1 - \alpha$
- interval  $(-\infty, H)$ 
  - $100(1 - \alpha)\%$  pravostranný IS pro param.  $\theta$
  - pro každé  $\theta : P(\theta < H) = 1 - \alpha$
- $\alpha$  se nazývá *riziko*,  $(1 - \alpha)$  se nazývá *spolehlivost*.

### 7.1.2 Konstrukce intervalů spolehlivosti

- konečný tvar IS pro param.  $\theta$  odvozujeme z příslušné pivotové statistiky
- pivotová statistika = statistika, jejíž rozdělení je známé a nezávisí na parametru  $\theta$ 
  - používá se také k testování hypotéz
- příklad odvození IS z pivotové statistiky viz studijní materiály

**Příklad 7.4.** Při kontrolních zkouškách životnosti 16 žárovek byl stanoven odhad  $m = 3000 \text{ h}$  střední hodnoty jejich životnosti. Z dřívějších zkoušek je známo, že životnost žárovky se řídí normálním rozdělením se směrodatnou odchylkou  $\sigma = 20 \text{ h}$ . Vypočtěte

- 99 % empirický interval spolehlivosti pro střední hodnotu životnosti;
- 90 % levostranný empirický interval spolehlivosti pro střední hodnotu životnosti;
- 95 % pravostranný empirický interval spolehlivosti pro střední hodnotu životnosti.

ad a)

$$d = m - \frac{\sigma}{\sqrt{n}} u_{1-\alpha} = 3000 - \frac{20}{\sqrt{16}} 2.57583 = 2987.1$$

$$h = m - \frac{\sigma}{\sqrt{n}} u_\alpha = 3000 + \frac{20}{\sqrt{16}} 2.57583 = 3012.9$$

```
m <- 3000
s <- 20
n <- 16

# a)
alpha <- 0.01
(dh <- m-s/sqrt(n)*qnorm(1-alpha/2))
(hh <- m-s/sqrt(n)*qnorm(alpha/2))
```

2987 h a 6 min  $< \mu <$  3012 h a 54 min s pravděpodobností 0.99.

ad b)

$$d = m - \frac{\sigma}{\sqrt{n}} u_{1-\alpha} = 3000 - \frac{20}{\sqrt{16}} 1.28155 = 2993.6$$

```
alpha <- 0.1
(dh <- m-s/sqrt(n)*qnorm(1-alpha))
```

2993 h a 36 min  $< \mu$  s pravděpodobností 0.9.

ad c)

$$h = m + \frac{\sigma}{\sqrt{n}} u_\alpha = 3000 + \frac{20}{\sqrt{16}} 1.95996 = 3008.2$$

```
alpha <- 0.05
(hh <- m-s/sqrt(n)*qnorm(alpha))
```

3009 h a 48 min  $> \mu$  s pravděpodobností 0.95.