

Numeričke karakteristike obilježja

Numeričke karakteristike obilježja

- Pokazatelji centralne tendencije
- Pokazatelji rasipanja oko centralnih vrijednosti
- Pokazatelji oblika raspodjele

Pokazatelji centralne tendencije

- Aritmetička sredina za negrupisane podatke

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$$

- Aritmetička sredina za grupisane podatke

$$\bar{x} = \frac{\sum_{i=1}^k x_i f_i}{\sum_{i=1}^k f_i}$$

Primjer

- Aritmetička sredina je $(1*5+3*6+\dots+3*10)/19=151/19=7,947$

Ocjene	Apsolutne frekvencije
x_i	f_i
5	1
6	3
7	4
8	2
9	6
10	3

- Aritmetička sredina je $(3*7+7*11+\dots+2*27)/30=474/30=15.8$

Broj stabala	Apsolutne frekvencije
l_i	f_i
[5, 9)	3
[9, 13)	7
[13, 17)	9
[17, 21)	5
[21, 25)	4
[25, 29)	2

Medijana

- Za obilježje X medijana M_e je vrijednost takva da je jednak broj vrijednosti obilježja koja su manja od medijane i onih koja su veća od medijane.
- Populaciju čini 19 studenata, a registruju se njihove ocjene iz statistike. Dobijeni su podaci: 6, 7, 6, 8, 9, 7, 9, 9, 10, 9, 7, 10, 6, 9, 10, 5, 7, 8, 9. ($M_e=8$)

Neparan broj podataka: $M_e = x_{\frac{n+1}{2}};$

Paran broj podataka: $M_e = \frac{x_{\frac{n}{2}} + x_{\frac{n}{2}+1}}{2};$

Medijalni interval

- L_{me} , donja granica medijalnog intervala
- K_{me} , redni broj medijalnog intervala
- f_{me} , frekvencija medijalnog intervala
- d_{me} , širina medijalnog intervala

$$M_e = L_{me} + \frac{\frac{N}{2} - \sum_{i=1}^{K_{me}-1} f_i}{f_{me}} \cdot \Delta$$

Primjer

- Obim populacije $N=10+14+\dots+2=100$

Prodato(kom)	Br. prodavnica
0,1 - 25	10
25,1 - 50	14
50,1 - 75	40
75,1 - 100	24
100,1 - 125	10
125,1 - 150	2

← Medijalni interval

$$M_e = L_m + \frac{\frac{n}{2} - K_{m-1}}{f_m} \cdot \Delta = 50 + \frac{50 - 24}{40} \cdot 25 = 66,25$$

Mod

- Mod M_o obilježja X je vrijednost koja se najčešće pojavljuje u nizu podataka. Za podatke 0, 2, 1, 0, 0, 7, 3, 2, 1, 0 mod je $M_o = 0$. Skup podataka 6, 7, 6, 8, 9, 7, 10, 9, 10, 6, 10, 5, 7, 8, 9 ima četiri moda 6, 7, 9, 10. Skup podataka 1, 2, 3, 4, 5, 6 nema mod.
- Za grupisane podatke odredi se modalni interval – interval čija je frekvencija najveća

$$M_o = L_m + \frac{f_m - f_{m-1}}{(f_m - f_{m-1}) + (f_m - f_{m+1})} \cdot \Delta$$

Primjer

Prodato(kom)	Br. prodavnica
0,1 - 25	10
25,1 - 50	14
50,1 - 75	40
75,1 - 100	24
100,1 - 125	10
125,1 - 150	2

← Modalni interval

$$M_o = L_m + \frac{f_m - f_{m-1}}{(f_m - f_{m-1}) + (f_m - f_{m+1})} \cdot \Delta$$
$$= 50 + \frac{40 - 14}{(40 - 14) + (40 - 24)} \cdot 25 = 65,47619 \approx 65,48$$

Primjer

- Da li je New York bogata država? Prosječan prihod u državi New York je osmi po redu među američkim državama, blizu susjednog Connecticuta i New Jerseyua, koje su prva i druga po redu. Međutim, dok su medijane prihoda u državama Connecticut i New Jersey treća i peta po redu, New York je na 27. mjestu.

Kvantili

- Za obilježje X kvantil reda p , u oznaci M_p , dijeli niz vrijednosti obilježja y_1, y_2, \dots, y_N u odnosu $100p\%$ prema $100(1-p)\%$, odnosno $100p\%$ je manje od M_p , a $100(1-p)\%$ je veće od M_p .
 - Medijana je kvantil reda 0.5
- Kvartili
 - $Q_1 = M_{0.25}$
 - $Q_2 = M_{0.5}$
 - $Q_3 = M_{0.75}$
 - Intervali $(-\infty, Q_1), (Q_1, Q_2), (Q_2, Q_3), (Q_3, \infty)$ sadrže po 25% populacije
- Slično se definišu kvintili, decili itd.

Primjer

- Odrediti kvartile za skup podataka: 0, 1, 1, 3, 0, 0, 0, 1, 2, 3, 4, 1, 1, 0, 0, 2, 3.
 - Poređati podatke po veličini: 0, 0, 0, 0, 0, 0, 1, 1, 1, 1, 1, 2, 2, 3, 3, 3, 4
 - Medijana 9. po redu, $Q_2 = 1$
 - Prvi kvartil je sredina 4. i 5. podatka, $Q_1 = 0$
 - Treći i četvrti kvartil je sredina 13. i 14. podatka, $Q_3 = 2.5$

Kvantilni interval

- Kvantilni interval je prvi interval čija je kumulativna frekvencija veća ili jednaka od $N \cdot p$
 - L_p donja granica kvantilnog intervala
 - F_{p-1} kumulativna frekvencija intervala prije kvantilnog
 - f_p frekvencija kvantilnog intervala
 - d_p širina kvantilnog intervala

$$P_i = L_p + \frac{i \cdot \frac{N}{100} - \sum_{i=1}^{K_p-1} f_i}{f_p} \cdot \Delta$$

Primjer

- Odrediti kvartile

- Za $p=0.25$, $Np=575*0.25=143.75$, pa prvi kvartil pripada interval $[0,10)$,
 $Q_1=0+((143.75-0)*10)/229=6.277$
- $Q_2=12.773$
- $Q_3=19.585$

I_i	f_i	x_i	F_i
$[0,10)$	229	5	229
$[10,20)$	211	15	440
$[20,30)$	93	25	533
$[30,40)$	35	35	568
$[40,50)$	7	45	575
Σ	575		


Box & Whiskers grafik

- Ovaj grafik formira se na sljedeći način

- Odredi se medijana
- Odrede se prvi i treći kvartil
- Odrese se najveća i najmanja vrijednost
- Na liniju se ucrataju svi ovi podaci, oko kvartila se nacrtava pravougaonik, medijana se označi vertikalnom linijom, a povuku se i linije do ekstremnih vrijednosti

- Dat je skup podataka:

- V1: -10 1 2 3 4 5 6 7 8 9 10 11
- V2: 1 2 3 4 5 6 7 8 9 10 11 20
- V3: 1 2 3 4 5 6 7 8 9 10 11 20 28




Pokazatelji rasipanja, disperzije


- Raspon populacije je razlika između najveće i najmanje vrijednosti obilježja
- Interkvartilni razmak, $IQR = Q3 - Q1$
- Srednje apsolutno odstupanje
- Disperzija, varijansa, srednje kvadratno odstupanje
- Standardna devijacija, kvadratni korijen iz disperzije
- Koeficijent varijacije, $\sigma/m * 100\%$

Pokazatelji oblika raspodjele

- $m \leq M_e \leq M_o$



- $M_o \leq M_e \leq m$



Pravilo tri sigme

- Čebiševljeva teorema - procenat od ukupnog broja podataka unutar intervala $m \pm k\sigma$, pri čemu je k konstanta, barem $1 - 1/k^2$
 - Za proizvoljni skup podataka s aritmetičkom sredinom m , te standardnom devijacijom σ , procenat ukupnog broja podataka unutar intervala $m \pm 2\sigma$ je barem 75%, $m \pm 3\sigma$ je barem 89%
 - Za podatke iz normalne raspodjele

σ	68,26894921371%
2σ	95,44997361036%
3σ	99,73002039367%
4σ	99,99366575163%
5σ	99,99994266969%
6σ	99,9999980268%
7σ	99,9999999974%

z-score

- Standardizacija vrijednosti obilježja, $z = (x - m)/\sigma$
- Ako neka vrijednost ima veliki, pozitivan z-score znači da je veća od većine vrijednosti tog obilježja
- Ako neka vrijednost ima mali, negativan z-score znači da je manja od većine vrijednosti tog obilježja
- Ako je z-score = 0, onda je ta vrijednost aritmetička sredina
- Vrijednosti obilježja koje imaju z-score između -2 i -1 nalaze se u intervalu $(m-2\sigma, m-\sigma)$