

Testy o střední hodnotě při neznámém rozptylu

Mgr. Zdeňka Geršlová

Teorie

Studijní materiály k přednáškám:

stka_STATINF_statinferencence_handout_02_2024_draft.pdf

kniha Aplikovaná štatistická inferencia I.,
kapitola 6.1 (od str. 143)

Praktický příklad

Z archivních materiálů (Schmidt, 1888) máme k dispozici původní kranio-metrické údaje 215 dospělých mužů a 107 dospělých žen ze starověké egyptské populace o basion-bregmatické výšce lebky. Údaje jsou k dispozici v souboru [two-samples-means-skull.txt](#). Současně máme k dispozici hodnoty basion-bregmatické výšky ($\bar{x}_m = 133.977, \text{mm}$; $\bar{x}_f = 126.942, \text{mm}$) a hodnoty směrodatné odchylky ($s_m = 5.171, \text{mm}$; $s_f = 4.430, \text{mm}$) mužů a žen novověké egyptské populace.

Na hladině významnosti $\alpha = 0.05$ otestujte nulovou hypotézu

$H_0 : \mu_f = 126.942$ oproti alternativní hypotéze

$H_1 : \mu_f \neq 126.942$.

Před testováním ověřte předpoklad normality.

Testování proveďte pomocí

(a) kritického oboru;

(b) intervalu spolehlivosti;

(c) p-hodnoty

při použití testovacích statistik (1) T_W , (2) U_W , (3) U_S , (4) $U_L R$.

Načtení dat

Načteme data, vyfiltrujeme (pomocí `==`) pouze ženy a proměnnou `skull.H`, odstraníme NA hodnoty. Střední hodnotu a rozptyl neznáme, proto je odhadneme pomocí `mean()` a `var()`, resp. `sd()`.

```
read.delim("cesta k souboru", sep = '\\t', dec = '.')
```

$$\hat{\mu} = 125.682243$$

$$\hat{s} = 4.6532564$$

Ověření normality

Normalitu ověříme graficky (histogram, qq-plot) a testem (adekvátně rozsahu náh. výběru). U histogramu je nutné nastavit počet třídících intervalů pomocí Sturgesova pravidla

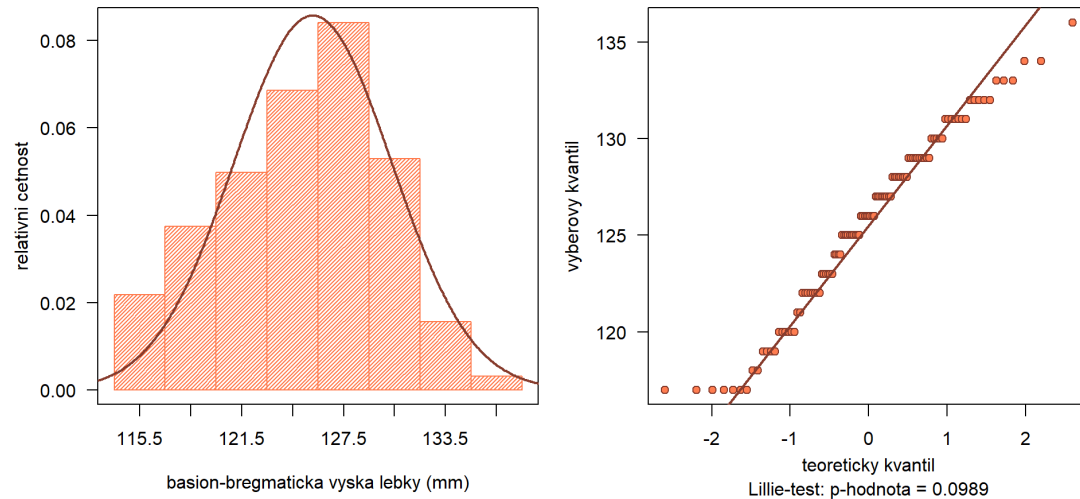
```
r <- 3.3 + log10(n) + 1 # 7.69 -> 8
range(skull.F) # 117 136 -> 19 -> 24/8 = 3
```

Zaokrouhlíme na nejbližší vyšší celé číslo, spočítáme rozsah proměnné a adekvátně ho rozšíříme tak, aby byl dělitelný tímto číslem, čímž získáme šířku třídících intervalů. Tedy v našem případě rozšíříme rozsah na 114 - 138 a délka intervalu je 3.

```
b <- seq(114, 138, by = 3)
hist(..., breaks = b, ...)
lines(..., dnorm(..., mean(skull.F), sd(skull.F)), ...)

qqnorm(skull.F, ylab = 'vyberovy kvantil', ...)
qqline(skull.F, ...)
mtext('teoreticky kvantil', side = 1, line = 2.2)
mtext(paste('Lillie-test: p-hodnota =', round(nortest::lillie.test(skull.F)$p.val, 4)), side = 1, line = 3.3)
# zpusob, jak zadat vysledek testu do popisku grafu
```

Grafy pro ověření normality



Protože p-hodnota Lillieforsova testu je,
zamítáme/nezamítáme H_0 na hladině významnosti 0.05, a tedy
předpokládáme, že data pocházejí/nepocházejí z normálního
rozdělení. Vizualním posouzením vidíme/nevidíme výrazné
odchylky od normality.

Testovací statistiky

Vypočítáme testovací statistiku t_W a ostatní statistiky vypočítáme pomocí vztahů mezi jednotlivými typy statistik:

$$u_W = \frac{n}{n-1} t_W^2, u_S = \frac{n t_W^2}{n-1+t_W^2},$$

$$u_{LR} = n \ln \left(1 + \frac{t_W^2}{n-1} \right), \text{ kde } t_W^2 = \frac{(\bar{x} - \mu_0)^2}{S_{n-1}^2/n}$$

(pozn.: používáme směrodatnou odchylku S_{n-1} , tj. funkci `sd()`)

Vytvoříme funkce pro výpočet statistik na základě statistiky t_W , kde vstupem bude právě statistika t_W a rozsah náh. výběru n .

```
UW <- function(tw, n){  
  uw <- tw ^ 2 * (n / (n - 1))  
  return(uw)  
}
```

Výsledky:

$$t_W = -2.8004105, u_W = 7.9162827, u_S = 7.3709506, u_{LR} = 7.6371306.$$

Funkce t.test()

V R lze pro výpočet t-statistiky testu o střední hodnotě použít rovněž funkci `t.test()`

```
t.test(skull.F, mu = 126.942)
```

One Sample t-test

```
data: skull.F
t = -2.8004, df = 106, p-value = 0.006067
alternative hypothesis: true mean is not equal to 126.942
95 percent confidence interval:
 124.7904 126.5741
sample estimates:
mean of x
 125.6822
```

Test pomocí kritického oboru

Waldův test: $t_{n-1}(1 - \alpha/2), t_{n-1}(\alpha/2)$

Test poměrem věrohodnosti: $\chi_1^2(\alpha)$ (pozn.: v R zadáváme jako 1-alpha)

```
alpha <- 0.05  
(qw <- qt(alpha / 2, n - 1))
```

```
[1] -1.982597
```

```
(qlr <- qchisq(1 - alpha, 1))
```

```
[1] 3.841459
```

Máme tedy kritické obory $W_W = (-\infty, -1.98) \cup (1.98, \infty)$
a $W_{LR} = (3.84, \infty)$.

Testy pomocí IS a p-hodnoty

Waldův IS máme ve výstupu funkce `t.test()` (vzorcem si vypočítejte samostatně jako DÚ).

```
dhW <- t.test(skull.F, mu = 126.942)$conf.int[1]
hhW <- ...
```

Pro věrohodnostní IS musíme sestavit posloupnost pro μ přibližně mezi hodnotami $\bar{x} - s$, $\bar{x} + s$ o minimální délce 2000 (čím více bodů, tím přesnější máme hranice IS), vytvořit vektory hodnot test. statistik v této posloupnosti a porovnat je s kritickou hodnotou:

```
mu_i <- seq(m - s, m + s, length = ...)
tW_i <- (m - mu_i) / s * sqrt(n)
uW_i <- ... # statistika uW pro tW_i

dh_uW <- round(min(mu_i[uW_i < qlr]), 4)
hh_uW <- round(max(mu_i[uW_i < qlr]), 4)
# analogicky pro uS a uLR

## p-hodnoty
pW <- 2 * min(pt(tW, n - 1), 1 - pt(tW, n - 1))
p_uW <- 1 - pchisq(uW, 1)
p_uS <- ...
p_uLR <- ...
```


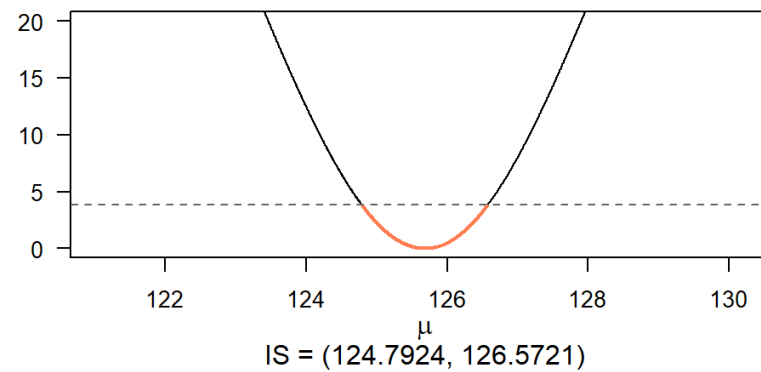
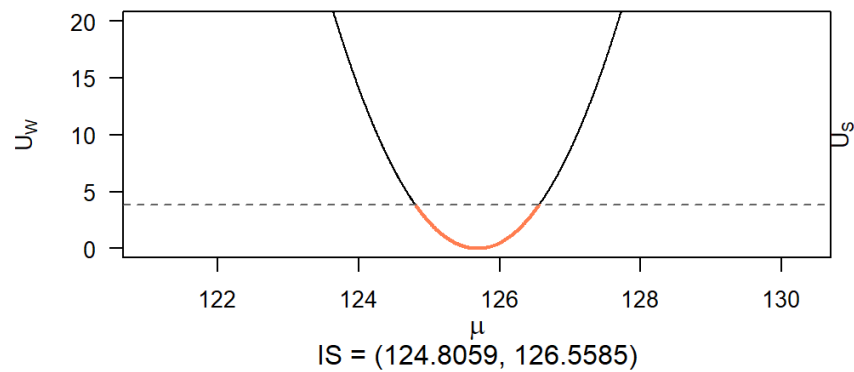
Tabulka výsledků

	statistika	W_{hh}	W_{dh}	IS_{dh}	IS_{hh}	p -hodnota
t_W	-2.800	-1.983	1.983	124.790	126.574	0.006
u_W	7.916	NA	3.841	124.806	126.558	0.005
u_S	7.371	NA	3.841	124.792	126.572	0.007
u_{LR}	7.637	NA	3.841	124.797	126.568	0.006

Interpretace: Mezi basion-bregmatickou výškou lebky žen starověké a novověké egyptské populace existuje statisticky významný rozdíl ($\mu - \mu_0 = -1.259757$).

Grafy IS

```
par(mar = c(5, 4, 1, 0), mfrow = c(2,2))
plot(mu_i, uW_i, type = 'l', ylim = c(0, 20), xlab = '',
     ylab = bquote(U[W]), las = 1)
lines(mu_i[uW_i < qlr], uW_i[uW_i < qlr], col = 'coral', lwd = 2)
abline(...) # seda carkovana cara v hodnote kvantilu
mtext(bquote(mu), side = 1, line = 2.2)
mtext(bquote(paste('IS = (', .(dh_uW), ', ', ', .(hh_uW), ')')')),
     side = 1, line = 3.3)
```



Příklad 2

Rozdělení testovacích statistik t_W a t_W^2

Nechť náhodný výběr X pochází z normálního rozdělení, t.j. $X \sim N(\mu, \sigma^2)$, kde $\mu = 150$ a $\sigma^2 = 30^2$. Rozsah náhodného výběru zvolte (a) $n = 10$; (b) $n = 100$.

Pomocí simulační studie ověřte, že pro test o střední hodnotě μ , když σ^2 neznáme, platí za platnosti H_0 následující:

$$1. T_W = \frac{(\bar{x} - \mu_0)}{s/\sqrt{n}} \sim t_{n-1};$$

$$2. T_W^2 = \frac{(\bar{x} - \mu_0)^2}{s^2/n} \sim F_{1, n-1};$$

$$3. U_W = t_W^2 \frac{n}{n-1} \sim \chi_1^2;$$

$$4. U_S = \frac{\frac{nt_W^2}{n-1}}{1 + \frac{t_W^2}{n-1}} \sim \chi_1^2;$$

$$5. U_{LR} = n \ln \left(1 + \frac{t_W^2}{n-1} \right) \sim \chi_1^2.$$

Postup

Vygenerujte $M = 1000$ pseudonáhodných výběrů o rozsahu $n = 5$. Pro každý náhodný výběr vypočítejte hodnoty realizací testovacích statistik. Vytvořte histogramy těchto testovacích statistik a superponujte je křivkami příslušného rozdělení. Dále vytvořte animaci, pomocí které vizualizujete přesnost rozdělení testovacích statistik při různých rozsazích náhodného výběru. Animaci vytvořte pro měnící se $n \in \{5, 10, 15, 20, 25, 30, 35, 40, 50, 100, 250, 500\}$.

V R vytvoříme funkci TStat, která nám pro vstupní parametry rozdělení spočítá test. statistiky a v závislosti na typu statistiky (parametr `type`) nám vykreslí histogramy proložené křivkou přílušného rozdělení.

Funkce TStat

```
TStat <- function(mu, sigma, M = 1000, n, type = 'tW')
  x <- rnorm(M * n, mu, sigma)
  X <- matrix(x, nrow = M)
  m <- apply(..., # vektor prumeru
  s <- apply(..., # vektor vyb. sd
  tW <- ... # tW

  if (type == 'tW') {
    X <- tW
    main <- expression(t[W])
    xlim = c(-7, 7)
    xx <- seq(-7, 7, length = 512)
    yy <- ... # hustota Student. rozdeleni
             # o n-1 stupnich volnosti
  }
  if (type == 'tW2') {...}
  # rozsah x pro tw^2 volte (0,15)
  if (type == 'uW') {
    X <- ...
    main <- ...
    xlim = c(0, 10)
    xx <- seq(0, 15, length = 512)
    yy <- ... # hustota prislusneho rozdeleni pro uW
  }
  ... ## doplnte pro uS a uLR
```



Tipy pro nastavení histogramu:

```
## pokračovani funkce TStat
## nastaveni histogramu
hist(..., main = '', ylim = c(0, 0.5),
      xlim = xlim, breaks = 15)
box(bty = 'o')
... # vykresleni krivky hustoty
mtext(main, side = 1, line = 2.2)
mtext(bquote(paste(n == .(n))), side = 1, line = 3.3)
}
```




Výsledné animace

```
```\r\n#| fig-show: animate\r\n#| eval: false\r\nlibrary(gifski)\r\nn <- ... \r\npar(mfrow = c(1, 2), mar = c(5, 5, 1, 1))\r\nfor (i in 1:length(n)) {\r\n  TStat(mu = ..., sigma = ..., n = n[i], type = 'tW')\r\n  TStat(mu = ..., sigma = ..., n = n[i], type = 'tW2')\r\n}\r\n```\r\n
```

Výsledná animace pro  $T_W$  a  $T_W^2$



# Animace pro věrohodnostní statistiky



# Příklad 3

## Porovnání testovacích statistik $U_W$ , $U_S$ a $U_{LR}$

Pomocí simulační studie porovnejte tvary těchto tří testovacích statistik a ukažte, že platí vztah  $U_S < U_{LR} < U_W$ .

Vygenerujte  $M = 1000$  náhodných výběrů  $X \sim N(0, 3)$  a pro každý výběr vypočítejte hodnoty testovacích statistik  $U_W$ ,  $U_S$  a  $U_{LR}$  pro test nulové hypotézy  $H_0 : \mu = \mu_0 = 0$  oproti alternativní hypotéze  $H_1 : \mu \neq \mu_0$ .

(A) Pro každou testovací statistiku následně najděte její jádrový odhad a křivky jádrového odhadu pro pevně zvolené  $n$  vykreslete do jednoho grafu. Vytvořte animaci zobrazující tvary křivek jádrových odhadů testovacích statistik při rostoucím rozsahu náhodných výběrů  $n$ . Rozsah výběrů  $n$  volte postupně

$n = 2, 3, \dots, 9, 10, 15, 20, 25, 30, 35, 40, 50, 100, 250, 500$ .


(B) Dále vypočítejte průměrné hodnoty testovacích statistik  $U_W$ ,  $U_S$  a  $U_{LR}$  pro  $n = 5, 10, 100$  a  $1000$  a zanepte je do jednoho grafu.

# Funkce PorovnaníU

```
PorovnaníU <- function(n, M = 1000, mu0, mu, sigma, plot = T) {
 X <- t(replicate(M, rnorm(n, mu, sigma)))
 ... # vypočet m, s, tw, uW, uS, uLR jako u pr. 2

 prumery <- c(mean(uW), mean(uS), mean(uLR)) # předchystání pro B)
 if (plot == T) { # graf se vykreslí pouze pro plot = T
 plot(uW, # příprava prázdného grafu
 type = "n", ylim = c(0, 1), xlim = c(0, 4),
 xlab = "", ylab = "hustota", main = "", las = 1
)
 lines(density(uW, from = 0), col = "red") # křivka jadrového odhadu hustoty
 # z definice nemůže být statistika záporná
 ... # další 2 křivky, legenda
 abline(v = 0, lty = 2, col = "gray60") # přidání ref. křivky do 0
 }
 return(prumery = prumery)
}
```

# Výsledná animace




Z animace je patrné, že se statistiky asymptoticky blíží. Také si můžeme všimnout, že pro malé rozsahy náh. výběru statistika  $U_W$  selhává a není tedy pro testy o střední hodnotě při neznámém rozptylu v případech malých  $n$  vhodná.

# B) graf průměrných hodnot statistik

```
pro vypocet prumeru pouzijeme funkci PorovnaníU s nastavením plot = F
m5 <- PorovnaníU(mu0 = 0, mu = 0, sigma = sqrt(3), n = 5, plot = F)
m10 <- ... # m100, m1000
m <- cbind(m5, m10, m100, m1000)
m_uW <- m[1,] # průmery uW jsou v prvním sloupci m
m_uS <- ... # průmery uS jsou ve druhém sloupci m
m_uLR <- ... # průmery uLR jsou ve třetím sloupci m

plot(1:4, m_uW, type = 'o', ylim = c(min(m_uS) - 0.1, max(m_uW) + 0.1),
 axes = F, ...)
ylim nastavujeme podle minima nejmenší a maxima největší statistiky
type = 'o' vykreslí body spojené čarami
axis(1, at = c(1, 2, 3, 4), labels = c(5, 10, 100, 1000)) # změna popisku osy x
přidáme další křivky a legendu
```



# Příklad 4

Hustota a distribuční funkce centrálního a necentrálního  $t$ -rozdělení

Nakreslete

(a) hustotu;

(b) distribuční funkci

jednoho centrálního a čtyř necentrálních  $t$ -rozdělení  $t_{n-1,\lambda}$  ( $\delta = \mu - \mu_0$  a  $\lambda = \delta / (\sigma / \sqrt{n})$ ) do jednoho obrázku tak, aby byly odlišitelné barvou nebo typem čáry. Zvolte  $\mu_0 = 0$ ,  $\sigma = 1.4$ ,  $n = 26$ ,  $\delta = 0, 0.5, 0.8, 1$  a  $1.2$ .



# Postup v R



```
delta <- c(...) # vektor delta
barvy <- c(...) # zvolime vektor 5 barev

plot(0, 0, type = 'n', xlab = 'x', ylab = 'hustota', main = '',
 las = 1, xlim = c(-4, 9), ylim = c(0, 0.5)) # predchystani grafu

for (i in 1:length(delta)) {
 lambda <- ... # parametr necentrality pro delta[i]
 xfit <- seq(-5, 10, length = ...)
 yfit <- ...(..., ..., ncp = lambda)
 # hustota student. rozdeleni s n-1 stupni volnosti
 lines(..., ..., col = barvy[i])
}

obdobne pro distribucni funkci
nezapomente spravne nastavit ylim u distribucni fce
v grafu distrib. fce cheme mit referencni caru
v hodnote kvantilu $t_{n-1}(1 - \alpha/2)$
ta by mela protinat krivku ve vysce 0.975
abline(v = qt(0.975, n), col = 'grey60', lty = 5)
```

# Graf hustoty a distribuční fce



Z grafu distribuční funkce lze pozorovat, jak necentralita ovlivňuje vztah kvantilu a distribuční fce. Dále lze z grafů pozorovat, že s měnící se hodnotou  $\lambda$  se mění nejen střední hodnota, ale i rozptyl Studentova necentrálního rozdělení.

