

Primijenjena i inženjerska matematika

Statistika - predavanja 1 i 2
Tipovi i opisivanje podataka

13.10.2023.





- **statistika** - riječ koja je u svakodnevnom životu vezana uz brojčane vrijednosti kojima pokušavamo opisati bitne karakteristike nekog skupa podataka
- Državni zavod za statistiku Republike Hrvatske (<http://www.dzs.hr/>):
 - *prosječna mjesecna isplaćena neto plaća po zaposlenome u pravnim osobama Republike Hrvatske za srpanj 2016. iznosila je 5594 kune*
 - *minimalna plaća za razdoblje od 1. lipnja 2012. do 30. lipnja 2012. u Republici Hrvatskoj iznosila je 2814 kuna*
 - *stopa registrirane nezaposlenosti za kolovoz 2016. iznosila je 13.1%*



- **statistika** - znanstvena disciplina koja se bavi razvojem metoda **prikupljanja, opisivanja i analiziranja** podataka te primjenom tih metoda u procesu **donošenja zaključaka** na temelju prikupljenih podataka
- **statističko istraživanje** - fokusirano na skup **objekata**, tj. **jedinki** (ljudi, životinja, biljaka, stvari, država, gradova, poduzeća, itd.) i skup odabranih veličina koje se na njima promatraju (skup **varijabli** ili **obilježja**)
- **populacija** - skup svih jedinki koje se žele obuhvatiti istraživanjem (o kojima se želi zaključivati)
- primjeri 1.1 i 1.2



Primjena statistike u istraživanju podrazumijeva:

- populaciju koja je predmet istraživanja potrebno je detaljno proučiti, zabilježiti njene osnovne karakteristike i ciljeve istraživanja, kreirati kvalitetan uzorak i odabrati metodu za prikupljanje podataka
- izabrati prikladne metode za opis skupa prikupljenih podataka (deskriptivna statistika)
- izabrati prikladne statističke metode za zaključivanje o populaciji na temelju prikupljenih podataka na uzorku (statističko zaključivanje)



U ovom čemo se kolegiju baviti:

- metodama prikupljanja podataka i kreiranja uzorka
- metodama deskriptivne statistike
- metodama statističkog zaključivanja

Populacija i uzorak



- **populacija** - skup svih jedinki koje su predmet istraživanja, tj. zadovoljavaju neka svojstva bitna za obilježje koje se istražuje
- **uzorak** - populacija može sadržavati vrlo velik broj jedinki i stoga je teško ili čak nemoguće istraživanje provesti na svim jedinkama populacije - tada odabiremo jedan podskup populacije na kojem je osigurano kvalitetno provođenje istraživanja, a kojeg nazivamo uzorak
- **reprezentativan uzorak** - uzorak u kojem su zastupljene sve tipične karakteristike populacije bitne za istraživanje
- **primjeri 2.1 i 2.2**
- **slučajan uzorak** - uzorak konstruiran u skladu sa zahtjevom da svaka jedinka populacije ima jednaku vjerojatnost (šansu) biti izabrana u uzorak



Izvori podataka

Način prikupljanja podataka ovisi o karakteristikama obilježja koje je predmet proučavanja:

- podaci iz javnih izvora (knjige, časopisi, novine, Internet)
- podaci iz dizajniranog eksperimenta (istraživač raspoređuje eksperimentalne jedinke u skupine nad kojima vrši eksperimente te bilježi podatke za varijable koje ga zanimaju)
- podaci iz ankete (istraživač sastavlja anketni upitnik, izabire skupinu ljudi koju anketira i na osnovu njihovih odgovora prikuplja podatke)
- podaci prikupljeni promatranjem (istraživač promatra eksperimentalne jedinke u njihovom prirodnom okruženju i bilježi podatke za varijable od interesa)
- primjer 2.3

Organizacija baze podataka



- baza podataka najčešće će biti organizirana u obliku tablice u kojoj svaki redak predstavlja jednu jedinku, a svaki stupac promatrane varijable
- **glukoza.sta**

↔↔↔



Tipovi varijabli - kvalitativne varijable

Kvalitativne (kategorijalne) varijable - varijable čije vrijednosti po svojim svojstvima nisu realni brojevi nego njihove vrijednosti svrstavamo u kategorije. Razlikujemo:

- **Kvalitativne nominalne varijable** - među kategorijama nema prirodnog poretku, npr.
 - boja očiju (plava, smeđa, zelena)
 - krvne grupe (A, B, AB, 0)
 - spol (m ili ž)
 - radna mjesta u školi (spremačica, domar, tajnik, nastavnik, pedagog, ravnatelj)
- **Kvalitativne ordinalne varijable** - među kategorijama postoji poredak, npr.
 - stručna spremna (SSS, VŠS, VSS)
 - opisne ocjene (ništa, malo, srednje, puno)



Tipovi varijabli - numeričke varijable

Numeričke varijable - varijable prirodno primaju vrijednosti iz skupa realnih brojeva, npr.

- postotak prolaznosti na pojedinim ispitima tijekom jedne akademske godine
- broj bodova na državnoj maturi iz matematike
- broj ulovljenih komaraca u klopu
- temperatura mora
- koncentracija soli u morskoj vodi
- kategorije kvalitativnih varijabli mogu se izražavati brojevima, no to ih ne čini numeričkim varijablama
- među numeričkim varijablama razlikujemo **diskretne i neprekidne** varijable

Tipovi varijabli - diskretne numeričke varijable



Diskretne numeričke varijable - mogu poprimiti samo konačno ili prebrojivo mnogo vrijednosti (vrijednosti možemo ispisati u niz), npr.

- broj djece
- broj bodova na državnoj maturi iz matematike
- broj ulovljenih komaraca u klopku
- broj dana u godini s temperaturom zraka većom od 35°C

Tipovi varijabli - neprekidne numeričke varijable



Neprekidne numeričke varijable - skup mogućih vrijednosti je cijeli skup realnih brojeva ili neki interval, npr.

- postotak prolaznosti na pojedinim ispitima u jednoj akademskoj godini
- temperatura nekog mora
- vodostaj neke rijeke
- u svrhu prikaza podataka i nekih statističkih analiza, vrijednosti numeričke varijable se također mogu svrstati u **kategorije**
- [primjer 2.8](#)
- [primjer 2.9](#)





Metode opisivanja kvalitativnih podataka

- kvalitativne varijable - primaju vrijednosti koje su razvrstane u kategorije
- pri proučavanju kvalitativnih varijabli pažnju usmjeravamo na zastupljenost pojedine kategorije u uzorku na kojem provodimo istraživanje
- **frekvencija kategorije, relativna frekvencija kategorije** - mjere kojima opisujemo zastupljenost jedne kategorije u uzorku

Primjer



primjer 3.1

ispitanik	spol	krvna grupa
1	Ž	A
2	Ž	B
3	M	0
4	Ž	0
5	M	AB
6	M	B
7	Ž	B
8	M	A
9	Ž	AB
10	Ž	A



Metode opisivanja kvalitativnih podataka

- neka varijabla, koju ćemo označiti X , ima k kategorija (recimo $k = 4$ znači da varijabla ima 4 kategorije - npr. krvne grupe)
- označimo pojedine kategorije kao x_1, x_2, \dots, x_k , odnosno, u drugom zapisu $\{x_i : i = 1, \dots, k\}$
- **frekvencija kategorije** x_i je broj izmјerenih vrijednosti varijable koje pripadaju kategoriji x_i , $i = 1, \dots, k$
- frekvenciju kategorije x_i označavamo f_i
- frekvencija pojedine kategorije ovisi o broju izvršenih mјerenja odnosno veličini uzorka



Metode opisivanja kvalitativnih podataka

- **relativna frekvencija (udio) kategorije** x_i je broj izmjerениh vrijednosti varijable koje pripadaju kategoriji x_i podijeljen s ukupnim brojem izmjerениh vrijednosti za promatranoj varijablu, $i = 1, \dots, k$
- ako je n veličina uzorka (broj svih izmjereniih vrijednosti promatrane varijable), relativnu frekvenciju kategorije x_i računamo kao

$$\frac{f_i}{n}$$

- relativna frekvencija kategorije je mjera zastupljenosti koja daje informaciju o udjelu kategorije u uzorku poznate dimenzije i često se izražava kao postotak



Metode opisivanja kvalitativnih podataka

- **tablično** - tablicom frekvencija i relativnih frekvencija ([primjeri 3.2 - 3.4](#))
- **grafički** - stupčastim dijagramom i kružnim dijagramom frekvencija i relativnih frekvencija ([primjeri 3.5 - 3.7](#))
- u tabličnom i grafičkom prikazu frekvencija i relativnih frekvencija trebaju biti zastupljene sve kategorije promatrane varijable





Metode opisivanja numeričkih podataka

Numeričke varijable mogu biti:

- **diskretne** - primaju konačno ili prebrojivo mnogo vrijednosti,
- **neprekidne** - vrijednost može biti bilo koji broj iz nekog intervala realnih brojeva ili bilo koji realan broj



Metode opisivanja numeričkih i ordinalnih podataka - diskretne numeričke i ordinalne varijable

Ako su varijable ordinalne ili ako su numeričke diskretne s malo mogućih vrijednosti, za opis izmjerениh vrijednosti tih varijabli možemo koristiti **iste metode kao pri opisivanju kvalitativnih podataka:**

- tablice frekvencija i relativnih frekvencija
- grafičke prikaze frekvencija i relativnih frekvencija - stupčasti i kružni dijagram
- primjer 3.8



Metode opisivanja numeričkih podataka - neprekidne numeričke varijable

- **neprekidne numeričke varijable** - za prikazivanje podataka iz takvih varijabli su frekvencije, stupčasti i kružni dijagrami napravljeni na osnovu svake pojedine izmjerene vrijednosti nepraktični
- primjer 3.9



Metode opisivanja numeričkih podataka - postupak razvrstavanja neprekidnih numeričkih podataka u kategorije

Razvrstavanje izmjerениh vrijednosti neprekidne numeričke varijable u kategorije:

- skup svih mjerenih vrijednosti (ili nešto veći skup koji sadrži skup svih mjerenih vrijednosti ali kojega je jednostavnije podijeliti na jednake dijelove) podijeliti na disjunktne intervale jednake duljine
- nema točno definiranog pravila po kojemu bi trebalo definirati duljine intervala niti njihov broj, ali ne smije ih biti niti previše niti premalo da bi cijeli postupak imao smisla i služio svrsi
- kriterij za kategorizaciju vrijednosti kontinuirane numeričke varijable treba biti temeljen na razumijevanju problema koji proučavamo

Tako dobiveni stupčasti dijagram naziva se **histogram** - stupci su postavljeni u koordinatni sustav nad odgovarajućim intervalima

- primjer 3.10





Metode opisivanja numeričkih podataka - mjere deskriptivne statistike

Karakteristika numeričkih varijabli - među njihovim vrijednostima postoji prirodan uređaj i možemo definirati **numeričke karakteristike** tih varijabli koje imaju logičnu interpretaciju i mogu se iskoristiti u cilju prikazivanja skupa mjernih vrijednosti:

- mjere centra podataka – opisuju centar podataka (tipičnu vrijednost)
- mjere raspršenosti podataka – opisuju raspršenost podataka



Mjere centra podataka aritmetička sredina podataka

- **aritmetička sredina** (eng. mean) niza izmjerenih vrijednosti (podataka) x_1, x_2, \dots, x_n varijable X definirana je izrazom

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

- npr. neka su 1.2, 2.1, 3.2, 4.3, 5.4, 6.5, 7.6, 8.7, 9.8 izmjerene vrijednosti jedne varijable
- obzirom da ih ima ukupno devet, aritmetička sredina ovog skupa podataka je

$$\frac{1.2 + 2.1 + 3.2 + 4.3 + 5.4 + 6.5 + 7.6 + 8.7 + 9.8}{9} \approx 5.42$$



Mjere centra podataka medijan podataka

- **medijan** ima značenje izmjerene vrijednosti koja se nalazi na sredini niza podataka kada je on uređen po veličini - barem pola podataka je manje ili jednako medijanu, a istovremeno je barem pola podataka veće ili jednako od medijana
- način njegovog određivanja ovisi o tome imamo li **neparan** ili **paran** broj podataka



Mjere centra podataka medijan podataka - neparan broj podataka

- ukoliko imamo **neparan broj** izmjerениh vrijednosti, onda postoji podatak koja je na srednjoj poziciji u uređenom skupu izmjerениh vrijednosti, pa njega definiramo kao medijan
- npr. neka su 1, 2, 5, 6, 5, 1, 2, 7, 2, 2, 3 izmjerene vrijednosti jedne varijable
- prvo ove vrijednosti poredamo po veličini: 1, 1, 2, 2, 2, **2**, 3, 5, 5, 6, 7
- obzirom da ih ima ukupno jedanaest, medijan je vrijednost koja je na šestoj poziciji u tako dobivenom nizu, tj. broj 2



Mjere centra podataka medijan podataka - paran broj podataka

- ukoliko imamo **paran broj** izmjerениh vrijednosti, onda ne postoji podatak koji je na srednjoj poziciji jer srednju poziciju "zauzimaju" dva podatka - medijan se tada definira kao polovina između ta dva podatka (tj. aritmetička sredina tih dvaju podataka)
- npr. neka su $1, 2, 5, 6, 5, 1, 2, 7, 2, 2, 3, 3$ izmjerene vrijednosti jedne varijable
- prvo ove vrijednosti poredamo po veličini:
 $1, 1, 2, 2, 2, \mathbf{2, 3}, 3, 5, 5, 6, 7$
- obzirom da ih ima dvanaest, "sredinu" čine šesti i sedmi podatak, tj. brojevi 2 i 3 - medijan ovog skupa podataka je sredina ta dva broja, tj. medijan je $(2 + 3)/2 = 2.5$



Mjere centra podataka mod podataka

- **mod** podataka je vrijednost iz niza izmjerениh vrijednosti varijable X kojoj pripada najveća frekvencija (izmjerena je najviše puta)
- mod ne mora biti jedinstven
- npr. neka su

1, 2, 5, 6, 5, 1, 2, 7, 2, 2, 3, 3

izmjerene vrijednosti jedne varijable - vrijednost 2 je izmjerena najviše puta (četiri puta) pa je 2 mod ovog skupa podataka

- npr. neka su

1, 2, 5, 6, 3, 3, 1, 2, 7, 2, 2, 3, 3

izmjerene vrijednosti jedne varijable - najviše puta izmjerene su dvije vrijednosti, tj. 2 i 3 su obje izmjerene točno četiri puta pa mod ovog skupa podataka nije jedinstven nego su mod i 2 i 3



Odabir mjere centra podataka

- Primjer: U jednoj tvrtki s devet zaposlenika zabilježeni su sljedeći iznosi plaća zaposlenika u kunama:

4200, 3100, 3200, 3150, 3850, 14000, 15000, 3700, 3800.

Izračunajte aritmetičku sredinu i medijan.



Odabir mjere centra podataka

- Primjer: Prema izvješću Državnog zavoda za statistiku prosječna neto plaća po zaposlenom u Hrvatskoj za svibanj 2019. iznosila je 6476kn.
Medijan svih isplaćenih neto plaća iznosi 5590kn prema istom izvješću (informativniji pokazatelj i bolje odražava tipičnu plaću).
Listopad 2018.: 6281kn i 5172kn.



Odabir mjere centra podataka

Odabir mjere centralne tendencije podataka:

- mod treba koristiti kada se želi naglasiti najčešći podatak, a to je obično slučaj kod kvalitativnih obilježja
- ako se radi o ordinalnim varijablama obično je medijan najpogodniji izbor
- ako uzorak sadrži stršeće vrijednosti, medijan će u pravilu biti bolji pokazatelj tipične vrijednosti od aritmetičke sredine
- kada je obilježje simetrično raspodijeljeno, tada je opravdano koristiti i aritmetičku sredinu i medijan kao mjere centra i vrijednosti će biti vrlo bliske
- kada je raspodjela asimetrična, medijan je bolji reprezentant centra



Odabir mjere centra podataka




Figure 1: Primjer uzorka iz simetrične distribucije



Odabir mjere centra podataka




Figure 2: Primjer uzorka iz asimetrične distribucije



Mjere raspršenosti podataka

- **raspršenost (varijabilnost)** podataka
- Primjer: neka su zadana tri uzroka
 - $0, 0, -1, 1$
 - $-200, 100, 200, -100$
 - $0, 0, -1, 1, 0, 0$

Izračunajte aritmetičku sredinu i medijan za svaki uzorak. Je li mjera centra jednako kvalitetna u sva tri uzorka?



Mjere raspršenosti podataka varijanca i standardna devijacija podataka

- **varijanca i standardna devijacija** karakteriziraju raspršenost podataka oko aritmetičke sredine
- varijanca niza izmjerениh vrijednosti x_1, x_2, \dots, x_n varijable X definirana je izrazom

$$s_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2,$$

a standardna devijacija je kvadratni korijen varijance, tj.

$$s_n = \sqrt{s_n^2} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2}.$$



Mjere raspršenosti podataka varijanca i standardna devijacija podataka

- npr. neka su izmjerene vrijednosti jedne varijable

1.2, 2.1, 3.2, 4.3, 5.4, 6.5, 7.6, 8.7, 9.8

- iz primjera znamo da je aritmetička sredina ovog skupa podataka približno jednaka 5.42, pa su varijanca i standardna devijacija ovog skupa podataka

$$s_n^2 \approx \frac{1}{8} \sum_{i=1}^9 (x_i - 5.42)^2 \approx 8.86, \quad s_n \approx \sqrt{\frac{1}{8} \sum_{i=1}^9 (x_i - 5.42)^2} \approx 2.98$$



Mjere raspršenosti podataka varijanca i standardna devijacija podataka

- Primjer: neka su zadana tri skupa podataka
 - $0, 0, -1, 1$
 - $-200, 100, 200, -100$
 - $0, 0, -1, 1, 0, 0$

Izračunajte varijancu i standardnu devijaciju za sva tri uzorka.



Mjere raspršenosti podataka kvantili

- **p -kvantil ili kvantil reda p** (postotna vrijednost) za neki izabrani broj $p \in (0, 100)$, označimo je x'_p , definira se poštujući zahtjev da je barem $p\%$ izmjerena vrijednosti varijable manje ili jednako x'_p , dok je barem $(100 - p)\%$ vrijednosti veće ili jednako x'_p
- medijan je kvantil reda 0.5 (50%-tna vrijednost)
- kvantil reda 0.25 (25%-tna vrijednost) zove se **donji kvartil**
- kvantil reda 0.75 (75%-tna vrijednost) zove se **gornji kvartil**
- kao i kod računanja medijana, ako se na traženoj poziciji za računanje postotne vrijednosti nalaze dva podatka u uređenom skupu izmjerena vrijednosti, postotnu vrijednost određujemo kao njihovu aritmetičku sredinu



Mjere raspršenosti podataka kvantili

- na osnovu n podataka želimo odrediti p -kvantil, $p \in (0, 100)$
- izračunamo vrijednost $j = np/100$
- ako j nije prirodan broj onda je p -kvantil podatak na poziciji $\lceil j \rceil$ - najmanji prirodni broj veći od j (prvi sljedeći)
- ako je j prirodan broj onda je p -kvantil aritmetička sredina podataka na pozicijama j i $j + 1$



Mjere raspršenosti podataka postotna vrijednost, donji i gornji kvartil

- npr. neka su $1, 2, 5, 6, 6, 1, 3, 7, 3, 3, 3, 3$ izmjerene vrijednosti jedne varijable
- prvo ove vrijednosti poredamo po veličini:
 $1, 1, 2, 3, 3, 3, 3, 3, 5, 6, 6, 7$
- želimo li odrediti donji kvartil, potrebno je prvo odrediti četvrtinu podataka (25%) - obzirom da imamo 12 podataka, četvrtinu (25%) čine tri podatka
- treći podatak u gornjem skupu je broj 2, a četvrti 3 - donji kvartil je 2.5
- deveti broj u gornjem skupu podataka je broj 5, a deseti 6 - gornji kvartil je 5.5



Mjere raspršenosti podataka najmanja i najveća vrijednost, raspon podataka

- ako su x_1, x_2, \dots, x_n izmjerene vrijednosti varijable X , označimo najmanju od njih (**minimum**) x_{\min} , a najveću od njih (**maksimum**) x_{\max}
- **raspon** (eng. range) podataka - razlika najveće i najmanje vrijednosti u skupu izmjerениh vrijednosti varijable ($x_{\max} - x_{\min}$)
- npr. neka su izmjerene vrijednosti jedne varijable $1, 2, 5, 6, 5, 1, 2, 7, 2, 2, 3, 3$ - 1 je najmanja izmjerena vrijednost, a 7 najveća, pa je raspon ovog skupa izmjerениh vrijednosti $7 - 1 = 6$



Mjere raspršenosti podataka maksimalno odstupanje od "prosjeka"

- **maksimalno odstupanje izmjerenih vrijednosti varijable od "prosjeka"** - veći od brojeva $(\bar{x}_n - x_{\min})$ i $(x_{\max} - \bar{x}_n)$, tj. broj

$$\max \{(\bar{x}_n - x_{\min}), (x_{\max} - \bar{x}_n)\}.$$

- npr. neka su $1, 2, 5, 6, 5, 1, 2, 7, 2, 2, 3, 3$ izmjerene vrijednosti neke varijable X :

$$x_{\min} = 1, \quad x_{\max} = 7,$$

$$\bar{x}_n = \frac{1 + 2 + 5 + 6 + 5 + 1 + 2 + 7 + 2 + 2 + 3 + 3}{12} = 3.25$$

- maksimalno odstupanje izmjerenih vrijednosti ove varijable od prosjeka:

$$\max \{3.25 - 1, 7 - 3.25\} = \max \{2.25, 3.75\} = 3.75$$





Grafička metoda opisivanja numeričkih podataka - kutijastog dijagrama

- korištenjem numeričkih karakteristika numeričkih varijabli skup mjerih vrijednosti može se prikazati grafički pomoću **kutijastog dijagrama** (eng. box plot, boxplot ili box-and-whisker plot)
- kutijastim dijagramom prikazujemo odnos pet numeričkih karakteristika skupa izmjerih vrijednosti: minimalnu vrijednost, donji kvartil, medijan, gornji kvartil i maksimalnu vrijednost
- na kutijastom dijagramu se također označavaju takozvane **stršeće vrijednosti** skupa podataka, ako postoje
- primjer 3.20



Detekcija stršećih vrijednosti

Stršeća vrijednost - podatak koji je značajno veći ili manji u odnosu na druge izmjerene vrijednosti jedne varijable i čije je pojavljivanje najčešće vezano uz jedan od sljedećih razloga:

- podatak je ili netočno izmjerен ili krivo unesen u bazu podataka
- podatak dolazi iz druge populacije (ne iz populacije koju promatramo u kontekstu problema kojeg proučavamo)
- podatak je točno izmjeren i unesen u bazu, ali predstavlja rijetku pojavu u populaciji
- **primjer 3.21**

↔↔↔



Oblik distribucije uzorka

- prema obliku histograma možemo nešto reći o razdiobi (raspodjeli, distribuciji) uzorka
- lijevi rep distribucije je teži ako su podaci manji od prosjeka udaljeniji od njega nego podaci s desne strane prosjeka (oni koji su veći od njega) - i obratno
- simetrične distribucije - repovi su podjednaki
- asimetrične distribucije - jedan rep je teži od drugoga (lijevo nagnute ili desno nagnute)



Oblik raspodjele uzorka




Figure 3: Primjer uzorka iz simetrične distribucije



Oblik raspodjele uzorka




Figure 4: Primjer uzorka iz asimetrične distribucije - desno nagnute (desni rep je duži - teži)