

Téma 3: Výpočet číselných charakteristik jednorozměrného a dvourozměrného datového souboru

Úkol 1.: U 100 náhodně vybraných domácností byl zjišťován 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).

| způsob zásobování | bydliště | | |
|-------------------|-------------|------------|---------|
| | velké město | malé město | vesnice |
| vlastní sklep | 13 | 15 | 14 |
| jinde | 11 | 7 | 2 |
| nákup | 19 | 9 | 10 |

a) Pro oba znaky určíme modus.

b) Vypočteme Cramérův koeficient znaků X, Y.

Návod: Otevřeme nový datový soubor se třemi proměnnými X, Y, četnost a devíti případy. Do proměnné X napíšeme 3 jedničky, 3 dvojky a 3 trojky, do proměnné Y napíšeme 3 krát pod sebe 1, 2, 3 a do proměnné četnost napíšeme odpovídající simultánní absolutní četnosti dvojic variant (X, Y), tj. 13, 15, 14, 11, 7, 2, 19, 9, 10. Proměnným vytvoříme návěští a popíšeme význam jednotlivých variant (viz Úkol 2 v Tématu 1).

ad a) Výpočet modu: Statistika – Základní statistiky/tabulky – Popisné statistiky – OK – klikneme na tlačítko se závažím – zaškrtneme Stav zapnuto, vybereme proměnnou vah četnost – OK - Proměnné X, Y – OK – Detailní výsledky – zaškrtneme Modus.

| Promě | Popisné statistiky | |
|-------|--------------------|--------------|
| | Modus | Četnost modu |
| X | 1,000 | 4,000 |
| Y | 1,000 | 4,000 |

Proměnná X má modus 1, tj. nejvíce domácností skladuje brambory ve vlastním sklepě a proměnná Y má také modus 1, tj. nejvíce domácností bydlí ve velkém městě.

ad b) Výpočet Cramérova koeficientu: Statistika – Základní statistiky/tabulky – Kontingenční tabulky – OK – Specif. tabulky - List 1 X, List 2 Y - OK – na záložce Možnosti ve Statistikách 2 rozměrných tabulek zaškrtneme Fí (tabulky 2x2) & Cramérovo V & C – přejdeme na záložku Detailní výsledky – Detailní 2-rozm. tabulky.

| Statist. | Statist. : X(3) x Y(3) | | |
|-----------------|------------------------|-----|-------|
| | Chi-kvadr. | sv | p |
| Pearsonův chi-k | 6,420 | df= | p=,16 |
| M-V chi-kvadr. | 7,075 | df= | p=,13 |
| Fí | ,2533 | | |
| Kontingenční ko | ,2456 | | |
| Cramér. V | ,1791 | | |

Na posledním řádku najdeme, že Cramérův koeficient nabývá hodnoty 0,179, tedy mezi způsobem zásobování bramborami a bydlištěm domácnosti existuje jen slabá závislost – viz následující tabulka:

| | |
|---------------------|------------------------|
| Cramérův koeficient | interpretace |
| mezi 0 až 0,1 | zanedbatelná závislost |
| mezi 0,1 až 0,3 | slabá závislost |
| mezi 0,3 až 0,7 | střední závislost |
| mezi 0,7 až 1 | silná závislost |

Úkol 2.: Otevřeme datový soubor znamky.sta.

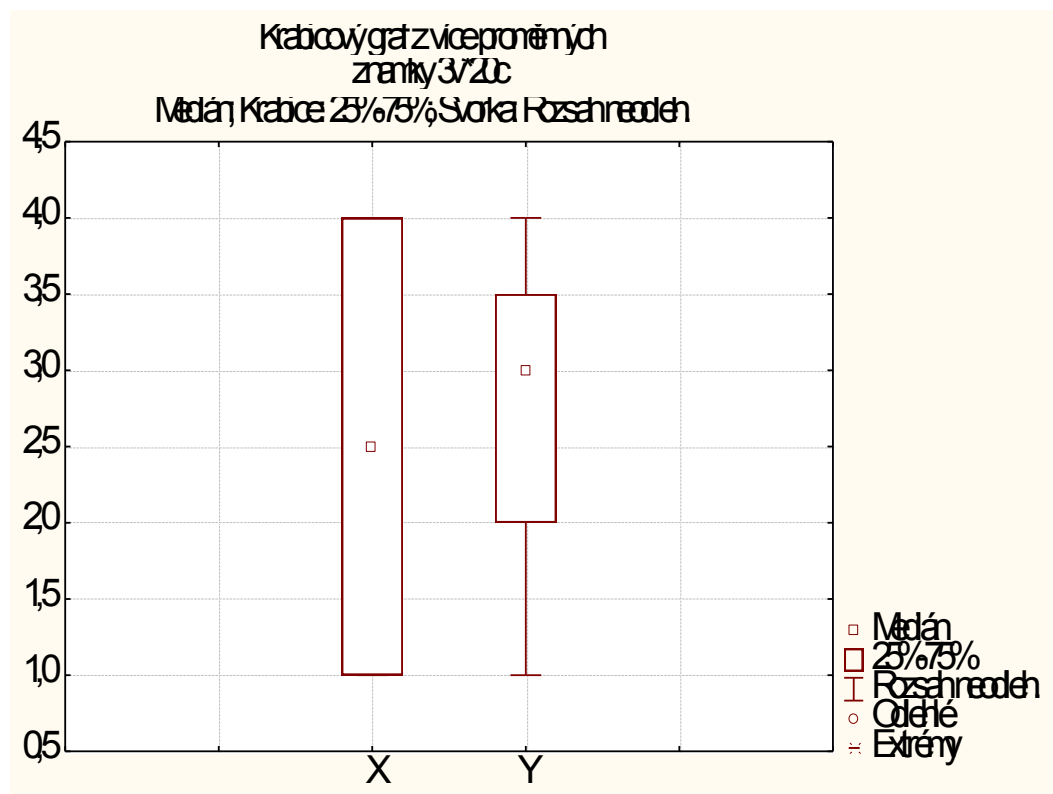
- a) Pro známky z matematiky a angličtiny vypočteme medián, dolní a horní kvartil, kvartilovou odchylku a vytvoříme krabicový diagram.
- b) Vypočteme Spearmanův korelační koeficient známek z matematiky a angličtiny pro všechny studenty, pak zvlášť pro muže a zvlášť pro ženy. Získané výsledky budeme interpretovat.

Návod:

ad a) Statistika – Základní statistiky/tabulky – Popisné statistiky – OK – Proměnné X, Y – OK – Detailní výsledky - zaškrtneme Medián, Dolní & horní kvartily, Kvartil. rozpětí – Výpočet.

| Proměnná | Popisné statistiky (znamky) | | | |
|----------|-----------------------------|----------------|---------------|------------------|
| | Medián | Spodní kvartil | Horní kvartil | Kvartil. rozpětí |
| X | 2,500 | 1,000 | 4,000 | 3,000 |
| Y | 3,000 | 2,000 | 3,500 | 1,500 |

Vytvoření krabicového diagramu: Grafy – 2D Grafy – Krabicové grafy – vybereme Vícenásobný – Proměnné X, Y – OK.



ad b) Statistika – Neparametrická statistika – Korelace – OK – Proměnné X, Y – OK – Spearman R.

Pro všechny:

| Spearmanovy korelace (znamí ChD vynechány párově Označ. korelace jsou významn | | |
|---|-------|-------|
| Promě | X | Y |
| X | 1,000 | 0,688 |
| Y | 0,688 | 1,000 |

Počítáme-li Spearmanův korelační koeficient pro ženy (resp. pro muže), použijeme filtr: tlačítko Select Cases – Zapnout filtr – včetně případů – některé, vybrané pomocí výrazu $Z=0$ (resp. $Z=1$).


Pro ženy:

| Spearmanovy korelace (znamí ChD vynechány párově Označ. korelace jsou významn Zhrnout podmínku: $Z=0$ | | |
|--|-------|-------|
| Promě | X | Y |
| X | 1,000 | 0,860 |
| Y | 0,860 | 1,000 |

Pro muže:

| Spearmanovy korelace (znamí ChD vynechány párově Označ. korelace jsou významn Zhrnout podmínku: $Z=1$ | | |
|--|-------|-------|
| Promě | X | Y |
| X | 1,000 | 0,373 |
| Y | 0,373 | 1,000 |

Vidíme, že nejsilnější přímá pořadová závislost mezi známkami z matematiky a angličtiny je u žen, $r_s = 0,86$. U mužů je tato závislost mnohem slabší, $r_s = 0,37$. U žen tedy dochází k tomu, že se sdružují podobné známky z obou předmětů, zatímco u mužů se projevuje spíše tendence k různým známkám. Je to zřetelně vidět na dvourozměrných tečkových diagramech.



Význam hodnot Spearmanova (i Pearsonova) koeficientu korelace je popsán v tabulce:

| Absolutní hodnota korelačního koeficientu | Interpretace hodnoty |
|---|--------------------------------|
| 0 | lineární nezávislost |
| (0, 0,1) | velmi nízký stupeň závislosti |
| [0,1, 0,3) | nízký stupeň závislosti |
| [0,30, 0,50) | mírný stupeň závislosti |
| [0,50, 0,70) | význačný stupeň závislosti |
| [0,70, 0,90) | vysoký stupeň závislosti |
| [0,90, 1) | velmi vysoký stupeň závislosti |
| 1 | úplná lineární závislost |

Úkol 3.: Otevřeme datový soubor ocel.sta.

a) Pro mez plasticity a mez pevnosti vypočteme aritmetický průměr, směrodatnou odchylku, rozptyl, koeficient variace, šikmost a špičatost. Výsledky porovnáme s údaji ve skriptech Popisná statistika (viz str. 30).

b) Vypočteme Pearsonův koeficient korelace meze plasticity a meze pevnosti. Dále vypočteme také kovarianci a výsledek porovnáme s výsledkem ve skriptech Popisná statistika (str. 30).

Návod:

ad a) Statistika – Základní statistiky/tabulky – Popisné statistiky – OK – Proměnné X, Y – OK – Detailní výsledky - zaškrtneme Průměr, Směrodat. odchylka, Rozptyl, Variační koeficient, Šikmost, Špičatost – Výsledky.

| Popisné statistiky (ocel) | | | | | | |
|---------------------------|-------|-------|-------|---------|--------|--------|
| Promě | Prům | Rozpt | Sm.od | Koef.pr | Šikmo | Spicat |
| X | 95,88 | 1070, | 32,71 | 34,11 | -0,046 | -0,605 |
| Y | 114,4 | 1075, | 32,78 | 28,66 | 0,297 | -0,592 |

Vysvětlení: Rozptyl a směrodatná odchylka vyjdou ve STATISTICE jinak než ve skriptech, protože STATISTICA ve vzorci pro výpočet rozptylu nepoužívá 1/n, ale 1/(n-1). Koeficient variace (v tabulce označený jako Koef. Prom.) je udán v procentech.

ad b) Statistika – Základní statistiky/tabulky – Korelační matice – OK – 1 seznam proměnných – X, Y – OK, na záložce Možnosti zrušíme volbu Včetně průměrů a sm. odch. – Výpočet.

| Korelace (ocel) | | |
|--|-----|-----|
| Označ. korelace jsou významné N=60 (Celé případy vynechány) | | |
| Promě | X | Y |
| X | 1,0 | 0,9 |
| Y | 0,9 | 1,0 |

Vidíme, že mezi X a Y existuje silná přímá lineární závislost.

Kovariance se počítá složitěji. Statistika – Vícenásobná regrese - Proměnné Nezávislá X, Závislá Y – OK – OK – Residua/předpoklady/předpovědi – Popisné statistiky – Další statistiky - Kovariance.

| | | |
|-------|--------------|-------|
| Promě | Kovariance (| |
| | X | Y |
| X | 1070, | 1002, |
| Y | 1002, | 1075, |

Vysvětlení: Na hlavní diagonále jsou rozptyly proměnných X, Y, mimo hlavní diagonálu je kovariance. Kovariance vyjde ve STATISTICE jinak než ve skriptech, protože ve STATISTICE se ve vzorci pro výpočet kovariance nepoužívá $1/n$, ale $1/(n-1)$.

Úkol 4.: Je třeba si uvědomit, že průměr a rozptyl nepopisují rozložení četností jednoznačně. Existují datové soubory, které mají shodný průměr i rozptyl, ale přesto se jejich rozložení četností velmi liší. Tuto skutečnost dobře ilustruje následující příklad: Tři skupiny studentů o počtech 149, 69 a 11 odpovídaly při testu na 10 otázek. Znak X je počet správně zodpovězených otázek. Známe absolutní četnosti znaku X ve všech třech skupinách.

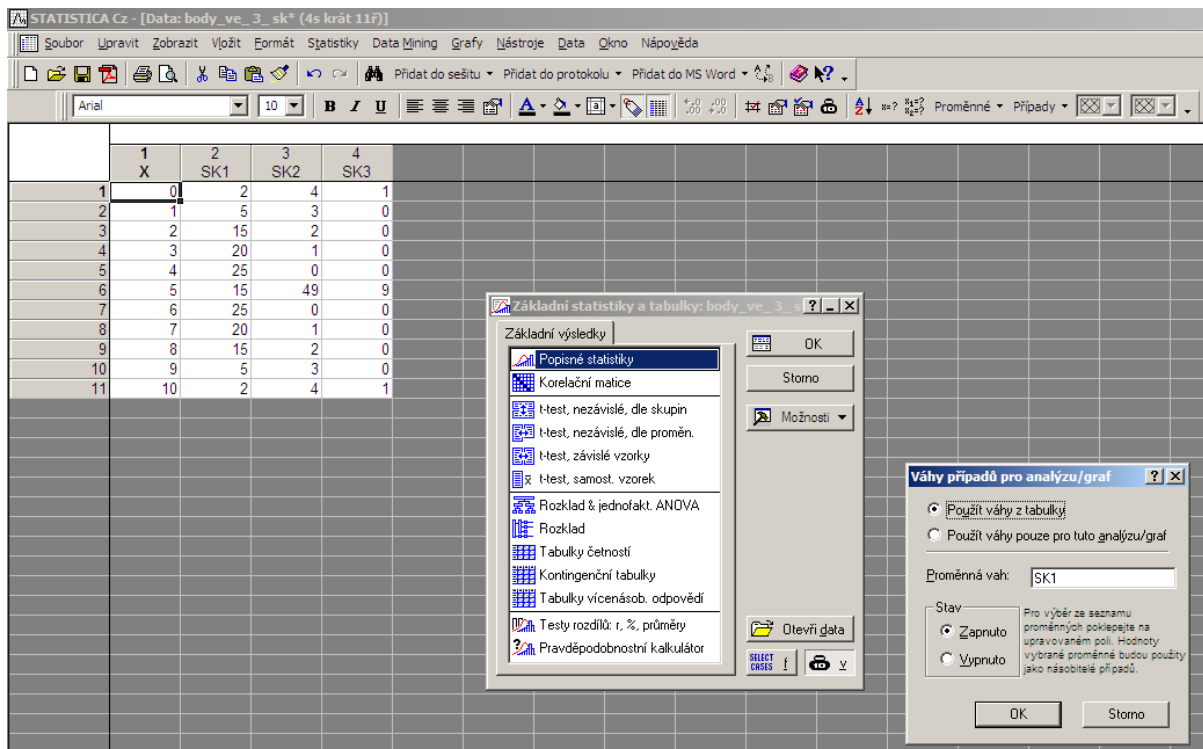
| č. sk. | X | | | | | | | | | | |
|--------|---|---|----|----|----|----|----|----|----|---|----|
| | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| 1 | 2 | 5 | 15 | 20 | 25 | 15 | 25 | 20 | 15 | 5 | 2 |
| 2 | 4 | 3 | 2 | 1 | 0 | 49 | 0 | 1 | 2 | 3 | 4 |
| 3 | 1 | 0 | 0 | 0 | 0 | 9 | 0 | 0 | 0 | 0 | 1 |

Vypočítejte průměr, rozptyl, šikmost a špičatost počtu správně zodpovězených otázek ve všech třech skupinách. Nakreslete sloupcové diagramy absolutních četností.

Návod: Při zadávání dat do STATISTIKY utvořte čtyři proměnné a 11 případů. V 1. sloupci budou varianty znaku X (tj. 0 až 10), v dalších sloupcích pak absolutní četnosti. Proměnné pojmenujeme X, SK1, SK2, SK3.

| | 1 | 2 | 3 | 4 |
|----|----|-----|-----|-----|
| | X | SK1 | SK2 | SK3 |
| 1 | 0 | 2 | 4 | 1 |
| 2 | 1 | 5 | 3 | 0 |
| 3 | 2 | 15 | 2 | 0 |
| 4 | 3 | 20 | 1 | 0 |
| 5 | 4 | 25 | 0 | 0 |
| 6 | 5 | 15 | 4 | 9 |
| 7 | 6 | 25 | 0 | 0 |
| 8 | 7 | 20 | 1 | 0 |
| 9 | 8 | 15 | 2 | 0 |
| 10 | 9 | 5 | 3 | 0 |
| 11 | 10 | 2 | 4 | 1 |

V tabulce Popisné statistiky zadáme Proměnná X a klepneme na tlačítko W, abychom program upozornili, že budeme pracovat s daty zadanými pomocí absolutních četností. Zadáme Proměnná vah SK1, zaškrtneme Stav Zapnuto, OK



Ve volbě Popisné statistiky zaškrtneme Průměr, Rozptyl, Šikmost, Špičatost – Výpočet. Dále pro znak X nakreslíme sloupcový diagram. Tytéž úkoly provedeme s váhovými proměnnými SK2 a SK3.

1. skupina (X váženo pomocí SK1)

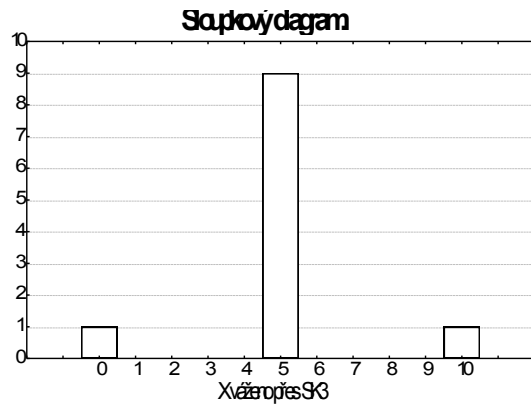


| Descriptive Statistics | |
|------------------------|---------------------------|
| Varial | Mean Variar Skewn Kurtos |
| X | 5,000 5,000 -0,000 -0,759 |

2. skupina (X váženo pomocí SK2)

| Descriptive Statistics | |
|------------------------|--------------------------|
| Varial | Mean Variar Skewn Kurtos |
| X | 5,000 5,000 -0,000 1,291 |

3. skupina (X váženo pomocí SK3)

| Descriptive Statistics (ciscr) | |
|--------------------------------|--------------------------|
| Varial | Mean Variar Skewn Kurtos |
| X | 5,000 5,000 -0,000 5,000 |



Všechny tři skupiny mají též průměr, rozptyl a šikmost, liší se pouze ve špičatosti. Sloupkové diagramy počtu správně zodpovězených otázek v každé ze tří uvažovaných skupin mají naprosto odlišný vzhled.