

a) $X \sim N(20, 100)$

b) $X \sim pN(20, 100) + (1-p)N(28, 100), p = 0.9$

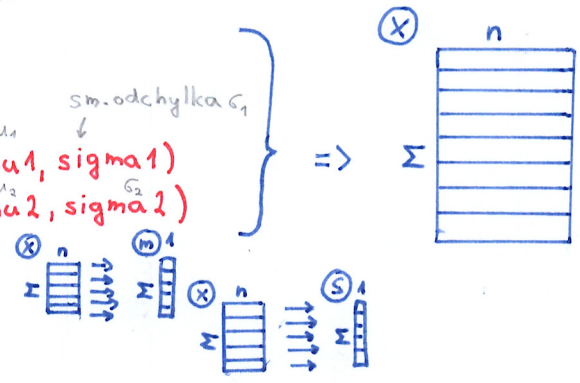
$H_0: \mu = \mu_0 \quad H_1: \mu \neq \mu_0$
 $H_0: \mu = 20 \quad H_1: \mu \neq 20$

H_0 testujeme testem $\sigma \mu$ když σ^2 známe. (Simulace reálné situace, kdy máme nějaký náhodný výtěr, který má nějakou skř. hodnotu μ a nějaký rozptyl σ^2 , ale my je známe. Zde obě hodnoty známe, ale chováme se, jako bychom je neznali. O μ pouze prostřednictvím H_0 předpokládáme, že $\mu = 20$, σ^2 nevíme nic).

Testovací statistika testu $\sigma \mu$ když σ^2 známe: $T_W = \frac{\bar{X} - \mu_0}{S} \sqrt{n} \stackrel{H_0}{\sim} t_{n-1}$
 $S = \sqrt{S^2}$, kde $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$
↑ Studentovo rozdělení s $n-1$ stupni volnosti.

Řešení (a) i (b) v jednom: parametry μ_0 , $M=500$, $\mu_1=...$, $\mu_2=\mu_1$, $\sigma_1=...$, $\sigma_2=\sigma_1$, $p=0.9$, $\alpha=...$ doplnit

```
M <- 500; n <- 5; p <- 0.9
X <- matrix(NA, M, n)
for(i in 1:M){
  bin <- rbinom(n, 1, p)
  X[i, ] [bin == 1] <- rnorm(sum(bin == 1), mu1, sigma1)
  X[i, ] [bin == 0] <- rnorm(sum(bin == 0), mu2, sigma2)
}
m <- apply(X, 1, mean) ...  $\bar{x}$  ... vektor průměrů  $\bar{x}$ 
S <- apply(X, 1, sd) ... S ... vektor sm. odchylek S
tw <- (m - mu0) / S * sqrt(n)
```



```
histogram
d <- hist(tw, plot=F)$dens ... nějaký sloupců histogramu (myřujeme poději k nasazení optimálního rozsahu osy y)
xfit <- seq(..., prob=prob, od tw-10 do tw+10 a délka minimálně 500)
yfit <- dt(..., hustota Studentova rozdělení s n-1 st. volnosti nad posloupností xfit)
akt.hl.vyzn <- sum(I(abs(tw) > qt(1-alpha/2))) / M = dhat
akt.p.pokryti <- 1 - dhat
```

```
hist(tw, prob=T, xlim=c(-6,6), ylim=c(0, max(yfit, d)),
      breaks=seq(floor(min(tw)), ceiling(max(tw)), by=0.5), ... ) histogram
```

hranice intervalů budou čísla
cca -6, -5.5, -5, -4.5, ..., 5.5, 6

```
box(...)
mtext(expression(tw), side=1, line=2.2) ... popisek tw
mtext(bquote(paste(1-alpha == .(1-alpha), ' ', 1-widehat(alpha) == .(akt.p.pokryti))), ... )
mtext(main, ...) ... popisek  $X \sim N(20, 100); n=5$ 
lines(xfit, yfit, ...)
```

(b) $KWaldT(\mu_0=20, n=5, \mu_1=28, main='X \sim 0.9N(20, 100) + 0.1N(28, 100)')$

! Nezapomeňte u každé situace uvést závěr, zda je test konzervativní nebo liberální (def. viz S02)

5.2 + 5.3

$X \sim N(150, 30^2)$

$H_0: \mu = \mu_0 \quad H_1: \mu \neq \mu_0$
 $H_0: \mu = 150 \quad H_1: \mu \neq 150$

H_0 budeme testem σ μ když σ^2 rovnáme.

1. Testovací statistika $T_W = \frac{\bar{x} - \mu_0}{s} \sqrt{n} \sim t_{n-1}$

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

3. Testovací statistika $U_W = t_W^2 \frac{n}{n-1} \sim \chi^2_1$

4. Testovací statistika $U_S = \frac{\frac{n \cdot s_w^2}{n-1}}{1 + \frac{s_w^2}{n-1}} \sim \chi^2_1$

5. Testovací statistika $U_{LR} = n \ln(1 + \frac{t_W^2}{n-1}) \sim \chi^2_1$

$S = \sqrt{S^2} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$

Příklady 5.2 a 5.3 vyřešíme společně vytvořením funkce **T.stat()**, která v závislosti na zvoleném typu testovací statistiky vykreslí odpovídající obrázek. Tuto funkci pak použijeme k vykreslení animací v obou příkladech.

```
T.stat ← function(mu0, mu, n, sigma1=30, sigma2=sigma1, M=..., p=..., type='tW') {
```

Generování dat

```
n ← 5; M ← 1000
X ← matrix(NA, M, n)
for(...) {
  ...
}
```

Viž předchozí příklad $((...)\text{rnorm}(\text{sum}(\text{bin}==1), \mu, \text{sigma1}))$
 $((...)\text{rnorm}(\text{sum}(\text{bin}==0), \mu, \text{sigma2}))$

Kód si nachystáme i pro směs, ač ji v tomto příkladu nemáme zadanou. Se změnou parametru G_1 a G_2 pak můžete kdykoli libovolně experimentovat =).

Příprava testovacích statistik

```
m ← apply( ) vektor nřídřinných průmřřř  $\bar{x}$  (dřřřř = 1000)
s ← apply( ) vektor nřídřinných sm odchylek s (1000)
tW ←  $\frac{\bar{x} - \mu_0}{s} \sqrt{n}$  (1000)
tW2 ←  $s_w^2$  (1000)
uW ←  $s_w^2 \frac{n}{n-1}$  (1000)
uS ←  $\frac{n \cdot s_w^2}{n-1 + s_w^2}$  (1000)
uLR ←  $n \ln(1 + \frac{s_w^2}{n-1})$  (1000)
```

testovací statistiky

```
if (type == 'tW') { // nastavení specifických prřřřřř při vykreslení histogramu pro test. statistiku tW.
  x ← tW
  main ← expression(...) ... popis ek tW
  xlim ← c(-7, 7)
  xx ← seq(-7, 7, length=512) přřřřřř od -7 do 7 o minimální dřřřřř 500
  yy ← dt(...) hustota Studentova rozdělení o n-1 sv. volnosti nad postupností xx
}
```

Specifikace vybraných proměnných podle zvolené

```

if (type == 'tw1') {
  X ← tw1
  main ← ... popisek tw
  xlim ← c(0, 15)
  xx ← seq(...) posl. od 0 do 20 a délka minimálně 500
  yy ← df(...) hustota Fisher - Snedecorova F-rozdělení s 1 a n-1 stupni volnosti nad poloupravou xx
}

```

```

if (type == 'uW') {
  X ← ...
  main ← ... popisek uW
  xlim ← c(0, 10)
  xx ← ... posl. od 0 do 15 a délka minimálně 500
  yy ← dchisq(...) } hustota  $\chi^2$ -rozdělení s 1 stupni volnosti nad poloupravou xx
}

```

```

if (type == 'uS') { analogicky jako uW }
if (type == 'uLR') { analogicky jako uW }

```

```

hist(X, prob=T, ylim=c(0, 0.5), breaks=15, xlim=xlim, ...)
box(...) □

```

```

mtext(main, ...) popisek ... nahor zvolené hodnoty statistiky
mtext(bquote(paste(...)), ...) popisek n = m (m se automaticky mění v závislosti na zvoleném rozsahu máh. výběru).
lines(xx, yy, ...) křivka hustoty příslušného rozdělení súb. statistiky

```

* 5.2: Animace asymptotického rozdělení statistik tw a tw^2 :

```

n ← c(5, 10, 15, ..., 250, 500)
par(mfrow=c(1, 2), mar=c(5, 5, 1, 1))
opts ← ...
ani.record ← ...
saveLatex(for (i in 1:length(n)) {
  T.stat(mu0=150, mu=150, n=n[i], type='tw')
  T.stat(mu0=150, mu=150, n=n[i], type='tw2')
}, ...)

```

5.3: Animace (asymptotického) rozdělení statistik Uw , Us a ULR :

- analogicky jako 5.2 (*).

$$U_S = \frac{\frac{n \Delta_w^2}{n-1}}{1 + \frac{\Delta_w^2}{n-1}} \quad U_{LR} = n \ln\left(1 + \frac{\Delta_w^2}{n-1}\right) \quad U_W = \frac{n \Delta_w^2}{n-1} \quad // x = \frac{\Delta_w^2}{n-1}$$

$$\frac{n x}{1+x} \quad n \ln(1+x) \quad n x$$


Z příkladu 2.1 (z druhého cvičení) víme, že platí nerovnost $\frac{x}{1+x} \leq \ln(1+x) \leq x$.
 $\Rightarrow U_S \leq U_{LR} \leq U_W$. Při $n \rightarrow \infty$ se na platnosti H_0 rozdílů všech tří test. statistik blíží k χ^2_1 rozdělení a platí $U_S \approx U_{LR} \approx U_W$.

Platnost nerovnosti $U_S \leq U_{LR} \leq U_W$ ověříme pomocí simulační studie:

1. Vygenerujeme $M=1000$ náh. výběrů ($X \sim N(0,3)$).
 - Vypočítáme 1000 realizací test. statistik U_W, U_S a U_{LR} .
 - Vypočítáme 3 jádrové odhady hustot rozdělení test. statistik U_W, U_S a U_{LR} a křivky těchto jádrových odhadů nakreslíme do grafu.
 - Vyrobíme animaci zobrazující změnu těchto jádrových odhadů při rostoucím n . Tuto změnu porovnáme.
2. Vypočítáme průměrné hodnoty $M=1000$ realizací test. statistik U_W (resp. U_S a U_{LR}) pro $n=5, n=10, n=100$ a $n=1000$ a zakreslíme je jako body do jednoho grafu. Rozdíly v bodech porovnáme.

1. porovnani ← function (n, M=..., mu=..., mu0=..., sigma=..., plot=...) {

```
M ← 1000; mu0 ← 0; mu ← 0; sigma ← sqrt(3)
```



```
X ← t(replicate(M, rnorm(n, mu, sigma))) ... matice náh. výběrů
```

```
m ← apply(..., n) vektor náh. průměrů (1000)
```

```
s ← apply(..., n) vektor náh. rozptylů (1000)
```

```
tW1 ← Δw^2 (1000)
```

```
uW ← U_W (1000)
```

```
uS ← U_S (1000)
```

```
uLR ← U_LR (1000)
```

```
prumery ← c(mean(uS), mean(uLR), mean(uW)) ... vektor 3 průměrů test. statistik (3)
```

```
if(plot == T) { graf se vykreslí, pokud argument plot == T. Jde o přípravu na část 2., kde chceme porovnat vektor průměrů i ale grafy nechceme.
```

```
plot(uW, type='n', ylim=c(0,1), xlim=c(0,4), ...) ... příprava prázdného grafu
```

```
mtext(...) popisek 'x'
```

```
mtext(paste('n =', n), ...) ... popisek n=5. Jednoduché popisky lze vložit rovnou i bez funkce expression() a bquote().
```

```
lines(density(uW, from=0), ...) ... křivka jádrového odhadu hustoty vypočítaného na základě M=1000 realizací U_W. Odhad konstruuje od 0 dále, protože U_W (stejně jako U_S a U_LR) nemůže být a definice napomáhá.
```

```
lines(...) křivka pro u_S
```

```
lines(...) křivka pro u_LR
```

```
legend(..., legend=c(expression(u_LR), expression(...), expression(u_S)), ...) ... legenda
```

```
} return(prumery)
```

Animace:

```
n ← c(2:10, 15, 20, ...) ... posloupnost našich náh. výběrů
```

```
... úvodní nastavení animace
```

```
saveLatex(for(...){
  porovnani(n=n[i])
}, ...)
```

```

2. m5 <- porovnavani (n=5, plot=F)  průměrné hodnoty M=1000 des. statistik Uw, Us a ULR (3), bodyporovnavy vyřívá n=5.
m10 <- -||- (3) -||- n=10
m100 <- -||- (3) -||- n=100
m1000 <- -||- (3) -||- n=1000

```

```

m <- cbind (m5, m10, m100, m1000)

```

```

m.uW <- m [1, ]  vektor prům. hodnot des. statistik uw pro n=5, n=10, n=100, n=1000. (4)

```

```

m.uS <- ... -||- us -||-
m.uLR <- ... -||- uLR -||-

```

```

plot(1:4, m.uW, type='o', ylim=c(min(m.uS)-0.1, max(m.uW)+0.1), pch=20, axes=F, ... )

```

vybrali body a spoji je čarami *rovná osy x y* *plní body* *vybrali měřítka os x a y*

```

box(...) □

```

```

axis(1, at=c(1,2,3,4), labels=c(5, 10, 100, 1000)) ... širší osa x. Čísel 1-4 převedeme popisky 5, 10, 100 a 1000

```

```

axis(2, las=1) ... měřítko os y y

```

```

lines(1:4, m.uS, type='o', pch=20, ... ) body průměrných hodnot Us pro n=5, n=10, n=100 a n=1000 spojené čarami

```

```

lines(...) -||- ULR -||-

```

```

legend(...) legenda; pořadí popisů v legendě rozdíme Uw, ULR a Us, které odpovídá umístění čar v grafu

```



Motivace:

$X \sim N(\mu, \sigma^2)$, σ^2 nemáme

$H_0: \mu = \mu_0$ $H_1: \mu \neq \mu_0$

>
<

Za platnosti H_0 : $T_W = \frac{\bar{x} - \mu_0}{s} \sqrt{n} \sim t_{n-1}$ Studentovo centrální t-rozdělení o n-1 stupních volnosti.

Pokud H_0 neplatí: $T_W = \frac{\bar{x} - \mu_0}{s} \sqrt{n} \sim t_{n-1, \lambda}$ Studentovo nacentrální t-rozdělení o n-1 stupních volnosti s parametrem nacentrality $\lambda = \frac{\mu - \mu_0}{\sigma} \sqrt{n}$.

Odvosení a nprvření viz následující příklad 5.6.

V tomto příkladu máme pouze ka ukol srovnání s δ tvarem nacentr. Studentova rozdělení a porovnat tento tvar (pro různé hodnoty parametru nacentrality λ) s tvarem centrálních a St. rozdělení.

$\lambda = \frac{\mu - \mu_0}{\sigma} \sqrt{n} = \frac{\delta}{\sigma} \sqrt{n}$ (delta = rozdíl mezi skutečnými hodnotami μ a μ_0)

$\Rightarrow \lambda = 0 \Rightarrow t_{n-1, \lambda} = t_{n-1, 0} = t_{n-1}$

$n = 26, \sigma^2 = 1.4^2, \delta = 0, \dots$ Pokud $\delta = 0 \Rightarrow$ rozdíl mezi μ a μ_0 je 0 $\Rightarrow \mu = \mu_0 \Rightarrow H_0$ platí (centrální St. t-rozdělení o n-1 st. volnosti (pouze když H_0 platí)).
 $\delta = 0.5, 0.8, 1, 1.2$

Připrava podkladů pro grafy

```
n <- ...
sigma <- ...
delta <- ... vektor 0, 0.5, 0.8, 1, 1.2
lambda <- (x_bar - mu_0) / sigma * sqrt(n)
barvy <- c('red', 'blue', 'darkgreen', 'violet', 'orange') ... vektor libovolných 5 barev
lwd <- c(2, 1, 1, 1, 1) vektor šířky čar (referenční křivka centrálního rozdělení bude mít šířku 2, ostatní šířky (tloušťky) 1)
```

Graf hustoty

```
plot(0, 0, xlim = c(-4, 9), ylim = c(0, 0.5), type = 'n', ...) ... příprava prázdného grafu
xfit <- seq(...) posl. od -5 do 10 sigma dělec minimálně 500.
for (i in 1:length(delta)) {
  yfit <- dt(xfit, n-1, ncp = lambda[i]) hustota cent. (resp. nacentr.) rozdělení mod. parametry xfit.
  lines(xfit, yfit, col = barvy[i], lwd = lwd[i]) vykreslení křivky hustoty
}
legend(..., legend = c(expression(paste(delta, ' = 0.0')),
                        expression(paste('-', ' = 0.05')),
                        -||- -||- -||- )) ... legenda
```

Graf distr. fce

```
plot(..., ylim = c(0, 1), ...)
for (...) {
  yfit <- pt(...)
  lines(...)
}
legend(...) (lty = 5)
abline(...) svízelá přešikovaná čára referenční čára v hodnotě kvantilu  $t_{n-1}(1 - \alpha/2)$ ,  $\alpha = 0.05$ . Čára by měla procházet křivkou distr. fce  $F(x)$  ve výšce 0.975 (97.5%). Z grafu tedy můžeme porovnat, jak moc nacentralita  $\lambda$  (porovnáte o rozdíl mezi  $\lambda$ ) ovlivňuje vzhled kvantilu a distr. funkce.
```

analogický jako u grafu hustoty

(a) Data pocházejí z $N(130, 30^2)$, ale my testujeme $H_0: \mu = 150$ oproti $H_1: \mu \neq 150$.

(Analogie reální situace, kde skutečnou hodnotu μ neznáme (může být klidně 146) a neznáme ani skutečnou hodnotu rozptylu σ^2 (může být např. 30^2), a přesto nějakou H_0 o μ (např. $H_0: \mu = 150$) testujeme)

Za platnosti H_0 : $T_W = \frac{\bar{x} - \mu_0}{s} \sqrt{n} \sim t_{n-1}$ $S = \sqrt{S^2}$, kde $S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$

\updownarrow des. slab. je silná \leftarrow rozdělení des. slab. se liší

Pokud H_0 neplatí: $T_W = T_{W,\lambda} = \frac{\bar{x} - \mu_0}{s} \sqrt{n} \sim t_{n-1,\lambda}$... (necentrální) Studentovo rozdělení s parametrem necentrality λ .

Zderivování:

$T_{W,\lambda} = \frac{Z_W + \lambda}{\sqrt{V/(n-1)}}$, kde $Z_W = \frac{\bar{x} - \mu}{\sigma} \sqrt{n} \sim N(0,1)$ $\lambda = \frac{\mu - \mu_0}{\sigma} \sqrt{n}$ $V = \frac{(n-1)S^2}{\sigma^2} \sim \chi^2_{n-1}$

statistika číslo číslo číslo číslo číslo statistika

číslo číslo číslo statistika

statistika konstanta číslo statistika

$T_{W,\lambda} = \frac{\frac{\bar{x} - \mu}{\sigma} \sqrt{n} + \frac{\mu - \mu_0}{\sigma} \sqrt{n}}{\sqrt{\frac{(n-1)S^2}{\sigma^2(n-1)}}} = \frac{\bar{x} - \mu + \mu - \mu_0}{\frac{S}{\sigma}} \sqrt{n} = \frac{\bar{x} - \mu_0}{\frac{S}{\sigma}} \sqrt{n} = \frac{\bar{x} - \mu_0}{s} \sqrt{n} = T_W \sim t_{n-1,\lambda}$

definice Studentova rozdělení

Věta: Nechtě $Z \sim N(0,1)$ a $V \sim \chi^2_n$, přičemž Z a V jsou nezávislé. Potom des. slab. $T_W = \frac{Z}{\sqrt{V/n}} \sim t_n$.

Věta: Nechtě $Z \sim N(0,1)$ a $V \sim \chi^2_n$, přičemž Z a V jsou nezávislé. Potom des. slab. $T_W = \frac{Z + \lambda}{\sqrt{V/n}} \sim t_{n,\lambda}$.

$H_0: \mu = \mu_0$ $H_1: \mu \neq \mu_0$
 $H_0: \mu = 150$ $H_1: \mu \neq 150$ (a) $\mu = 130, \sigma^2 = 30^2, n = 50$

rozdělení T_W

rozdělení $T_W \leftarrow$ function ($\mu_0, \mu_1, \sigma_0 = \dots, \sigma_1 = \dots, \sigma_2 = \sigma_1, M = \dots, n = \dots, p = 0.9, \text{main} = \dots, \text{pozice} = \dots$) {

$X \leftarrow$ matrix (NA, M, n) $\begin{matrix} \textcircled{X} & n \\ \hline & \\ \hline & \\ \hline & \\ \hline & \\ \hline & \end{matrix}$ $M = 2000$
 $n = 50$

for (...) { \implies viz příklad 4.2 a 4.1 $((\dots) \text{norm}(\text{sum}(\text{bin} = 1), \mu_0, \sigma_1))$
 $((\dots) \text{norm}(\text{sum}(\text{bin} = 0), \mu_1, \sigma_2))$ Opisť si kód pomocí nachytkování pro směr, která máš čekat (c) a (d)


$\bar{x} \dots m \leftarrow$ apply (...) vektor průměrů (2000)
 $s \dots S \leftarrow$ apply (...) vektor sm. odchylek (2000)
 $t_w \dots \frac{\bar{x} - \mu_0}{s} \sqrt{n}$ vektor des. slabistik t_w (2000)
 $\lambda \dots \frac{\mu_1 - \mu_0}{\sigma} \sqrt{n}$... parametry (parametr necentrality λ) ... číslo (délka = 1)

$xfit \leftarrow$ seq (...) min(t_w) - 6 až max(t_w) + 6
 $yfit \leftarrow$ dt (...) t_{n-1}
 $lfrit \leftarrow$ dt (... , df = n - 1, ncp = λ) $t_{n-1,\lambda}$

hist (t_w , breaks = 20, xlim = c(min(t_w) - 6, max(t_w) + 6), ylim = c(0, max(yfit) + 0.05), probs = T, density = ... , ...)

box (...)
mtext (expression (...), ...) $\leftarrow t_w$
mtext (bquote (...), ...) $\leftarrow n = 50, \mu_0 = 150$ (automaticky)
mtext (main, ...) $\leftarrow X \sim N(130, 900)$ (volitelný vstup funkce (main), nebo automaticky)

lines (...)
lines (...)
legend (pozice, fill = ..., bty = ..., legend = ..., ...)

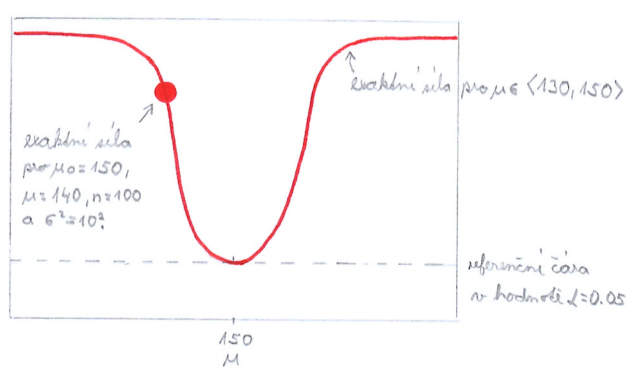
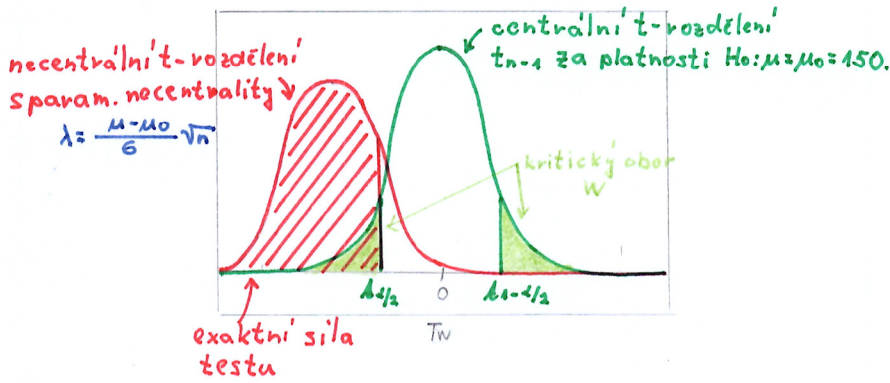


- T_W
- Jak by to mělo vypadat za platnosti H_0
- Jak to vypadá

(d) rozdělení T_W ($\mu = 170, \sigma^2 = 75, \text{main} = 'X \sim 0.9 N(170, 900) + 0.1 N(170, 56.25)', \text{pozice} = \dots$)

Copyright!

Výstupem tohoto příkladu je animace, ve které se s měřicí hodnotou μ mění rozdělení test. statistiky T_W a hodnota exaktní síly. Rozoberme si nejprve, co vidíme na jedné dvojici obrázků.



1. V druhém grafu je zobrazena exaktní síla testu σ μ při nurnáimém rozptylu σ^2 . Nejprve bych vytvořime funkci $\text{sila.exact.t}()$, která vraci pro zadane parametry $\mu, \mu_0, \sigma, n, \alpha$ a alternative hodnotu exaktní síly.

I. Odvození:

2. $H_{02}: \mu \leq \mu_0$ $H_{12}: \mu > \mu_0$ (pravoschanná alb.)

Krit. obor: $W = \langle k_{n-1}(1-\alpha); \infty \rangle$

$B_{12} = \Pr(H_0 \text{ namítáme} \mid H_0 \text{ neplatí}) \dots \Pr(\text{CHDD})$

$B_{12}^* = \Pr(H_0 \text{ namítáme} \mid H_0 \text{ neplatí}) \dots$ síla testu

$B_{12}^*(\mu, \sigma) = 1 - B_{12}(\mu, \sigma) = \Pr_{\mu, \sigma} \left(\frac{\bar{x} - \mu_0}{s} \sqrt{n} \geq k_{n-1}(1-\alpha) \right)$
 $= \Pr_{\mu, \sigma} (T_W \geq k_{n-1}(1-\alpha))$

Toto vyjádření mám tendenci nepomíjet. Výpočet síly je korekční náležitost, ve výpočtu mám vždy přibírá \bar{x} a s (statistický náhlet má máh. výberu, který při výpočtu síly nemáme). I když bychom \bar{x} "odstranili" analogickou funkcí jako v 4.6, pořád nistává s , pro které funkci nemáme. Vyúžijeme tedy toho, že máme rozdělení, které platí, když $X \in N(\mu, \sigma^2)$ a H_0 neplatí! $\Rightarrow (T_W \sim k_{n-1, \alpha})$.

Pod, že H_0 namítáme $\mid H_0$ neplatí,
 Oněm když H_0 neplatí,
 potom $T_W \sim k_{n-1, \alpha}$ (viz 5.5)

$= 1 - \Pr_{\mu, \sigma} (T_W \leq k_{n-1}(1-\alpha))$
 $= 1 - G_{n-1, \lambda}(k_{n-1}(1-\alpha))$
 (with $pt()$ and $qt()$ labels)

kde $G_{n-1, \lambda}(x)$ je distr. fce Studentova necentr. rozdělení $k_{n-1, \lambda}$ a $k_{n-1}(1-\alpha)$ je $(1-\alpha)$ -kvantil centrálního Studentova k -rozdělení k_{n-1} .

3. $H_{03}: \mu \geq \mu_0$ $H_{13}: \mu < \mu_0$ (levosch. alb.)

Krit. obor: $W = (-\infty; k_{n-1}(\alpha))$

$B_{13}^* = \Pr(H_0 \text{ namítáme} \mid H_0 \text{ neplatí}) \dots$ síla testu

$B_{13}^*(\mu, \sigma) = 1 - B_{13}(\mu, \sigma) = \Pr(T_W \in W)$
 $= \Pr_{\mu, \sigma} \left(\frac{\bar{x} - \mu_0}{s} \sqrt{n} \leq k_{n-1}(\alpha) \right)$
 $= \Pr_{\mu, \sigma} (T_W \leq k_{n-1}(\alpha)) \dots$ Pod, že H_0 namítáme $\mid H_0$ neplatí.

Oněm když H_0 neplatí, potom $T_W \sim k_{n-1, \lambda} \Rightarrow$

$\Rightarrow G_{n-1, \lambda}(k_{n-1}(\alpha))$
 (with $pt()$ and $qt()$ labels)

kde $G_{n-1, \lambda}(x)$ je distr. fce Studentova necentr. k -rozdělení $k_{n-1, \lambda}$ a $k_{n-1}(\alpha)$ je α -kvantil centrálního Studentova k -rozdělení k_{n-1} .

1. $H_{01}: \mu = \mu_0$ $H_{11}: \mu \neq \mu_0$ (obousch. alb.)

Krit. obor: $W = (-\infty; k_{n-1}(\alpha/2)) \cup \langle k_{n-1}(1-\alpha/2); \infty \rangle$

$B_{11}^* = \Pr(H_0 \text{ namítáme} \mid H_0 \text{ neplatí}) \dots$ síla testu

$B_{11}^*(\mu, \sigma) = 1 - B_{11}(\mu, \sigma) = \Pr(T_W \in W)$
 $= \Pr_{\mu, \sigma} (T_W \leq k_{n-1}(\alpha/2)) + \Pr_{\mu, \sigma} (T_W \geq k_{n-1}(1-\alpha/2))$

$$= \Pr_{\mu, \epsilon} (T_w \leq t_{n-1}(\alpha/2)) + 1 - \Pr_{\mu, \epsilon} (T_w \leq t_{n-1}(1-\alpha/2)) \dots \text{Pat. je Horomilani, ... 9}$$

Pokud Horomilani, pak $T_w \sim t_{n-1, \lambda} \Rightarrow$

$$= G_{n-1, \lambda}(t_{n-1}(\alpha/2)) + 1 - G_{n-1, \lambda}(t_{n-1}(1-\alpha/2))$$

kde $G_{n-1, \lambda}(x)$ je distrib. fce necentrálního Studentova rozdělení $t_{n-1, \lambda}$ a $t_{n-1}(\alpha/2)$ (resp. $t_{n-1}(1-\alpha/2)$) je $\alpha/2$ (resp. $1-\alpha/2$)-kvantil centrálního Studentova t -rozdělení t_{n-1} .

II. Funkce `sila.exact.t()`:

`sila.exact.t` ← function(μ , μ_0 , σ , n , α = ... , alternative = ...) {

$\lambda \leftarrow \frac{\mu - \mu_0}{\epsilon} \sqrt{n}$

if(alternative == 'two.sided') { $\text{sila} \leftarrow G_{n-1, \lambda}(t_{n-1}(\alpha/2)) + 1 - G_{n-1, \lambda}(t_{n-1}(1-\alpha/2))$ }

if(== 'greater') { $\text{sila} \leftarrow 1 - G_{n-1, \lambda}(t_{n-1}(1-\alpha))$ }

if(== 'less') { $\text{sila} \leftarrow G_{n-1, \lambda}(t_{n-1}(\alpha))$ }

\downarrow $p_t(\dots, n-1, ncp=\lambda)$ \rightarrow $q_t(\alpha, n-1)$

return(sila)

}

2. Vytvoříme funkci `sila.animace.t()`, která vykreslí 1 dvojici grafů:

`sila.animace.t` ← function(μ , μ_0 , σ , n , α = 0.05) {

$\mu_0 \leftarrow 150$; $\mu \leftarrow 140$; $\sigma \leftarrow 10$; $n \leftarrow 100$; $\alpha \leftarrow 0.05$

Funkce `sila.animace.t()` je analogická funkci `sila.animace()` z příkladu 4.6. Tato funkce tedy může posloužit jako náhled. Modifikací několika málo řádků získáte velmi rychle funkci `sila.animace.t()`. Aby bylo vidět, že kódu z příkladu 4.6 dobře rozumíte, případně se v jednotlivých příkazech ubránili, doporučuji vám upravit si modifikaci bez kontrolní ma následující řádky a ty posloužit jako kontrolu v případě, že se modifikace nepovede. Protože řešení příkladu 5.7 je oproti analogické, uvádím tu pouze seznam modifikovaných řádků (pro vaši kontrolu).

(...)

$y \leftarrow dt(\dots)$ hustota t_{n-1} mod. μ_0, x

$k \leftarrow dt(\dots)$ hustota $t_{n-1, \lambda}$ mod. μ, x

(...)
`mtext(expression(...), ...)` popis t_w

(...)
 $q_1 \leftarrow qt(\dots)$... kvantil $t_{n-1}(\alpha/2)$

$q_2 \leftarrow qt(\dots)$... kvantil $t_{n-1}(1-\alpha/2)$

// V příkazech `polygon` změňte a korat barvy (v materiálech jsou použity "darkgreen" a "coral", ale můžete použít libovolné)

(...)

$\text{sila.ex} \leftarrow \text{sila.exact.t}(\mu = \mu_1, \mu_0 = \mu_0, \sigma = \dots, n = \dots)$ vektor reálných sil (délka = 500)

(...)

$\text{sila.akt} \leftarrow \text{sila.exact.t}(\mu = \mu, \mu_0 = \mu_0, \dots)$

) ... hodnota reálné síly pro 1 konkrétní μ (např. $\mu = 140$) (délka = 1)

3. Vytvoříme animaci (analogicky jako v 4.6):

(...)

`saveLatex(for(...)) {`

`sila.animace.t(mu = mu[i], ...)`

}

V rámci tohoto příkladu si vykoušíme aplikaci testovacích statistik T_w, U_w, U_s a U_{LR} testu o μ když σ^2 neznáme na reálná data. Nejprve ověříme (graficky i testem) předpoklad normality, jehož splnění je nutné pro použití parametrického testu. Následně deskyjme nulovou hypotézu H_0 , a to všemi třemi způsoby (kritickým oborem, IS i p-hodnotou) pro každou test. statistiku T_w, U_w, U_s i U_{LR} . Nezapomeneme vždy uvést odůvodněný závěr o H_0 a interpretaci závěru testování.

Nakonec vykreslíme hranice a oblasti Waldova, které a rozhodnutího 95% empirického IS.

Příprava dat

```
data <- read.delim('navez_souboru.txt', sep='\t', dec='.') ... načtení dat
skull.F <- data[data$sex == 'f', 'skull.H'] ... z datové tabulky vybereme pouze údaje o basion-broqm, nejvíce
skull.F <- na.omit(skull.F) ... odstranění NA hodnot
```

Test normality ověříme Lillieforsovým testem ($n > 30$) a dvojicí grafů histogram + Q-Q diagram. K vykreslení histogramu potřebujeme stanovit správný počet i hranice třídících intervalů:

Sturgesovo pravidlo: $r = 3.3 + \log_{10}(n) + 1 = 3.3 + \log_{10}(107) + 1 \approx 8 \dots 8$ třídících intervalů

Hodnoty jsou v rozsahu 117 - 136 $\rightarrow 136 - 117 = 19 \xrightarrow{+5} 24 \dots 24 : 8 = 3 \dots$ šířka jednoho třídícího intervalu bude 3.

$\Rightarrow 117 - 136$
 $\swarrow -3 \quad \searrow +2$
 114 - 138
 $\xrightarrow{\text{rozdělenost 24}}$
 $\Rightarrow b \leftarrow \text{seq}(114, 138, by=3)$

Test normality
Histogram
Q-Q graf + test.

```
b <- seq(114, 138, by=3) ... vektor hranic třídících intervalů
hist(skull.F, breaks=b, prob=..., ...) ... histogram n/n
box(...) □
x <- seq(...) pol. od 110 do 145 o délce min 500
y <- dnorm(...) hustota norm. rozdělení s  $\hat{\mu} = \bar{x}$  a  $\hat{\sigma} = S$  (z dat skull.F)
lines(...) ...
qqnorm(skull.F, pch=21, ...)
qqline(skull.F, ...)
mtext(...) popis 'teoretický kvantil'
mtext(paste('Lillie ... =', round(nortest::lillie.test(skull.F)$p.val, 4)), ...) ... popis p-hodnotu na 4 des. místa
```

Do komentářů uveďte kompletní test normality:

- # H_0 :
- # H_1 :
- # Protože p...d, H_0 zamítáme / nezamítáme na hladině významnosti $\alpha = 0.05$.
- # Interpretace: Data pochází / nepochází z normálního rozdělení.

Test o μ , když σ^2 neznáme.

Do komentářů uveďte znění H_0 a H_1 :

- # H_0 :
- # H_1 :

va hodnot

```
mu0 <- ...  $\mu_0$ 
m <- ...  $\bar{x}$ 
s <- ... S
n <- ... n
```

Případy: $\alpha \leftarrow \dots$
Testování kritickým oborem:

$tW \leftarrow \dots t_w$
 $uW \leftarrow \dots u_w$
 $uS \leftarrow \dots u_s$
 $uLR \leftarrow \dots u_{LR}$

Hranice krit. ob. Testovací stat.
 $q1 \leftarrow \dots t_{n-1}(\alpha/2)$
 $q2 \leftarrow \dots t_{n-1}(1-\alpha/2)$
 $q \leftarrow \dots \chi^2_{\alpha}(1-\alpha)$

Pro každý test uveďte zdůvodněný závěr o H_0 : apod.


Protože $tW = \dots$ náleží / nenáleží do krit. oboru $W = (-\infty; \dots) \cup (\dots; \infty)$, H_0 zamítáme / nezamítáme na hl. významnosti $\alpha = \dots$. (analogicky pro uW, uS a uLR)

Testování IS:

$dhW \leftarrow \bar{x} - t_{n-1}(1-\alpha/2) \frac{s}{\sqrt{n}}$ dolní hranice Waldova 95% empirického IS (náčteného na test. stat. tW)
 $hhW \leftarrow \bar{x} - t_{n-1}(\alpha/2) \frac{s}{\sqrt{n}}$ horní hranice -||-
čím více bodů, tím přesnější hranice IS.

$\mu_{i.1} \leftarrow seq(\dots)$ posl. μ od 120 do 130 s min. délkou 2000... μ_i
 $tW_{i.1} \leftarrow (m - \mu_{i.1}) / s * \sqrt{n}$ vektor $tW_{i.1} := \frac{\bar{x} - \mu_i}{s} \sqrt{n}$, kde za μ_i dosazujeme rovnáči μ z vektoru $\mu_{i.1}$ (délka = 2000)

$uW_{i.1} \leftarrow \dots$ vektor 2000 test. statistik $uW_{i.1}$ pro posl. μ_i ($\mu_{i.1}$)
 $dh.uW \leftarrow round(\min(\mu_{i.1}[uW_{i.1} < q]), 4)$ dolní hr. Waldova 95% emp. IS (mícháři z uW)
 $hh.uW \leftarrow round(\max(\mu_{i.1}[uW_{i.1} < q]), 4)$ horní hranice -||-



$uS_{i.1} \leftarrow \dots$ vektor 2000 test. statistik $uS_{i.1}$ pro posl. μ_i ($\mu_{i.1}$)
 $dh.uS \leftarrow \dots$ analogicky jako u $dh.uW$ dolní hr. stejné 95% emp. IS (mícháři z uS)
 $hh.uS \leftarrow \dots$ analogicky jako u $hh.uW$ horní hr. -||-

$uLR_{i.1} \leftarrow \dots$ vektor 2000 test. statistik $uLR_{i.1}$ pro posl. μ_i ($\mu_{i.1}$)
 $dh.uLR \leftarrow \dots$ analogicky jako u $dh.uW$ dolní hr. náhodného 95% IS (mícháři z uLR)
 $hh.uLR \leftarrow \dots$ analogicky jako u $hh.uW$ horní hr. -||-

Pro každý test uveďte zdůvodněný závěr o H_0 :

Protože ... náleží / nenáleží do IS = (...; ...), H_0 zamítáme / nezamítáme na hl. význ. $\alpha = \dots$.

Testování p-hodnotou:

$pW \leftarrow 2 * \min(p_t(tW, n-1), 1 - p_t(tW, n-1))$
 $p.uW \leftarrow 1 - pchisq(uW, 1)$
 $p.uS \leftarrow \dots$
 $p.uLR \leftarrow \dots$

Pro každý test uveďte zdůvodněný závěr o H_0 :

Protože p-hodnota = ... < / > alpha, H_0 zamítáme / nezamítáme na hl. význ. $\alpha = \dots$.

Interpretace výsledků testování: Uveďte antropologický závěr (interpretaci výsledků testování). Co jsme se dozvěděli o basion - kurganické výšce lebky rím?

$tab \leftarrow data.frame(m = rep(m, 4),$ vektor průměrů m
 $stat = c(tW, uW, uS, uLR),$ vektor test. statistik
 $wh = c(q1, NA, NA, NA),$ W_{hh}
 $wl = c(q2, q1, q1, q1),$ W_{lh}
 $dh = \dots$ I_{Sh}
 $hh = \dots$ I_{Sh}

ulka výsledků

p = ...
row.names = c('tW', 'uW', 'uS', 'uLR'))

Tab
Grafy s intervaly spolehlivosti (uW, uS, uLR)

plot(mu.i, uW.i, ylim = c(0, 20), ylab = bquote(U[W]), ...) křivka U
lines(mu.i[uW.i < q], uW.i[uW.i < q], ...) ... červení (col = 'red') výpočtená oblast uW v IS. U
abline(h = q, ...) vodorovná čára přerušovaná referenční čára v hodnotě kvantilu $\chi^2_{1-\alpha}$ ----
mtext(expression()) popisek μ
mtext(bquote(paste('IS = (', .(dh.uW), ', ', .(hh.uW), ')')), ...) ... popisek IS = (... , ...)

plot(mu.i, uS.i, ...) U
lines(mu.i[uS.i < q], uS.i[uS.i < q], ...) ... U
abline(...) ----
mtext(...) popisek μ
mtext(...) popisek IS = (... , ...)

plot(mu.i, uLR.i, ...) U
lines(...) ... U
abline(...) ----
mtext(...) popisek μ
mtext(...) popisek IS = (... , ...)