

## 2 Bodové a intervalové rozložení četností - OSNOVA

### Úvod

- pilotní analýza
- Motivace: Někdo nám poskytne data → seznámení s daty, grafické znázornění
- různý typ dat → různé způsoby reprezentace a vizualizace
  - kategoriální data – pohlaví, vzdělání, počet sourozenců, ...
  - spojité data – výška, porodní hmotnost, největší šířka/délka mozkovny, ...
    - \* můžeme je kategorizovat
- jedna vlastnost / více vlastností najednou
- → jednorozměrné/vícerozměrné bodové/intervalové rozdělení četností

### Jednorozměrné bodové rozdělení četností

- **Příklad č.1, Příklad č.2: Úvodní práce s datovým souborem**

- jedna porodnice, novorozenci; údaje o porodní hmotnosti, vzdělání matky, pohlaví novorozence a počtu starších sourozenců
- řádek ... údaje o jednom novorozenci ... **objekt**
- sloupec ... porodní hmotnost, vzdělání, pohlaví, počet st. sourozenců ... **znamky**
- **znak**
  - \* **konkrétní číslo**, které má samo o sobě výpovědní hodnotu (porodní hmotnost)
  - \* **kódování** (0–žena, 1–muž); (1–ZŠ, 2–SŠ, 3–SŠm, 4–VŠ)
- znak *vzdělání*, resp. *kategorizovaná por. hm* → kategoriální proměnná → bodové rozdělení četností

- **Příklad č.3: Variační řada**

- Variační řada ... tabulka obsahující pro každou ( $j$ -tou) variantu znaku  $X$ 
  - \* absolutní četnost  $n_j$ 
    - kolik matek má ZŠ
  - \* relativní četnost  $p_j$ 
    - poměr matek se ZŠ vzd. ku celkovému počtu matek
    - $p_j * 100$  - kolik % matek má ZŠ?
  - \* absolutní kumulativní četnost  $N_j$ 
    - kolik matek má SŠm nebo nižší
  - \* relativní kumulativní četnost  $F_j$ 
    - poměr matek se SŠm nebo nižší ku celkovému počtu matek
    - $F_j * 100$  - kolik % matek má SŠm nebo nižší?

- **Příklad č.4: Sloupcové grafy**

## Dvouozměrné bodové rozložení četností

- **Příklad č.5: KT simultánních absolutních a relativních četností**

- dva znaky . . . vzdělání matky ( $X$ ; 4 varianty), porodní hmotnost (kat) ( $Y$ ; 3 varianty)
- → 12 kombinací dvojic variant
- kontingenční tabulka abs. četností

	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	$n_{.1}$	$n_{.2}$	$n_{.3}$	$n$

- \*  $n_{jk}$  . . . **simultánní absolutní četnost** dvojice znaků  $x_{[j]}$  a  $y_{[k]}$ 
  - počet novorozenců s nízkou porodní hmotností a matkou se ZŠ
- \*  $n_{j.}$  . . . **marginální absolutní četnost varianty**  $x_{[j]}$ 
  - počet novorozenců, jejichž matka má ZŠ bez ohledu na jejich porodní hmotnost
- \*  $n_{.k}$  . . . **marginální absolutní četnost varianty**  $y_{[k]}$ 
  - počet novorozenců s nízkou porodní hmotností bez ohledu na vzdělání matky
- KT relativních četností . . . KT abs. četností podělená celkovým počtem objektů

- **Příklad č.6: KT řádkově/sloupcově podmíněných relativních četností**

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

## Intervalové rozdělení četnosti

- **Příklad č.7, Příklad č.8: Histogram, Krabicový diagram**

- skelety ze starověké egyptské populace; id, (egyptská) populace, pohlaví, největší délka/šířka mozkovny v mm
- *největší šířka mozkovny u mužů* . . . spojitá proměnná → intervalové rozdělení četností
- spojitá data → třídime je do stejně dlouhých *třídicích 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
- optimální počet intervalů . . . Sturgesovo pravidlo  $r \approx 1 + 3.3 \log_{10} n$  → optimální šířka jednoho intervalu → hranice intervalů