

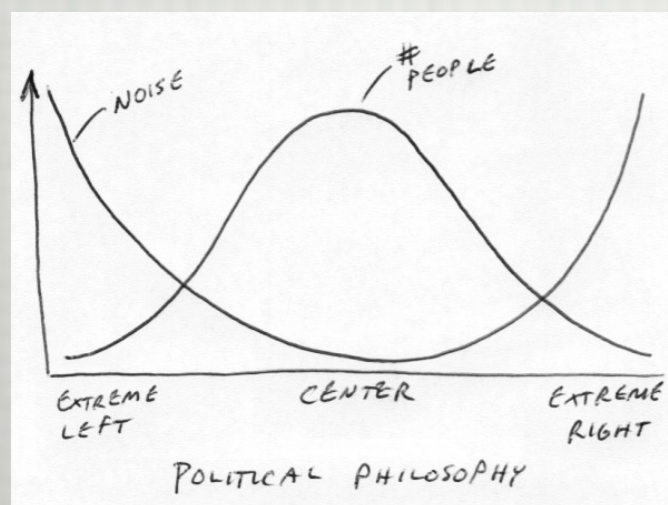
STATISTIKA I OSNOVE FIZIKALNIH MJERENJA

ŽELJKO SKOKO

PREDAVANJA: PONEĐJELJAK, 13-15 h, F25

VJEŽBE: PONEĐJELJAK, 15-16 h, F25

TEODORO KLASER



KONZULTACIJE: prema dogovoru
e-mail: zskoko@phy.hr
soba 224, tel.: 4605 518

STATISTIKA I OSNOVE FIZIKALNIH MJERENJA

LITERATURA:

WALPOLE ET AL.: Probability & Statistics For Engineers & Scientists; Pearson, Prentice Hall, 2007.

I. ŠOŠIĆ, V. SERDAR: Uvod u Statistiku; ŠK, Zagreb 1994. (Ekonomski fakultet).

V. VRANIĆ: Vjerojatnost i statistika, Tehnička knjiga, Zagreb 1971.

I. PAVLIĆ: Statistička teorija i primjena, Tehnička knjiga, Zagreb 1970 (Strojarski fakultet).

N. SARAPA: Teorija vjerojatnosti, ŠK, Zagreb 1992. (PMF-MO)

D. UGRIN-ŠPARAC: Primijenjena teorija vjerojatnosti I., II., Sveučilišna naklada - Liber, Zagreb, 1975/1976. (FER).

STATISTIKA I OSNOVE FIZIKALNIH MJERENJA

<http://www.phy.pmf.unizg.hr/~zskoko/>

- nastavni materijali
- obavijesti
- ispitna pitanja
- terminni ispita, rezultati
- itd...

Pravila kolegija:

- predavanja nisu obavezna ali iskustvo pokazuje da su vrlo korisna kod polaganja ispita
- u toku semestra bit će održana 2 kolokvija (neobavezna)
- ukoliko je zbroj na oba kolokvija veći od 50% oslobađanje pismenog dijela ispita
- ukoliko kolokviji nisu položeni obavezan je izlazak na pismeni dio ispita (zadaci kao na vježbama)
- usmeni dio ispita je obavezan (pitanja na webu)
- usmeni: tri teorijska pitanja, na svako barem nešto odgovoriti
- zadaće nose dodatne bodove
- ispitni rokovi u lipnju (2x), rujnu (2x), studenom (1x), veljači (2x)
- prolaznost: ak. god. 2017/2018 položilo 25 od 54 studenata (46%)
(ak. god. 2016/17 - 71%)

ČEMU SLUŽI TEORIJA VJEROJATNOSTI I STATISTIKA

- ◆ IGRE NA SREĆU
- ◆ POLITIKA I MARKETING (DOVOLJANJE UZORAK < 0.1% POPULACIJE)
- ◆ GOSPODARSTVO
- ◆ ZDRAVSTVO
- ◆ GENETIKA
- ◆ FIZIKA
 - TEORIJSKA FIZIKA
 - STATISTIČKA FIZIKA
 - KVANTNA FIZIKA
 - EKSPERIMENTALNA FIZIKA
 - OBRADA REZULTATA MJERENJA - PROCJENA POGREŠAKA
 - PROVJERA HIPOTEZA

UVOD

- ◆ MNOŠTVO PODATAKA - Statistika nam daje metode za njihovo organiziranje i sažeto prikazivanje te izvlačenje zaključaka na osnovu informacija sadržanih u tim podacima
- ◆ Od latinskog "STATUS" - stanje, situacija
- ◆ Povijesno, državni interes - popis vojni obveznika u Kini, Perziji, Grčkoj...
- ◆ Državni zavod za statistiku <http://www.dzs.hr>
<http://www.dzs.hr/StatInfo/Zaposl.htm>
<http://www.dzs.hr/StatInfo/RADSNAGA.htm> (anketa na reprezentativnom uzorku)
- ◆ Primjeri u meteorologiji: <http://meteo.hr>

KOMBINATORIKA

(1) PERMUTACIJE BEZ PONAVLJANJA

- N RAZLIČITIH ELEMENATA A_1, \dots, A_n MOGUĆE JE POREDATI U NIZ NA VIŠE RAZLIČITIH NAČINA
- BROJ TIH NAČINA ZOVEMO PERMUTACIJE BEZ PONAVLJANJA
- ODABEREMO JEDAN ELEMENT \longrightarrow N IZBORA
- ODABEREMO SLJEDEĆI ELEMENT \longrightarrow N - 1 IZBORA
- ODABEREMO TREĆI ELEMENT \longrightarrow N - 2 IZBORA

$$P(N) = N \cdot (N-1) \cdot (N-2) \cdot \dots \cdot 2 \cdot 1 = N!$$

PO DEFINICIJI: $0! = 1$

Prímjer: Na koliko načina možemo poredati brojeve 1, 2 i 3?

123, 132, 213, 231, 312, 321 \longrightarrow 6 načina

$$P(3) = 3! = 3 \cdot 2 \cdot 1 = 6$$

(2) PERMUTACIJE S PONAVLJANJEM

- n elemenata unutar kojih je r_1, r_2, \dots, r_k jednakih

$$\sum_i r_i = n$$

- na koliko načina možemo poredati te elemente u niz?

- zamislimo da su svi elementi različiti; tada bi bilo $n!$ načina;

zamislimo da su svi elementi različiti osim njih r_1 \longrightarrow

permutacije tih istih elemenata ne pridonose ništa: $\frac{n!}{r_1!}$ načina

- ako su r_1 i r_2 elemenata isti: $\frac{n!}{r_1! r_2!}$ načina

OPĆENITO:

$$P_{r_1, r_2, \dots, r_k}^{(n)} = \frac{n!}{r_1! r_2! \dots r_k!}$$

Prímjer: Na koliko načina možemo poredati brojeve 1, 1 i 2?

1 1 2, 1 2 1, 2 1 1

3 načina

$$n = 3, r_1 = 2$$

$$P_2^{(3)} = \frac{3!}{2!} = 3$$

Prímjer: Na koliko načina možemo poredati slova a, a, b, b, b, c?

60 načina

$$n = 6, r_1 = 2, r_2 = 3$$

$$P_{2,3}^{(6)} = \frac{6!}{2!3!} = 60$$

Permutations:

{a, a, b, b, b, c} | {a, a, b, b, c, b} | {a, a, b, c, b, b} | {a, a, c, b, b, b} | {a, b, a, b, b, c} | {a, b, a, b, c, b} | {a, b, a, c, b, b} | {a, b, b, a, b, c} | {a, b, b, a, c, b} | {a, b, b, b, a, c} | {a, b, b, b, c, a} | {a, b, b, c, a, b} | {a, b, b, c, b, a} | {a, b, c, a, b, b} | {a, b, c, b, a, b} | {a, b, c, b, b, a} | {a, c, a, b, b, b} | {a, c, b, a, b, b} | {a, c, b, b, a, b} | {a, c, b, b, b, a} | {b, a, a, b, b, c} | {b, a, a, b, c, b} | {b, a, a, c, b, b} | {b, a, b, a, b, c} | {b, a, b, a, c, b} | {b, a, b, b, a, c} | {b, a, b, b, c, a} | {b, a, b, c, a, b} | {b, a, b, c, b, a} | {b, a, c, a, b, b} | {b, a, c, b, a, b} | {b, a, c, b, b, a} | {b, b, a, a, b, c} | {b, b, a, a, c, b} | {b, b, a, b, a, c} | {b, b, a, b, c, a} | {b, b, a, c, a, b} | {b, b, a, c, b, a} | {b, b, b, a, a, c} | {b, b, b, a, c, a} | {b, b, b, c, a, a} | {b, b, c, a, a, b} | {b, b, c, a, b, a} | {b, b, c, b, a, a} | {b, c, a, a, b, b} | {b, c, a, b, a, b} | {b, c, a, b, b, a} | {b, c, b, a, a, b} | {b, c, b, a, b, a} | {b, c, b, b, a, a} | {c, a, a, b, b, b} | {c, a, b, a, b, b} | {c, a, b, b, a, b} | {c, a, b, b, b, a} | {c, b, a, a, b, b} | {c, b, a, b, a, b} | {c, b, a, b, b, a} | {c, b, b, a, a, b} | {c, b, b, a, b, a} | {c, b, b, b, a, a} (total: 60)

☰ **WolframAlpha** 📄

permutations of {a,a,b,b,b,c} 📄 📷

Input interpretation

permutations {a, a, b, b, b, c}

Number of distinct permutations

60

(3) VARIJACIJE BEZ PONAVLJANJA

- n različitih elemenata A_1, \dots, A_n i želimo od njih stvoriti skup od r elemenata, s time da se isti element može pojaviti samo jednom i da je poredak elemenata važan!
- odaberemo prvi član skupa $\longrightarrow n$ načina
- odaberemo drugi član skupa $\longrightarrow n - 1$ načina
- ...
- odaberemo r -ti član skupa $\longrightarrow (n - r + 1)$
- slično kao kod permutacija bez ponavljanja

$$n(n-1)(n-2)\dots[n-(r-1)] = \frac{n!}{(n-r)!}$$

- iz binomnog poučka imamo:

$$(a+b)^n = \sum_{x=0}^n \binom{n}{x} a^{n-x} b^x; \quad \binom{n}{x} = \frac{n!}{(n-x)!x!}$$

VARIJACIJE BEZ PONAVLJANJA:

$$V_r^{(n)} = \frac{n!}{(n-r)!} = \frac{n!}{(n-r)!r!} \cdot r! = \binom{n}{r} \cdot r!$$

Prímjer: Na koliko načina možemo od brojeva 1, 2, 3, 4 formirati skupove od po dva broja, ali tako da se svaki broj može pojaviti samo jednom, i da je poredak brojeva u skupu važan?

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

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

12 NAČINA!

$$V_2^{(4)} = \frac{4!}{(4-2)!} = \frac{4!}{2!} = 12$$

(3) VARIJACIJE S PONAVLJANJEM

- n različítih elemenata A_1, \dots, A_n i želimo od njih stvoríti skup od r elemenata, poredak elemenata je važan, ístí element se može pojavíti više puta!
- odaberemo prvi član skupa $\longrightarrow n$ načína
- odaberemo drugi član skupa $\longrightarrow n$ načína
- ...
- odaberemo r -tí član skupa $\longrightarrow n$ načína
- slíčno kao í prije

$$n \cdot n \cdot n \cdot n \dots n = n^r \quad (r \text{ elemenata})$$

$$\bar{V}_r^{(n)} = n^r$$

Prímjer: Na koliko načina možemo od brojeva 1, 2, 3, 4 formirati skupove od po dva broja, tako da se svaki broj može pojaviti više puta, i da je poredak brojeva u skupu važan?

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

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

1 1, 2 2, 3 3, 4 4

16 NAČINA!

$$\bar{V}_2^{(4)} = 4^2 = 16$$

(5) KOMBINACIJE BEZ PONAVLJANJA

- n različitih elemenata slažemo u skupove veličine r , svaki element smije se u skupu pojaviti samo jednom, poredak nije važan
- isto kao i varijacije bez ponavljanja, samo što poredak nije važan

$$K_r^{(n)} = \frac{V_r^{(n)}}{r!} = \frac{n!}{r!(n-r)!} = \binom{n}{r}$$

Prímjér: Na koliko načina možemo od brojeva 1, 2, 3, 4 formirati skupove od po dva broja, tako da se svaki broj može pojaviti više puta, i da je poredak brojeva u skupu važan?

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

6 NAČINA!

$$K_2^{(4)} = \frac{4!}{2!(4-2)!} = \frac{4!}{2!2!} = \frac{4 \cdot 3 \cdot 2 \cdot 1}{2 \cdot 1 \cdot 2 \cdot 1} = 6$$

(6) KOMBINACIJE S PONAVLJANJEM

- n različitih elemenata slažemo u skupove veličine r , svaki element smije se u skupu pojaviti više puta, poredak nije važan
- isto kao i varijacije sa ponavljanjem, samo što poredak nije važan

$$\bar{K}_r^{(n)} = \binom{n+r-1}{r} = K_r^{(n+r-1)}$$

OSNOVNI STATISTIČKI POJMOVI

POPULACIJA - dobro definiran skup objekata koji nas zanima

Populacija može biti konačna ili beskonačna, realna ili hipotetska

Primeri:

1. svi zaposlenici na području Grada Zagreba u 2014.
2. svi stanovnici Republike Hrvatske 31. 03. 2014.
3. sve baterije proizvedene u nekoj tvornici u jednom mjesecu
4. svi mogući rezultati nekog mjerenja

Poznavanje cijele populacije - **CENZUS**

Cenzus rijetko možemo imati (preskupo ili neizvedivo)

OSNOVNI STATISTIČKI POJMOVI

UZORAK - podskup populácie koji uzímamo na unaprijed određen način

Prímjeri:

1. iz populácie svih studenata uzímamo samo jednu godinu
2. u skladištu opeka uzímamo jedan red
3. obavimo deset mjerenja mase nekog predmeta

VARIJABLA - obilježje čija vrijednost se može mijenjati od objekta do objekta

Možemo promatrati jedno obilježje (npr. visina studentata) pa govorimo o 1-D skupu podataka ili više obilježja. Npr. promatramo li visinu i težinu studenata, imat ćemo 2-D skup podataka.

STATISTIKA



Istraživač je sakupio podatke i želi ih organizirati, te sažeto opisati važna svojstva

Grafičke metode: histogrami, krivulje, kružni dijagrami...

Numeričke vrijednosti: prosjek, standardna devijacija, korelacijski koeficijent,...

Statističko zaključivanje

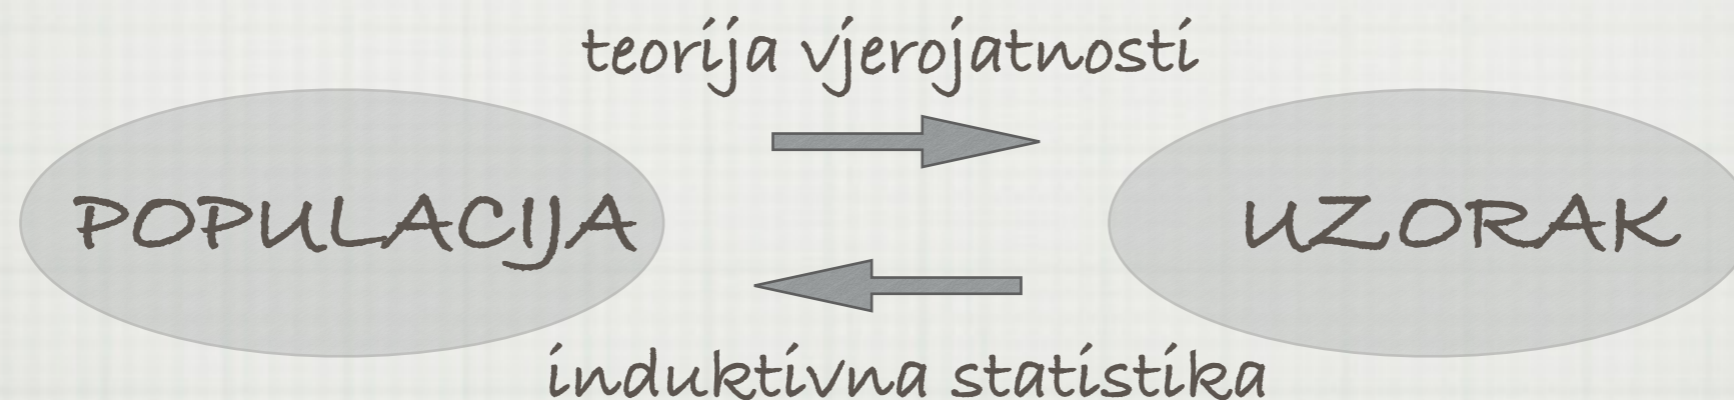
Istraživač je proučio uzorak i iz njegovih svojstava želi izvesti zaključke o cijeloj populaciji

Nužno je razumjeti neodređenosti povezane s uzimanjem uzorka iz populacije

STATISTIKA

TEORIJA VJEROJATNOSTI

pretpostavka - znamo svojstva populacije i želimo predvidjeti svojstva uzorka



U OVOM KOLEGIJU NAJPRIJE ĆEMO UKRATKO NAUČITI METODE OPISNE STATISTIKE, ZATIM ĆEMO PROUČAVATI TEORIJU VJEROJATNOSTI, I NAKON TOGA INDUKTIVNU STATISTIKU

METODE OPISNE STATISTIKE

GRAFIČKE I TABLIČNE METODE

S-L DIJAGRAM (STEM AND LEAF, STABLJKA I LIST)

primjer: Na 140 američkih koledža provedena je anketa o "tulum-pijanacima". Kao tulum-pijanac opisan je onaj student koji u nizu popije 4 ili više alkoholnih pića. Postotak tulum-pijanaca dan je u sljedećem popisu:

37	27	36	43	49	57
61	27	37	44	49	46
11	28	68	55	50	26
14	29	37	44	50	58
17	29	64	45	51	59
29	4	37	66	51	60
18	29	38	45	52	42
51	30	59	46	52	61
19	64	57	59	52	62
21	31	16	57	18	64
22	39	38	46	53	65
66	31	39	13	37	43
22	32	39	46	53	65
23	56	39	47	54	46
24	32	41	67	47	66
52	33	41	47	55	67
25	48	42	58	56	48
56	44	61	48	56	39
28	34	42	49	41	36
26	35	46	33	56	44
61	35	42	58	48	33
48	35	18	26	57	
26	36	27	38	38	
34	36	58	42	15	

S-L DIJAGRAM


Da bismo iz ove "šume" podataka stekli dojam o rasprostranjenosti pojave, izradujemo S-L dijagram:

1. odaberemo jednu ili više početnih znamenki za 'stabljiku'
2. u stupac popišemo sve moguće 'stabljike'
3. desno od svake stabljike popišemo sve pripadajuće 'listove'

0	4
1	1345678889
2	1223456666777889999
3	0112233344555666677777888899999
4	111222223344445566666677788888999
5	00111222233455666667777888899
6	01111244455666778

PRIKAZ POMOČU TOČKA

1. Nacrtamo díio brojevnog pravca koji obuhvaća sve moguće podatke
 2. Svako opažanje prikažemo točkom iznad odgovarajućeg položaja
- Za podatke iz gornjeg primjera točkasti prikaz izgleda ovako:



HISTOGRAMI

Postupak crtanja histograma različit je za diskretne i kontinuirane varijable

Diskretna varijabla - ona za koju je skup mogućih vrijednosti konačan ili prebrojiv

- najčešće se radi o prebrojavanju

Kontinuirana varijabla - skup mogućih vrijednosti jest cijeli interval na brojevnom pravcu

- najčešće rezultat mjerenja

PRIMJER DISKRETNE VARIJABLE

Starost djece koja se igraju u parku. varijabla je x = starost djeteta
Rezultati ankete za 48 djece (starost u godinama):

5	5	8	9
10	11	11	12
3	5	8	9
4	6	18	10
9	11	9	9
11	6	8	3
4	4	1	7
14	10	8	10
4	9	9	5
10	6	11	12
5	7	9	5
8	10	4	20

Moguće vrijednosti varijable x su 1, 2, 3, ..., 18, 19, 20,

Dakle, radi se o diskretnoj varijabli

FREKVENCIA

Def.: **Frekvencija** f_i neke određene vrijednosti x_i varijable X jest broj pojavljivanja te vrijednosti u promatranom skupu podataka.

vrijedi: $\sum_i f_i = N$, gdje je N broj svih podataka u skupu

Tablični prikaz svih frekvencija naziva se **raspodjela frekvencija** u našem primjeru raspodjela frekvencija izgleda ovako:


x_i	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
f_i	1	0	2	5	6	3	2	5	8	6	5	2	0	1	0	0	0	1	0	1

Def.: **Relativna frekvencija**, f_{ri} , neke određene vrijednosti x_i varijable X jest frekvencija podijeljena s ukupnim brojem podataka $N = \sum f_i$,

$$f_{ri} = \frac{f_i}{N}$$

U našem primjeru je $N = 48$ pa je raspodjela relativnih frekvencija dana tablicom:

x_i	f_{ri}	$f_{ri}(\%)$
1	0,0208	2,08
2	0	0,00
3	0,0417	4,17
4	0,1042	10,42
5	0,125	12,50
6	0,0625	6,25
7	0,0417	4,17
8	0,1042	10,42
9	0,1667	16,67
10	0,125	12,50
11	0,1042	10,42
12	0,0417	4,17
13	0	0,00
14	0,0208	2,08
15	0	0,00
16	0	0,00
17	0	0,00
18	0,0208	2,08
19	0	0,00
20	0,0208	2,08




Crtanje histograma

(za diskretnu raspodjelu):

1. odredimo frekvencije ili rel. frekvencije
2. na apscisi označimo moguće vrijednosti varijable x
3. nacrtamo pravokutnik visine f_i ili f_{ri}

"NAŠ" PRIMJER:



Konstrukcija histograma za kontinuiranu varijablu

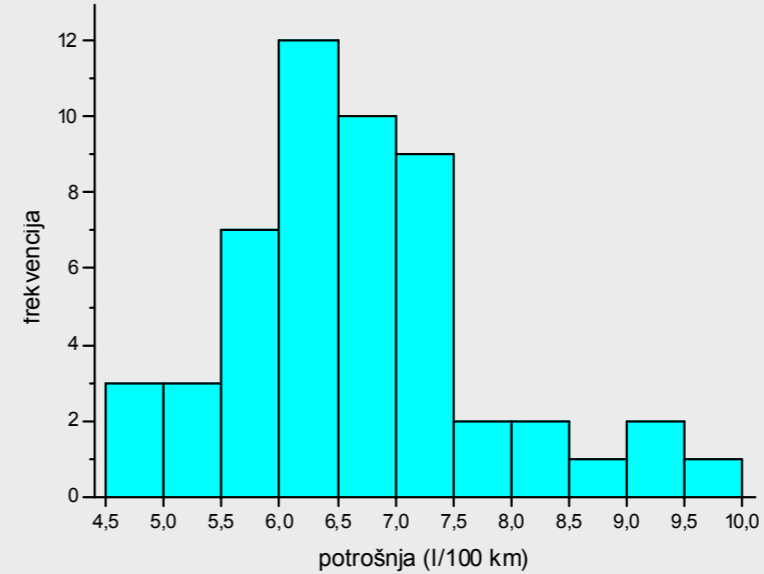
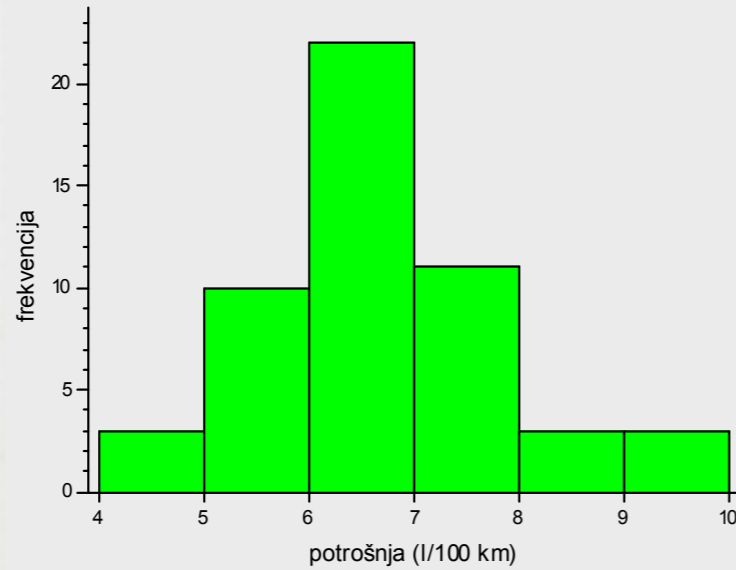
Primer: potrošnja benzina (u litrama na 100 km):

6,25	5,93	7,8	4,95	9,2	8,57
6,82	7,43	5,78	5,46	6,54	7,02
6,78	4,75	5,32	7,11	5,66	5,99
6,87	8,35	7,66	7,23	6,58	6,92
6,32	7,08	5,98	6,25	5,45	6,72
6,38	6,9	9,87	6,23	6,52	6,43
6,12	5,81	6,37	7,23	7,46	8,06
6,09	5,82	4,99	6,32	6,51	6,49
9,49	6,39				

Konstrukcija histograma:

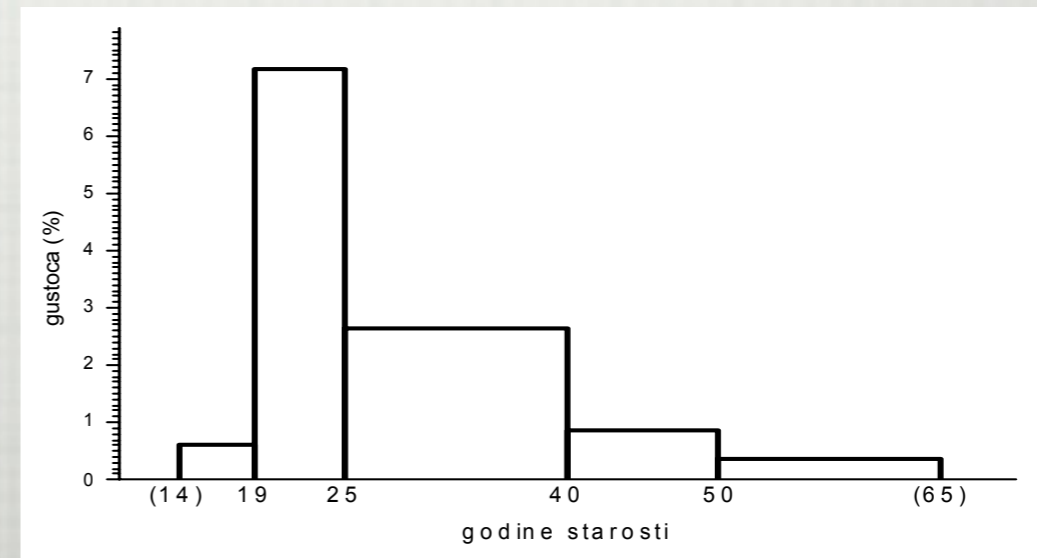
1. podijelimo apscisu na prikladan broj razreda (ekvidistantno ili ne)
2. odredimo frekvencije
3. crtamo pravokutnike
 - za ekvidistantne razrede visina = f_{ri}
 - za neekvidistantne razrede visina = $f_{ri}/\text{širina}$

Príklad potrošnje benzína - ekvidistantní razredi



Príklad neekvidistantních razreda:
osobe prijávljene zavodima za zapošljavanje, RH 1990:

dob	broj osoba (u tisućama)	f_{ri} (%)
(14)-19	6,1	3,12
19-25	84,0	42,99
25-40	77,5	39,66
40-50	16,6	8,50
50-(65)	11,2	5,73
UKUPNO	195,4	100,00



HISTOGRAMI - napomene:

- površina pravokutnika je frekvencija danog razreda
- ukupna površina relativnih frekvencija je 1

Prema obliku histogrami mogu biti:

- unimodalni
- bimodalni
- višemodalni

ili

- simetrični
- pozitivno nagnuti
- negativno nagnuti

MJERE POLOŽAJA

Grafičkim prikazom stekli smo impresiju, ali želimo izvući neke numeričke vrijednosti koji karakteriziraju skup podataka.


Neka se skup sastoji od brojeva x_1, x_2, \dots, x_n . Najprije nas zanima položaj i -tog elementa, posebno središte.

Neka skup x_1, x_2, \dots, x_n predstavlja uzorak iz veće populacije!

Def: Srednja vrijednost, \bar{x} , uzorka x_1, x_2, \dots, x_n dana je s:

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \sum_{i=1}^n x_i$$

Fizikalno značenje - težište!



Def: Srednju vrijednost populacije označavamo s μ

u induktivnoj statistici najčešće želimo procijeniti μ na osnovu uzorka

Najveći nedostatak srednje vrijednosti kao mjere položaja -
podliježe utjecaju ekstremnih vrijednosti u uzorku

Def: Medijan, $\tilde{\mu}$, određujemo tako da sva opažanja poredamo po veličini. Ako je broj opažanja neparan, medijan je vrijednost $([n+1]/2)$ -tog opažanja. Ako je broj opažanja paran, medijan je srednja vrijednost $(n/2)$ -tog i $(n/2+1)$ -tog opažanja

Kvartilí dijele skup opažanja na četiri dijela


Percentilí dijele skup opažanja na 100 dijelova

"Ošišani prosjek" - odbacimo jednak broj ekstrema s obje strane pa računamo srednju vrijednost

MJERE POLOŽAJA

uzorcí s ístím mjerama položaja (prosjeak, medíjan)
mogu se **bitno razlíkovatí**

Slíka príkazuje trí različíta skupa ístog prosjeka í medíjana:



Osím središta uzorka, zaníma nas í koliko je **raspršen**
Nájjednostavníja mjera raspršenja je:

Def: **Raspon uzorka** - razlíka ízmeđu najveće í
najmanje vríjednosti u uzorku

Mana: ovísí samo o ekstremíma

Def: Odstupanje od prosjeka pojedine vrijednosti u uzorku: $x_i - \bar{x}$

Želimo izraziti mjeru odstupanja u jednom broju

1. ideja: zbrojimo sva odstupanja: $\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})$

No, to je jednako nuli (pozitivna i negativna odstupanja se poništavaju)

2. ideja: zbrojimo apsolutne vrijednosti svih odstupanja: $\frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}|$

Timo dobivamo mjeru odstupanja, ali i znatne matematičke komplikacije

3. ideja: zbrojimo sve kvadrate odstupanja: $\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$

Def: varijanca uzorka: $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$

Def: standardna devijacija uzorka: $s = \sqrt{s^2}$

Pitanje! Zašto smo uzeli $n-1$, a ne n ?

Def: varijanca populacije:
(gdje je μ prosjek populacije)

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2$$

vrlo rijetko poznajemo μ pa pokušavamo iz uzorka odrediti μ i σ . No, prosječni kvadrat odstupanja $(x_i - \bar{x})^2$ u uzorku je manji od nepoznatog $(x_i - \mu)^2$. Da bismo to korigirali, u nazivnik izraza za varijancu stavljamo $n-1$ umjesto n . Na taj način možemo s pomoću varijance uzorka procijeniti varijancu populacije.

Korekcija dolazi zbog umanjenog broja stupnjeva slobode u uzorku.

To ćemo dokazati kasnije u semestru.