

V tomto příkladu chceme vzájemně porovnat průběh tří funkcí, a sice (a)  $y = \frac{x}{1+x}$ ; (b)  $y = \log(1+x)$  a (c)  $y = x$ . Řešení příkladu je velmi jednoduché. Vygenerujeme postupnost bodů osy x a pro každý bod postupnosti vypočítáme hodnotu podle přepisu funkce (a), resp. (b), či (c). Následně vykreslíme křivky těchto tří funkcí (jednak pro větší rozsah osy x (0-5) a osy y (0-5) a potom pro výřez, tj. pro rozsah osy x 0-0.05 a pro rozsah osy y 0-0.05.). Křivky vzájemně porovnáme.

```

x ← seq(...) ... postupnost od 0 do 5 o délce minimálně 512. (d=512)
y1 ← ... vektor hodnot  $\frac{x}{x+1}$  (d=512)
y2 ← ... vektor hodnot  $\log(x+1)$  (d=512)
y3 ← ... vektor hodnot x (d=512)

plot(x, y1, type='n', xlim=c(0,5), ylim=c(0,5), las=1, ylab=...) ... příprava
lines(x, y1, col=..., lwd=..., lty=...) ... křivka  $y = \frac{x}{x+1}$  (mapř. červená) grafu
lines(x, y2, ...) ... křivka  $y = \log(x+1)$  (mapř. modrá)
lines(...) ... křivka  $y = x$  (mapř. zelená)
legend('topleft', lwd=..., lty=..., col=..., legend=..., bty='n') ... legenda

```

*Annotations for the first plot:*  
 -  $\frac{x}{x+1}$ : mapř. červená (red)  
 -  $\log(x+1)$ : mapř. modrá (blue)  
 -  $y = x$ : mapř. zelená (green)  
 -  $col=...$ : vektor barev čar (color vector)  
 -  $lty=...$ : vektor typů čar (line type vector)  
 -  $legend=...$ : vektor popisů legendy (legend text vector)  
 -  $bty='n'$ : okolo legendy nebude rámeček (no box around legend)

```

plot(x, y3, xlim=c(0,0.05), ylim=c(0,0.05), ...) ... příprava
lines(x, y1, ...) ... křivka  $y = \frac{x}{x+1}$  grafu
lines(...) ... křivka  $y = \log(1+x)$ 
lines(...) ... křivka  $y = x$ 
legend(...) ... legenda

```

*Annotations for the second plot:*  
 -  $y = \frac{x}{x+1}$ : mapř. červená (red)  
 -  $y = \log(1+x)$ : mapř. modrá (blue)  
 -  $y = x$ : mapř. zelená (green)

Závěr: Z grafu vidíme, že  $\frac{x}{1+x} \leq \log(1+x) \leq x$ .

Poznámka: Uvedenou nerovnost  $\frac{x}{1+x} \leq \log(1+x) \leq x$ , jejíž platnost jsme v tomto příkladu graficky ověřili, využijeme ve 3. cvičení při porovnání distribučních statistik  $U_s$ ,  $U_w$  a  $U_{LR}$  kedu  $\sigma$  a  $\mu$ , když  $\sigma^2$  nemáme.

V tomto příkladu chceme graficky porovnat konvergenci Studentova rozdělení  $t_n$  ke standardizovanému normálnímu rozdělení  $N(0,1)$  pro  $n \rightarrow \infty$ . Konvergenci vizualizujeme pomocí animace. Nejprve vytvoříme funkci `normalni_student(n)`, jejímž vstupem bude počet stupňů volnosti Studentova rozdělení  $t_n$  a výstupem bude dvojice grafů vykreslených vedle sebe. Na levím grafu bude zobrazena křivka hustoty rozdělení  $N(0,1)$  a rozdělení  $t_n$ , na pravím grafu bude zobrazena křivka distribuční funkce rozdělení  $N(0,1)$  a rozdělení  $t_n$ . Funkci `normalni_student()` následně použijeme ke tvorbě animace.

↑ povinný vstupní argument funkce

`normalni_student ← function(n) {`

**příprava podkladů**

- `mu ← ...` parametr  $\mu$  rozdělení  $N(0,1)$
- `sigma ← ...` parametr  $\sigma$  rozdělení  $N(0,1)$
- `xfit ← seq(...)` ... posloupnost  $x$  od -3 do 3 s dílkou 512
- `yfit ← dnorm(xfit, mean = ..., sd = ...)` ... hustota rozdělení  $N(0,1)$  nad posl. `xfit` ( $d=512$ )
- `zfit ← dt(xfit, df = ...)` ... hustota rozdělení  $t_n$  nad posl. `xfit` ( $d=512$ )

**graf křivky hustoty**

- `par(mfrow = c(1,2), mar = c(...))` ... rozdělení obrátka má 2 okna vedle sebe + okraje 5,4,2,1
- `plot(xfit, yfit, type = 'l', ylim = c(0,0.5), xlab = '', ylab = ..., col = ..., lwd = ..., las = ...)` ... graf s křivkou hustoty  $N(0,1)$  (např. modrá)
- `lines(xfit, zfit, ...)` ... křivka hustoty  $t_n$  (např. červená)
- `mtext('x', side = 1, line = 2.5)` ... popisek osy  $x$
- `mtext(paste('n =', n), ...)` ... druhý popisek osy  $x$  ( $n = ...$ ); automatická aktualizace hodnoty podle parametru  $n$
- `legend(..., lty = ..., col = ..., legend = ..., bty = ...)` ... legenda

**příprava podkladů**

- `yfit ← pnorm(...)` ... distr. fce rozdělení  $N(0,1)$  nad posl. `xfit` ( $d=512$ )
- `zfit ← pt(...)` ... distr. fce rozdělení  $t_n$  nad posloupností `xfit` ( $d=512$ )

**graf křivky distr. fce**

- `plot(xfit, yfit, ...)` ... graf s křivkou distr. fce  $N(0,1)$  (např. modrá)
- `lines(...)` ... křivka distr. fce rozdělení  $t_n$  (např. červená)
- `mtext(...)` ... popisek osy  $x$
- `mtext(...)` ... druhý popisek osy  $x$  ( $n = ...$ ); automatická aktualizace hodnoty podle parametru  $n$
- `legend(...)` ... legenda

**animace**

- `n ← seq(...)` ... posloupnost 5, 10, 50, 100, 500, 1000
- `opts ← ani.options()`
- `ani.record(reset=T)` ... vymazání předchozích grafů z paměti
- `saveLatex(for(i in 1:length(n)) { ... cyklus pro vytvoření obrátek animace`
- `normalni_student(n=n[i])`
- `}, ...)` ... animace

Závěr: Z průběhu animace vidíme, jak se pro  $n \rightarrow \infty$  blíží tvar křivky hustoty (resp. distribuční fce) Studentova rozdělení  $t_n$  k tvaru křivky hustoty (resp. distribuční fce) rozdělení  $N(0,1)$ .

V tomto příkladu si graficky ověříme tři vztahy, se kterými se setkáváme na přednáškách z S1-11.

$$(1) \chi^2_{d-1}(1-\alpha) = (u_{1-\alpha/2})^2$$

$$(2) F_{1,n}(1-\alpha) = (t_n(1-\alpha/2))^2$$

$$(3) \chi^2_n(1-\alpha) = \Gamma_{\frac{n}{2}, 2}(1-\alpha)$$

$n=10$

Řešení příkladu si demonstrováme na situaci (1). Nejprve vygenerujeme posloupnost hodnot ( $\alpha$ ) z intervalu (0.01; 0.99). Dále pro každou hodnotu posl.  $\alpha$  vypočítáme hodnotu  $(1-\alpha)$ -kvantilu  $\chi^2$  rozdělení s 1 stupni volnosti, tj.  $\chi^2_{d-1}(1-\alpha)$  a hodnotu druhé mocniny  $(1-\alpha/2)$ -kvantilu rozdělení  $N(0,1)$ , tj.  $(u_{1-\alpha/2})^2$ . Následně vykreslíme graf, kde na ose x bude posloupnost  $\alpha$  a na ose y posloupnost hodnot kvantilů  $\chi^2_{d-1}(1-\alpha)$ , resp.  $(u_{1-\alpha/2})^2$ . Obě křivky vzájemně porovnáme.

V situaci (2) a (3) postupujeme analogicky jako v situaci (1). Ve (3) situaci potřebyme vypočítat hodnoty  $(1-\alpha/2)$ -kvantilu gamma rozdělení s parametry  $\frac{n}{2}$  (shape) a 2 (scale). K tomu použijeme funkci  $qgamma()$ .

- (1) `alpha <- seq(...)` ... posl.  $\alpha$  od 0.01 do 0.99 s dílkem minimálně  $d=512$   
`yfit <- qchisq(1-alpha, ...)` ... hodnoty kvantilů  $\chi^2_{d-1}(1-\alpha)$  nad posl.  $\alpha$  ( $d=512$ )  
`zfit <- qnorm(1-alpha/2, ...)^2` ... druhé mocniny kvantilů  $u_{1-\alpha/2}$  nad posl.  $\alpha$  ( $d=512$ )  
`par(mar=...)` ... strojí grafu 4,4,2,1  
`plot(alpha, yfit, ...)` ... graf s křivkou kvantilů  $\chi^2_{d-1}(1-\alpha)$  (např. modrá plná křivka)  
`lines(alpha, zfit, ...)` ... křivka druhých mocnin kvantilů  $u_{1-\alpha/2}$  (např. červená přerušovaná křivka)  
`mtext(expression(alpha), ...)` ... popisek osy x ( $\alpha$ )  
`legend(...)` ... legenda
- (2) `n <- ...` ... zadána hodnota parametru  $n$   
`yfit <- qf(...)` ... hodnoty kvantilů  $F_{1,n}(1-\alpha)$  nad posl.  $\alpha$  ( $d=512$ )  
`zfit <- qt(...)^2` ... druhé mocniny kvantilů  $t_n(1-\alpha/2)$  nad posl.  $\alpha$  ( $d=512$ )  
`plot(alpha, yfit, ...)` ... graf s křivkou kvantilů  $F_{1,n}(1-\alpha)$  (např. modrá plná křivka)  
`lines(alpha, zfit, ...)` ... křivka druhých mocnin kvantilů  $t_n(1-\alpha/2)$  (např. červená přerušovaná křivka)  
`mtext(...)` ... popisek osy x ( $\alpha$ )  
`legend(...)` ... legenda
- (3) `yfit <- qchisq(...)` ... hodnoty kvantilů  $\chi^2_n(1-\alpha)$  nad posl.  $\alpha$  ( $d=512$ )  
`zfit <- qgamma(1-alpha, shape = n/2, scale = 2)` ... hodnoty kvantilů  $\Gamma_{\frac{n}{2}, 2}(1-\alpha)$   
`plot(...)` ... graf s křivkou kvantilů  $\chi^2_n(1-\alpha)$  (např. modrá plná křivka) nad posl.  $\alpha$  ( $d=512$ )  
`...`  
`legend(...)` ... legenda


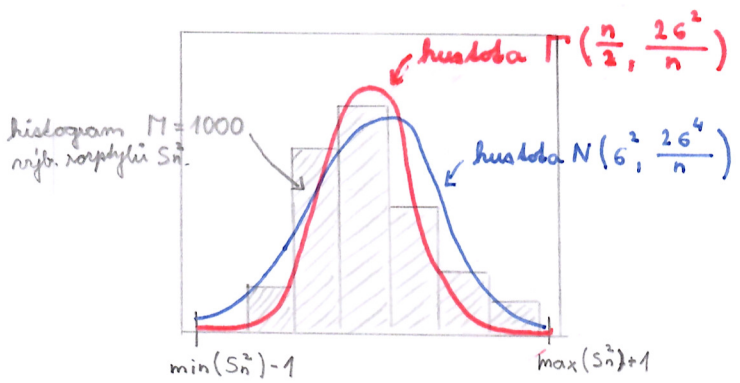
Závěr: Z vykreslených grafů vidíme že (1)  $\chi^2_{d-1}(1-\alpha)$  a  $(u_{1-\alpha/2})^2$  jsou identické; (2)  $F_{1,n}(1-\alpha)$  a  $(t_n(1-\alpha/2))^2$  jsou identické; (3)  $\chi^2_n(1-\alpha)$  a  $\Gamma_{\frac{n}{2}, 2}(1-\alpha)$  jsou identické, tedy, že všechny tři rovnosti skutečně platí.

2.4

V tomto příkladu si graficky ověříme, že pokud náhodná veličina  $X \sim N(\mu, \sigma^2)$ , potom pro výběrový rozptyl  $S_n^2$ , resp. pro výběrovou sm. odchylku  $S_n$  platí:

- (1)  $S_n^2 \sim \Gamma(\frac{n}{2}, \frac{2\sigma^2}{n})$  exaktně
- (2)  $S_n^2 \sim N(\sigma^2, \frac{2\sigma^4}{n})$  asymptoticky
- (3)  $S_n \sim \Gamma_G(\sqrt{\frac{2\sigma^2}{n}}, 2, \frac{n}{2})$  exaktně
- (4)  $S_n \sim N(\sigma, \frac{\sigma^2}{2n})$  asymptoticky.

$\Gamma(\frac{n}{2}, \frac{2\sigma^2}{n})$  je gamma rozdělení s parametry shape =  $\frac{n}{2}$  a scale =  $\frac{2\sigma^2}{n}$ .  $\Gamma_G(\sqrt{\frac{2\sigma^2}{n}}, 2, \frac{n}{2})$  je zobecněné gamma rozdělení s parametry scale =  $\sqrt{\frac{2\sigma^2}{n}}$ , d = 2 a k =  $\frac{n}{2}$ .



Nejprve naprogramujeme funkci rozdělení  $S_n^2$  -  $S_n()$ , která pro zadání  $\sigma$  a  $n$  vrátí dvojici výše makrobných histogramů. Pomocí funkce makroce vytvoříme animaci. Hustotu rozdělení  $\Gamma(\frac{n}{2}, \frac{2\sigma^2}{n})$  vypočítáme pomocí funkce  $dgamma()$ . Hustotu rozdělení  $\Gamma_G(\sqrt{\frac{2\sigma^2}{n}}, 2, \frac{n}{2})$  vypočítáme pomocí funkce  $dgengamma.stacy()$  z knihovny **VGAM**.

```

Var.n ← function(x) { funkce, jejímž vstupem je náhodný výběr  $X_1, \dots, X_n$  a výstupem výběrový rozptyl  $S_n^2$ .
  n ← length(...) ... délka vektoru x
  Sn2 ← ...  $\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$  ...  $\frac{1}{n} (\text{sum}((x - \text{mean}(x))^2))$ 
  return(...) ... vrátí hodnotu  $S_n^2$ 
}
  
```

```

rozdeleni_Sn2_Sn ← function(sigma, n, M=1000) {
  Sn2 ← replicate(M, Var.n(rnorm(n, 0, sigma))) ... vstupem je vektor  $M=1000$  výběr rozptylů  $S_n^2$ .
  Sn ← sqrt(...) ...  $\sqrt{Sn2}$  ... výběr vektor pseudonáhodných čísel
  x.Sn2 ← seq(...) ... posl. od min(Sn2) do max(Sn2) o délce 512 o délce n z rozdělení  $N(0, \sigma^2)$  a
  x.Sn ← seq(...) ... posl. od min(Sn) do max(Sn) o délce 512 vypočítá z něj výběr rozptylů  $S_n^2$ . Toho proved  $M=1000$ .
  y.e ← dgamma(...) ... vektor hodnot hustoty rozdělení  $\Gamma(\frac{n}{2}, \frac{2\sigma^2}{n})$  nad posl. Sn2 (d=512)
  y.a ← dnorm(...) ... vektor hodnot hustoty rozdělení  $N(\sigma^2, \frac{2\sigma^4}{n})$  -11- -11-
  z.e ← VGAM::dgengamma.stacy(xfit.Sn, scale =  $\sqrt{\frac{2\sigma^2}{n}}$ , d=..., k=...) ... vektor hodnot hustoty
  z.a ← dnorm(...) ... vektor hodnot hustoty rozdělení  $N(\sigma, \frac{\sigma^2}{2n})$  nad posl. Sn (d=512)  $\Gamma_G(\sqrt{\frac{2\sigma^2}{n}}, 2, \frac{n}{2})$  nad
  }
  
```

příprava prostředí

```

par(mfrow=..., mar=...) ...  $\square\square$ , okraje 5,4,2,1
hist(Sn2, prob=T, ylim=c(0, as.numeric(max(y.e, y.a))+0.1), density=30, col=..., border=..., ...) ... histogram  $S_n^2$ 
box(bty='o') ... rámeček okolo histogramu
lines(x.Sn2, y.e, ...) ... křivka hustoty  $\Gamma(\frac{n}{2}, \frac{2\sigma^2}{n})$ 
lines(x.Sn2, y.a, ...) ... křivka hustoty  $N(\sigma^2, \frac{2\sigma^4}{n})$ 
  
```

hustota šrafovaná  
výplně histogramu

$S_n^2$

histogram  
 mtext(expression (S[n]^2), ...) ... popisok sy x (S<sub>n</sub><sup>2</sup>)  
 mtext(bquote(paste(mu == 0, ' ', sigma^2 == .(sigma^2), ' ', n == .(n))), ...) ... druhý popisok sy x (μ=0, σ<sup>2</sup>=..., n=...)  
 legend(...) ... legenda

histogram S<sub>n</sub>  
 hist(Sn, prob=..., ylim=c(0, as.numeric(max(zfit.e, zfit.a))+0.1), density=..., col=..., border=..., ...) ... histogram S<sub>n</sub>  
 box(...) ... rámeček okolo grafu  
 lines(x.Sn, z.e, ...) ... křivka hustoty Γ<sub>G</sub>(√(2σ<sup>2</sup>/n), 2, n/2)  
 lines(x.Sn, z.a, ...) ... křivka hustoty N(σ, σ<sup>2</sup>/2n)  
 mtext(expression(...), ...) ... popisok sy x (S<sub>n</sub>)  
 mtext(bquote(paste(...)), ...) ... druhý popisok sy x (μ=0, σ<sup>2</sup>=..., n=...)  
 legend(...) ... legenda

```
n ← seq(...) ... posloupnost 5, 10, 50, 100, 500, 1000
opts ← ani.options()
ani.record(reset = T) ... vymazání obrátek z paměti
saveLatex(for (i in 1:length(n)) {
  rozdeleni_Sn2.Sn(sigma=..., n=n[i])
}, ...) ... animace
```

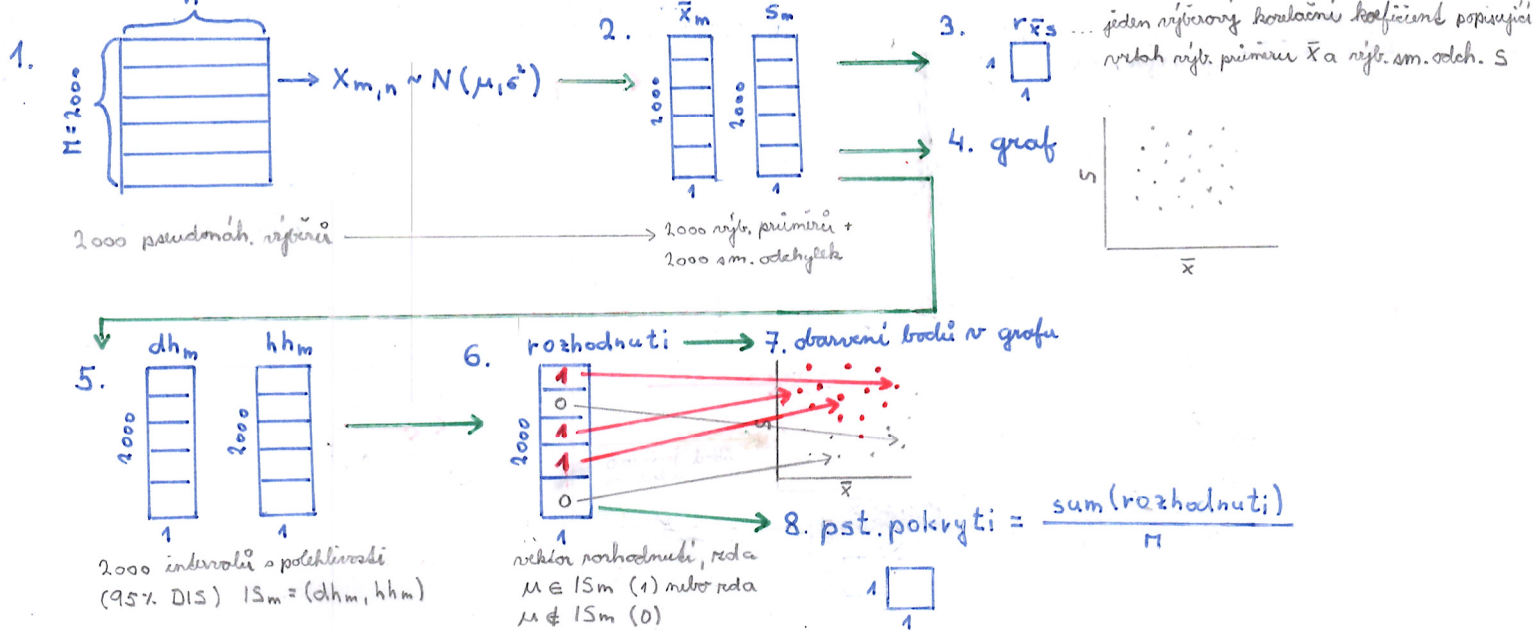
Závěr: Z uvedené animace pro S<sub>n</sub><sup>2</sup> je patrné, že reální rozdílání Γ(n/2, 2σ<sup>2</sup>/n) popisuje rozdílání S<sub>n</sub><sup>2</sup> velmi dobře i pro malé rozsahy náhodných výtěrů n. Pro n → ∞ se rozdílání S<sub>n</sub><sup>2</sup> blíží k normálnímu rozdílání a tedy S<sub>n</sub><sup>2</sup> ~ N(σ<sup>2</sup>, 2σ<sup>4</sup>/n) asymptoticky. Z grafu dále vidíme, jak pro n → ∞ se křivky dvou hustot čím dál více jedná druhé podobají.

Z animace pro S<sub>n</sub> je patrné že reální rozdílání Γ<sub>G</sub>(√(2σ<sup>2</sup>/n), 2, n/2) popisuje rozdílání S<sub>n</sub> velmi dobře i pro malé rozsahy náh. výtěrů n. Pro n → ∞ se rozdílání S<sub>n</sub> tvarem blíží k normálnímu rozdílání N(σ, σ<sup>2</sup>/n). S n → ∞ se také křivky dvou hustot vzájemně čím dál více podobají, a tedy pro n → ∞ se S<sub>n</sub> ~ N(σ, σ<sup>2</sup>/n), tj. S<sub>n</sub>  $\hat{=}$  N(σ, σ<sup>2</sup>/n).


Poznámka: Asymptotické rozdílání S<sub>n</sub><sup>2</sup> i S<sub>n</sub> v praxi často používáme, protože normální rozdílání je jednodušší, než Γ, resp. Γ<sub>G</sub> rozdílání a má škréle vlastnosti. Z malost reálních rozdílání S<sub>n</sub><sup>2</sup> a S<sub>n</sub> je však také velmi užitečná, nicméně často opomíjána.

V tomto příkladu si graficky ověříme nezávislost parametru  $\mu$  a  $\sigma^2$  normálního rozdělení  $N(\mu, \sigma^2)$ . Pomocí grafu si také rozbavíme pravděpodobnost pokrytí 95%. Waldova empirického DIS pro  $\mu$  když  $\sigma^2$  nemáme. Nezávislost  $\mu$  a  $\sigma^2$  a pst. pokrytí 95%. DIS rozhodujeme nejprve na předpokladu, že  $X \sim N(\mu, \sigma^2)$ . Nakonec budeme ujišťovat, zda a případně jak se situace mění, pokud bude homogenní normální rozdělení  $N(150, 10^2) \approx 10\%$  množství rozdělením  $N(150, 20^2)$ , tj. normálním rozdělením se stejnou střední hodnotou, ale větším rozptylem.

Příklad vyřešíme v más ledujících krocích (postup pro  $n=5$ ;  $X \sim N(\mu, \sigma^2)$ ):



9. hraniční čáry



$m_i \dots$  pos. od  $\min(m)$  do  $\max(m)$  s dílem 2000 (osa x)  
 pro každé  $m_i$  vypočítáme hodnotu  $s_i$  (osa y) tak, aby platilo:

$$dh_{m_i} = hh_{m_i} = \mu, \text{ tj. } \underbrace{(m_i - t_{1-\alpha/2} \frac{s_i}{\sqrt{n}})}_{\text{I.}} = \underbrace{\mu}_{\text{II.}} = \underbrace{m_i - t_{\alpha/2} \frac{s_i}{\sqrt{n}}}_{\text{II.}}$$

I.  $m_i - t_{1-\alpha/2} \frac{s_i}{\sqrt{n}} = \mu$

$$s_i = \frac{\mu - m_i}{t_{1-\alpha/2}} \sqrt{n}$$

II.  $m_i - t_{\alpha/2} \frac{s_i}{\sqrt{n}} = \mu$

$$s_i = \frac{\mu - m_i}{t_{\alpha/2}} \sqrt{n}$$

$$\left. \begin{matrix} t_{1-\alpha/2} = -t_{\alpha/2} \\ \Rightarrow \end{matrix} \right\} s_i = \left| \frac{\mu - m_i}{t_{1-\alpha/2}} \sqrt{n} \right| = \left| \frac{\mu - m_i}{t_{\alpha/2}} \sqrt{n} \right|$$

Pročtěte v rámci příkladu máme rozhodnout nezávislost  $\mu$  a  $\sigma^2$  a aktuální pst. pokrytí  $1 - \hat{\alpha}$  v řadě různých situacích ((1)  $X \sim N(\mu, \sigma^2)$ ; (2)  $X \sim pN(\mu, \sigma^2) + (1-p)N(\mu, \sigma_2^2)$ ) x ((a)  $n=5$ ; (b)  $n=50$ ; (c)  $n=100$ ), bude nejlepší vytvořit funkci pokrytí ( ), která pro zadání  $\mu, \sigma_1, \sigma_2, n, M, p$  a  $\alpha$  vrátí graf s hodnotou výřb. korel. koef.  $r_{\bar{x}, s}$  a aktuální pst. pokrytí  $1 - \hat{\alpha}$ .

Na nákladě výřb. korel. koeficientu  $r_{\bar{x}, s}$  rozhodujeme pro každou situaci nezávislost mezi  $\mu$  a  $\sigma^2$ . Nakonec pro každou situaci porovnáme hodnotu aktuální pst. pokrytí  $(1 - \hat{\alpha})$  s nominální pst. pokrytí  $(1 - \alpha) = 0.95$  Waldova 95% empirického DIS pro  $\mu$  když  $\sigma^2$  nemáme.

pokryti ← function (mu = <sup>150</sup>..., sigma = <sup>10</sup>..., sigma2 = sigma, n = <sup>5</sup>..., M = <sup>1000</sup>..., p = <sup>0.9</sup>...) {

**generování dat**  
 $X \leftarrow \text{matrix}(NA, \dots, \dots)$  ... příprava prázdné matice dimenze  $M \times n$   
**for**(i in 1:M) { cyklus: univerzální kód pro generování homogenních dat (pokud  $\sigma = \sigma_2$ ) i heterogenních dat (směsí) (pokud  $\sigma \neq \sigma_2$ )  
 $\text{bin} \leftarrow \text{rbinom}(n, 1, p)$  ... posl. n hodnot  $\sim \text{Bin}(1, p)$  ...  $X=1$  s p,  $X=0$  s  $(1-p)$   
 $X[i, ][\text{bin} == 1] \leftarrow \text{rnorm}(\text{sum}(\text{bin} == 1), \text{mu}, \text{sigma})$  ... na i-tý řádek matice X na pozici, kde  $\text{bin} == 1$  vloží hodnoty  $\sim N(\mu, \sigma^2)$   
 $X[i, ][\text{bin} == 0] \leftarrow \text{rnorm}(\text{sum}(\text{bin} == 0), \text{mu}, \text{sigma2})$  ... na i-tý řádek matice X na pozici, kde  $\text{bin} == 0$  vloží hodnoty  $\sim N(\mu, \sigma_2^2)$   
**}** **! pozor na syntaxi funce rnorm(n, mean =  $\mu$ , sd =  $\sigma$ ) !**

**podkladi**  
 $m \leftarrow \text{apply}(X, 1, \text{mean})$  ... vektor nřj. průměrů  $\bar{x}_m$  ( $d=2000$ )  
 $s \leftarrow \text{apply}(\dots)$  ... vektor nřj. sm. odchylek  $s_m$  ( $d=2000$ )  
 $r \leftarrow \text{round}(\text{cor}(\dots), \text{digits} = \dots)$  ... nřj. korel. koef. cor(m, s) zaokr. na 4 des. místa ( $d=1$ )  
**připrava**  
 $\text{dh} \leftarrow \bar{x}_m - t_{n-1}(1-\alpha/2) \frac{s}{\sqrt{n}}$  ... vektor dolních hranic 95% DIS pro  $\mu$  když  $\sigma^2$  neznáme ( $d=2000$ )  
 $\text{hh} \leftarrow \bar{x}_m + t_{n-1}(\alpha/2) \frac{s}{\sqrt{n}}$  ... vektor horních hranic -||- -||- ( $d=2000$ )  
 $\text{rozhodnuti} \leftarrow (\text{dh} < \text{mu}) \& (\text{mu} < \text{hh})$  ... vektor rozhodnutí, zda  $\mu = 150 \in IS_m$ ,  $m=1, \dots, 2000$  ( $d=2000$ )  
 $\text{pst.pokryti} \leftarrow \frac{\sum(\text{rozhodnuti})}{M}$  ... aktuální podíl pokrytí  $1-\hat{\alpha}$

**grafu**  
 $\text{par}(\dots)$  ... nastave 5, 4, 2, 1  
 $\text{plot}(m, s, \text{asp} = T, \text{xlim} = c(130, 170), \text{ylim} = c(0, 30), \text{cex} = 0.4, \dots)$  ... graf; zde body ( $\bar{x}_m, s_m$ )  
 $\text{mtext}(\text{expression}(\text{bar}(x)), \dots)$  ... popisek osy x, řj.  $\bar{x}$   
 $\text{mtext}(\text{bquote}(\text{paste}(n == .(n), ', ', r == .(r), ', ', 1 - \alpha == .(1 - \alpha), ', ', 1 - \widehat{\alpha} == .(\text{pst.pokryti}), \text{sep} = ' ')), \dots)$  ... druhý popisek osy x  
**vykreslení**  
 $\text{points}(m[\text{rozhodnuti} == 1], s[\text{rozhodnuti} == 1], \text{col} = \text{coral}, \text{cex} = \dots)$  ... červené obarvení bodů ( $\bar{x}_m, s_m$ ), pro které platí, že  $\mu \in IS_m$ .  
 $\text{mi} \leftarrow \text{seq}(\dots)$  ... posl. od  $\min(m)$  do  $\max(m)$  s délkou 2000  
 $\text{si} \leftarrow \left| \frac{m_i - \mu}{t_{n-1}(1-\alpha/2)} \sqrt{n} \right|$  ... vektor hodnot  $s_i$  odpovídající hodnotám  $m_i$  tak, aby platilo  $\text{dh}_{m_i} = \text{hh}_{m_i} = \mu$   
 $\text{lines}(m_i, s_i, \dots)$  ... hranicní čáry, kde  $\text{dh}_{m_i} = \text{hh}_{m_i} = \mu$

$X \sim N(\mu, \sigma^2)$ ,  $n=5$ : **pokryti(n=5)** ... použije funce pokryti() k vykreslení grafu pro homogenní data ( $n=5$ )  
 $X \sim pN(\mu, \sigma^2) + (1-p)N(\mu, \sigma_2^2)$ ,  $n=5$ : **pokryti(sigma2=20, n=5)** ... vykreslení grafu pro směs ( $n=5$ )

Z dvou obrázků vidíme, že pro homogenní data i pro data s 10% příměsí hodnot s větší rozptylem jsou parametry  $\mu$  a  $\sigma^2$  nezávislé. Vykreslení body jsou nahodile rozmístěny po ploše grafu a hodnota nřj. korel. koeficientu je velmi blízko nule.

Z grafu dále vidíme, že pro homogenní data i pro směs se hodnota aktuálního podílu pokrytí  $(1-\hat{\alpha})$  95% Waldova empirického DIS pro  $\mu$  když  $\sigma^2$  neznáme pohybuje okolo nominálního podílu pokrytí  $(1-\alpha) = 0.95$ .

Jediný rozdíl, který u dvou grafů pozorujeme, je, že v případě směsi jsou body z hlediska osy y více rozptálené (mají větší rozptyl). To odpovídá 10% příměsí dat s větší rozptylem.

Analogicky bychom vykreslili a rozhodnuli dvojici grafů pro (h)  $n=50$  a (c)  $n=100$ .

V tomto příkladu si pomocí simulační studie virtualizujeme aktuální post pokrytí 95% Waldova empirického DIS pro  $\mu$  při známém  $\sigma^2$ . Aktuální post pokrytí si ukážeme přímo na grafu s vyresanými hranicemi  $M=100$  95% DIS. Hodnotu aktuálního postu pokrytí prostudujeme ve třech různých situacích:

- (1) u homogenních dat  $X \sim N(\mu, \sigma^2)$ ;
- (2) u dat  $X \sim N(\mu, \sigma^2) \Delta$  10% směsí hodnot se stejnou střední hodnotou a různým rozptylem, tj. + 10% hodnot  $\sim N(\mu, \sigma_2^2)$ ;
- (3) u dat  $X \sim N(\mu, \sigma^2) \Delta$  10% směsí hodnot se stejným rozptylem a různou střední hodnotou, tj. + 10% hodnot  $\sim N(\mu_2, \sigma^2)$ .

Poznámka: Analogickou simulační studii bychom mohli vytvořit pro libovolný typ IS (dvoustanný, levostanný, pravostanný, 90%, 95%, 99%, ..., parametry  $\mu, \sigma^2, \lambda, \mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \dots$ )

**Řešení příkladu:** Nejprve vygenerujeme  $M=100$  náh. výběrů. Z každého výběru vypočítáme výběr. průměr  $\bar{x}_m$ , výběrovou sm. odchylku  $s_m$  a nakonec dolní hranici  $dh_m$  a horní hranici  $hh_m$  95% Waldova emp. DIS pro  $\mu$ , když  $\sigma^2$  známe.  $IS = (dh, hh) = (m - u_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}; m - u_{\alpha/2} \frac{\sigma}{\sqrt{n}})$ . Dále vytvoříme vektor rozhodnutí, pro který platí, že rozhodnutí<sub>m</sub> = 1, pokud  $\mu = 5 \in IS_m$  a rozhodnutí<sub>m</sub> = 0, pokud  $\mu = 5 \notin IS_m$ . Dále vypočítáme aktuální post pokrytí  $1 - \hat{\alpha}$  jako  $(1 - \hat{\alpha}) = \frac{I(\mu \in IS)}{M} = \frac{\sum(\text{rozhodnutí})}{M}$  a aktuální hl. významnosti  $\hat{\alpha} = 1 - (1 - \hat{\alpha})$ . Následně vyresíme graf, kde každý IS bude reprezentován svislou úsečkou, přičemž  $IS_m$ , pro které  $\mu = 5 \notin IS_m$ , barvně odlišíme. Nakonec stanovíme hranice 95% DIS pro aktuální post pokrytí  $(1 - \hat{\alpha})$  podle vzorce:

$$(dh_{1-\hat{\alpha}}; hh_{1-\hat{\alpha}}) = ((1 - \hat{\alpha}) - u_{1-\alpha/2} \hat{SE}; (1 - \hat{\alpha}) - u_{\alpha/2} \hat{SE}),$$

kde  $\hat{SE} = \sqrt{\frac{\hat{\alpha}(1 - \hat{\alpha})}{M}}$ . Hodnoty  $(1 - \hat{\alpha})$ ,  $(1 - \hat{\alpha})$ ,  $dh_{1-\hat{\alpha}}$ ,  $hh_{1-\hat{\alpha}}$  vložíme do souhrnné tabulky.

Protože v rámci příkladu máme aktuální post pokrytí porovnat v šesti situacích, vytvoříme funkci `DIS_mu()`, která pro zadání  $n, \mu_1, \mu_2, \sigma, \sigma_2, M, \rho$  a  $\alpha$  vyresí graf a vrátí příslušnou souhrnnou tabulku výsledků. Šestici grafů a tabulek potom vygenerujeme pomocí této funkce.

```
DIS_mu <- function(n, mu = ..., mu2 = mu, sigma = sqrt(15), sigma2 = sigma, M = 100, rho = 0.9, alpha = 0.05) {
```

```

  # příprava dat
  X <- matrix(...) ... příprava NA matice dimenze M x n
  for(i in 1:M) { cyklus; analogický jako v příkladu 2.5
    bin <- rbinom(...)
    X[i, ] <- rnorm(...) ... X ~ N(mu, sigma^2)
    X[i, ] <- rnorm(...) ... X ~ N(mu2, sigma2^2)
  }

  # podkladů
  m <- apply(...) ... vektor výběr. průměrů x_m (d=100)
  s <- apply(...) ... vektor výběr. sm. odchylek s_m (d=100)
  dh <- m - u_{1-alpha/2} * sigma / sqrt(n) ... vektor dolních hranic 95% DIS pro mu když sigma^2 známe (d=100)
  hh <- m - u_{alpha/2} * sigma / sqrt(n) ... vektor horních hranic (d=100)
  rozhodnuti <- dh < mu < hh ... viz příklad 2.5

```



připrav  
 $a.pst.pokryti \leftarrow \frac{\sum(rozhodnuti)}{n}$  ... aktuální pod pokrytí  $(1-\hat{\alpha})$   
 $a.alpha \leftarrow 1-(1-\hat{\alpha})$  ... aktuální hl. významnosti  $\hat{\alpha}$   
 $x \leftarrow 1:M$  ... diskretní posloupnost čísel 1, 2, 3, ..., 99, 100

grafu  
 $par(...)$  ... okraje  $4 \times \frac{1}{5}$   
 $plot(x, dh, type=..., ylim=c(min(dh), max(hh)), xlab='', ylab=expression(...), ...)$  ... příprava prádného grafu  
 $mtext(bquote(...), ...)$  ... popisek osy x ...  $1-\hat{\alpha} = \dots$   
 $mtext(paste(...), ...)$  ... druhý popisek osy x ...  $n = \dots$   
 $segments(x, dh, x, hh, col='grey40')$  ... dokreslení svislých úseček  $IS_m$   
 $segments(x[rozhodnuti == 0], dh[rozhodnuti == 0], ...)$  ... obarvení úseček  $IS_m$ , pro které  $u = 5 \notin IS$ .  
 $abline(h=mu)$  ... vodorovná čára v hodnotě  $u = 5$

souhrnná tabulka  
 $SE \leftarrow \sqrt{\frac{\hat{\alpha}(1-\hat{\alpha})}{n}}$  ... standardní chyba  $\hat{SE}$  pod pokrytí  $(1-\hat{\alpha})$   
 $dh.alpha \leftarrow 1-\hat{\alpha} - u_{1-\alpha/2} \hat{SE}$  ... dolní hranice 95% DIS pro  $(1-\hat{\alpha})$ , tj.  $dh_{1-\hat{\alpha}}$   
 $hh.alpha \leftarrow 1-\hat{\alpha} + u_{1-\alpha/2} \hat{SE}$  ... horní hranice -||- -||- , tj.  $hh_{1-\hat{\alpha}}$   
 $tab \leftarrow data.frame(1-\hat{\alpha}, 1-\hat{\alpha}, dh_{1-\hat{\alpha}}, hh_{1-\hat{\alpha}})$  ... souhrnná tabulka výsledků  
 $return(...)$  ... navrát souhrnnou tabulku sob.

(1)  
 $X \sim N(5, 15), n=5$ :  $DIS\_mu(n=5)$  ... použijí fun  $DIS\_mu()$  pro vykreslení grafu a výpáček tabulky  
 $X \sim N(5, 15), n=1000$ :  $DIS\_mu(n=1000)$  ... -||- -||- (n=1000)  
 Analogicky bychom vykreslili dvojice grafů ( $n=5; n=1000$ ) pro každou směs.

Poznámka: Komentáře jednotlivých grafů viz radání samostatné práce.  
 Nezapomeňte u každého grafu rozhodnout, zda je DIS konzervativní nebo liberální. Závěr uvedte v řešení jako komentář v R-Skriptu (varianta .R) nebo slavně v pdf souboru (varianta Rnw).