

Popisné statistiky:

Míry centrální tendence a variability

Mgr. Zuzana Lenhartová

Popisné statistiky:

Míry centrální tendence a variability

Mgr. Zuzana Lenhartová

Popisné statistiky

Kategoriální deskriptivy

- entropie
- modus

Pořadové deskriptivy

- medián
- kvartily
- percentily
- grafické zobrazení pomocí pořadových dekriptiv - boxplot

Odchylkové, momentové dekriptivy

- aritmetický průměr
- rozptyl, směrodatná odchylka
- zešikmení
- špičatost

Centrální tendence

Střední hodnoty, umístění

- nevýhoda tabulky četností i grafického zobrazení - neúspornost (hodně čísel -> špatná orientace)
- nemůžeme proměnnou popsat rychle

Jak zobrazení dat zredukovat?

- úsporně popsat rozložení proměnných skrze ukazatele centrální tendence a ukazatele variability

Ukazatel centrální tendence

- = ukazatel středních hodnot; ukazatel míry polohy
- charakteristika typické hodnoty dat
- ukazuje, kde se na měřené škále (číselné ose) data nalézají
- popisuje rozložení četností jedné proměnné

Ukazatel variability

- udává, jak moc či málo jsou data na škále rozptýlená



Ukazatele centrální tendence

- popisná statistika (číselná charakteristika proměnné)
- ukazatel středních hodnot
- udávají průměrnou, typickou, reprezentativní, očekávanou hodnotu - jeden údaj
- jedno číslo - krásné a zrádné
 - modus
 - medián
 - aritmetický průměr

Modus \hat{X}, Mo

- kategoriální typická hodnota
- **nejčastější hodnota**
(hodnota s nejvyšší četností v datech)
- jediná možnost u nominálních dat, u vyšších úrovní často užitečnou volbou
- když známe všechny naměřené hodnoty, stanovíme modus tak, že zjistíme, která hodnota se v daném souboru vyskytuje nejčastěji

Příklad: 14, 3, 18, 4, 8, 18, 4, 6, 8, 10, 8

- v případě tabulky četnosti s intervaly lze modus určit přibližně jako střed intervalu s největší četností
- *nezávislý na extrémních hodnotách naměřené veličiny*
 - modus nemusí být určen jednoznačně - se stejnou nejvyšší frekvencí se může vyskytovat více hodnot
 - rozdelení s jedním modelem (vrcholem) - unimodální
 - rozdelení pravděpodobnosti s dvěma vrcholy - dvouvrcholová (bimodální).



Medián

$$\tilde{X}, Md$$

- pořadová střední hodnota
- prostřední hodnota z řady hodnot seřazených podle velikosti
- 50. percentil - rozděluje soubor dat na dvě stejné části
- při sudém počtu prvků je mediánem průměr ze dvou prostředních hodnot/ kterékoli číslo z intervalu mezi nejbližší vyšší a nejbližší nižší hodnotou (konsensuálně střed intervalu)
- používáme pro pořadová data a výše
- nezávislý na extrémních hodnotách měřené veličiny

Příklad: Měření vědomostí žáků didaktickým testem, výsledky:

14, 3, 18, 4, 8, 18, 4, 6, 8, 10, 8

Aritmetický průměr

- deviační, ochylková, momentová střední hodnota
- jak ho znáte ze školy:

součet všech naměřených údajů vydelený jejich počtem

- používáme pouze pro intervalová a poměrová data
- nevýhoda: velmi citlivý na extrémní hodnoty

Příklad: **1,3,6,8,9,9,10,10,10**

Příklad:



	s 15	bez 15
Průměr	2,48	2,05
Medián	1,00	1,00
Modus	0	0

	s 15	bez 15
Průměr	2,48	2,05
Medián	1,00	1,00
Modus	0	0

Příklad:

Určete průměr, medián a modus u těchto čtyř rozložení (sad dat):

- a. 3, 3, 4, 5, 6, 8, 8, 8, 9
- b. 2, 4, 4, 4, 6, 7, 7
- c. 7, 7, 8, 9, 10, 10, 10
- d. 1, 1, 3, 4, 5, 9

Míry variability (rozptylenosti)

- omezenost středních hodnot - udávají pouze to, kolem jaké hodnoty se data "centrují" - který jsou nejčastější
- data se stejnou střední hodnotou mohou mít různou rozptylenost

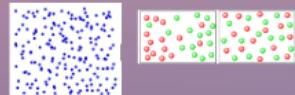
Variabilita - jak moc či málo jsou data na škále rozptylená

- malá variabilita - většina hodnot v souboru je stejných nebo velmi blízkých
- vysoká variabilita - hodnoty jsou velmi rozmanité
- tři ukazatelé variability (podle škál)

Na nominální škále:

Entropie

- veličina udávající "míru neuspořádanosti" zkoumaného systému
- míra neurčitosti systému



- v sociálních vědách se moc nepoužívá

Na pořadové škále:

Variační rozpětí

- pokud můžeme seřadit hodnoty od nejménší po největší a můžeme říct, co je minimum a co je maximum, máme rozpětí

$$R = X_{\max} - X_{\min}$$

- extrémně roste s velikostí vzorku - čím větší soubor, tím větší hodnota rozpětí

Příklad: 2, 8, 9, 10, 1, 0, 5

Interkvartilové rozpětí

- vzdálenost mezi dvěma body na škále, které jsou na nějakém místě, které můžeme snadno definovat - používá se 25. a 75. percentil

$$IQR = Q_3 - Q_1 \quad (75. \text{ percentil minus 25. percentil})$$

- používáme spíše než jednoduché vanační rozpětí

Na intervalové, poměrové škále

- charakteristiky založené na odchylkách od průměru
- měří rozptylenost dat kolem aritmetického průměru

$$x = X - \bar{m}$$

Rozptyl

- aritmetický průměr čtverců odchylek od aritmetického průměru
- průměrná odchylka na druhou
- populační rozptyl: $(\sum x^2 / n)$
- výběrový rozptyl: $(\sum x^2 / (n - 1))$ - při počítání pro všechny prvky populace
- součet odchylek na druhou = suma čtverců
- používá se v inferenční statistice

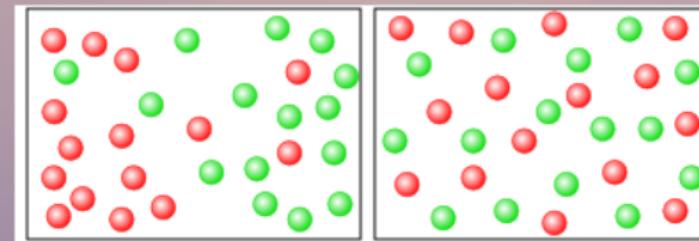
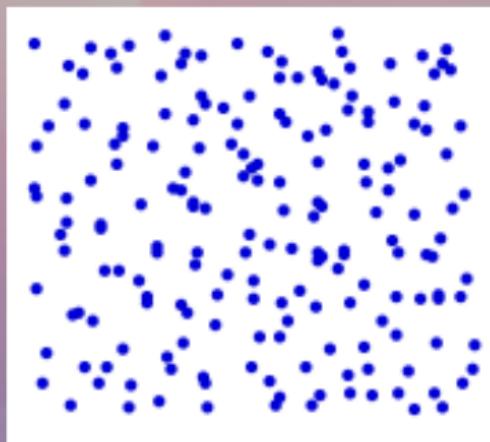
Směrodatná odchylka

- standardní odchylka
- odmocnina rozptylu - návrat k původní jednotce, ve které měříme

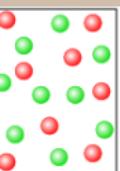
Na nominální škále:

Entropie

- veličina udávající "míru neuspořádanosti" zkoumaného systému
- míra neurčitosti systému



- v sociálních vědách se moc nepoužívá



Na pořadové škále:

Variační rozpětí

- pokud můžeme seřadit hodnoty od nejmenší po největší a můžeme říct, co je minimum a co je maximum, máme rozpětí
- $R = X_{\max} - X_{\min}$
- extrémně roste s velikostí vzorku - čím větší soubor, tím větší hodnota rozpětí

Příklad: 2, 8, 9, 10, 1, 0, 5

Interkvartilové rozpětí

- vzdálenost mezi dvěma body na škále, které jsou na nějakém místě, které můžeme snadno definovat - používá se 25. a 75. percentil
- $Q = Q_3 - Q_1$ (75. percentil minus 25. percentil)
 - používáme spíše než jednoduché variační rozpětí



Na intervalové, poměrové škále

- charakteristiky založené na odchylkách od průměru
- měří rozptylenost dat kolem aritmetického průměru

$$x = X - m$$

Rozptyl

- aritmetický průměr čtverců odchylek od aritmetického průměru
- průměrná odchylka na druhou
- populační rozptyl: $(\sum x^2 / n)$
- výběrový rozptyl: $(\sum x^2 / (n - 1))$ - při počítání pro všechny prvky populace
součet odchylek na druhou = suma čtverců
- používá se v inferenční statistice

Směrodatná odchylka

- standardní odchylka
- odmocnina rozptylu - návrat k původní jednotce, ve které měříme



Popisné statistiky:

Míry centrální tendence a variability

Mgr. Zuzana Lenhartová

