

Aplikovaná statistika I

Téma 2: Bodové a intervalové rozložení četností

Veronika Bendová

bendova.veroonika@gmail.com

Úvod a motivace

- = pilotní analýza
- motivace: seznámení s daty, prvotní náhled na data, grafické znázornění
- různé typy dat → různé způsoby jejich reprezentace a vizualizace
 - kategoriální data
 - pohlaví, vzdělání, počet sourozenců, ...
 - spojitá data
 - výška (v cm), porodní hmotnost (v g), největší šířka/délka mozkovny (v mm), poměr obvodu pasu a boků (bez jednotky) ...
 - můžeme je kategorizovat
- jedna vlastnost / více vlastností najednou
- → jednorozměrné/vícerozměrné bodové/intervalové rozložení četností

Jednorozměrné bodové rozložení četností

Dataset: 17-anova-newborns-2.txt

Máme k dispozici údaje o porodní hmotnosti novorozenců z okresní nemocnice získané v období jednoho roku a současně máme k dispozici údaje o počtu starších biologických sourozenců novorozence, pohlaví novorozence a vzdělání matky (Alánová, 2008; soubor 17-anova-newborns-2.txt).

Popis proměnných v datasetu:

- edu.M – vzdělání matky (1 – základní, 2 – střední bez maturity, 3 – střední s maturitou, 4 – vysokoškolské);
- prch.N – počet biologických starších sourozenců (0–9);
- sex.C – pohlaví dítěte (m – muž, f – žena);
- weight.C – porodní hmotnost dítěte (g);
- weight.K – porodní hmotnost dítěte (1 = nízká (nižší než 2 500 g), 2 = norma (2 500 – 4 200 g), 3 = vysoká (větší než 4 200 g))

Příklad 2.1. Načtení datového souboru

Načtěte dataset 17-anova-newborns-2.txt do proměnné data a vypište prvních 5 řádků z načteného souboru. Zjistěte, zda soubor obsahuje neznámé (NA) hodnoty a pokud ano, tak je odstraňte. Potom zjistěte dimenzi datové tabulky.

Řešení příkladu 2.1

```
1 data <- read.delim('17-anova-newborns-2.txt', sep = '\t', dec = '.')
2 head(data, n = 5)
```

	edu.M	prch.N	sex.C	weight.C	weight.K
1	2	0	m	3470	2
2	2	0	m	3240	2
3	2	0	f	2980	2
4	1	0	m	3280	2
5	3	0	m	3030	2

3
4
5
6
7
8

Rozbor příkladu

- jedna porodnice, novorozenci; údaje o vzdělání matky, počtu starších sourozenců, pohlaví a porodní hmotnosti novorozence
- řádek . . . údaje o jednom novorozenci (**objekt**)
- sloupec . . . porodní hmotnost, vzdělání, pohlaví, počet st. sourozenců (**znaky**)
- znak
 - **konkrétní číslo**, které má samo o sobě výpovědní hodnotu (porodní hmotnost (v g))
 - **kódování** (0–žena, 1–muž); (1–ZŠ, 2–SŠ, 3–SŠm, 4–VŠ)

Ošetření NA hodnot a dimenze datové tabulky

```
9 sum(is.na(data)) # 30
10 data <- na.omit(data)
11 dim(data) # 1381 x 5
```

Načtená datová tabulka obsahuje údaje o znacích: vzdělání matky (edu.M), počet starších sourozenců novorozence (prch.N), pohlaví novorozence (sex.C), porodní hmotnost novorozence (weight.C) a kategoriální porodní hmotnost novorozence (weight.K). Datový soubor obsahuje celkem NA hodnot. Tabulka data má po odstranění NA hodnot celkem řádků a sloupců. V tabulce jsou tedy po odstranění NA hodnot uloženy údaje o **objektech**, přičemž u každého objektu máme záznamy o **znacích**.

Příklad 2.2. Úprava datového souboru

Upravte označení jednotlivých variant kategorického znaku *porodní hmotnost* tak, aby bylo na první pohled zřejmé, jakou hmotnost novorozenec má (1 = nizka, 2 = norma, 3 = vysoka). Analogicky upravte označení jednotlivých variant znaku *vzdělání matky* (1 – ZS, 2 – SS, 3 – SSm, 4 – VS).

Řešení příkladu 2.2

```
12 data$weight.K <- factor(data$weight.K, labels = c('nizka', 'norma', 'vysoka'))
13 data$edu.M <- factor(data$edu.M, labels = c('ZS', 'SS', 'SSm', 'VS'))
14 head(data, n = 5)
```

	edu.M	prch.N	sex.C	weight.C	weight.K
1	SS	0	m	3470	norma
2	SS	0	m	3240	norma
3	SS	0	f	2980	norma
4	ZS	0	m	3280	norma
5	SSm	0	m	3030	norma

15
16
17
18
19
20

Příklad 2.3. Variační řada

Vytvořte variační řadu znaku $X = \text{vzdělání matky}$ a variační řadu kategorického znaku $Y = \text{porodní hmotnost novorozence}$.

Řešení příkladu 2.3

Znaky *vzdělání* a *kateg. porodní hmotnost* ... kategoriální proměnné \rightarrow bodové rozložení četností

Variační řada ... tabulka obsahující pro každou (j -tou) variantu znaku X :

- absolutní četnost n_j
 - kolik matek má ZŠ vzdělání
- relativní četnost p_j
 - poměr matek se ZŠ vzděláním ku celkovému počtu matek
 - $p_j * 100$ - kolik % matek má ZŠ vzdělání?
- absolutní kumulativní četnost N_j
 - kolik matek má SŠm vzdělání nebo nižší
- relativní kumulativní četnost F_j
 - poměr matek se SŠm vzděláním nebo nižším ku celkovému počtu matek
 - $F_j * 100$ - kolik % matek má SŠm vzdělání nebo nižší?

Zaměřme se nejprve na znak $X = \text{vzdělání matky}$. Znak má celkem čtyři varianty:

.....,, a

..... . Variační řada je tabulka obsahující pro každou (j -tou) variantu

znaku X (a) absolutní četnost ; (b) relativní četnost; (c) absolutní kumulativní četnost; (d) relativní kumulativní četnost

```

21 edu <- data$edu.M
22 n1 <- sum(edu == 'ZS') # 417
23 n2 <- sum(edu == 'SS') # 448
24 n3 <- sum(edu == 'SSm') # 435
25 n4 <- sum(edu == 'VS') # 81
26 nj <- c(n1, n2, n3, n4)
27
28 nj <- as.numeric(table(edu))
29 n <- sum(nj)
30 pj <- nj / n
31 Nj <- cumsum(nj)
32 Fj <- cumsum(pj)

33 edu.name <- c('ZS', 'SS', 'SSm', 'VS')
34 edu.rada <- data.frame(nj, pj, Nj, Fj, row.names = edu.name)
35 round(edu.rada, digits = 4)

```

	nj	pj	Nj	Fj	
ZS	417	0.3020	417	0.3020	36
SS	448	0.3244	865	0.6264	37
SSm	435	0.3150	1300	0.9413	38
VS	81	0.0587	1381	1.0000	39
					40

Interpretace výsledků: Datový soubor obsahuje údaje o celkovém počtu novorozenců, přičemž v 417 případech (30.20 %) bylo nejvyšší dosažené vzdělání matky, v případech (..... %) bylo nejvyšší dosažené vzdělání matky středoškolské bez maturity, apod. Celkem (..... %) matek novorozenců v datovém souboru získalo středoškolské vzdělání bez maturity nebo nižší, celkem 1300 (94.13 %) matek novorozenců získalo nebo vzdělání.

Zaměříme se nyní na znak $Y = \text{porodní hmotnost novorozence}$. Protože variační řadu má smysl sestavovat pouze pro kategoriální / spojitý znak, použijeme k vytvoření variační řady proměnnou `weight.C` / `weight.K`. Znak Y má varianty: nízká porodní hmotnost, norma a vysoká porodní hmotnost.

```
41 source('Sbirka-AS-I-2018-funkce.R')
42 wei <- data$weight.K
43 wei.name <- c('nizka', 'norma', 'vysoka')
44 wei.rada <- variacni.rada(wei, row.names = wei.name)
45 round(wei.rada, digits = 4)
```

	nj	pj	Nj	Fj	
nizka	266	0.1926	266	0.1926	46
norma	1071	0.7755	1337	0.9681	47
vysoka	44	0.0319	1381	1.0000	48
					49

Interpretace výsledků: Porodní hmotnost novorozenců v datovém souboru se v případech (..... %) pohybovala v normě. Celkem novorozenců (..... %) mělo porodní hmotnost nižší nebo rovnu normě a novorozenců (..... %) mělo porodní hmotnost vysokou, v normě, nebo nižší.

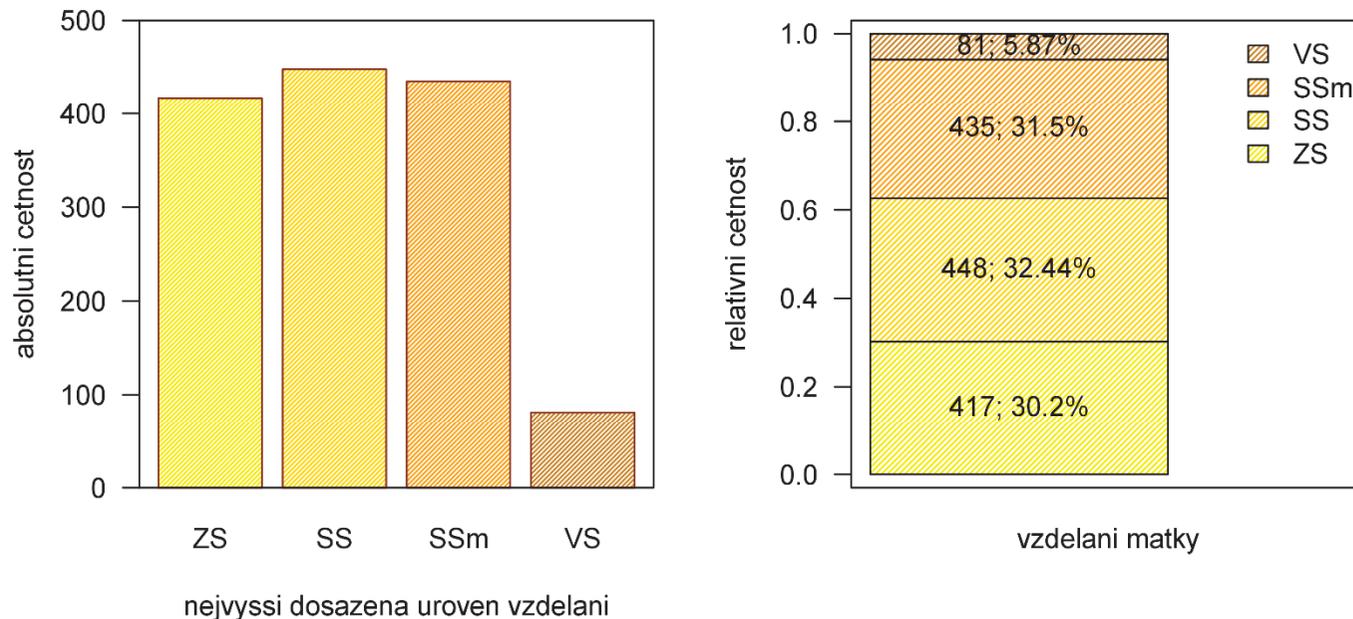
Příklad 2.4. Sloupcový diagram absolutních a relativních četností

Nakreslete sloupcový diagram absolutních četností a sloupcový diagram relativních četností pro znak $X = \text{vzdělání matky}$.

Řešení příkladu 2.4

```
50 barvy <- c('yellow', 'gold', 'orange', 'orange3')
51 par(mar = c(4, 4, 2, 2))
52 barplot(edu.rada$nj, ylim = c(0, 500), density = 50, col = barvy,
53         border = 'tomato4', xlab = 'nejvyssi dosazena uroven vzdelani',
54         ylab = 'absolutni cetnost', names = edu.name, las = 1)
55 box(bty = 'o')
```

```
56 rel.barplot(edu.rada$nj, xlim = c(0.2, 1.8), density = 40, col = barvy,
57            xlab = 'vzdelani matky', names = edu.name, axes = T)
58 box(bty = 'o')
```



Dvourozměrné bodové rozložení četností

Příklad 2.5. Kontingenční tabulka absolutních a relativních simultánních četností

Zaměřme se nyní na oba znaky $X = \text{vzdělání matky}$ a $Y = \text{kategorizovaná porodní hmotnost novorozence}$ najednou. Z předchozího textu víme, že znak X má čtyři varianty, znak Y má tři varianty. Celkem tedy můžeme získat $4 * 3 = 12$ různých kombinací variant znaků X a Y . Sestrojte kontingenční tabulku simultánních absolutních četností a kontingenční tabulku simultánních relativních četností znaků X a Y .

Řešení příkladu 2.5

- dva znaky X (r variant $x_{[1]}, \dots, x_{[r]}$) a Y (s variant $y_{[1]}, \dots, y_{[s]}$)
 - $\rightarrow r \times s$ kombinací variant znaků X a Y
- kontingenční tabulka absolutních četností

	$y_{[1]}$	\dots	$y_{[s]}$	suma
$x_{[1]}$	n_{11}	\dots	n_{1s}	$n_{1.}$
\vdots	\vdots	\vdots	\vdots	\vdots
$x_{[r]}$	n_{r1}	\dots	n_{rs}	$n_{r.}$
suma	$n_{.1}$	\dots	$n_{.s}$	n

- n_{jk} ... **simultánní absolutní četnost** dvojice znaků $x_{[j]}$ a $y_{[k]}$
- $n_{j.}$... **marginální absolutní četnost varianty** $x_{[j]}$
- $n_{.k}$... **marginální absolutní četnost varianty** $y_{[k]}$

KT relativních četností ... KT absolutních četností dělená celkovým počtem objektů n

V tomto příkladě 2.5 bude kontingenční tabulka absolutních četností velikosti $(4 + 1) \times (3 + 1) = 5 \times 4$, a to konkrétně ve tvaru

	nizka	norma	vysoka	suma
ZS	n_{11}	n_{12}	n_{13}	$n_{1.}$
SS	n_{21}	n_{22}	n_{23}	$n_{2.}$
SSm	n_{31}	n_{32}	n_{33}	$n_{3.}$
VS	n_{41}	n_{42}	n_{43}	$n_{4.}$
suma	$n_{.1}$	$n_{.2}$	$n_{.3}$	n

- n_{jk} je simultánní absolutní četnost j -té varianty znaku X a k -té varianty znaku Y
 - n_{11} ... počet novorozenců s nízkou porodní hmotností a matkou se ZŠ vzděláním
- $n_{j.}$ je marginální absolutní četnost j -té varianty znaku X
 - $n_{1.}$... počet novorozenců, jejichž matka má ZŠ vzdělání bez ohledu na jejich porodní hmotnost
- $n_{.k}$ je marginální absolutní četnost k -té varianty znaku Y
 - $n_{.1}$... počet novorozenců s nízkou porodní hmotností bez ohledu na vzdělání matky
- n je celkový počet objektů v datovém souboru

Kontingenční tabulka absolutních četností

```

59 n11 <- sum(edu == 'ZS' & wei == 'nizka') # 97
60 # (...)
61 n41 <- sum(edu == 'VS' & wei == 'vysoka') # 13
62
63 KT.abs <- table(edu, wei)
64 nj. <- apply(KT.abs, MARGIN = 1, FUN = sum)
65 KT.abs <- cbind(KT.abs, suma = nj.)
66 n.k <- apply(KT.abs, MARGIN = 2, FUN = sum)
67 KT.abs <- rbind(KT.abs, suma = n.k)

```

68 `KT.abs`

	nizka	norma	vysoka	suma
ZS	97	312	8	417
SS	82	346	20	448
SSm	74	349	12	435
VS	13	64	4	81
suma	266	1071	44	1381

69
70
71
72
73
74

Interpretace výsledků: V datovém souboru se vyskytuje celkem 97 novorozenců, kteří mají porodní hmotnost a jejichž matka má vzdělání, a novorozenců, jejichž porodní hmotnost je v normě a jejichž matka má středoškolské vzdělání s maturitou. Celkem 81 novorozenců se narodilo matkám s vzděláním.

Kontingenční tabulka relativních četností

75 `KT.rel <- KT.abs / n`
76 `round(KT.rel, digits = 4)`

	nizka	norma	vysoka	suma
ZS	0.0702	0.2259	0.0058	0.3020
SS	0.0594	0.2505	0.0145	0.3244
SSm	0.0536	0.2527	0.0087	0.3150
VS	0.0094	0.0463	0.0029	0.0587
suma	0.1926	0.7755	0.0319	1.0000

77
78
79
80
81
82

Interpretace výsledků: V datovém souboru se vyskytuje celkem 7.02 % novorozenců, kteří mají porodní hmotnost a jejichž matka má vzdělání. V datovém souboru se vyskytuje celkem% novorozenců, jejichž porodní hmotnost je v normě a jejichž matka má středoškolské vzdělání s maturitou. Celkem 3.19 % novorozenců v datovém souboru má porodní hmotnost.

Příklad 2.6. Kontingenční tabulka řádkově a sloupcově podmíněných relativních četností

Zaměřte se nyní opět na oba znaky $X = \text{vzdělání matky}$ a $Y = \text{kategorizovaná porodní hmotnost novorozence}$ najednou. Vytvořte kontingenční tabulku řádkově podmíněných relativních četností a kontingenční tabulku sloupcově podmíněných relativních četností.

Řešení příkladu 2.6

- $p_{k(j)}$... **řádkově podmíněná relativní četnost** varianty $y_{[k]}$ za předpokladu varianty $x_{[j]}$
 - $p_{k(j)} = \frac{n_{jk}}{n_{j.}}$
 - poměr novorozenců s nízkou porodní hmotností vzhledem k počtu novorozenců se ZŠ vzděláním matky
- $p_{j(k)}$... **sloupcově podmíněná relativní četnost** varianty $x_{[j]}$ za předpokladu varianty $y_{[k]}$
 - $p_{j(k)} = \frac{n_{jk}}{n_{.k}}$
 - poměr novorozenců se SS vzděláním matky vzhledem k počtu novorozenců s porodní hmotností v normě.

Kontingenční tabulka řádkově podmíněných relativních četností

```
83 KT.abs <- table(edu, wei)
84 RP.abs <- prop.table(KT.abs, margin = 1)
```

```
85 round(RP.abs, digits = 4)
```

	wei		
edu	nizka	norma	vysoka
ZS	0.2326	0.7482	0.0192
SS	0.1830	0.7723	0.0446
SSm	0.1701	0.8023	0.0276
VS	0.1605	0.7901	0.0494

86
87
88
89
90
91

Interpretace výsledků: Ze všech novorozenců v datovém souboru, jejichž matka má dokončené středoškolské vzdělání zakončené maturitou, má 17.01 % porodní hmotnost a 2.76 % porodní hmotnost. Ze všech novorozenců v datovém souboru, jejichž matka má dokončené vysokoškolské vzdělání, má % **nízkou** porodní hmotnost a % **vysokou** porodní hmotnost.

Kontingenční tabulka sloupcově podmíněných relativních četností

```
92 SP.abs <- prop.table(KT.abs, margin = 2)  
93 round(SP.abs, digits = 4)
```

	wei		
edu	nizka	norma	vysoka
ZS	0.3647	0.2913	0.1818
SS	0.3083	0.3231	0.4545
SSm	0.2782	0.3259	0.2727
VS	0.0489	0.0598	0.0909

94
95
96
97
98
99

Interpretace výsledků: Ze všech novorozenců v datovém souboru, jejichž porodní hmotnost byla nízká, se 36.47 % narodilo matkám s ukončeným vzděláním. Ze všech novorozenců v datovém souboru, jejichž porodní hmotnost byla v normě, se % se narodilo matkám s dokončeným středoškolským vzděláním bez maturity.

Jednorozměrné intervalové rozložení četností

Dataset: 01-one-sample-mean-skull-mf.txt

Z archivních materiálů (Schmidt, 1888; soubor 01-one-sample-mean-skull-mf.txt) máme k dispozici původní kranio-metrické údaje o délce a šířce mozkovny a ze starověké egyptské populace.

Popis proměnných v datasetu:

- id – pořadové číslo;
- pop – populace (egant – egyptská starověká);
- sex – pohlaví (m – muž, f – žena);
- skull.L – největší délka mozkovny (mm), t.j. přímá vzdálenost kranio-metrických bodů *glabella* a *opisthocranion*;
- skull.B – největší šířka mozkovny (mm), t.j. vzdálenost obou kranio-metrických bodů *euryon*.

Příklad 2.7. Načtení datového souboru

Načtěte dataset 01-one-sample-mean-skull-mf.txt a vypište první čtyři řádky z načteného souboru. Prozkoumejte, zda soubor obsahuje neznámé hodnoty a případně je ze souboru odstraňte. Potom zjistěte dimenzi datové tabulky.

Řešení příkladu 2.7

```
100 rm(list = ls())
101 data <- read.delim('01-one-sample-mean-skull-mf.txt')
102 head(data, n = 4)
```

	id	pop	sex	skull.L	skull.B
1	416	egant	m	188	145
2	417	egant	m	172	139
3	420	egant	m	176	138
4	421	egant	m	184	128

103
104
105
106
107

Rozbor příkladu

- skelety ze starověké egyptské populace; údaje o id, populaci (starověká egyptská), pohlaví, největší délce mozkovny (v mm), největší šířce mozkovny (v mm)

Ošetření NA hodnot a dimenze datové tabulky

```
108 sum(is.na(data)) # 5
109 data <- na.omit(data)
110 dim(data) # 325 x 5
```

V datovém souboru se vyskytuje celkem neznámých (NA) hodnot. Po odstranění NA pozorování nám zůstala datová tabulka o velikosti řádků a sloupců. Celkem tedy máme údaje o 325 přičemž pro každý objekt máme identifikační proměnnou id a údaje o znacích: populaci (pop), pohlaví skeletu (sex), největší délce mozkovny (skull.L) a největší šířce mozkovny (skull.B).

Příklad 2.8. Histogram a krabicový diagram

V následující analýze se zaměříme primárně na znak $X =$ *největší šířka mozkovny u skeletů mužského pohlaví*. Proveďte prvotní náhled na znak $X =$ *největší šířka mozkovky u mužů* pomocí (a) histogramu; (b) krabicového diagramu.

Řešení příkladu 2.8

```
111 skull.BM <- data[data$sex == 'm', 'skull.B']
112 n.M      <- length(skull.BM) # 216
113 range(skull.BM) # 124-149
```

Celkem máme údaje o největší šířce mozkovny u mužských skeletů. Hodnoty největší šířky mozkovny v datovém souboru se pohybují v rozmezí–..... mm.

Rozbor příkladu

- *největší šířka mozkovny u mužů* ... spojitá proměnná → intervalové rozložení četností
- spojitá data → třídíme je do stejně dlouhých *třídících intervalů* $(-\infty; u_1)$, $(u_1; u_2)$, ..., $(u_r; u_{r+1})$, $(u_{r+1}; \infty)$
- $(u_j; u_{j+1})$... j -tý třídící interval
- optimální počet intervalů ... Sturgesovo pravidlo $r \approx 1 + 3.3 \log_{10}(n)$ → optimální šířka jednoho intervalu → hranice třídících intervalů

Sturgesovo pravidlo

```
114 r <- round(1 + 3.3 * log10(n.M)) # 9
```

Podle Sturgersova pravidla je optimální počet třídících intervalů pro znak X = největší šířka mozkovny roven Minimální naměřená hodnota znaku X je mm, maximální hodnota je mm. Rozsah hodnot mezi minimální a maximální hodnotou je mm.

Optimální šířka třídícího intervalu pro znak X je mm. Vynásobíme-li počet třídících intervalů optimálním rozsahem jednoho intervalu, zjistíme, že rozsah třídících intervalů je $9 \times 3 = 27$. Rozsah hodnot 124–149 je však pouze 25. Proto dolní hranici prvního třídícího intervalu u_1 stanovíme jako 123, $u_2 = 126, \dots, u_9 = 150$.

Histogram a krabicový diagram

```
115 b      <- seq(123, 150, by = 3)
116 centr <- seq(124.5, 148.5, by = 3)
117
118 par(mar = c(4, 4, 1, 2))
119 hist(skull.BM, breaks = b, ylim = c(0, 52),
120      col = 'dodgerblue', border = 'slateblue4',
121      density = 40, xlab = 'nejvetsi sirka mozkovny (mm) - muzi',
122      ylab = 'absolutni cetnosti', main = '', axes = F)
123 box(bty = 'o')
124 axis(side = 1, centr)
125 axis(side = 2, las = 1)
```

```
126 boxplot(skull.BM, type = 2, horizontal = T,  
127         col = 'aliceblue', border = 'slateblue4', medcol = 'deepskyblue4',  
128         xlab = 'nejvetsi sirka mozkovny (mm) - muzi')
```

