

1 1 - Bodové a intervalové rozložení četností - OSNOVA

Úvod

- jde o tzv. pilotní analýzu
- Motivace: Někdo nám poskytne data → chceme se s nimi seznámit, pochopit jejich podstatu, nějak si je graficky znázornit a získat nad nimi nadhled
- podle typu dat volíme různé způsoby reprezentace a vizualizace dat (jiné grafy používáme pro diskrétní data (známky, pohlaví, typ pracího prášku, apod.) a jiné pro spojité data (výška a váha člověka, krevní tlak, přesný věk pacienta, apod.)
- záleží také, zda zkoumáme pouze jednu vlastnost, nebo více vlastností na jednou
- Podle toho, jaká data máme, používáme buď jednorozměrné/vícerozměrné bodové nebo intervalové rozdělení četností

Jednorozměrné bodové rozdělení četnosti

Příklad 1.1. Načtěte soubor `znamky.txt`. Znakům X, Y, Z vytvořte návěští (X - známka z matematiky, Y - známka z angličtiny, Z - pohlaví studenta). Popište, co znamenají jednotlivé varianty (u znaků X a Y: 1 - výborně, 2 - chvalitebně, 3 - dobře, 4 - neprospěl, u znaku Z: 0 - žena, 1 - muž).

```
data <- read.delim('znamky.txt', sep=' ', dec=',')
```

```
##   V1 V2 V3
## 1  2  2  0
## 2  1  3  1
## 3  4  3  1
## 4  1  1  0
## 5  1  2  1
## 6  4  4  1
```

- Popis tabulky:
 - Dvaceti žáků jsme se zeptali, jakou dostali na konci roku známku z matematiky (1.sloupec) a z angličtiny (2.sloupec) a zaznamenali jsme si jejich pohlaví (3.sloupec)
 - v každém jednom řádku jsou informace o jednom konkrétním žákovi
 - žák ... **objekt** našeho zkoumání
 - známka z matematiky/angličtiny a pohlaví ... **znaky** každého objektu (žáka)
 - znaku můžeme přiřadit **konkrétní číslo**, které má samo o sobě výpovědní hodnotu (známka z předmětu), nebo jde o **kódování** jisté vlastnosti: např. 0-žena, 1-muž
 - * znak *pohlaví* je příklad kodování 0 = ženy, 1 = muži
 - * 1 - výborně, 2 - chvalitebně, 3 - dobře, 4 - neprospěl
 - známky 1 - výborně, 2 - chvalitebně, 3 - dobře, 4 - neprospěl ... **varianty** znaku známka

```

data <- read.table('znamky.txt', sep='\t', dec='.')
head(data)

f1 <- factor(data$matematika, levels=c(1,2,3,4),
              labels=c('vyborne','chvalitebne','dobre','nedostatecne'))
f2 <- factor(data$anglictina, levels=c(1,2,3,4),
              labels=c('vyborne','chvalitebne','dobre','nedostatecne'))
f3 <- factor(data$pohlavi, levels=c(0,1), labels=c('zena','muz'))
data2 <- data.frame(f1, f2, f3)
names(data2) = c('matematika', 'anglictina', 'pohlavi')
head(data2)

```

Příklad 1.2. Vytvořte

- a) variační řadu známek z **matematiky** a angličtiny;
 - b) sloupkový diagram absolutních četností znaků **X=Matematika** a **Y=Angličtina**;
 - c) polygon absolutních četností znaků **X=Matematika** a **Y=Angličtina**.
- pro každou variantu můžeme stanovit její
 - absolutní četnost n_j
 - * kolik žáků mělo známku 2
 - relativní četnost p_j
 - * poměr žáků, kteří měli z matiky 2 ku celkovému počtu žáků
 - * $p_j * 100$ - kolik % žáků mělo známku 2
 - absolutní kumulativní četnost N_j
 - * kolik žáků mělo známku ≤ 2
 - relativní kumulativní četnost F_j
 - * poměr žáků, kteří měli známku z matiky ≤ 2 vzhledem k celkovému počtu žáků
 - * $F_j * 100$ - kolik % žáků mělo známku ≤ 2
 - všechny výše zmíněné četnosti můžeme zapsat do přehledné tabulky ... **variační řady**
 - teď si naprogramujeme
 - variační řadu pro známky z matematiky

```

matematika <- data2$matematika
n1 <- sum(matematika=='vyborne')
n2 <- sum(matematika=='chvalitebne')
n3 <- sum(matematika=='dobre')
n4 <- sum(matematika=='nedostatecne')

nj <- c(n1,n2,n3,n4)
n <- sum(nj)
pj <- nj/n
Nj <- cumsum(nj)
Fj <- cumsum(pj)

```

```
variacni.rada <- data.frame(nj=nj, Nj=Nj, pj=pj, Fj=Fj)
```

```

row.names(variacni.rada) <- c('vyborne', 'chvalitebne', 'dobre', ,
    nedostatecne')
variacni.rada

(VR.Mat <- variacni_rada(X=matematika,
    nazvy=c('vyborne', 'chvalitebne', 'dobre', ,
    nedostatecne'))

```

- Sloupkový diagram

```

nazvy.znamek <- c('vyborne', 'chvalitebne', 'dobre', 'nedostatecne')

# Matematika
barplot(VR.Mat$nj, col='white', border='white', axes=T,
    xlab='Znamka', ylab='Pocet_pozorovani', names=nazvy.znamek,
    main='Sloupkovy_diagram_proupredmet_matematika')
abline(h=0:9, col='grey80', lty=2)
barplot(VR.Mat$nj, col='blue', axes=F, density=20, border='darkblue',
    add=T)

```

- Polygon četností

```

plot(1:4, VR.Mat$nj, type='n', xlim=c(0.5,4.5), ylim=c(1,9),
    xlab='Znamka', ylab='Absolutni_cetnost',
    main='Polygon_cetnosti_pro_predmet_matematika', axes=F)
abline(h=0:9, col='grey80', lty=2)
abline(v=0:9, col='grey80', lty=2)

lines(1:4, VR.Mat$nj, col='darkblue', lwd=2 )
points(1:4, VR.Mat$nj, col='darkblue', pch=20, cex=1.2)
axis(1, at=0:5, lab=c('', nazvy.znamek, ''))
axis(2, at=0:10)

```

Příklad 1.3. Vytvořte variační řady známek z matematiky a angličtiny pouze

- pro ženy,

```

pohlavi<-data2$pohlavi
variacni_rada(X=matematika[pohlavi=='zena'], nazvy=nazvy.znamek)

```

- pro muže.

Dvouozměrné bodové rozložení četnosti

Příklad 1.4. Nadále budeme pracovat s celým datovým souborem. Vytvoříme kontingenční tabulku simultánních absolutních četností znaků X=Matematika a Y=Angličtina.

- vezměme si nyní z datové tabulky známky z matematiky (znak X) a z angličtiny (znak Y)
- dvouozměrný datový soubor; $X \dots 4$ varianty; $Y \dots 4$ varianty
- pro každou dvojici variant (celkem 16 dvojic) můžeme stanovit
 - $n_{jk} \dots$ **simultánní absolutní četnost** dvojice znaků $x_{[j]}$ a $y_{[k]}$
 - * $n_{jk} = \text{pocet}(X = x_{[j]} \text{ a } Y = y_{[k]})$

- * počet studentů, kteří měli z matiky 1 a z angličtiny 1, ...
- n_j ... marginální absolutní četnost varianty $x_{[j]}$
 - $n_j = n_{j1} + \dots + n_{j4}$
 - počet studentů, kteří měli z matiky 1 bez ohledu na to, co měli z angličtiny
- n_k ... marginální absolutní četnost varianty $y_{[k]}$
 - $n_k = n_{1k} + \dots + n_{4k}$
 - počet studentů, kteří měli z angličtiny 1 bez ohledu na to, co měli z matematiky

```
K.Tab <- table(matematika, anglictina)
K.Tab2 <- cbind(K.Tab, suma=apply(K.Tab, 1, sum))
(K.Tab3 <- rbind(K.Tab2, suma=apply(K.Tab2, 2, sum)))
```

Příklad 1.5. Vytvořte kontingenční tabulku řádkově a sloupcově podmíněných relativních četností znaků X=Matematika a Y=Angličtina.

- $p_{k(j)}$... řádkově podmíněná relativní četnost varianty $y_{[k]}$ za předpokladu $x_{[j]}$
 - $p_{k(j)} = \frac{n_{jk}}{n_j}$
 - poměr počtu studentů, kteří měli z matiky 1 a z angličtiny 1 vzhledem k počtu studentů, kteří měli z matiky 1
- $p_{j(k)}$... sloupcově podmíněná relativní četnost varianty $x_{[j]}$ za předpokladu $y_{[k]}$
 - $p_{j(k)} = \frac{n_{jk}}{n_k}$
 - poměr počtu studentů, kteří měli z matematiky 1 a z angličtiny 1 vzhledem k počtu studentů, kteří měli z angličtiny 1

```
Tab <- table(matematika, anglictina)
# Radkove podminene relativni cetnosti
round(prop.table(Tab, margin=1), digits=3)

# Sloupcove podminene relativni cetnosti
round(prop.table(Tab, margin=2), digits=3)
```

Intervalové rozdelení četností

Práci s intervalovým rozložením četností si ukážeme na datovém souboru lebky.txt.

Popis datového souboru: Máme k dispozici údaje o rozměrech lebek staroegyptské populace. Jedná se o 216 mužů a 109 žen. Znak X ... největší délka mozkovny v mm Znak Y ... největší šířka mozkovny v mm Znak Z ... pohlaví osoby (1–muž, 0–žena)

Příklad 1.6. Načtěte soubor lebky.txt. Podle Sturgersova pravidla najděte optimální počet třídicích intervalů pro znaky X a Y a vhodně stanovte meze třídicích intervalů, a to zvlášť pro muže a zvlášť pro ženy.

- spojité data → třídíme je do intervalů $(\infty; u_1]$, $(u_1; u_2]$, ..., $(u_r; u_{r+1}]$, $(u_{r+1}; \infty)$
- $(u_j; u_{j+1}]$... j -tý třídicí interval
- třídicí intervalu vyvolíme stejně dlouhé
- Sturgesovo pravidlo

$$r \approx 1 + 3.3 \log_{10} n$$

```

data      <- read.delim('lebky.txt', sep='\t', dec='.', header=F)
names(data) <- c('delka', 'sirka', 'pohlavi')
head(data)

# Muži
data.M      <- data[data$pohlavi=='muz',]
n.M         <- dim(data.M)[1]
(Sturges.M <- round(1+3.3*log10(n.M), digits=0))

delka.M     <- data.M$delka
range(delka.M)
max(delka.M) - min(delka.M)
round((max(delka.M) - min(delka.M))/Sturges.M, digits=0)

```

Příklad 1.7. Vytvořte histogram pro X a pro Y (s uvedenými absolutními a relativními četnostmi jednotlivých třídicích intervalů), a to zvlášť pro muže a zvlášť pro ženy.

```

hist(delka.M, breaks=seq(163, 199, by=4), ylim=c(0,52),
     main='Histogram', xlab='Delka lebky', ylab='Pocetnosti',
     col='white', border='white', density=20, axes=F)
abline(h=seq(0, 60, by=10), col='grey80', lty=2)
hist(delka.M, breaks=seq(163, 199, by=4),
     col='blue', border='darkblue', density=20, add=T)
axis(1, at=seq(163, 199, by=4))
axis(2, at=seq(0, 50, by=10))

abs.c <- hist(delka.M, breaks=seq(163, 199, by=4), plot=F)$counts
stred <- hist(delka.M, breaks=seq(163, 199, by=4), plot=F)$mids
rel.c <- round(abs.c/sum(abs.c)*100, 0)

cetnosti <- paste(abs.c, ';', rel.c, '%', sep=' ')
text(stred, abs.c+2, cetnosti, cex=0.8)

```