

2 Výpočet číselných charakteristik - OSNOVA

- Minulá hodina → bodové/intervalové rozložení četností.
 - důvod: pilotní analýza; seznámení s daty
- Nová látka: Motivace
 - Karolína s Markétou 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)

Nomiální znaky

Příklad 2.1. U 100 náhodně vybraných domácností byl zjištován způsob zásobování bramborami (znak X, varianty 1 = vlastní sklep, 2 = jinde, 3 = nákup) a bydliště (znak Y, varianty 1 = velké město, 2 = malé město, 3 = vesnice).

- = jednotlivé varianty znaku jsou neporovnatelné:
 - zvíře u veterináře: kočka, pes, papoušek, 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(velke.mesto=c(13,11,19), male.mesto=c(15,7,9),
                     vesnice=c(14,2,10),
                     row.names=c('sklep','jinde','nakup')))

apply(data,1,sum)
apply(data,2,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] 0.179

```

Ordinální znaky

Příklad 2.2. Otevřeme datový soubor **znamky.txt**.

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

- Získaná data 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
 - α -kvantil ... x_α
 - * 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.txt', sep='\t', dec='.', header=F)
source('AS-funkce.R')
head(data)
names(data) <- c('matematika', 'anglictina', 'pohlavi')
f3      <- factor(data$pohlavi, levels=c(0,1), labels=c('zena', 'muz'))
data[,3] <- f3
head(data)

matematika <- data$matematika
anglictina <- data$anglictina
pohlavi    <- data$pohlavi

q.M <- quantile(matematika, probs=c(0.5, 0.25, 0.75), type=2) #type=5
iqr.M <- q.M[3]-q.M[2]

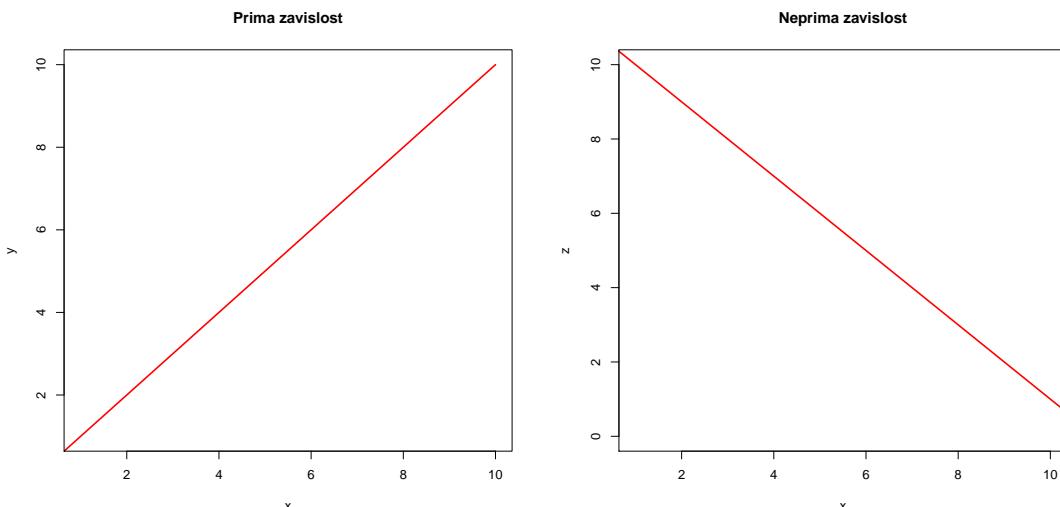
(tabulka<-data.frame(median=q.M[1], kv1=q.M[2], kv3=q.M[3],
                      IQR=iqr.M, row.names='matematika'))

boxplot(matematika, anglictina, main='Krabicovy ugraf u dvou u promennych',
         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?
- $r_S \in \langle -1; 1 \rangle$.
 - * $r_S > 0$... přímá závislost (s rostoucí hodnotou znaku X roste i hodnota znaku Y)
 - * $r_S < 0$... nepřímá závislost (s rostoucí hodnotou znaku X hodnota znaku Y klesá)
 - * $r_S = 0$... nezávislost



```

cor(matematika, anglictina, method='spearman')
cor(matematika[pohlavi=='zena'], anglictina[pohlavi=='zena'], method='spearman')

```

- Nakreslete tečkový graf

```
dotplot(matematika[pohlavi=='zena'], anglictina[pohlavi=='zena'],
        main='Teckovy graf znamek - Zeny', 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)
```

Intervalové znaky

Příklad 2.3. Otevřeme datový soubor lebky.txt.

- Pro největší délku a největší šířku mozkovny mužů vypočteme aritmetický průměr, rozptyl, směrodatnou odchylku, koeficient variace, šikmost a špičatost.
- Vypočítejte Pearsonův koeficient korelace největší délky a největší šířky mozkovny mužů. Dále vypočtěte kovarianci těchto dvou znaků a nakreslete dvourozměrný tečkový diagram.

- Hodnoty znaků můžeme nejen vzájemně porovnat, ale můžeme též říci, o kolik se liší:
- Výška/váha dětí, věk pacienta, hodnota glukózy v krvi, množství vyplaveného testosteronu, šířka lebky mužů/žen/neandrtálců, ...
- Charakteristika polohy:
 - aritmetický průměr: $m = \frac{1}{n} \sum_{i=1}^n x_i$
 - součet podprůměrných hodnot je stejný, jako součet nadprůměrných hodnot
 - silně 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.
 - $s^2 \geq 0$
 - je ovlivněn vybočujícími hodnotami → je vhodný, máme-li symetrická data
 - oproti jednotkám původních dat tato data jsou v jednotkách na druhou.
 2. směrodatná odchylka
 - $s = \sqrt{s^2}$
 - převádí rozptyl do původních jednotek
- Charakteristika nesymetrie:
 1. šikmost α_3
 - $\alpha_3 = 0 \rightarrow$ rozložení dat je symetrické
 - $\alpha_3 < 0 \rightarrow$ záporně zešikmené rozložení → prosloužený levý
 - $\alpha_3 > 0 \rightarrow$ kladně zešikmené rozložení → prosloužený pravý konec

2. špičatost α_4

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

```
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)

prumer.D    <- mean(delka.M)
rozptyl.D   <- 1/n*sum((delka.M-prumer.D)^2)
sm.odch.D   <- sqrt(rozptyl.D)
koef.var.D  <- sm.odch.D/mean(delka.M)*100
sikmost.D   <- skewness(delka.M, type=2)
spicatost.D <- kurtosis(delka.M, type=2)
(tab.D       <- round(data.frame(n=n, prumer=prumer.D, rozptyl=rozptyl.D, sm.
odch=sm.odch.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
- * $r_{12} > 0 \dots$ přímá závislost
- * $r_{12} < 0 \dots$ nepřímá závislost
- * $r_{12} = 0 \dots$ 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')
```

```
kovariance <- sum((delka.M-prumer.D)*(sirka.M-prumer.S))/n
round(kovariance, 4)
```

```
plot(delka.M, sirka.M, main='Teckovy graf delky a sirky lebky muzu', 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)
```