

# Testy o střední hodnotě při neznámém rozptylu

Mgr. Zdeňka Geršlová

## Teorie

Studijní materiály k přednáškám: stka\_STATINF\_statinference\_handout\_02\_2024\_draft.pdf

knihy Aplikovaná statistická 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 hypotézu o shodě střední hodnoty basion-bregmatické výšky lebky žen staroegyptské populace se střední hodnotou basion-bregmatické výšky lebky žen novověké egyptské populace, tj. 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)  $U_{LR}$ .

Dále vykreslete grafy zobrazující věrohodnostní intervaly spolehlivosti pro test o střední hodnotě získané na základě testovacích statistik  $U_W$ ,  $U_S$  a  $U_{LR}$ .

## 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 = '.')
skull.F <- data[data$sex == 'f', 'skull.H']
skull.F <- na.omit(skull.F)
```

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

$$\hat{s} = 4.6532564$$

## 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 # 6.32 -> 7
range(skull.F) # 117 136 -> 19 -> 21/7 = 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 116 - 137 a délka intervalu je 3.


```
b <- seq(116, 137, 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)), si
# zpusob, jak zadat vysledek testu do popisku grafu
```

## Grafy pro ověření normality



basion-bregmaticka vyska lebky (



Lillie-test: p-hodnota = 0.098!

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:

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

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

(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  $\mu$  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 <- ...
```

Nakonec sestavíme tabulku výsledků, kde budou pro jednotlivé statistiky jejich hodnoty, hranice IS, kritických oborů a p-hodnota testu.




### 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  $\mu$ , když  $\sigma^2$  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 příslušného 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(..., MARGIN = 2) # vektor prumeru
  s <- apply(..., MARGIN = 2) # 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}
#| fig-show: animate
#| eval: false
library(gifski)
n <- ...
par(mfrow = c(1, 2), mar = c(5, 5, 1, 1))
for (i in 1:length(n)) {
  TStat(mu = ..., sigma = ..., n = n[i], type = 'tW')
  TStat(mu = ..., sigma = ..., n = n[i], type = 'tW2')
}
```

```

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 zanešte 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)) # zmena popisku osy x
# pridame dalsi krivky 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)

```

## Vytvoření legendy

Protože funkce `legend()` se přepisuje při každém zavolání, je nutné zadat ji až na konci mimo `for` cyklus (pokud bychom ji chtěli ponechat uvnitř cyklu, museli bychom nastavit postupné posouvání souřadnic, kde se má legenda vykreslit). K vykreslení symbolu  $\delta$  s příslušnou hodnotou můžeme použít 2 způsoby:

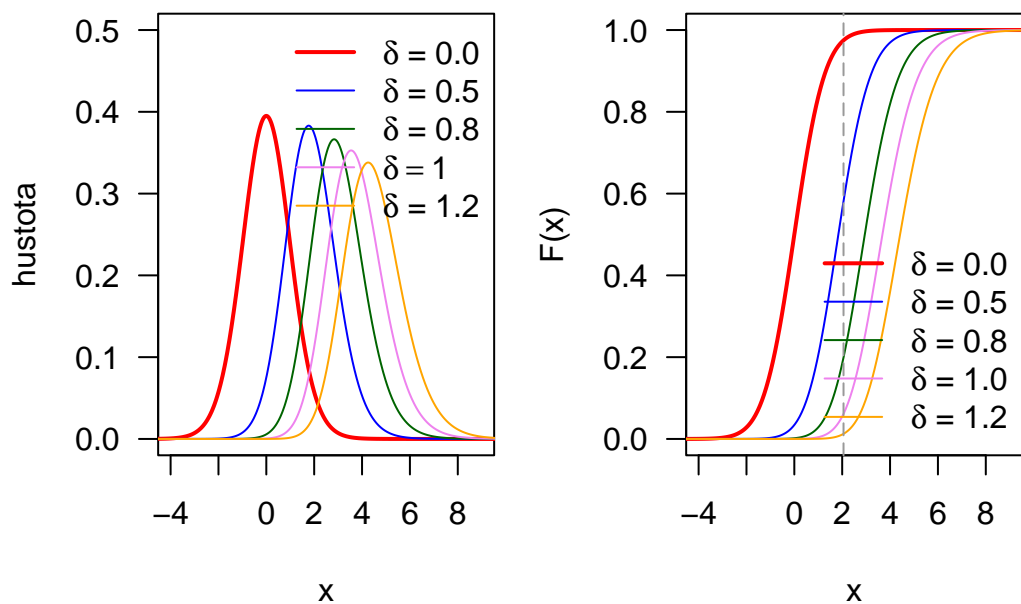
```

# 1. zpusob
legend('pozice', col = barvy,
      legend = c(expression(paste(delta, ' = 0.0'))), # rucni nastaveni hodnoty
      ... # totez pro dalsi hodnoty
      ))

# 2. zpusob
legend('pozice', col = barvy,
      legend = c(bquote(paste(delta == .(delta[1])))),
      ... # analogicky pro dalsi hodnoty
      ))

```

## 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.