

Aplikovaná statistika I

Téma 3: Základní číselné charakteristiky

Veronika Bendová

bendova.veroonika@gmail.com

Úvod a motivace

- minulá hodina → bodové/intervalové rozložení četnosti
 - seznámení s daty
 - výhody: široké množství informací, globální pohled na data
 - nevýhody: přemíra informací, horší interpretovatelnost, ztížené srovnávání dvou datasetů
 - Adam a Bára provádí nezávislý výzkum na stejné téma → dvě různé nemocnice → dva různé datasety (A) a (B) → dvě různé variační řady → porovnávání variačních řad (nepřehledné a neefektivní)
- → vznik *číselných charakteristik*
 - elegantní a jednoduché vystihnutí charakteristických rysů znaku zpravidla pomocí jednoho čísla
 - snadno spočítatelné i interpretovatelné
- různá data → různé charakteristiky
- typy dat
 - Nomiální,
 - Ordinální,
 - Intervalová,

- typy charakteristik
 - polohy
 - variability
 - závislosti
 - + nesymetrie (intervalové znaky)
- přehled číselných charakteristik podle typu znaku a sledované vlastnosti

	Poloha	Variabilita	Symetrie	Závislost
Nominální	modus	–	–	Cramérův koeficient
Ordinální	medián	interkvartilové rozpětí	–	Spearmanův koef. poř. korel.
Intervalový	aritmetický průměr	rozptyl směrodatná odchylka	koeficient šikmosti koeficient špičatosti	Pearsonův korel. koeficient

Nominální znaky

- varianty znaku jsou neporovnatelné
 - vzdělání: ZŠ, SŠ, SŠm, VŠ
 - barva očí: modrá, zelená, hnědá
 - pohlaví: m, f
- charakteristika polohy
 - *modus* . . . nejčetnější varianta znaku
- charakteristika závislosti
 - Cramérův koeficient r_C - těsnost závislosti u nominálních znaků
 - $r_C \in \langle 0; 1 \rangle$.
 - stupnice míry závislosti podle Cramérova koeficientu

Cramérův koeficient	Interpretace
0.0 – 0.1	zanedbatelný stupeň závislosti
0.1 – 0.3	slabý stupeň závislosti
0.3 – 0.7	střední stupeň závislosti
0.7 – 1.0	silný stupeň závislosti

Příklad 3.1. Charakteristika polohy nominálního znaku

Navážme na práci s datasetem 17-anova-newborns-2.txt. V rámci cvičení 2 jsme jako mezivýstup příkladu 2.5 získali kontingenční tabulku simultánních absolutních četností znaků $X = \text{vzdělání matky}$ a $Y = \text{porodní hmotnost novorozence}$ (viz tabulka 3.1). Znaky X a Y jsou typickým příkladem znaků nominálního typu. Najděte modus pro znak vzdělání matky i pro znak $\text{porodní hmotnost novorozence}$.

Tabulka 3.1: Simultánní absolutní četnosti pro znaky vzdělání matky a $\text{porodní hmotnost novorozence}$

	nízká	norma	vysoká
ZS	97	312	8
SS	82	346	20
SSm	74	349	12
VS	13	64	4

Řešení příkladu 3.1

```
1 (data <- data.frame(nizka = c(97, 82, 74, 13),
2                      norma  = c(312, 346, 349, 64),
3                      vysoka = c(8, 20, 12, 4),
4                      row.names = c('ZS', 'SS', 'SSm', 'VS')))
```

	nizka	norma	vysoka
ZS	97	312	8
SS	82	346	20
SSm	74	349	12
VS	13	64	4

5
6
7
8
9

Zaměřme se nejprve na znak $X = \text{vzdělání matky}$. Číselná charakteristika *modus* je definována jako nejčetnější varianta sledovaného znaku.

10 `(nj. <- apply(data, MARGIN = 1, FUN = sum))`

ZS	SS	SSm	VS
417	448	435	81

11

12

Interpretace výsledků: Nejčetnější variantou znaku *vzdělání matky* je
($n = \dots$). Nejvíce novorozenců v datovém souboru se narodilo matkám s dokončeným

Analogicky nyní najdeme modus znaku $Y = \text{porodní hmotnost novorozence}$.

13 `(n.k <- apply(data, MARGIN = 2, FUN = sum))`

nizka	norma	vysoka
266	1071	44

14

15

Interpretace výsledků: Nejvíce novorozenců v datovém souboru mělo porodní hmotnost
..... ($n = \dots$).

Příklad 3.2. Charakteristika závislosti mezi dvěma nominálními znaky

Zaměřte se nyní na oba znaky $X = \text{vzdělání}$ a $Y = \text{porodní hmotnost novorozence}$ najednou. Určete míru závislosti mezi znaky X a Y .

Řešení příkladu 3.2

Protože X a Y jsou znaky typu, použijeme na určení míry závislosti mezi nimi Stupnice míry závislosti podle hodnoty Cramérova koeficientu je uvedena v tabulce 3.2

Tabulka 3.2: Stunice míry závislosti podle Cramérova koeficientu

Cramérův koeficient	Interpretace
0.0 – 0.1	Zanedbatelný stupeň závislosti
0.1 – 0.3	Slabý stupeň závislosti
0.3 – 0.7	Střední stupeň závislosti
0.7 – 1.0	Silný stupeň závislosti

```
16 lsr::cramersV(data)
```

```
[1] 0.0645725
```




17

Interpretace výsledků: Hodnota Cramérova koeficientu vyšla Mezi vzděláním matky a porodní hmotností novorozence existuje stupeň

Ordinální znaky

- hodnoty znaku můžeme porovnávat, ale nemůžeme stanovit, jak velký je mezi nimi rozdíl
 - počet starších sourozenců, pořadí 10 pacientů podle závažnosti onemocnění, ...
- charakteristika polohy
 - α -kvantil x_α ... takové číslo, že $\alpha \times 100\%$ hodnot v datovém souboru je menších nebo rovných hodnotě x_α ; $\alpha \in \langle 0; 1 \rangle$
 - medián $x_{0.5}$
 - dolní kvartil $x_{0.25}$
 - horní kvartil $x_{0.75}$
 - $n\alpha =$ celé číslo $c \rightarrow x_\alpha = \frac{x_{(c)} + x_{(c+1)}}{2}$
 - $n\alpha =$ necelé číslo \rightarrow zaokrouhlíme nahoru na nejbližší vyšší celé číslo $c \rightarrow x_\alpha = x_{(c)}$
- charakteristika variability
 - (inter)kvartilové rozpětí IQR
 - $IQR = x_{0.75} - x_{0.25}$
 - v intervalu leží 50 % dat.
- charakteristika závislosti
 - dva znaky; aspoň jeden znak je ordinální: X – počet starších sourozenců (ord.), Y – porodní hmotnost novorozence (int.)
 - Spearmanův koeficient pořadové korelace r_s


- určuje míru pořadové závislosti mezi znaky X a Y
- $r_S \in \langle -1; 1 \rangle$
- $r_S > 0 \dots$ přímá závislost
- $r_S < 0 \dots$ nepřímá závislost
- $r_S = 0 \dots$ nezávislost



- stupnice míry závislosti podle Spearmanova koeficientu pořadové korelace

$ r_S $	Interpretace
0.0	pořadová nezávislost
0.0 – 0.1	velmi nízký stupeň závislosti
0.1 – 0.3	nízký stupeň závislosti
0.3 – 0.5	mírný stupeň závislosti
0.5 – 0.7	význačný stupeň závislosti
0.7 – 0.9	vysoký stupeň závislosti
0.9 – 1.0	velmi vysoký stupeň závislosti
1.0	úplná pořadová závislost

- grafická visualizace ordinálních dat
 - krabicový diagram



Příklad 3.3. Základní číselné charakteristiky pro ordinální znak

Načtěte datový soubor 17-anova-newborns-2.txt a odstraňte neznámé hodnoty. Zaměřte se pouze na novorozence ženského pohlaví s vysokou porodní hmotností. Zjistěte dimenzi datové tabulky obsahující údaje o těchto novorozencích a vytvořte tabulku základních číselných charakteristik pro znak $X = \text{počet starších sourozenců}$.

Řešení příkladu 3.3

```
18 data <- read.delim('17-anova-newborns-2.txt', sep = '\t')
19 head(data, n = 4)
```

	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

```
20
21
22
23
24
25 data <- na.omit(data)
26 data.FH <- data[data$sex == 'f' & data$weight.C > 4200, ]
27 dim(data.FH) # 14 x 5
```

Po odstranění neznámých hodnot obsahuje datová tabulka údaje o novorozencích ženského pohlaví s vysokou porodní hmotností, přičemž u každého z těchto novorozenců máme záznamy o znacích.

Znak $X = \text{počet starších sourozenců novorozence}$ je příkladem dat. V tabulce základních charakteristik budou obsaženy následující charakteristiky: minimální hodnota, dolní kvartil, medián, horní kvartil, maximální hodnota a interkvartilové rozpětí.

20
21
22
23
24

1. minimální hodnota $x_{min} = \dots$

```
28 prch <- data.FH$prch.N # 0 0 2 0 1 1 0 1 1 2 2 3 1 2  
29 prch.sort <- sort(prch) # 0 0 0 0 1 1 1 1 1 2 2 2 2 3  
30 min <- min(prch) # 0
```

2. dolní kvartil $x_{0.25}$

- $n = \dots$, $\alpha = \dots$
- $\alpha \times n = \dots \rightarrow$ je / není celé číslo
- $x_{0.25} = \dots$

```
31 n <- length(prch) # 14  
32 alpha <- 0.25  
33 alpha * n # 3.5 ... není cele cislo -> zaokrouhleni  
34 ceiling(alpha * n) # 4  
35 prch.sort[4] # 0  
36 x0.25 <- quantile(prch, probs = 0.25, type = 2) # 0
```

3. medián $x_{0.50}$

- $n = \dots$, $\alpha = \dots$
- $\alpha \times n = \dots \rightarrow$ je / není celé číslo
- $x_{0.50} = \dots$

```
37 alpha <- 0.5  
38 alpha * n # 7  
39 (prch.sort[7] + prch[8]) / 2 # 1  
40 x0.5 <- median(prch, type = 2) # 1  
41 x0.5 <- quantile(prch, probs = 0.50, type = 2) # 1
```

4. horní kvartil $x_{0.75}$

- $n = \dots$, $\alpha = \dots$
- $\alpha \times n = \dots \rightarrow$ je / není celé číslo
- $x_{0.75} = \dots$

```
42 alpha <- 0.75
43 alpha * n # 10.5
44 ceiling(alpha * n) # 11
45 prch.sort[11] # 2
46 x0.75 <- quantile(prch, probs = 0.75, type = 2) # 2
```

5. maximální hodnota $x_{max} = \dots$

```
47 max <- max(prch) # 3
```

6. interkvartilové rozpětí $IQR = x_{0.75} - x_{0.25} = \dots$

```
48 IQR <- x0.75 - x0.25 # 2
49 (tab <- data.frame(min = min, dolni.kv = x0.25, median = x0.5,
50                      horni.kv = x0.75, max = max, IQR = IQR))
```

	min	dolni.kv	median	horni.kv	max	IQR
25%	0	0	1	2	3	2

51
52

Interpretace výsledků: Počet starších sourozenců u novorozenců ženského pohlaví s vysokou porodní hmotností se pohyboval v rozmezí – Dolní kvartil počtu starších sourozenců nabývá hodnoty, tj. % novorozenců ženského pohlaví s vysokou porodní hmotností má starších sourozenců. Medián počtu starších sourozenců nabývá hodnoty, tj. % novorozenců ženského pohlaví s vysokou porodní hmotností má nebo starších sourozenců.


Horní kvartil počtu starších sourozenců nabývá hodnoty , tj. % novorozenců ženského pohlaví s vysokou porodní hmotností má , nebo starších sourozenců. Hodnota interkvartilového rozpětí je rovna

Příklad 3.4. Krabicový diagram

Sestrojte krabicový diagram pro znak $X = \text{počet starších sourozenců}$ pro novorozence ženského pohlaví s vysokou porodní hmotností. Zaměřte se na vzhled krabicového diagramu a zamyslete se nad tím, kde je v krabicovém diagramu zobrazen medián, dolní kvartil, horní kvartil a mezikvartilové rozpětí.

Řešení příkladu 3.4

```
53 par(mar = c(2, 3, 1, 1))
54 boxplot(prch, type = 2, horizontal = F, las = 1, col = 'darkolivegreen1',
55       border = 'chartreuse4', medcol = 'darkgreen', xlab = '')
56 mtext('pocet starsich sourozencu', side = 1, line = 1)
```



Příklad 3.5. Charakteristika závislosti mezi ordinálními znaky

Zaměřme se nyní na oba znaky $X = \text{počet starších sourozenců}$ a $Y = \text{porodní hmotnost novorozence}$ najednou. Určete míru závislosti mezi znaky X a Y u novorozeneců ženského pohlaví.

Řešení příkladu 3.5

Znak X je typu, zatímco znak Y je typu → ke znaku Y budeme přistupovat jako ke znaku typu. Ke stanovení míry závislosti použijeme koeficient korelace.

Tabulka 3.3: Stupnice míry závislosti podle Spearmanova koeficientu pořadové korelace

r_s	Interpretace
0.0	pořadová nezávislost
0.0 – 0.1	velmi nízký stupeň závislosti
0.1 – 0.3	nízký stupeň závislosti
0.3 – 0.5	mírný stupeň závislosti
0.5 – 0.7	význačný stupeň závislosti
0.7 – 0.9	vysoký stupeň závislosti
0.9 – 1.0	velmi vysoký stupeň závislosti
1.0	úplná pořadová závislost

```
57 data.F <- data[data$sex == 'f', ]  
58 prch.F <- data.F$prch.N  
59 wei.F <- data.F$weight.C  
60 cor(prch.F, wei.F, method = 'spearman')
```

```
[1] 0.05918883
```

61

Interpretace výsledku: Hodnota Spearmanova koeficientu pořadové korelace vyšla Mezi počtem starších sourozenců a porodní hmotností novorozence ženského pohlaví existuje stupeň závislosti.


Intervalové znaky

- hodnoty znaků můžeme nejen vzájemně porovnat, ale můžeme též říci, o kolik se liší
 - porodní hmotnost novorozence (v g), největší šířka mozkovny (v mm), BMI (v kg/m²)
- charakteristiky polohy
 - aritmetický průměr m
 - $m = \frac{1}{n} \sum_{i=1}^n x_i$
 - ovlivněn vybočujícími hodnotami → vhodný, máme-li symetrická data
 - α -kvantily x_α
 - medián $x_{0.5}$, dolní kvartil $x_{0.25}$, horní kvartil $x_{0.75}$, ...
 - nejsou ovlivněny vybočujícími hodnotami → vhodné, máme-li nesymetrická data
- charakteristiky variability
 - rozptyl s^2
 - $s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2$
 - průměrná kvadratická odchylka hodnot od jejich aritmetického průměru.
 - $s^2 \geq 0$
 - ovlivněn vybočujícími hodnotami → vhodný, máme-li symetrická data
 - rozptyl $s^2 \rightarrow$ jednotky $\wedge 2$
 - směrodatná odchylka s
 - $s = \sqrt{s^2}$
 - převádí rozptyl do původních jednotek
 - interkvartilové rozpětí IQR

- charakteristiky nesymetrie


- šikmost α_3

- $\alpha_3 = 0 \rightarrow$ symetrické rozdělení dat
 - $\alpha_3 < 0 \rightarrow$ záporně zešikmené \rightarrow prodloužený levý konec
 - $\alpha_3 > 0 \rightarrow$ kladně zešikmené \rightarrow prodloužený pravý konec



- špičatost α_4

- $\alpha_4 = 0 \rightarrow$ normální rozdělení dat
 - $\alpha_4 > 0 \rightarrow$ strmé rozdělení dat
 - $\alpha_4 < 0 \rightarrow$ ploché rozdělení dat (Říp)



- charakteristika těsnosti závislosti

- dva znaky X a Y , oba intervalového typu
- Pearsonův korelační koeficient r_{12}
 - určuje míru **lineární závislosti** mezi znaky X a Y
 - $$r_{12} = \frac{1}{n} \sum_{i=1}^n \frac{x_i - m_1}{s_1} \frac{y_i - m_2}{s_2}$$
 - $r_{12} \in \langle -1; 1 \rangle$
 - $r_{12} > 0 \dots$ přímá závislost
 - $r_{12} < 0 \dots$ nepřímá závislost
 - $r_{12} = 0 \dots$ nezávislost

- stupnice míry závislosti podle Pearsonova korelačního koeficientu

$ r_{12} $	Interpretace
0.0	lineární nezávislost
0.0 – 0.1	velmi nízký stupeň závislosti
0.1 – 0.3	nízký stupeň závislosti
0.3 – 0.5	mírný stupeň závislosti
0.5 – 0.7	význačný stupeň závislosti
0.7 – 0.9	vysoký stupeň závislosti
0.9 – 1.0	velmi vysoký stupeň závislosti
1.0	úplná lineární závislost

Příklad 3.6. Základní číselné charakteristiky pro intervalový znak

Načtěte datový soubor 01-one-sample-mean-skull-mf.txt a odstraňte z načtených dat NA hodnoty.

Zaměřte se pouze na znak $X = \text{největší šířka mozkovny}$ pro skelety mužského pohlaví. Vytvořte tabulku základních číselných charakteristik pro znak X .

Řešení příkladu 3.6

```
62 data <- read.delim('01-one-sample-mean-skull-mf.txt')  
63 head(data, n = 3)
```

	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

64
65
66
67

```
68 data <- na.omit(data)  
69 skull.BM <- data[data$sex == 'm', 'skull.B']
```

Po odstranění neznámých hodnot obsahuje datová tabulka údaje o skeletech mužského pohlaví.

Znak $X = \text{největší šířka mozkovny}$ pro skelety mužského pohlaví je příkladem dat. V tabulce základních číselných charakteristik budou obsaženy následující charakteristiky: aritmetický průměr, směrodatná odchylka, minimální hodnota, dolní kvartil, medián, horní kvartil, maximální hodnota, interkvartilové rozpětí, koeficient šikmosti a koeficient špičatosti.

1. aritmetický průměr m

$$\bullet m = \frac{1}{n} \sum_{i=1}^n x_i =$$

```
70 n <- length(skull.BM) # 216  
71 m <- 1 / n * sum(skull.BM) # 137.1852  
72 m <- mean(skull.BM) # 137.1852
```

2. rozptyl s^2

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

```
73 s2 <- 1 / n * sum((skull.BM - m) ^ 2) # 23.16941
```

3. směrodatná odchylka s

- $s = \sqrt{s^2} =$

```
74 s <- sqrt(s2) # 4.813461
```

4. minimální hodnota $x_{min} = \dots$

```
75 skull.BM.sort <- sort(skull.BM) # 124, 127, 127, ..., 148, 149, 149  
76 min <- min(skull.BM) # 124
```

5. dolní kvartil $x_{0.25}$

- $n = \dots, \alpha = \dots$

- $\alpha \times n = \dots \rightarrow$ je / není celé číslo

- $x_{0.25} =$

```
77 alpha <- 0.25  
78 n * alpha # 54  
79 (skull.BM.sort[54] + skull.BM.sort[55]) / 2 # 134  
80 x0.25 <- quantile(skull.BM, probs = 0.25, type = 2) # 134
```

6. medián $x_{0.50}$

- $n = \dots$, $\alpha = \dots$
- $\alpha \times n = \dots \rightarrow$ je / není celé číslo
- $x_{0.50} =$

```
81 alpha <- 0.5
82 n * alpha # 108
83 (skull.BM.sort[108] + skull.BM.sort[109]) / 2 # 137
84 x0.50 <- quantile(skull.BM, probs = 0.50, type = 2) # 137
```

7. horní kvartil $x_{0.75}$

- $n = \dots$, $\alpha = \dots$
- $\alpha \times n = \dots \rightarrow$ je / není celé číslo
- $x_{0.75} =$

```
85 alpha <- 0.75
86 n * alpha # 162
87 (skull.BM.sort[162] + skull.BM.sort[163]) / 2 # 140
88 x0.75 <- quantile(skull.BM, probs = 0.75, type = 2) # 140
```

8. maximální hodnota $x_{max} = \dots$

```
89 max <- max(skull.BM) # 149
```

9. interkvartilové rozpětí $IQR = x_{0.75} - x_{0.25} = \dots$

```
90 IQR <- x0.75 - x0.25
```

6. koeficient šikmosti b_1

- $b_1 = \dots$

```
91 sikmost <- e1071::skewness(skull.BM, type = 3) # 0.08410943
```

7. koeficient špičatosti b_2

- $b_2 = \dots$

```
92 spicatost <- e1071::kurtosis(skull.BM, type = 3) # -0.2956831
93 tab <- data.frame(m, s, min, dolni.kv = x0.25, median = x0.50,
94                      horni.kv = x0.75, max, IQR, sikmost, spicatost,
95                      row.names = c('muzi'))
96 (tab <- round(tab, digits = 2))
```

	m	s	min	dolni.kv	median	horni.kv	max	IQR	sikmost	spicatost	
muzi	137.19	4.81	124		134	137	140	149	6	0.08	-0.3

97

98

Interpretace výsledků: Naměřené hodnoty největší šířky mozkovny pro skelety mužského pohlaví se pohybují v rozmezí – mm. Průměrná hodnota největší šířky mozkovny je mm se směrodatnou odchylkou mm. 25% naměřených hodnot je menších nebo rovných mm, 50% naměřených hodnot je menších nebo rovných mm, 75% naměřených hodnot je menších nebo rovných mm. Interkvartilové rozpětí naměřených hodnot je rovno mm. Hodnota koeficientu šikmosti,, ukazuje na zešikmená data (prodloužený konec). Hodnota koeficientu špičatosti,, ukazuje na charakter dat.

Příklad 3.7. Charakteristika závislosti pro znaky intervalového typu

Zaměřme se nyní na znaky $X = \text{největší šířka mozkovny}$ a $Y = \text{největší délka mozkovny}$ pro skelety mužského pohlaví najednou. Určete míru závislosti mezi znaky X a Y .

Řešení příkladu 3.7

Oba znaky X a Y jsou typu. Ke stanovení míry závislosti použijeme korelační koeficient.

Tabulka 3.4: Stupnice míry závislosti podle Pearsonova korelačního koeficientu

$ r_{12} $	Interpretace
0.0	lineární nezávislost
0.0 – 0.1	velmi nízký stupeň závislosti
0.1 – 0.3	nízký stupeň závislosti
0.3 – 0.5	mírný stupeň závislosti
0.5 – 0.7	význačný stupeň závislosti
0.7 – 0.9	vysoký stupeň závislosti
0.9 – 1.0	velmi vysoký stupeň závislosti
1.0	úplná lineární závislost

```
99 skull.BM <- data[data$sex == 'm', 'skull.B']  
100 skull.LM <- data[data$sex == 'm', 'skull.L']  
101 cor(skull.BM, skull.LM, method = 'pearson')
```

```
[1] 0.168157
```

102

Interpretace výsledků: Pearsonův korelační koeficient nabývá hodnoty Mezi největší šírkou mozkovny a největší délkou mozkovny pro skelety mužského pohlaví existuje stupeň závislosti.

Příklad 3.8. Dvouozměrný tečkový diagram

Pro znaky $X = \text{největší šířka mozkovny}$ a $Y = \text{největší délka mozkovny u mužů}$ vykreslete dvouozměrný tečkový diagram.

Řešení příkladu 3.8

```
103 par(mar = c(3, 4, 2, 2))
104 plot(skull.BM, skull.LM, pch = 21, bg = 'mintcream', col = 'darkblue',
105       xlab = '', ylab = 'nejvetsi delka mozkovny (mm)', main = '', las = 1)
106 mtext('nejvetsi sirka mozkovny (mm)', side = 1, line = 2.1)
```

