

## 2 Výpočet číselných charakteristik - OSNOVA

- Minulá hodina → bodové/intervalové rozložení četností.
  - důvod: pilotní analýza; seznámení s daty
- Nová látka: Motivace
  - Karolína s Janou se domluví na výzkumu. Půjdou na dvě různé školy → 20 žáků → u každého zjistí známku z matiky a anginy → výsledky roztrídí do variační tabulky → 2 variační řady → porovnávání absolutních četností pro každou dvojici známek? ... nepřehledné a neefektivní.
- Potřebujeme jednodušší charakteristiky, které nám řeknou o datech ty nejdůležitější informace a budou dostatečně jednoduché na to, aby se dali snadno vypočítat a interpretovat.
- Různá data → různé charakteristiky:
- Typy dat:
  - Nomiální
  - Ordinální
  - Intervalová
- Tři základní typy charakteristik:
  - polohy
  - variability
  - závislosti
  - + nesymetrie (intervalové znaky)

### Nominální znaky

**Příklad 2.1.** Ve vzorku, který tvořilo 200 studentů (100 mužů a 100 žen) byly snímány dematoglyfy dlaně (Býmová, 1990). Na otiscích bylo hodnoceno zakončení tří hlavních dlaňových linií. Podle vzorce zakončení byly jednotliví studenti rozdeleni do tří kategorií: vysoká (Hi), střední (Mi) a nízká (Lo). Současně byla zhodnocena barva vlasů studentů podle standardní Fisher-Sallerové stupnice (Martin a Saller, 1957–1966, s. 391), na základě které byli studenti rozdeleni do tří skupin: Světlá (LoH), střední (MH) a tmavá (DaH). K dispozici máme početnosti jedinců v jednotlivých kategoriích, zvlášť pro muže a zvlášť pro ženy.

A) Početnosti v jednotlivých kategoriích pro muže

	Hi	Mi	Lo
LiH	6	6	4
MH	20	15	7
DaH	18	12	12

1. Určete modus zakončení dlaňových linií a modus barvy vlasů pro muže.
2. Pomocí Cramérova koeficientu stanovte stupeň závislosti mezi zakončením dlaňových linií a barvy vlasů u mužů.

- = jednotlivé varianty znaku jsou neporovnatelné:

- zvíře u veterináře: kočka, pes, ara, želva
- oblast výzkumu: dolní věstonice, pohansko, klášterec
- barva očí: modrá, zelená, hnědá

- Charakteristika polohy

- varianty jsou navzájem neporovnatelné → můžeme vybrat pouze nejčetnější variantu ... *modus*.

```
data <- data.frame(vysoke=c(6,20,18),
                     stredni=c(6,15,12),
                     nizke=c(4,7,12),
                     row.names=c('svetle', 'stredni', 'tmave'))
apply(data, 2, sum)
apply(data, 1, sum)
```

- Charakteristika závislosti

- Cramérův koeficient  $r_C$  - slouží k určení těsnosti závislosti u nominálních veličin
- $r_C \in \langle 0; 1 \rangle$ .

```
library(lsr)
round(cramersV(data), digits=3)
[1] 0.101
```

## Ordinální znaky

**Příklad 2.2.** Otevřeme datový soubor `znamky_me.txt`.

- Pro známky z **angličtiny** a matematiky vypočtěte medián, dolní a horní kvartil, kvartilovou odchylku a vytvoříme krabicový diagram.
- Vypočtěte **Spearmanův korelační koeficient** známk z angličtiny a matematiky pro všechny studenty.

- Hodnoty můžeme porovnávat, ale nemůžeme říci, jaký je mezi nimi rozdíl.
  - 10 pacientů ... pořadí podle závažnosti onemocnění
  - Známky studentů - výborně, chvalitebně, dobré, dostatečně a nedostatečně. Mezi výborně a chvalitebně je jiný rozdíl než mezi dostatečně a nedostatečně.
- Charakteristika polohy
  - $\alpha$ -kvantil ...  $x_\alpha$

- \* 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 celé číslo  $c \rightarrow x_\alpha = x_{(c)}$

- Charakteristika variability:

- kvartilové rozpětí
- $q = x_{0.75} - x_{0.25}$
- v intervalu leží 50 % dat.

```
data <- read.delim('znamky_me.txt', sep='\t', dec='.', header=T)
source('AS-funkce.R')

matematika <- data$math
anglictina <- data$english
pohlavi <- data$sex


qA <- quantile(anglictina, probs=c(0.5, 0.25, 0.75), type=2) # type=5
iqrA <- qA[3] - qA[2]

(tabA<-data.frame(median=qA[1], kv1=qA[2], kv3=qA[3],
IQR=iqrA, row.names='anglictina'))

boxplot(matematika, anglictina, main='Krabicovy graf',
names=c('matematika', 'anglictina'), ylab='znamka', ylim=c(0,5),
border='darkgreen', col='darkolivegreen1')
```

- Charakteristika závislosti:

- Spearmanův koeficient pořadové korelace  $r_S$
- máme dva znaky:  $X$  - známka z matematiky,  $Y$  známka z angličtiny
- existuje mezi znaky  $X$  a  $Y$  závislost a když, jak silná?
- $r_S \in \langle -1; 1 \rangle$ .
  - \*  $r_S > 0 \dots$  přímá závislost
  - \*  $r_S < 0 \dots$  nepřímá závislost
  - \*  $r_S = 0 \dots$  nezávislost



```
cor(matematika, anglictina, method='spearman')
```

- Nakreslete tečkový graf

```
dotplot(matematika, anglictina,
        main='Teckovy graf', xlab='matematika', ylab='anglictina',
        col='darkgreen', bg='darkolivegreen1', xlim=c(1,4), ylim=c(1,4))
abline(v=seq(1,4,by=0.5), col='grey80', lty=2)
abline(h=seq(1,4,by=0.5), col='grey80', lty=2)
```

**Příklad 2.3.** Vypočítejte medián, dolní a horní kvartil, kvartilovou odchylku a vytvořte krabicový diagram pro známky z angličtiny, když víte, že absolutní četnosti známek byly

známka	1	2	3	4
absolutní četnost	4	4	7	5

```
anglictina <- c(1,1,1,1,2,2,2,2,3,3,3,3,3,3,3,4,4,4,4,4,4)
q.A <- quantile(anglictina, probs=c(0.5,0.25,0.75), type=2) #type=5
iqrA <- qA[3]-qA[2]

(tabA<-data.frame(median=qA[1], kv1=qA[2], kv3=qA[3],
IQR=iqrA, row.names='anglictina'))
```

## Intervalové znaky

**Příklad 2.4.** Otevřeme datový soubor lebky.txt.

- Pro největší délku a největší šířku mozkovny mužů vypočteme aritmetický průměr, rozptyl, směrodatnou odchylku, koeficient variace, šíkmost a špičatost.
- Vypočítejte Pearsonův koeficient korelace největší délky a největší šířky mozkovny mužů. Nakreslete dvourozměrný tečkový diagram.

- Hodnoty znaků můžeme nejen vzájemně porovnat, ale můžeme též říci, o kolik se liší:
- Výška/váha dětí, hodnota glukózy v krvi, množství vyplaveného testosteronu, šířka lebky mužů/žen/neandrtálců, ...
- Charakteristika polohy:
  - aritmetický průměr:  $m = \frac{1}{n} \sum_{i=1}^n x_i$
  - ovlivněn vybočujícími hodnotami → vhodný máme-li symetrická data
- Charakteristika polohy:
  1. rozptyl:
    - $s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2$
    - průměrná kvadratická odchylka hodnot od jejich aritmetického průměru.
    - $s^2 \geq 0$

- ovlivněn vybočujícími hodnotami → je vhodný, máme-li symetrická data
- oproti jednotkám původních dat je rozptyl v jednotkách  $\wedge 2$ .



## 2. směrodatná odchylka

- $s = \sqrt{s^2}$
- převádí rozptyl do původních jednotek

- Charakteristika nesymetrie:


### 1. šikmost $\alpha_3$

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



### 2. špičatost $\alpha_4$

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



```

library(e1071)
data      <- read.delim('lebky.txt', sep='\t', dec='.', header=F)
names(data) <- c('delka', 'sirka', 'pohlavi')
#head(data)
delka.M   <- data$delka[data$pohlavi=='muz']
n         <- length(delka.M)

mean.D     <- mean(delka.M)
s2.D       <- 1/n*sum((delka.M-mean.D)^2)
s.D        <- sqrt(s2.D)
koef.var.D <- s.D/mean.D*100
sikmost.D  <- skewness(delka.M, type=2)
spicatost.D <- kurtosis(delka.M, type=2)
tab.D      <- round(data.frame(n=n, prumer=mean.D, rozptyl=s2.D, sm.odch=s.
D, koef.var=koef.var.D, sikmost=sikmost.D, spicatost=spicatost.D), digits
=4)

```

- Charakteristika těsnosti závislosti:

- máme dva intervalové znaky – existuje mezi nimi nějaká závislost a když, tak jak silná?

1. Pearsonův koeficient korelace

- \*  $r_{12} = \frac{1}{n} \sum_{i=1}^n \frac{x_i - m_1}{s_1} \frac{y_i - m_2}{s_2}$
- \* nabývá hodnot mezi -1 a 1
- \*  $r_{12} > 0$  ... přímá závislost
- \*  $r_{12} < 0$  ... nepřímá závislost
- \*  $r_{12} = 0$  ... nezávislost

2. kovariance

$$* s_{12} = \frac{1}{n} \sum_{i=1}^n (x_i - m_1)(y_i - m_2)$$

```

cor(delka.M, sirka.M, method='pearson')

plot(delka.M, sirka.M, main='Teckovy graf', pch=21,
      xlab='delka_lebky', ylab='sirka_lebky', col='darkgreen', bg=
      darkolivegreen1)
abline(v=seq(160,200,by=5), col='grey80', lty=2)
abline(h=seq(120,145,by=5), col='grey80', lty=2)

```