Apsolutne mjere disperzije

Pošto je prosjek odstupanja pojedinih vrijednosti obilježja od aritmetičke sredine jednak nuli, možemo uzeti kao mjeru disperzije prosjek kvadrata odstupanja, koja se naziva **varijansom**.

Za seriju negrupisanih podataka izračunava se kao:

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

A za grupisane podatke:

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

1

Apsolutne mjere disperzije

Obrazac za izračunavanje varijanse za grupisane podatke daljim raščlanjivanjem svodimo na sledeći obrazac:

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

2

Apsolutne mjere disperzije

Standardna devijacija za negrupisane podatke dobija se kao:

$$\sigma = \sqrt{\frac{1}{N}\sum_{i=1}^{N} x_i^{\,2} - \bar{x}^{2}}$$

Standardna devijacija za grupisane podatke izračunava se kao:

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

3

Data je tabela

Iznos mjesečne stipendije	Broj studenata
5,51 – 6,5	175
6,51 – 7,5	195
7,51 – 8,5	145
8,51 – 9,5	135
9,51 – 10,5	185
10,51 – 11,5	215
11,51 – 12,5	275
12,51 – 13,5	280
UKUPNO:	1605

Izračunati varijansu

Iznos mjesečne stipendije	Broj studenata				
5,51 – 6,5	175				
6,51 – 7,5	195				
7,51 – 8,5	145				
8,51 – 9,5	135				
9,51 – 10,5	185				
10,51 – 11,5	215				
11,51 – 12,5	275				
12,51 – 13,5	280				
UKUPNO:	**1605**				

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

Iznos mjesečne stipendije	Broj studenata	x'	$\bar{X}$-Xi	($\bar{X}$-Xi)^2	F*($\bar{X}$-Xi)^2
5,51 – 6,5	175	6			
6,51 – 7,5	195	7			
7,51 – 8,5	145	8			
8,51 – 9,5	135	9			
9,51 – 10,5	185	10			
10,51 – 11,5	215	11			
11,51 – 12,5	275	12			
12,51 – 13,5	280	13			
UKUPNO:	**1605**				

$\bar{x} = 9{,}93$

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

Iznos mjesečne stipendije	Broj studenata	x'	$\bar{X}$-Xi	($\bar{X}$-Xi)^2	F*($\bar{X}$-Xi)^2
5,51 – 6,5	175	6	-3,93		
6,51 – 7,5	195	7	-2,93		
7,51 – 8,5	145	8	-1,93		
8,51 – 9,5	135	9	-0,93		
9,51 – 10,5	185	10	0,07		
10,51 – 11,5	215	11	1,07		
11,51 – 12,5	275	12	2,07		
12,51 – 13,5	280	13	3,07		
UKUPNO:	**1605**				

$\bar{x} = 9,93$

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

Iznos mjesečne stipendije	Broj studenata	x'	$\bar{X}$-Xi	($\bar{X}$-Xi)^2	F*($\bar{X}$-Xi)^2
5,51 – 6,5	175	6	-3,93	15,48	
6,51 – 7,5	195	7	-2,93	8,61	
7,51 – 8,5	145	8	-1,93	3,74	
8,51 – 9,5	135	9	-0,93	0,87	
9,51 – 10,5	185	10	0,07	0,00	
10,51 – 11,5	215	11	1,07	1,14	
11,51 – 12,5	275	12	2,07	4,27	
12,51 – 13,5	280	13	3,07	9,40	
UKUPNO:	**1605**				

$\bar{x} = 9,93$

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

Iznos mjesečne stipendije	Broj studenata	x'	$\bar{X}$-Xi	($\bar{X}$-Xi)^2	F*($\bar{X}$-Xi)^2
5,51 – 6,5	175	6	-3,93	15,48	2709,16
6,51 – 7,5	195	7	-2,93	8,61	1679,29
7,51 – 8,5	145	8	-1,93	3,74	542,68
8,51 – 9,5	135	9	-0,93	0,87	117,91
9,51 – 10,5	185	10	0,07	0,00	0,79
10,51 – 11,5	215	11	1,07	1,14	244,05
11,51 – 12,5	275	12	2,07	4,27	1173,14
12,51 – 13,5	280	13	3,07	9,40	2631,10
UKUPNO:	**1605**				**9098,13**

$\bar{x} = 9,93$

$$\sigma^2 = \frac{1}{N}\sum_{i=1}^{k} f_i\left(x_i - \bar{x}\right)^2 = \frac{9098,13}{1605} = 5,67$$

Iznos mjesečne stipendije	Broj studenata	x'	x^2	f*x^2
5,51 – 6,5	175	6		
6,51 – 7,5	195	7		
7,51 – 8,5	145	8		
8,51 – 9,5	135	9		
9,51 – 10,5	185	10		
10,51 – 11,5	215	11		
11,51 – 12,5	275	12		
12,51 – 13,5	280	13		
UKUPNO:	1605			

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

Iznos mjesečne stipendije	Broj studenata	x'	x^2	f*x^2
5,51 – 6,5	175	6	36	
6,51 – 7,5	195	7	49	
7,51 – 8,5	145	8	64	
8,51 – 9,5	135	9	81	
9,51 – 10,5	185	10	100	
10,51 – 11,5	215	11	121	
11,51 – 12,5	275	12	144	
12,51 – 13,5	280	13	169	
UKUPNO:	1605			

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

Iznos mjesečne stipendije	Broj studenata	x'	x^2	f*x^2
5,51 – 6,5	175	6	36	6300
6,51 – 7,5	195	7	49	9555
7,51 – 8,5	145	8	64	9280
8,51 – 9,5	135	9	81	10935
9,51 – 10,5	185	10	100	18500
10,51 – 11,5	215	11	121	26015
11,51 – 12,5	275	12	144	39600
12,51 – 13,5	280	13	169	47320
UKUPNO:	1605			167505

$$\sigma^2 = \frac{1}{N}\sum_{i=1}^{k} f_i x_i^2 - \bar{x}^2 = \frac{167505}{1605} - 9,93^2 = 5,67$$

Relativne mjere disperzije

U relativne mjere disperzije ubrajaju se :

- **koeficijent varijacije,**
- **koeficijenti interkvartalne varijacije,**
- **standardizovan ili normalizovano odstupanje.**

Relativne mjere disperzije

Odnos standardne devijacije i aritmetičke sredine naziva se koeficijentom varijacije.

$$V = \frac{\sigma}{\overline{\overline{X}}}$$

Izračunati koeficijent varijacije iz prethodnog zadatka

$$V = \frac{\sigma}{\overline{\overline{X}}} = \frac{\sqrt{5,67}}{9,93} = 0,2397 = 23,97\%$$

Relativne mjere disperzije

Što je koeficijent varijacije veći, odstupanje je veće. Za serije čiji su svi članovi jednaki, koeficijent varijacije biće jednak 0.

Pošto je ovaj koeficijent relativna mjera, koristi se za poređenje raspršenosti serija čije mjerne jedinice nijesu iste.

Relativne mjere disperzije

Za upoređivanje disperzije više skupova ili uzoraka upotrebljava se i **koeficijent interkvartilne varijacije**, čiji obrazac glasi:

$$V_Q = \frac{Q_1 - Q_3}{Q_1 + Q_3}$$

Relativne mjere disperzije

Ovaj koeficijent može imati vrijednost od 0 do 1, odnosno od 0 do 100 % ako je iskazan u procentima.

Ukoliko se približava nuli disperzija je relativno manja a ukoliko se približava jedinici disperzija je relativno veća.

Relativne mjere disperzije

Kad se odstupanje aritmetičke sredine od bilo koje vrijednosti obilježja izražava u jedinicama standardne devijacije dobija se tzv. **normalizovano ili standardizovano dostupanje.**

$$Z = \frac{X - \overline{X}}{\sigma}$$

Relativne mjere disperzije

Standardizovano odstupanje predstavlja opštu mjeru odstupanja individualnih podataka od aritmetičke sredine.

Uzorak i statistike uzorka

Potpune informacije o karakteristikama osnovnog skupa daje samo statistički popis.

Popis se ne može sprovesti kada je osnovni skup neograničen (beskonačan), a njegovo izvršenje je besmisleno kada prikupljanje podataka znači uništenje svih jedinica skupa.

Zbog toga se popis zamjenjuje jednim drugim metodom za ispitivanje osnovnog skupa – metodom uzorka.

Uzorak i statistike uzorka

Uzorak je dio osnovnog skupa, a svrha njegovog izbora je da se u što kraćem vremenu i sa što manjim troškovima dobije valjana informacija o karakteristikama cijelog skupa iz kojeg uzorak potiče.

Uzorak i statistike uzorka

Izbor uzorka

Uzorak mora biti reprezentativan da bi zaključci o karakteristikama osnovnog skupa bili realni.

Uzorak je reprezentativan ako je po svojoj strukturi sličan osnovnom skupu.

Uzorak i statistike uzorka

Postoji više metoda za izbor uzorka iz osnovnog skupa:

1. Prema načinu izbora, uzorke dijelimo na dvije osnovne grupe:

- **Slučajne (probabilističke) uzorke.**
- **Namjerne (neprobabilističke) uzorke.**

Uzorak i statistike uzorka

Ako prilikom izbora elemenata u uzorak svi elementi osnovnog skupa imaju unaprijed poznatu vjerovatnoću da budu izabrani, i ako je ta vjerovatnoća različita od 0, takav uzorak nazivamo **slučajnim**.

Svi ostali metodi izbora uzorka su poznati kao neslučajni, a tako izabrani uzorci kao **namjerni.**

Uzorak i statistike uzorka

Namjerni uzorak formira se od jedinica skupa koje biramo po ličnom uvjerenju kao tipične ili reprezentativne za dati osnovni skup.

U namjerne uzorke spadaju uzorci formirani na osnovu:

- **Subjektivnog suda istraživača**
- **Kvota uzorci**
- **Pogodni uzorci**

Uzorak i statistike uzorka

Ako istraživač po svom nahođenju bira svaku jedinicu uzorka, vjerujući da je takav uzorak reprezentativan za cijeli osnovni skup, on formira tzv. **uzorak zasnovan na subjektivnom sudu.**

Uzorak i statistike uzorka

Za izbor kvota uzorka prisutna su određena ograničenja.

Struktura uzorka mora da odgovara cilju istraživanja i da odražava strukturu skupa.

Uzorak i statistike uzorka

Pogodni uzorci formiraju se od jedinica skupa čiji je izbor pogodan. Često se koriste u ispitivanju javnog mnjenja, ali su rijetko reprezentativni.

Uzorak i statistike uzorka

Principi teorije uzoraka se ne mogu primjenjivati na namjerne uzorke. Namjerni uzorak je prikladan za takozvana pilot istraživanja.

Uzorak i statistike uzorka

Predmet statističkog izučavanja su uglavnom **<u>slučajni uzorci</u>** jar samo za njih postoje statistički metodi čijom primjenom donosimo zaključak o osnovnom skupu i istovremeno objektivno ocjenjujemo prihvatljivost našeg zaključka.

Među slučajnim uzorcima najreprezentativniji je **<u>prost slučajan uzorak</u>.**

Uzorak i statistike uzorka

- **Prost slučajan uzorak**
- **Kontrolisani slučajni uzorak**
- **Stratifikovani uzorak**
- **Uzorak skupina i višeetapni uzorak**
- **Sistemski uzorak**