

Deskriptivna statistika

Vježbe III

24.10.2018.
Nemanja Batrićević

Deskriptivna statistika

- Mjere centralne tendencije
- Mjere varijacije

Centralna tendencija

- Centralna tendencija – mjere čije izračunavanje služi određivanju numeričke vrijednosti oko koje se rezultati grupišu

- Aritmetička sredina – “prosjek”
- Medijana – “središnja vrijednost”
- Modus – “najfrekventnija vrijednost”


Mjere centralne tendencije

Pregled

Centralna tendencija


Aritmetička
sredina

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$$



Središna
vrijednost
opservacije
(centralna
opservacija)

Modus



Geometrijska
sredina

$$\bar{X}_G = (X_1 \times X_2 \times \cdots \times X_n)^{1/n}$$

Opservirana
vrijednost sa
najvećom
frekvencijom

Centralne tendencije

- Aritmetička sredina** – suma vrijednosti podijeljena brojem vrijednosti.
 - Zavisi od ekstremnih vrijednosti
 - U slučaju agregatnih podataka koristit sredinu intervala i broj observacija
- Medijana** – središnja opservacija nakon što ih poređamo po veličini
 - Ne zavisi od ekstremnih vrijednosti
 - Uzim se središnja vrijednost (neparan broj), ili prosjek dvije središnje vrijednosti (paran)
 - $(n + 1) / 2$ je pozicija u uređenom nizu, ne vrijednost medijane
- Modus** – Vrijednost koja se najčešće pojavljuje
 - I za numeričke i atributivne (nominalne) podatke
 - Multi-modalna distribucija

Aritmetička sredina

- Aritmetička sredina (sredina) je najčešće korišćena mjera centralne tendencije
 - Za uzorak veličine n aritmetička sredina je:

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} = \frac{X_1 + X_2 + \dots + X_n}{n}$$


Veličina uzorka

Vrijednosti varijable


Aritmetička sredina

(nastavak)

- Sredina = suma vrijednosti podijeljena brojem tih vrijednosti (opservacija)
- Zavisi od ekstremnih vrijednosti





$$\frac{1+2+3+4+5}{5} = \frac{15}{5} = 3$$



$$\frac{1+2+3+4+10}{5} = \frac{20}{5} = 4$$

Medijana

- U uređenom nizu, medijana je “srednja” observacija (50% iznad, 50% ispod)



- Ne zavisi od ekstremnih vrijednosti

Određivanje medijane

- Lokacija medijane se određuje na sledeći način:

$$\text{Medijana} = \frac{n+1}{2} \text{ pozicija u uredjenom nizu}$$



- Ako je broj opservacija paran, medijana je sredina opservacija
 - Ako je broj opservacija paran, medijana je prosjek dvije središne opservacije
-
- Napomena nije *vrijednost* medijane, već samo *pozicija*

medijane u uređenom nizu podataka

$$\frac{n+1}{2}$$

Modus

- Jedna od mjera centralne tendencije
- Vrijednost koja se najčešće pojavljuje
- Ne zavisi od ekstremnih vrijednosti
- Određuje se i za numeričke i za atributivne podatke
- Moguće je da serija nema modus
- Moguće je da serija ima više modusa (multi-modana)



Primjer:

Cijene kuća:

\$2,000,000

500,000

300,000

100,000

100,000

Suma \$3,000,000

- **Sredina:** $(\$3,000,000 / 5)$

(prosječna cijena) = **\$600,000**

- **Medijana:** centralna vrijednost (cijena) u nizu
= **\$300,000**

- **Modus:** najčešća vrijednost (cijena)
= **\$100,000**

Mjere Skale	Prosjek	Medijana	Modus
Racio	+	+	(+)
Intervalna	+	+	(+)
Ordinalna	(-)	+	+
Nominalna	-	-	+

Varijacija

- Mjere varijacije – mjere koje opisuju „rasprostranjenost“ (disperziju) podataka.
 - Raspon
 - Interkvartalni raspon
 - Varijansa
 - Standardna devijacija

Mjere varijacije

Raspon - X_{max} - X_{min}


- Zavisi od ekstremnih vrijednosti; distribucija nevažna; problem velikog uzorka

Varijansa – prosječno kvadratno odstupanje od prosjeka


Standardna devijacija - kvadratni korijen iz varijanse

- Najčešće korišćena mjera
- Izražena u jedinicama kao i originalni podaci
- Empirijsko pravilo: +- 1SD (68%)
 - +- 2SD (95%)
 - +- 3SD (99.7%)
- Z- skor (standardizovano odstupanje)

Mjere varijacije



- Mjere varijacije daju informaciju o **disperziji ili varijabilnosti** vrijednosti obilježja, odnosno podataka.




Isti centar,
različita varijacija

Raspon

- Najjednostavnija mјera varijacije
- Razlika između najveće i najmanje vrijednosti obilježja u statističkoj seriji:


$$\text{Raspon} = X_{\max} - X_{\min}$$

Primjer:



Nedostaci raspona

- Ignoriše se distribucija podataka



- Osjetljiv na outlier-e

1,1,1,1,1,1,1,1,1,1,1,1,1,2,2,2,2,2,2,2,2,3,3,3,3,4,5


Raspon = 5 - 1 = 4

1,1,1,1,1,1,1,1,1,1,1,1,1,2,2,2,2,2,2,2,2,3,3,3,3,4,120


Raspon = 120 - 1 = 119

Nedostaci raspona

- Gubi smisao kod jako velikih uzoraka
- Ove 2 distribucije imaju isti raspon.
- Koliko vam raspon govori o varijabilnosti podataka?



a. Cost estimator A



b. Cost estimator B

Copyright © 2005 Pearson Prentice Hall, Inc.

Varijansa

- Prosječno (približno) kvadratno odstupanje vrijednosti obilježja od aritmetičke sredine

– Uzoračka varijansa:

$$S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n - 1}$$

Đe je:

\bar{X} = aritmetička sredina

n = veličina uzorka

X_i = i^{ta} vrijednost varijable X

Standardna devijacija

- Najčešće korišćena mjera varijacije
- Pokazuje varijaciju oko aritmetičke sredine
- Izračunava se kao kvadratni koren iz varijanse
- Iskazuje se u **istim jedinicama kao i originalni podaci**
 - Standardna devijacija u uzorku:

$$S = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n - 1}}$$

Interpretiranje standardne devijacije

- Koliko opservacija se nalazi u intervalu $\pm n s$ od aritmetičke sredine?

$1+1s$ ili $1+1\sigma$

$1+2s$ ili $1+2\sigma$

$1+3s$ ili $1+3\sigma$

Empirijsko pravilo


približno 68%

približno 95%

približno 99.7%



Empirijsko pravilo (pravilo 3σ)

- Ako podaci imaju distribuciju u obliku zvona, onda interval:
- $\mu \pm 1\sigma$ sadrži oko 68% vrijednosti obilježja u populaciji ili u uzorku




Empirijsko pravilo (pravilo 3σ)

- $\mu \pm 2\sigma$ sadrži oko 95% vrijednosti obilježja u populaciji ili u uzorku
- $\mu \pm 3\sigma$ sadrži oko 99.7% vrijednosti obilježja u populaciji ili u uzorku



Mjerenje varijacije


Mala standardna devijacija
Velika standardna devijacija



Tipovi distribucije


„Iskrivljena“ uljevo

Prosjek < Medijana




Normalna

Prosjek = Medijana



„Iskrivljena“ udesno

Prosjek > Medijana



Vježba I

Populacija za vrijednost aritmetičke sredine ima 30 i standardnu devijaciju 5.

Ukoliko dodamo vrijednost 5 svakom skoru u populaciji, koja bi bila nova vrijednost aritmetičke sredine i standardne devijacije?

Ukoliko svaki skor u populaciji pomnožimo sa 3, koja bi bila nova vrijednost aritmetičke sredine i standardne devijacije?

Vježba I

Populacija za vrijednost aritmetičke sredine ima 30 i standardnu devijaciju 5.

Ukoliko dodamo vrijednost 5 svakom skoru u populaciji, koja bi bila nova vrijednost aritmetičke sredine i standardne devijacije?

Arit. Sredina: 35 **Stand. devijacija:** 5

Ukoliko svaki skor u populaciji pomnožimo sa 3, koja bi bila nova vrijednost aritmetičke sredine i standardne devijacije?

Arit. Sredina: 90 **Stand. devijacija:** 15

Vježba II

Istraživač analizira donacije građana prema političkim partijama u zemlji X. Za populaciju od 6 partija izračunaj: aritmetičku sredinu, medijanu, modus, raspon i standardnu devijaciju.

Napomena: jedinica numeričke vrijednosti izražena je u „1.000 eura.“

Vrijednost donacija: 11, 0, 2, 9, 9, 5

Vježba II

Arit. sredina:

Medjana:

Modus:

Vježba II

Arit. sredina:

$$(11+0+2+9+9+5)/6 = 36/6 = 6$$

U prosjeku, partije u zemlji X su primile 6.000 eura donacija od strane građana.

Medijana:

11, 9, 9, 5, 2, 0; niz ima paran broj vrijednosti

Dvije središnje vrijednosti su 9 i 5. Medijanu u ovom slučaju dobijamo iz aritmetičke sredine ova dva broja.

Vrijednost medijane je: 7

Modus:

Donacija: 11 0 2 **9** 5

Frekvenc.: 1 1 1 2 1

Vježba III

Vrijednost donacije: 11, 0, 2, 9, 9, 5

Raspon:

Varijansa: $(SS = \sum(X - \mu)^2)/N$

Standardna devijacija: korijenovana varijansa = 4

Vježba III

Vrijednost donacije: 11, 0, 2, 9, 9, 5

Raspon:

$$11 - 0 = 11$$

Varijansa: $(SS = \Sigma(X - \mu)^2)/N$

$$\begin{aligned} SS &= (11 - 6)^2 + (0 - 6)^2 + (2 - 6)^2 + (9 - 6)^2 + (9 - 6)^2 + (5 - 6)^2 \\ &= 25 + 36 + 16 + 9 + 9 + 1 = 96 \end{aligned}$$

$$\text{Var} = 96/6 = 16$$

Standardna devijacija: korijenovana varijansa = 4

Izračunavanje stand. dev.

- Korak 1: Pronađi aritmetičku sredinu.
- Korak 2: Od svake pojedinačne vrijednosti oduzmi aritmetičku sredinu (devijaciju).
- Korak 3: Kvadriraj svaku pojedinačnu devijaciju od aritmetičke sredine.
- Korak 4: Saberi sve kvadrirane devijacije.
- Korak 5: Podijeli sa brojem opservacija (veličinom populacije).
- Korak 6: Izračunaj kvadratni korijen iz dobijene vrijednosti.