

## 5 Pravděpodobnostní modely pro spojité náhodné veličiny

### 5.1 Spojitá náhodná veličina

Spojitá náhodná veličina nabývá všech hodnot z nějakého intervalu. Její pravděpodobnostní chování je popsáno hustotou pravděpodobnosti, což je po částech spojitá nezáporná funkce  $f(x)$ , která je normovaná (tj.  $\int_{-\infty}^{\infty} f(x)dx = 1$ ) a s distribuční funkcí je spjata integrálním vztahem:  $\forall x \in \mathbb{R}: F(x) = \int_{-\infty}^x f(t)dt$ . Je to zidealizovaný protějšek hustoty četnosti. Pravděpodobnost, že spojitá náhodná veličina nabude nějaké konkrétní hodnoty, je 0. Při výpočtu pravděpodobnosti jevu, že spojitá náhodná veličina nabude hodnot z nějakého intervalu, tedy nehráje roli, zda je tento interval uzavřený, polouzavřený nebo otevřený, tj.  $\forall a, b \in \mathbb{R}, a < b: \Pr(a \leq X \leq b) = \Pr(a < X \leq b) = \Pr(a \leq X < b) = \Pr(a < X < b) = F(b) - F(a) = \int_a^b f(x)dx$ .

#### 5.1.1 Normální rozdelení

Normální rozdelení se vyskytuje při opakování nezávislých měřeních též charakteristiky za stejných podmínek. Jednotlivé naměřené hodnoty, tj. realizace náhodné veličiny  $X$ , se v důsledku působení náhodných vlivů, jejichž proměnlivost je vyjádřena konstantou  $\sigma > 0$ , poněkud odchylují od skutečné hodnoty  $\mu$  zkoumané charakteristiky. Příseme  $X \sim N(\mu, \sigma^2)$ . Parametr  $\mu$  má význam střední hodnoty náhodné veličiny  $X$ , parametr  $\sigma^2$ , resp.  $\sigma$  představuje její rozptyl, resp. směrodatnou odchylku (viz kapitola 6).

Hustota:  $f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$ .

Grafem hustoty normálního rozdelení je tzv. Gaussova křivka. Má zvonovitý tvar a je symetrická kolem osy procházející jejím vrcholem, který kulminuje nad hodnotou parametru  $\mu$ .

**Věta 5.1:** Důležité vlastnosti normálního rozdelení:

- Jestliže  $X \sim N(\mu, \sigma^2)$  a  $Z = a + bX$ , pak  $Z \sim N(a + b\mu, b^2\sigma^2)$ .
- Jestliže  $X_1, \dots, X_n$  jsou stochasticky nezávislé náhodné veličiny,  $X_i \sim N(\mu_i, \sigma_i^2)$ ,  $i = 1, \dots, n$ ,  $Z = \sum_{i=1}^n X_i$ , pak  $Z \sim N\left(\sum_{i=1}^n \mu_i, \sum_{i=1}^n \sigma_i^2\right)$ .
- Jestliže  $X_1, \dots, X_n$  jsou stochasticky nezávislé náhodné veličiny,  $X_i \sim N(\mu, \sigma^2)$ ,  $i = 1, \dots, n$ ,  $M = \frac{1}{n} \sum_{i=1}^n X_i$ , pak  $M \sim N\left(\mu, \frac{\sigma^2}{n}\right)$ .
- Pravděpodobnost, že náhodná veličina  $X \sim N(\mu, \sigma^2)$  se realizuje v nějakém intervalu  $\langle a, b \rangle$ , nemůžeme vypočítat jako  $\Pr(a \leq X \leq b) = \int_a^b f(x)dx$ , protože jde o integrál z vyšší transcendentní funkce (funkce, kterou nelze vyjádřit prostřednictvím konečného počtu elementárních funkcí). Lze využít toho, že  $\Pr(a \leq X \leq b) = F(b) - F(a)$ , přičemž hodnoty distribuční funkce  $F(x)$  získáme pomocí statistického softwaru.

V praxi jsou zvlášť užitečné následující pravděpodobnosti (společně tvoří pravidlo 3 $\sigma$ ):

- $\Pr(\mu - \sigma \leq X \leq \mu + \sigma) \doteq 0,6827$ ,
- $\Pr(\mu - 2\sigma \leq X \leq \mu + 2\sigma) \doteq 0,9545$ ,
- $\Pr(\mu - 3\sigma \leq X \leq \mu + 3\sigma) \doteq 0,9973$ .

**Poznámka:** Uvedené tři rovnosti lze použít k jednoduchému ověření, zda se hodnoty v datovém souboru řídí normálním rozdelením. Z dat vypočítáme aritmetický průměr  $m$  a směrodatnou odchylku  $s$ . Pokud přibližně 68, 27 % hodnot leží v intervalu  $(m - s, m + s)$ , 95, 45 % hodnot leží v intervalu  $(m - 2s, m + 2s)$  a 99, 73 % hodnot leží v intervalu  $(m - 3s, m + 3s)$ , lze soudit, že data pocházejí z normálního rozdelení.

**Vzorce pro výpočty pravděpodobností pomocí normálního rozdelení v softwaru R**

- $\Pr(X \leq x) = F(x) = \text{pnorm}(x, \text{mu}, \text{sigma})$ ,
- $\Pr(X \geq x) = 1 - F(x) = 1 - \text{pnorm}(x, \text{mu}, \text{sigma})$ ,
- $\Pr(a \leq X \leq b) = F(b) - F(a) = \text{pnorm}(b, \text{mu}, \text{sigma}) - \text{pnorm}(a, \text{mu}, \text{sigma})$ .

### 5.1.2 Standardizované normální rozdělení

Pro  $\mu = 0$ ,  $\sigma^2 = 1$  se jedná o standardizované normální rozdělení, píšeme  $U \sim N(0, 1)$ .

Hustota:  $f(u) = \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}}$ .

Hodnoty distribuční funkce  $F(u) = \int_{-\infty}^u \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt$  vypočítáme v softwaru R příkazem `pnorm(u)`. Pro  $u \geq 0$  lze hodnoty  $F(u)$  nalézt také ve statistických tabulkách. Pro  $u < 0$  se při použití tabulek používá přepončový vzorec  $F(u) = 1 - F(-u)$ . Jestliže  $X \sim N(\mu, \sigma^2)$ , pak  $U = \frac{X-\mu}{\sigma} \sim N(0, 1)$ .

#### Příklad 5.1. Řešený příklad

Načtěte datový soubor 13-two-samples-correlations-trunk.txt obsahující údaje o délce dolní končetiny v mm (`lowex.L`) a délce trupu v mm (`tru.L`) u mladých dospělých mužů a žen. Předpokládejme, že náhodná veličina  $X$  popisuje délku dolní končetiny v mm u žen. (a) Najděte rozdělení, které dostatečně dobře vystihuje pravděpodobnostní chování náhodné veličiny  $X$ , a odhadněte parametry tohoto rozdělení; (b) ověřte, že nalezené rozdělení je vhodné na popis náhodné veličiny  $X$ ; pro naměřená data vykreslete histogram a superponujte jej křivkou jádrového odhadu hustoty a křivkou hustoty nalezeného rozdělení. Obě křivky vzájemně porovnejte.

#### Řešení příkladu 5.1

Datový soubor načteme a vypíšeme prvních pět rádků tabulky. Z načteného souboru vybereme pouze údaje o délce dolní končetiny u žen a z výběru odstraníme rádky s chybějícími hodnotami. Nakonec příkazem `length()` zjistíme rozsah výběru a příkazem `range()` rozptět naměřených hodnot.

```
1 data <- read.delim("13-two-samples-correlations-trunk.txt", sep = "\t")
2 head(data, n = 5)
3 lowex.LF <- na.omit(data[data$sex == "f", "lowex.L"])
4 n <- length(lowex.LF) # 100
5 range(lowex.LF) # 836; 1076
```

Datový soubor obsahuje údaje o délce dolní končetiny u 100 žen. Naměřené hodnoty se pohybují v rozmezí 836 mm až 1076 mm. Délka dolní končetiny u žen je spojitý znak, k jeho popisu tedy použijeme spojitu náhodnou veličinu. Protože délka dolní končetiny je tělesný rozměr, mohlo by k popisu tohoto znaku být vhodné normální rozdělení. O náhodné veličině  $X$  tedy předpokládáme, že pochází z normálního rozdělení s parametry  $\mu$  a  $\sigma^2$ , kde  $\mu$  je střední hodnota délky dolní končetiny u žen a  $\sigma^2$  je rozptyl délky dolní končetiny u žen okolo střední hodnoty  $\mu$ . Parametr  $\mu$  odhadneme pomocí aritmetického průměru naměřených hodnot, tj.

$$\hat{\mu} = m = \frac{1}{n} \sum_{i=1}^n x_i.$$

Parametr  $\sigma^2$  odhadneme pomocí rozptylu naměřených hodnot, tj.

$$\hat{\sigma}^2 = s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - m)^2.$$

Aritmetický průměr  $m$  vypočítáme příkazem `mean()`. Rozptyl  $s^2$  budeme častěji zapisovat ve tvaru druhé mocniny směrodatné odchylky, jejíž hodnotu vypočítáme příkazem `sd()`.

```
6 m <- mean(lowex.LF) # 940,50
7 s <- sd(lowex.LF) # 45,47116
```

Odhad parametru střední hodnoty  $m = 940,50$ , odhad parametru rozptylu  $s^2 = 45,47^2$ . Délka dolní končetiny u žen se pohybuje okolo střední hodnoty 940,50 mm se směrodatnou odchylkou 45,47 mm. O náhodné veličině  $X$  předpokládáme, že pochází z normálního rozdělení s parametry  $\mu = 940,50$  a  $\sigma^2 = 45,47^2$ , tj.  $X \sim N(940,50; 45,47^2)$ .

Nyní vykreslíme histogram s křivkou jádrového odhadu hustoty, který vypočítáme na základě naměřených dat, a s křivkou hustoty rozdělení  $N(940,50; 45,47^2)$ . Naměřené hodnoty roztrídíme do osmi třídicích intervalů o ekvidistantní délce 31 mm stanovením hranic 830, 861, ..., 1078 mm. Histogram vykreslíme příkazem `hist()` s argumentem `prob = T` (viz kapitola 2). Jádrový odhad hustoty vypočítáme příkazem `density()`, jehož jediným vstupním argumentem bude vektor `lowex.LF`. Křivku jádrového odhadu hustoty vykreslíme příkazem `lines()` aplikovaným na

výstup funkce `density()`. Barvu křivky jádrového odhadu hustoty volíme v podobném odsířtu jako barvu histogramu, protože oba objekty reprezentují naměřená data.

```

8 r <- round(1 + 3.3 * log10(n)) # 8
9 # 1076 - 835 = 241; 248 / 8 = 31 -> seq(830, 1078, by = 31)
10 b.lowex.LF <- seq(from = 830, to = 1078, by = 31)
11 hist(belowex.LF, prob = T, breaks = b.lowex.LF, include.lowest = F, ylim = c(0, 0.012),
       axes = F, col = "thistle1", border = "mediumorchid4", xlab = "délka dolní končetiny
       (mm)", ylab = "f(x)", main = "")
12 box(bty = "o")
13 c.lowex.LF <- hist(belowex.LF, breaks = b.lowex.LF, plot = F)$mids
14 axis(side = 1, at = c.lowex.LF)
15 axis(side = 2, las = 1)
16 lines(density(belowex.LF), lwd = 2, col = "mediumorchid4")


```

Pro vykreslení křivky hustoty rozdělení  $N(940, 50; 45, 47^2)$  je třeba nejprve příkazem `seq()` vytvořit posloupnost hodnot  $x$  pokrývající rozpětí naměřených délek dolní končetiny u žen. Pro každý prvek této posloupnosti potom příkazem `dnorm()` vypočítáme hodnotu hustoty rozdělení  $N(940, 50; 45, 47^2)$ . Vstupními argumenty příkazu budou posloupnost  $x$  (argument `x`), odhad parametru  $\mu$  (argument `mean`) a odhad parametru  $\sigma$  (argument `sd`). Křivku hustoty vykreslíme příkazem `lines()`. Nakonec do grafu doplníme legendu popisující význam vykreslených křivek. Výsledný histogram je zobrazen na obrázku 5.1.

```

17 x <- seq(from = 830, to = 1080, length = 512)
18 fx <- dnorm(x = x, mean = m, sd = s)
19 lines(x, fx, col = "red", lwd = 2)
20 legend("topright", bty = "n", lwd = c(2, 2), col = c("red", "mediumorchid4"), legend =
      c("hustota", "jádrový odhad hustoty"))

```



Obrázek 5.1: Histogram pro délku dolní končetiny u žen superponovaný křivkou jádrového odhadu hustoty a křivkou hustoty normálního rozdělení

Z obrázku 5.1 vidíme, že křivka jádrového odhadu hustoty a křivka hustoty rozdělení  $N(940, 50; 45, 47^2)$  jsou si tvarem velmi blízké. Grafická vizualizace tedy podporuje náš závěr, že náhodná veličina  $X$  popisující délku dolní končetiny v mm u žen pochází z normálního rozdělení s parametry  $\mu = 940, 50$  a  $\sigma^2 = 45, 47^2$ .

*Poznámka:* Grafická vizualizace je nástrojem sloužícím k subjektivnímu posouzení normálního rozdělení dat. V kapitole 8 si ukážeme objektivní zhodnocení normality dat prostřednictvím testů normality. ★

### Příklad 5.2. Řešený příklad

Za předpokladu, že náhodná veličina  $X$  popisující délku dolní končetiny v mm u žen pochází z rozdělení  $N(940, 50; 45, 47^2)$ , vypočítejte pravděpodobnost, že délka dolní končetiny u žen bude (a) menší než 962,50 mm; (b) větší než 974,13 mm;

(c) v rozmezí 930,00 mm až 950,00 mm; (d) rovná 943,25 mm. K výpočtu pravděpodobností použijte nezaokrouhlené odhady parametrů  $\mu$  a  $\sigma^2$  vypočítané v příkladu 5.1.

### Řešení příkladu 5.2

Pravděpodobnost, že délka dolní končetiny u žen bude menší než 962,50 mm, tj.  $\Pr(X < 962,50) = \Pr(X \leq 962,50)$  odpovídá hodnotě distribuční funkce  $F(x)$  rozdělení  $N(940, 50; 45, 47^2)$  v bodě  $x = 962,50$ . Tuto hodnotu vypočítáme příkazem `pnorm()`. Vstupními argumenty příkazu budou hodnota  $x$  (argument `q`), odhad parametru  $\mu$  (argument `mean`) a odhad parametru  $\sigma$  (argument `sd`).

```
21 pnorm(q = 962.50, mean = m, sd = s) # 0,6857443
```

Pravděpodobnost, že délka dolní končetiny u žen bude větší než 974,13 mm, tj.  $\Pr(X > 974,13) = \Pr(X \geq 974,13)$ , vypočítáme tak, že od jedné odečteme pravděpodobnost, že délka dolní končetiny u žen bude nejvýše 974,13 mm. Tuto pravděpodobnost, odpovídající hodnotě distribuční funkce  $F(x)$  v bodě  $x = 974,13$ , vypočítáme příkazem `pnorm()`.

```
22 1 - pnorm(q = 974.13, mean = m, sd = s) # 0,2297745
```

Pravděpodobnost, že délka dolní končetiny u žen bude v rozmezí 930,00 mm až 950,00 mm, tj.  $\Pr(930,00 < X < 950,00) = \Pr(930,00 \leq X < 950,00) = \Pr(930,00 < X \leq 950,00) = \Pr(930,00 \leq X \leq 950,00)$ , vypočítáme tak, že od pravděpodobnosti, že délka dolní končetiny u žen bude nejvýše 950,00 mm, odečteme pravděpodobnost, že délka dolní končetiny u žen bude nejvýše 930,00 mm. Obě pravděpodobnosti jsou hodnotami distribuční funkce  $F(x)$  v bodě  $x = 950,00$ , resp. v bodě  $x = 930,00$  a vypočítáme je příkazem `pnorm()`.

```
23 pnorm(q = 950.00, mean = m, sd = s) - pnorm(q = 930.00, mean = m, sd = s) # 0,1740559
```

Pravděpodobnost, že délka dolní končetiny u žen bude rovná 943,25 mm, tj.  $\Pr(X = 943,25)$ , je z definice rovná nule, protože náhodná veličina  $X$  má spojité rozdělení.

Pravděpodobnost, že délka dolní končetiny u žen bude menší než 962,50 mm, je 0,6857 (68,57%). Pravděpodobnost, že délka dolní končetiny u žen bude větší než 974,13 mm, je 0,2298 (22,98%). Pravděpodobnost, že délka dolní končetiny u žen bude v rozmezí 930,00 mm až 950,00 mm, je 0,1741 (17,41%). Pravděpodobnost, že délka dolní končetiny u žen bude rovná 943,25 mm, je 0,0000 (0,00%). ★

### Příklad 5.3. Řešený příklad

Za předpokladu, že náhodná veličina  $X$  popisující délku dolní končetiny v mm u žen pochází z rozdělení  $N(940, 50; 45, 47^2)$ , (a) zjistěte rozdělení náhodné veličiny  $M = \frac{1}{8} \sum_{i=1}^8 X_i$  popisující průměrnou délku dolní končetiny v mm u osmi žen a odhadněte parametry tohoto rozdělení; (b) vypočítejte pravděpodobnost, že průměrná délka dolní končetiny u osmi žen bude (i) menší než 962,50 mm; (ii) větší než 974,13 mm; (iii) v rozmezí 930,00 mm až 950,00 mm; (iv) rovná 943,25 mm. K výpočtu odhadů parametrů rozdělení náhodné veličiny  $M$  použijte nezaokrouhlené odhady parametrů  $\mu$  a  $\sigma^2$  vypočítané v příkladu 5.1.

### Řešení příkladu 5.3

Za předpokladu, že náhodná veličina  $X$  pochází z normálního rozdělení s parametry  $\mu = 940,50$  a  $\sigma^2 = 45,47^2$ , můžeme z třetího bodu věty 5.1 odvodit, že náhodná veličina  $M$  pochází z normálního rozdělení s parametry  $\mu_M = \mu = 940,50$  a  $\sigma_M^2 = \frac{45,47^2}{8} = 16,08^2$ , tj.  $M \sim N(940,50; 16,08^2)$ .

```
24 sM <- sqrt(s ^ 2 / 8) # 16,07648
```

Průměrná délka dolní končetiny u osmi žen se pohybuje okolo střední hodnoty 940,50 mm se směrodatnou odchylkou 16,08 mm.

Pravděpodobnost, že průměrná délka dolní končetiny u osmi žen bude menší než 962,50 mm, tj.  $\Pr(M < 962,50) = \Pr(M \leq 962,50)$  odpovídá hodnotě distribuční funkce  $F_M(x)$  rozdělení  $N(940, 50; 16, 08^2)$  v bodě  $x = 962,50$ . Tuto hodnotu vypočítáme příkazem `pnorm()`.

```
25 pnorm(q = 962.50, mean = m, sd = sM) # 0,9144157
```

Pravděpodobnost, že průměrná délka dolní končetiny u osmi žen bude větší než 974,13 mm, tj.  $\Pr(M > 974,13) = \Pr(M \geq 974,13)$ , vypočítáme tak, že od jedné odečteme pravděpodobnost, že průměrná délka dolní končetiny u

osmi žen bude nejvýše 974,13 mm. Tuto pravděpodobnost, odpovídající hodnotě distribuční funkce  $F_M(x)$  v bodě  $x = 974,13$ , vypočítáme příkazem `pnorm()`.

```
26 1 - pnorm(q = 974.13, mean = m, sd = sM) # 0,01822483
```

Pravděpodobnost, že průměrná délka dolní končetiny u osmi žen bude v rozmezí 930,00 mm až 950,00 mm, tj.  $\Pr(930,00 < M < 950,00) = \Pr(930,00 \leq M < 950,00) = \Pr(930,00 < M \leq 950,00) = \Pr(930,00 \leq M \leq 950,00)$ , vypočítáme tak, že od pravděpodobnosti, že průměrná délka dolní končetiny u osmi žen bude nejvýše 950,00 mm, odečteme pravděpodobnost, že průměrná délka dolní končetiny u osmi žen bude nejvýše 930,00 mm. Obě pravděpodobnosti jsou hodnotami distribuční funkce  $F_M(x)$  v bodě  $x = 950,00$ , resp. v bodě  $x = 930,00$  a vypočítáme je příkazem `pnorm()`.

```
27 pnorm(q = 950.00, mean = m, sd = sM) - pnorm(q = 930.00, mean = m, sd = sM) # 0,4658779
```

Pravděpodobnost, že průměrná délka dolní končetiny u osmi žen bude rovná 943,25 mm, tj.  $\Pr(M = 943,25)$ , je z definice rovná nule, protože náhodná veličina  $M$  pochází ze spojitého rozdělení.

Pravděpodobnost, že průměrná délka dolní končetiny u osmi žen bude menší než 962,50 mm, je 0,9144 (91,44%). Pravděpodobnost, že průměrná délka dolní končetiny u osmi žen bude větší než 974,13 mm, je 0,0182 (1,82%). Pravděpodobnost, že průměrná délka dolní končetiny u osmi žen bude v rozmezí 930,00 mm až 950,00 mm, je 0,4659 (46,59%). Pravděpodobnost, že průměrná délka dolní končetiny u osmi žen bude rovná 943,25 mm, je 0,0000 (0,00%).



#### Příklad 5.4. Řešený příklad

Předpokládejme, že náhodná veličina  $X$  popisující délku dolní končetiny v mm u žen pochází z rozdělení  $N(940,50; 45,47^2)$  a náhodná veličina  $M$  popisující průměrnou délku dolní končetiny v mm u osmi žen pochází z rozdělení  $N(940,50; 16,08^2)$ . Do jednoho grafu nakreslete (a) křivku funkce hustoty  $f(x)$ , resp.  $f_M(x)$ ; (b) křivku distribuční funkce  $F(x)$ , resp.  $F_M(x)$ . Křivky vzájemně porovnejte.


#### Řešení příkladu 5.4

K vykreslení grafu s křivkami hustot si nejprve vytvoříme posloupnost hodnot z intervalu se středem v bodě 940,50 mm, tj. například posloupnost v rozmezí 810 mm až 1071 mm. Pro každý prvek této posloupnosti potom příkazem `dnorm()` vypočítáme hodnotu hustoty  $f(x)$  rozdělení  $N(940,50; 45,47^2)$ , resp. hustoty  $f_M(x)$  rozdělení  $N(940,50; 16,08^2)$ . Následně příkazem `plot()` s argumentem `type = "l"` vykreslíme graf s křivkou hustoty  $f(x)$  a příkazem `lines()` do něj doplníme křivku hustoty  $f_M(x)$ . Výsledný graf je zobrazen na obrázku 5.2 vlevo.

```
28 x <- seq(from = 810, to = 1071, length = 512)
29 fx <- dnorm(x = x, mean = m, sd = s)
30 fM <- dnorm(x = x, mean = m, sd = sM)
31 plot(x, fx, type = "l", las = 1, ylim = c(0, 0.03), lwd = 2, col = "red", xlab = "délka
    dolní končetiny (mm)", ylab = "hustota")
32 lines(x, fM, lwd = 2, col = "darkred")
33 legend("topright", bty = "n", lwd = c(2, 2), col = c("red", "darkred"), legend =
    c("f(x)", expression(f[M](x))))
```

Nyní se zaměříme na vykreslení grafu s křivkami distribučních funkcí. Nejprve pro každý prvek posloupnosti z rozmezí 810 mm až 1071 mm vypočítáme pomocí funkce `pnorm()` hodnotu distribuční funkce  $F(x)$  rozdělení  $N(940,50; 45,47^2)$ , resp. distribuční funkce  $F_M(x)$  rozdělení  $N(940,50; 16,08^2)$ . Následně příkazem `plot()` s argumentem `type = "l"` vykreslíme graf s křivkou distribuční funkce  $F(x)$  a příkazem `lines()` do něj doplníme křivku distribuční funkce  $F_M(x)$ . Graf s křivkami distribučních funkcí je zobrazen na obrázku 5.2 vpravo.

```
34 Fx <- pnorm(q = x, mean = m, sd = s)
35 FM <- pnorm(q = x, mean = m, sd = sM)
36 plot(x, Fx, type = "l", las = 1, lwd = 2, col = "red", xlab = "délka dolní končetiny
    (mm)", ylab = "distribuční funkce")
37 lines(x, FM, lwd = 2, col = "darkred")
38 legend("topleft", bty = "n", lwd = c(2, 2), col = c("red", "darkred"), legend =
    c("F(x)", expression(F[M](x))))
```



Obrázek 5.2: Graf křivek funkcí hustoty (vlevo); graf křivek distribučních funkcí (vpravo) rozdělení  $N(940, 50; 45, 47^2)$ , resp. rozdělení  $N(940, 50; 16, 08^2)$

Z obrázku 5.2 vlevo vidíme, že vrchol křivek obou hustot se nachází nad střední hodnotou  $\mu = 940, 50$  mm. Křivka hustoty  $f_M(x)$  nabývá zpočátku hodnot blízkých nule, od určitého okamžiku pak začíná strmě růst až do vrcholu v bodě  $940, 50$  mm, a následně strmě klesá. Ve srovnání s křivkou hustoty  $f_M(x)$  křivka hustoty  $f(x)$  od začátku roste pozvolna až do svého vrcholu v bodě  $940, 50$  mm a od tohoto bodu pozvolna klesá. Tento průběh je důsledkem osmkrát většího rozptylu rozdělení náhodné veličiny  $X$ . Z obrázku 5.2 vpravo vidíme, že křivka distribuční funkce  $F_M(x)$  nabývá na poměrně dlouhém úseku hodnot blízkých nule, následně začná strmě růst a od určitého okamžiku je její růst k hodnotě 1 velmi pomalý. Ve srovnání s křivkou distribuční funkce  $F_M(x)$  křivka distribuční funkce  $F(x)$  roste pozvolna po celé délce zobrazeného úseku. Obě křivky se protínají v jediném bodě  $[940, 50; 0, 5]$ , což značí, že 50 % hodnot délky dolní končetiny u žen je menších než  $940, 50$  mm a stejně tak 50 % hodnot průměrné délky dolní končetiny u osmi žen je menších než  $940, 50$  mm.



### Příklad 5.5. Neřešený příklad

Načtěte datový soubor 15-anova-means-skull.txt obsahující údaje o výšce horní části tváře v mm (upface.H) u mužů bantuské, čínské, malajské, německé a peruánské populace. Předpokládejme, že náhodná veličina  $X$  popisuje výšku horní části tváře v mm u mužů malajské populace. (a) Najděte rozdělení, které dostatečně dobře vystihuje pravděpodobnostní chování náhodné veličiny  $X$ , a odhadněte parametry tohoto rozdělení; (b) ověrte, že nalezené rozdělení je vhodné na popis náhodné veličiny  $X$ ; pro naměřená data vykreslete histogram a superponujte jej křivkou jádrového odhadu hustoty a křivkou hustoty nalezeného rozdělení. Obě křivky vzájemně porovnejte.

**Výsledky:** (a)  $X \sim N(70, 13; 4, 95^2)$ ; (b) histogram s křivkou jádrového odhadu hustoty a s křivkou hustoty rozdělení  $N(70, 13; 4, 95^2)$  viz obrázek 5.3.




### Příklad 5.6. Neřešený příklad

Za předpokladu, že náhodná veličina  $X$  popisující výšku horní části tváře v mm u mužů malajské populace pochází z rozdělení  $N(70, 13; 4, 95^2)$ , vypočítejte pravděpodobnost, že výška horní části tváře u mužů malajské populace bude (a) větší než  $70,75$  mm; (b) menší než  $66,15$  mm; (c) rovná  $82,30$  mm; (d) v rozmezí  $64,40$  mm až  $72,40$  mm. K výpočtu pravděpodobností použijte nezaokrouhlené odhady parametrů  $\mu$  a  $\sigma^2$  vypočítané v příkladu 5.5.

**Výsledky:** (a)  $\Pr(X > 70,75) = 0,4502$ ; (b)  $\Pr(X < 66,15) = 0,2108$ ; (c)  $\Pr(X = 82,30) = 0,0000$ ; (d)  $\Pr(64,40 < X < 72,40) = 0,5530$ .





Obrázek 5.3: Histogram pro výšku horní části tváře u mužů superponovaný křivkou jádrového odhadu hustoty a křivkou hustoty normálního rozdělení

#### Příklad 5.7. Neřešený příklad

Za předpokladu, že náhodná veličina  $X$  popisující výšku horní části tváře v mm u mužů malajské populace pochází z rozdělení  $N(70, 13; 4, 95^2)$ , (a) zjistěte rozdělení náhodné veličiny  $M = \frac{1}{5} \sum_{i=1}^5 X_i$  popisující průměrnou výšku horní části tváře v mm u pěti mužů malajské populace a odhadněte parametry tohoto rozdělení; (b) vypočítejte pravděpodobnost, že průměrná výška horní části tváře u pěti mužů malajské populace bude (i) větší než 70,75 mm; (ii) menší než 66,15 mm; (iii) rovná 82,30 mm; (iv) v rozmezí 64,40 mm až 72,40 mm. K výpočtu odhadů parametrů rozdělení náhodné veličiny  $M$  použijte nezaokrouhlené odhady parametrů  $\mu$  a  $\sigma^2$  vypočítané v příkladu 5.5.

**Výsledky:** (a)  $M \sim N(70, 13; 2, 21^2)$ ; (b-i)  $\Pr(M > 70,75) = 0,3898$ ; (b-ii)  $\Pr(M < 66,15) = 0,0362$ ; (b-iii)  $\Pr(M = 82,30) = 0,0000$ ; (b-iv)  $\Pr(64,40 < M < 72,40) = 0,8424$ .



#### Příklad 5.8. Neřešený příklad

Předpokládejme, že náhodná veličina  $X$  popisující výšku horní části tváře v mm u mužů malajské populace pochází z rozdělení  $N(70, 13; 4, 95^2)$  a náhodná veličina  $M$  popisující průměrnou výšku horní části tváře v mm u pěti mužů malajské populace pochází z rozdělení  $N(70, 13; 2, 21^2)$ . Do jednoho grafu nakreslete (a) křivku funkce hustoty  $f(x)$ , resp.  $f_M(x)$ ; (b) křivku distribuční funkce  $F(x)$ , resp.  $F_M(x)$ . Křivky vzájemně porovnejte.


**Výsledky:** (a) graf s křivkami hustot  $f(x)$  a  $f_M(x)$  viz obrázek 5.4 vlevo; (b) graf s křivkami distribučních funkcí  $F(x)$  a  $F_M(x)$  viz obrázek 5.4 vpravo.



## 5.2 Spojitý dvourozměrný náhodný vektor

Jestliže obě složky dvourozměrného náhodného vektoru  $(X, Y)^T$  jsou spojité náhodné veličiny, hovoříme o spojitém dvourozměrném náhodném vektoru. Jeho pravděpodobnostní chování je popsáno simultání hustotou pravděpodobnosti  $f(x, y)$ . Hustota náhodné veličiny  $X$ , resp.  $Y$  se značí  $f_X(x)$ , resp.  $f_Y(y)$  a nazývá se marginální hustota. Získá se tak, že se simultání hustota pravděpodobnosti integruje přes přebývající proměnnou. Náhodné veličiny  $X$ ,  $Y$  jsou stochasticky nezávislé, když  $\forall (x, y)^T \in \mathbb{R}^2$  platí  $f(x, y) = f_X(x)f_Y(y)$ . Pravděpodobnost, že náhodný vektor  $(X, Y)^T$  se bude realizovat v nějaké dvourozměrné oblasti  $B$ , se vypočítá jako dvojnásobný integrál ze simultání hustoty přes tuto oblast:

$$\Pr((X, Y)^T \in B) = \int_{(x,y)^T \in B} \int f(u, v) du dv.$$



Obrázek 5.4: Graf křivek funkcí hustoty (vlevo); graf křivek distribučních funkcí (vpravo) rozdělení  $N(70, 13; 4, 95^2)$ , resp. rozdělení  $N(70, 13; 2, 21^2)$

### 5.2.1 Dvouozměrné normální rozdělení

Dvouozměrné normální rozdělení vzniká ve dvouozměrných situacích za podobných okolností jako normální rozdělení. Závisí na reálném vektoru  $\mu = (\mu_1, \mu_2)^T$  a reálné čtvercové symetrické matici  $\Sigma = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}$ . Vektor  $\mu$  se nazývá vektor středních hodnot, matice  $\Sigma$  se nazývá varianční matice. Přísluší  $(X, Y)^T \sim N_2(\mu, \Sigma)$ . Přitom  $\mu_1 \in \mathbb{R}, \mu_2 \in \mathbb{R}$  jsou střední hodnoty veličin  $X, Y$ ,  $\sigma_1 > 0, \sigma_2 > 0$  jsou směrodatné odchylky a  $\rho \in \langle -1, 1 \rangle$  je koeficient korelace veličin  $X, Y$  (viz kapitola 6).

Hustota má tvar:  $f(x, y) = \frac{1}{\sigma_1\sigma_2\sqrt{1-\rho^2}} e^{-\frac{q(x,y)}{2}}$ , kde  $q(x, y) = \frac{1}{1-\rho^2} \left[ \left( \frac{x-\mu_1}{\sigma_1} \right)^2 - 2\rho \frac{x-\mu_1}{\sigma_1} \frac{y-\mu_2}{\sigma_2} + \left( \frac{y-\mu_2}{\sigma_2} \right)^2 \right]$ .

Pro  $\mu_1 = 0, \mu_2 = 0, \sigma_1^2 = 1, \sigma_2^2 = 1, \rho \in \langle -1; 1 \rangle$  se jedná o standardizované dvouozměrné normální rozdělení. Přísluší  $\mathbf{U} = (U_1, U_2)^T \sim N_2(\mathbf{0}, \mathbf{I})$ , kde  $\mathbf{0} = (0, 0)^T$  je nulový vektor a  $\mathbf{I} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$  je jednotková matice druhého rádu.

**Věta 5.2:** Důležité vlastnosti dvouozměrného normálního rozdělení:

- Jestliže  $(X, Y)^T \sim N_2(\mu, \Sigma)$ ,  $\mathbf{a} = (a_1, a_2)^T$  je reálný vektor,  $\mathbf{B} = \begin{pmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{pmatrix}$  je reálná matice, pak pro transformovaný náhodný vektor  $\mathbf{Z} = \mathbf{a} + \mathbf{B}(X, Y)^T$  platí, že  $\mathbf{Z} \sim N_2(\mathbf{a} + \mathbf{B}\mu, \mathbf{B}\Sigma\mathbf{B}^T)$ .
- Marginální rozdělení náhodné veličiny  $X$ , resp.  $Y$  jsou  $X \sim N(\mu_1, \sigma_1^2)$ , resp.  $Y \sim N(\mu_2, \sigma_2^2)$ .
- Je-li koeficient korelace  $\rho = 0$ , pak řekneme, že veličiny  $X$  a  $Y$  jsou nekorelované a znamená to, že mezi nimi není žádná lineární závislost. U dvouozměrného normálního rozdělení je však nekorelovanost ekvivalentní se stochastickou nezávislostí veličin  $X$  a  $Y$ .

### Příklad 5.9. Řešený příklad

Načtěte datový soubor 31-goldman-alaska-hfrt.csv obsahující údaje o délce pažní kosti z levé strany v mm (`humerus.L`) a vertikálním průměru (zkráceně též v. p.) hlavice pažní kosti z levé strany v mm (`humerus.HDL`) u mužů a žen tří aljašských populací. Předpokládejme, že máme náhodný vektor  $(X, Y)^T$ , kde náhodná veličina  $X$  popisuje délku pažní kosti z levé strany v mm a náhodná veličina  $Y$  popisuje vertikální průměr hlavice pažní kosti z levé strany v mm u mužů z kmene Tigara. (a) Najděte rozdělení, které dostatečně dobře vystihuje pravděpodobnostní chování náhodného vektoru  $(X, Y)^T$ , a odhadněte parametry tohoto rozdělení; (b) ověřte, že nalezené rozdělení je vhodné na popis náhodného vektoru  $(X, Y)^T$ ; (i) vykreslete dvouozměrný tečkový diagram a superponujte jej konturami jádrového odhadu hustoty  $k(x, y)$ , resp. konturami hustoty  $f(x, y)$  nalezeného rozdělení; (ii) vykreslete

vrstevnicový diagram jádrového odhadu hustoty  $k(x, y)$  a superponujte jej konturami jádrového odhadu hustoty  $k(x, y)$ , resp. konturami hustoty  $f(x, y)$  nalezeného rozdělení; (iii) vykreslete 3D-diagram (trojrozměrný diagram) jádrového odhadu hustoty  $k(x, y)$ , resp. 3D-diagram hustoty  $f(x, y)$  nalezeného rozdělení. K vykreslení vrstevnicových diagramů a 3D-diagramů použijte 10 barev z palety `terrain.colors()`.

### Řešení příkladu 5.9

Datový soubor načteme a vypíšeme prvních pět řádků a deset sloupců tabulky. Z načteného souboru vybereme údaje o délce pažní kosti a vertikálním průměru hlavice pažní kosti z levé strany u mužů z kmene Tigara a z výběru odstraníme řádky s chybějícími hodnotami. Z výběru separujeme naměřené délky pažní kosti a naměřené vertikální průměry hlavice pažní kosti, zjistíme rozsah datového souboru a rozpětí naměřených hodnot každého znaku.

```

39 data <- read.delim("31-goldman-alaska-hfrt.csv", sep = ";", dec = ".")
40 head(data, n = c(5, 10))

  loc pop sex humerus.L humerus.R humerus.HDL humerus.HDR humerus.ADL humerus.ADR femur.L
1 ala   m    308.5      NA     47.55      NA     22.00      NA     443
2 ala   m    311.0     310     44.44     44.11     22.12    22.68     415
3 ala   m    289.0     298     42.94     44.41     20.36    22.09     398
4 ala   f    295.0     302     42.51     42.06     19.35    19.97     395
5 ala   f    270.5     281     39.74     39.84     19.42    19.38      NA
41
42
43
44
45
46
47 data.M <- na.omit(data[data$sex == "m" & data$pop == "tig", c("humerus.L",
48   "humerus.HDL")])
49 humerus.LM <- data.M$humerus.L
50 humerus.HDLM <- data.M$humerus.HDL
51 length(humerus.LM) # 25
52 range(humerus.LM) # 271,5; 340,0
53 range(humerus.HDLM) # 38,15; 52,00

```

Datový soubor obsahuje údaje o délce pažní kosti a vertikálním průměru hlavice pažní kosti z levé strany u 25 mužů z kmene Tigara. Naměřené hodnoty délky pažní kosti se pohybují v rozmezí 271,5 mm až 340,00 mm. Naměřené hodnoty vertikálního průměru hlavice pažní kosti se pohybují v rozmezí 38,15 mm až 52,00 mm.

Délka pažní kosti i vertikální průměr hlavice pažní kosti z levé strany tvoří dvojici spojitých znaků, k jejich společnému popisu tedy použijeme spojitý náhodný vektor  $(X, Y)^T$ . Protože oba znaky popisují tělesné rozměry, mohlo by k popisu této dvojice znaků být vhodné dvourozměrné normální rozdělení. O náhodném vektoru  $(X, Y)^T$  tedy předpokládáme, že pochází z dvourozměrného normálního rozdělení s vektorem středních hodnot  $\mu = (\mu_1, \mu_2)^T$  a varianční maticí  $\Sigma = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}$ , kde  $\mu_1$  a  $\sigma_1^2$  je střední hodnota a rozptyl délky pažní kosti,  $\mu_2$  a  $\sigma_2^2$  je střední hodnota a rozptyl vertikálního průměru hlavice pažní kosti a  $\rho$  je koeficient korelace. Parametr  $\mu_1$ , resp.  $\sigma_1^2$  odhadneme pomocí aritmetického průměru  $m_1$ , resp. rozptylu  $s_1^2$  naměřených hodnot délky pažní kosti. Parametr  $\mu_2$ , resp.  $\sigma_2^2$  odhadneme pomocí aritmetického průměru  $m_2$ , resp. rozptylu  $s_2^2$  naměřených hodnot vertikálního průměru hlavice pažní kosti. Parametr  $\rho$  odhadneme pomocí Pearsonova koeficientu korelace  $r_{12}$  (viz kapitola 3). Aritmetické průměry  $m_1$  a  $m_2$  vypočítáme příkazem `mean()`. Rozptyly  $s_1^2$  a  $s_2^2$  budeme častěji zapisovat ve tvaru druhých mocnin směrodatných odchylek, jejichž hodnoty vypočítáme příkazem `sd()`. Pearsonův koeficient korelace  $r_{12}$  vypočítáme příkazem `cor()` s argumentem `method = "pearson"`.

```

53 mL <- mean(humerus.LM) # 296,34
54 mHDL <- mean(humerus.HDLM) # 43,8984
55 sL <- sd(humerus.LM) # 16,30294
56 sHDL <- sd(humerus.HDLM) # 3,21493
57 r12 <- cor(humerus.LM, humerus.HDLM, method = "pearson") # 0,8523391

```

Odhady parametrů středních hodnot  $m_1 = 296,34$ ,  $m_2 = 43,90$ , odhady parametrů rozptylů  $s_1^2 = 16,30^2$ ,  $s_2^2 = 3,21^2$ , odhad parametru korelačního koeficientu  $r_{12} = 0,85$ . O náhodném vektoru  $(X, Y)^T$  předpokládáme, že pochází z dvourozměrného normálního rozdělení s vektorem středních hodnot  $\mu = (296,34; 43,90)^T$  a varianční maticí  $\Sigma = \begin{pmatrix} 16,30^2 & 0,85 \times 16,30 \times 3,21 \\ 0,85 \times 16,30 \times 3,21 & 3,21^2 \end{pmatrix}$ , tj.  $(X, Y)^T \sim N_2 \left( (296,34; 43,90)^T, \begin{pmatrix} 16,30^2 & 44,67 \\ 44,67 & 3,21^2 \end{pmatrix} \right)$ .

K vykreslení grafů je třeba vypočítat jádrový odhad hustoty  $k(x, y)$  a dvourozměrnou hustotu  $f(x, y)$  rozdělení

$N_2 \left( (296, 34; 43, 90)^T, \begin{pmatrix} 16, 30^2 & 44, 67 \\ 44, 67 & 3, 21^2 \end{pmatrix} \right)$ . Jádrový odhad hustoty  $k(x, y)$  vypočítáme příkazem `kde2d()` z knihovny MASS. Vstupními argumenty příkazu budou vektory `humerus.LM` (argument `x`) a `humerus.HDLM` (argument `y`), argument `n` specifikující počet bodů mřížky, pro kterou bude jádrový odhad počítán (je-li `n = c(75, 75)`, pak celkový počet bodů mřížky bude  $75 \times 75$ ), a argument `lim = c(xmin, xmax, ymin, ymax)` určující rozpětí hodnot z hlediska osy  $x$  a z hlediska osy  $y$ . Výstupem funkce bude posloupnost bodů osy  $x$  o délce 75 s hodnotami v rozpětí  $x_{\min}$  až  $x_{\max}$ , posloupnost bodů osy  $y$  o délce 75 s hodnotami v rozpětí  $y_{\min}$  až  $y_{\max}$  a matice  $z$ , která má dimenzi  $75 \times 75$  a obsahuje pro každý bod  $[x_i, y_j]$ ,  $i, j = 1, \dots, 75$ , hodnotu jádrového odhadu hustoty.

```
58 kxy <- MASS::kde2d(x = humerus.LM, y = humerus.HDLM, n = c(75, 75), lim = c(255, 348,
  35, 55))
```

Hustotu dvourozměrného normálního rozdělení  $f(x, y)$  vypočítáme pomocí funkce `d2norm()` implementované v R skriptu AS1-sbirka-funkce.R. Syntax a výstupy funkce `d2norm()` jsou analogické jako u funkce `kde2d()`.

```
59 source("AS1-sbirka-funkce.R")
60 fxy <- d2norm(x = humerus.LM, y = humerus.HDLM, n = c(75, 75), lim = c(255, 348, 35,
  55))
```

Dvourozměrný tečkový diagram vykreslíme příkazem `plot()`. Argumenty `xlim` a `ylim` nastavíme na stejné hodnoty, jaké jsme použili v argumentu `lim` příkazu `kde2d()`. Kontury jádrového odhadu hustoty  $k(x, y)$  vykreslíme příkazem `contour()`. Prvními třemi vstupními argumenty příkazu budou výstupy funkce `kde2d()`, tj. posloupnost `x`, posloupnost `y` a matice `z`. Dále následuje argument `add = T` určující, že se kontury vykreslí do stávajícího tečkového diagramu, argument `levels` specifikující výšky kontur (příkazem `seq()` nadefinujeme posloupnost  $l = 10$  výšek kontur v rozpětí od nuly po maximální hodnotu jádrového odhadu hustoty; tyto kontury od sebe oddělují  $l - 1$  vrstev) a argument `drawlabels = F` potlačující u každé kontury vypsání popisku s výškou kontury. Výsledný graf je zobrazen na obrázku 5.5 vlevo.

```
61 l <- 10
62 plot(humerus.LM, humerus.HDLM, las = 1, pch = 21, col = "darkgreen", bg =
  "darkolivegreen1", xlim = c(255, 348), ylim = c(35, 55), xlab = "délka pažní kosti
  (mm)", ylab = "v. p. hlavice pažní kosti (mm)")
63 contour(kxy$x, kxy$y, kxy$z, add = T, levels = seq(0, max(kxy$z), length = 1),
  drawlabels = F)
```


Analogickým způsobem vykreslíme tečkový diagram s konturami hustoty  $f(x, y)$  dvourozměrného normální rozdělení (viz obrázek 5.5 vpravo).

```
64 plot(humerus.LM, humerus.HDLM, las = 1, pch = 21, col = "darkgreen", bg =
  "darkolivegreen1", xlim = c(255, 348), ylim = c(35, 55), xlab = "délka pažní kosti
  (mm)", ylab = "v. p. hlavice pažní kosti (mm)")
65 contour(fxy$x, fxy$y, fxy$z, add = T, levels = seq(0, max(fxy$z), length = 1),
  drawlabels = F)
```

Vrstevnicový diagram jádrového odhadu hustoty  $k(x, y)$  vykreslíme příkazem `image()`. Prvními třemi vstupními argumenty příkazu budou výstupy funkce `kde2d()`, tj. posloupnost `x`, posloupnost `y` a matice `z`. Následuje argument `col`, kterým specifikujeme paletu odstínů barev vrstevnicového diagramu. Zde konkrétně volíme  $l - 1$  odstínů barev z palety `terrain.colors()`, neboť  $l$ -tým odstínem je vždy automaticky přednastavená bílá barva. Volit můžeme i další palety barev, například paletu `heat.colors()`, `topo.colors()`, `cm.colors()`, `hcl.colors()`, `rainbow()`, apod. Dále argumentem `breaks` specifikujeme výšky oddělující od sebe jednotlivé vrstvy diagramu. Syntax argumentu `breaks` je analogická syntaxi argumentu `levels` funkce `contour()`. Nakonec v příkazu nastavíme otočení popisků měřítka osy  $y$  o  $90^\circ$  (argument `las`), popisek osy  $x$  (argument `xlab`) a popisek osy  $y$  (argument `ylab`). Kontury doplníme do vrstevnicového diagramu zvlášť příkazem `contour()`. Výsledný graf je zobrazen na obrázku 5.6 vlevo.

```
66 image(kxy$x, kxy$y, kxy$z, col = terrain.colors(l - 1), breaks = seq(0, max(kxy$z),
  length = 1), las = 1, xlab = "délka pažní kosti (mm)", ylab = "v. p. hlavice pažní
  kosti (mm)")
67 contour(kxy$x, kxy$y, kxy$z, add = T, levels = seq(0, max(kxy$z), length = 1),
  drawlabels = F)
```


Analogickým způsobem vykreslíme vrstevnicový diagram jádrového odhadu hustoty  $k(x, y)$  superponovaný konturami hustoty  $f(x, y)$  dvourozměrného normálního rozdělení (viz obrázek 5.6 vpravo). Diagram slouží k porovnání



Obrázek 5.5: Dvouozměrný tečkový diagram superponovaný (a) konturami jádrového odhadu hustoty (vlevo); (b) konturami hustoty dvouozměrného normálního rozdělení (vpravo) pro délku pažní kosti a vertikální průměr hlavice pažní kosti z levé strany u mužů

tvaru dvouozměrných reálných dat s tvarem dvouozměrného normálního rozdělení s parametry odhadnutými na základě dat.

```
68 image(kxy$x, kxy$y, kxy$z, col = terrain.colors(1 - 1), breaks = seq(0, max(kxy$z),
  length = 1), las = 1, xlab = "délka pažní kosti (mm)", ylab = "v. p. hlavice pažní
  kosti (mm)")
69 contour(fxy$x, fxy$y, fxy$z, add = T, levels = seq(0, max(fxy$z), length = 1),
  drawlabels = F)
```



Obrázek 5.6: Vrstevnicový diagram jádrového odhadu hustoty superponovaný (a) konturami jádrového odhadu hustoty (vlevo); (b) konturami hustoty dvouozměrného normálního rozdělení (vpravo) pro délku pažní kosti a vertikální průměr hlavice pažní kosti z levé strany u mužů

3D-diagram jádrového odhadu hustoty  $k(x, y)$  vykreslíme příkazem `persp3D()` z knihovny GA. První tři vstupní argumenty příkazu jsou opět výstupy funkce `kde2d()`. Následují argumenty `phi` a `theta` specifikující natočení 3D-diagramu z hlediska osy  $x$  a osy  $y$ . Dále argumentem `ticktype = "simple"` nahradíme měřítko os  $x$ ,  $y$  a  $z$  ilustrativními šípkami ukazujícími směr růstu hodnot na osách (toto nastavení používáme pro přehlednější a elegantnější vzhled 3D-diagramu), argumentem `col.palette` vybereme paletu barev a argumentem `border = "black"` stanovíme černou barvu sítě 3D-diagramu. Nakonec specifikujeme popisek osy  $x$ ,  $y$  a  $z$  argumenty `xlab`, `ylab` a `zlab`. Výsledný diagram je zobrazen na obrázku 5.7 vlevo.

```

70 GA::persp3D(kxy$x, kxy$y, kxy$z, phi = 20, theta = 25, ticktype = "simple", col.palette
  = terrain.colors, border = "black", xlab = "délka pažní kosti (mm)", ylab = "v. p.
  hlavice pažní kosti (mm)", zlab = "k(x, y)")


```

Analogicky vykreslíme 3D-diagram hustoty  $f(x, y)$  dvourozměrného normální rozdělení (viz obrázek 5.7 vpravo).

```

71 GA::persp3D(fxy$x, fxy$y, fxy$z, phi = 20, theta = 25, ticktype = "simple", col.palette
  = terrain.colors, border = "black", xlab = "délka pažní kosti (mm)", ylab = "v. p.
  hlavice pažní kosti (mm)", zlab = "f(x, y)")

```



Obrázek 5.7: 3D-diagram jádrového odhadu hustoty (vlevo); 3D-diagram hustoty dvourozměrného normálního rozdělení (vpravo) pro délku pažní kosti a vertikální průměr hlavice pažní kosti z levé strany u mužů

Porovnáním grafů zobrazujících jádrový odhad hustoty  $k(x, y)$  a hustotu  $f(x, y)$  dvourozměrného normálního rozdělení na obrázcích 5.5, 5.6 a 5.7 zjistíme, že grafická vizualizace podporuje náš závěr, že náhodný vektor  $(X, Y)^T$  popisující délku pažní kosti z levé strany v mm a vertikální průměr hlavice pažní kosti z levé strany v mm u mužů z kmene Tigara pochází z dvourozměrného normálního rozdělení s parametry  $\mu_1 = 296, 34$ ,  $\mu_2 = 43, 90$ ,  $\sigma_1^2 = 16, 30^2$ ,  $\sigma_2^2 = 3, 21^2$  a  $\rho = 0, 85$ .



### Příklad 5.10. Řešený příklad

Za předpokladu, že náhodný vektor  $(X, Y)^T$  popisující délku pažní kosti z levé strany v mm a vertikální průměr hlavice pažní kosti z levé strany v mm u mužů z kmene Tigara pochází z dvourozměrného normálního rozdělení s parametry  $\mu_1 = 296, 34$ ,  $\mu_2 = 43, 90$ ,  $\sigma_1^2 = 16, 30^2$ ,  $\sigma_2^2 = 3, 21^2$  a  $\rho = 0, 85$ , (a) zjistěte marginální rozdělení náhodné veličiny  $X$ , resp.  $Y$ ; (b) nakreslete graf křivky hustoty  $f_X(x)$ , resp.  $f_Y(y)$  marginálního rozdělení spolu s křivkou jádrového odhadu hustoty náhodné veličiny  $X$ , resp.  $Y$ .

### Řešení příkladu 5.10

Za předpokladu, že náhodný vektor  $(X, Y)^T$  pochází z dvourozměrného normálního rozdělení s parametry  $\mu_1 = 296, 34$ ,  $\mu_2 = 43, 90$ ,  $\sigma_1^2 = 16, 30^2$ ,  $\sigma_2^2 = 3, 21^2$  a  $\rho = 0, 85$ , můžeme z druhého bodu věty 5.2 odvodit, že náhodná veličina  $X \sim N(296, 34; 16, 30^2)$  a náhodná veličina  $Y \sim N(43, 90; 3, 21^2)$ . Délka pažní kosti z levé strany u mužů z kmene Tigara se pohybuje okolo střední hodnoty 296, 34 mm se směrodatnou odchylkou 16, 30 mm. Vertikální průměr hlavice pažní kosti z levé strany u mužů z kmene Tigara se pohybuje okolo střední hodnoty 43, 90 mm se směrodatnou odchylkou 3, 21 mm.


K vykreslení grafu křivky hustoty  $f_X(x)$  marginálního rozdělení náhodné veličiny  $X$  si nejprve vytvoříme posloupnost hodnot z intervalu se středem v bodě 296 mm, tj. například posloupnost v rozmezí 246 mm až 346 mm. Pro každý prvek této posloupnosti potom příkazem `dnorm()` vypočítáme hodnotu hustoty  $f_X(x)$  rozdělení  $N(296, 34; 16, 30^2)$ . V příkazu použijeme nezaokrouhlené odhady parametrů  $\mu_1$  a  $\sigma_1^2$  vypočítané v příkladu 5.9. Následně příkazem

`plot()` s argumentem `type = "l"` vykreslíme graf s křivkou hustoty  $f_X(x)$  a příkazem `lines()` do něj doplníme křivku jádrového odhadu hustoty vypočítaného příkazem `density()`. Nakonec do grafu doplníme legendu rozšiřující obě vykreslené křivky. Výsledný graf je zobrazen na obrázku 5.8 vlevo.

```
72 x <- seq(from = 246, to = 346, length = 512)
73 fx <- dnorm(x = x, mean = mL, sd = sL)
74 plot(x, fx, type = "l", las = 1, lwd = 2, col = "darkgreen", ylim = c(0, 0.033), xlab =
    "délka pažní kosti (mm)", ylab = expression(f[X](x)))
75 lines(density(humerus.LM), lwd = 2, col = "orange")
76 legend("topright", bty = "n", lwd = c(1, 1), col = c("darkgreen", "orange"), legend =
    c("hustota marg. rozdělení", "jádrový odhad hustoty"))
```

Analogicky vykreslíme graf hustoty  $f_Y(y)$  marginálního rozdělení a jádrového odhadu hustoty náhodné veličiny  $Y$  (viz obrázek 5.8 vpravo).

```
77 y <- seq(from = 33, to = 55, length = 512)
78 fy <- dnorm(x = y, mean = mHDL, sd = sHDL)
79 plot(y, fy, type = "l", las = 1, lwd = 2, col = "darkgreen", ylim = c(0, 0.16), xlab =
    "v. p. hlavice pažní kosti (mm)", ylab = expression(f[Y](y)))
80 lines(density(humerus.HDLM), lwd = 2, col = "orange")
81 legend("topright", bty = "n", lwd = c(1, 1), col = c("darkgreen", "orange"), legend =
    c("hustota marg. rozdělení", "jádrový odhad hustoty"))
```




Obrázek 5.8: Křivka hustoty marginálního rozdělení a jádrového odhadu hustoty pro délku pažní kosti (vlevo) a pro vertikální průměr hlavice pažní kosti (vpravo) z levé strany u mužů




### Příklad 5.11. Neřešený příklad

Načtěte datový soubor `01-one-sample-mean-skull-mf.txt` obsahující údaje o délce mozkovny v mm (`skull.L`) a šířce mozkovny v mm (`skull.B`) u mužů a žen starověké egyptské populace. Předpokládejme, že máme náhodný vektor  $(X, Y)^T$ , kde náhodná veličina  $X$  popisuje délku mozkovny v mm a náhodná veličina  $Y$  popisuje šířku mozkovny v mm u žen starověké egyptské populace. (a) Najděte rozdělení, které dostatečně dobře vystihuje pravděpodobnostní chování náhodného vektoru  $(X, Y)^T$ , a odhadněte parametry tohoto rozdělení; (b) ověrte, že nalezené rozdělení je vhodné na popis náhodného vektoru  $(X, Y)^T$ ; (i) vykreslete dvourozměrný tečkový diagram a superponujte jej konturami jádrového odhadu hustoty  $k(x, y)$ , resp. konturami hustoty  $f(x, y)$  nalezeného rozdělení; (ii) vykreslete vrstevnicový diagram jádrového odhadu hustoty  $k(x, y)$  a superponujte jej konturami jádrového odhadu hustoty  $k(x, y)$ , resp. konturami hustoty  $f(x, y)$  nalezeného rozdělení; (iii) vykreslete 3D-diagram jádrového odhadu hustoty  $k(x, y)$ , resp. 3D-diagram hustoty  $f(x, y)$  nalezeného rozdělení. K vykreslení vrstevnicových diagramů a 3D-diagramů použijte 12 barev z palety `heat.colors()`.

**Výsledky:** (a)  $(X, Y)^T \sim N_2 \left( (174, 53; 134, 15)^T, \begin{pmatrix} 6,22^2 & 11,12 \\ 11,12 & 4,70^2 \end{pmatrix} \right)$ ,  $r_{12} = 0,38$ ; (b-i) dvourozměrný tečkový diagram superponovaný konturami jádrového odhadu hustoty  $k(x, y)$ , resp. konturami hustoty  $f(x, y)$  dvourozměrného normálního rozdělení viz obrázek 5.9 vlevo, resp. vpravo; (b-ii) vrstevnicový diagram superponovaný konturami jádrového odhadu hustoty  $k(x, y)$ , resp. konturami hustoty  $f(x, y)$  viz obrázek 5.10 vlevo, resp. vpravo; (b-iii) 3D-diagram jádrového odhadu hustoty  $k(x, y)$ , resp. hustoty  $f(x, y)$  viz obrázek 5.11 vlevo, resp. vpravo.



Obrázek 5.9: Dvourozměrný tečkový diagram superponovaný (a) konturami jádrového odhadu hustoty (vlevo); (b) konturami hustoty dvourozměrného normálního rozdělení (vpravo) pro délku mozkovny a šířku mozkovny u žen




Obrázek 5.10: Vrstevnicový diagram jádrového odhadu hustoty superponovaný (a) konturami jádrového odhadu hustoty (vlevo); (b) konturami hustoty dvourozměrného normálního rozdělení (vpravo) pro délku mozkovny a šířku mozkovny u žen




### Příklad 5.12. Neřešený příklad

Za předpokladu, že náhodný vektor  $(X, Y)^T$  popisující délku mozkovny v mm a šířku mozkovny v mm u žen stárověké egyptské populace pochází z dvourozměrného normálního rozdělení s parametry  $\mu_1 = 174,53$ ,  $\mu_2 = 134,15$ ,  $\sigma_1^2 = 6,22^2$ ,  $\sigma_2^2 = 4,70^2$  a  $\rho = 0,38$ , (a) zjistěte marginální rozdělení náhodné veličiny  $X$ , resp.  $Y$ ; (b) nakreslete graf křivky hustoty  $f_X(x)$ , resp.  $f_Y(y)$  marginálního rozdělení spolu s křivkou jádrového odhadu hustoty náhodné veličiny  $X$ , resp.  $Y$ .



Obrázek 5.11: 3D-diagram jádrového odhadu hustoty (vlevo); 3D-diagram hustoty dvouozměrného normálního rozdělení (vpravo) pro délku mozkovny a šířku mozkovny u žen

**Výsledky:** (a)  $X \sim N(174, 53; 6, 22^2)$ ,  $Y \sim N(134, 15; 4, 70^2)$ ; (b) graf křivky hustoty  $f_X(x)$ , resp.  $f_Y(y)$  marginálního rozdělení a jádrového odhadu hustoty náhodné veličiny  $X$ , resp.  $Y$  viz obrázek 5.12 vlevo, resp. vpravo.



Obrázek 5.12: Křivka hustoty marginálního rozdělení a jádrového odhadu hustoty pro délku mozkovny (vlevo) a pro šířku mozkovny (vpravo) u žen

