

Náhodný výběr  $X_1$  pochází z  $N(4, 2^2)$ , měřodný výběr  $X_2$  pochází z  $N(2.5, 1^2)$ . Rozdíl  $\mu_1 - \mu_2 = 4 - 2.5 = 1.5$ . My ale testujeme  $H_0: \mu_1 - \mu_2 = \mu_0 = 0$  oproti  $H_1: \mu_1 - \mu_2 \neq 0$ . (Analogně reálné situace, kde s kružnicí hodnoty  $\mu_1$  a  $\mu_2$  měříme (motor byl kladně navení) a měříme ani skutečné hodnoty rozptylu  $s_1^2$  a  $s_2^2$  (které jsou ale málošti v tomto případě stejné) a chceme testovat  $H_0$  o rovnosti středních hodnot, tj.  $H_0: \mu_1 - \mu_2 = 0$ .

$$\text{Za platnosti } H_0: T_W = \frac{\bar{X}_1 - \bar{X}_2 - \mu_0}{S_D} \sim t_{n_1+n_2-2}$$

$\uparrow$  jed. statist. je stejná       $\uparrow$  rozdělení stejné       $\downarrow$  soub. se liší

$$S_D^2 = \frac{n_1 + n_2}{n_1 n_2} S^2$$

$$S_1^2 = \frac{1}{n_1-1} \sum_{i=1}^{n_1} (X_{1i} - \bar{X}_1)^2$$

$$S_2^2 = \frac{1}{n_2-1} \sum_{i=1}^{n_2} (X_{2i} - \bar{X}_2)^2$$

$$\text{mecenability } \lambda = \frac{\delta}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \quad \delta = \mu_1 - \mu_2 - \mu_0$$

$$\text{Potud } H_0 \text{ neplatí: } T_W = \frac{\bar{X}_1 - \bar{X}_2 - \mu_0}{S_D} \sim t_{n_1+n_2-2, 1} \dots \text{(necentrální)}$$

$$\text{Studentovo rozdělení s parametry mecenality } \lambda = \frac{\delta}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \quad \delta = \mu_1 - \mu_2 - \mu_0$$

$$H_0: \mu_1 - \mu_2 = \mu_0 \quad H_1: \mu_1 - \mu_2 \neq \mu_0$$

$$H_0: \mu_1 - \mu_2 = 0 \quad H_1: \mu_1 - \mu_2 \neq 0$$

1. Vyberieme funkci **rozdeleniTw2()**, která pro zadovanou sadu parametrů vrátí jeden graf s histogramem  $M=2000$  test. statistik  $T_W$ , kružni hustoty  $t_{n_1+n_2-2}$  a kružni hustoty  $t_{n_1+n_2-2, 1}$ . Funkci naprogramujeme tak, aby vykreslovala společně graf v situaci, kdy  $X_1$  a  $X_2$  jsou náhodné výběry pocházející ze směsi s různými parametry rozptylu i středních hodnot, tj. rozdílní parametry budou:

$\mu_0, \mu_1, \mu_2, \sigma_{11}, \sigma_{12}, p_1, \mu_1 - \mu_2, \sigma_{21}, \sigma_{22}, p_2, n_1, n_2, M$ , až d.

**rozdeleniTw2 <- function(mu0, mu1 = ..., mu12 = mu1, sigma11 = ..., sigma12 = sigma11, p1 = 0.8, mu2 = ..., mu22 = mu2, sigma21 = ..., sigma22 = sigma21, p2 = 0.8, n1 = 50, n2 = 50, M = ..., alpha = ...){**

**X1 <- matrix(NA, M, n1)** ... příprava prázdné matice pro  $M=2000$  náhodných výběrů  $X_1$   
**X2 <- matrix(...)** ... příprava prázdné matice pro  $M=2000$  měř. výběrů  $X_2$

**for(i in 1:M){**

**bin1 <- rbinom(n1, 1, p1)**



**bin2 <- ...**

**X1[i, ][bin1 == 1] <- rnorm(sum(bin1 == 1), mu1, sigma11)**

**X1[i, ][bin1 == 0] <- rnorm(sum(bin1 == 0), mu12, sigma12)**

**X2[i, ][bin2 == 1] <- ...**

**X2[i, ][bin2 == 0] <- ...**



**m1 <- apply(X1, 1, mean)** ... vektor  $M=2000$  měř. průměrů  $\bar{X}_1$  z  $M=2000$  měř. výběrů  $X_1$  (délka = 2000)  
**m2 <- apply(...)** ... vektor  $M=2000$  měř. průměrů  $\bar{X}_2$  z  $M=2000$  měř. výběrů  $X_2$  (2000)

**s1 <- apply(...)** ... vektor  $M=2000$  měř. sm. odchylek z  $M=2000$  měř. výběrů  $X_1$  (2000)

**s2 <- apply(...)** ... vektor  $M=2000$  měř. sm. odchylek z  $M=2000$  měř. výběrů  $X_2$  (2000)

**s <- sqrt((n1-1)s1^2 + (n2-1)s2^2) / (n1+n2-2)** ... vektor  $M=2000$   $S$  (délka = 2000)

**S0 <- sqrt((n1+n2-2)/n1\*n2) \* s** ... vektor  $M=2000$   $S_D$  (délka = 2000)

**df <- n1 + n2 - 1** ... počet stupňů volnosti (číslo, délka = 1)

**tW <- (bar{X}\_1 - bar{X}\_2 - mu\_0) / S\_D** ... vektor  $M=2000$  test. statistik  $T_W$  (2000)

**p <- 2\*apply(chbind(pt(abs(tW), df), 1-pt(abs(tW), df)), 1, min)** ... vektor  $M=2000$  p-hodnot (2000)

**sila.emp <- sum(p < alpha) / M** ... empirická síla (počet namířených  $H_0$  díleno počtem simulací  $M$ )

Příprava podkladů	<p><math>\delta \leftarrow \mu_1 - \mu_2 - \mu_0</math> ... minimální dlebozadlná vzdálenost <math>\delta</math> (číslo, délka=1)</p> <p><math>\lambda \leftarrow \frac{\delta}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}</math> ... parametr recentality <math>\lambda</math> (číslo, délka=1)</p>
Vykreslení grafů	<p><math>x_{fit} \leftarrow seq(\dots)</math> ... posloupnost od -10 do 10 o délce minimálně 1000</p> <p><math>y_{fit} \leftarrow dt(\dots)</math> ... hodnoty hustoty rozdělení <math>\lambda n_1 + n_2 - 2</math> nad pol. <math>x_{fit}</math></p> <p><math>z_{fit} \leftarrow dt(\dots)</math> ... hodnoty hustoty rozdělení <math>\lambda n_1 + n_2 - 2</math> nad pol. <math>x_{fit}</math></p>
	<p><math>par(\dots)</math> <math>\square \square</math></p> <p><math>hist(tW, \dots, xlim=c(-10,10), ylim=c(0,0.5), axes=F, \dots)</math> ... histogram test. statistiky <math>T_W</math></p> <p><math>box(\dots) \square</math></p> <p><math>axis(1, seq(-10,10, by=2))</math> ... osa x bude mít 5 násobků od -10 do 10 po každou 2</p> <p><math>axis(2, \dots)</math> ... osa y</p> <p><math>mtext(expression(\dots), \dots, line=2.2)</math> ... popisek 'tw'</p> <p><math>mtext(bquote(paste(mu[1] - mu[2] == .(mu1 - mu2), \dots), \dots, line=3.3))</math> ... automaticky se měníci popisek <math>n = \dots</math>, <math>\mu_1 - \mu_2 = \dots</math></p> <p><math>mtext(bquote(paste(. . . == .(round(sila, 6))), \dots, line=4.7))</math> ... automaticky se měníci popisek <math>1 - \beta_{11} = \dots</math></p>
	<p><math>lines(x_{fit}, y_{fit}, \dots)</math> ... krivka hustoty centrálního sl. rozdělení <math>\lambda n_1 + n_2 - 2</math> <math>\curvearrowright</math></p> <p><math>lines(\dots)</math> ... krivka hustoty necentrálního sl. rozdělení <math>\lambda n_1 + n_2 - 2, \lambda</math> <math>\curvearrowright</math></p> <p><math>legend(\dots)</math> ... legenda</p>
	<p>2. Vykreslime animaci, která v rozdílosti mezi měnicí se vzdáleností <math>\mu_1 - \mu_2</math> (při pevném <math>\mu_1</math> a měnícím se <math>\mu_2</math>) ukáže změnu ve pozici histogramu test. statistiky <math>T_W</math> a krivky hustoty <math>\lambda n_1 + n_2 - 2, \lambda</math> vzhledem ke krivce hustoty <math>\lambda n_1 + n_2 - 2</math>, a to pro (a) <math>X_1 \sim N(4, 2^2)</math>, <math>X_2 \sim N(2.5, 2^2)</math>, <math>n_1 = n_2 = 50</math> ;      (b) <math>X_1 \sim pN(4, 2^2) + (1-p)N(4, 6^2)</math>, <math>p = 0.9</math> , <math>X_2 \sim N(2.5, 2^2)</math>, <math>n_1 = n_2 = 50</math>.</p> <p><math>\mu_2 \leftarrow seq(\dots)</math> ... pol. od 6 do 2 po každou -0.5 (<math>by = -0.5</math>)</p> <p><math>for(\dots) \{</math></p> <p style="padding-left: 20px;"><math>par(\dots) \square \square</math></p> <p style="padding-left: 20px;"><math>rozdeleniTw2(mu0=0, mu1=4, mu2=mu2[i], \dots)</math> ... graf pro (a)</p> <p style="padding-left: 20px;"><math>rozdeleniTw2(mu0=0, mu1=4, mu2=mu2[i], sigma12=6, \dots)</math> ... graf pro (b; oměa)</p>

V tomto příkladě máme porovnat půl pokrytí čtyř typů DIS pro různé  $\mu_1, \mu_2$ , dvou měřitelných náhýří  $X_1$  a  $X_2$ . Aktuální půl pokrytí 1-2 počítáme jako počet situací, kdy  $H_0$  nerazíláme k aktuálnímu počtu simulací  $M=2000$ . Rovnou můžeme srovnat rozložení kritického oboru. Tenbo postup je vzhodný pro následující 4 typy DIS. K vypočítání půl pokrytí mám sedy skácí známkou historických stabilistik a jejich rozdělení.

(1) Klasický dvouzářivý  $t$ -test:

$$T_W = \frac{\bar{X}_1 - \bar{X}_2 - \mu_0}{S_D} \stackrel{H_0}{\sim} t_{df}, \quad df = n_1 + n_2 - 2, \quad S_D^2 = \frac{n_1 + n_2}{n_1 n_2} S^2$$

$$S^2 = \frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1 + n_2 - 2}$$

(2) Dvouzářivý  $t$ -test s Welchovou approximací stupňů volnosti:

$$T_W = \frac{\bar{X}_1 - \bar{X}_2 - \mu_0}{S_D} \stackrel{H_0}{\sim} t_{df}, \quad df = \frac{\left(\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}\right)^2}{\frac{\left(\frac{S_1^2}{n_1}\right)^2}{n_1-1} + \frac{\left(\frac{S_2^2}{n_2}\right)^2}{n_2-1}}, \quad S_D^2 = \frac{S_1^2}{n_1} - \frac{S_2^2}{n_2}$$

$$S_1^2 = \frac{1}{n_1-1} \sum_{i=1}^{n_1} (X_{1i} - \bar{X}_1)^2$$

$$S_2^2 = \frac{1}{n_2-1} \sum_{i=1}^{n_2} (X_{2i} - \bar{X}_2)^2$$

(3) Věrohodnostní test na předp. že  $\sigma_1^2$  a  $\sigma_2^2$  jsou nerazílé a shodné:

$$U_{LR} = n \ln \left( 1 + \frac{T_W^2}{n-2} \right) \stackrel{H_0}{\sim} \chi_1^2, \quad n = n_1 + n_2$$

(4) Věrohodnostní test na předp. že  $\sigma_1^2$  a  $\sigma_2^2$  jsou nerazílé a různé:

$$U_{LR} = 2 \cdot \underbrace{\frac{n_1 n_2 (\bar{X}_2 - \bar{X}_1)^2}{2(n_1 + \gamma n_2)^2} \left( \frac{\gamma^2 n_2}{\hat{\sigma}_1^2} + \frac{n_1}{\hat{\sigma}_2^2} \right)}_{-\ln(\lambda(x_1, x_2))} \stackrel{H_0}{\sim} \chi_1^2, \quad \gamma = \frac{\hat{\sigma}_1^2}{\hat{\sigma}_2^2}$$

$$\hat{\sigma}_1^2 = \frac{1}{n_1} \sum_{i=1}^{n_1} (X_{1i} - \bar{X}_1)^2$$

$$\hat{\sigma}_2^2 = \frac{1}{n_2} \sum_{i=1}^{n_2} (X_{2i} - \bar{X}_2)^2$$

$$\begin{aligned} \text{Aktuální půl. pokrytí } 1-2 &= \frac{\sum_{m=1}^M I(|t_{W,m}| < t_{df})}{M} \quad \text{pro (1), (2)} \\ &= \frac{\sum_{m=1}^M I(U_{LR,m} < \chi_1^2)}{M} \quad \text{pro (3), (4)} \end{aligned}$$

1. Vyholovíme funkci Pokryti2Vybbery(), která pro zadání hodnoty parametrů vrací vektor čtyř půl pokrytí (1prst x 4situace). Funkci si rovnou připravíme tak, aby uměla spočítat půl pokrytí i za předpokladu, že  $X_1$ , resp.  $X_2$  budou pocházeny ze smlíčeného rozdělení. Vstupními parametry bude budou  $\mu_0, \mu_1, \mu_2, \sigma_{11}, \sigma_{12}, \sigma_{21}, \sigma_{22}, p_1, p_2, n_1, n_2, M$  a  $\alpha$ .

```
Pokryti2Vybbery <- function(mu0, mu1=.2, mu2=mu1, sigma11=.9, sigma12=sigma11,
                                sigma21=..., sigma22=sigma21, p1=..., p2=..., n1=..., n2=n1,
                                M=..., alpha=...){
```

```
X1 <- matrix(...) ... připrava prázdné matice pro M=2000 měřitelných náhýří X1
X2 <- matrix(...) ... -||- -||- -||- X2
```

```
for(i in 1:M){
  bin1 <- rbinom(n1, 1, p1)
  bin2 <= ...
```

$X1[i,][\text{bin1} == 1] \leftarrow \text{rnorm}(\text{sum}(\text{bin} == 1), \mu_1, \sigma_1)$   
 $X1[i,][\text{bin1} == 0] \leftarrow \dots \quad \text{--||--} \quad \mu_1, \sigma_1$   
 $X2[i,][\text{bin2} == 1] \leftarrow \dots \quad \Rightarrow \quad \begin{matrix} X_2 \\ \Sigma \end{matrix} \begin{matrix} n_2 \\ \Sigma \end{matrix}$   
 $X2[i,][\text{bin2} == 0] \leftarrow \dots$   
}

$m1 \leftarrow \text{apply}(\dots) \dots$  vektor  $M=2000$  r.v. průměrů  $\bar{X}_1$  z  $M=2000$  měr. r.v.  $X_1$  (délka = 2000)

$m2 \leftarrow \text{apply}(\dots) \dots \quad \text{--||--} \quad \bar{X}_2 \quad \text{--||--} \quad X_2 \quad (2000)$

$S1 \leftarrow \text{apply}(\dots) \dots \quad \text{--||--} \quad \text{r.v. s.m. odchylek } S_1^2 \quad \text{--||--} \quad X_1 \quad (2000)$

$S2 \leftarrow \text{apply}(\dots) \dots \quad \text{--||--} \quad \text{--||--} \quad S_2^2 \quad \text{--||--} \quad X_2 \quad (2000)$

$S \leftarrow \sqrt{\frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2}} \dots$  vektor  $S$  (délka = 2000)

$S_D \leftarrow \sqrt{\frac{n_1+n_2}{n_1n_2} S^2} \dots$  vektor  $S_D$  pro klasický dvouzároveň  $t$ -test (2000)

$tW.Wald \leftarrow \frac{\bar{X}_1 - \bar{X}_2 - M_0}{S_D} \dots$  vektor test. statistik  $tW$  (2000)

$df.Wald \leftarrow n_1 + n_2 - 2 \dots$  počet stupňů volnosti (číslo; délka = 1)

$pokryti.Wald \leftarrow \frac{\sum(|tW| < d_{df, 1-\alpha/2})}{M} \dots$  aktuální počet pokrytí (číslo; délka = 1)

$S_D \leftarrow \sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}} \dots$  vektor  $S_D$  pro dvouzároveň  $t$ -test s Welchovou approximací ( $S_1^2 \neq S_2^2$ ) ; (2000)

$tW.Welch \leftarrow \frac{\bar{X}_1 - \bar{X}_2 - M_0}{S_D} \dots$  vektor test. statistik  $tW$  (2000)

$df.Welch \leftarrow \frac{\left(\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}\right)^2}{\frac{(S_1^2)^2}{n_1-1} + \frac{(S_2^2)^2}{n_2-1}} \dots$  vektor Welchových approximací počtu stupňů volnosti (délka 2000)

$pokryti.Welch \leftarrow \frac{\sum(|tW| < d_{df, 1-\alpha/2})}{M} \dots$  aktuální počet pokrytí (číslo; délka = 1)

$n \leftarrow n_1 + n_2 \dots$  celkový počet měr počítaných (délka = 1)

$ULR.SR \leftarrow n \cdot \ln\left(1 + \frac{T_W^2}{n-2}\right) \dots$  vektor test. statistik  $ULR$  (2000); SR = shodné rozpisy

$pokryti.ulr.SR \leftarrow \frac{\sum(ULR < \chi_{df, 1-\alpha}^2)}{M} \dots$  aktuální počet pokrytí (číslo; délka = 1)

$S1 \leftarrow \sqrt{\frac{(n_1-1)}{n_1} S_1^2} \dots$  vektor  $\sqrt{\hat{\sigma}_1^2}$ , kde  $\hat{\sigma}_1^2 = \frac{1}{n_1} \sum_{i=1}^{n_1} (X_{1i} - \bar{X}_1)^2 = \frac{n_1-1}{n_1} \cdot \frac{1}{n_1-1} \sum_{i=1}^{n_1} (X_{1i} - \bar{X}_1)^2 = \frac{n_1-1}{n_1} \cdot S_1^2$  (délka = 2000)

$S2 \leftarrow \sqrt{\frac{(n_2-1)}{n_2} S_2^2} \dots$  vektor  $\sqrt{\hat{\sigma}_2^2}$  (2000)

$g \leftarrow \frac{\hat{\sigma}_1^2}{\hat{\sigma}_2^2} \dots$  vektor  $g$  (2000)

$ULR.RR \leftarrow 2 \cdot \frac{n_1 n_2 (\bar{X}_2 - \bar{X}_1)^2}{2(n_1 + g n_2)^2} \left( \frac{g^2 n_2}{\hat{\sigma}_1^2} + \frac{n_1}{\hat{\sigma}_2^2} \right) \dots$  vektor test. statistik  $ULR$  (2000); RR = různé rozpisy

$pokryti.ulr.RR \leftarrow \frac{\sum(ULR < \chi_{df, 1-\alpha}^2)}{M} \dots$  aktuální počet pokrytí (číslo; délka = 1)

$\text{return}(c(pokryti.Wald, pokryti.Welch, pokryti.ulr.SR, pokryti.ulr.RR))$

}

2. Pomocí funkce `Pokryti2Vybery()` vypočítáme počet pokrytí pro různé parametry (a) - (d) a pro různé měr. r.v. (i) - (iii) a vyrobíme finální soubornou tabulkou výsledků.

`b.a5 <- Pokryti2Vybery(mu0=0, sigma21=q, n1=5)`

`b.a50 <- Pokryti2Vybery(mu0=0, sigma21=q, n1=50)`

`b.a100 <- Pokryti2Vybery(mu0=0, sigma21=q, n1=100)`

p.d100  $\leftarrow$  Pokryti2Vybery(mu0=0, sigma21=12, sigma12=18, sigma22=22, n1=100)

pst.pokryti  $\leftarrow$  rbind(p.a5, p.a50, p.a100,  
p.b5, p.b50, p.b100,  
p.c5, p.c50, p.c100,  
p.d5, p.d50, p.d100) ... tabulka psí pokrytí ( $12 \times 4$ )


tab  $\leftarrow$  data.frame(mu1 = rep(20,12),  
mu2 = -11-,  
Sigma11 = ...,  
Sigma12 = ...,  
sigma21 = c(rep(NA,6), rep(18,6)),  
Sigma22 = ...  
n1 = rep(c(5,50,100), 4),  
n2 = -11-

pst.pokryti ... finalní souhrnná tabulka výsledních psí pokrytí typy DIS(1)-(4)  
při různých sadačích parametrů (a)-(d) pro rozsahy měř. výberu  
(i)-(iii).

3. Vyberoume funkci PokrytiPlot(), jejímž následem bude matice psí pokrytí X a následem bude spojiby diagram.

matice psí pokrytí pro 1 sadu (např. (a))  
 $\downarrow$   $\rightarrow$  defaultní pozice legendy

PokrytiPlot(X, position = 'bottomright') {

par(...)  naprostě se dojde k body i čáry mají směr  
 $\downarrow$   $\rightarrow$  barva čáry a smysl bodu

plot(X[1, ], type = 'o', xlim = c(0.5, 3.5), pch = 21, col = ..., bg = ...,  
ylim = c(min(x), 1), axes = F, ...) ... připrava grafu + první čára pro (1) klasický dvouzj. t-test.

box(...)

axis(1, 1:3, labels = c(5, 50, 100)) ... řízení osy x: souřadnice 1, 2 a 3 mají popisek 5, 50 a 100

axis(2, ...) ... osy y

mtext(...) ... popisek 'n'


lines(X[2, ], type = 'o', pch = 21, col = ..., bg = ...) ... čára pro (2)

lines(X[3, ], ...) ... čára pro (3)

lines(...) ... čára pro (4)

abline(...) ... referenční čára 

legend(position, lty = 1, pch = 21, col = c(...), pt.bg = c(...), legend = c(...),  
btg = 'n') ... legenda



}

4. Pomoci funkce PokrytiPlot() vykreslime postupně následny 4 grafy pro sady parametrů (a), (b), (c), (d):

Xa  $\leftarrow$  rbind(p.a5, p.a50, p.a100)  $\rightarrow$

Xa  $\leftarrow$  t(Xa)  $\rightarrow$   ... konverze Xa



PokrytiPlot(Xa) ... spojiby diagram pro (a)

PokrytiPlot(t(rbind(p.b5, p.b50, p.b100))) ... spojiby diagram pro (b)

PokrytiPlot(-11-) ... spojiby diagram pro (c)

PokrytiPlot(-11-) ... -11- ... pro (d)

## 9.3

Vrámcí tohoto příkladu si nejdříve aplikaci klasického dvoujádrového  $t$ -testu,  $t$ -testu s Welchovou approximací, <sup>(3)</sup> věrohodnostního testu na předpokladu, že rozptyly  $\sigma_1^2$  a  $\sigma_2^2$  jsou stejná, ale stejně, a <sup>(4)</sup> věrohodnostního testu na předpokladu, že rozptyly jsou stejná a různá. Nejdříve ověříme předpoklad normality obou měřodních náležitostí (porovnání vhodným testem normality, neporovnání graficky, budete-li chlit =)). Následně otestujeme  $H_0$  ne nadání, a to různími členy různobodovými (krit. oborem, 15 je p-hodnota) pro hantý test. Nezapomeneme vždy uvést návrh o  $H_0$  a nakonec interpretaci návratu testování. Nakonec vyhodslíme hranice a oblasti 95% věrohodnostních empirických DIS.

Pomácká: Všechny potřebné návody jsou si uvedli v řešení příkladu 9.2. =)

Načtení a příprava dat	<pre>data &lt;- read.delim(...)</pre> <p>... načtení dat</p>
	<pre>length.m &lt;- data[... , ...]</pre> <p>... náhodný dílčí klínovitý kódí a první sloupec (length.R) a může</p>
	<pre>length.f &lt;- data[... , ...]</pre> <p>... -  -</p>
	<pre>length.m &lt;- na.omit(...)</pre>
	<pre>length.f &lt;- na.omit(...)</pre> <p>} odstranění NA hodnot</p>
Test normality - muži	<pre># H0m:</pre> <pre># H1m:</pre> <p><b>lillie.test(...)</b> nebo <b>shapiro.test(...)</b> ... vyberete z uvedených testů vhodnější a test provedete. Svou volbu rozhodněte.</p>
	<pre># Závěr:</pre>
	<pre># Interpretace:</pre>
Test normality ženy	<pre># H0f:</pre> <pre># H1f:</pre> <p><b>lillie.test(...)</b> nebo <b>shapiro.test(...)</b> ... vyberete z uvedených testů vhodnější a test provedete. Svou volbu rozhodněte.</p>
	<pre># Závěr:</pre>
	<pre># Interpretace:</pre>

Pomácká: Grafické rozhodnutí normality pomocí histogramu a Q-Q diagramu mechaniků jako dobrovolný úkol pro najetce. =)

Test o podílu rozptylů  $\sigma_1^2 / \sigma_2^2$ :

Před provedením klasického  $t$ -testu bychom správně měli ověřit správný předpoklad o shodě rozptylů obou měřodních náležitostí. Test o podílu rozptylů máš čeká až ve cv. 10, proto se jsem rozhodl nebudeme nabírat podrobně, ale pouze okrajově:

#  $H_0$ :  $\sigma_1^2 = \sigma_2^2$

#  $H_1$ :  $\sigma_1^2 \neq \sigma_2^2$

**var.test(length.m, length.f)** \$p.value ... dvoujádrový  $t$ -test o shodě rozptylů  $\sigma_1^2$  a  $\sigma_2^2$ .

# Závěr: Protože p-hodnota = ....,  $H_0$  ... na hl. významnosti  $\alpha=0.05$ .

# Interpretace:

Ze návratu testování vidíme, že předpoklad k použití klasického dvoujádrového  $t$ -testu je splněn.  $H_0$  ne nadání testy můžeme obstarat různými čtyřimi testy (1)-(4) =).

# Testy o rozdílu středních hodnot $\mu_1 - \mu_2$

# $H_0:$

# $H_1:$

Příprava hodnot

```

mu0 <- ...  $\mu_0$ 
alpha <- ...  $\alpha$ 
m1 <- mean(...) ...  $\bar{x}_1$ 
m2 <- ... ...  $\bar{x}_2$ 
s1 <- sd(...) ...  $s_1$ 
s2 <- ...  $s_2$ 
n1 <- length(...) ...  $n_1$ 
n2 <- ...  $n_2$ 

```

## klasický dvotvýběrový t-test

$$S \leftarrow \sqrt{\frac{(n_1-1)s_1^2 + (n_2-1)s_2^2}{n_1+n_2-2}}$$

$$SD \leftarrow \sqrt{\frac{n_1+n_2}{n_1n_2} S^2}$$

t.W.Wald <- ...	hodnota test. statistiky klasického dvotvýb. t-testu
df.Wald <- ...	pocet stupni volnosti - 11-
W.hh.Wald ...	df( $\alpha/2$ ) ... horní hranice krit. oboru - 11-
W.dh.Wald ...	df(1- $\alpha/2$ ) ... dolní hranice krit. oboru - 11-
#závěr:	
dh.Wald <- $\bar{x}_1 - \bar{x}_2 - t_{df}(1-\alpha/2) \cdot SD$ ... dolní hranice 15	
hh.Wald <- $\bar{x}_1 - \bar{x}_2 - t_{df}(\alpha/2) \cdot SD$ ... horní hranice 15	
#závěr:	
p.Wald <- 2 · min(pt(...), 1-pt(...))	... p-hodnota
#závěr:	

## dvotvýběrový t-test s Welchovou approximací

$$SD.Welch \leftarrow \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}$$

t.W.Welch <- ...	hodnota test. statistiky dvotvýb. t-testu s Welch. approximací
df.Welch <- ...	pocet stupni volnosti - 11-
W.hh.Welch <... df( $\alpha/2$ ) ... horní hranice krit. oboru	
W.dh.Welch <... df(1- $\alpha/2$ ) ... dolní hranice krit. oboru	
#závěr:	
dh.Welch <- $\bar{x}_1 - \bar{x}_2 - t_{df}(1-\alpha/2) \cdot SD$ ... dolní hranice 15	
hh.Welch <- $\bar{x}_1 - \bar{x}_2 - t_{df}(\alpha/2) \cdot SD$ ... horní hranice 15	
#závěr:	
p.Welch <- 2 · min(pt(...), 1-pt(...))	... p-hodnota
#závěr:	

## Vérohodnostní test pro neznámé, ale shodné rozptyly

$$n <- n_1 + n_2$$

ULR.SR <- ...	hodnota test. stat. ULR když $\sigma_1^2 = \sigma_2^2$ jsou neznámé a shodné
W.dh.ulr.SR <- ... $\chi^2_{(1-\alpha)}$	... dolní hranice krit. oboru.
#závěr:	

Hranice 95%. DIS opět chceme stanovit přesně. Použijeme tedy funkci `uniroot()`, která hledá kořen rovnice  $ULR - \chi^2_{(1-\alpha)} = 0$ . Nejdříve tedy myšlenkou použijeme funkci `ULR.chisq()`, která pro zadání rozložení X a Y, hodnotu  $\mu_0$  a hl. významnosti  $\alpha$  máli hodnotu  $ULR - \chi^2_{(1-\alpha)}$ . Funkci si rovnou připravíme tak, aby jí mohli použít i pro hledání hranic věroh. DIS, když  $\sigma_1^2 = \sigma_2^2$  jsou neznámé a různé (4).

ULRchisq ← function (mu0, X, Y, alpha = 0.05, equal = T) {
   
 $m1 \leftarrow \text{mean}(X) \dots \bar{x}_1$ 
  
 $m2 \leftarrow \dots \bar{x}_2$ 
  
 $s1 \leftarrow \text{sd}(X) \dots s_1$ 
  
 $s2 \leftarrow \dots s_2$ 
  
 $n1 \leftarrow \text{length}(X) \dots n_1$ 
  
 $n2 \leftarrow \dots n_2$ 
  
 $n \leftarrow n1+n2 \dots n$ 
  
 $S1 \leftarrow \sqrt{\frac{n1-1}{n1} s1^2} \dots g_1$ 
  
 $S2 \leftarrow \sqrt{\frac{n2-1}{n2} s2^2} \dots g_2$ 
  
 $g \leftarrow \frac{\hat{G}_1^2}{\hat{G}_2^2} \dots \eta$ 
  
 $S \leftarrow \sqrt{\frac{(n1-1)s1^2 + (n2-1)s2^2}{n1+n2-2}} \dots S$ 
  
 $SD.Wald \leftarrow \dots SD$ 
  
 $tW.Wald \leftarrow \dots$  test. stat klasického dvouj. t - testu  
 použijeme rovněž
   
 $\text{if}(equal == T) \{ uLR \leftarrow \dots$  test. stat uLR věroh. testu když  $G_1^2$  a  $G_2^2$  jsou merné a shodné }
   
 $\text{if}(equal == F) \{ uLR \leftarrow \dots$  test. stat uLR věroh. testu když  $G_1^2$  a  $G_2^2$  jsou merné a různé }
   
 $uLR.chisq \leftarrow uLR - qchisq(\dots)$  hodnota  $uLR - \chi^2_{1-(1-\alpha)}$ 
  
 $\text{return}(\dots)$ 
}

} dolní hranice IS

dh.uLR.SR ← uniroot (ULRchisq, c(0, 17), alpha = ..., x = length.m, Y = ..., equal = T) \$root
   
 hh.uLR.SR ← uniroot (... , c(17, 30), ...) \$root ... horní hranice IS
   
 # závěr:
   
 p.uLR.SR ← 1 - pchisq (...) ... p - hodnota

Vérohodnostní test pro neznámé a různé rozptyly  $G_1^2$  a  $G_2^2$

$n \leftarrow n1+n2$

$S1 \leftarrow \hat{G}_1$

$S2 \leftarrow \hat{G}_2$

$g \leftarrow \eta$

ULR.RR ← ... hodnota test. stat uLR když  $G_1^2$  a  $G_2^2$  jsou merné a různé

W.dh.uLR.RR ← ... dolní hranice krit. oboru

# závěr:
   
 dh.uLR.RR ← uniroot (... , equal = F) \$root ... dolní hranice IS

hh.uLR.RR ← uniroot (...) \$root ... horní hranice IS

# závěr:
   
 p.uLR.RR ← 1 - pchisq (...) ... p - hodnota

# závěr:

tab ← data.frame (m1 = rep(m1, 4), m2 = ... ,  
 $\text{stat} = \text{c}(tW.Wald, tW.Welch, uLR.SR, uLR.RR),$   
 $hh.W = \text{c}(..., NA, NA),$   
 $dh.W = \text{c}(...),$   
 $dh = \text{c}(...),$   
 $hh = \text{c}(...),$   
 $p = \text{c}(...),$   
 $\text{row.names} = \text{c}(...))$  ... souhrnná tabulka výsledků

# Interpretace výsledků: Uvede antropologický návrh. INTERPRETACI VÝSLEDKŮ TESTOVÁNÍ! =)

Graf věrohodnostního DIS, když  $\sigma_1^2$  a  $\sigma_2^2$  jsou neznámé a shodné

`mu0.i <- seq(...)` ... posl.  $\mu_0$  i od 0 do 30 s délka minimálně 1000 (délka=1000)

`tW.Wald.i <- ...` vektor statistik Waldova. l-dílu pro různé  $\mu_0$  (1000)

`ULR.SR.i <- ...` vektor statistik ULR dleží  $\sigma_1^2$  a  $\sigma_2^2$  pouz. neznámé a shodné (1000)

`plot(mu0.i, ULR.SR.i, ylim=c(0,15), ...)` ... ✓

`lines(mu0.i [mu0.i > dh.ULR.SR & mu0.i < hh.ULR.SR],`  
`ULR.SR.i [mu0.i > ... -11-], ...)` ... ✓

`abline(...)` ... referenční čára (vodorovná, přešrouvaná ředá) v hodnotě  $\chi^2_{\alpha}(1-\delta)$

`mtext(expression(...), ...)` ... popisek ' $\mu_0$ '

`mtext(bquote(...), ...)` ... popisek ' $\bar{S} = (\dots, \dots)$ '

Graf věrohodnostního DIS, když  $\sigma_1^2$  a  $\sigma_2^2$  jsou neznámé a různé

`ULR.RR.i <- ...` vektor statistik ULR dleží  $\sigma_1^2$  a  $\sigma_2^2$  pouz. neznámé a různé (1000)

`plot(mu0.i, ULR.RR.i, ylim=c(0,15), ...)` ... ✓

`lines(...)` ... ✓

`abline(...)` ... referenční horizontální písací řada přešrouvaná čára v hodnotě  $\chi^2_{\alpha}(1-\delta)$

`mtext(...)` ... popisek ' $\mu_0$ '

`mtext(...)` ... popisek ' $\bar{S} = (\dots, \dots)$ '