

7 Základní pojmy matematické statistiky

7.1 Vybrané statistiky pro jeden jednorozměrný náhodný výběr a jejich vlastnosti

X_1, \dots, X_n je náhodný výběr z rozložení se střední hodnotou μ a rozptylem σ^2 , $n \geq 2$.

Definice statistik

- $M = \frac{1}{n} \sum_{i=1}^n X_i$... výběrový průměr,
- $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - M)^2$... výběrový rozptyl,
- $S = \sqrt{S^2}$... výběrová směrodatná odchylka.

Vlastnosti statistik

- M je nestranným bodovým odhadem μ ,
- S^2 je nestranným bodovým odhadem σ^2 ,
- S je asymptoticky nestranným bodovým odhadem σ .

Příklad 7.1. Řešený příklad

Načtete datový soubor 17-anova-newborns.txt. Pro porodní hmotnost novorozence (weight.C) ženského pohlaví stanovte (a) hodnotu bodového odhadu μ ; (b) hodnotu bodového odhadu σ^2 ; (c) hodnotu bodového odhadu σ .

Řešení příkladu 7.1

Nestranným bodovým odhadem μ je výběrový průměr M . Jeho hodnotu stanovíme pomocí funkce mean(). Nestranným bodovým odhadem σ^2 je výběrový rozptyl S^2 . Jeho hodnotu stanovíme pomocí funkce var(). Asymptoticky nestranným bodovým odhadem σ je výběrová směrodatná odchylka S . Její hodnotu stanovíme pomocí funkce sd().

```
1 data <- read.delim('17-anova-newborns.txt')
2 weight.CF <- na.omit(data[data$sex == 'f', 'weight.C'])
3 m <- mean(weight.CF) # 3012,832
4 s2 <- var(weight.CF) # 455722,4
5 s <- sd(weight.CF) # 675,0722
```

Hodnota výběrového průměru $m = 3012,8$ mm, hodnota výběrového rozptylu $s^2 = 455722,4$ mm², hodnota výběrové směrodatné odchylky $s = 675,1$ mm. ★

Příklad 7.2. Neřešený příklad

Načtete datový soubor 18-more-samples-variances-clavicle.txt. Pro největší délku klíční kosti z pravé strany (cla.L) mužů řecké populace z Atén stanovte (a) hodnotu bodového odhadu μ ; (b) hodnotu bodového odhadu σ^2 ; (c) hodnotu bodového odhadu σ .

Výsledky: (a) $m = 153,5$ mm; (b) $s^2 = 83$, mm²; (c) $s = 9,1$ mm. ★

7.2 Vybrané statistiky pro jeden dvourozměrný náhodný výběr a jejich vlastnosti

$(X_1, Y_1)^T, \dots, (X_n, Y_n)^T$ je náhodný výběr z dvourozměrného rozložení se středními hodnotami μ_1, μ_2 , rozptily σ_1^2, σ_2^2 , kovariancí σ_{12} a koeficientem korelace ρ .

Definice statistik

- $M_1 = \frac{1}{n} \sum_{i=1}^n X_i$, $M_2 = \frac{1}{n} \sum_{i=1}^n Y_i$... výběrové průměry,
- $S_1^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - M_1)^2$, $S_2^2 = \frac{1}{n-1} \sum_{i=1}^n (Y_i - M_2)^2$... výběrové rozptily,
- $S_{12} = \frac{1}{n-1} \sum_{i=1}^n (X_i - M_1)(Y_i - M_2)$... výběrová kovariance,

- $R_{12} = \begin{cases} \frac{S_{12}}{S_1 S_2} & \text{pro } S_1 S_2 \neq 0, \\ 0 & \text{jinak,} \end{cases}$... výběrový koeficient korelace.

Vlastnosti statistik

- S_{12} je nestranným bodovým odhadem σ_{12} ,
- R_{12} je vychýleným bodovým odhadem ρ (vychýlení je zanedbatelné pro $n \geq 30$).

Příklad 7.3. Řešený příklad

Načtěte datový soubor 05-one-sample-correlation-skull-mf.txt. Pro největší výšku mozkovny (skull.pH) a morfologickou výšku tváře (face.H) žen stanovte (a) hodnotu bodového odhadu σ_{12} ; (b) hodnotu bodového odhadu ρ .

Řešení příkladu 7.3

Nestranným bodovým odhadem σ_{12} je výběrová kovariance S_{12} . Její hodnotu stanovíme pomocí funkce `cov()`. Vychýleným bodovým odhadem korelačního koeficientu ρ je výběrový koeficient korelace R_{12} . Jeho hodnotu stanovíme pomocí funkce `cor()`.

```
6 data <- read.delim('05-one-sample-correlation-skull-mf.txt')
7 data.F <- na.omit(data[data$sex == 'f', ])
8 skull.pHF <- data.F$skull.pH
9 face.HF <- data.F$face.H
10 cov(skull.pHF, face.HF) # 1,808192
11 cor(skull.pHF, face.HF) # 0,06417166
```

Hodnota výběrové kovariance $s_{12} = 1,808$, hodnota výběrového korelačního koeficientu $r_{12} = 0,064$. Mezi největší výškou mozkovny a morfologickou výškou tváře existuje zanedbatelný stupeň přímé lineární závislosti. ★

Příklad 7.4. Neřešený příklad

Načtěte datový soubor 19-more-samples-correlations-skull.txt. Pro výšku nosu (nose.H) a šířku nosu (nose.B) peruánské populace stanovte (a) hodnotu bodového odhadu σ_{12} ; (b) hodnotu bodového odhadu ρ .

Výsledky: $s_{12} = 0,699$; $r_{12} = 0,137$. Mezi výškou a šířkou nosu mužů peruánské populace existuje slabý stupeň přímé lineární závislosti. ★

7.3 Vybrané statistiky pro dva nezávislé náhodné výběry a jejich vlastnosti

X_{11}, \dots, X_{1n_1} a X_{21}, \dots, X_{2n_2} jsou dva nezávislé náhodné výběry, první z rozložení se střední hodnotou μ_1 a rozptylem σ^2 , druhý z rozložení se střední hodnotou μ_2 a rozptylem σ^2 , $n_1 \geq 2$, $n_2 \geq 2$.

Definice statistik

- $M_1 - M_2 = \frac{1}{n_1} \sum_{i=1}^{n_1} X_{1i} - \frac{1}{n_2} \sum_{i=1}^{n_2} X_{2i}$... rozdíl výběrových průměrů,
- $\frac{S_1^2}{S_2^2} = \frac{\frac{1}{n_1-1} \sum_{i=1}^{n_1} (X_{1i} - M_1)^2}{\frac{1}{n_2-1} \sum_{i=1}^{n_2} (X_{2i} - M_2)^2}$... podíl výběrových rozptylů,
- $S_*^2 = \frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2}$... vážený průměr výběrových rozptylů.

Vlastnosti statistik

- $M_1 - M_2$ je nestranným bodovým odhadem $\mu_1 - \mu_2$,
- S_*^2 je nestranným bodovým odhadem σ^2 .

Příklad 7.5. Řešený příklad

Načtěte datový soubor 15-anova-means-skull.txt. Pro výšku horní části tváře (upface.H) malajské a čínské populace

stanovte (a) hodnotu bodového odhadu $\mu_1 - \mu_2$; (b) hodnotu bodového odhadu σ^2 .

Řešení příkladu 7.5

Nestranným bodovým odhadem $\mu_1 - \mu_2$ je rozdíl výběrových průměrů $M_1 - M_2$. Hodnoty výběrových průměrů vypočítáme pomocí funkce `mean()`. Nestranným bodovým odhadem σ^2 je vážený průměr výběrových rozptylů S_*^2 . Hodnoty výběrových rozptylů vypočítáme pomocí funkce `var()`, rozsahy náhodných výběrů stanovíme pomocí funkce `length()`.

```
12 data <- read.delim('15-anova-means-skull.txt')
13 data <- na.omit(data)
14 upface.HM <- data[data$pop == 'mal', 'upface.H']
15 upface.HC <- data[data$pop == 'cin', 'upface.H']
16 m1 <- mean(upface.HM) # 70,13043
17 m2 <- mean(upface.HC) # 72
18 m1 - m2 # -1,869565
19 s1 <- var(upface.HM) # 24,52685
20 s2 <- var(upface.HC) # 20,82353
21 n1 <- length(upface.HM) # 69
22 n2 <- length(upface.HC) # 18
23 sh <- ((n1 - 1) * s1 + (n2 - 1) * s2) / (n1 + n2 - 2) # 23,78619
```

Hodnota rozdílu výběrových průměrů $m_1 - m_2 = -1,9$ mm, hodnota váženého průměru výběrových rozptylů $s_*^2 = 23,8$ mm². ★

Příklad 7.6. Neřešený příklad

Načtěte datový soubor 01-one-sample-mean-skull-mf.txt. Pro největší délku mozkovny mužů a žen (skull.L) stanovte (a) hodnotu bodového odhadu $\mu_1 - \mu_2$; (b) hodnotu bodového odhadu σ^2 .

Výsledky: $m_1 - m_2 = 7,5$ mm; $s_*^2 = 39,9$ mm². ★

7.4 Vybrané statistiky pro aspoň tři nezávislé náhodné výběry a jejich vlastnosti

X_{11}, \dots, X_{1n_1} až X_{r1}, \dots, X_{rn_r} , je $r \geq 3$ nezávislých náhodných výběrů, první z rozložení se střední hodnotou μ_1 a rozptylem σ^2 až r -tý z rozložení se střední hodnotou μ_r a rozptylem σ^2 , $n_1 \geq 2, \dots, n_r \geq 2$. Označme $n = \sum_{j=1}^r n_j$. Nechť c_1, \dots, c_r jsou reálné konstanty, aspoň jedna nenulová.

Definice statistik

- $\sum_{j=1}^r c_j M_j$... lineární kombinace výběrových průměrů,
- $S_*^2 = \frac{\sum_{j=1}^r (n_j - 1) S_j^2}{n - r}$... vážený průměr výběrových rozptylů.

Vlastnosti statistik

- $\sum_{j=1}^r c_j M_j$ je nestranným bodovým odhadem $\sum_{j=1}^r c_j \mu_j$,
- S_*^2 je nestranným bodovým odhadem σ^2 .

Příklad 7.7. Řešený příklad

Načtěte datový soubor 18-more-samples-variances-clavicle.txt. Pro největší délku klíční kosti z pravé strany (cla.L) řecké populace z Atén, indické populace z Amritsaru a indické populace z Varanasi stanovte (a) hodnotu bodového odhadu $\sum_{j=1}^r c_j \mu_j$, kde $c_1 = -2, c_2 = 2, c_3 = 3$; (b) hodnotu bodového odhadu σ^2 .

Řešení příkladu 7.7

Nestranným bodovým odhadem $\sum_{j=1}^r c_j \mu_j$ je lineární kombinace výběrových průměrů $\sum_{j=1}^r c_j M_j$. Hodnoty výběrových průměrů vypočítáme pomocí funkce `mean()`. Nestranným bodovým odhadem σ^2 je vážený průměr výběrových rozptylů S_*^2 . Hodnoty výběrových rozptylů vypočítáme pomocí funkce `var()`, rozsahy náhodných výběrů stanovíme pomocí funkce `length()`.

```

24 data <- read.delim('18-more-samples-variances-clavicle.txt')
25 data <- na.omit(data)
26 cla.LG <- data[data$pop == 'gre', 'cla.L']
27 cla.LA <- data[data$pop == 'ind1', 'cla.L']
28 cla.LV <- data[data$pop == 'ind2', 'cla.L']
29 m1 <- mean(cla.LG) # 153,5213
30 m2 <- mean(cla.LA) # 145,5667
31 m3 <- mean(cla.LV) # 141,4938
32 c1 <- -2
33 c2 <- 2
34 c3 <- 3
35 c1 * m1 + c2 * m2 + c3 * m3 # 408,5723
36 s1 <- var(cla.LG) # 83,15546
37 s2 <- var(cla.LA) # 76,27283
38 s3 <- var(cla.LV) # 67,57184
39 n1 <- length(cla.LG) # 94
40 n2 <- length(cla.LA) # 120
41 n3 <- length(cla.LV) # 81
42 sh <- ((n1 - 1) * s1 + (n2 - 1) * s2 + (n3 - 1) * s3) / (n1 + n2 + n3 - 3) # 76,08107

```

Hodnota lineární kombinace $-2m_1 + 2m_2 + 3m_3 = 408,5723$, hodnota váženého průměru výběrových rozptylů $s_*^2 = 76,0811$. ★

Příklad 7.8. Neřešený příklad

Načtěte datový soubor 19-more-samples-correlations-skull.txt. Pro interorbitální šířku (intorb.B) německé, bantuské, malajské, čínské a peruánské populace stanovte (a) hodnotu bodového odhadu $\sum_{j=1}^r c_j \mu_j$, kde $c_1 = 1$, $c_2 = 2$, $c_3 = -1$, $c_4 = 0$, $c_5 = -1$; (b) hodnotu bodového odhadu σ^2 .

Výsledky: (a) $m_1 + 2m_2 - m_3 + 0m_4 - m_5 = 30,8$ mm; (b) $s_*^2 = 5,6$ mm². ★