

Osnove statistike u demografiji

Predavanje 4

Mjere disperzije

- Mjerama disperzije mjeri se stupanj homogenosti numeričkog niza, odnosno stupanj varijabilnosti podataka. Razlikujemo:
 - Potpune mjere disperzije, odnosno mjere u čijem izračunu sudjeluju sve vrijednosti (numeričke) variable su varijanca, standardna devijacija i koeficijent varijacije, dok su ostale mjere
 - nepotpune mjere disperzije (raspon varijacije, interkvartilni raspon, koeficijent kvartilne devijacije).
- Raspon varijacije, interkvartilni raspon i standardna devijacija izraženi su u **mjernim jedinicama variable** za koju se izračunavaju, dok su ostale mjere izražene relativno

Raspon varijacije, interkvartil i koeficijent kvartilne devijacije

- Raspon varijacije R je razlika između najveće i najmanje vrijednosti numeričke varijable

$$R = x_{\max} - x_{\min},$$

- Raspon varijacije središnjih 50% podataka mjeri se interkvartilom IQ (apsolutna mjera) i

$$I_Q = Q_3 - Q_1,$$

- koeficijentom kvartilne devijacije VQ (relativna mjera)

$$V_Q = \frac{Q_3 - Q_1}{Q_3 + Q_1}, \quad 0 \leq V_Q \leq 1.$$

Raspon varijacije, interkvartil i koeficijent kvartilne devijacije

- Analogno se mogu definirati i interdecilni i interpercentilni raspon.
- Npr. razlika sedmog i trećeg decila pokazuje raspon varijacije središnjih 40% podataka, dok je razlika osamdeset i petog i petnaestog percentila raspon varijacije središnjih 70% podataka

B-P dijagram

- Stupanj varijabilnosti može se predočiti grafički B-P dijagramom (engl. Box-Plot).
- B-P dijagram se temelji na pet osnovnih pokazatelja (5 statistika, 5'S; engl. Five-Number Summaries): x_{\min} (najmanjoj vrijednosti), Q_1 (prvom kvartilu), Me (medijanu), Q_3 (trećem kvartilu) i x_{\max} (najvećoj vrijednosti).

Varijanca, standardna devijacija i koeficijent varijacije

- **Varijanca** σ^2 je prosječno kvadratno odstupanje vrijednosti numeričke variable od aritmetičke sredine.
- Mjeri **varijabilnost podataka i reprezentativnost aritmetičke sredine**.
- Što je varijabilnost podataka **veća**, to je **reprezentativnost** prosjeka **manja** i obrnuto.



Varijanca, standardna devijacija i koeficijent varijacije

- Zbroj odstupanja vrijednosti numeričke varijable od prosjeka jednak je nuli
- Stoga se za izračun varijance koriste kvadrati odstupanja.
- Kvadriranjem se “poništava” predznak, a istovremeno, kvadriranjem veća vrijednost odstupanja dobiva veći absolutni udio u izračunu varijance.
- **Varijanca negrupiranih podatka** definira se kao

$$\sigma^2 = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}.$$

Varijanca, standardna devijacija i koeficijent varijacije

- Za **distribuciju frekvencija, varijanca je**

$$\sigma^2 = \frac{\sum_{i=1}^k f_i (x_i - \bar{x})^2}{\sum_{i=1}^k f_i},$$

- Varijanca kao **mjera disperzije** izražena je u **kvadratima mjernih jedinica variable**. $\sigma = +\sqrt{\sigma^2}$,
- Stoga je potrebno izračunati **standardnu devijaciju** σ , kao pozitivni drugi korijen iz varijance.
- Standardna devijacija izražava prosječno odstupanje vrijednosti variable od aritmetičke sredine izraženo u mjernim jedinicama variable (apsolutna mjera).



Varijanca, standardna devijacija i koeficijent varijacije

- Ako se **standardna devijacija podijeli s aritmetičkom sredinom**, a omjer pomnoži s posto, dobiveni pokazatelj je **koeficijent varijacije V** i relativna je mjera disperzije, izražena u %.

$$V = \frac{\sigma}{\bar{x}} \cdot 100 \%$$

- Standardna devijacija interpretira se kao **prosječno apsolutno odstupanje**, a koeficijent varijacije kao **prosječno relativno odstupanje od prosjeka**.



Standardizirano obilježje

- **Linearna transformacija** vrijednosti numeričke varijable x_i oblika

$$z_i = \frac{x_i - \bar{x}}{\sigma}, \quad i = 1, 2, \dots, N$$

- naziva se **standardizacija**
- Standardizirana vrijednost varijable višestruko se koristi u **empirijskim istraživanjima**.
- Ona **pokazuje relativni položaj** vrijednosti numeričke varijable u nizu, odnosno pokazuje za koliko standardnih devijacija vrijednost numeričke varijable odstupa od aritmetičke sredine.
- Osim toga, na temelju standardiziranih vrijednosti moguće je **usporediti relativni položaj podataka u različitim numeričkim nizovima (s različitim mernim jedinicama i na različitim razinama vrijednosti)**.

Empirijsko pravilo i Čebiševljevo pravilo

- Ukoliko su vrijednosti numeričke varijable raspoređene po simetričnoj zvonolikoj unimodalnoj distribuciji (normalnoj distribuciji) primjenjuje se empirijsko pravilo

Empirijsko pravilo i Čebiševljevo pravilo

- Za distribuciju nepoznatog oblika, proporcija podataka iz određenog intervala određuje se pomoću **Čebiševljevog pravila** ili Čebiševljeve nejednakosti.

Mjere oblika distribucije: mjere asimetrije i mjera zaobljenosti

- Mjerama asimetrije, odnosno mjerama oblika distribucije, mjeri se način rasporeda podataka oko neke srednje vrijednosti.
- Uglavnom je to aritmetička sredina.

Položaj srednjih vrijednosti



Položaj srednjih vrijednosti







Mjera zaobljenosti

- Mjerom zaobljenosti a_4 mjeri se zaobljenost unimodalnog vrha (simetrične ili približno simetrične) distribucije i **mjera je “debljine” odnosno “težine” repova distribucije.**
- Koeficijent a_4 je potpuna mjera. Izračunava se za **negrupirane podatke** i za **distribuciju frekvencija** prema izrazima:



Mjere koncentracije

- Mjere koncentracije su pokazatelji načina razdiobe totala (zbroja vrijednosti numeričke varijable) po jedinicama niza ili po modalitetima kvalitativnih ili vrijednostima kvantitativnih varijabli.