

Ústav matematiky a statistiky  
Přírodovědecká fakulta  
Masarykova univerzita

---

## Štatistická inferencia I

*Zadania prikladov a domácich úloh a niektoré riešenia*

Stanislav Katina

[katina@math.muni.cz](mailto:katina@math.muni.cz)

14. decembra 2014

# **Obsah**

1	Model rozdelenia pravdepodobnosti a štatistický model	1
2	Charakteristiky polohy a variability a štatistická grafika	19
3	Testovanie hypotéz	20

# 1 Model rozdelenia pravdepodobnosti a štatistický model

**Príklad 1 (porovnanie dvoch typov modelov)** Model rozdelenia pravdepodobnosti je modelom náhodnej premennej  $X$ , napr. model rozdelenia pravdepodobnosti náhodnej premennej  $X$  šírka dolnej čeluste alebo (2) model rozdelenia pravdepodobnosti náhodnej premennej  $X$  hrúbka kožných rias u dospelých zdravých žien. Štatistický model je modelom náhodnej premennej  $Y|X$  ( $Y$  kauzálnie závisí na  $X$ ), napr. (1) model závislosti náhodnej premennej  $Y$  šírka dolnej čeluste na premennej  $X$  pohlavie alebo (2) model závislosti náhodnej premennej  $Y$  hrúbka kožných rias u dospelých zdravých žien na premennej  $X$  BMI. Všimnime si, že náhodné premenné označujeme  $X$  alebo  $Y$  podľa toho, aký model ich charakterizuje.

pred

**Príklad 2 (jednoduchý náhodný výber)** *V jednoduchom náhodnom výbere s rozsahom  $n$  z populácie s konečným rozsahom  $N$  má každý prvok rovnakú pravdepodobnosť vybratia. Ak vyberáme bez vrátenia, hovoríme o jednoduchom náhodnom výbere bez vrátenia<sup>1</sup> (Dalgaard 2008). Ak vyberáme s vrátením, hovoríme o jednoduchom náhodnom výbere s vrátením<sup>2</sup>.* Majme množinu  $\mathcal{M}$  s  $N = 10$  prvkami a chceme z nej vybrať  $n = 3$  prvkov (a) bez vrátenia a (b) s vrátením. Kolko máme možností? Ako vyzerá jedna takáto možnosť, ak ide o množinu  $\mathcal{M} = \{1, 2, \dots, 10\}$ . Zopakujte to isté pre  $N = 100$ ,  $n = 30$  a množinu  $\mathcal{M} = \{1, 2, \dots, 100\}$ .

cvič

## Riešenie aj v

(a) Spolu máme  $\binom{N}{n}$  možných náhodných výberov. Ak  $N = 10$  a  $n = 3$ , potom kombinačné číslo  $\binom{N}{n} = \frac{N!}{(N-n)!n!} = \binom{10}{3} = 120$  možností. Ak  $N = 100$  a  $n = 30$ , potom  $\binom{N}{n} = \binom{100}{30} = 2.937234 \times 10^{25}$  možností.

```

1 choose(10,3) # pocet vsetkych moznych vyberov bez vratenia
2 choose(100,30)
3 library(utils)
4 combn(10,3) # pocet vsetkych moznych vyberov bez vratenia
5 combn(100,30)
6 sample(x=1:10,size=3,replace = FALSE) # jednoduchy nahodny vyber bez vratenia
7 sample(x=1:100,size=30,replace = FALSE)

```

(b) Spolu máme  $\binom{N+n-1}{n}$  možných náhodných výberov. Ak  $N = 10$  a  $n = 3$ , potom  $\binom{N+n-1}{n} = \frac{(N+n-1)!}{(N-1)!n!} = \binom{10+3-1}{3} = 220$  možností. Ak  $N = 100$  a  $n = 30$ , potom  $\binom{N+n-1}{n} = \binom{100+30-1}{30} = 2.009491 \times 10^{29}$  možností.

```

1 choose(10+3-1,3) # pocet vsetkych moznych vyberov s vratenim
2 choose(100+30-1,30)
3 library(utils)
4 combn(10+3-1,3) # pocet vsetkych moznych vyberov s vratenim
5 combn(100+30-1,30)
6 sample(x=1:10,size=3,replace = TRUE) # jednoduchy nahodny vyber s vratenim
7 sample(x=1:100,size=30,replace = TRUE)

```

**Príklad 3 (jednoduchý náhodný výber)** Nech je skupina ľudí označená identifikačnými číslami (ID) od 1 do 30. Vyberte (a) náhodne 5 ľudí z 30 bez návratu, (b) náhodne 5 ľudí z 30 s návratom a nakoniec (c) náhodne 5 ľudí z 30 bez návratu, kde ľudia s ID od 28 do 30 majú pravdepodobnosť vybratia 4× väčšiu ako ľudia s ID od 1 do 27.

cvič

<sup>1</sup>Kombinácie bez opakovania  $n$ -tej triedy z  $N$  prvkov množiny  $\mathcal{M}$ .

<sup>2</sup>Kombinácie s opakováním  $n$ -tej triedy z  $N$  prvkov množiny  $\mathcal{M}$ .

**Riešenie v **

```
1 | sample(x=1:30, size=5, replace = FALSE)
2 | sample(x=1:30, size=5, replace = TRUE)
3 | sample(x=1:30, size=5, prob=c(rep(1/39,27),rep(4/39,3)), replace = FALSE)
```

**Príklad 4 (normálne rozdelenie)** Majme náhodnú premennú  $X$  (môže to byť napr. výška postavy 10-ročných dievčat) a predpokladáme, že má normálne rozdelenie s parametrami  $\mu$  (stredná hodnota) a  $\sigma^2$  (rozptyl), čo zapisujeme ako  $X \sim N(\mu, \sigma^2)$ ,  $\mu = 140.83$ ,  $\sigma^2 = 33.79$ . Normálne rozdelenie predstavuje model rozdelenia pravdepodobnosti pre túto náhodnú premennú. Vypočítajte pravdepodobnosť  $\Pr(a < X < b) = \Pr(X < b) - \Pr(X < a) = F_X(b) - F_X(a)$ , kde  $a = \mu - k\sigma$ ,  $b = \mu + k\sigma$ ,  $k = 1, 2, 3$ .<sup>3</sup> Nakreslite hustotu rozdelenia pravdepodobnosti, vyfarbite oblasť medzi bodmi  $a$  a  $b$  a popíšte osi  $x$  a  $y$  tak, ako je uvedené na obrázku 1.

cvič

**Riešenie (aj v )**; (pozri obrázok 1)

$a = \mu - \sigma = 135.0171$ ,  $b = \mu + \sigma = 146.6429$ ,  
 $\Pr(|X - \mu| > \sigma) = 0.3173$ ,  $\Pr(|X - \mu| < \sigma) = 1 - 0.3173 = 0.6827$ ,  
 $a = \mu - 2\sigma = 129.2042$ ,  $b = \mu + 2\sigma = 152.4558$ ,  
 $\Pr(|X - \mu| > 2\sigma) = 0.0455$ ,  $\Pr(|X - \mu| < 2\sigma) = 1 - 0.0455 = 0.9545$ ,  
 $a = \mu - 3\sigma = 123.3913$ ,  $b = \mu + 3\sigma = 158.2687$ ,  
 $\Pr(|X - \mu| > 3\sigma) = 0.0027$ ,  $\Pr(|X - \mu| < 3\sigma) = 1 - 0.0027 = 0.9973$ .

Alternatívny výpočet cez štandardizované normálne rozdelenie (syn. normálne normované rozdelenie) je nasledovný:

```
1 | mu <- 0
2 | sig <- 1
3 | bin <- seq(mu-3*sig, mu+3*sig, by=sig)
4 | pnorm(bin[7]) - pnorm(bin[1]) # 0.9973002
5 | pnorm(bin[6]) - pnorm(bin[2]) # 0.9544997
6 | pnorm(bin[5]) - pnorm(bin[3]) # 0.6826895
```

Dostaneme pravidlo  $68.27 - 95.45 - 99.73$  (tzv. „miery normálneho rozdelenia“).

**Príklad 5 (normálne rozdelenie)** Majme  $X \sim N(\mu, \sigma^2)$ , kde  $\mu = 150$ ,  $\sigma^2 = 6.25$ . Vypočítajte  $a = \mu - x_{1-\alpha}\sigma$  a  $b = \mu + x_{1-\alpha}\sigma$  tak, aby  $\Pr(a \leq X \leq b) = 1 - \alpha$ , bola rovná 0.90, 0.95 a 0.99. Číslo  $x_{1-\alpha}$  je kvantil normovaného rozdelenia, t.j.  $\Pr(Z = \frac{X-\mu}{\sigma} < x_{1-\alpha}) = 1 - \alpha$ ,  $Z \sim N(0, 1)$ . Nakreslite hustotu rozdelenia pravdepodobnosti, vyfarbite oblasť medzi bodmi  $a$  a  $b$  a popíšte osi  $x$  a  $y$  tak, ako je uvedené na obrázku 2.


cvič

Dostaneme pravidlo  $90 - 95 - 99$  (tzv. „upravené miery normálneho rozdelenia“). Použili sme nerovnosť  $\Pr(u_{\alpha/2} < Z < u_{1-\alpha/2}) = \Phi(u_{1-\alpha/2}) - \Phi(u_{\alpha/2}) = 1 - \alpha$ , kde  $\Phi$  je distribučná funkcia normálneho normovaného rozdelenia a všeobecne  $\alpha \in (0, 1/2)$ ; v príklade  $\alpha = 0.1, 0.05$  a  $0.01$ . Pozri obrázok 2.


**Príklad 6 (normálne rozdelenie)** Predpokladajme model normálneho rozdelenia  $N(132, 13^2)$  pre systolický krvný tlak. Aká časť populácie ( $v\%$ ) bude mať hodnoty väčšie ako  $160 \text{ mm Hg}$ ?

cvič

<sup>3</sup>Pravdepodobnosť  $\Pr(a < X < b) = \Pr(a \leq X \leq b)$ , pretože pravdepodobnosť v bode (tu  $a$  a  $b$ ) je rovná nule pre spojité premenné, t.j.  $\Pr(a) = \Pr(b) = 0$ . Pre diskrétné premenné to neplatí.



Obr. 1: Upravené miery normálneho rozdelenia; krivka hustoty s vyfarbeným obsahom pod touto krívkou medzi príslušnými kvantilmi na osi  $x$ ; obsah je rovný pravdepodobnosti výskytu subjektov s danou normovanou výškou v rozpäti týchto kvantilov



Obr. 2: Upravené miery normálneho rozdelenia; krivka hustoty s vyfarbeným obsahom pod touto krívkou medzi príslušnými kvantilmi na osi  $x$ ; obsah je rovný pravdepodobnosti výskytu subjektov s danou normovanou výškou v rozpäti týchto kvantilov

**Príklad 7 (binomické rozdelenie)** Predpokladajme, že počet ľudí uprednostňujúcich liečbu A pred liečbou B sa správa podľa modelu binomického rozdelenia s parametrami  $p$  (pravdepodobnosť výskytu udalosti) a  $N$  (rozsah náhodného výberu), ozn.  $\text{Bin}(N, p)$ , kde  $N = 20$ ,  $p = 0.5$ , t.j. ľudia preferujú oba typy liečby rovnako. (a) Aká je pravdepodobnosť, že bude 16 a viac pacientov uprednostňovať liečbu A pred liečbou B? (b) Aká je pravdepodobnosť, že bude 16 a viac a zároveň 4 alebo menej pacientov uprednostňovať liečbu A pred liečbou B?

cvič

### Riešenie (aj v R)

(a)  $\Pr(X \geq 16) = 1 - \sum_{i:x_i \leq 15} \Pr(X = x_i) = 1 - \sum_{i:x_i \leq 15} \binom{N}{x_i} p^{x_i} (1-p)^{N-x_i} = 1 - \sum_{i:x_i \leq 15} \binom{20}{x_i} 0.5^{x_i} (1-0.5)^{20-x_i} = 0.006$ .

```
1 | pbinom(16, size=20, prob=0.5) # 0.9987116
2 | 1-pbinom(16, size=20, prob=0.5) # 0.001288414
```

Z vyššie uvedeného R-kódu vyplýva, že ide o pravdepodobnosť  $\Pr(X \leq 16)$  a  $\Pr(X > 16)$ , ale my potrebujeme  $\Pr(X \geq 16)$ . Preto R-kód upravíme nasledovne

```
1 | 1-pbinom(15, size=20, prob=0.5) # 0.005908966
```

```
2 | sum(choose(20, 16:20)*0.5^(16:20)*0.5^(20-16:20)) # 0.005908966
```

(b)  $\Pr(X \leq 4, X \geq 16) = 1 - \sum_{i:x_i \leq 15} \Pr(X = x_i) + \sum_{i:x_i \leq 4} \Pr(X = x_i) = 0.012$ . Táto pravdepodobnosť je dvojnásobkom predchádzajúcej pravdepodobnosti, lebo  $Bin(N, 0.5)$  je symetrické okolo 0.5, t.j.

```
1 | 1-pbinom(15, size=20, prob=0.5) + pbinom(4, size=20, prob=0.5) # 0.01181793
```

**Príklad 8 (binomické rozdelenie)** Predpokladajme, že  $\Pr(vír) = 0.533 = p_1$  je pravdepodobnosť výskytu dermatoglyfického vzoru vír na palci pravej ruky mužov českej populácie a  $\Pr(\text{ostatné}) = 0.467 = p_2$  je pravdepodobnosť výskytu ostatných vzorov na palci pravej ruky mužov českej populácie, pričom  $X$  je počet vírov a  $Y$  je počet ostatných vzorov, kde  $X \sim Bin(N, p_1)$  a  $Y \sim Bin(N, p_2)$ . Vypočítajte (1)  $\Pr(X \leq 120)$ , keď  $N = 300$  a (2)  $\Pr(Y \leq 120)$ , keď  $N = 300$ .

cvič

**Príklad 9 (parametre)** Príklady parametrov  $\theta$  – stredná hodnota  $\mu$ , rozptyl  $\sigma^2$ , korelačný koeficient  $\rho$ , pravdepodobnosť  $p$  výskytu nejakej udalosti, rozdiel dvoch stredných hodnôt  $\mu_1 - \mu_2$ , podiel dvoch rozptylov  $\sigma_1^2/\sigma_2^2$ , rozdiel dvoch korelačných koeficientov  $\rho_1 - \rho_2$ , rozdiel dvoch pravdepodobností  $p_1 - p_2$  a pod.

pred

**Príklad 10 (binomické rozdelenie)** Ak  $X \sim Bin(N, \theta)$ ,  $\theta = p \in \langle 0, 1 \rangle$ , potom  $\mathcal{Y}_\theta$  je rovnaký pre všetky  $\theta$  a koinciduje s výberovým priestorom  $\mathcal{Y} = \{0, 1, \dots, N\}$ .

pred

**Príklad 11 (aproximácia binomického rozdelenia normálnym)** <sup>4</sup> Nech  $\Pr(muž) = 0.515$  znamená pravdepodobnosť výskytu mužov v populácii a  $\Pr(\text{žena}) = 0.485$  pravdepodobnosť výskytu žien. Nech  $X$  je počet mužov a  $Y$  počet žien. Za predpokladu modelu  $Bin(N, p)$  vypočítajte (a)  $\Pr(X \leq 3)$ , ak  $N = 5$ , (b)  $\Pr(X \leq 5)$ , ak  $N = 10$  a (c)  $\Pr(X \leq 25)$ , ak  $N = 50$ . Porovnajte vypočítané pravdepodobnosti s pravdepodobnosťami approximovanými normálnym rozdelením  $N(Np, Npq)$ . Nakreslite hustotu rozdelenia pravdepodobnosti normálneho rozdelenia a superponujte ju pravdepodobnosťou funkciou binomického rozdelenia tak, ako je uvedené na obrázku 3. Nakreslite distribučnú funkciu normálneho rozdelenia a superponujte ju distribučnou funkciou binomického rozdelenia tak, ako je uvedené na obrázku 4.

cvič

**Príklad 12 (normálne rozdelenie)** Model pre náhodný výber  $X_1, X_2, \dots, X_n$  je  $N(\mu, \sigma^2)$  a hovoríme, že  $X_1, X_2, \dots, X_n$  pochádza z normálneho rozdelenia, t.j.  $X \sim N(\mu, \sigma^2)$ . Parameter modelu  $N(\mu, \sigma^2)$  je vektor  $\boldsymbol{\theta} = (\mu, \sigma^2)$ . Hustota tohto rozdelenia má tvar  $f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$ ,  $x \in \mathbb{R}$ .

pred


**Príklad 13 (štandardizované normálne rozdelenie)** Model pre náhodný výber  $X_1, X_2, \dots, X_n$  je  $N(0, 1)$  a hovoríme, že  $X_1, X_2, \dots, X_n$  pochádza zo štandardizovaného normálneho rozdelenia, t.j.  $X \sim N(\mu, \sigma^2)$ , kde  $\mu = 0$  a  $\sigma^2 = 1$ . Parameter modelu  $N(\mu, \sigma^2)$  je vektor  $\boldsymbol{\theta} = (0, 1)$ . Hustota tohto rozdelenia má tvar  $\phi(x) = f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$ ,  $x \in \mathbb{R}$ .

pred

**Príklad 14 (dvojrozmerné normálne rozdelenie)** Náhodný vektor  $(X, Y)^T$  má dvojrozmerné normálne rozdelenie

$$N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma}), \text{ kde } \boldsymbol{\mu} = (\mu_1, \mu_2)^T \text{ a } \boldsymbol{\Sigma} = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix},$$

<sup>4</sup>Aproximácia znamená „približné vyjadrenie“, t.j. bud’ nejaké rozdelenie approximujeme iným (majúcim isté výhody oproti tomu, ktoré approximujeme), alebo approximujeme dátu nejakým rozdelením (ktoré popisuje dátu pomocou ľahko interpretovateľných parametrov).



Obr. 3: Aproximácia binomického rozdelenia normálnym pre  $p = 0.515$  a  $N = 5, 10$  a  $50$ ; spojnicový graf superponovaný hustotou (prvý riadok) a distribučnou funkciou (druhý riadok)

s hustotou

$$f(x, y) = \frac{1}{2\pi\sqrt{\sigma_1^2\sigma_2^2(1-\rho^2)}} \exp\left\{-\frac{1}{2(1-\rho^2)}\left\{\frac{(x-\mu_1)^2}{\sigma_1^2} - 2\rho\frac{(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \frac{(y-\mu_2)^2}{\sigma_2^2}\right\}\right\},$$

kde  $(x, y)^T \in \mathbb{R}^2$ ,  $\mu_j \in \mathbb{R}^1$ ,  $\sigma_j^2 > 0$ ,  $j = 1, 2$ ,  $\rho \in \langle -1, 1 \rangle$  sú parametre, potom  $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$ . Výraz v exponente môžeme písat' ako

$$-\frac{1}{2} \begin{pmatrix} x - \mu_1 \\ y - \mu_2 \end{pmatrix}^T \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}^{-1} \begin{pmatrix} x - \mu_1 \\ y - \mu_2 \end{pmatrix},$$

marginálne rozdelenia<sup>5</sup> sú  $X \sim N(\mu_1, \sigma_1^2)$  a  $Y \sim N(\mu_2, \sigma_2^2)$ ,  $\rho$  je koeficient korelácie<sup>6</sup> (pozri obrázok 5). cvič.

**Príklad 15 (dvojrozumné normálne rozdelenie)** (1) Nakreslite hustotu dvojrozumného normálneho rozdelenia  $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  pomocou funkcie `image()` a superponujte ho s kontúrovým grafom hustoty tohto istého rozdelenia pomocou funkcie `contour()`. (2) Nakreslite hustotu dvojrozumného normálneho rozdelenia  $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  pomocou funkcie `persp()`. Hustotu rozsekajte na 12 intervalov, kde hodnoty v týchto intervaloch budú zodpovedať farbám `terrain.colors(12)`. Použite nasledovné parametre


- (a)  $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0$ ;
- (b)  $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0.5$ ;
- (c)  $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1.2, \rho = 0.5$ .

Vzorové riešenie pozri na obrázku 5.

cvič.

<sup>5</sup>Marginné rozdelenie je rozdelenie marginálnej náhodnej premennej, tu  $X$  nezávisle na  $Y$  a naopak  $Y$  nezávisle na  $X$ .

<sup>6</sup>Z tohto príkladu je zrejmé, že na dostatočný popis dvojrozumného normálneho rozdelenia potrebujeme päť parametrov, t.j. strednú hodnotu a rozptyl pre marginálne rozdelenie náhodných premenných  $X$  a  $Y$  a korelačný koeficient  $\rho = \rho(X, Y)$  popisujúci silu lineárneho vzťahu  $X$  a  $Y$ .



Obr. 4: Aproximácia binomického rozdelenia normálnym pre  $p = 0.1$  a  $N = 5, 10$  a  $50$ ; spojnicový graf superponovaný hustotou (prvý riadok) a distribučnou funkciou (druhý riadok)

**Príklad 16 (dvojrozmerné normálne rozdelenie)** Nech náhodnou premennou  $X$  je najväčšia výška mozgovne u mužov (*skull.pH*; v mm) a náhodnou premennou  $Y$  je morfologická výška tváre u mužov (*face.H*; v mm); dátá: *one-sample-correlation-skull.txt*. Nech  $E[X] = \mu_1$  je stredná hodnota najväčšej výšky mozgovne a  $\text{Var}[X] = \sigma_1^2$  je rozptyl najväčšej výšky mozgovne,  $E[Y] = \mu_2$  je stredná hodnota morfologickej výšky tváre a  $\text{Var}[Y] = \sigma_2^2$  je rozptyl morfologickej výšky tváre. Predpokladajme, že najväčšia výška mozgovne  $X$  má normálne rozdelenie  $N(\mu_1, \sigma_1^2)$  a morfologická výška tváre  $Y$  má normálne rozdelenie  $N(\mu_2, \sigma_2^2)$ . Potom  $(X, Y)^T$  má dvojrozmerné normálne rozdelenie  $N_2(\boldsymbol{\mu}, \Sigma)$  s parametrami  $\boldsymbol{\mu} = (\mu_1, \mu_2)^T$ , čo je vektor stredných hodnôt a  $\sigma_1^2, \sigma_2^2$  a  $\rho$ , čo sú parametre kovariančnej matice  $\Sigma$ , kde sila lineárneho vzťahu týchto dvoch premenných je daná veľkosťou a znamienkom  $\rho$ . Potom  $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)^T$ . (1) Nakreslite hustotu dvojrozmerného normálneho rozdelenia  $N_2(\boldsymbol{\mu}, \Sigma)$  pomocou funkcie *image()* a superponujte ho s kontúrovým grafom hustoty tohto istého rozdelenia pomocou funkcie *contour()*. (2) Nakreslite dvojrozmerný jadrový odhad hustoty pomocou funkcií *kde2d()* a *image()* a superponujte ho s kontúrovým grafom hustoty dvojrozmerného normálneho rozdelenia  $N_2(\boldsymbol{\mu}, \Sigma)$  pomocou funkcie *contour()*. Hustotu rozsekajte na 12 intervalov, kde hodnoty v týchto intervaloch budú zodpovedať farbám *terrain.colors(12)*. Namiesto  $\boldsymbol{\theta}$  použite vektor  $\hat{\boldsymbol{\theta}}$  odhadnutý z dát. Riešenie pozri na obrázku 6.


cvič.

**Príklad 17 (štandardizované dvojrozmerné normálne rozdelenie)** Náhodný vektor  $(X, Y)^T$  má dvojrozmerné normálne rozdelenie

$$N_2(\mathbf{0}, \Sigma), \text{ kde } \mathbf{0} = (0, 0)^T \text{ a } \Sigma = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix},$$

s hustotou

$$\phi(x, y) = f(x, y) = \frac{1}{2\pi\sqrt{1-\rho^2}} \exp \left\{ -\frac{x^2 - 2\rho xy + y^2}{2(1-\rho^2)} \right\},$$



Obr. 5: Hustoty dvojrozmerného normálneho rozdelenia pri rôznych parametroch (prvý riadok – kontúrový graf, druhý riadok – perspektívny trojrozmerný graf v podobe plochy); čím je  $\rho$  odlišnejšie od nuly, tým viac sa kontúry líšia od kruhov (menia sa na elipsy); so zväčšujúcim sa rozdielom medzi  $\sigma_1$  a  $\sigma_2$  sa zväčšuje rozdiel rozptýlenia koncentrických kruhov v smere jednotlivých osí (hovoríme, že rozdiel variability premenných  $X_1$  a  $X_2$  sa zväčšuje)

kde  $(x, y)^T \in \mathbb{R}^2$ ,  $\rho \in \langle -1, 1 \rangle$  sú parametre, potom  $\boldsymbol{\theta} = (0, 0, 1, 1, \rho)$ . Výraz v exponente môžeme písat ako

$$-\frac{1}{2} \begin{pmatrix} x \\ y \end{pmatrix}^T \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}^{-1} \begin{pmatrix} x \\ y \end{pmatrix},$$

marginálne rozdelenia sú obe  $N(0, 1)$  a  $\rho$  je koeficient korelácie.


cvič.

**Príklad 18 (štandardizované dvojrozmerné normálne rozdelenie)** Nech náhodnou premenou  $X \sim N(\mu_1, \sigma_1^2)$  je najväčšia výška mozgovne (*skull.pH*; v mm) a náhodnou premenou  $Y \sim N(\mu_2, \sigma_2^2)$  je morfologická výška tváre (*face.H*; v mm). Nech  $X$  a  $Y$  majú dvojrozmerné normálne rozdelenie s parametrami  $(\mu_1, \mu_2)^T$  a  $\sigma_1^2, \sigma_2^2$  a  $\rho$  sú parametre kovariančnej matice  $\Sigma$ . Ked' od  $X$  odpočítame jej strednú hodnotu  $\mu_1$  a tento rozdiel vydelíme odmocninou z rozptylu  $\sigma_1$ , dostaneme náhodnú premenú  $Z_X$ , ktorá má asymptoticky normálne rozdelenie so strednou hodnotou  $\mu_1 = 0$  a rozptylom  $\sigma_1^2 = 1$ , čo zapisujeme ako  $Z_X \sim N(0, 1)$ . Ked' od  $Y$  odpočítame jej strednú hodnotu  $\mu_2$  a tento rozdiel vydelíme odmocninou z rozptylu  $\sigma_2$ , dostaneme náhodnú premenú  $Z_Y$ , ktorá má asymptoticky normálne rozdelenie so strednou hodnotou  $\mu_2 = 0$  a rozptylom  $\sigma_2^2 = 1$ , čo zapisujeme ako  $Z_Y \sim N(0, 1)$ . Potom  $(Z_X, Z_Y)^T$  má štandardizované dvojrozmerné normálne rozdelenie  $N_2(\boldsymbol{\mu}, \Sigma)$  s parametrami  $\boldsymbol{\mu} = (0, 0)^T$  a  $\sigma_1^2 = 1, \sigma_2^2 = 1$  a  $\rho$  sú parametre kovariančnej matice  $\Sigma$ .

cvič.

**Príklad 19 (dvojrozmerné normálne rozdelenie)** Simuláciu pseudonáhodných čísel z  $N_2(\boldsymbol{\mu}, \Sigma)$  môžeme v urobiť nasledovne použitím:

- 1) knižnice *library(MASS)* a funkcie *mvrnorm()*;



Obr. 6: Hustota dvojrozmerného normálneho rozdelenia s parametrom  $\hat{\theta}$ , ktorý je odhadnutý z dát (vľavo) a superimpozícia kontúr hustoty dvojrozmerného normálneho rozdelenia s parametrom  $\hat{\theta}$ , ktorý je odhadnutý z dát a dvojrozmerného jadrového odhadu hustoty (vpravo)

- 2) knižnice `library(mvtnorm)` a funkcie `rmvnorm()`;
- 3) funkcie `rnorm()` a nasledovného algoritmu – nech  $X_1 \sim N(0, 1)$  a  $X_2 \sim N(0, 1)$ ; potom  $(Y_1, Y_2) \sim N_2(\boldsymbol{\mu}, \Sigma)$ , kde  $\boldsymbol{\mu} = (\mu_1, \mu_2)^T$ , čo je vektor stredných hodnôt a  $\sigma_1^2, \sigma_2^2$  a  $\rho$ , čo sú parametre kovariančnej matice  $\Sigma$ , kde sila lineárneho vzťahu  $Y_1$  a  $Y_2$  je daná veľkosťou a znamienkom  $\rho$ ;  $Y_1 = \sigma_1 X_1 + \mu_1$  a  $Y_2 = \sigma_2(\rho X_1 + \sqrt{1 - \rho^2} X_2) + \mu_2$ . Nasimulujte pseudonáhodné čísla  $Y_1$  a  $Y_2$  z  $N_2(\boldsymbol{\mu}, \Sigma)$ . Vypočítajte dvojrozmerný jadrový odhad hustoty  $(Y_1, Y_2)^T$  pomocou funkcie `kde2d()`. Nakreslite ho pomocou funkcie `image()` a superponujte ho s kontúrovým grafom hustoty dvojrozmerného normálneho rozdelenia  $N_2(\boldsymbol{\mu}, \Sigma)$  pomocou funkcie `contour()`. Pri simulácii použite nasledovné parametre
  - (a)  $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0$ ; (1)  $n = 50$  a (2)  $n = 1000$ ;
  - (b)  $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0.5$ ; (1)  $n = 50$  a (2)  $n = 1000$ ;
  - (c)  $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1.2, \rho = 0.5$ ; (1)  $n = 50$  a (2)  $n = 1000$ .


Vzorové riešenie pozri na obrázku 6.

cvič.

**Príklad 20 (dvojrozmerné normálne rozdelenie)** Simuláciu pseudonáhodných čísel z  $N_2(\boldsymbol{\mu}, \Sigma)$  môžeme v R urobiť použitím nasledovných alternatívnych funkcií:

- 1) knižnice `library(MASS)` a funkcie `mvrnorm()`;
- 2) knižnice `library(mvtnorm)` a funkcie `rmvnorm()`;
- 3) funkcie `rnorm()` a nasledovného algoritmu – nech  $X_1 \sim N(0, 1)$  a  $X_2 \sim N(0, 1)$ ; potom  $(Y_1, Y_2) \sim N_2(\boldsymbol{\mu}, \Sigma)$ , kde  $\boldsymbol{\mu} = (\mu_1, \mu_2)^T$ , čo je vektor stredných hodnôt a  $\sigma_1^2, \sigma_2^2$  a  $\rho$ , čo sú parametre kovariančnej matice  $\Sigma$ , kde sila lineárneho vzťahu  $Y_1$  a  $Y_2$  je daná veľkosťou a znamienkom  $\rho$ ;  $Y_1 = \sigma_1 X_1 + \mu_1$  a  $Y_2 = \sigma_2(\rho X_1 + \sqrt{1 - \rho^2} X_2) + \mu_2$ . Nasimulujte pseudonáhodné čísla  $Y_1$  a  $Y_2$  z  $N_2(\boldsymbol{\mu}, \Sigma)$ . Vypočítajte dvojrozmerný jadrový odhad hustoty  $(Y_1, Y_2)^T$  pomocou funkcie `kde2d()`. Nakreslite ho pomocou funkcie `image()` a superponujte ho s kontúrovým grafom hustoty dvojrozmerného normálneho rozdelenia  $N_2(\boldsymbol{\mu}, \Sigma)$  pomocou funkcie `contour()`. Hustotu rozsekajte na 12 intervalov, kde hodnoty v týchto intervaloch budú zodpovedať farbám `terrain.colors(12)`. Pri simulácii použite nasledovné parametre
  - (a)  $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0$ ; (1)  $n = 50$  a (2)  $n = 1000$ ;
  - (b)  $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0.5$ ; (1)  $n = 50$  a (2)  $n = 1000$ ;
  - (c)  $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1.2, \rho = 0.5$ ; (1)  $n = 50$  a (2)  $n = 1000$ .

Vzorové riešenie pozri na obrázku 7.

Obr. 7: Hustoty dvojrozmerného normálneho rozdelenia (prvý riadok  $n = 50$ ; druhý riadok  $n = 1000$ )

**Príklad 21 (zmes dvoch dvojrozmerných normálnych rozdelení)** Simuláciu pseudonáhodných čísel zo zmesi dvoch normálnych rozdelení  $pN_2(\boldsymbol{\mu}_1, \Sigma_1) + (1-p)N_2(\boldsymbol{\mu}_2, \Sigma_2)$  môžeme v R urobiť použitím jedného z alternatívnych postupov z príkladu 20. Nasimulujuje pseudonáhodné čísla  $X$  a  $Y$  (1) zo zmesi  $pN_2(\boldsymbol{\mu}_1, \Sigma_1) + (1-p)N_2(\boldsymbol{\mu}_2, \Sigma_2)$ , kde  $\boldsymbol{\theta} = (\mu_{11}, \mu_{12}, \sigma_{11}^2, \sigma_{12}^2, \rho_1, \mu_{21}, \mu_{22}, \sigma_{21}^2, \sigma_{22}^2, \rho_2)^T$  a (2) z dvojrozmerného rozdelenia  $N_2(\boldsymbol{\mu}, \Sigma)$ , kde parametre predstavujú spoločný vektor stredných hodnôt a spoločnú kovariančnú maticu. t.j.  $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)^T$ . Pre (1) vypočítajte dvojrozmerný jadrový odhad hustoty  $(X, Y)^T$  pomocou funkcie `kde2d()`.

(a) Nakreslite teoretickú hustotu (2) pomocou funkcie `image()` a superponujte ju s kontúrovým grafom teoretickej hustoty (2) pomocou funkcie `contour()`.

(b) Nakreslite teoretickú hustotu (1) pomocou funkcie `image()` a superponujte ju s kontúrovým grafom teoretickej hustoty (1) pomocou funkcie `contour()`.

(c) Nakreslite dvojrozmerný jadrový odhad hustoty realizácií (1) pomocou funkcie `image()` a superponujte ju s kontúrovým grafom teoretickej hustoty (1) pomocou funkcie `contour()`.

Hustotu rozsekajte na 12 intervalov, kde hodnoty v týchto intervaloch budú zodpovedať farbám `terrain.colors(12)`. Pri simulácii použite  $\boldsymbol{\theta} = (-1.2, -1.2, 1, 1, 0, 1, 1, 1, 1, 0)^T$ ,


(1)  $\hat{\boldsymbol{\theta}} = (\hat{\mu}_{11}, \hat{\mu}_{12}, \hat{\sigma}_{11}^2, \hat{\sigma}_{12}^2, \hat{\rho}_1, \hat{\mu}_{21}, \hat{\mu}_{22}, \hat{\sigma}_{21}^2, \hat{\sigma}_{22}^2, \hat{\rho}_2)^T$ ,  $n_1 = n_2 = 50$  a  $p = 0.5$  (odhad pochádzajú z nasimulovaných dát).

(2)  $\hat{\boldsymbol{\theta}} = (\hat{\mu}_1, \hat{\mu}_2, \hat{\sigma}_1^2, \hat{\sigma}_2^2, \hat{\rho})^T$  a  $n_1 = n_2 = 50$  (odhad pochádzajú zo spoločného výberu nasimulovaných dát).

Vzorové riešenie pozri na obrázku 8.

DÚ

**Príklad 22 (zmes dvoch dvojrozmerných normálnych rozdelení)** Nech  $(X_1, Y_1)^T$  pochádza z rozdelenia  $N_2(\boldsymbol{\mu}_1, \Sigma_1)$ , kde  $X_1$  je priemerná dĺžka dolnej končatiny `lowex.L` v milimetroch a  $Y_1$  dĺžka trupu `tru.L` v milimetroch (u mužov). Nech  $(X_2, Y_2)^T$  pochádza z rozdelenia  $N_2(\boldsymbol{\mu}_2, \Sigma_2)$ , kde  $X_2$  je



Obr. 8: Spoločná hustota dvojrozmerného normálneho rozdelenia (vľavo), hustota zmesi dvoch dvojrozmerných normálnych rozdelení (uprostred) a dvojrozmerný jadrový odhad superponovaný hustotou zmesi dvoch dvojrozmerných normálnych rozdelení (vpravo)

priemerná dĺžka dolnej končatiny  $lowex.L$  v milimetroch a  $Y_2$  dĺžka trupu  $tru.L$  v milimetroch (užien). Predpokladajme, že  $X$  je priemerná dĺžka dolnej končatiny a  $Y$  dĺžka trupu pochádzajú (1) zo zmesi  $pN_2(\boldsymbol{\mu}_1, \Sigma_1) + (1-p)N_2(\boldsymbol{\mu}_2, \Sigma_2)$ , kde  $\boldsymbol{\theta} = (\mu_{11}, \mu_{12}, \sigma_{11}^2, \sigma_{12}^2, \rho_1, \mu_{21}, \mu_{22}, \sigma_{21}^2, \sigma_{22}^2, \rho_2)^T$  a (2) z dvojrozmerného rozdelenia  $N_2(\boldsymbol{\mu}, \Sigma)$ , kde parametre predstavujú spoločný vektor stredných hodnôt a spoločnú kovariančnú maticu. t.j.  $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)^T$ . Pre (1) vypočítajte dvojrozmerný jadrový odhad hustoty  $(X, Y)^T$  pomocou funkcie `kde2d()`.

(a) Nakreslite teoretickú hustotu (2) pomocou funkcie `image()` a superponujte ju s kontúrovým grafom teoretickej hustoty (2) pomocou funkcie `contour()`.

(b) Nakreslite teoretickú hustotu (1) pomocou funkcie `image()` a superponujte ju s kontúrovým grafom teoretickej hustoty (1) pomocou funkcie `contour()`.

(c) Nakreslite dvojrozmerný jadrový odhad hustoty realizácií (1) pomocou funkcie `image()` a superponujte ju s kontúrovým grafom teoretickej hustoty (1) pomocou funkcie `contour()`.

Hustotu rozsekajte na 12 intervalov, kde hodnoty v týchto intervaloch budú zodpovedať farbám `terrain.colors(12)`.


(1)  $\hat{\boldsymbol{\theta}} = (\hat{\mu}_{11}, \hat{\mu}_{12}, \hat{\sigma}_{11}^2, \hat{\sigma}_{12}^2, \hat{\rho}_1, \hat{\mu}_{21}, \hat{\mu}_{22}, \hat{\sigma}_{21}^2, \hat{\sigma}_{22}^2, \hat{\rho}_2)^T$  a  $p = n_1/(n_1+n_2)$ ; parametre sú odhadnuté z dát.

(2)  $\hat{\boldsymbol{\theta}} = (\hat{\mu}_1, \hat{\mu}_2, \hat{\sigma}_1^2, \hat{\sigma}_2^2, \hat{\rho})^T$ ; parametre sú odhadnuté zo spoločného výberu.

Vzorové riešenie pozri na obrázku 9 (dáta `two-samples-correlations-trunk.txt`). DÚ

**Odlišnosti od teoretického rozdelenia.** Odlišnosti empirického rozdelenia (rozdelenia realizácií) od teoretického (napr. normálneho) rozdelenia, môžeme charakterizovať napr. ako pravostranne alebo ľavostranne zošikmené rozdelenie (obrázok 10, prvý riadok vľavo a vpravo), ploché alebo špicaté rozdelenie (obrázok 10, prvý riadok uprostred). Pri viacrozmerných rozdeleniach je situácia komplikovanejšia. Pri dvojrozmernom normálnom rozdelení može byť napr. zošikmená jedna alebo obe premenné (príklad zošikmenia oboch premenných zlava pozri na obrázku 10, dolný riadok).

**Príklad 23 (binomické rozdelenie, binomický experiment)** Experiment pozostávajúci z fixného počtu Bernouliho experimentov (ozn.  $N$ ) sa nazýva binomický experiment. Pravdepodobnosť úspechu ozn.  $p$ , pravdepodobnosť neúspechu  $q = 1 - p$ . Náhodná premenná  $X$  je počet pozorovaných úspechov počas experimentu. Pravdepodobnosť  $X = x$  za podmienky, že  $X$  pochádza z binomického rozdelenia  $Bin(N, p)$  píšeme ako  $\Pr(X = x) = \binom{N}{x} p^x (1 - p)^{N-x}$ ,  $x = 0, 1, \dots, N$  (Ugarte a kol. 2008). Stredná



Obr. 9: Spoločná hustota dvojrozmerného normálneho rozdelenia (vl'avo), hustota zmesi dvoch dvojrozmerných normálnych rozdelení (uprostred) a dvojrozmerný jadrový odhad superponovaný hustotou zmesi dvoch dvojrozmerných normálnych rozdelení (vpravo) – reálne dátá

hodnota  $E[X] = Np$  a rozptyl  $Var[X] = Np(1-p)$ . Naprogramujte a zobrazte v pravdepodobnosťnú funkciu a (kumulatívnu) distribučnú funkciu pre  $Bin(5,0.5)$ . Riešenie pozri na obrázku 11.

cvič.

**Príklad 24 (multinomické rozdelenie)** Majme náhodné premenné (1) socioekonomickej status (vysoký – H, nízky – Lo), (2) politická príslušnosť (demokrat – D, republikán – R) a (3) politická filozofia (liberál – Li, konzervatív – C). Označme ich interakcie nasledovne  $X_1$  (H-D-Li),  $X_2$  (H-D-C),  $X_3$  (H-R-Li),  $X_4$  (H-R-C),  $X_5$  (Lo-D-Li),  $X_6$  (Lo-D-C),  $X_7$  (Lo-R-Li) a  $X_8$  (Lo-R-C). Predpokladajme, že máme náhodný výber s rozsahom  $N = 50$ . Pravdepodobnosti  $p_j$  sú nasledovné

	D-Li	D-C	R-Li	R-C	spolu
H	0.12	0.12	0.04	0.12	0.4
Lo	0.18	0.18	0.06	0.18	0.6
spolu	0.30	0.30	0.10	0.30	1.0

Vypočítajte  $Var[X_1]$ ,  $Var[X_3]$ ,  $Cov[X_1, X_3]$ ,  $Cor[X_1, X_3]$  a očakávané početnosti  $Np_j$ ,  $j = 1, 2, \dots, 8$ . pred

### Riešenie

$X = (X_1, X_2, \dots, X_8) \sim Mult(N, \mathbf{p})$ , kde  $N = 50$ ,  $\mathbf{p} = (p_1, p_2, \dots, p_8)^T$ , vieme, že  $X_j \sim Bin(N, p_j)$ ,  $p_j$  sú v tabuľke v zadaní príkladu a  $j = 1, 2, \dots, 8$ . Potom

$$Var[X_1] = 50 \times 0.12 \times (1 - 0.12) = 5.28,$$


$$Var[X_3] = 50 \times 0.04 \times (1 - 0.04) = 1.92.$$

Vybraná kovariancia a korelácia (medzi počtami príslušných skupín) je rovná

$$Cov[X_1, X_3] = -50 \times 0.12 \times 0.04 = -0.24, Cor[X_1, X_3] = -0.24 / \sqrt{5.28 \times 1.92} = -0.075.$$

Očakávané početnosti pre každú bunku tabuľky sú (všeobecne nemusia byť) celé čísla:

	D-Li	D-C	R-Li	R-C
H	6	6	2	6
Lo	9	9	3	9




Obr. 10: Hustoty normálneho rozdelenia a zošikmeného normálneho rozdelenia pri rôznych parametroch (prvý riadok); hustoty dvojrozmerného zošikmeného normálneho rozdelenia (druhý riadok vľavo a uprostred) a dvojrozmerného normálneho rozdelenia (druhý riadok vpravo) pri rôznych parametroch

**Príklad 25 (súčinové multinomické rozdelenie)** Majme dátu z predchádzajúceho príkladu a náhodný výber s rozsahom  $N_1 = 30$  zo skupiny H, ďalší náhodný výber s rozsahom  $N_2 = 20$  zo skupiny Lo. Označme interakcie premenných nasledovne  $X_{11} = X_{1|1}$  (H-D-Li),  $X_{12} = X_{2|1}$  (H-D-C),  $X_{13} = X_{3|1}$  (H-R-Li),  $X_{14} = X_{4|1}$  (H-R-C),  $X_{21} = X_{1|2}$  (Lo-D-Li),  $X_{22} = X_{2|2}$  (Lo-D-C),  $X_{23} = X_{3|2}$  (Lo-R-Li) a  $X_{24} = X_{4|2}$  (Lo-R-C), kde  $\mathbf{X}_1 = (X_{11}, X_{12}, X_{13}, X_{14})^T$  a  $\mathbf{X}_2 = (X_{21}, X_{22}, X_{23}, X_{24})^T$ . Potom  $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2)$  má súčinové multinomické rozdelenie s  $K = 2$ ,  $N_1 = 30$ ,  $J_1 = 4$ ,  $N_2 = 20$ ,  $J_2 = 4$ . Zápis s  $X_{j|k}$ , kde  $j = 1, 2, 3, 4$  a  $k = 1, 2$  zvýrazňuje fakt, že rozdelenie je podmienené socioekonomickým statusom (vysoký – H, nízky – Lo), t.j. rozdelenie v stĺpcoch tabuľky je podmienené jej riadkom. Realizácie  $X_{j|k}$  označujeme ako  $n_{j|k} = n_{kj}$ , pravdepodobnosti ekvivalentné  $X_{j|k} = X_{kj}$  ako  $p_{j|k} = p_{kj}$ . Vypočítajte podmienené pravdepodobnosti  $p_{j|k}$ , očakávané početnosti  $N_{kj}p_{kj}$ ,  $\text{Var}[X_{13}]$ ,  $\text{Cov}[X_{21}, X_{23}]$  a  $\text{Cor}[X_{11}, X_{23}]$ .

### Riešenie

Pravdepodobnosti štyroch kategórií asociovaných s H statusom sú podmienené pravdepodobnosti dané H statusom. Napr.  $\Pr(X_{3|1}) = 0.04/0.4 = 0.1$ ,  $\Pr(X_{1|1}) = 0.12/0.4 = 0.3$ ,  $\Pr(X_{3|2}) = 0.06/0.6 = 0.1$ . Musíme ale tabuľku prepísat na súčinovo-multinomický model, teda podmienené pravdepodobnosti  $p_{j|i}$  dané socioekonomickým statusom  $i$  budú

	D-Li	D-C	R-Li	R-C	spolu
H	0.3	0.3	0.1	0.3	1.0
Lo	0.3	0.3	0.1	0.3	1.0

Obr. 11: Pravdepodobnostná funkcia a distribučná funkcia  $\text{Bin}(5, 0.5)$ 

Pre  $N_1 = 30$  a  $N_2 = 20$  máme očakávané počty nasledovné

	D-Li	D-C	R-Li	R-C	spolu
H	9	9	3	9	30
Lo	6	6	2	6	20

$$\text{Var}(X_{3|1}) = 30 \times 0.1 \times (1 - 0.1) = 2.7.$$

Vybrané kovariancie (medzi počtami príslušných skupín) sú rovné

$$\text{Cov}[X_{1|2}, X_{3|2}] = -20 \times 0.3 \times 0.1 = -0.6,$$

$\text{Cov}[X_{1|1}, X_{3|2}] = 0$ , lebo  $\mathbf{X}_1$  a  $\mathbf{X}_2$  sú nezávislé.

**Príklad 26 (Poissonovo rozdelenie; počet havárií za týždeň)** Ak každý z 50 miliónov ľudí šoféruje auto v Taliansku budúci týžden nezávisle, potom pravdepodobnosť smrti pri autonehode bude  $0.0000002$ , kde počet úmrtí má binomické rozdelenie  $\text{Bin}(50\text{mil}, 0.0000002)$  alebo limitne Poissonovo rozdelenie s parametrom  $50\text{mil} \times 0.0000002 = 100$ .

**Príklad 27 (Poissonovo rozdelenie; pruské armádne jednotky)** Nech početnosti úmrtí  $X$  ako následok kopnutia koňom v Pruských armádnych jednotkách (Bortkiewicz 1898), má Poissonovo rozdelenie s parametrom  $\lambda$ , t.j.  $X \sim \text{Poiss}(\lambda)$ . Pravdepodobnosť, že niekto bude smrteľne zranený v danom dni je extrémne malá. Majme 10 vojenských jednotiek za 20-ročnú períodu s rozsahom  $M = 200$  ( $200 = 10 \times 20$ ), kde popri početnostiach úmrtí  $n = 1, 2, 3, 4, 5+$ , v danej jednotke a v danom roku, zaznamenávame aj početnosti vojenských jednotiek  $m_n$  pri danom  $n$ , kde  $M = \sum m_n$  (pozri tabuľku). Vypočítajte očakávané početnosti, za predpokladu  $X \sim \text{Poiss}(\lambda)$ , kde  $\lambda = \frac{\sum_n nm_n}{\sum_n m_n}$ .

cvič.

$n$	0	1	2	3	4	5+
$m_n$	109	65	22	3	1	0

**Príklad 28 (podiel chlapcov a dievčat v rodinách)** Nech  $X$  predstavuje početnosť chlapcov medzi deťmi v rodinách. Tu môžeme predpokladať, že  $X \sim \text{Bin}(N, p)$ , t.j. rodina môže mať vychýlený pomer pohlaví detí v smere ku chlapcom alebo dievčatám. V realite teda môžeme mať príliš veľa rodín len s chlapcami alebo len s dievčatami a nemáme dostatok rodín s pomerom pohlaví blízkym 51 : 49 (pomer chlapcov ku dievčatám). Z toho nám vyplýva, že rozptyl početnosti chlapcov bude v skutočnosti väčší ako rozptyl predpokladaný binomickým modelom  $\text{Bin}(N, p)$ .

pred

**Príklad 29 (overdispersion v binomickom modeli)** V klasickej štúdii pomeru pohlaví u ľudí z roku 1889 na základe záznamov z nemocníc v Sasku (bližšie pozri Lindsey a Altham (1998)) Geissler (1889) zaznamenal rozdelenie počtu chlapcov v rodinách. Medzi  $M = 6115$  rodinami s  $N = 12$  deťmi pozoroval nasledovné početnosti chlapcov ( $n$  sú početnosti chlapcov a  $m_n$  početnosti rodín s  $n$  chlapcami)

$n$	0	1	2	3	4	5	6	7	8	9	10	11	12
$m_n$	3	24	104	286	670	1033	1343	1112	829	478	181	45	7

Vypočítajte  $m_n$  za predpokladu, že početnosti chlapcov  $X$  v rodinách majú binomické rozdelenie s parametrami  $\pi = \frac{\sum_{n=0}^N nm_n}{NM} = 0.5192$  a  $N = 12$ , ozn.  $X \sim Bin(N, \pi)$ .

cvič.

### Riešenie

$n$	0	1	2	3	4	5	6	7	8	9	10	11	12
očakávané $m_n$	1	12	72	258	628	1085	1367	1266	854	410	133	26	2

Ked' porovnáme pozorované  $m_n$  a vypočítané (teoretické)  $m_n$  zistíme, že pozorované poukazujú na overdispersion, t.j. máme väčšie početnosti rodín s malým a veľkým množstvom chlapcov v porovnaní s teroretickejmi početnosťami.

**Príklad 30 (overdispersion v Poissonovom modeli)** Majme početnosti úrazov  $n$  medzi robotníkmi v továrni, kde početnosti robotníkov  $m_n$  pri danom  $n$  pozri v tabuľke (Greenwood a Yule 1920).

cvič.

$n$	0	1	2	3	4	$\geq 5$
$m_n$	447	132	42	21	3	2

Vypočítajte očakávané početnosti robotníkov za predpokladu, že početnosti úrazov na robotníka  $X$  majú Poissonove rozdelenie s parametrom  $\lambda = \frac{\sum_n nm_n}{\sum_n m_n} = 0.47$ , ozn.  $X \sim Poiss(\lambda)$ .

### Riešenie

$n$	0	1	2	3	$\geq 4$
očakávané $m_n$	406	189	44	7	1


Ked' porovnáme pozorované  $m_n$  a vypočítané (teoretické, očakávané)  $m_n$  zistíme, že pozorované poukazujú na overdispersion, t.j. máme viac robotníkov bez úrazu ako aj viac robotníkov s väčším množstvom úrazov v porovnaní s teroretickejmi početnosťami.

**Príklad 31 (binomický rozdelenie, simulačná štúdia)** Vygenerujte pseudonáhodné čísla  $X$  (početnosti úspechov) opakovane  $M$ -krát ( $M = 1000$ ) z  $Bin(N, p)$ , kde  $N = 5$  a  $p = 0.5$ . Vytvorte tabuľku vygenerovaných (simulovaných) ako aj teoretických relatívnych početností (pre  $n = 0, 1, \dots, 5$ ). Superponujte histogram vygenerovaných pseudonáhodných čísel s teoretickou pravdepodobnosťou funkciou.

cvič.

**Riešenie** (pozri obrázok 12)

$r$	0	1	2	3	4	5
simulované relatívne početnosti	0.021	0.152	0.318	0.324	0.155	0.030
teoretické relatívne početnosti	0.031	0.156	0.312	0.312	0.156	0.031



Obr. 12: Histogram vygenerovanych pseudonahodnych cisel superponovaný spojnicovým grafom teoretickej pravdepodobnostnej funkcie  $X$

**Príklad 32 (binomické vs normálne rozdelenie)** Nech  $X_N \sim \text{Bin}(N, p)$ , potom môžeme approximovať binomické rozdelenie normálnym nasledovne –  $X_N \sim N(Np, Np(1-p))$ , kde tiež platí  $Z_N = \frac{X_N - Np}{\sqrt{Np(1-p)}} \sim N(0, 1)$ . Ukážte, že CLV platí pre  $N = 100$  a  $p = 1/2$  na tri desatinné miesta.

### Riešenie

Príklad hovorí o tom, ako dobre normálne rozdelenie aproximuje binomické pri rozsahu  $N = 100$ , čo je dôležité pri testovaní hypotéz.

$$E[X_N] = Np = 50, \sqrt{\text{Var}[X_N]} = \sqrt{Np(1-p)} = \sqrt{5}.$$

Ak  $Y_N = X_N/N$ , potom  $\Pr(|Y_N - 1/2| < \epsilon) = 0.236$ , kde  $\epsilon = 0.02$ .  $\Pr(0.48 < Y_{100} < 0.52) = \Pr(48 < X_{100} < 52) = \Pr(48.5 < X_{100} < 51.5) = \Pr(\frac{48.5 - 50}{\sqrt{5}} < Z_{100} < \frac{51.5 - 50}{\sqrt{5}})$ , kde  $X_{100} \sim N(50, 5)$  s použitím úpravy na spojitost.

**Príklad 33 (normálne rozdelenie, simulačná štúdia)** Na základe simulačnej štúdie preverte, že ak  $X \sim N(150, 6.25)$ , potom  $\bar{X}_n \sim N(150, 6.25/n)$ . Použite  $n = 30$ . Pre každú simuláciu  $X$  vypočítajte aritmetické priemery  $\bar{x}_m$ ,  $m = 1, 2, \dots, M$ , kde  $M = 500000$ . Superponujte ich histogram v relatívnej škále s teoretickou krivkou hustoty pre  $\bar{X}_n$ . Vypočítajte  $\Pr(\bar{X}_n > 151)$  zo simulovaných dát a porovnajte tento výsledok s teoretickou (očakávanou) pravdepodobnosťou. Riešenie pozri na obrázku 13.

cvič.

**Príklad 34 (normálne rozdelenie, simulačná štúdia)** Nech  $X \sim N(\mu_1, \sigma_1^2)$  a  $Y \sim N(\mu_2, \sigma_2^2)$ . Potom  $\bar{X}_{n_1} - \bar{Y}_{n_2} \sim N(\mu_1 - \mu_2, \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2})$ . Generujte pseudonahodné císla  $X$  a  $Y$  rozdelení  $N(\mu_j, \sigma_j^2)$ ,  $j = 1, 2$ , kde  $\mu_1 = 100$ ,  $\sigma_1 = 10$ ,  $\mu_2 = 50$ ,  $\sigma_2 = 9$  pri (a)  $n_1 = 4$ ,  $n_2 = 5$ , (b)  $n_1 = 100$ ,  $n_2 = 81$ . Pre každú simuláciu  $X$  a  $Y$  vypočítajte rozdiel  $\bar{x}_m - \bar{y}_m$ ,  $m = 1, 2, \dots, M$ , kde  $M = 1000$ . Superponujte histogram týchto rozdielov v relatívnej škále s teoretickou krivkou hustoty rozdielu  $\bar{X}_{n_1} - \bar{Y}_{n_2}$ . Pre prípad (a) aj (b) vypočítajte  $\Pr(\bar{X}_{n_1} - \bar{Y}_{n_2} < 52)$  na základe empirického (vygenerovaného) a teoretického rozdelenia  $\bar{X}_{n_1} - \bar{Y}_{n_2}$ .

cvič.

**Príklad 35 (štatistika)** Majme náhodný výber  $(X_1, X_2, \dots, X_n)^T$ , kde  $X_i \in \mathbb{R}$ ,  $i = 1, 2, \dots, n$ , potom príkladmi štatistik sú:  $T_1 = \sum_{i=1}^n X_i \in \mathbb{R}$ ,  $T_2 = \sum_{i=1}^n X_i^2 \in \mathbb{R}^+ \cup \{0\}$ ,  $T_3 = (\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2) \in \mathbb{R}^2$ .

pred

**Príklad 36 (testovacia štatistika, simulačná štúdia)** Na základe simulačnej štúdie preverte, že ak náhodná premenná  $X$  má asymptoticky binomické rozdelenie  $Bin(N, p)$ , potom testovacia štatistika  $Z_W = \frac{X/N-p}{\sqrt{(p(1-p)/N)}}$ , má asymptoticky normálne rozdelenie  $N(0, 1)$ . Použite  $p = 0, 0.1, 0.5, 0.9$  a  $1$ , a  $N = 5, 10, 30, 50$  a  $100$ . Okomentujte výsledky v spojitosti s Haldovou podmienkou  $Np(1 - p) > 9$ . Pre každú simuláciu  $X$  vypočítajte  $z_{W,m}$ ,  $m = 1, 2, \dots, M$ , kde  $M = 1000$ . Superponujte histogram vygenerovaných testovacích štatistik v relatívnej škále s teoretickou krivkou hustoty  $Z_W$ .

cvič.

Príklad 36 hovorí o použití jednovýberovej testovacej štatistiky pre parameter binomického rozdelenia (pravdepodobnosť) pre rôzne pravdepodobnosti a rôzne početnosti. Ak Haldova podmienka nie je splnená, nie je možné testovaciu štatistiku použiť.

**Príklad 37 (testovacia štatistika, simulačná štúdia)** Na základe simulačnej štúdie preverte, že ak (a)  $X \sim N(\mu, \sigma^2)$ , kde  $\mu = 0, \sigma^2 = 1$  a (b)  $X \sim Exp(\lambda)$ , kde  $\lambda = 1$ ,  $E[X] = 1$  a  $Var[X] = 1$ , potom testovacia štatistika  $F = \frac{(n-1)S^2}{\sigma^2}$  má asymptoticky  $\chi^2_{n-1}$  rozdelenie s  $n - 1$  stupňami voľnosti. Použite rozsahy náhodných výberov  $n = 15$  a  $n = 100$ . Pre každú simuláciu  $X$  vypočítajte  $F_{poz,m}$ ,  $m = 1, 2, \dots, M$ , kde  $M = 1000$ . Superponujte histogram vygenerovaných testovacích štatistik v relatívnej škále s teoretickou krivkou hustoty  $F$ .

cvič.

**Príklad 38 (maximálne vieročodné odhady; Poissonovo rozdelenie)** Každý rok za posledných päť rokov boli v nejakom meste registrované 3, 2, 5, 0 a 4 zemetrasenia za rok. Za predpokladu, že počet zemetrasení za rok  $X$  má Poissonovo rozdelenie s parametrom  $\lambda$ , t.j.  $X \sim Poiss(\lambda)$ , odhadnite  $\lambda$  ( $\lambda$  predstavuje očakávanú početnosť zemetrasení za rok).

pred

**Príklad 39 ( $\mathcal{I}(\hat{p})$  a rozptyl pre  $p$ ;  $X \sim Bin(N, p)$ )** Z funkcie vieročodnosti odvod'te pozorovanú Fisherovu mieru informácie  $\mathcal{I}(\hat{p})$  a rozptyl  $\widehat{Var[\hat{p}]}$ .

pred

**Príklad 40 ( $\mathcal{I}(\hat{\lambda})$  a rozptyl pre  $\lambda$ ;  $X \sim Poiss(\lambda)$ )** Každý rok za posledných päť rokov boli v nejakom meste registrované 3, 2, 5, 0 a 4 zemetrasenia za rok. Za predpokladu, že počet zemetrasení za rok  $X \sim Poiss(\lambda)$ , odhadnite rozptyl parametra  $\lambda$  a vypočítajte hodnotu tohto odhadu rozptylu pre počet zemetrasení.


pred

**Príklad 41 (kvadratická approximácia funkcie vieročodnosti)** (1) Nakreslite škálovaný logaritmus funkcie vieročodnosti binomického rozdelenia. Na  $x$ -ovej osi bude  $p$  a na  $y$ -ovej osi  $\ln \mathcal{L}(p) = l(p|\mathbf{x}) - \max(l(p|\mathbf{x}))$ . Porovnajte  $\ln \mathcal{L}(p)$  s kvadratickou approximáciou vypočítanou pomocou Taylorovho rozvoja  $\ln \mathcal{L}(p) = \ln\left(\frac{L(p|\mathbf{x})}{L(\hat{p}|\mathbf{x})}\right) \approx -\frac{1}{2}\mathcal{I}(\hat{p})(p - \hat{p})^2$ . (2) Nech skóre funkcia  $S(p) = \frac{\partial}{\partial p} \ln L(p|\mathbf{x})$ . Ked' zoberieme deriváciu kvadratickej approximácie uvedenej vyššie, dostaneme  $S(p) \approx -\mathcal{I}(\hat{p})(p - \hat{p})$  alebo  $-\mathcal{I}^{-1/2}(\hat{p})S(p) \approx \mathcal{I}^{1/2}(\hat{p})(p - \hat{p})$ . Potom zobrazením pravej strany na  $x$ -ovej osi a ľavej strany na  $y$ -ovej osi dostaneme asymptoticky lineárnu funkciu s jednotkovým sklonom. Asymptoticky tiež platí  $\mathcal{I}^{1/2}(\hat{p})(p - \hat{p}) \sim N(0, 1)$ . Je postačujúce mať rozsah  $x$ -vej osi  $(-2, 2)$ , pretože funkcia je asymptoticky (lokálne) lineárna na tomto intervale. Rozumne škálujte  $y$ -ovú os. Zobrazte pre (a)  $n = 8, N = 10$ , (b)  $n = 80, N = 100$  a (c)  $n = 800, N = 1000$  ( $p \in (0.5, 0.99)$ ). Okomentujte rozdiely medzi (a), (b) a (c). Grafické riešenie je na obrázku 13.

cvič.

**Príklad 42 ( $\mathcal{I}(\hat{\theta})$  pre vektor  $\theta = (\mu, \sigma^2)^T$ ;  $X \sim N(\mu, \sigma^2)$ )** Nech  $X \sim N(\mu, \sigma^2)$ . Čomu je rovná pozorovaná Fisherova informačná matica  $\mathcal{I}(\hat{\theta})$ , kde  $\theta = (\hat{\mu}, \hat{\sigma}^2)^T$ ?

pred



Obr. 13: Porovnanie škálovaného logaritmu funkcie vieročodnosti (plná čiara) s jeho kvadratickou aproximáciou (čiarkovaná čiara) v prvom riadku a porovnanie škálovanej skóre funkcie a priamky s nulovým interceptom a jednotkovým sklonom v druhom riadku

**Príklad 43 ( $\mathcal{I}(\hat{\mathbf{p}})$  a rozptyl pre  $\mathbf{p}; \mathbf{X} \sim \text{Mult}_J(N, \mathbf{p})$ )** Z funkcie vieročodnosti odvodte pozorovanú Fisherovu informačnú maticu  $\mathcal{I}(\hat{\mathbf{p}})$  a kovariančnú maticu  $\widehat{\text{Var}}[\hat{\mathbf{p}}]$ .

pred

**Príklad 44 (profilová vieročodnosť; normálne rozdelenie)** Profilová funkcia vieročodnosti pre  $\mu$  počítaná pre každe fixované  $\mu$ , kde maximálne vieročodný odhad  $\sigma^2$  bude  $\hat{\sigma}_\mu^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2$ , má tvar  $L(\mu|\mathbf{x}) = c (\hat{\sigma}_\mu^2)^{-n/2}$ , kde  $c$  je nejaká konštanta.  $L(\mu|\mathbf{x})$  nie je identická s odhadnutou funkciou vieročodnosti  $L(\mu, \sigma^2 = \hat{\sigma}^2|\mathbf{x}) = c \exp(-\frac{1}{2\hat{\sigma}^2} \sum_{i=1}^n (x_i - \mu)^2)$ , t.j. s rezom  $L(\mu, \sigma^2|\mathbf{x})$  v bode  $\sigma^2 = \hat{\sigma}^2$ . Obe funkcie vieročodnosti budú veľmi podobné, ak je rozptyl  $\sigma^2$  dobre odhadnutý. V opačnom prípade sa preferuje profilová funkcia vieročodnosti. Profilová funkcia vieročodnosti pre  $\sigma^2$  je rovná  $L(\sigma^2|\mathbf{x}) = c (\sigma^2)^{-n/2} \exp(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \bar{x})^2) = c (\sigma^2)^{-n/2} \exp(-n\hat{\sigma}^2/(2\sigma^2))$ .

pred


**Príklad 45 (kvadratická aproximácia profilovej funkcie vieročodnosti)** (1) Nakreslite škálovaný logaritmus profilovej funkcie vieročodnosti normálneho rozdelenia pre  $\mu$ . Na  $x$ -ovej osi bude  $\mu$  a na  $y$ -ovej osi  $\ln \mathcal{L}(\mu|\mathbf{x}) = l(\mu|\mathbf{x}) - \max(l(\mu|\mathbf{x}))$ . Porovnajte  $\ln \mathcal{L}(\mu|\mathbf{x})$  s kvadratickou aproximáciou vypočítanou pomocou Taylorovho rozvoja  $\ln \mathcal{L}(\mu|\mathbf{x}) = \ln(\frac{L(\mu|\mathbf{x})}{L(\hat{\mu}|\mathbf{x})}) \approx -\frac{1}{2}\mathcal{I}(\hat{\mu})(\mu - \hat{\mu})^2$ . (2) Nech skóre funkcia  $S(\mu) = \frac{\partial}{\partial \mu} \ln L(\mu|\mathbf{x})$ . Ked' zoberieme deriváciu kvadratickej aproximácie uvedenej vyššie, dostaneme  $S(\mu) \approx -\mathcal{I}(\hat{\mu})(\mu - \hat{\mu})$  alebo  $-\mathcal{I}^{-1/2}(\hat{\mu})S(\mu) \approx \mathcal{I}^{1/2}(\hat{\mu})(\mu - \hat{\mu})$ . Potom zobrazením pravej strany na  $x$ -ovej osi a ľavej strany na  $y$ -ovej osi dostaneme asymptoticky lineárnu funkciu s jednotkovým sklonom. Asymptoticky tiež platí  $\mathcal{I}^{1/2}(\hat{\mu})(\mu - \hat{\mu}) \sim N(0, 1)$ . Je postačujúce mať rozsah  $x$ -vej

osi  $\langle -2, 2 \rangle$ , pretože funkcia je asymptoticky (lokálne) lineárna na tomto intervale. Rozumne škálujte  $y$ -ovú os. Zobrazte pre (a)  $n = 10$ , (b)  $n = 100$  a (c)  $n = 1000$ . Použite (1)  $X \sim N(0, 1)$  a (2)  $X \sim (1 - p)N(0, 1) + pN(0, 2)$ , kde  $p = 0.05$ . Okomentujte rozdiely medzi (a), (b) a (c), ako aj rozdiely medzi (1) a (2).

DÚ

**Príklad 46 (maximálne vieročodný odhad  $\mu$  a  $\sigma^2$ )** Vygenerujte pseudonáhodné čísla z  $X \sim N(4, 1)$ ,  $n = 1000$ . (a) Napište logaritmus profilovej funkcie vieročodnosti pre  $\mu$  a  $\sigma^2$  a preverte, či sú maximálne vieročodné odhady  $\mu$  a  $\sigma^2$  dostatočne blízko k ich skutočným hodnotám. Nakreslite grafy  $l(\mu|x)$  a  $l(\sigma^2|x)$ , kde zvýrazníte polohu maxím týchto funkcií. (b) Napište logaritmus funkcie vieročodnosti pre  $\theta = (\mu, \sigma^2)$  a preverte, či je maximálne vieročodný odhad  $\theta = (\mu, \sigma^2)^T$  dostatočne blízko k jeho skutočnej hodnote. (c) Nakreslite graf  $l((\mu, \sigma^2)|x)$  použitím funkcie `image()` a superponujte ho s kontúrovým grafom použitím funkcie `contour()`. Zvýraznite polohu maxima (pozri obrázok 14).

DÚ



Obr. 14: Profilová funkcia vieročodnosti pre  $\mu$  (vľavo),  $\sigma^2$  (uprostred) a funkcia vieročodnosti pre oba parametre (vpravo);  $X \sim N(4, 1)$ ; maximálne vieročodné odhady strednej hodnoty a rozptylu sú označené zvislou čiarou (vľavo a uprostred) a maximálne vieročodný odhad vektora parametrov je označený ● (vpravo)

**Príklad 47 (binomické rozdelenie, maximálne vieročodný odhad  $p$ )** Nech  $X \sim Bin(N, p)$  a realizácie  $X$  sú  $x = n$ . Predpokladajme, že sme pozorovali (a)  $x = 2$ , (b)  $x = 10$  a (c)  $x = 18$  úspechov v  $N = 20$  pokusoch. Pomocou R vypočítajte maximálne vieročodný odhad  $p$ . Výsledok zobrazte do grafu spolu s funkciou vieročodnosti.

cvič.

**Príklad 48 (maximálne vieročodné odhady; multinomické rozdelenie)** Majme dátá *more-samples-probabilities-pubis.txt*. Nakreslite logaritmus štandardizovanej funkcie vieročodnosti v parametroch  $p_1$  a  $p_2$  Európskej populácie ( $n_1 = 30$ ,  $n_2 = 20$  a  $n_3 = 10$ ) pomocou funkcie `contour()`. Dokreslite do obrázku jej maximum v bode  $\hat{\theta} = (\hat{p}_1, \hat{p}_2)^T$ .

DÚ

**Príklad 49 (overdispersion v Poissonovom modeli, pokrač.)** Majme početnosti úrazov  $n$  medzi robotníkmi v továrni, kde početnosti robotníkov  $m_n$  pri danom  $n$  pozri v tabuľke (Greenwood a Yule 1920).

$n$	0	1	2	3	4	$\geq 5$
$m_n$	447	132	42	21	3	2

Vypočítajte  $m_n$  za predpokladu, že početnosti úrazov na robotníka  $X$  majú negatívne binomické rozdelenie s parametrami  $\alpha$  a  $\pi$ .

cvič.

## 2 Charakteristiky polohy a variability a štatistická grafika

**Príklad 50 (argument minima)** Vygenerujte pseudonáhodné čísla  $X \sim N(\mu, \sigma^2)$ ,  $n = 1000$ ,  $\mu = 0, \sigma^2 = 1$ . Vygenerované čísla ozn.  $x_i, i = 1, 2, \dots, 1000$ . Nájdite numericky také  $c$ , ktoré minimalizuje (a) sumu štvorcov odchýlok  $\sum_{i=1}^{1000} (x_i - c)^2$ , t.j.  $c_1 = \arg \min_{\forall c} \sum_{i=1}^{1000} (x_i - c)^2$  a (b) sumu absolútnych odchýlok  $\sum_{i=1}^{1000} |x_i - c|$ , t.j.  $c_2 = \arg \min_{\forall c} \sum_{i=1}^{1000} |x_i - c|$ . Za  $c$  dosadzujte postupne (1) všetky  $x_{(j)}$  ( $x_{(j)}$  sú usporiadane  $x_i$  podľa veľkosti od najmenšieho po najväčšie) a vybrané charakteristiky polohy ako (2) aritmetický priemer, (3) nejaké kvantily  $\tilde{x}_p$ , kde  $p \in \langle 0, 1 \rangle$  a pod. Nakreslite obrázok závislosti (a) sumy štvorcov odchýlok na  $x_{(j)}$ , t.j. body  $[x_j, y_j]$ , kde  $y_j = \sum_{i=1}^{1000} (x_i - x_{(j)})^2$  a (b) sumy absolútnych odchýlok na  $x_{(j)}$ , t.j. body  $[x_{(j)}, y_j]$ , kde  $y_j = \sum_{i=1}^{1000} |x_i - x_{(j)}|$ . Podobné obrázky nakreslite aj pre  $\tilde{x}_p$  namiesto  $x_{(j)}$ .

DÚ

**Definícia 1 (asymptotické rozdelenie poriadkovej štatistiky)** Nech  $X_{(1)}, X_{(2)}, \dots, X_{(n)}$  sú poriadkové štatistiky náhodného výberu  $X_1, X_2, \dots, X_n$ . Majme pravdepodobnosť  $\alpha$ , kde  $F(t_\alpha) = \alpha$ . Asymptoticky platí, že  $\sqrt{n}(\frac{j}{n} - \alpha)$  konverguje k 0. Potom je poriadková štatistika  $X_{(j)}$  normálne rozdelená so strednou hodnotou  $E[X_{(j)}] = t_\alpha$  a rozptylom  $\sigma_{X_{(j)}}^2 = \frac{\alpha(1-\alpha)}{f^2(t_\alpha)n}$ . Ak  $X \sim N(\mu, \sigma^2)$ , potom  $\sigma_{X_{(j)}}^2 = \sigma^2 \frac{\pi^2}{24 \ln n}$ .

**Príklad 51 (rozptyl poriadkovej štatistiky)** Pomocou delta metódy odvod'te rozptyl poriadkovej štatistiky v definícii 1.

DÚ

**Príklad 52 (rozptyl poriadkovej štatistiky,  $X \sim N(\mu, \sigma^2)$ )** Pomocou definície 1 odvod'te rozptyl poriadkovej štatistiky, ak  $X \sim N(\mu, \sigma^2)$ .

DÚ

**Definícia 2 (stredná hodnota a rozptyl mediánu)** Stredná hodnota mediánu  $X_{(\frac{n+1}{2})}$  je rovná  $E[X_{(\frac{n+1}{2})}] = \tilde{\mu}$  a rozptyl mediánu  $\sigma_{X_{(\frac{n+1}{2})}}^2 = \frac{1}{4f^2(\tilde{\mu})n}$ , kde  $n$  je nepárne. Ak  $X \sim N(\mu, \sigma^2)$ , potom  $\sigma_{X_{(\frac{n+1}{2})}}^2 = \sigma^2 \frac{\pi}{2n}$ .

pred


**Príklad 53 (rozptyl mediánu)** Pomocou delta metódy odvod'te rozptyl poriadkovej štatistiky v definícii 2.

DÚ

**Príklad 54 (rozptyl mediánu,  $X \sim N(\mu, \sigma^2)$ )** Pomocou definície 2 odvod'te rozptyl poriadkovej štatistiky, ak  $X \sim N(\mu, \sigma^2)$ .

DÚ

**Príklad 55 (pásy normality)** Na základe vygenerovaných pseudonáhodných čísel  $X \sim N(\mu, \sigma^2)$ ,  $n = 100, \mu = 0, \sigma^2 = 1$ , kde  $M = 1000$ , odhadnite (a) hustotu  $m$ -tej realizácie pomocou funkcie `density()`; ponechajte argument `n=512` a nastavte `from=-3` a `to=3`; (b) distribučnú funkciu  $m$ -tej realizácie pomocou (a) a funkcie `cumsum()` a (c) empirické kvantily  $m$ -tej realizácie pomocou funkcie `qqnorm()`. Vygenerované čísla  $x_{mi}, m = 1, 2, \dots, 1000$  a  $i = 1, 2, \dots, 100$ , uložte po riadkoch do matice  $\mathbf{X}$ , ktorá bude mať rozmer 1000  $\times$  100. Odhadnuté hustoty a distribučné funkcie uložte po riakodoch do matíc  $\mathbf{H}$  a  $\mathbf{D}$ , ktoré bude mať rozmer 1000  $\times$  512 a empirické kvantily do matice  $\mathbf{K}$ , ktorá bude mať rozmer 1000  $\times$  100. Pre každú z matíc  $\mathbf{H}$ ,  $\mathbf{D}$  a  $\mathbf{K}$  vypočítajte  $\tilde{x}_{0.05}$  a  $\tilde{x}_{0.95}$  po stĺpcach a zobrazte ich ako pásy pomocou funkcie `polygon()`. Do obrázkov vkreslite (a) teoretickú hustotu, (b) teoretickú distribučnú funkciu a (c) kvantilovú priamku (pomocou funkcie `qqline()`) červenou farbou. Obrázky usporiadajte ako trojicu vedľa seba. Dáta, ktorých normalitu chceme graficky testovať budú (1)  $X \sim N(0, 1)$ ,  $n = 100$ , (2)  $X \sim [pN(0, 1) + (1-p)N(0, 4)]$ ,  $n = 100$  a  $p = 0.95$  a (3)  $X \sim [pN(0, 1) + (1-p)N(0, 4)]$ ,  $n = 100$  a  $p = 0.9$ . Zobrazte (1), (2) a (3) oddelene do grafov (a), (b) a (c). Okomentujte. Riešenie (1) pozri na obrázku 15.



Obr. 15: Pásy spoľahlivosti normálneho rozdelenia – pre hustotu (vl'avo), distribučnú funkciu (uprostred) a kvantilovú priamku (vpravo)

### 3 Testovanie hypotéz

Aby sme mohli z dát vyvodíť nejaké interpretovateľné závery, musíme najprv ciele (účely, biologicky formulované hypotézy) výskumu preformulovať do matematicko-štatistickej podoby. Takáto formulácia je dôležitá pri výbere správneho modelu na dátu. V prípade parametrického modelu máme jeho parametre  $\theta$ , kde hypotézy sú o týchto parametroch. Jednou hypotézou je tzv. nulová hypotéza, čo je tvrdenie o  $\theta$ , ktoré testujeme prostredníctvom nejakého **štatistického testu**. Ďalšou je alternatívna hypotéza, ktorá je doplnkom nulovej hypotézy v priestore, z ktorého pochádza  $\theta$ . Na základe výsledku testu vyvodíme záver o  $\theta$ . Proces testovania hypotéz nazývame aj **štatistická inferencia**, ktorej základom je **štatistická teória testovania hypotéz**.

**Definícia 3 (štatistický test)** Ak parametrický priestor  $\Theta$ , do ktorého patrí parameter  $\theta$  modelu  $\mathcal{F}$  rozdelíme na dve podmnožiny  $\Theta_0$  a  $\Theta_1$ , kde  $\Theta = \Theta_0 \cup \Theta_1$ , potom **štatistický test**  $T = T(X)$  predstavuje funkciu  $X$  z výberového priestoru  $\mathcal{Y}$  do priestoru  $\Theta_0 \cup \Theta_1$ . Štatistický test je teda pravidlo výberu jednej z dvoch možností, nulovej a alternatívnej, na základe dát. **Nulovú hypotézu** definujeme ako  $H_0 : \theta \in \Theta_0$  a **alternatívnu hypotézu** ako  $H_1 : \theta \in \Theta_1$ . Prvky množiny  $\mathcal{Y}$ , pre ktoré zamietame  $H_0$ , predstavujú tzv. **oblasť (obor) nezamietania nulovej hypotézy**. Tieto prvky označujeme  $\mathcal{Y}_0$ . V tomto prípade  $H_0$  nezamietame. Prvky množiny  $\mathcal{Y}$ , pre ktoré nezamietame  $H_0$ , predstavujú tzv. **oblasť (obor) zamietania nulovej hypotézy alebo kritickú oblasť**. Tieto prvky označujeme  $\mathcal{Y}_1 = \mathcal{W}_X$ . V tomto prípade  $H_0$  zamietame. Rozdelenie priestoru  $\Theta$  na obor zamietania  $\mathcal{W}_T = \mathcal{W}$  a nezamietania  $\mathcal{A}_T$  prebieha na základe **testovacej štatistiky**  $T(X)$ .

Stretávame sa s nasledovnými štyrmi možnosťami:

- A) ak platí  $H_0$ , tak naše rozhodutie je nezamietnuť  $H_0$  (správne);
- B) ak platí  $H_0$ , tak naše rozhodutie je zamietnuť  $H_0$  (nesprávne);
- C) ak neplatí  $H_0$ , tak naše rozhodutie je nezamietnuť  $H_0$  (nesprávne);
- D) ak neplatí  $H_0$ , tak naše rozhodutie je zamietnuť  $H_0$  (správne).

V prípade B, C je naše rozhodnutie nesprávne, v prípade A, D správne. V prípade B sa dopúšťame **chyby prvého druhu (CHPD)**, kde  $\text{Pr}(\text{CHPD}) \leq \alpha$  a  $\alpha$  sa nazýva **hladina významnosti**. Doplňok

ku  $\alpha$  je pravdepodobnosť  $1 - \alpha$  a nazýva sa **koefficient spoľahlivosti** (prípad A). V prípade C sa dopúšťame **chyby druhého druha** (CHDD), kde  $\Pr(\text{CHDD}) = \beta$ . Doplnok ku  $\Pr(\text{CHDD})$  je pravdepodobnosť  $1 - \beta$  a nazýva sa **sila testu** (pri nejakej alternatíve; prípad D). Sila testu závisí na zvolenej testovacej metóde a hlavne na tom, aké je skutočné rozdelenie náhodnej premennej  $X$ , aký je typ použitej testovacej štatistiky alebo aké sú skutočné hodnoty parametrov  $\theta$ .

Teda

rozhodnutie/skutočnosť	$H_0$ platí	$H_0$ neplatí
$H_0$ nezamietnuť	správne rozhodnutie	chyba II. druha
$H_0$ zamietnuť	chyba I. druha	správne rozhodnutie

Vyššie uvedené pravdepodobnosti môžeme zosumarizovať nasledovne:

- A)  $1 - \alpha \leq \Pr(\text{nezamietni } H_0 | H_0 \text{ platí}) = \Pr(\text{nezamietni } H_0 | H_1 \text{ neplatí});$
- B)  $\alpha \geq \Pr(\text{CHPD}) = \Pr(\text{zamietni } H_0 | H_0 \text{ platí}) = \Pr(\text{zamietni } H_0 | H_1 \text{ neplatí});$
- C)  $\beta = \Pr(\text{CHDD}) = \Pr(\text{nezamietni } H_0 | H_0 \text{ neplatí}) = \Pr(\text{nezamietni } H_0 | H_1 \text{ platí});$
- D)  $1 - \beta = \Pr(\text{zamietni } H_0 | H_0 \text{ neplatí}) = \Pr(\text{zamietni } H_0 | H_1 \text{ platí}).$

V prípade (A) a (B) hovoríme o teste na hladine významnosti  $\alpha$  ( $\alpha$ -level test). Ak v (A) a (B) nahradíme znamienko nerovnosti rovnosťou, hovoríme o teste úrovne  $\alpha$  (size  $\alpha$  test). Test  $\mathcal{T}(\mathbf{x})$  charakterizujeme jeho **silofunkciou**  $\beta^*(\theta) = 1 - \beta(\theta) = \Pr(\theta \in \Theta : \mathcal{T}(\mathbf{x}) = \Theta_1)$ . Táto je závislá na  $\theta$  a niekoľkých iných argumentoch (vždy sú špecifikované pri konkrétnych testoch) ako aj na type alternatívnej hypotézy. **Hladina významnosti**  $\alpha$  je možné definovať tiež pomocou  $\beta^*(\theta)$ , kde  $\alpha = \sup_{\theta \in \Theta_0} \beta^*(\theta)$ , t.j. ide o najväčšiu možnú pravdepodobnosť chyby I. druha.

Hladina významnosti  $\alpha$  je daná (určená štatistikom, experimentátorom) vopred, testovacia štatistika  $\mathcal{T}(\mathbf{x})$  sa vypočíta na základe realizácií (odpovedí)  $x$  náhodnej premennej  $X$ , kritická hodnota (alebo kvantil) sa nájde v štatistických tabuľkách alebo ju vypočítame pomocou .

V praxi teda voľba  $\mathcal{W}$  závisí na požiadavke, aby pravdepodobnosť chyby I. druha bola menšia alebo rovná zvolenému kladnému číslu  $\alpha$ , kde  $\alpha \in (0, 1/2)$ , najčastejšie  $\alpha = 0.05, 0.01$  alebo  $0.001$ . Súčasne volíme  $\mathcal{W}$  tak, aby pravdepodobnosť chyby I. druha bola čo najmenšia. Optimálne by sme chceli mať  $\beta^*(\theta)$  (pri nejakej hodnote  $\theta$ ) tak veľké číslo (blížiace sa jednotke) ako je možné, ked'  $\theta \in \Theta_1$  a také malé číslo, ked'  $\theta \in \Theta_0$ . Tieto dve požiadavky sú v konflikte, t.j.

- zväčšovanie oboru nezamietania  $H_0$  zmenšuje pravdepodobnosť chyby I. druha, ale zväčšuje pravdepodobnosť chyby II. druha;
- zmenšovanie oboru nezamietania  $H_0$  zväčšuje pravdepodobnosť chyby I. druha, ale zmenšuje pravdepodobnosť chyby II. druha.

Extrémnymi prípadmi sú dve situácie, kde  $\mathcal{T}_0(\mathbf{x}) = \Theta_0$  a  $\mathcal{T}_1(\mathbf{x}) = \Theta_1$ , t.j. každý z týchto dvoch testov je najlepší možný, ked'  $\theta$  patrí určitej podmnožine  $\Theta$ , ale najhorší možný v opačnom prípade.


Klasickým prístupom k tejto dileme je **Neyman-Pearsonov prístup**, kde dopredu fixujeme  $\alpha$  a vyberieme taký test, ktorý má pri danej alternatíve najväčšiu silu  $1 - \beta$  pre  $\theta \in \Theta_1$  medzi všetkými možnými na teoretsky stanovenej (danej, nominálnej) hladine významnosti  $\alpha$ . Testy spomínané v kapitolách 5 až 8 sú najsilnejšími testami pri daných alternatívach za určitých predpokladov (bližšie pozri kap. 5 až 8). V reálnych situáciách (alebo často aj za porušenie predpokladov testov) sa nominálna hladina významnosti lísi od aktuálnej (skutočnej) hladiny významnosti.

**Definícia 4 (kvantil)** Nech  $F_X$  je distribučná funkcia náhodnej premennej  $X$  a  $\alpha \in (0, 1)$ , kde  $F_X(x_\alpha) = \alpha$ . Potom číslo  $x_\alpha = F_X^{-1}(\alpha)$  sa nazýva  $\alpha$ -**kvantil** príslušného rozdelenia. Pre vybrané rozdelenia platí

- $\Pr(X < x(1 - \alpha)) = 1 - \alpha$  pre  $X \sim N(0, 1)$  (**normálne rozdelenie** s parametrami  $\mu = 0$  a  $\sigma^2 = 1$ ; hovorí sa mu aj **normálne normované rozdelenie** alebo **štandardizované normálne rozdelenie**);  $x(1 - \alpha)$  sa často zapisuje ako  $x_{1-\alpha}$ ;
- $\Pr(X < \chi^2_{df}(1 - \alpha)) = 1 - \alpha$  pre  $X \sim \chi^2_{df}$  (**chi-kvadrát rozdelenie** s  $df$  stupňami voľnosti);
- $\Pr(X < t_{df}(1 - \alpha)) = 1 - \alpha$  pre  $X \sim t_{df}$  (**Studentovo t-rozdelenie** s  $df$  stupňami voľnosti);
- $\Pr(X < F_{df_1, df_2}(1 - \alpha)) = 1 - \alpha$  pre  $X \sim F_{df_1, df_2}$  (**Fisherovo F-rozdelenie** s  $df_1$  a  $df_2$  stupňami voľnosti).

Hustoty vyššie spomenutých rozdelení pozri na obrázku 16. Tiež platí

- $\Pr(x_{\alpha/2} < X < x_{1-\alpha/2}) = F_X(x_{1-\alpha/2}) - F_X(x_{\alpha/2}) = 1 - \alpha$ , kde  $\alpha \in (0, 1/2)$ ;
- $\Pr(X < Q_1) = 1/4$ , kde  $Q_1 = F_X^{-1}(1/4)$  sa nazýva **výberový prvý kvartil (dolný kvartil)**;
- $\Pr(X < Q_2) = 1/2$ , kde  $Q_2 = F_X^{-1}(1/2)$  sa nazýva **výberový druhý kvartil (medián)**;
- $\Pr(X < Q_3) = 3/4$ , kde  $Q_3 = F_X^{-1}(3/4)$  sa nazýva **výberový tretí kvartil (horný kvartil)**;
- $Q_d = F_X^{-1}(k/10)$  sa nazýva **výberový k-ty decil**,  $Q_p = F_X^{-1}(k/100)$  sa nazýva **výberový k-ty percentil**.



Obr. 16: Grafické znázornenie hustôt normálneho rozdelenia,  $t$ -rozdelenia,  $\chi^2$ -rozdelenia a  $F$ -rozdelenia pri rôznych stupňoch voľnosti

**Definícia 5 (kritická hodnota)** **Kritická hodnota** príslušného rozdelenia je hodnota, ktorú náhodná premenná  $X$  prekročí s pravdepodobnosťou  $\alpha$ . Pre vybrané rozdelenia platí

- $\Pr(X > u(\alpha)) = \alpha$  pre  $X \sim N(0, 1)$ ;  $u(\alpha)$  sa často zapisuje ako  $u_\alpha$ ;

- $\Pr(X > \chi^2_{df}(\alpha)) = \alpha$  pre  $X \sim \chi^2_{df}$ ;
- $\Pr(X > t_{df}(\alpha)) = \alpha$  pre  $X \sim t_{df}$ ;
- $\Pr(X > F_{df_1, df_2}(\alpha)) = \alpha$  pre  $X \sim F_{df_1, df_2}$ .

Z vyššie uvedeného je zreteľné, že  $\alpha \times 100\%$  kritická hodnota je identická s  $(1 - \alpha) \times 100\%$  kvantilom. Pri kritickej hodnote počítame obsah pod krivkou hustoty príslušného rozdelenia nad týmto bodom a pri kvantile pod týmto bodom.


**Stupeň volnosti**  $df$  predstavujú množstvo nezávislej informácie, ktoré potrebujeme na charakterizáciu rozdelenia pravdepodobnosti nejakej náhodnej premennej. Používajú sa aj namiesto  $n$  ako prevencia pred nadhodnotením odhadu nejakého parametra (napr. rozptylu). Ide najčastejšie o rozsah náhodného výberu  $n$  zmenšený o jedna (napr. Studentovo  $t$ -rozdelenie,  $F$ -rozdelenie), kde jednotka odpočítaná od  $n$  znamená jeden voľne viazaný parameter (napr. jedna stredná hodnota, jeden rozptyl a pod.). Pri zložitejších modeloch s viacerými parametrami odpočívame od  $n$  počet voľne viazaných parametrov (napr. počet stredných hodnôt) alebo  $df$  môže tiež predstavovať počet hladín kategoriálnej premennej zmenšený o počet voľne viazaných parametrov.

**Príklad 56 (štandardizované normálne rozdelenie)** Vypočítajte kritické hodnoty  $u(\alpha)$  rozdelenia  $N(0, 1)$ , kde  $\alpha = 0.1, 0.05, 0.01, 0.025$  a  $0.005$ .


**Riešenie v R** (pozri obrázok 17 a 18)

```
2 | qnorm(1-0.1) # 1.281552
3 | qnorm(1-0.05) # 1.644854
4 | qnorm(1-0.01) # 2.326348
5 | qnorm(1-0.025) # 1.959964
6 | qnorm(1-0.005) # 2.575829
```

Na výpočet pravdepodobnosti pod kvantilom sa používa funkcia `pnorm(Q)`. Na výpočet pravdepodobnosti nad kritickou hodnotou sa používa funkcia `1-pnorm(Q)`. Ked'že štandardizované normálne rozdelenie je symetrické okolo nuly,  $u(\alpha) = u(1 - \alpha)$ .



Obr. 17: Grafické znázornenie významu pravdepodobnosti pod krivkou rozdelenia medzi dvoma kvantilmi (normálne rozdelenie)



Obr. 18: Grafické znázornenie významu pravdepodobnosti (obsahu) pod krivkou normálneho rozdelenia; obsah pod (prvý riadok) a nad (druhý riadok) príslušným kvantilom

**Príklad 57 (Studentove t-rozdelenie)** Vypočítajte kritické hodnoty Studentovho  $t$ -rozdelenia so stupňami voľnosti  $df = 10$ , t.j.  $t_{df}(\alpha)$ , kde  $\alpha = 0.1, 0.05, 0.01, 0.025$  a  $0.005$ .

**Riešenie v R** (pozri obrázok 19)

```


7 | qt(1-0.1,10) # 1.372184
8 | qt(1-0.05,10) # 1.812461
9 | qt(1-0.01,10) # 2.763769
10 | qt(1-0.025,10) # 2.228139
11 | qt(1-0.005,10) # 3.169273

```

Na výpočet pravdepodobnosti pod kvantilom sa používa funkcia `pt(Q, df)`. Na výpočet pravdepodobnosti nad kritickou hodnotou sa používa funkcia `1-pt(Q, df)`. Ked'že Studentovo  $t$ -rozdelenie je symetrické okolo nuly,  $t_{df}(\alpha) = t_{df}(1-\alpha)$ . Nejaký kvantil štandardizovaného normálneho rozdelenia je približne rovný kvantilu  $t$ -rozdelenia až pre veľmi veľké stupne voľnosti (resp. pravdepodobnosti nad kritickými hodnotami sú približne rovnaké). Napr.  $1-pnorm(1.644854) \approx 1-pt(1.644869, 100000) = 0.05$ . Avšak napr.  $1-pt(1.644869, 100) \doteq 0.052$ .

**Príklad 58 ( $\chi^2$ -rozdelenie)** Vypočítajte kritické hodnoty  $\chi^2$ -rozdelenia so stupňami voľnosti  $df = 10$ , t.j.  $\chi_{df}^2(\alpha)$ , kde  $\alpha = 0.1, 0.05, 0.01, 0.025$  a  $0.005$ .

**Riešenie v R** (pozri obrázok 20)



Obr. 19: Grafické znázornenie významu pravdepodobnosti (obsahu) pod krivkou  $t$ -rozdelenia s  $df = 10$ ; obsah pod (prvý riadok) a nad (druhý riadok) príslušným kvantilom

```

12 | qchisq(1-0.1,10) # 15.98718
13 | qchisq(1-0.05,10) # 18.30704
14 | qchisq(1-0.01,10) # 23.20925
15 | qchisq(1-0.025,10) # 20.48318
16 | qchisq(1-0.005,10) # 25.18818

```

Na výpočet pravdepodobnosti pod kvantilom alebo nad kritickou hodnotou sa používa funkcia  $pchisq(Q, df)$ . Keďže  $\chi^2$ -rozdelenie nie je symetrické,  $\chi_{df}^2(\alpha) \neq \chi_{df}^2(1 - \alpha)$ .

**Príklad 59 ( $F$ -rozdelenie)** Vypočítajte kritické hodnoty  $F$ -rozdelenia so stupňami volnosti  $df_1 = 20$  a  $df_2 = 20$ , t.j.  $F_{df_1, df_2}(\alpha)$ , kde  $\alpha = 0.1, 0.05, 0.01, 0.025$  a  $0.005$ .


**Riešenie v R** (pozri obrázok 21)

```

17 | qf(1-0.1,20,20) # 1.793843
18 | qf(1-0.05,20,20) # 2.124155
19 | qf(1-0.01,20,20) # 2.937735
20 | qf(1-0.025,20,20) # 2.464484
21 | qf(1-0.005,20,20) # 3.317786

```

Na výpočet pravdepodobnosti pod kvantilom sa používa funkcia  $pf(Q, df1, df2)$ . Na výpočet pravdepodobnosti nad kritickou hodnotou sa používa funkcia  $1-pf(Q, df1, df2)$ . Keďže  $F$ -rozdelenie nie je symetrické,  $F_{df_1, df_2}(\alpha) \neq F_{df_1, df_2}(1 - \alpha)$ .



Obr. 20: Grafické znázornenie významu pravdepodobnosti (obsahu) pod krivkou  $\chi^2$ -rozdelenia s  $df = 10$ ; obsah pod (prvý riadok) a nad (druhý riadok) príslušným kvantilom

**Veta 1 (koeficient variácie)** Nech náhodná premenná  $X$  pochádza z normálneho rozdelenia s parametrami  $\mu$  a  $\sigma^2$ ,  $X \sim N(\mu, \sigma^2)$ , kde  $E[X] = \mu$  je stredná hodnota a  $Var[X] = \sigma^2$  je rozptyl náhodnej premennej  $X$ . Nech  $g(\boldsymbol{\theta}) = \sigma/\mu$ , kde  $\boldsymbol{\theta} = (\mu, \sigma^2)^T$ ,  $g(\hat{\boldsymbol{\theta}}_n) = \frac{S_n}{\bar{X}_n}$  a  $\Delta = \frac{\partial}{\partial \boldsymbol{\theta}} g(\boldsymbol{\theta}) = \left( -\frac{\sigma}{\mu^2}, \frac{1}{2\sigma\mu} \right)^T$ . Potom

$$\sqrt{n} \left( \frac{S_n}{\bar{X}_n} - \frac{\sigma}{\mu} \right) \stackrel{\mathcal{D}}{\sim} N_k \left( 0, \Delta^T (i(\boldsymbol{\theta}))^{-1} \Delta \right),$$


$$\text{kde } \Delta^T (i(\boldsymbol{\theta}))^{-1} \Delta = \left( -\frac{\sigma}{\mu^2}, \frac{1}{2\sigma\mu} \right) \begin{pmatrix} \sigma^2 & 0 \\ 0 & 2\sigma^4 \end{pmatrix} \left( -\frac{\sigma}{\mu^2}, \frac{1}{2\sigma\mu} \right)^T = \frac{\sigma^2}{\mu^2} \left( \frac{\sigma^2}{\mu^2} + \frac{1}{2} \right).$$

**Príklad 60 (koeficient variácie)** Pomocou delta metódy odvod'te rozptyl koeficientu variácie z vety 1.

DÚ

**Príklad 61 (MC experiment pre IS)** Nech (a)  $X \sim N(0, 1)$  a (b)  $X \sim [pN(0, 1) + (1-p)N(0, 4)]$ , kde  $p = 0.9$ , t.j. ide o zmes dvoch normálnych rozdelení  $X \sim N(0, 1)$  a  $X \sim N(0, 4)$  v pomere 9:1. Vygenerujte  $M = 100$  náhodných výberov s rozsahom  $n = 500$  a vypočítajte  $100(1 - \alpha)\%$  empirický IS pre  $\mu$ . Zistite, kol'ko IS obsahuje strednú hodnotu  $\mu = 0$ . Toto číslo podelené  $M$  predstavuje simulovanú hladinu významnosti  $\alpha$ .

cvič.



Obr. 21: Grafické znázornenie významu pravdepodobnosti (obsahu) pod krivkou  $F$ -rozdelenia s  $df_1 = 20$  a  $df_2 = 20$ ; obsah pod (prvý riadok) a nad (druhý riadok) príslušným kvantilom

**Definícia 6 (hodnoty distribučnej funkcie v kvantiloch)** Empirická distribučná funkcia  $F_n(x)$  je definovaná nasledovne

$$F_n(x) = \begin{cases} 0, & \text{ak } x < X_{(1)}, \\ \frac{i}{n}, & \text{ak } X_{(i)} \leq x < X_{(i+1)}, \\ 1, & \text{ak } x \geq X_{(n)}. \end{cases}$$

Majme transformáciu  $T_{(1)} = F_n(X_{(1)})$ ,  $T_{(2)} = F_n(X_{(2)})$ , ...,  $T_{(n)} = F_n(X_{(n)})$ . Potom  $T_{(1)}$ ,  $T_{(2)}$ , ...,  $T_{(n)}$  sú **poriadkové štatistiky**. Potom platí

$$\lim_{n \rightarrow \infty} \Pr\left(\sup_{\forall x \in \mathcal{Y}} [F_n(x) - F(x)] n^{1/2} \leq \lambda\right) = \Phi(\lambda),$$

kde  $F(X)$  je teoretická distribučná funkcia a  $\Phi(\lambda) = \sum_{k=-\infty}^{\infty} (-1)^k e^{-2k^2\lambda^2}$ . Potom  $100 \times (1 - \alpha)\%$  pás spoločlivosti pre  $F_n(x)$  definujeme ako  $F_n(x) \pm \lambda_\alpha 1/n^{1/2}$ , kde  $\Phi(\lambda_\alpha) = 1 - \alpha$  a  $\text{Var}[F_n(x)] = 1/n$ . Potom môžeme tvrdiť, že  $F(X)$  patrí do  $100 \times (1 - \alpha)\%$  pásu spoločlivosti a zároveň je medzi nulou a jednotkou s pravdepodobnosťou  $1 - \alpha$ .

pred

**Príklad 62 (graf distribučnej funkcie a jej IS)** Nakreslite graf distribučnej funkcie  $N(\mu, \sigma^2)$ , kde  $\mu = 0$  a  $\sigma^2 = 1$ . Do grafu dokreslite 95% pás spoločlivosti pre  $F(x)$ . Jeho hranice vypočítajte pomocou simulácie pseudonáhodných čísel z  $N(0, 1)$  pri  $n = 50$ , kde  $F_n(x)$  je odhadnutá z dát.

cvič.