

## 2 Intervalové rozložení četnosti

### 2.1 Jednorozměrné intervalové rozložení četnosti

Jestliže v jednorozměrném datovém souboru je počet variant znaku  $X$  blízký rozsahu souboru  $n$ , pak četnosti přiřazujeme nikoliv jednotlivým variantám, ale třídicím intervalům  $(u_1; u_2), \dots, (u_r; u_{r+1})$ . Hovoříme pak o intervalovém rozložení četnosti.

Označení:

- $(u_j; u_{j+1})$  –  $j$ -tý třídicí interval znaku  $X$ ,  $j = 1, \dots, r$ ,
- $d_j = u_{j+1} - u_j$  – délka  $j$ -tého třídicího intervalu znaku  $X$ ,
- $x_{[j]} = \frac{u_j + u_{j+1}}{2}$  – střed  $j$ -tého třídicího intervalu znaku  $X$ .

Třídicí intervaly volíme nejčastěji stejně dlouhé, jinak řečeno ekvidistantní. Jejich počet určíme například pomocí Sturgesova pravidla:  $r \approx 1 + 3,3 \log_{10}(n)$ , kde  $n$  je rozsah souboru.

Názvy četností jsou podobné jako v sekci 1.2. Navíc se používá četnostní hustota  $j$ -tého třídicího intervalu:  $f_j = \frac{p_j}{d_j}$ . Četnosti a četnostní hustotu zapisujeme do tabulky rozložení četností (viz tabulka 2.1).

Tabulka 2.1: Tabulka rozložení četností znaku  $X$

$(u_j; u_{j+1})$	$d_j$	$x_{[j]}$	$n_j$	$p_j$	$N_j$	$F_j$	$f_j$
$(u_1; u_2)$	$d_1$	$x_{[1]}$	$n_1$	$p_1$	$N_1$	$F_1$	$f_1$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$(u_r; u_{r+1})$	$d_r$	$x_{[r]}$	$n_r$	$p_r$	$N_r$	$F_r$	$f_r$

Jednorozměrné intervalové rozložení četností graficky znázorníme pomocí histogramu. Nad třídicími intervaly se strojíme soustavu obdélníků, jejichž plocha je rovna relativním četnostem a výšky četnostním hustotám jednotlivých intervalů. Schodovitá čára shora omezující histogram je grafem hustoty četnosti:

$$f(x) = \begin{cases} f_j \text{ pro } u_j < x \leq u_{j+1}, j = 1, \dots, r, \\ 0 \text{ jinak.} \end{cases}$$

Pomocí hustoty četnosti zavedeme intervalovou empirickou distribuční funkci:  $F(x) = \int_{-\infty}^x f(t)dt$ .

#### Příklad 2.1. Řešený příklad

Načtěte datový soubor 16-anova-head.txt obsahující údaje o délce hlavy v mm (head.L) u mladých dospělých mužů a žen. Pro znak  $X$  popisující délku hlavy u mužů (a) zjistěte hranice třídicích intervalů; (b) vytvořte tabulkou rozložení četností; (c) nakreslete histogram a graf intervalové empirické distribuční funkce  $F(x)$ .

#### Řešení příkladu 2.1

Datový soubor načteme příkazem `read.delim()` s argumenty `sep = "\t"` a `dec = "."`. Pro náhled datového souboru si zobrazíme prvních pět řádků tabulky pomocí funkce `head()` s argumentem `n = 5`.

```
1 data <- read.delim("16-anova-head.txt", sep = "\t", dec = ".")
2 head(data, n = 5)
```

sex	sexor	obra	body.H	head.L	head.W	bigo.W	bizyg.W	3
1	m	<NA>	no	1782	180	159	109	150
2	m	op	no	1824	195	163	108	150
3	f	<NA>	no	1631	197	144	100	138
4	f	op	no	1576	186	148	105	127
5	m	op	no	1792	197	151	106	142
								4
								5
								6
								7
								8

Z načtených dat vybereme pomocí operátoru [ ] pouze řádky týkající se mužů a sloupec `head.L`. Z výběru odstraníme řádky s chybějícími pozorováními příkazem `na.omit()`. Ke stanovení hranic třídicích intervalů potřebujeme znát rozsah datového souboru a minimální a maximální naměřenou hodnotu délky hlavy u mužů. Rozsah datového souboru zjistíme příkazem `length()`, minimální a maximální naměřenou hodnotu příkazem `range()`. Optimální počet třídicích intervalů stanovíme pomocí vzorce  $r \approx 1 + 3,3 \log_{10}(n)$ . Hodnotu logaritmu při základu 10, tj.  $\log_{10}(n)$ , vypočítáme příkazem `log10()`.

```
9 head.LM <- na.omit(data[data$sex == "m", "head.L"])
10 n <- length(head.LM) # 75
11 range(head.LM) # 180; 214
12 r <- round(1 + 3.3 * log10(n)) # 7
```

Optimální počet třídicích intervalů  $r = 7$ . Naměřené hodnoty délky hlavy se pohybují v rozmezí 180 až 214 mm. Vzdálenost mezi minimální naměřenou hodnotou sníženou o 1 a maximální naměřenou hodnotou je  $214 - 179 = 35$  mm. Tato vzdálenost je beze zbytku dělitelná počtem třídicích intervalů, tj. sedmi. Optimální délka jednoho třídicího intervalu  $d = \frac{35}{7} = 5$  mm. Hranice třídicích intervalů tedy stanovíme jako posloupnost  $u_1 = 179, u_2 = 184, \dots, u_8 = 214$  mm. Celkem získáme osm hranic definujících sedm třídicích intervalů. Posloupnost hranic vytvoříme příkazem `seq()`.

```
13 # 214 - 179 = 35; 35 / 7 = 5 -> seq(179, 214, by = 5)
14 b.head.LM <- seq(from = 179, to = 214, by = 5) # 179, 184, ..., 214
```

Tabulkou rozložení četností dopočítáme pomocí funkce `trc()` implementované v R skriptu AS1-sbirka-funkce.R. Vstupními argumenty funkce jsou vektor naměřených hodnot `x` a hranice třídicích intervalů `breaks`. Výstupem funkce je tabulka rozložení četností, kterou si zobrazíme zaokrouhlenou na čtyři desetinná místa.

```
15 source("AS1-sbirka-funkce.R")
16 tab.rc <- trc(head.LM, b.head.LM)
17 round(tab.rc, 4)
```

	dj	xj	nj	pj	Nj	Fj	fj
(179;184]	5	181,5	5	0,0667	5	0,0667	0,0133
(184;189]	5	186,5	6	0,0800	11	0,1467	0,0160
(189;194]	5	191,5	20	0,2667	31	0,4133	0,0533
(194;199]	5	196,5	24	0,3200	55	0,7333	0,0640
(199;204]	5	201,5	12	0,1600	67	0,8933	0,0320
(204;209]	5	206,5	6	0,0800	73	0,9733	0,0160
(209;214]	5	211,5	2	0,0267	75	1,0000	0,0053

18  
19  
20  
21  
22  
23  
24  
25

Pro ukázku si zde uvedeme interpretace vybraných hodnot ze třetího a pátého řádku tabulky rozložení četností. Celkem 20 mužů (26,67 %) v datovém souboru mělo délku hlavy v rozmezí 189 až 194 mm, celkem 31 mužů (41,33 %) v datovém souboru mělo délku hlavy nejvýše 194 mm. Celkem 12 mužů (16,00 %) v datovém souboru mělo délku hlavy v rozmezí 199 až 204 mm, celkem 67 mužů (89,33 %) v datovém souboru mělo délku hlavy nejvýše 204 mm.

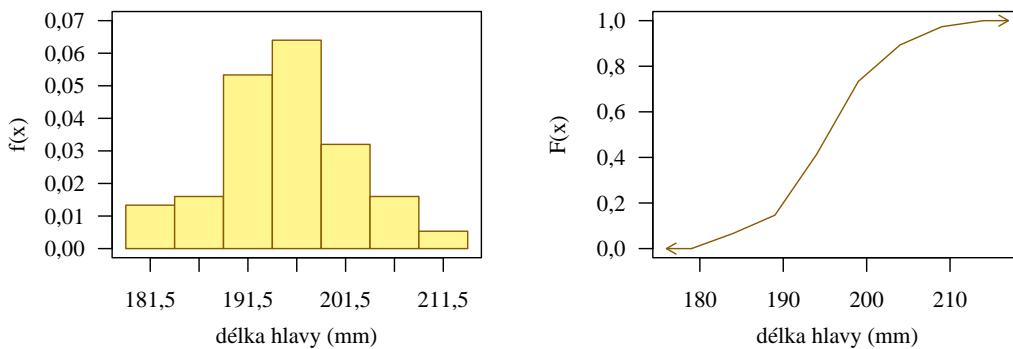
Histogram vykreslíme příkazem `hist()` s argumentem `prob = T`. Tento argument zajistí, že plocha obdélníků v histogramu bude odpovídat relativním četnostem a výšky obdélníků četnostním hustotám. V histogramu dále nastavíme hranice (`breaks = b.head.LM`) zleva otevřených (`include.lowest = F`) třídicích intervalů, rozsah osy `y` (`ylim = c(0, 0.07)`), potlačení vykreslení os `x` a `y` (`axes = F`), barvu výplně obdélníků (`col`), barvu obrysů obdélníků (`border`), popisek osy `x` (`xlab`), popisek osy `y` (`ylab`) a potlačení nadpisu (`main = ""`). Okolo grafu dokreslíme rámeček příkazem `box()`. Osu `x`, resp. osu `y` vykreslíme samostatně pomocí příkazu `axis()`. V souladu se zavedenou konvencí vykreslíme měřítko osy `x` ve středech třídicích intervalů. Středy intervalů můžeme získat buď ručním výpočtem nebo jako výstup `mids` funkce `hist()` se specifikací argumentu `plot = F`. Tento argument umožní provedení všech výpočtů potřebných k vytvoření histogramu, ale potlačí jeho vykreslení. Výsledný histogram je zobrazen na obrázku 2.1 vlevo.

```
26 hist(head.LM, prob = T, breaks = b.head.LM, include.lowest = F, ylim = c(0, 0.07), axes
      = F, col = "khaki1", border = "orange4", xlab = "délka hlavy (mm)", ylab = "f(x)",
      main = "", )
27 box(bty = "o")
28 c.head.LM <- hist(head.LM, breaks = b.head.LM, plot = F)$mids
29 axis(side = 1, at = c.head.LM)
```

```
30 axis(side = 2, las = 1)
```

K vykreslení grafu intervalové empirické distribuční funkce  $F(x)$  potřebujeme zadefinovat její průběh. Funkce  $F(x)$  je až do hodnoty 179 rovná nule, v bodech 184, 189, ..., 214 její hodnoty odpovídají hodnotám kumulativní distribuční funkce  $F_j$  a od hodnoty 214 je tato funkce rovná jedné. Graf funkce  $F(x)$  vykreslíme příkazem `plot()` s argumentem `type = "l"`. Prvním vstupním argumentem příkazu bude vektor hranic třídicích intervalů, druhým argumentem bude vektor hodnot funkce  $F(x)$ . Do grafu dále dokreslíme šipku značící nulovou hodnotu empirické distribuční funkce  $F(x)$  ve všech hodnotách menších než 179, a dále šipku značící jednotkovou hodnotu funkce  $F(x)$  ve všech hodnotách větších než 214. Šipky vykreslíme pomocí funkce `arrows()`. Prvními čtyřmi vstupními argumenty funkce jsou  $x$ -ová a  $y$ -ová souřadnice počátečního bodu (argumenty `x0` a `y0`) a  $x$ -ová a  $y$ -ová souřadnice koncového bodu (argumenty `x1` a `y1`). Při definování souřadnic počátečního a koncového bodu je třeba mít na paměti, že hrot šipky se vždy vykresluje v koncovém bodu. Dále specifikujeme barvu šipky (argument `col`) a délku hrotu šipky (argument `length`). Výsledný graf intervalové empirické distribuční funkce  $F(x)$  je zobrazen na obrázku 2.1 vpravo.

```
31 Fx <- c(0, tab.rc$Fj)
32 plot(b.head.LM, Fx, type = "l", las = 1, col = "orange4", xlim = c(176, 217), xlab =
   "délka hlavy (mm)", ylab = "F(x)")
33 arrows(x0 = 179, y0 = 0, x1 = 176, y1 = 0, col = "orange4", length = 0.1)
34 arrows(x0 = 214, y0 = 1, x1 = 217, y1 = 1, col = "orange4", length = 0.1)
```



Obrázek 2.1: Histogram (vlevo); graf intervalové empirické distribuční funkce  $F(x)$  (vpravo) pro délku hlavy u mužů



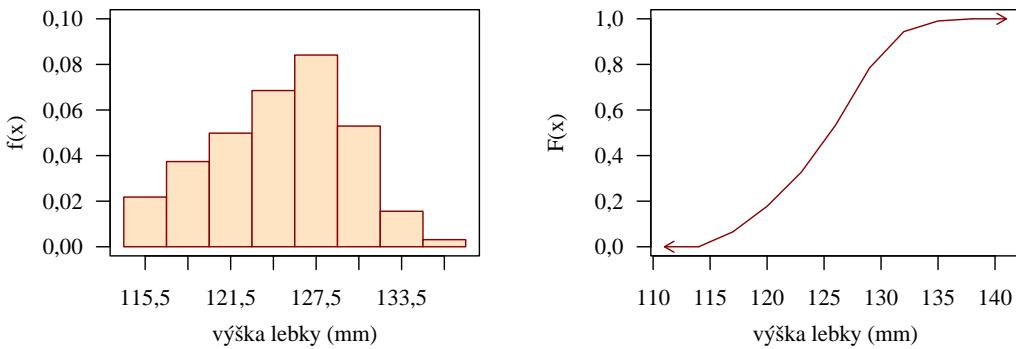
### Příklad 2.2. Neřešený příklad

Načtěte datový soubor 11-two-samples-means-skull.txt obsahující údaje o výšce lebky v mm (skull.H) u mužů a u žen starověké egyptské populace. Pro znak  $X$  popisující výšku lebky u žen (a) zjistěte hranice třídicích intervalů; (b) vytvořte tabulkou rozložení četnosti; (c) nakreslete histogram a graf intervalové empirické distribuční funkce  $F(x)$ .

**Výsledky:** (a) rozsah datového souboru  $n = 107$ , optimální počet třídicích intervalů  $r = 8$ , rozsah naměřených hodnot je 117 až 136 mm, optimální délka jednoho třídicího intervalu  $d = 3$ , hranice třídicích intervalů:  $u_1 = 114$ ,  $u_2 = 117, \dots, u_9 = 138$ ; (b) tabulka rozložení četností viz tabulka 2.2; (c) histogram, resp. graf intervalové empirické distribuční funkce  $F(x)$  viz obrázek 2.2.

Tabulka 2.2: Tabulka rozložení četností pro výšku lebky u žen

	$d_j$	$x_{[j]}$	$n_j$	$p_j$	$N_j$	$F_j$	$f_j$
$(114; 117]$	3,00	115,50	7	0,07	7	0,07	0,02
$(117; 120]$	3,00	118,50	12	0,11	19	0,18	0,04
$(120; 123]$	3,00	121,50	16	0,15	35	0,33	0,05
$(123; 126]$	3,00	124,50	22	0,21	57	0,53	0,07
$(126; 129]$	3,00	127,50	27	0,25	84	0,79	0,08
$(129; 132]$	3,00	130,50	17	0,16	101	0,94	0,05
$(132; 135]$	3,00	133,50	5	0,05	106	0,99	0,02
$(135; 138]$	3,00	136,50	1	0,01	107	1,00	0,00



Obrázek 2.2: Histogram (vlevo); graf intervalové empirické distribuční funkce  $F(x)$  (vpravo) pro výšku lebky u žen

★

## 2.2 Dvouozměrné intervalové rozložení četnosti

Ve dvouozměrném datovém souboru o rozsahu  $n$  roztrídíme hodnoty znaku  $X$  do  $r$  ekvidistantních třídicích intervalů  $(u_j; u_{j+1}]$ ,  $j = 1, \dots, r$  s jednotnou délkou  $d$  a hodnoty znaku  $Y$  také roztrídíme do  $s$  ekvidistantních třídicích intervalů  $(v_k; v_{k+1}]$ ,  $k = 1, \dots, s$  s jednotnou délkou  $h$ . Obdélník  $(u_j; u_{j+1}] \times (v_k; v_{k+1}]$  se nazývá  $(j, k)$ -tý dvouozměrný třídicí interval. Názvy četností jsou podobné jako v sekci 1.3. Simultánní absolutní četnosti, resp. simultánní relativní četnosti zapisujeme do kontingenční tabulky (viz tabulka 2.3 vlevo, resp. vpravo).

Tabulka 2.3: Kontingenční tabulka (a) simultánních absolutních četností (vlevo); (b) simultánních relativních četností (vpravo)

$X$	$Y$							
	$y_{[1]}$	$\dots$	$y_{[s]}$					
$x_{[1]}$	$n_{11}$	$\dots$	$n_{1s}$					
$\vdots$	$\vdots$	$\dots$	$\vdots$					
$x_{[r]}$	$n_{r1}$	$\dots$	$n_{rs}$					

$X$	$Y$							
	$p_{11}$	$\dots$	$p_{1s}$					
$x_{[1]}$	$p_{11}$	$\dots$	$p_{1s}$					
$\vdots$	$\vdots$	$\dots$	$\vdots$					
$x_{[r]}$	$p_{r1}$	$\dots$	$p_{rs}$					

Navíc zavádíme simultánní a marginální četnostní hustoty:

- $f_{jk} = \frac{p_{jk}}{dh}$  – simultánní četnostní hustota v  $(j, k)$ -tém třídicím intervalu,
- $f_{j\cdot} = \frac{p_{j\cdot}}{d}$  – marginální četnostní hustota v  $j$ -tém třídicím intervalu pro znak  $X$ ,
- $f_{\cdot k} = \frac{p_{\cdot k}}{h}$  – marginální četnostní hustota v  $k$ -tém třídicím intervalu pro znak  $Y$ .

Dvourozměrné intervalové rozložení četností graficky znázorníme pomocí stereogramu. Nad dvourozměrnými třídicími intervaly sestojíme soustavu kvádrů, jejichž objem je roven relativním četnostem a výšky simultánním četnostním hustotám jednotlivých intervalů. Schodovitá plocha shora omezující stereogram je grafem simultánní četnostní hustoty:

$$f(x, y) = \begin{cases} f_{jk} \text{ pro } u_j < x \leq u_{j+1}, v_k < y \leq v_{k+1}, j, k = 1, \dots, r, \\ 0 \text{ jinak.} \end{cases}$$

Marginální hustoty četnosti pro znaky  $X$  a  $Y$  odlišíme indexem takto:

$$f_1(x) = \begin{cases} f_j \text{ pro } u_j < x \leq u_{j+1}, j = 1, \dots, r, \\ 0 \text{ jinak,} \end{cases}$$

$$f_2(y) = \begin{cases} f_k \text{ pro } v_k < y \leq v_{k+1}, k = 1, \dots, r, \\ 0 \text{ jinak.} \end{cases}$$

Mezi simultánní hustotou četnosti a marginálními hustotami četnosti platí vztahy:  $f_1(x) = \int_{-\infty}^{\infty} f(x, y) dy$ ,  $f_2(y) = \int_{-\infty}^{\infty} f(x, y) dx$ .

Znaky  $X$  a  $Y$  jsou v daném výběrovém souboru četnostně nezávislé při daném dvourozměrném intervalovém rozložení četností, jestliže pro  $\forall j, k = 1, \dots, r$  platí:  $f_{jk} = f_j f_k$ , neboli pro  $\forall (x, y)^T \in \mathbb{R}^2$ :  $f(x, y) = f_1(x) f_2(y)$ .

### Příklad 2.3. Řešený příklad

Načtěte datový soubor 16-anova-head.txt obsahující údaje o délce hlavy v mm (head.L) a šířce tváře v mm (bizyg.W) u mladých dospělých mužů a žen. Pro znak  $X$  popisující délku hlavy a znak  $Y$  popisující šířku tváře u mužů (a) zjistěte hranice dvourozměrných třídicích intervalů; (b) vytvořte kontingenční tabulkou simultánních absolutních, resp. relativních četností; (c) nakreslete histogram pro znak  $X$ , resp. pro znak  $Y$ ; (d) nakreslete stereogram a dvourozměrný tečkový diagram; (e) zjistěte, zda jsou znaky  $X$  a  $Y$  četnostně nezávislé při daném dvourozměrném intervalovém rozložení četností.

### Řešení příkladu 2.3

Datový soubor načteme a z načtených dat vybereme pouze řádky týkající se mužů a sloupce head.L a bizyg.W. Z výběru odstraníme řádky s chybějícími pozorováními příkazem `na.omit()`. V dalším kroku si z výběru separujeme hodnoty délky hlavy, které vložíme do proměnné `head.LM`, a hodnoty šířky tváře, které vložíme do proměnné `bizyg.WM`. Ke stanovení hranic třídicích intervalů potřebujeme znát rozsah dvourozměrného datového souboru a minimální a maximální naměřenou hodnotu každého znaku. Rozsah datového souboru zjistíme příkazem `length()`, minimální a maximální naměřenou hodnotu příkazem `range()`. Optimální počet třídicích intervalů stanovíme na základě Sturgesova pravidla. Počet třídicích intervalů je stejný pro oba znaky, neboť závisí pouze na rozsahu datového souboru.

```
35 data <- read.delim("16-anova-head.txt", sep = "\t", dec = ".")
36 data.M <- data[data$sex == "m", c("head.L", "bizyg.W")]
37 data.M <- na.omit(data.M)
38 head.LM <- data.M$head.L
39 bizyg.WM <- data.M$bizyg.W
40 n <- length(head.LM) # 75
41 range(head.LM) # 180; 214
42 range(bizyg.WM) # 113; 155
43 r <- round(3.3 * log10(n) + 1) # 7
```

Optimální počet třídicích intervalů  $r = 7$ . Naměřené hodnoty znaku  $X$ , tj. délky hlavy, se pohybují v rozmezí 180 až 214 mm. Analogicky jako v příkladu 2.1 rozdělíme naměřené hodnoty tohoto znaku do 7 ekvidistantních třídicích intervalů o optimální délce  $d = 5$  mm, a to stanovením hranic  $u_1 = 179, u_2 = 184, \dots, u_8 = 214$  mm. Naměřené hodnoty znaku  $Y$ , tj. šířky tváře, se pohybují v rozmezí 113 až 155 mm. Vzdálenost mezi minimální naměřenou hodnotou sníženou o 1 a maximální naměřenou hodnotou je  $155 - 112 = 43$  mm. Nejbližší vyšší celé číslo dělitelné beze zbytku počtem třídicích intervalů, tj. sedmi, je 49. Optimální délka jednoho třídicího intervalu  $h = \frac{49}{7} = 7$  mm. Hranice třídicích intervalů pro šířku tváře tedy stanovíme jako posloupnost  $v_1 = 110, v_2 = 117, \dots, v_8 = 159$  mm.

```

44 # head.LM: viz priklad 2.1
45 # bizyg.WM: 155 - 112 = 43 => 49 / 7 = 7 -> seq(110, 159, by = 7)
46 b.head.LM <- seq(from = 179, to = 214, by = 5)
47 b.bizyg.WM <- seq(from = 110, to = 159, by = 7)

```

V dalším kroku roztrídíme naměřené hodnoty každého znaku do příslušných třídicích intervalů, a to pomocí příkazu `cut()`. Vstupními argumenty příkazu jsou vektor naměřených hodnot a vektor hranic třídicích intervalů (argument `breaks`). Informace o třídicím intervalu přiřazeném každému měření znaku  $X$ , resp. znaku  $Y$  vložíme do proměnné `head.LM.c`, resp `bizyg.WM.c`. Kontingenční tabulkou simultánních absolutních četností vypočítáme pomocí funkce `table()`, jejímiž vstupními argumenty budou právě vektory `head.LM.c` a `bizyg.WM.c`.

```

48 head.LM.c <- cut(head.LM, breaks = b.head.LM)
49 bizyg.WM.c <- cut(bizyg.WM, breaks = b.bizyg.WM)
50 KT.abs <- table(head.LM.c, bizyg.WM.c)

```

	(110;117]	(117;124]	(124;131]	(131;138]	(138;145]	(145;152]	(152;159]	51
(179;184]	0	0	0	3	1	1	0	52
(184;189]	1	0	0	0	4	0	1	53
(189;194]	0	2	2	7	7	2	0	54
(194;199]	0	0	0	5	12	6	1	55
(199;204]	0	0	1	2	6	2	1	56
(204;209]	0	0	1	0	2	3	0	57
(209;214]	0	0	1	1	0	0	0	58

Kontingenční tabulkou simultánních relativních četností získáme příkazem `prop.table()`.

```

59 KT.rel <- prop.table(KT.abs)

```

	(110;117]	(117;124]	(124;131]	(131;138]	(138;145]	(145;152]	(152;159]	60
(179;184]	0,0000	0,0000	0,0000	0,0400	0,0133	0,0133	0,0000	61
(184;189]	0,0133	0,0000	0,0000	0,0000	0,0533	0,0000	0,0133	62
(189;194]	0,0000	0,0267	0,0267	0,0933	0,0933	0,0267	0,0000	63
(194;199]	0,0000	0,0000	0,0000	0,0667	0,1600	0,0800	0,0133	64
(199;204]	0,0000	0,0000	0,0133	0,0267	0,0800	0,0267	0,0133	65
(204;209]	0,0000	0,0000	0,0133	0,0000	0,0267	0,0400	0,0000	66
(209;214]	0,0000	0,0000	0,0133	0,0133	0,0000	0,0000	0,0000	67

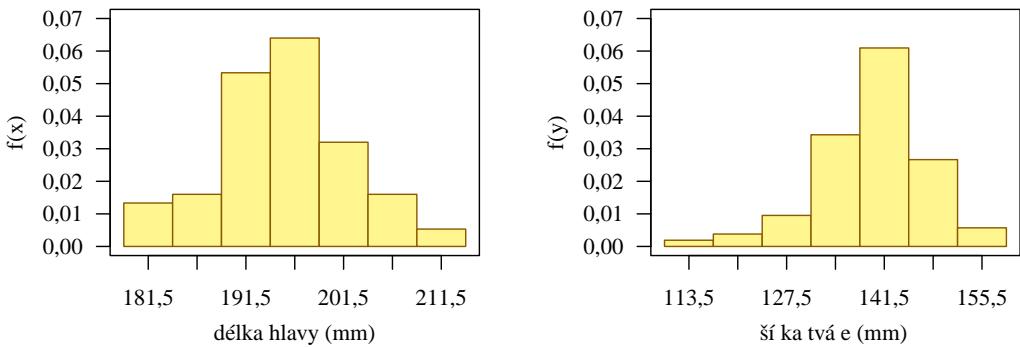
Pro ukázku si uvedeme interpretace vybraných hodnot z prvního, druhého a třetího sloupce kontingenční tabulky simultánních absolutních, resp. relativních četností. V datovém souboru se vyskytoval jeden muž (1, 33 %), jehož délka hlavy nabývala hodnoty z intervalu (184; 189) mm a jehož šířka tváře nabývala hodnoty z intervalu (110; 117) mm, dva muži (2, 67 %), jejichž délka hlavy nabývala hodnoty z intervalu (189; 194) mm a jejichž šířka tváře nabývala hodnoty z intervalu (117; 124) mm, dva muži (2, 67 %), jejichž délka hlavy nabývala hodnoty z intervalu (189; 194) mm a jejichž šířka tváře nabývala hodnoty z intervalu (124; 131) mm, apod.

Histogram znaku  $X$ , resp. znaku  $Y$  vykreslíme pomocí funkce `hist()` s argumentem `prob = T`. Hranice třídicích intervalů definujeme explicitně pomocí argumentu `breaks`. Měřítko osy  $x$  vykreslíme v hodnotách středů třídicích intervalů příkazem `axis()`. Histogramy pro oba znaky jsou zobrazeny na obrázku 2.3.

```

68 hist(head.LM, prob = T, breaks = b.head.LM, include.lowest = F, ylim = c(0, 0.07), axes
      = F, col = "khaki1", border = "orange4", xlab = "délka hlavy (mm)", ylab = "f(x)",
      main = "")
69 box(bty = "o")
70 c.head.LM <- hist(head.LM, breaks = b.head.LM, plot = F)$mids
71 axis(side = 1, at = c.head.LM)
72 axis(side = 2, las = 1)
73
74 hist(bizyg.WM, breaks = b.bizyg.WM, prob = T, ylim = c(0, 0.07), col = "khaki1", border
      = "orange4", xlab = "šířka tváře (mm)", ylab = "f(y)", main = "", axes = F,
      include.lowest = F)
75 box(bty = "o")
76 c.bizyg.WM <- hist(bizyg.WM, breaks = b.bizyg.WM, plot = F)$mids
77 axis(side = 1, at = c.bizyg.WM)
78 axis(2, las = 1)

```



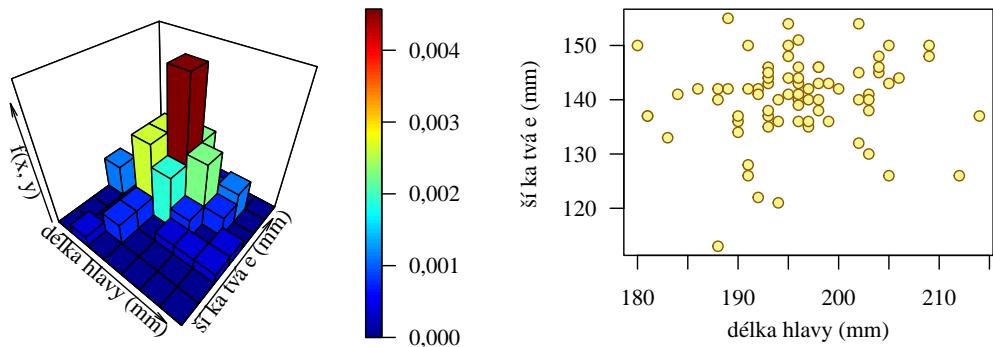
Obrázek 2.3: Histogram pro délku hlavy u mužů (vlevo); histogram pro šířku tváře u mužů (vpravo)

K vykreslení stereogramu potřebujeme znát hodnoty simultánních četnostních hustot  $f_{jk}$ . Ty dopočítáme pomocí vzorce  $f_{jk} = \frac{p_{jk}}{dh}$ , kde  $p_{jk}$ ,  $j, k = 1, \dots, 7$  jsou simultánní relativní četnosti (viz proměnná KT.rel),  $d = 5$  je ekvidistantní délka třídicích intervalů znaku  $X$  a  $h = 7$  je ekvidistantní délka třídicích intervalů znaku  $Y$ . Stereogram potom vykreslíme pomocí funkce hist3D() z knihovny plot3D. Vstupními argumenty funkce budou matice simultánních četnostních hustot ( $z = \text{as.matrix}(fjk)$ ), barva obrysu sloupců ( $\text{border} = "black"$ ) a popisky os  $x$ ,  $y$  a  $z$  ( $\text{xlab}$ ,  $\text{ylab}$  a  $\text{zlab}$ ). Dvouozměrný tečkový diagram vykreslíme příkazem plot(). Stereogram je zobrazen na obrázku 2.4 vlevo. Barevné spektrum přecházející od odstínu modré po červenou vizuálně rozlišuje hodnoty simultánních četnostních hustot. Dvouozměrný tečkový diagram je zobrazen na obrázku 2.4 vpravo.

```

79 pjk <- KT.rel; d <- 5; h <- 7
80 fjk <- pjk / (d * h)
81 plot3D::hist3D(z = as.matrix(fjk), border = "black", xlab = "délka hlavy (mm)", ylab =
  "šířka tváře (mm)", zlab = "f(x, y)")
82 plot(head.LM, bizyg.WM, pch = 21, col = "orange4", bg = "khaki1", las = 1, xlab =
  "délka hlavy (mm)", ylab = "šířka tváře (mm)")

```



Obrázek 2.4: Stereogram (vlevo); dvouozměrný tečkový diagram (vpravo) pro délku hlavy a šířku tváře u mužů

Znaky  $X$  a  $Y$  jsou četnostně nezávislé, pokud  $f_{jk} = f_j f_k$ , kde  $f_{jk}$  jsou simultánní četnostní hustoty,  $f_j$  je marginální četnostní hustota v  $j$ -tém třídicím intervalu pro znak  $X$  a  $f_k$  je marginální četnostní hustota v  $k$ -tém třídicím intervalu pro znak  $Y$ ,  $j, k = 1, \dots, 7$ . Simultánní četnostní hustoty  $f_{jk}$  máme vloženy v proměnné fjk. Tuto proměnnou si zobrazíme zaokrouhlenou na čtyři desetinná místa pomocí funkce round() s argumentem digits = 4.

```
83 round(fjk, digits = 4)
```

(110;117]	(117;124]	(124;131]	(131;138]	(138;145]	(145;152]	(152;159]	84
(179;184]	0,0000	0,0000	0,0000	0,0011	0,0004	0,0004	0,0000
(184;189]	0,0004	0,0000	0,0000	0,0000	0,0015	0,0000	0,0004
(189;194]	0,0000	0,0008	0,0008	0,0027	0,0027	0,0008	0,0000
(194;199]	0,0000	0,0000	0,0000	0,0019	0,0046	0,0023	0,0004
(199;204]	0,0000	0,0000	0,0004	0,0008	0,0023	0,0008	0,0004
(204;209]	0,0000	0,0000	0,0004	0,0000	0,0008	0,0011	0,0000
(209;214]	0,0000	0,0000	0,0004	0,0004	0,0000	0,0000	0,0000

Marginální četnostní hustotu  $f_j$ , dopočítáme pomocí vzorce  $f_j = \frac{p_j}{d}$ , kde  $p_j$  je marginální relativní četnost  $k$ -té variandy znaku  $X$  a  $d$  je ekvidistantní délka  $j$ -tého třídicího intervalu. Marginální relativní četnosti  $p_j$ ,  $j = 1, \dots, 7$  vypočítáme pomocí funkce `apply()` s argumenty `MARGIN = 1` a `FUN = sum` aplikované na matici `pjk`. Marginální četnostní hustotu  $f_k$  dopočítáme pomocí vzorce  $f_k = \frac{p_k}{h}$ , kde  $p_k$  je marginální relativní četnost  $k$ -té variandy znaku  $Y$  a  $h$  je ekvidistantní délka  $k$ -tého třídicího intervalu. Marginální relativní četnosti  $p_k$ ,  $k = 1, \dots, 7$  vypočítáme pomocí funkce `apply()` s argumenty `MARGIN = 2` a `FUN = sum` aplikované na matici `pjk`. Matici součinů  $f_j.f_k$  nakonec vypočítáme maticovým vynásobením vektoru `fj` s transponovaným vektorem `f.k`. Operaci maticového násobení zadefinujeme operátorem `%*%`, transpozici vektoru `f.k` provedeme pomocí funkce `t()`. Matici součinů si opět zobrazíme zaokrouhlenou na čtyři desetinná místa.

```
92 pj. <- apply(pjk, MARGIN = 1, FUN = sum)
93 p.k <- apply(pjk, MARGIN = 2, FUN = sum)
94 fj. <- pj. / d
95 f.k <- p.k / h
96 fj.f.k <- fj. %*% t(f.k)
97 round(fj.f.k, digits = 4)
```

(110;117]	(117;124]	(124;131]	(131;138]	(138;145]	(145;152]	(152;159]	98
(179;184]	0,0000	0,0001	0,0001	0,0005	0,0008	0,0004	0,0001
(184;189]	0,0000	0,0001	0,0002	0,0005	0,0010	0,0004	0,0001
(189;194]	0,0001	0,0002	0,0005	0,0018	0,0033	0,0014	0,0003
(194;199]	0,0001	0,0002	0,0006	0,0022	0,0039	0,0017	0,0004
(199;204]	0,0001	0,0001	0,0003	0,0011	0,0020	0,0009	0,0002
(204;209]	0,0000	0,0001	0,0002	0,0005	0,0010	0,0004	0,0001
(209;214]	0,0000	0,0000	0,0001	0,0002	0,0003	0,0001	0,0000

Porovnáním matice simultánních četnostních hustot  $f_{jk}$  s příslušnými součiny marginálních četnostních hustot  $f_j.f_k$  vidíme, že znaky  $X$  a  $Y$  nejsou četnostně nezávislé při daném intervalovém rozložení četnosti. Například  $f_{14} \neq f_1.f_4$  ( $0,0011 \neq 0,0005$ ),  $f_{36} \neq f_3.f_6$  ( $0,0008 \neq 0,0014$ ),  $f_{65} \neq f_6.f_5$  ( $0,0008 \neq 0,0010$ ), apod. ★

#### Příklad 2.4. Neřešený příklad

Načtěte datový soubor `05-one-sample-correlation-skull-mf.txt` obsahující údaje o největší výšce mozkovny v mm (`skull.pH`) a morfologické výšce tváře v mm (`face.H`) u mužů a žen starověké egyptské populace. Pro znak  $X$  popisující největší výšku mozkovny a znak  $Y$  popisující morfologickou výšku tváře u žen (a) zjistěte hranice dvourozměrných třídicích intervalů; (b) vytvořte kontingenční tabulku simultánních absolutních, resp. relativních četností; (c) nakreslete histogram pro znak  $X$ , resp. pro znak  $Y$ ; (d) nakreslete stereogram a dvourozměrný tečkový diagram; (e) zjistěte, zda jsou znaky  $X$  a  $Y$  četnostně nezávislé při daném dvourozměrném intervalovém rozložení četnosti.

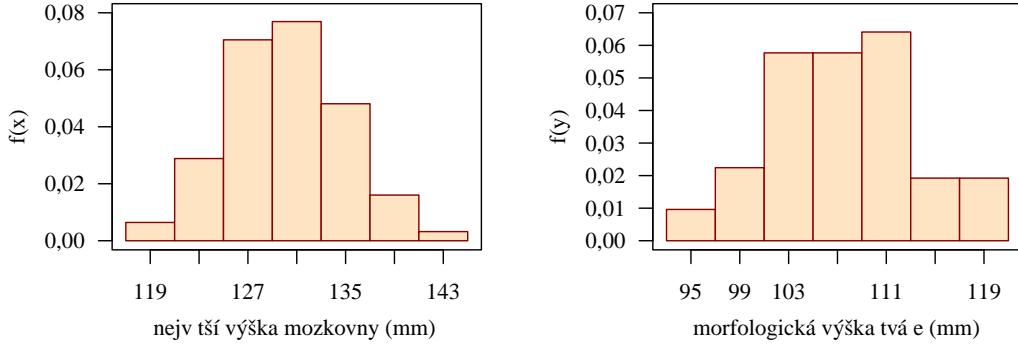
**Výsledky:** (a) rozsah náhodného výběru  $n = 78$ , optimální počet třídicích intervalů  $r = 7$ ; znak  $X$ : rozsah naměřených hodnot je 120 až 142 mm, optimální délka jednoho třídicího intervalu  $d = 4$ , hranice třídicích intervalů:  $u_1 = 117$ ,  $u_2 = 121$ , ...,  $u_8 = 145$ ; znak  $Y$ : rozsah naměřených hodnot je 95 až 119 mm, optimální délka jednoho třídicího intervalu  $h = 4$ , hranice třídicích intervalů:  $u_1 = 93$ ,  $u_2 = 97$ , ...,  $u_8 = 121$  mm; (b) kontingenční tabulka simultánních absolutních, resp. relativních četností viz tabulka 2.4, resp. tabulka 2.5; (c) histogram znaku  $X$ , resp. znaku  $Y$  viz obrázek 2.5; (d) stereogram a dvourozměrný tečkový diagram viz obrázek 2.6; (e) mezi znaky  $X$  a  $Y$  neexistuje četnostní nezávislost při daném dvourozměrném intervalovém rozložení četností (viz porovnání simultánních četnostních hustot  $f_{jk}$  (tabulka 2.6) se součiny marginálních četnostních hustot  $f_j.f_k$  (tabulka 2.7)).

Tabulka 2.4: Tabulka simultánních absolutních četností  $n_{jk}$  pro největší výšku mozkovny a morfologickou výšku tváře u žen

	(93; 97)	(97; 101)	(101; 105)	(105; 109)	(109; 113)	(113; 117)	(117; 121)
(117; 121)	0	1	0	0	1	0	0
(121; 125)	1	0	3	2	1	1	1
(125; 129)	0	1	8	4	6	2	1
(129; 133)	2	2	4	7	6	3	0
(133; 137)	0	2	1	3	6	0	3
(137; 141)	0	1	2	2	0	0	0
(141; 145)	0	0	0	0	0	0	1

Tabulka 2.5: Tabulka simultánních relativních četností  $p_{jk}$  pro největší výšku mozkovny a morfologickou výšku tváře u žen

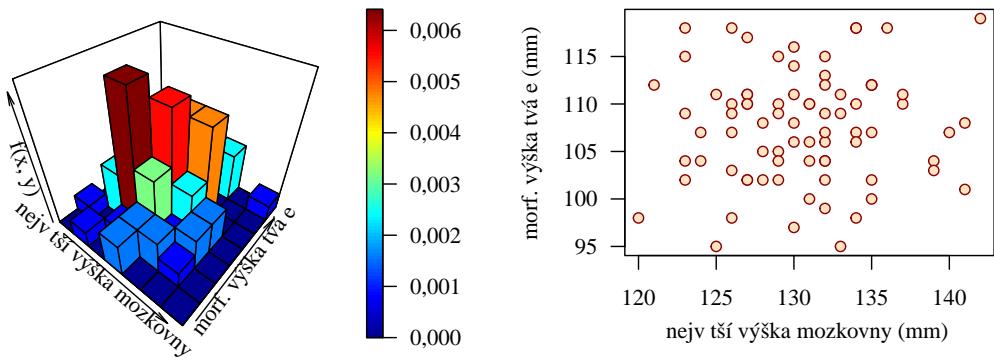
	(93; 97)	(97; 101)	(101; 105)	(105; 109)	(109; 113)	(113; 117)	(117; 121)
(117; 121)	0,0000	0,0128	0,0000	0,0000	0,0128	0,0000	0,0000
(121; 125)	0,0128	0,0000	0,0385	0,0256	0,0128	0,0128	0,0128
(125; 129)	0,0000	0,0128	0,1026	0,0513	0,0769	0,0256	0,0128
(129; 133)	0,0256	0,0256	0,0513	0,0897	0,0769	0,0385	0,0000
(133; 137)	0,0000	0,0256	0,0128	0,0385	0,0769	0,0000	0,0385
(137; 141)	0,0000	0,0128	0,0256	0,0256	0,0000	0,0000	0,0000
(141; 145)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0128



Obrázek 2.5: Histogram pro největší výšku mozkovny u žen (vlevo); histogram pro morfologickou výšku tváře u žen (vpravo)

Tabulka 2.6: Tabulka simultánních četnostních hustot  $f_{jk}$  pro největší výšku mozkovny a morfologickou výšku tváře u žen

	(93; 97)	(97; 101)	(101; 105)	(105; 109)	(109; 113)	(113; 117)	(117; 121)
(117; 121)	0,0000	0,0008	0,0000	0,0000	0,0008	0,0000	0,0000
(121; 125)	0,0008	0,0000	0,0024	0,0016	0,0008	0,0008	0,0008
(125; 129)	0,0000	0,0008	0,0064	0,0032	0,0048	0,0016	0,0008
(129; 133)	0,0016	0,0016	0,0032	0,0056	0,0048	0,0024	0,0000
(133; 137)	0,0000	0,0016	0,0008	0,0024	0,0048	0,0000	0,0024
(137; 141)	0,0000	0,0008	0,0016	0,0016	0,0000	0,0000	0,0000
(141; 145)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0008



Obrázek 2.6: Stereogram (vlevo); dvourozměrný tečkový diagram (vpravo) pro největší výšku mozkovny a morfologickou výšku tváře u žen

Tabulka 2.7: Tabulka součinů marginálních četnostních hustot  $f_{j..} f_{..k}$  pro největší výšku mozkovny a morfologickou výšku tváře u žen

	(93; 97)	(97; 101)	(101; 105)	(105; 109)	(109; 113)	(113; 117)	(117; 121)
(117; 121)	0,0001	0,0001	0,0004	0,0004	0,0004	0,0001	0,0001
(121; 125)	0,0003	0,0006	0,0017	0,0017	0,0018	0,0006	0,0006
(125; 129)	0,0007	0,0016	0,0041	0,0041	0,0045	0,0014	0,0014
(129; 133)	0,0007	0,0017	0,0044	0,0044	0,0049	0,0015	0,0015
(133; 137)	0,0005	0,0011	0,0028	0,0028	0,0031	0,0009	0,0009
(137; 141)	0,0002	0,0004	0,0009	0,0009	0,0010	0,0003	0,0003
(141; 145)	0,0000	0,0001	0,0002	0,0002	0,0002	0,0001	0,0001

★