

3 Základní číselné charakteristiky

Tabulka 1: 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 šiknosti koeficient špičatosti	Pearsonův korel. koeficient

3.1 Číselné charakteristiky pro nominální znaky

Příklad 3.1. Charakteristika polohy nominálního znaku

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

Tabulka 2: Simultánní absolutní četnosti pro znaky $vzdělání matky$ a $porodní hmotnost novorozence$

	nízká	norma	vysoká
ZS	75	264	8
SS	79	325	20
SSm	73	341	11
VS	13	63	4

Řešení příkladu 3.1

nízka	norma	vysoka
ZS	75	264
SS	79	325
SSm	73	341
VS	13	63

1
2
3
4
5

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

ZS	SS	SSm	VS
347	424	425	80

6
7

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 $Y = porodní hmotnost novorozence$.

nízka	norma	vysoka
240	993	43

8
9

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

Tabulka 3: 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

[1] 0.05502639

10

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

3.2 Číselné charakteristiky pro ordinální znaky

Příklad 3.3. Základní číselné charakteristiky pro ordinální znak

Načtěte datový soubor 17-anova-newborns.txt a odstraňte neznámé hodnoty. Zaměřte se na novorozence s vysokou porodní hmotností (větší než 4 200 g). Zjistěte dimenzi datové tabulky s novorozencemi s vysokou porodní hmotností. Vytvořte tabulku základních číselných charakteristik pro znak $X = \text{počet starších sourozenců}$ pro tyto novorozence.

Řešení příkladu 3.3

[1] 44 4

11

Po odstranění neznámých hodnot obsahuje datová tabulka údaje o novorozencích s vysokou porodní hmotností, přičemž u každého novorozence 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.

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

2. Dolní kvartil $x_{0.25}$

• $n = \dots$

• $\alpha = \dots$

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

• $x_{0.25} = \dots$

3. Medián $x_{0.50}$

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

- $x_{0.50} = \dots$

4. Horní kvartil $x_{0.75}$

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

- $x_{0.75} = \dots$

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

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

	min	dolni.kv	median	horni.kv	max	IQR
25%	0	0.5	1	2	5	1.5

12
13

Interpretace výsledků: Počet starších sourozenců u novorozeneců s vysokou porodní hmotností v datovém souboru se pohyboval v rozmezí –

Dolní kvartil počtu starších sourozenců u novorozeneců s vysokou p.h. v datovém souboru nabývá hodnoty , tj. % novorozeneců v datovém souboru má starších sourozenců.


Medián počtu starších sourozenců u novorozeneců s vysokou p.h. v datovém souboru nabývá hodnoty , tj. % novorozeneců v datovém souboru má nebo starších sourozenců.

Horní kvartil počtu starších sourozenců u novorozeneců s vysokou p.h. v datovém souboru nabývá hodnoty , tj. % novorozeneců v datovém souboru má , nebo starších sourozenců. Rozsah interkvartilového rozpětí je roven

Příklad 3.4. Krabicový diagram

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

Řešení příkladu 3.4



pocet starsich sourozencu

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 .

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. Stupnice těsnosti závislosti mezi dvěma znaky podle hodnoty Spearmanova koeficientu pořadové korelace je uvedena v tabulce 4.

Tabulka 4: Stupnice míry závislosti podle Spearmanova a Pearsonova korelačního koeficientu

Spearmanův (Pearsonův) koeficient	Interpretace
0.0	Pořadová (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 pořadová (lineární) závislost

[1] 0.2428544


14

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

Příklad 3.6. Dvouzměrný tečkový diagram

Pro znaky $X = \text{počet starších sourozenců}$ a $Y = \text{porodní hmotnost novorozence}$ vykreslete dvouzměrný tečkový diagram.

Řešení příkladu 3.6



3.3 Číselné charakteristiky pro intervalové znaky

Příklad 3.7. 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 tabulkou základních číselných charakteristik pro znak X .

Řešení příkladu 3.7

[1] 216

15

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, mezikvartilové rozpětí, koeficient šíklosti a koeficient špičatosti.

1. Aritmetický průměr m

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

2. Rozptyl s^2

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

3. Směrodatná odchylka s

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

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

5. Dolní kvartil $x_{0.25}$

$$\bullet n = \dots$$

$$\bullet \alpha = \dots$$

$$\bullet \alpha \times n = \dots \rightarrow \text{je / není celé číslo} \rightarrow$$

$$\bullet x_{0.25} =$$

6. Medián $x_{0.50}$

$$\bullet n = \dots$$

$$\bullet \alpha = \dots$$

$$\bullet \alpha \times n = \dots \rightarrow \text{je / není celé číslo} \rightarrow$$

$$\bullet x_{0.50} =$$

7. Horní kvartil $x_{0.75}$

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

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

9. Výběrový koeficient šikmosti b_1

- $b_1 = \dots$
- 10. Výběrový koeficient špičatosti b_2
- $b_2 = \dots$

	m	s	min	dolni.kv	median	horni.kv	max	iqr	sikmost	spicatost
muži	137.	19	4.81	124	134	137	140	149	6	0.08

16
17

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

Příklad 3.8. 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 3.8

Oba znaky X a Y jsou typu. Ke stanovení míry závislosti použijeme korelační koeficient. Stupnice těsnosti závislosti mezi dvěma znaky podle hodnoty Pearsonova korelačního koeficientu je uvedena výše v tabulce 4.

[1] 0.168157

18

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

Příklad 3.9. Dvouozměrný tečkový diagram

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