

## Statistická inference I

*Téma 8: Dvouozměrný normální model*

**Veronika Bendová**

bendova.veroonika@gmail.com

# Dvouzměrné normální rozdělení $N_2(\mu, \Sigma)$

- $(X_1, Y_1)^T, \dots, (X_n, Y_n)^T$  ... dvojice nezávislých stejně rozdělených náhodných (iid) veličin
- $(X, Y)^T$  ... dvouzměrný náhodný vektor
- Dvouzměrné normální rozdělení
  - $(X, Y)^T \sim N_2(\mu, \Sigma)$
  - $\theta = (\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)^T$
  - hustota

$$\begin{aligned} f(x, y) &= \frac{1}{2\pi\sqrt{\sigma_1^2\sigma_2^2(1-\rho^2)}} e^{-\frac{1}{2(1-\rho^2)}\left(\frac{(x-\mu_1)^2}{\sigma_1^2} - \frac{2\rho(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \frac{(y-\mu_2)^2}{\sigma_2^2}\right)} \\ &= \frac{1}{2\pi\sqrt{\sigma_1^2\sigma_2^2(1-\rho^2)}} e^{-\frac{1}{2}\begin{pmatrix} x - \mu_1 \\ y - \mu_2 \end{pmatrix}^T \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}^{-1} \begin{pmatrix} x - \mu_1 \\ y - \mu_2 \end{pmatrix}} \\ &= \frac{1}{2\pi(\det(\Sigma))^{1/2}} e^{-\frac{1}{2}U^T \Sigma^{-1} U}, \end{aligned}$$

kde  $(x, y)^T \in \mathbb{R}$ ,  $(\mu_1, \mu_2)^T \in \mathbb{R}$ ,  $\sigma_j^2 > 0$ ,  $j = 1, 2$  a korelační koeficient  $\rho \in \langle -1; 1 \rangle$ .

- marginální rozdělení  $X \sim N(\mu_1, \sigma_1^2)$ ,  $Y \sim N(\mu_2, \sigma_2^2)$ .
- `mvtnorm::dmvnorm(x, Mu, Sigma)`, `mvtnorm::rmvnorm(n, Mu, Sigma)`

- Standardizované dvourozměrné normální rozdělení

- $(X, Y)^T \sim N_2(\mu, \Sigma)$
- $\theta = (0, 0, 1, 1, \rho)^T$
- hustota

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

$$= \frac{1}{2\pi\sqrt{1-\rho^2}} e^{-\frac{1}{2} \begin{pmatrix} x \\ y \end{pmatrix}^T \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}^{-1} \begin{pmatrix} x \\ y \end{pmatrix}}$$

kde  $(x, y)^T \in \mathbb{R}$  a korelační koeficient  $\rho \in \langle -1; 1 \rangle$ .

- margiální rozdělení  $X \sim N(0, 1)$ ,  $Y \sim N(0, 1)$ .
- **Dataset 7: 13-two-samples-correlations-trunk.txt**
  - Máme k dispozici soubor hodnot délky trupu (rozdíl akrominální a spinální výšky těla) a délky dolní končetiny (spinální výška těla) mladých dospělých jedinců, převážně studentů vysokých škol z Brna a Ostravy (Králík, nepublikovaná data).
  - Přehled proměnných v datasetu:
    - sex ... pohlaví jedince (m - muž, f - žena);
    - lowex.L ... délka dolní končetiny (v mm);
    - tru.L ... délka trupu (v mm).

### Příklad 8.1. Hustota dvourozměrného normálního modelu

Naprogramujte v  funkci dnorm2(), jejímiž vstupy budou hodnoty  $x$ ,  $y$ ,  $\mu_1$ ,  $\mu_2$ ,  $\sigma_1$ ,  $\sigma_2$  a  $\rho$  a výstupem bude hodnota hustoty dvourozměrného normálního rozdělení  $N_2(\mu, \Sigma)$  s parametry

$\mu = (\mu_1, \mu_2)^T$  a  $\Sigma = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}$  v hodnotách  $x$  a  $y$ . Správnost funkce otestujte na výpočtu  $f(x, y)$  pro (a)  $x = 1$ ,  $y = 1$ ,  $\mu_1 = 0$ ,  $\mu_2 = 0$ ,  $\sigma_1^2 = 1$ ,  $\sigma_2^2 = 1$ ,  $\rho = 0.5$ ; (b)  $x = 2.5$ ,  $y = 1.5$ ,  $\mu_1 = 3$ ,  $\mu_2 = 2$ ,  $\sigma_1^2 = 9$ ,  $\sigma_2^2 = 16$ ,  $\rho = 0.75$ . Výsledky ověřte s výsledky funkce dmvnorm() z knihovny mvtnorm.

### Řešení příkladu 8.1

```
1  dnorm2 <- function(x, y, mu1, mu2, s1, s2, rho){  
2      U <- c(...) # vektor (x - mu1, y - mu2)^T  
3      S <- matrix(...) # variancni matice Sigma  
4      Z <- ... # hustota f(x, y) rozdeleni N2(Mu, Sigma)  
5      return(...)  
6  }  
7  dnorm2(...) # hustota N2(Mu, Sig); fce dnorm2()  
8  mvtnorm::dmvnorm(x = ..., mean = ...,  
9                      sigma = matrix(...)) # hustota N2(Mu, Sigma); fce dmvnorm()
```

f(1, 1) f(2.5, 1.5)	10
1 0.0943539 0.01977507	11

(a)  $f(1, 1) = 0.0944$ ; (b)  $f(2, 3) = 0.0198$ .

## Příklad 8.2. Základní číselné charakteristiky dvojice spojitých znaků

Načtěte datový soubor 13-two-samples-correlations-trunk.txt. Nechť náhodná proměnná  $X$  popisuje délku dolní končetiny (v mm) a náhodná proměnná  $Y$  popisuje délku trupu u žen. Pomocí tečkového diagramu vizualizujte vztah proměnných  $X$  a  $Y$ . Za předpokladu, že data pochází z dvourozměrného normálního rozdělení  $(X, Y)^T \sim N_2(\mu, \Sigma)$  odhadněte hodnoty parametrů  $\mu_1$ ,  $\mu_2$ ,  $\sigma_1^2$ ,  $\sigma_2^2$ ,  $\sigma_{12}$  a  $\rho$ . Výsledky řádně interpretujte.

### Řešení příkladu 8.2

```
12 data <- read.delim(..., sep = ..., dec = ...) # nacteni datoveho souboru
13 data.F <- data[data$sex == ..., c('lowex.L', 'tru.L')] # potrebne udaje pro zeny
14 data.F <- na.omit(...) # odstraneni NA
15 lowex.LF <- ... # vyber vektoru delek dolni koncetiny zen
16 tru.LF <- ... # vyber vektoru delek trupu zen
17 n <- ... # rozsah nahodneho vyberu
18 m1 <- ... # vyberovy prumer delky dolni koncetiny
19 m2 <- ... # vyberovy prumer delky trupu
20 s1 <- ... # sm. odchylka delky dolni koncetiny
21 s2 <- ... # sm. odchylka delky trupu
22 s12 <- cov(..., ...) # vyberova kovariance
23 r12 <- cor(..., ...) # vyberovy koef. korelace
24 tab <- data.frame(..., row.names = ...) # souhrnna tabulka vysledku
```


	n	mean	sd	s12	rho
delka d.koncetiny	100	940.50	45.4712	441.3081	0.2853
delka trupu		100	423.17	34.0229	441.3081

25

26

27

```
28 par(...)  
29 plot(lowex.LF, tru.LF, ...)
```



Obrázek: Dvourozměrný tečkový diagram pro délku dolní končetiny a délku trupu

Datový soubor obsahuje údaje o délce dolní končetiny a délce trupu 100 žen. Délka dolní končetiny se pohybuje okolo hodnoty 940.50 mm se směrodatnou odchylkou 45.47 mm. Délka trupu se pohybuje okolo hodnoty 423.17 mm se směrodatnou odchylkou 34.02 mm. Hodnota kovariance  $s_{12} = 441.31$ . Mezi délkou dolní končetiny a délkou trupu žen existuje nízký stupeň přímé lineární závislosti ( $r_{12} = 0.2853$ ).

### Příklad 8.3. Test dvouozměrné normality

Načtěte datový soubor 13-two-samples-correlations-trunk.txt. Nechť náhodná proměnná  $X$  popisuje délku dolní končetiny a náhodná proměnná  $Y$  popisuje délku trupu žen. Na hladině významnosti  $\alpha = 0.05$  testujte hypotézu o dvouozměrné normalitě vektoru  $(X, Y)^T$ . K otestování použijte Mardiův test.

### Řešení příkladu 8.3

Na hladině významnosti  $\alpha = 0.05$  testujeme  $H_0$ : Data pochází z dvouozměrného normálního rozdělení, oproti  $H_1$ : Data nepochází z dvouozměrného normálního rozdělení.

**Mardiův test** – sestává ze dvou testů:

(i) test šikmosti

- $H_{0a}$ : Data nejsou kladně ani záporně vyšikmená.
- $H_{1a}$ : Data jsou kladně nebo záporně vyšikmená.

(ii) test špičatosti

- $H_{0b}$ : Data nejsou kladně ani záporně zešpičatělá.
- $H_{1b}$ : Data jsou kladně nebo záporně zešpičatělá.

*Poznámka:* Náhodný výběr pochází z dvouozměrného normálního rozdělení, pokud nevykazuje kladné ani záporné zešikmení ani kladné nebo záporné zešpičatění.

30

```
MVN:::mvn(data.F, mvnTest = 'mardia')$multivariateNormality
```

	Test	Statistic	p value	Result
1	Mardia Skewness	6.31326657225727	0.176942962210473	YES
2	Mardia Kurtosis	-0.207066071208097	0.835958259081491	YES
3	MVN	<NA>	<NA>	YES

31

32

33

34

Protože  $p$ -hodnota testu šikmosti  $p = 0.1769$  je větší než  $\alpha$ ,  $H_{0a}$  nezamítáme na hladině významnosti  $\alpha = 0.05$ . Protože  $p$ -hodnota testu špičatosti  $p = 0.8360$  je větší než  $\alpha$ ,  $H_{0b}$  nezamítáme na hladině významnosti  $\alpha = 0.05$ . Data nejsou kladně ani záporně zešikmená ani zešpičatělá. Data pochází z dvouozměrného normálního rozdělení.

### Příklad 8.4. Vizualizace dat z dvourozměrného normálního modelu

Načtěte datový soubor 13-two-samples-correlations-trunk.txt. Nechť náhodná proměnná  $X$  popisuje délku dolní končetiny a náhodná proměnná  $Y$  popisuje délku trupu žen. Na základě řešení příkladů 8.2 a 8.3 předpokládáme, že data pochází z dvourozměrného normálního rozdělení  $(X, Y)^T \sim N_2(\mu, \Sigma)$  s odhadem středních hodnot  $\hat{\mu}_1 = 940.50$ ,  $\hat{\mu}_2 = 423.17$ , s odhadem rozptylů  $\hat{\sigma}_1^2 = 45.47^2$  a  $\hat{\sigma}_2^2 = 34.02^2$  a s odhadem korelačního koeficientu  $\hat{\rho} = 0.2853$ .

- (a) Sestrojte tečkový diagram pro délku dolní končetiny a délku trupu. Tečkový diagram superponujte (i) konturami hustoty dvourozměrného normálního rozdělení (funkce dnorm2() + contour()); (ii) jádrovým odhadem dvourozměrné hustoty (funkce kde2d() z knihovny MASS + funkce contour()).
- (b) Sestrojte (i) vrstevnicový diagram hustoty dvourozměrného normálního rozdělení délky dolní končetiny a délky trupu superponovaný svými konturami (dnorm2() + image() + contour()); (ii) vrstevnicový diagram jádrového odhadu hustoty délky dolní končetiny a délky trupu superponovaný svými konturami (MASS::kde2d() + image() + contour()).
- (c) Sestrojte (i) 3D-diagram hustoty dvourozměrného normálního rozdělení délky dolní končetiny a délky trupu (dnorm2() + persp()); (ii) 3D-diagram jádrového odhadu hustoty dvourozměrného normálního rozdělení délky dolní končetiny a délky trupu (MASS::kde2d() + persp()).


### Řešení příkladu 8.4

- (a) Tečkové diagramy

```

35 n <- 50
36 x <- seq(...) # posl. bodu osy x; od 800 do 1100 o delce n
37 y <- seq(...) # posl. bodu osy y; od 300 do 550 o delce n
38 M <- matrix(NA, ...) # prazdna matice dimenze (n x n)
39 for(i in 1:length(x)){
40   for(j in 1:length(y)){
41     M[i, j] <- dnorm2(x[i], y[j], m1, m2, s1, s2, r12)
42   }
43 } # hodnoty hustoty f(x, y) rozdeleni N2(Mu, Sig)
44 Z <- MASS::kde2d(lowex.LF, tru.LF, lim = c(800, 1100, 300, 550),
45                   n = n) # jadrovy odhad hustoty f(x, y)
46 k <- 8
47 par(...) # okraje grafu 4, 5, 1, 1
48 plot(lowex.LF, tru.LF, xlim = c(800, 1100), ylim = c(300, 550),
49       ...) # teckovy diagram
50 contour(x, y, M, drawlabels = T, levels = seq(0, max(M), length = k + 1),
51           add = T, col = ...) # kontury hustoty f(x, y) rozdeleni N2(Mu, Sig)
52 plot(...) # teckovy diagram
53 contour(Z$x, Z$y, Z$z, ...) # kontury jadroveho odhadu hustoty f(x, y)

```





Obrázek: Dvouozměrný tečkový diagram pro délku dolní končetiny a délku trupu žen superponovaný (a) konturami hustoty dvouozměrného normálního rozdělení (vlevo); (b) jádrovým odhadem hustoty dvouozměrného normálního rozdělení (vpravo)

## (b) Vrstevnicové diagramy

```

54 k <- 12
55 par(...) # okraje grafu 4, 5, 1, 1
56 image(x, y, M, breaks = seq(0, max(M), length = k + 1), xlim = c(800, 1100),
57       ylim = c(300, 550), asp = F, col = terrain.colors(k), las = 1, xlab = ...,
58       ylab = ...) # vrstevnicovy diagram hustoty f(x, y) rozd. N2(Mu, Sig)
59 contour(x, y, M, add = ..., drawlabels = ...,
60          levels = ...) # kontury hustoty f(x, y) rozdeleni N2(Mu, Sig)
61
62 image(Z$x, Z$y, Z$z, ...) # vrstevnicovy diagram jadr. odhadu hustoty f(x, y)
63 contour(...) # kontury jadr. odhadu hustoty f(x, y)

```





Obrázek: (a) Hustota dvourozměrného normálního rozdělení pro délku dolní končetiny a délku trupu žen superponovaná konturami (vlevo); (b) jádrový odhad hustoty dvourozměrného normálního rozdělení superponovaný konturami (vpravo)

(c) 3D-diagramy

```

64 nrz <- nrow(M) # pocet radku matice Z
65 ncz <- ncol(M) # pocet sloupcu matice z
66 color <- terrain.colors(k) # paleta k barev
67 stredy <- (M[-1, -1] + M[-1, -ncz] + M[-nrz, -1] + M[-nrz, -ncz]) / 4
68 # matice stredu site
69 stredy.col <- cut(stredy, k) # rozdel rozpeti hodnot do 12 ekvidistantnich
70 # intervalu a kazde hodnote prirad interval, do ktereho nalezi
71 par(...) # okraje grafu 1, 1, 1, 1
72 persp(x, y, M, col = color[stredy.col], phi = 30, theta = 20, xlab = ...,
73 ylab = ..., zlab = ...) # 3D-diagram hustoty f(x, y) rozd. N2(Mu, Sig)
74
75 nrz <- nrow(Z$z) # pocet radku matice z promenne Z
76 (... )
77 persp(Z$x, Z$y, Z$z, ...) # 3D diagram jadr. odhadu hustoty f(x, y)

```



Obrázek: (a) 3D-diagram hustoty normálního rozdělení pro délku dolní končetiny a délku trupu (vlevo); (b) 3D-diagram jádrového odhadu hustoty dvourozměrného normálního rozdělení (vpravo) 10 / 13

### Příklad 8.5. Simulace dat z dvouozměrného normálního rozdělení

Nasimulujte data  $(X, Y)^T$  z dvouozměrného normálního rozdělení s parametry  $\mu_1 = 940.50$ ,  $\mu_2 = 423.17$ ,  $\sigma_1^2 = 45.47^2$ ,  $\sigma_2^2 = 34.02^2$  a  $\rho = 0.2853$ ;  $n = 100$ . Simulaci pseudonáhodných čísel z  $N_2(\mu, \Sigma)$  proved'te použitím funkce `rmvnorm()` z knihovny `mvtnorm`. Pro nasimulovaná data vykreslete (a) histogram náhodné veličiny  $X$  a histogram náhodné veličiny  $Y$ , přičemž každý histogram superponujte křivkou marginálního normálního rozdělení  $N(\mu_i, \sigma_i^2)$ ,  $i = 1, 2$  a křivkou jádrového odhadu hustoty; (b) tečkový diagram náhodných veličin  $X$  a  $Y$ , přičemž graf superponujte konturami jádrového odhadu dvouozměrné hustoty.


### Řešení příkladu 8.5

```
78 simnorm2 <- function(n, Mu, Sig, method = 'rmvnorm', col1 = ..., col2 = ...,
79                         col3 = ..., k = 12){
80   mu1 <- Mu[1] # vyber mu1 z vektoru Mu
81   mu2 <- ... # vyber mu2 z vektoru Mu
82   sigma1 <- sqrt(Sig[1, 1]) # vyber sm. odchylky s1 z matice Sig
83   sigma2 <- sqrt(Sig[2, 2]) # vyber sm. odchylky s2 z matice Sig
84   if(method == 'rmvnorm') {
85     data <- mvtnorm::rmvnorm(n = ..., mean = ..., sigma = ...) # simulace dat
86   }
```

```

87 x <- data[, 1] # vyber vektoru x z nasimulovanych dat
88 y <- data[, 2] # vyber vektoru y z nasimulovanych dat
89 xx <- seq(min(x) - 100, max(x) + 100,
90           length = 512) # posl. bodu osy x pro krvku f(x)
91 xy <- dnorm(xx, mu1, sigma1) # hustota rozdeleni N(mu1, sigma1^2)
92 yx <- seq(...) # posl. bodu osy x pro krvku f(y)
93 yy <- ... # hustota rozdeleni N(mu2, sigma2^2)
94 Z <- MASS::kde2d(x, y, n = 50) # jadrovy odhad hustoty f(x, y)
95
96 par(...) # okraje grafu 4, 5, 1, 1
97 hist(x, prob = T, ylim = c(0, max(xy) + 0.005), ...) # histogram simul. dat x
98 box(...) # ramecek okolo grafu
99 lines(density(x), ...) # krvka jadroveho odhadu hustoty f(x)
100 lines(xx, xy, ...) # krvka hustoty N(mu1, sigma1^2)
101 mtext(...) # popisek osy x
102 mtext(...) # popisek osy y
103 legend(...) # legenda
104
105 hist(...) # histogram nasimulovanych dat y
106 ...
107
108 plot(x, y, ...) # teckovy diagram
109 contour(Z$x, Z$y, Z$z, levels = seq(..., ..., length = k + 1),
110           ...) # kontury jadr. odhadu hustoty f(x, y)
111 mtext(...) # popisek osy x
112 }
113
114 Mu <- c(...) # vektor vyberovych prumeru
115 Sig <- matrix(...) # kovarianci matice
116 n <- ... # rozsah nahodneho vyber n
117 simnorm2(n, Mu, Sig, method = 'rmvnorm', col1 = ..., col2 = ..., col3 = ...,
118           k = 6) # provedeni simulace

```



*Poznámka:* Simulaci dat z dvouozměrného normálního rozdělení lze dále provést

1. pomocí funkce `mvrnorm()` z knihovny MASS
2. použitím funkce `rnorm()` a následujícího algoritmu: Nechť  $U_1 \sim N(0, 1)$  a  $U_2 \sim N(0, 1)$ ; potom  $(X, Y)^T \sim N_2(\mu, \Sigma)$ , kde  $\mu = (\mu_1, \mu_2)^T$  je vektor středních hodnot a  $\sigma_1^2$  a  $\sigma_2^2$  a  $\rho$  jsou parametry kovarianční matice  $\Sigma$ , přičemž síla lineárního vztahu  $X$  a  $Y$  je daná velikostí a znaménkem  $\rho$ ;  $X = \sigma_1 U_1 + \mu_1$  a  $Y = \sigma_2(\rho U_1 + \sqrt{1 - \rho^2} U_2) + \mu_2$ .

V případě zájmu si můžete simulaci těmito dvěma způsoby také vyzkoušet.