

Nechť máh. vektor $(X, Y)^T \sim N_2(\mu, \Sigma)$, kde $\mu = (\mu_1, \mu_2)^T$ je vektor středních hodnot a $\Sigma = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}$ je varianční matice. K vyjádření vztahu mezi máh. veličinami X a Y použijeme klasický / lineární Pearsonův korelační koeficient

$$R = \frac{1}{n-1} \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{S_x^2 S_y^2}} = \frac{1}{n-1} \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{S_x S_y},$$

kde $S_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$ a $S_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2$.

Z bakalářského studia víme, že Pearsonův korelační koeficient pochází asymptoticky z normálního rozdělení, konkrétně

$$R \stackrel{A}{\sim} N\left(g, \frac{(1-g^2)^2}{n-1}\right),$$

$\underbrace{\text{střední}}_{\text{hodnota}}$ $\underbrace{\text{rozptyl}}_{\text{}}$

Konvergence R k normalitě je však pomalá, proto používáme dva Fisherovy Z - proměnnou

$$Z_R = \frac{1}{2} \ln \frac{1+R}{1-R} \sim N\left(\underbrace{\frac{1}{2} \ln \frac{1+g}{1-g}}_{\text{střední hodnota}}, \underbrace{\frac{1}{n-3}}_{\text{rozptyl}}\right)$$

V příkladech 7.1 a 7.2 se naměříme na rychlosť konvergence statistik R a Z_R k normálnímu rozdělení při $n \rightarrow \infty$ (7.1) a při $g \rightarrow 1$ (7.2). Příklady využijeme společně vykrojením funkce rho.stat(), která pro zadání $n, g, \mu_1, \mu_2, \sigma_1, \sigma_2$ a M vytvoří dvojici histogramů (pro R + pro Z_R). Tuto funkci pak použijeme k vykreslení animací v oborech příkladů.

```
rho.stat <- function(n, rho, mu1=..., mu2=..., sigma1=..., sigma2=..., M=...,  
  xlim1=c(0.5,1), xlim2=c(-0.5,2), ylim1=c(0,10), ylim2=c(0,4)) {  
  r1 <- ran.gen & první hist.  r2 <- ran.gen & druhý hist.  r3 <- ran.gen & první hist.  r4 <- ran.gen & druhý hist.
```

mu <- c(...) ... vektor středních hodnot $\mu = (\mu_1, \mu_2)$

Sigma <- matrix(...) ... varianční matice $\Sigma = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}$... ! po vykrojení matice Sigma si je vyplňuje a zkontroluje ! často se v ní chybí !

Generování dat: I. násobek - cyklem:

R <- zR <- NULL ... příprava prázdných vektorů R a zR

for(i in 1:M) {

XY <- MASS::mvrnorm(n=n, mu=mu, Sigma=Sigma) ...

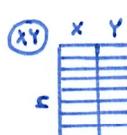
X <- XY[,1] ... vektor X (délka=n)

Y <- XY[,2] ... vektor Y (délka=n)

R[i] <- cor(...) ... R (1 číslo; délka R[i]=1)

zR[i] <- zR (1 číslo, délka zR[i]=1)

} ... výsledek cyklu jsou dva vektory R a zR o délce M.



Generování dat: II. násobek - funkci replicate():

Vykrojuje korelační matice!!! $\begin{pmatrix} 1 & R \\ R & 1 \end{pmatrix}$

R <- replicate(M, cor(mvrnorm(n=n, mu=mu, Sigma=Sigma))[1,2]) ... vektor M=1000 korel. koef. R

zR <- 1/2 * ln(1+R)/(1-R) ... vektor M=1000 Fisherových Z-transformací.

R
Histogram
R
Histogram
}

xfit \leftarrow seq(...)
... posloupnost od -1 do 1 o délce minimálně 500

yfit \leftarrow dnorm(...)
... hustota $N(g, \frac{(1-g^2)^2}{n-1})$ nad posloupností xfit

par(mfrow=..., mar=...)

hist(..., prob=..., col=..., border=..., xlim=xlim1, ylim=ylim1, ...)
... histogram R se řádkováním sloupců, rozměr osy x (xlim) je nadán argumentem xlim1, y (ylim) -> -> ylim1

box(...)

lines(...) ... křivka hustoty $N(g, \frac{(1-g^2)^2}{n-1})$ se řádkem 2

mtext(...) ... popisek R

mtext(bquote(paste(...)), ...) ... automaticky se měníci popisek n=..., g=...

xfit \leftarrow seq(...)
... posloupnost od min(zR)-1 do max(zR)+1 o délce minimálně 500

yfit \leftarrow dnorm(...)
... hustota $N(\frac{1}{2} \ln \frac{1+g}{1-g}, \frac{1}{n-3})$ nad posl. xfit

hist(..., xlim=xlim2, ylim=ylim2, ...) ... histogram zR

box(...)

lines(...) ... křivka hustoty $N(\frac{1}{2} \ln \frac{1+g}{1-g}, \frac{1}{n-3})$

mtext(...) ... popisek zR

mtext(...) ... automaticky se měníci popisek n=..., g=...

S5.1: Animace:

n \leftarrow seq(...)
... posloupnost n nadaná podle zadání příkladu 5, 10, 15, ..., 70.

... úvodní nastavení animace

saveLatex(for(...){

rho.stat(n=n[i], rho=0.8)

}, ...)

Vygenerovanou animaci si pomalu projděte a porovnejte kvalitu konvergence R a \bar{z}_R k normálnímu rozdělení. Do komentářů uveděte zhodnocení kvality konvergence a navíc, pro jak velké n je podle vašeho názoru jíž vhodné použít Pearsonův korelační koeficient R a Fisherovu z-transformaci \bar{z}_R .

S5.2: Animace pro n=5:

rho \leftarrow seq(...)
... nadaná posloupnost g = 0.1, 0.2, ..., 0.9

... úvodní nastavení animace

saveLatex(for(...){

rho.stat(n=5, rho=rho[i], xlim1=c(0,1), xlim2=c(-2,3),

ylim1=c(0,5), ylim2=c(0,1))

}, ...)

S5.2: Animace pro n=50:

Analogicky jako pro n=5. Hodnoty ostatních argumentů mohou: xlim1=c(0,1), xlim2=c(-2,3), ylim1=c(0,12), ylim2=c(0,3).

Vygenerované animace si pomalu projděte a porovnejte kvalitu konvergence R a \bar{z}_R k normálnímu rozdělení. Do komentářů popište, jak se mění kvalita konvergence R a \bar{z}_R při $g \rightarrow 0.9$ (mění-li se nějak) a je-li nějaký rozdíl mezi situací když n=5 a n=50.

V rámci tohoto příkladu si vykoušíme aplikaci testovacích statistik Z_w a U_{LR} na reálná data. Nejprve ověříme předpoklad dvourozměrné normality. Následně dležíme H_0 ne rovnání, a to němi čími násobky (krit. oborem, IS a p-hodnotou) pro kódovou test. statistiku Z_w a U_{LR} . Nerapomene výsly uvít ránce o H_0 a nakonec interpretaci ránce testování. Nakonec vykreslime hranici a oblast významnostiho 95% empirického IS.

Náčelník a příprava dat

```
data <- read.delim(..)
data.M <- data [data$sex == ..., c('skull.pH', 'face.H')]
data.M <- na.omit(...)

skull.M <- data.M ...
face.M <- data.M$...
```

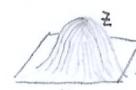
Test(y) dvourozměrné normality

```
# H0: ...
# H1: ...

MVN::mvn(data.M, mvnTest = 'mardia')$multi ... MARDIUV TEST ... testuje rovnost aspektů šířnosti a šířeklosti
MVN::mvn(-11- , -11- : 'hz')$... ... HENZE-ZIRKLERUV TEST
MVN::mvn(-11- , -11- : 'royston')$... ... ROYSTONUV TEST
# Závěr: Probělo ...,  $H_0$  ma bludně významnosti...
# Interpretace:
```

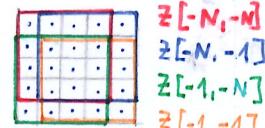
3D (persp) graf

```
kd <- MASS::kde2d(skull.M, face.M, n=50, lims = c(120, 155, 90, 145)) ... jádrový odhad dvourozměrné hustoty (med osou X a Y normované 120-155 a med osou Y a normované 90-145).
x <- kd$x ... vektory hodnot x vykrojených kde2d
y <- kd$y ... -11- y -11- kde2d
z <- kd$z ... matice dvourozměrné hustoty  $f(x,y)$  vykrojená kde2d.
N <- dim(z)[1] (50)
```



analogicky fina na výkaz sredni jako v S11.

```
Stredy <- z[-1,-1] + z[-1,-n] + z[...,-] + z[...,...] ... analogicky fina na výkaz sredni
ryska <- cut(stredy, 12) ... rozdeleni stredni do 12 kategorii
par(mar = ... ) 1 0 1 1 ... obranní kód kategorie jednotu a 12 barev šísky heat.colors().
persp(..., theta = -20, phi = 30, col = heat.colors(12)[ryska], ...) ... 3D jádrový odhad hustoty
```



Tečkový graf s 95% elipsou spolehlivosti

```
par(...) 4 2 1
car::dataEllipse(skull.M, face.M, level = 0.95, ... 95% elipsa s spolehlivostí
                xlim = c(122, 150), ylim = c(90, 141), ... rousah osy x
                pch = 21, bg = 'khaki1', col = c('orange2', 'khaki4'), ...) ... Graf elipsy spolehlivosti
                mtext(..., ... ) ... popisek 'nejvetsi rousah vyska mozku (mm)' ... rousah osy y
                mtext(..., ... ) ... popisek 'Mardiuv test ...' ... rousah bodu
                (nenemusí být automaticky). ... rousah bodu
                (nenemusí být automaticky).
```

Poznámka: Interpretace normality na základě lečového grafu s elipsou spolehlivosti.

Předpokládáme, že počet dat pochází z dvourozměrného normálního rozdělení N_2 , potom 95% elipsa spolehlivosti pokrývá alespoň 95% dat. (tj. nejvíce 5% dat leží mimo elipsu spolehlivosti).

Z jedule sedy rousah náhodného výběru n , spočítejte 5% z n , dále spočítejte, kolik bodů leží von elipsy spolehlivosti a do komentáře uveděte relevantní rámcov o dvourozměrné normalitě dat na základě tohoto grafu.

Test o korelačním koeficientu ρ :

H_0 :

H_1 :

$\rho_{00} \leftarrow \dots g_0$

$n \leftarrow \text{length}(\dots)$... počet porovnání (rozsah měř. výběru)

$\alpha \leftarrow \dots \alpha$

$r \leftarrow \text{cor}(\dots)$... vypočítání Pearsonova korelačního koeficientu R pro skupinu M

$$z_R \leftarrow \frac{1}{2} \ln \frac{1+R}{1-R} \dots z_R$$

$$\xi_0 \leftarrow \frac{1}{2} \ln \frac{1+g_0}{1-g_0} \dots \xi_0$$

Příprava hodnot

ULR.stat $\leftarrow \text{function}(r, \rho_{00}, n) \{$

$$ULR \leftarrow n \left(\ln \frac{(1-g_0^2)^2}{(1-g_0^2)(1-\hat{r}^2)} \right)$$

} return(...)

Testování kritickým oborem

$$z_W \leftarrow \sqrt{n-3} (z_R - \xi_0) \dots z_W$$

$ULR \leftarrow ULR.stat(\dots)$... hodnota test. statistiky ULR

$$q_1 \leftarrow \dots u_{1/2}$$

$$q_2 \leftarrow \dots u_{1-q_2}$$

$$q \leftarrow \dots \chi^2_4(1-\alpha)$$

Pro hantý test uveděte rozdělení návěr o H_0

Testování IS:

$$dh.z_R \leftarrow z_R - \frac{u_{1-\alpha/2}}{\sqrt{n-3}} \dots \text{dolní hranice Waldova IS pro } \xi_0$$

$$hh.z_R \leftarrow z_R - \frac{u_{\alpha/2}}{\sqrt{n-3}} \dots \text{horní hranice Waldova IS pro } \xi_0$$

$$dh.R \leftarrow \tanh(dh.z_R) \dots \text{zpětně transformovaná dolní hranice Waldova IS (pro } \rho \text{)}$$

$$hh.R \leftarrow \tanh(\dots) \dots \text{zpětně transformovaná horní hranice Waldova IS (pro } \rho \text{)}$$

$$\rho_{0,i} \leftarrow \text{seq}(\dots) \dots \text{počítačové hodnoty } \rho \text{ od } 0.1 \text{ do } 0.6 \text{ se rozdílem mezi body } 0.0001 \text{ (5001 hodnot)}$$

$$ULR.i \leftarrow ULR.stat(r, \dots) \dots \text{vektor 5001 test. statistik } ULR.i \text{ pro posloupnost } \rho_i \text{ (rho.i)}$$

$$dh.ULR \leftarrow \min(\dots) \dots \text{dolní hranice výrobní 95% empirického IS}$$

$$hh.ULR \leftarrow \max(\dots) \dots \text{horní hranice } -11$$

čím více bodů, tím přesnější bude období hranice výrobního IS

Pro hantý test uveděte rozdělení návěr o H_0 :

Testování p-hodnotou

$$p.z_W \leftarrow 2 \cdot \min(pnorm(\dots), 1-pnorm(\dots))$$

$$p.ULR \leftarrow 1 - pchisq(\dots)$$

Pro hantý test uveděte rozdělení návěr o H_0 .

Interpretace výsledků testování: Uveděte antropologický návěr (interpretaci výsledků testování). Co jsme se dozvídali o rozdílu mezi větší a menší morfologické a morfoložické výšky kváře u mužů starověké egyptské populace?

Na návěr uveděte také komplexní interpretaci Pearsonova korelačního koeficientu $r=0.3306$ tak, jak jsme si ji uvažovali na načátku semestru.

Tabulkou výsledků

```
tab <- data.frame(
  ...
  IS.dh=c(dh.R, dh.uLR),
  ...
)
```

round(tab, 4) ... zaokrouhlení na 4 des. místa

Graf s výrohodnostním IS

```
par(...)
```

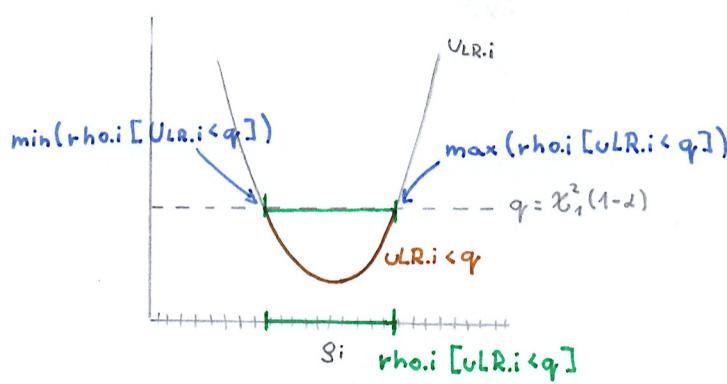
plot(rho.i, uLR.i, ylim=c(0,5), ...) ... křivka uLR \checkmark

mtext(...) ... popisek g

abline(...) ... vodorovná čára přesměrování referenční čára v hodnotě $\chi^2_1(1-\alpha)$ ---

lines(rho.i [...], uLR.i [...], ...) ... barevně vyznačená oblast uLR n r IS \checkmark

mtext(...) ... popisek IS = (... , ...), analogicky napsat jako v 5.8 a 6.6.



Odrození:

(Odrození je analogické jako ve cvičení 04. Doporučují využít zde uvedených vzorců sily, nezkoušet si odrození samostatně a rolo uvedení odrození povíd jako kontrolu. =))

$$1. H_0: g = g_0 \quad H_{11}: g \neq g_0 \quad (\text{obousměrná ab.})$$

$$\text{Exaktní síla: } \beta_{11}^*(\xi) = \underline{\Xi}(u_{d/2} + \sqrt{n-3}(\xi_0 - \xi)) + \overline{\Xi}(u_{d/2} - \sqrt{n-3}(\xi_0 - \xi))$$

$$\text{Aproximativní síla: } \tilde{\beta}_{11}^*(\xi) = \underline{\Xi}(u_{d/2} + \sqrt{n-3}|\xi_0 - \xi|)$$

Minimální rozsah n :

$$\tilde{\beta}_{11}^*(\xi) = \underline{\Xi}(u_{d/2} + \sqrt{n-3}|\xi_0 - \xi|) / u()$$

$$u_{\tilde{\beta}_{11}^*}(\xi) = u_{d/2} + \sqrt{n-3}|\xi_0 - \xi|$$

$$\left(\frac{u_{\tilde{\beta}_{11}^*}(\xi) - u_{d/2}}{|\xi_0 - \xi|} \right)^2 + 3 = n \Rightarrow n \geq \left(\frac{u_{\tilde{\beta}_{11}^*}(\xi) - u_{d/2}}{|\xi_0 - \xi|} \right)^2 + 3 \quad / u_{d/2} = -u_{1-d/2}$$

$$n \geq \left(\frac{u_{\tilde{\beta}_{11}^*}(\xi) + u_{1-d/2}}{|\xi_0 - \xi|} \right)^2 + 3$$

$$2. H_0: g \leq g_0 \quad H_{12}: g > g_0 \quad (\text{pravosměrná ab.})$$

$$\text{Exaktní síla: } \beta_{12}^*(\xi) = 1 - \underline{\Xi}(u_{1-d} + \sqrt{n-3}(\xi_0 - \xi)) = \underline{\Xi}(u_d - \sqrt{n-3}(\xi_0 - \xi))$$

Minimální rozsah n :

$$\beta_{12}^*(\xi) = 1 - \underline{\Xi}(u_{1-d} + \sqrt{n-3}(\xi_0 - \xi))$$

$$1 - \beta_{12}^*(\xi) = \underline{\Xi}(u_{1-d} + \sqrt{n-3}(\xi_0 - \xi)) / u()$$

$$u_{1-\beta_{12}^*}(\xi) = u_{1-d} + \sqrt{n-3}(\xi_0 - \xi)$$

$$\left(\frac{u_{1-\beta_{12}^*}(\xi) - u_{1-d}}{\xi_0 - \xi} \right)^2 + 3 = n \Rightarrow n \geq \left(\frac{u_{1-\beta_{12}^*}(\xi) - u_{1-d}}{\xi_0 - \xi} \right)^2 + 3 \quad / u_d = -u_{1-d}$$

$$n \geq \left(\frac{u_{1-\beta_{12}^*}(\xi) + u_d}{\xi_0 - \xi} \right)^2 + 3$$

$$3. H_0: g \geq g_0 \quad H_{13}: g < g_0 \quad (\text{levosměrná ab.})$$

$$\text{Exaktní síla: } \beta_{13}^*(\xi) = \underline{\Xi}(u_d + \sqrt{n-3}(\xi_0 - \xi))$$

Minimální rozsah n :

$$\beta_{13}^*(\xi) = \underline{\Xi}(u_d + \sqrt{n-3}(\xi_0 - \xi)) / u()$$

$$u_{\beta_{13}^*}(\xi) = u_d + \sqrt{n-3}(\xi_0 - \xi)$$

$$\left(\frac{u_{\beta_{13}^*}(\xi) - u_d}{\xi_0 - \xi} \right)^2 + 3 = n \Rightarrow n \geq \left(\frac{u_{\beta_{13}^*}(\xi) - u_d}{\xi_0 - \xi} \right)^2 + 3 \quad / u_d = -u_{1-d}$$

$$n \geq \left(\frac{u_{\beta_{13}^*}(\xi) + u_{1-d}}{\xi_0 - \xi} \right)^2 + 3$$

1. Nejdříve si napišme funkci `min.n()`, která pro zadání hodnoty β , β_0 , α , s a pro zadaný typ alternativy vrátí minimální rozsah měř. výběru n .

```
min.n <- function(rho, rho0, alpha=..., sila=0.8, alternative=...){  
 ksi <- ...  $\xi = \frac{1}{2} \ln \frac{1+s}{1-s}$   
 ksi0 <- ...  $\xi_0 = \frac{1}{2} \ln \frac{1+\beta_0}{1-\beta_0}$   
  if(alternative == 'two.sided') {n <-  $\left( \frac{U_{\beta_{1-\alpha}}(\xi) - U_{\beta_{1-\alpha}}(\xi_0)}{\xi_0 - \xi} \right)^2 + 3\right)$ }  
  if(alternative == 'greater') {n <-  $\left( \frac{U_{1-\beta_{1-\alpha}}(\xi) - U_{1-\alpha}(\xi_0)}{\xi_0 - \xi} \right)^2 + 3\right)}$ }  
  if(alternative == 'less') {n <-  $\left( \frac{U_{\beta_{1-\alpha}}(\xi) - U_{\alpha}(\xi_0)}{\xi_0 - \xi} \right)^2 + 3\right)}$ }  
  <- ((qnorm(sila) - qnorm(alpha)) /  
        (ksi0 - ksi))^2 + 3 }  
  return(round(n))  
}
```

2. Vyhledejme graf pro (a) oboustrannou alternativu:

```
rho <- c(seq(...), seq(...)) ... spojení dvou posloupností: První od -0.95 po -0.1 po krok 0.05; druhá od 0.1 do 0.95 po krok 0.05  
n11 <- min.n(rho=rho, rho0=0, alternative='two.sided') ... vektor minimálních rozsahů  $n$  pro každou hodnotu  $\beta$  a vektoru rho při volbě oboustranné alt.  
par(...)  
plot(rho, n11, xlim=c(-1,1), ...) ... lehký graf: body s jinou barvou napsané a obrys  
mtext(expression(rho - rho[0]), ...) ... popisek  $\beta - \beta_0$   
mtext(...) ... popisek 'oboustranná alternativa'
```

3. Vyhledejme graf ((b) pro pravosstrannou alt. resp. (c) pro levosstrannou alt.)

```
rho <- seq(...) ... posl. od 0.1 do 0.95 po 0.05 resp. od -0.95 do -0.1 po 0.05.  
n12 <- min.n(...) ... vektor minimálních rozsahů  $n$  pro každou hodnotu  $\beta$  a vektoru rho při volbě pravosatr. (resp. levosstranné) alt.  
plot(rho, n12, xlim=c(-1,1), ...) ... lehký graf: body s jinou barvou napsané a obrys  
Segments(-2, 0, 0, 0, ...) ... řada přerušovaná čára znáčící silnou, pro které nemělo smysl minimální rozsah  $n$  počítat  
mtext(expression(...)) ... popisek  $\beta - \beta_0$   
mtext(...) ... popisek s typem alternativy
```

4. Sestavíme tabulku:

```
n11 <- min.n(rho=0.60, rho0=0.85, alpha=..., sila=..., alternative=...)  
n12 <- min.n(...)  
n13 <- min.n(...)  
alpha <- c() 0.10 0.05 0.01 (délka=3)  
sila <- c() ... vektor nadaných sil (délka = 3)  
beta <- 1-sila ... vektor pati chyb II. druhu (délka = 3)  
rho0 <- c() ... vektor  $\beta_0$  (3)  
rho <- c() ... vektor  $\beta$  (3)  
n <- c(n11, n12, n13) ... vektor minimálních rozsahů  $n$   
tab <- data.frame(alpha, sila, ..., n, row.names=c('pravostranná', ...)) ... tabulka napsaná  
round(...) ... napsání tabulky naokrouhlení na 4 des. místa
```