

## Zadání příkladů - cvičení č.1 - 15-9-23

### Příklad č.1 (porovnání dvou typů modelů) (přednáška)

Model rozdělení pravděpodobnosti je modelem náhodné proměnné  $X$ , např. (1) model rozdělení pravděpodobnosti náhodné proměnné  $X$  šířka dolní čelisti, nebo (2) model rozdělení pravděpodobnosti náhodné proměnné  $X$  hrubost kožních řas u dospělých zdravých žen. Statistický model je modelem náhodné proměnné  $Y|X$  ( $Y$  kauzálně závisí na  $X$ ), např. (1) model závislosti náhodné proměnné  $Y$  šířka dolní čelisti na proměnné  $X$  pohlaví, nebo (2) model závislosti náhodné proměnné  $Y$  hrubost kožních řas u dospělých zdravých žen na proměnné  $X$  BMI. Všimněme si, že náhodné proměnné označujeme  $X$  anebo  $Y$  podle toho, jaký model je charakterizuje.

### Příklad č.2 (jednoduchý náhodný výběr)

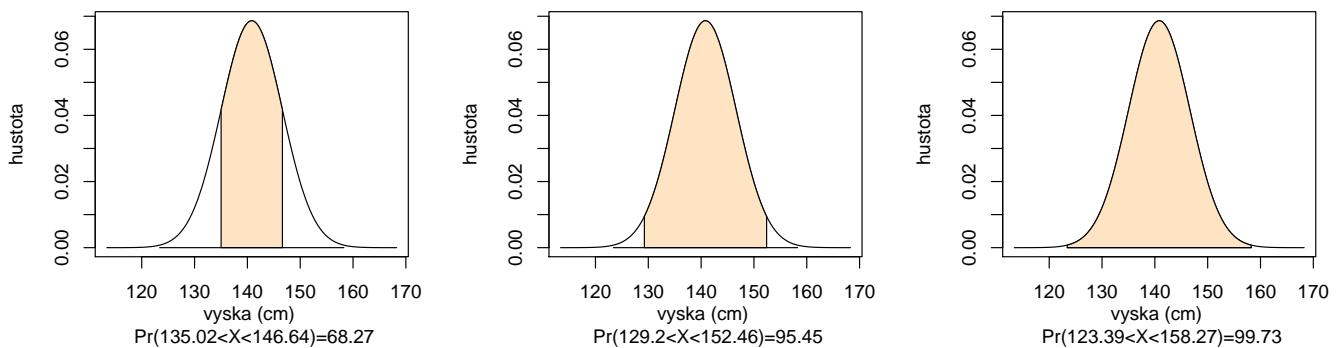
V jednoduchém náhodném výběru o rozsahu  $n$  z populace s konečným rozsahem  $N$  má každý prvek stejnou pravděpodobnost vybrání. Pokud vybíráme bez vracení (opakování), mluvíme o *jednoduchém náhodném výběru bez vracení* (Dalgaard, 2008). Pokud vybíráme s vracením, mluvíme o *jednoduchém náhodném výběru s vracením*. Mějme množinu  $\mathcal{M}$  s  $N = 10$  prvky a chceme z ní vybrat  $n = 3$  prvky (a) bez vracení, (b) s vracením. Kolik máme možností? Jak vypadá jedna takováto možnost, pokud  $\mathcal{M} = \{1, 2, \dots, 10\}$ ? Zopakujte to samé pro  $N = 100$ ,  $n = 30$  a množinu  $\mathcal{M} = \{1, 2, \dots, 100\}$ .

### Příklad č.3 (jednoduchý náhodný výběr)

Mějme skupinu lidí označených identifikačními čísly (ID) od 1 do 30. Vyberte (a) náhodně 5 lidí z 30-ti bez návratu, (b) náhodně 5 lidí ze 30-ti s návratem a nakonec (c) náhodně 5 lidí ze 30-ti bez návratu, přičemž lidé s ID od 28-mi do 30-ti mají pravděpodobnost vybrání 4× vyšší než lidé s ID od 1 do 27.

### Příklad č.4 (normální rozdělení)

Mějme náhodnou proměnnou  $X$  (může to být např. výška postavy desetiletých dívek) a předpokládejme, že tato náhodná proměnná má normální rozdělení s parametry  $\mu$  (střední hodnota) a  $\sigma^2$  (rozptyl), což zapisujeme jako  $X \sim N(\mu, \sigma^2)$ ,  $\mu = 140.83$ ,  $\sigma^2 = 33.79$ . Normální rozdělení představuje model rozdělení pravděpodobnosti pro tuto náhodnou proměnnou. Vypočítejte pravděpodobnost  $\Pr(a \leq X \leq b) = \Pr(X < b) - \Pr(X < a) = F_X(b) - F_X(a)$ , kde  $a = \mu - k\sigma$ ,  $b = \mu + k\sigma$ ,  $k = 1, 2, 3$ . Nakreslete hustotu rozdělení pravděpodobnosti, vybarvěte oblast mezi body  $a$  a  $b$  a popište osy  $x$  a  $y$  tak, jako je uvedeno na obrázku 1.

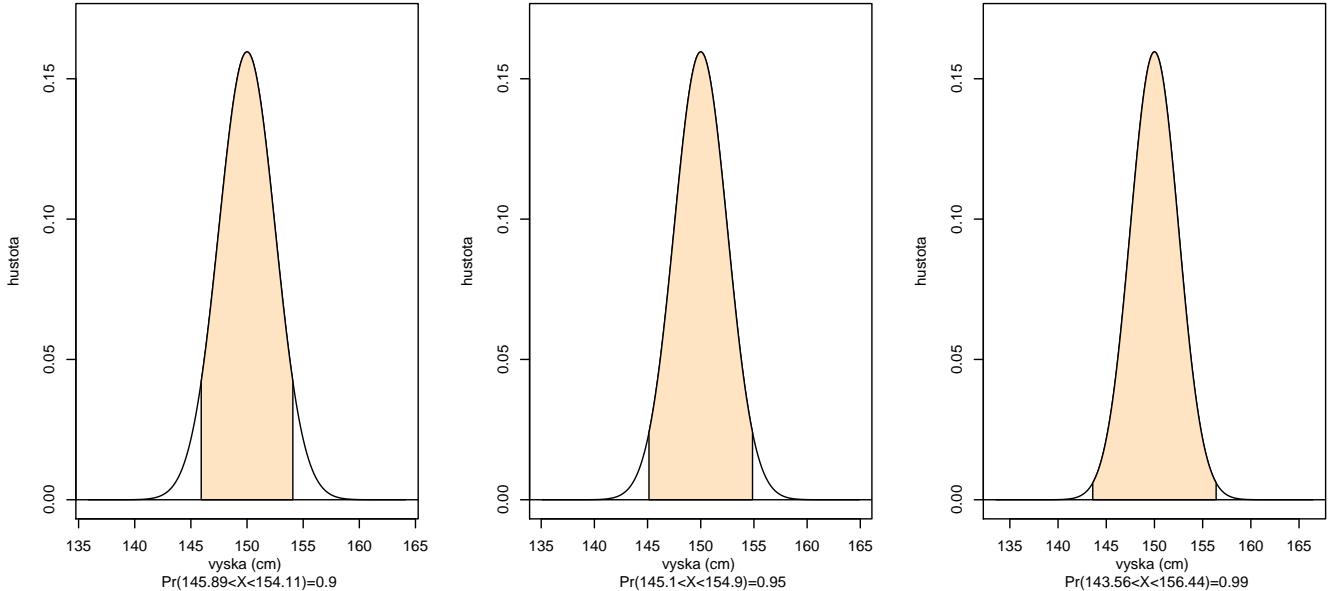


Obrázek 1: Míry normálního rozdělení; křivka hustoty s vybarveným obsahem pod touto křivkou mezi příslušnými kvantily na ose  $x$ ; obsah je rovný pravděpodobnosti výskytu subjektů s danou výškou v rozpětí těchto kvantilů.

Dostaneme pravidlo  $68.27 - 95.45 - 99.73$  (tzv. míry normálního rozdělení).

### Příklad č.5 (normální rozdělení)

Mějme  $X \sim N(\mu, \sigma^2)$ , kde  $\mu = 150$ ,  $\sigma^2 = 6.25$ . Vypočítejte  $a = \mu - x_{1-\alpha/2}\sigma$  a  $b = \mu + x_{1-\alpha/2}\sigma$  tak, aby  $\Pr(a \leq X \leq b) = 1 - \alpha$ , byla rovná 0.9, 0.95, 0.99. Číslo  $x_{1-\alpha/2}$  je kvantil normovaného normálního rozdělení, t.j.  $\Pr(Z = \frac{X-\mu}{\sigma} < x_{1-\alpha})$ ,  $Z \sim N(0, 1)$ . Nakreslete hustotu rozdělení pravděpodobnosti, vybarvěte oblast mezi body  $a$  a  $b$  a popište osy  $x$  a  $y$  tak, jako je uvedeno na obrázku 2.



Obrázek 2: Upravené míry normálního rozdělení; křivka hustoty s vybarveným obsahem pod touto křivkou mezi příslušnými kvantily na ose  $x$ ; obsah je rovný pravděpodobnosti výskytu subjektů s danou normovanou výškou v rozpětí těchto kvantilů.

Dostaneme pravidlo 90 – 95 – 99 (tzv. *upravené míry normálního rozdělení*). Použili jsme nerovnost  $\Pr(u_{\alpha/2} < Z < u_{1-\alpha/2}) = \Phi(x_{1-\alpha/2}) - \Phi(x_{\alpha/2}) = 1 - \alpha$ , kde  $\Phi$  je distribuční funkce normálního normovaného rozdělení a všeobecně ( $\alpha \in (0, 1/2)$ ); v příkladě  $\alpha = 0.1, 0.05$  a  $0.01$ .

### Příklad č.6 (normální rozdělení)

Předpokládejme model normálního rozdělení  $N(132, 13^2)$  pro systolický krevní tlak. Jaká část populace (%) bude mít hodnoty vyšší než 160 mm Hg?

### Příklad č.7 (binomické rozdělení)

Předpokládejme, že počet lidí upřednostňujících léčbu  $A$  před léčbou  $B$  se řídí modelem binomického rozdělení s parametry  $N$  (rozsah náhodného výběru) a  $p$  (pravděpodobnost výskytu), ozn.  $Bin(N, p)$ , kde  $N = 20$ ,  $p = 0.5$ , t.j. lidé preferují oba dva typy léčby stejnou měrou. (a) Jaká je pravděpodobnost, že 16 a více pacientů upřednostní léčbu  $A$  před léčbou  $B$ ? (b) Jaká je pravděpodobnost, že 16 a více a zároveň 4 a méně pacientů upřednostní léčbu  $A$  před léčbou  $B$ ?

### Příklad č.8 (binomické rozdělení)

Předpokládejme, že  $\Pr(vir) = 0.533 = p_1$  je pravděpodobnost výskytu dermatoglyfického vzoru vír na palci pravé ruky mužů české populace a  $\Pr(ostatni) = 0.467 = p_2$  je pravděpodobnost výskytu ostatních vzorů na palci pravé ruky mužů české populace, přičemž  $X$  je počet vírů a  $Y$  je počet ostatních vzorů, kde  $X \sim Bin(N, p_1)$  a  $Y \sim Bin(N, p_2)$ . Vypočítejte (1)  $\Pr(X \leq 120)$ , když  $N = 300$  a (2)  $\Pr(Y \leq 120)$ , když

$N = 300$ .

**Příklad č.9 (parametry) (přednáška)**

Příklady parametrů  $\theta$  - střední hodnota  $\mu$ , rozptyl  $\sigma^2$ , korelační koeficient  $\rho$ , pravděpodobnost  $p$  výskytu nějaké události, rozdíl dvou středních hodnot  $\mu_1 - \mu_2$ , podíl dvou rozptylů  $\sigma_1^2/\sigma_2^2$ , rozdíl dvou korelačních koeficientů  $\rho_1 - \rho_2$ , rozdíl dvou pravděpodobností  $p_1 - p_2$  apod.

**Příklad č.10 (binomické rozdělení) (přednáška)**

Pokud  $X \sim Bin(N, \theta)$ ,  $\theta = p \in \langle 0; 1 \rangle$ , potom  $\mathcal{Y}_\theta$  je stejný pro všechny  $\theta$  a koinciduje s výběrovým prostorem  $\mathcal{Y} = \{0, 1, \dots, N\}$ .

**Příklad č.11 (počet členů v mnohorozměrném LRM) (z přednášky)**

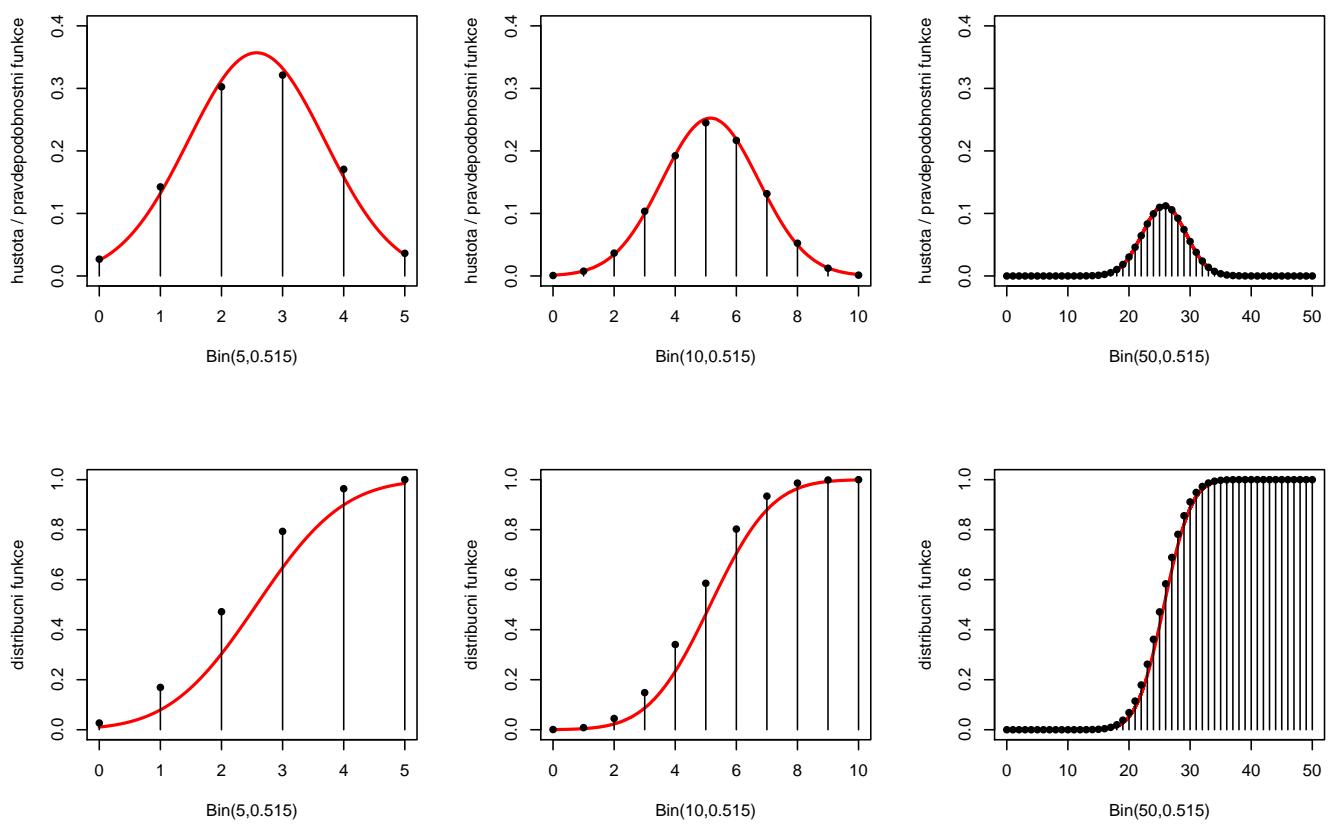
Mějme mnohorozměrný lineární regresní model  $\mathcal{L}$  o 20-ti proměnných, ve kterém jsou obsaženy všechny možné interakce těchto proměnných (dvojně, trojně, ...). Kolik členů (jednoduché regresory + všechny interakce) má takový model?

**Příklad č.11 (aproximace binomického rozdělení normálním)**

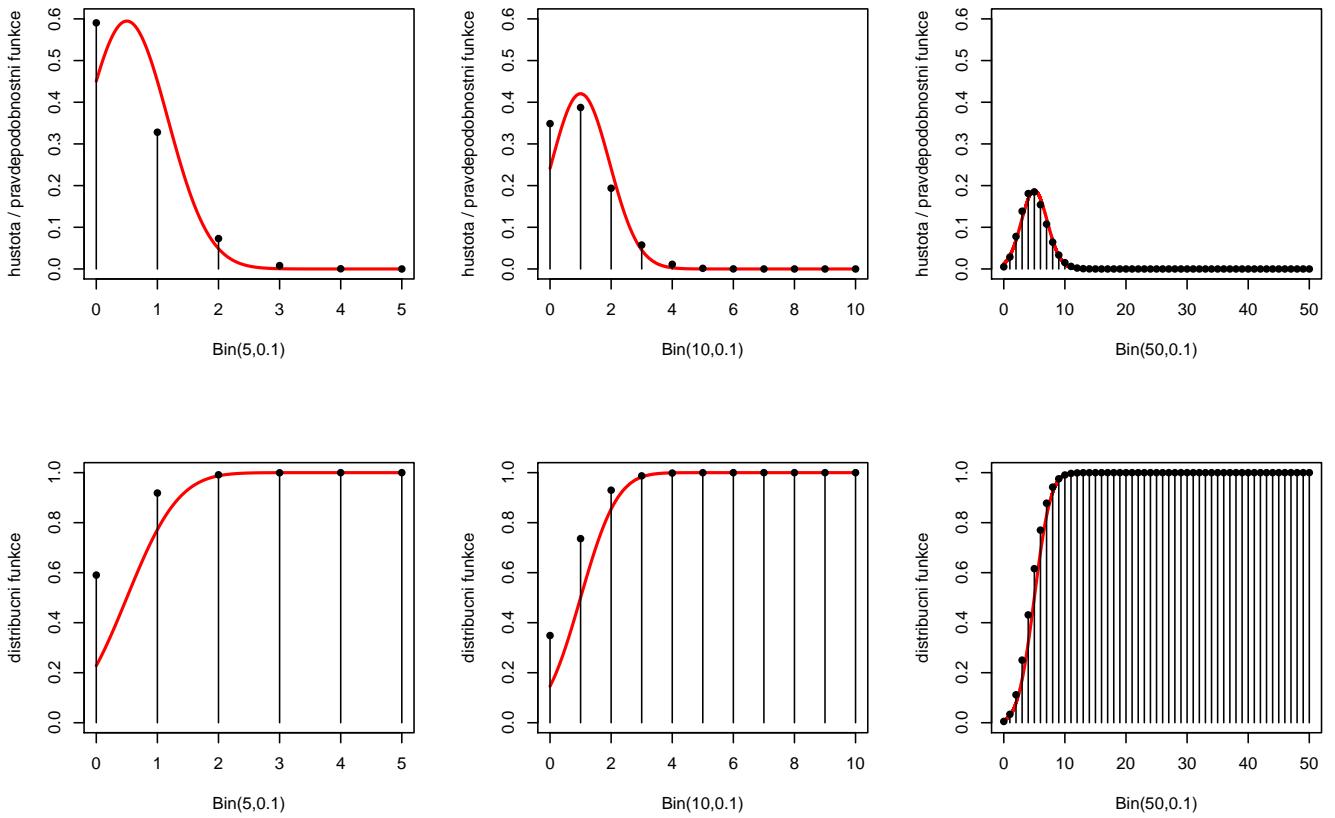
Nechť  $Pr(muz) = p = 0.515$  znamená pravděpodobnost výskytu mužů v populaci a  $Pr(zena) = q = 0.485$  pravděpodobnost výskytu žen. Nechť  $X$  je počet mužů a  $Y$  počet žen. Za předpokladu modelu  $Bin(N, p)$  vypočítejte (a)  $Pr(X \leq 3)$  pokud  $N = 5$ , (b)  $Pr(X \leq 5)$ , pokud  $N = 10$  a (c)  $Pr(X \leq 25)$ , pokud  $N = 50$ . Porovnejte vypočítané pravděpodobnosti s pravděpodobnostmi approximovanými normálním rozdělením  $N(Np, Npq)$ .

Nakreslete hustotu rozdělení pravděpodobnosti normálního rozdělení a superponujte ji pravděpodobnostní funkci binomického rozdělení tak, jak je uvedeno na obrázku 3. Nakreslete distribuční funkci normálního rozdělení a superponujte ji distribuční funkci binomického rozdělení tak, jak je uvedeno na obrázku 3.

Nakonec zvolte parametr  $p = 0.1$  a vygenerujte analogické grafy hustoty a distribuční funkce pro tento nový parametr. Z obrázků je vidět, že pro  $p$  blížící se k 1 nebo k 0 je potřebné mít větší početnosti než pro  $p$  blízké hodnotě 0.5. Viz obrázek 4.



Obrázek 3: Aproximace binomického rozdělení normálním pro  $p = 0.515$  a  $N = 5, 10$  a  $50$ ; spojnicový graf superponovaný hustotou (první řádek) a distribuční funkcií (druhý řádek).



Obrázek 4: Aproximace binomického rozdělení normálním pro  $p = 0.515$  a  $N = 5, 10$  a  $50$ ; spojnicový graf superponovaný hustotou (první řádek) a distribuční funkcí (druhý řádek).

### Příklad č.12 (normální rozdělení)

Model pro náhodný výběr  $X_1, X_2, \dots, X_n$  je z  $N(\mu, \sigma^2)$  a říkáme, že  $X_1, X_2, \dots, X_n$  pochází z normálního rozdělení, t.j.  $X \sim N(\mu, \sigma^2)$ . Parametr modelu  $N(\mu, \sigma^2)$  je vektor  $\theta = (\mu, \sigma^2)$ . Hustota tohoto rozdělení má tvar

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, x \in \mathbb{R}.$$

### Příklad č.13 (standardizované normální rozdělení)

Model pro náhodný výběr  $X_1, X_2, \dots, X_n$  pochází ze standardizovaného normálního rozdělení, t.j.  $X \sim N(\mu, \sigma^2)$ , kde  $\mu = 0$ ,  $\sigma^2 = 1$ . Parametr modelu  $N(\mu, \sigma^2)$  je vektor  $\theta = (0, 1)$ . Hustota tohoto rozdělení má tvar

$$\phi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}, x \in \mathbb{R}.$$

### Příklad č.14 (dvojrozměrné normální rozdělení)

Náhodný vektor  $(X, Y)^T$  má dvojrozměrné normální rozdělení

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

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  $(x, y)^T \in \mathbb{R}^2$ ,  $\mu_j \in \mathbb{R}$ ,  $\sigma_j^2 > 0$ ,  $j = 1, 2$ ,  $\rho \in \langle -1, 1 \rangle$  jsou parametry. Potom  $\boldsymbol{\theta} = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$ . Výraz v exponentu můžeme zapsat jako

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

Marginální rozdělení<sup>1</sup> jsou  $X \sim N(\mu_1, \sigma_1^2)$  a  $Y \sim N(\mu_2, \sigma_2^2)$ ,  $\rho$  je koeficient korelace<sup>2</sup> (Viz obrázek 5)

### Příklad č.15 (dvojrozměrné normální rozdělení)

(1) Nakreslete hustotu dvojrozměrného normálního rozdělení  $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  pomocí funkce `image()` a superponujte ho s konturovým grafem hustoty toho stejného rozdělení pomocí funkce `contour()`. (2) Nakreslete hustotu dvojrozměrného normálního rozdělení  $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  pomocí funkce `persp()`. Hustotu rozsekejte na 12 intervalů, kde hodnoty v těchto intervalech budou odpovídat barvám `terrain.colors(12)`. Použijte následující parametry:

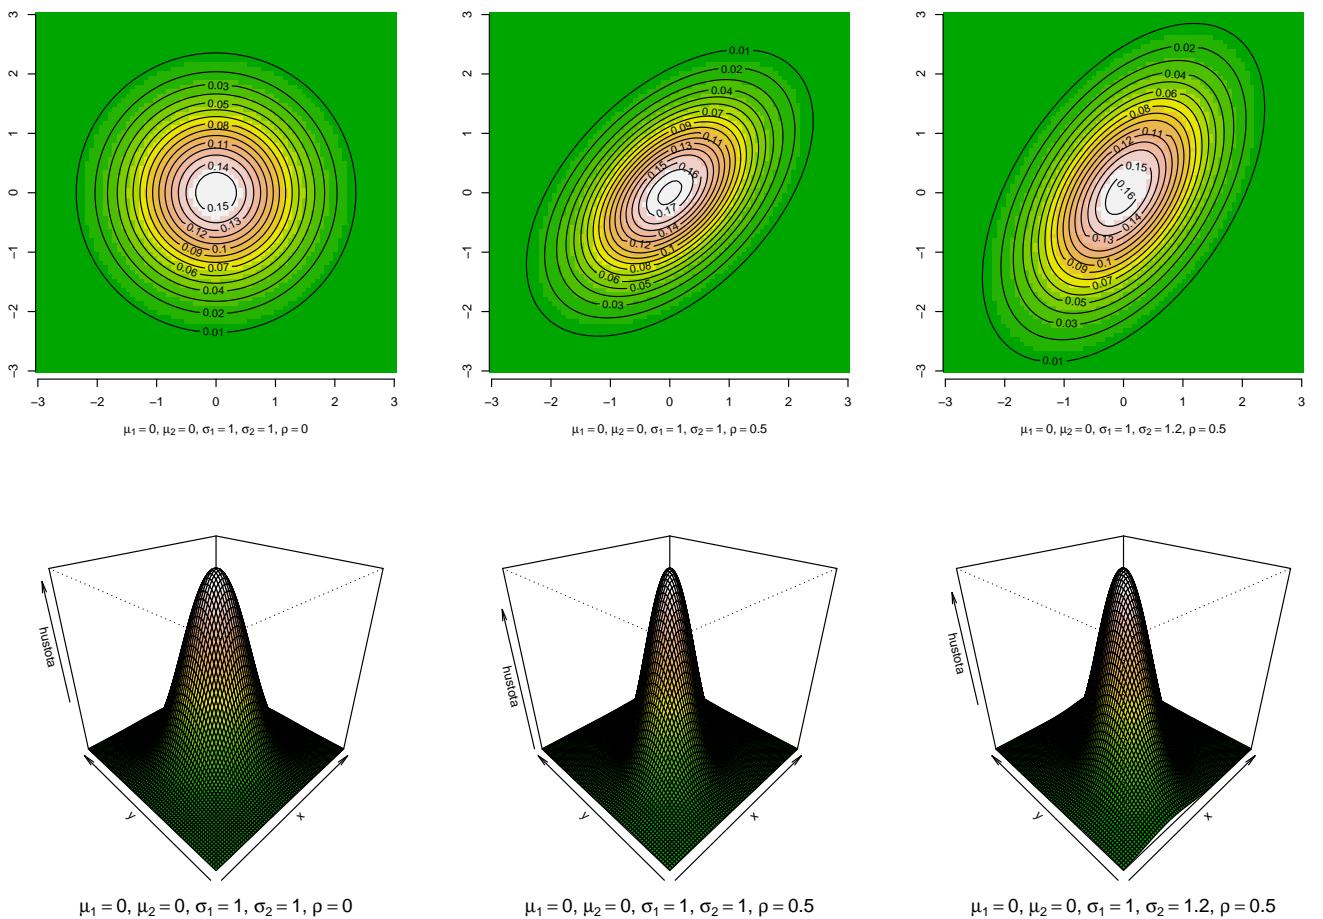
- $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0$ ;
- $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0.5$ ;
- $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1.2, \sigma_2 = 1, \rho = 0.5$ .

Vzorové řešení je uvedeno na obrázku 5.

---

<sup>1</sup>Marginální rozdělení je rozdělení náhodné proměnné, zde  $X$  nezávisle na  $Y$  a naopak  $Y$  nezávisle na  $X$ .

<sup>2</sup>Z tohoto příkladu je zřejmé, že na dostatečný popis dvojrozměrného normálního rozdělení potřebujeme pět parametrů, t.j. střední hodnotu a rozptyl pro marginální rozdělení náhodných proměnných  $X$  a  $Y$  a korelační koeficient  $\rho = \rho(X, Y)$  popisující sílu lineárního vztahu  $X$  a  $Y$ .



Obrázek 5: Hustoty dvojrozměrného normálního rozdělení při různých parametrech (první řádek – konturový graf; druhý řádek - perspektivní trojrozměrný graf v podobě plochy); čím je  $\rho$  odlišnější od nuly, tím více se kontury liší od kruhů (mění se na elipsy); se zvyšujícím se rozdílem mezi  $\sigma_1$  a  $\sigma_2$  se zvětšuje rozdíl rozptýlení koncentrických kruhů ve směru jednotlivých os (říkáme, že rozdíl variability proměnných  $X$  a  $Y$  se zvětšuje.)

### Příklad č.17 (standardizované normální rozdělení)

Náhodný vektor  $(X, Y)^T$  má dvojrozměrné normální rozdělení

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

s hustotou

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

kde  $(x, y)^T \in \mathbb{R}^2$ ,  $\rho \in \langle -1, 1 \rangle$  jsou parametry, potom  $\theta = (0, 0, 1, 1, \rho)$ . Výraz v exponentu můžeme psát jako

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

marginální rozdělení jsou obě  $N(0, 1)$  a  $\rho$  je koeficient korelace.

### Příklad č.18 (standardizované normální rozdělení)

Nechť náhodnou proměnnou  $X \sim N(\mu_1, \sigma_1^2)$  je největší výška mozkovny (skull.pH; v mm) a náhodnou

proměnnou  $Y \sim N(\mu_2, \sigma_2^2)$  je morfologická výška tváře (face.H; v mm). Nechť  $X$  a  $Y$  mají dvojrozměrné normální rozdělení s parametry  $(\mu_1, \mu_2)^T$  a  $\sigma_1^2, \sigma_2^2$  a  $\rho$  jsou parametry kovarianční matici  $\Sigma$ . Když od náhodné proměnné  $X$  odpočítáme její střední hodnotu  $\mu_1$  a tento rozdíl podělíme odmocninou z rozptylu ( $\sigma_1$ ), dostaneme náhodnou proměnnou  $Z_X$ , která má asymptoticky normální rozdělení se střední hodnotou  $\mu_1 = 0$  a rozptylem  $\sigma_1^2 = 1$ , což zapisujeme jako  $Z_X \sim N(0, 1)$ . Pokud od náhodné proměnné  $Y$  odečteme její střední hodnotu  $\mu_2$  a tento rozdíl podělíme odmocninou z rozptylu ( $\sigma_2$ ), dostaneme náhodnou proměnnou  $Z_Y$ , která má asymptoticky normální rozdělení se střední hodnotou  $\mu_2 = 0$  a rozptylem  $\sigma_2^2 = 1$ , což zapisujeme jako  $Z_Y \sim N(0, 1)$ . Potom  $(Z_X, Z_Y)^T$  má standardizované dvourozměrné normální rozdělení  $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  s parametry  $\boldsymbol{\mu} = (0, 0)^T$  a  $\sigma_1^2 = 1, \sigma_2^2 = 1$  a  $\rho$  jsou parametry kovarianční matici  $\Sigma$ .

### Příklad č.19 (dvourozměrné normální rozdělení)

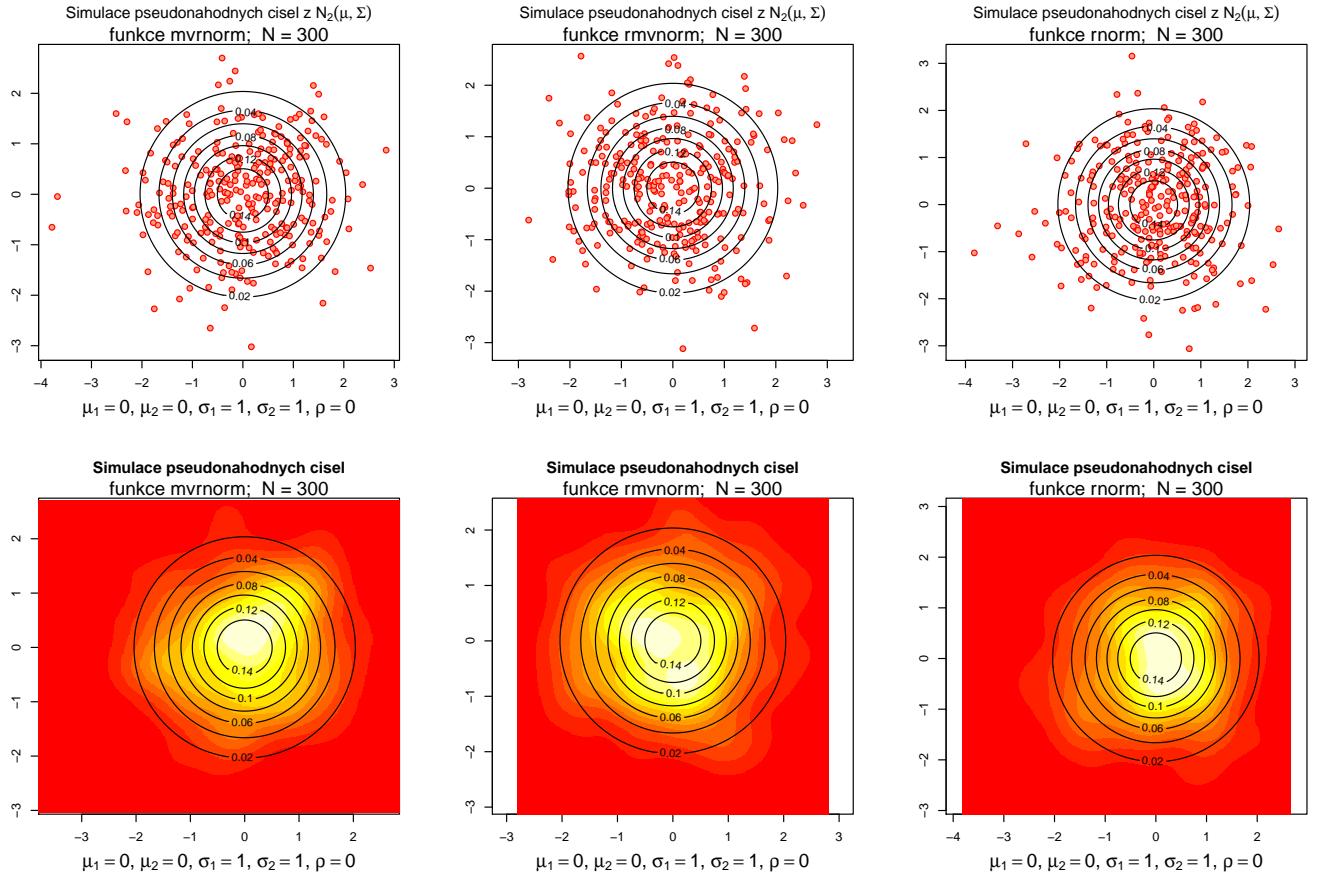
Simulaci pseudonáhodných čísel z  $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  můžeme v R vytvořit následujícími způsoby:

1. použitím funkce `mvrnorm()` z knihovny MASS;
2. použitím funkce `rmvnorm()` z knihovny mvtnorm
3. použitím funkce `rnorm()` a následujícího algoritmu:

Nechť  $X_1 \sim N(0, 1)$  a  $X_2 \sim N(0, 1)$ ; potom  $(Y_1, Y_2)^T \sim N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , kde  $\boldsymbol{\mu} = (\mu_1, \mu_2)^T$  je vektor středních hodnot a  $\sigma_1^2$  a  $\sigma_2^2$  a  $\rho$  jsou parametry kovarianční matici  $\boldsymbol{\Sigma}$ , přičemž síla lineárního vztahu  $Y_1$  a  $Y_2$  je daná velikostí a znaménkem  $\rho$ ;  $Y_1 = \sigma_1 X_1 + \mu_1$  a  $Y_2 = \sigma_2(\rho X_1 + \sqrt{1 - \rho^2} X_2) + \mu_2$ . Nasimulujte pseudonáhodná čísla  $Y_1$  a  $Y_2$  z  $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ . Vypočítejte dvourozměrný jádrový odhad hustoty  $(Y_1, Y_2)^T$  pomocí funkce `kde2d()`. Nakreslete jej také pomocí funkce `image()` a superponujte jej kontúrovým grafem hustoty dvourozměrného normálního rozdělení  $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  pomocí funkce `contour()`. Hustotu rozsekejte na 12 intervalů, kde hodnoty v těchto intervalech budou odpovídat barvám `terrain.colors(12)`. Při simulaci použijte následující parametry:

- (a)  $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0$ ; (1)  $n = 50$ , (2)  $n = 500$
- (b)  $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1, \rho = 0.5$ ; (1)  $n = 50$ , (2)  $n = 500$
- (c)  $\mu_1 = 0, \mu_2 = 0, \sigma_1 = 1, \sigma_2 = 1.2, \rho = 0.5$ ; (1)  $n = 50$ , (2)  $n = 500$

Vzorové řešení viz obrázek 6.



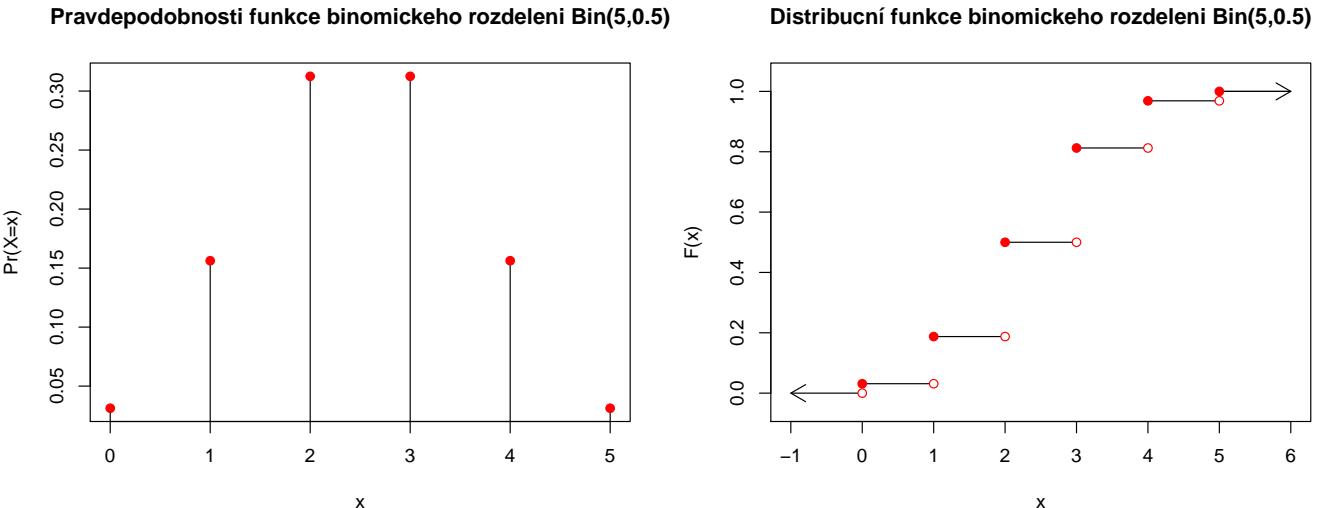
Obrázek 6: Hustoty dvouozměrného normálního rozdělení

### Příklad č.23 (binomické rozdělení, binomický experiment)

Experiment sestávající z fixního počtu Bernoulliho experimentů (ozn.  $N$ ) se nazývá binomický experiment. Pravděpodobnost úspěchu označme  $p$ , pravděpodobnost neúspěchu  $q = 1 - p$ . Náhodná proměnná  $X$  je počet pozorovaných úspěchů po dobu experimentu. Pravděpodobnost  $X = x$  za podmínky, že  $X$  pochází z binomického rozdělení  $Bin(N, p)$ , píšeme jako

$$\Pr(X = x) = \binom{N}{x} p^x (1-p)^{N-x}, x = 0, 1, \dots, N \quad (1)$$

(Ugarte a kol. 2008). Střední hodnota  $E[X] = Np$  a rozptyl  $Var[X] = Np(1-p)$ . Naprogramujte a zobrazte v R pravděpodobnostní funkci a (kumulativní) distribuční funkci pro  $Bin(5, 0.5)$ . Řešení viz obrázek 7.



Obrázek 7: Pravděpodobnostní a distribuční funkce binomického rozdělení  $Bin(5, 0.5)$

### Příklad č.26 (Poissonovo rozdělení; počet havárií za týden)

Pokud každý z 50 milionů lidí řídí v Itálii řídí auto následující týden nezávisle, potom pravděpodobnost smrti při autonehodě bude 0.000002, kde počet úmrtí má binomické rozdělení  $Bin(50\text{mil}, 0.000002)$  anebo limitní Poissonovo rozdělení s parametrem  $\lambda = 50\text{mil} \times 0.000002 = 100$ .

### Příklad č.27 (Poissonovo rozdělení; pruské armádní jednotky)

Nechť početnosti úmrtí  $X$  jako následek kopnutí koněm v Pruských armádních jednotkách (Bortkiewicz, 1898) mají Poissonovo rozdělení s parametrem  $\lambda$ , tj.  $X \sim Poiss(\lambda)$ . Pravděpodobnost, že někdo bude smrtele zraněný v daném dni, je extrémně malá. Mějme 10 vojenských jednotek za 20-letou periodu s rozsahem  $M = 200$  ( $200 = 10 \times 20$ ), kde, při početnostech úmrtí  $n = 1, 2, 3, 4, 5+$  v dané jednotce a v daném roce, zaznamenáváme také početnosti vojenských jednotek  $m_n$  při daném  $n$ , kde  $M = \sum m_n$  (viz tabulka). Vypočítejte očekávané početnosti, za předpokladu  $X \sim Poiss(\lambda)$ , kde

$$\lambda = \frac{\sum_n nm_n}{\sum_n m_n}. \quad (2)$$

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

### Příklad č.28 (podíl chlapců a dívek v rodinách)

Nechť  $X$  představuje početnost chlapců mezi dětmi v rodinách. Zde můžeme předpokládat, že  $X \sim Bin(N, p)$ , tj. rodina může mít vychýlený poměr pohlaví dětí ve směru k chlapcům nebo k dívкам. V realitě tedy můžeme mít velmi mnoho rodin jen s chlapci nebo jen s děvčaty a nemáme dostatek rodin s poměrem pohlaví blízkým 51 : 49 (poměr chlapců ku dívкам). Z toho nám vyplývá, že rozptyl početnosti chlapců bude ve skutečnosti větší než rozptyl předpokládaný binomickým rozdělením  $Bin(n, P)$ .

### Příklad č.29 (overdispersion v binomickém modelu)

V klasické studii poměru pohlaví u lidí z roku 1889 na základě záznamů z nemocnic v Sasku (více informací viz Lindsey a Altham, (1998)) zaznamenal Geissler (1889) rozdělení počtu chlapců v rodinách. Mezi  $M = 6115$  rodinami s  $N = 12$  dětmi pozoroval následující početnosti chlapců ( $n$  jsou početnosti chlapců a  $m_n$  početnosti rodin s  $n$  chlapci).

$n$	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

Vypočítejte  $m_n$  za předpokladu, že početnosti chlapců  $X$  v rodinách mají binomické rozdělení s parametry

$$\pi = \frac{\sum_{n=0}^N nm_n}{NM} = 0.5192 \quad (3)$$

a  $N = 12$ , ozn.  $X \sim Bin(N, \pi)$ .

### Příklad č.30 (overdispersion v Poissonově modelu)

Mějme početnosti úrazů  $n$  mezi dělníky v továrně, kde početnosti dělníků  $m_n$  při daném  $n$  (viz tabulka) (Greenwood a Yule (1920)).

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

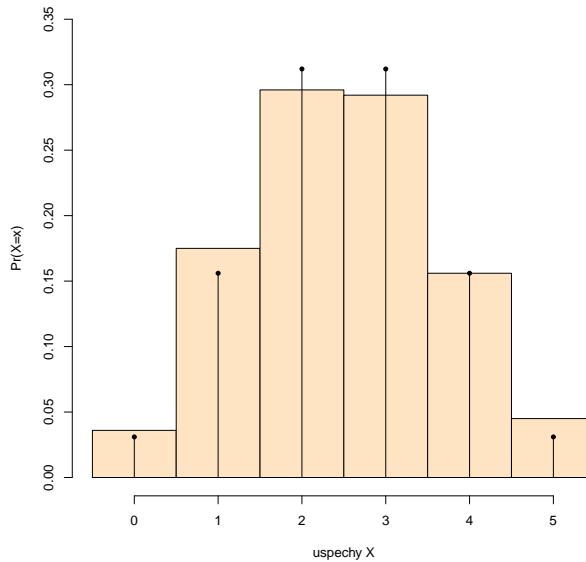
Vypočítejte očekávané početnosti dělníků za předpokladu, že početnosti úrazů na dělníka  $X$  mají Poissonovo rozdělení s parametrem

$$\lambda = \frac{\sum_n nm_n}{\sum_n m_n} = 0.47. \quad (4)$$

Ozn.  $X \sim Poiss(\lambda)$ .

### Příklad č.31 (binomické rozdělení, simulační studie)

Vygenerujte pseudonáhodná čísla  $X$  (početnosti úspěchů) opakovaná  $M$ -krát ( $M = 1000$ ) z  $Bin(N, p)$ , kde  $N = 5$  a  $p = 0.5$ . Vytvořte tabulku vygenerovaných (simulovaných) i teoretických relativních početností (pro  $n = 0, 1, \dots, 5$ ). Superponujte histogram vygenerovaných pseudonáhodných čísel s teoretickou pravděpodobnostní funkcí (viz obrázek 8).



Obrázek 8: Histogram vygenerovaných pseudonáhodných čísel superponovaný teoretickou pravděpodobnostní funkcí  $Bin(N, p)$ .

### Příklad č.32 (binomické vs normální rozdělení)

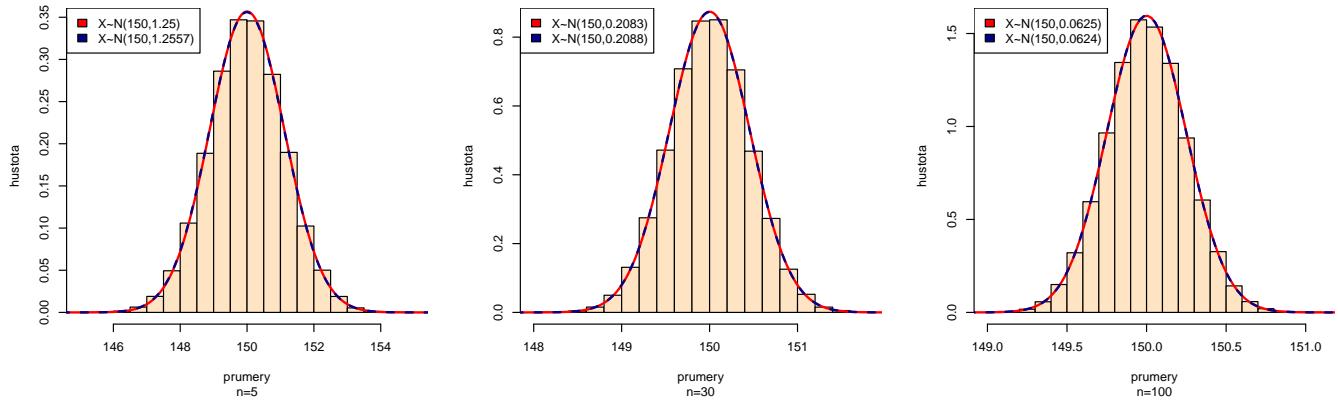
Nechť  $X_N \sim Bin(N, p)$ , potom můžeme approximovat binomické rozdělení normálním následovně:  $X_N \sim N(Np, Np(1-p))$ , kde také platí

$$Z_N = \frac{X_N - Np}{\sqrt{Np(1-p)}} \sim N(0, 1).$$

Ukažte, že CLV platí pro  $N = 100$  a  $p = 0.5$  na tři desetinná místa.

### Příklad č.33 (normální rozdělení, simulační studie)

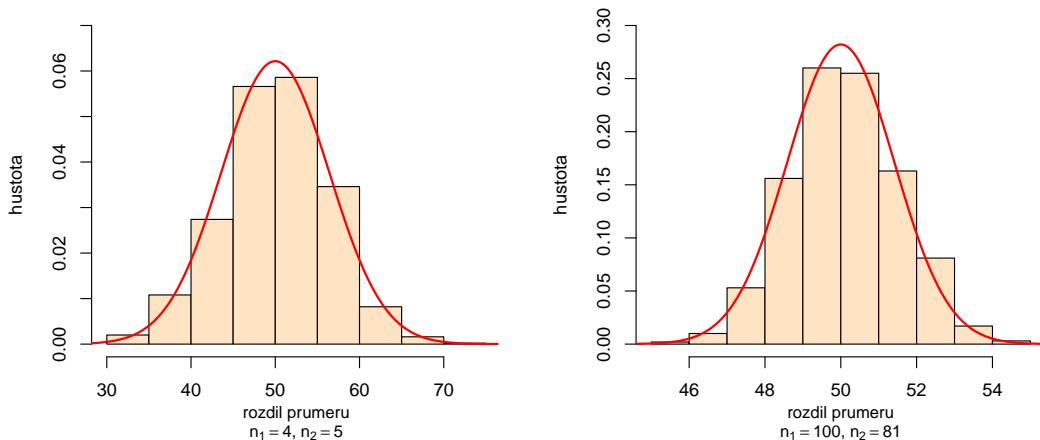
Na základě simulační studie prověrte, že pokud  $X \sim N(150, 6.25)$ , potom  $\bar{X}_n \sim N(150, 6.25/n)$ . Použijte  $n = 30$ . Pro každou simulaci  $X$  vypočítejte aritmetické průměry  $\bar{x}_m$ ,  $m = 1, 2, \dots, M$ , kde  $M = 500\,000$ . Superponujte je histogramem v relativní škále s teoretickou křivkou hustoty pro  $\bar{X}_n$ . Vypočítejte  $\Pr(\bar{X}_n > 151)$  ze simulovaných dat a porovnejte tento výsledek s teoretickou (očekávanou) pravděpodobností. Řešení viz obrázek 9.



Obrázek 9: Histogram vygenerovaných průměrů superponovaný teoretickou křivkou hustoty  $\bar{X}_n$ .

### Příklad č.34 (normální rozdělení, simulační studie)

Nechť  $X \sim N(\mu_1, \sigma_1^2)$  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 pseudonáhodná čásla  $X$  a  $Y$  rozdělení  $N(\mu_j, \sigma_j^2)$ ,  $j = 1, 2$ , kde  $\mu_1 = 100$ ,  $\sigma_1 = 10$ ,  $\mu_2 = 50$ ,  $\sigma_2 = 9$  při (a)  $n_1 = 4$ ,  $n_2 = 5$ , (b)  $n_1 = 100$ ,  $n_2 = 81$ . Pro každou simulaci  $X$  a  $Y$  vypočítejte rozdíl  $\bar{x}_m - \bar{y}_m$ ,  $m = 1, 2, \dots, M$ , kde  $M = 1000$ . Superponujte histogram těchto rozdílů v relativní škále s teoretickou křivkou hustoty rozdílu  $\bar{X}_{n_1} - \bar{Y}_{n_2}$ . Pro případ (a) i (b) vypočítejte  $\Pr(\bar{X}_{n_1} - \bar{Y}_{n_2} < 52)$  na základě empirického (vygenerovaného) a teoretického rozdělení  $\bar{X}_{n_1} - \bar{Y}_{n_2}$ .



Obrázek 10: Histogram vygenerovaných rozdílů průměrů superponovaný teoretickou křivkou hustoty rozdílu výběrových aritmetických průměrů

### Příklad č.35 (statistiky)

Mějme náhodný výběr  $(X_1, X_2, \dots, X_n)^T$ , kde  $X_i \in \mathbb{R}$ ,  $i = 1, 2, \dots, n$ , potom příklady statistik jsou:

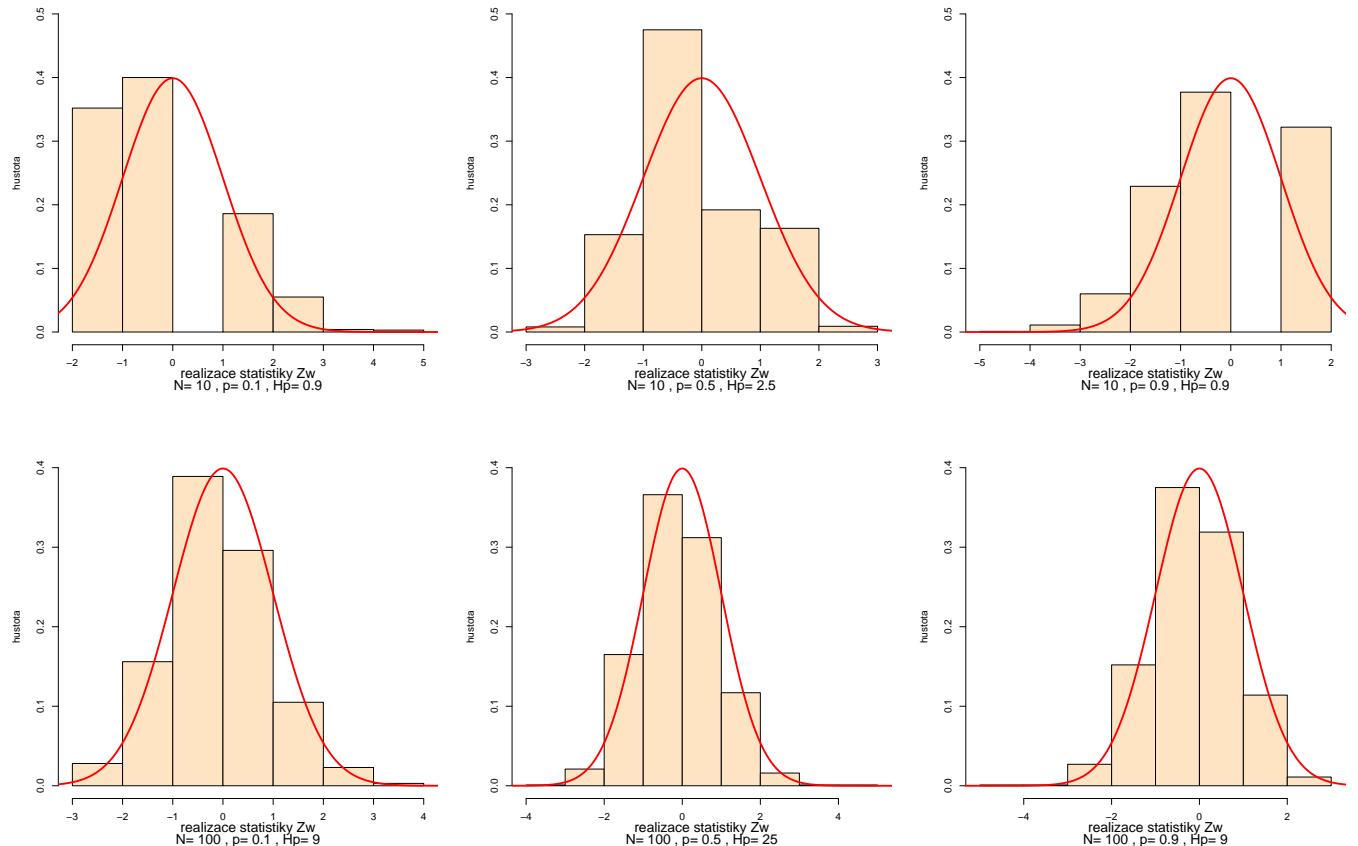
- $T_1 = \sum_{i=1}^n X_i \in \mathbb{R}$ ,
- $T_2 = \sum_{i=1}^n X_i^2 \in \mathbb{R}^+ \cup \{0\}$ ,
- $T_3 = (\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2) \in \mathbb{R}^2$ .

### Příklad č.36 (testovací statistika, simulační studie)

Na základě simulační studie prověřte, že pokud náhodná proměnná  $X$  má asymptoticky binomické rozdělení  $\text{Bin}(N, p)$ , potom testovací statistika

$$Z_W = \frac{X/N - p}{\sqrt{p(1-p)/N}}$$

má asymptoticky normální rozdělení  $N(0, 1)$ . Použijte  $p = 0, 0.1, 0.5, 0.9$  a  $1$ , a  $N = 5, 10, 30, 50$  a  $100$ . Okomentujte výsledky ve spojitosti s Haldovou podmínkou  $Np(1-p) > 9$ . Pro každou simulaci  $X$  vypočítejte  $z_{W,m}$ ,  $m = 1, 2, \dots, M$ , kde  $M = 1000$ . Superponujte histogram vygenerovaných testovacích statistik v relativní škále s teoretickou křivkou hustoty  $Z_W$ .



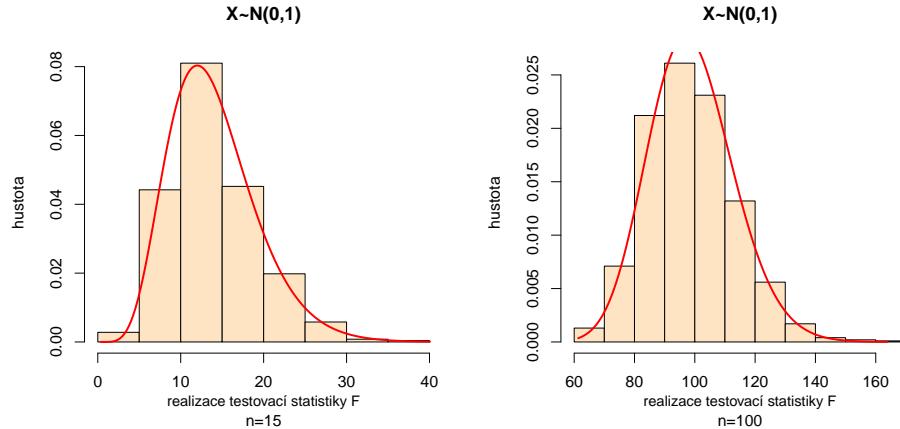
Obrázek 11: Histogram vygenerovaných testovacích statistik v relativní škále superponovaný s teoretickými křivkami hustoty.

Příklad č.36 mluví o použití jednovýběrové testovací statistiky pro parametr binomického rozdělení (pravděpodobnosti pro různé pravděpodobnosti a různé početnosti). Pokud není Haldova odmínka splněná, není možné testovací

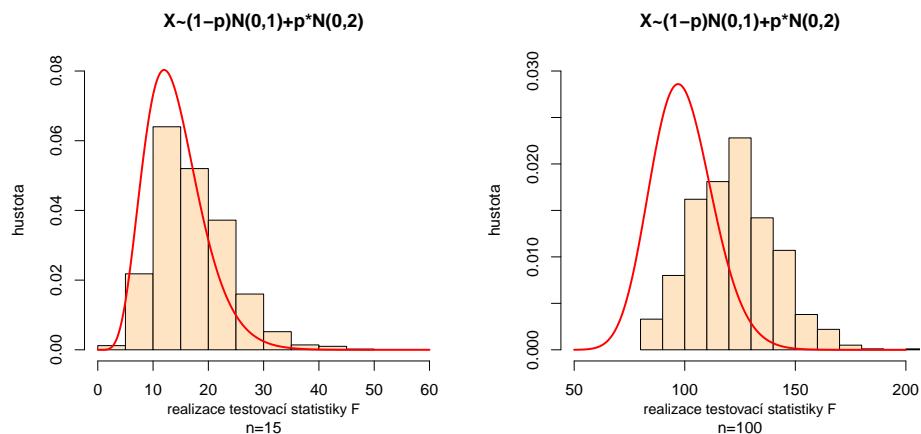
statistikou použít.

### Příklad č.37 (testovací statistika, simulační studie)

Na základě simulační studie prověrte, že pokud (a)  $X \sim N(\mu, \sigma^2)$ , kde  $\mu = 0$ ,  $\sigma^2 = 1$  a (b)  $X \sim [(1-p)N(\mu, \sigma^2) + pN(\mu, \sigma_1^2)]$ , kde  $\mu = 0$ ,  $\sigma^2 = 1$ ,  $p = 0.05$ ,  $\sigma_1^2 = 2$ , potom testovací statistika  $F = \frac{(n-1)S^2}{\sigma^2}$  má asymptoticky  $\chi_{n-1}^2$  rozdělení o  $n-1$  stupních volnosti. Použijte rozsahy náhodných výběrů  $n = 15$  a  $n = 100$ . Pro každou simulaci  $X$  vypočítejte  $F_{poz,m}$ ,  $m = 1, 2, \dots, M$ , kde  $M = 1000$ . Superponujte histogram vygenerovaných testovacích statistik v relativní škále s teoretickou křivkou hustoty  $F$ .



Obrázek 12: Histogram vygenerovaných testovacích statistik v relativní škále superponovaný s teoretickými křivkami hustoty  $N(0, 1)$ .



Obrázek 13: Histogram vygenerovaných testovacích statistik v relativní škále superponovaný s teoretickými křivkami hustoty  $(1-p)N(0, 1) + pN(0, 2)$ .

### Příklad č.38 (postačující statistika binomického rozdělení)

Nechť  $X_i$ ,  $i = 1, 2, \dots, N$  jsou iid Bernoulliho pokusy a  $X = \sum_{i=1}^N X_i$ . Potom  $X \sim Bin(N, p)$ . Ukažte, že  $T(\mathbf{X}) = \sum_{i=1}^N X_i$  je postačující statistika pro  $p$ .

### Příklad č.39 (postačující statistika normálního rozdělení)

Nechť  $X_i \sim N(\mu, \sigma^2)$ , kde  $i = 1, 2, \dots, N$  jsou iid proměnné a  $\sigma^2$  poznáme. Ukažte, že  $T(\mathbf{X}) = \sum_{i=1}^N X_i/N =$

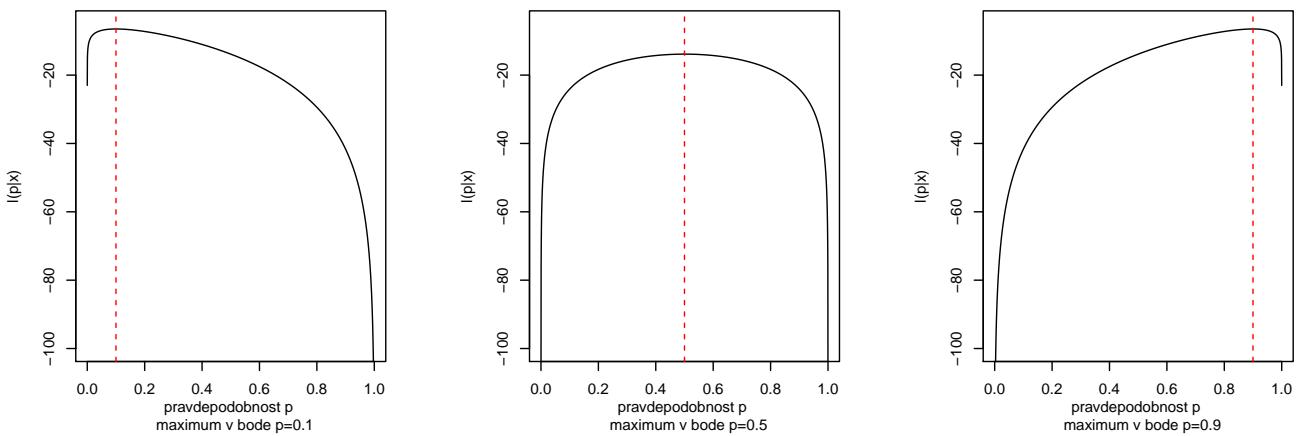
$\bar{X}$  je postačující statistika pro  $\mu$ .

#### Příklad č.40 (binomické rozdělení; maximálně věrohodný odhad $p$ )

Nechť  $X \sim Bin(N, p)$  a realizace  $X$  jsou  $x = n$ . Předpokládejme, že jsme pozorovali (a)  $x = 2$ , (b)  $x = 10$  a (c)  $x = 18$  úspěchů v  $N = 20$  pokusech.

- (a) Pomocí R vypočítejte maximálně věrohodný odhad  $p$ . Výsledek zobrazte do grafu spolu s logaritmickou funkcí věrohodnosti (viz graf 14).

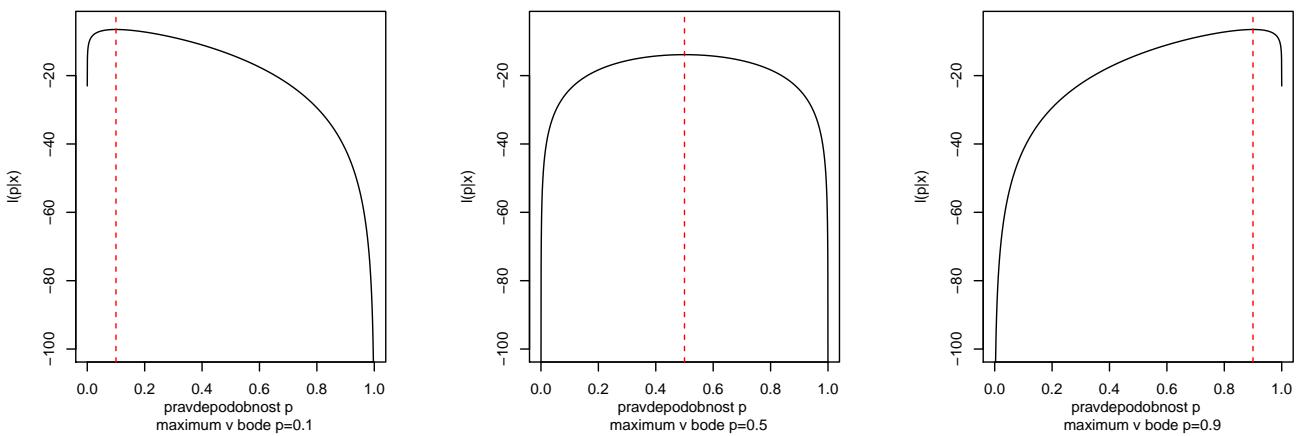
Logaritmus verohodnostni funkce + MLE parametru p – funkce optimize()



Obrázek 14: Logaritmická funkce věrohodnosti pro  $X \sim Bin(N, p)$  ( $p = 0.1; 0.5; 0.9$  a  $N = 20$ ) - funkce optimize()

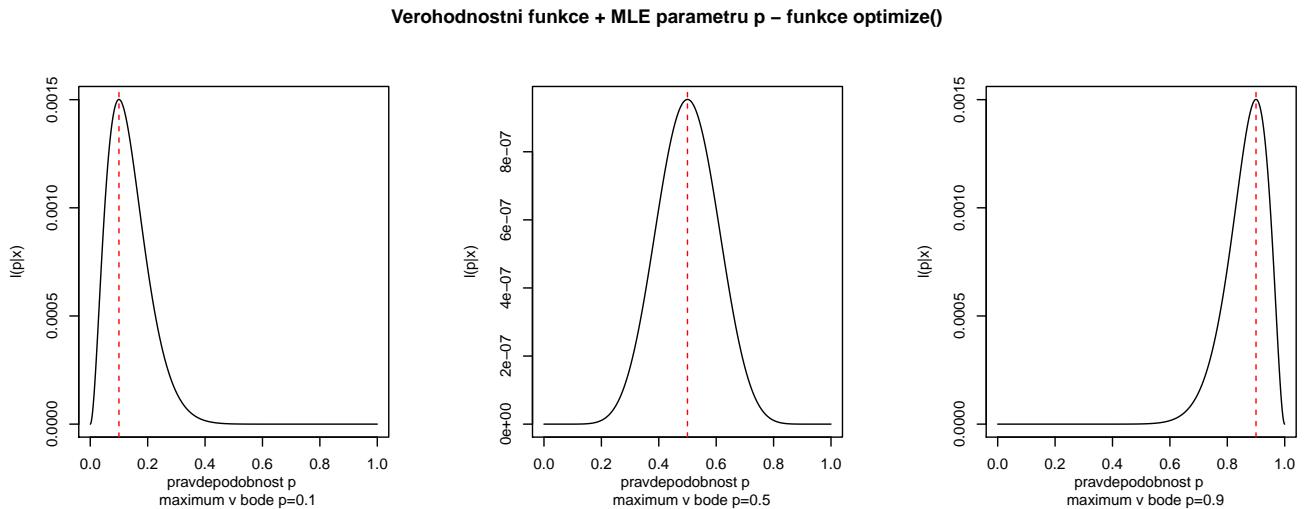
- (b) Naprogramujte Newton-Raphsonovu iterační metodu. Touto metodou nahrad'te funkci optimize(), nalezněte maximálně věrohodný odhad parametru  $p$ , výsledek zaneste do grafu spolu s logaritmickou funkcí věrohodnosti (grafy budou stejné, jako grafy vygenerované v části (a)).

Logaritmus verohodnostni funkce + MLE parametru p – Newton Rahpsonova metoda



Obrázek 15: Logaritmická funkce věrohodnosti pro  $X \sim Bin(N, p)$  ( $p = 0.1; 0.5; 0.9$  a  $N = 20$ ) - Newton-Raphsonova metoda

- (c) Pomocí R vypočítejte maximálně věrohodný odhad  $p$ . Výsledek zobrazte do grafu spolu s funkcí věrohodnosti (viz graf 16).



Obrázek 16: Funkce věrohodnosti pro  $X \sim Bin(N, p)$  ( $p = 0.1; 0.5; 0.9$  a  $N = 20$ ) - funkce `optimize()`

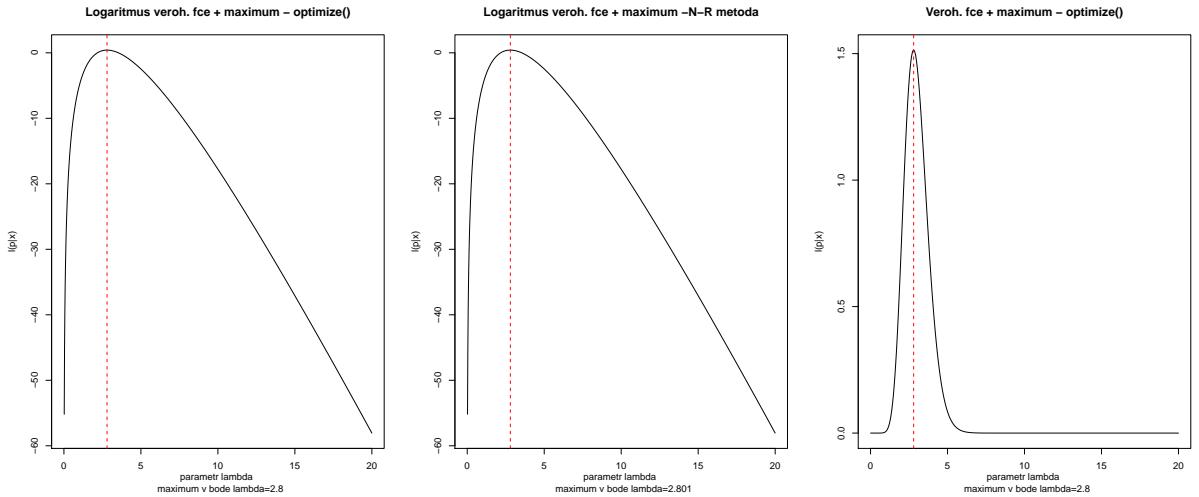
#### Příklad č.41 ( $\mathcal{I}(\hat{p})$ a rozptyl pro $p$ ; $X \sim Bin(N, p)$ )

Z funkce věrohodnosti odvod'te pozorovanou Fisherovu míru informace  $\mathcal{I}(\hat{p})$  a rozptyl  $\widehat{Var[\hat{p}]}$ .

#### Příklad č.42 (maximálně věrohodné odhady; Poissonovo rozdělení)

Každý rok za posledních pět let byly v nějakém městě registrovány 3, 2, 5, 0 a 4 zemětřesení za rok. Za předpokladu, že počet zemětřesení za rok (náh. veličina  $X$ ) má Poissonovo rozdělení s parametrem  $\lambda$ , tj.  $X \sim Poiss(\lambda)$ :

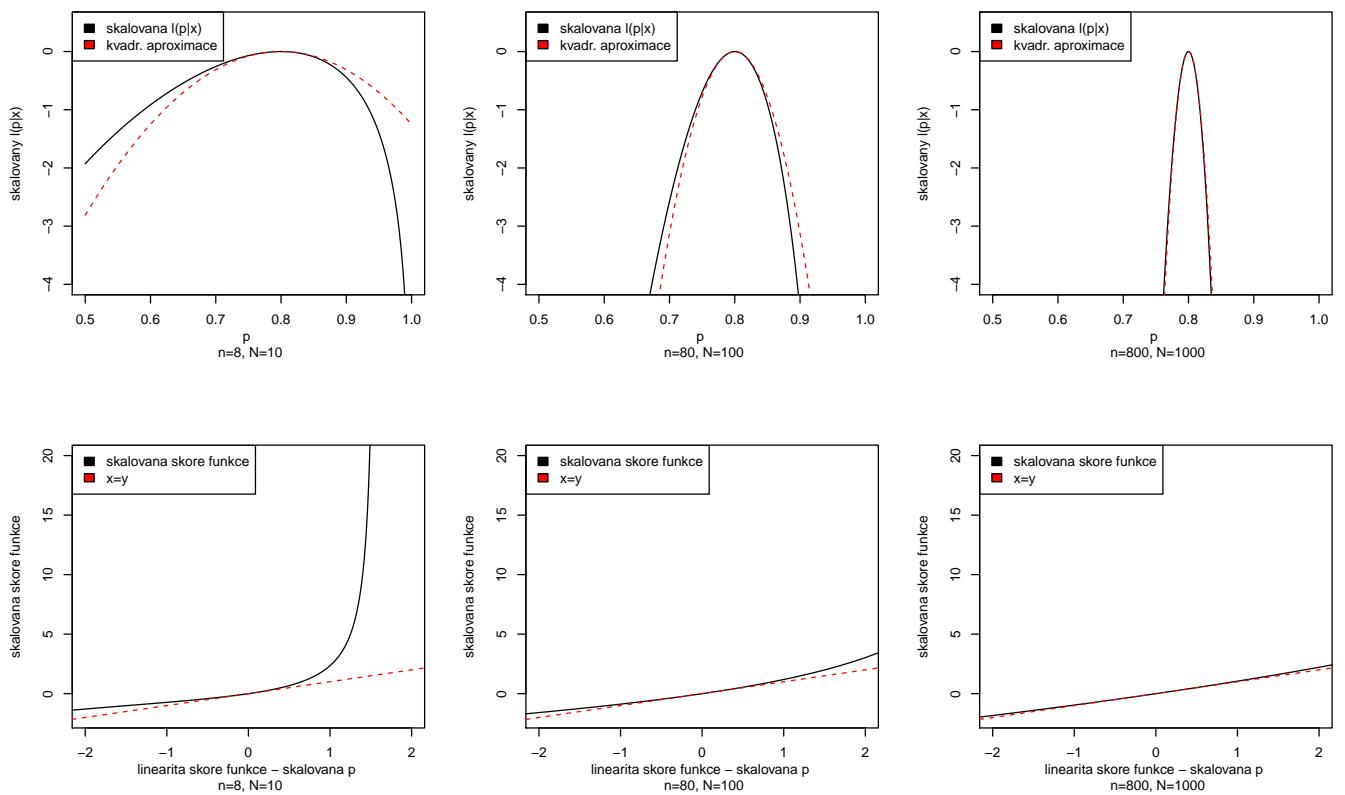
- Odvod'te obecný tvar maximálně věrohodného odhadu parametru  $\lambda$  a vypočítejte hodnotu tohoto parametru pro počet zemětřesení ( $\lambda$  představuje očekávanou početnost zemětřesení za rok).
- Odvod'te obecný tvar maximálně věrohodného odhadu rozptylu odhadu parametru  $\lambda$  a vypočítejte hodnotu tohoto odhadu rozptylu pro počet zemětřesení.
- Vykreslete maximálně věrohodný odhad parametru  $\lambda$  spolu s logaritmickou věrohodnostní funkcí Poissonova rozdělení (parametr  $\lambda$  odhadněte pomocí funkce `optimize()`).
- Vykreslete maximálně věrohodný odhad parametru  $\lambda$  spolu s logaritmickou věrohodnostní funkcí Poissonova rozdělení (parametr  $\lambda$  odhadněte pomocí vámi naprogramované Newtonovy-Raphsonovy iterační metody).
- Vykreslete maximálně věrohodný odhad parametru  $\lambda$  spolu s věrohodnostní funkcí Poissonova rozdělení.



Obrázek 17:  $X \sim Po(\lambda)$ , zemětřesení: (a) Logaritmická věrohodnostní funkce (použití fce `optimize()`); (b) Logaritmická věrohodnostní funkce - Newton-Raphsonova metoda; (c) Věrohodnostní funkce - (použití funkce `optimize()`)

#### Příklad č.43 (kvadratická approximace logaritmu funkce věrohodnosti)

- Nakreslete škálovaný logaritmus funkce věrohodnosti binomického rozdělení. Na  $x$ -ové ose bude  $p$  a na  $y$ -ové ose  $\ln \mathcal{L}(p) = l(p|\mathbf{x}) - \max(l(p|\mathbf{x}))$ . Porovnejte  $\ln \mathcal{L}(p)$  s kvadratickou approximací vypočítanou pomocí Taylorova rozvoje  $\ln \mathcal{L}(p) = \ln \left( \frac{L(p|\mathbf{x})}{L(\hat{p})|\mathbf{x}} \right) \approx -\frac{1}{2} \mathcal{I}(\hat{p})(p - \hat{p})^2$ .
- Nechtěj skóre funkce  $S(p) = \frac{\partial}{\partial p} \ln L(p|\mathbf{x})$ . Vezmeme-li derivaci kvadratické approximace uvedené výše, dostaneme  $S(p) = -\mathcal{I}(\hat{p})(p - \hat{p})$  anebo  $-\mathcal{I}^{-1/2}(\hat{p})S(p) \approx \mathcal{I}^{1/2}(\hat{p})(p - \hat{p})$ . Potom zobrazením pravé strany na  $x$ -ové ose a levé strany na  $y$ -ové ose dostaneme asymptoticky lineární funkci s jednotkovým sklonem. Asymptoticky také platí  $\mathcal{I}^{1/2}(\hat{p})(p - \hat{p}) \sim N(0, 1)$ . Je postačující mít rozsah  $x$ -ové osy  $(-2; 2)$ , protože funkce je asymptoticky (lokálně) lineární na tomto intervalu. Rozumně škálujte  $y$ -vou osu. Zobrazte pro (a)  $n = 8$ ,  $N = 10$ , (b)  $n = 80$ ,  $N = 100$  a (c)  $n = 800$ ,  $N = 1000$  ( $p \in (0.5; 0.99)$ ). Okomentujte rozdíly mezi (a), (b) a (c). Grafické řešení je na obrázku 18.



Obrázek 18: Porovnání škálovaného logaritmické funkce věrohodnosti s jeho kvadratickou approximací a prvním řádku a porovnání škálované skóre funkce a přímky  $x = y$  v druhém řádku