

# Osnove statistike u demografiji

Predavanje 7

# Procjene parametara jedne populacije

- Zaključci o karakteristikama pojave mogu se donijeti:
  - Prikupljanjem podataka o svim jedinicama promatrane pojave koje čine populaciju (osnovni skup), ili
  - o samo jednom dijelu jedinica
- Uzorak (engl. *sample*)
- Inferencijalna statistika: na temelju uzorka nastoje se donijeti što točniji zaključci o karakteristikama populacije koje se nazivaju parametrima
- Reprezentativan uzorak: dobro opisuje karakteristike populacije (osnovnog skupa)
- Jednostavni slučajni uzorak. Izbor u:
  - konačnim i
  - beskonačnim populacijama

# Procjene parametara jedne populacije

- Vrijednosti parametara populacije su nepoznate i one se procjenjuju s pomoću uzorka
- Zaključci o vrijednostima parametara populacije mogu se donijeti samo uz određenu razinu pouzdanosti
- Dvije su skupine metoda inferencijalne statistike:
  - Procjena parametara
  - Testiranje hipoteza

# Procjene parametara

- Potrebno je definirati procjenitelja i odrediti oblik njegove distribucije vjerojatnosti (sampling distribucija procjenitelja)
- Mogu se izračunati:
  - procjena parametra jednim brojem  $i$
  - intervalna procjena

# Testiranje hipoteza

- Procjenitelju odabranog parametra pridružuje se standardizirana varijabla
- Na temelju podataka iz slučajno izabranog uzorka veličine  $n$  i poznavanja distribucije vjerojatnosti standardiziranog procjenitelja donosi odluka o odbacivanju ili ne odbacivanju postavljene hipoteze u skladu s odgovarajućim pravilom odlučivanja

# Metode izbora uzorka

- Metode inferencijalne statistike temelje se na rezultatima teorije vjerojatnosti.
- Uvjet za primjenu teorije vjerojatnosti je slučajan izbor jedinica u uzorak
- Inferencijalna statistika bavi se poopćavanjem
- Kako bi poopćavanje bilo što kvalitetnije i vjerodostojnije uzorak mora biti reprezentativan
- Reprezentativnost, mogućnost poopćavanja rezultata i primjerenost primjene statističkih metoda ovise o načinu izbora uzorka iz populacije
- Izbor uzorka može biti:
  - namjeran ili
  - slučajan

# Metode izbora uzorka

- Namjerni izbor: subjektivan; zato često nije reprezentativan
- Slučajni izbor: objektivan
- Na rezultate slučajnog uzorka može se primijeniti teorija vjerojatnosti, što omogućava poopćavanje:
  - Procjenu parametara
  - Testiranje hipoteza
- Slučajni uzorci nazivaju se još probabilističkima (engl. *random samples*):
  - jednostavni slučajni uzorak,
  - sistematski uzorak,
  - stratificirani uzorak i
  - uzorak skupina
- Plan uzorka je skup pravila i postupaka određenog načina izbora uzorka iz populacije

# Jednostavni slučajni uzorak

- Svaka jedinica populacije ima jednaku vjerojatnost da bude izabrana u uzorak



# Sistematski uzorak

- Slučajni uzorak u kojem izbor jedinica ovisi o koraku izbora  $k$   $k = \frac{N}{n}$
- Frakcija izbora  $f = \frac{1}{k} = \frac{n}{N}$
- Na primjer, ako se iz populacije  $N = 50$  kućanstava u jednom selu izabire uzorak veličine  $n = 10$ , tada je korak izbora  $k = 5$ .
- Popis numeriranih jedinica cijele populacije naziva se okvir izbora

# Stratificirani uzorak

- Prikladan kada osnovni skup nije homogen
- Tada se osnovni skup može podijeliti u grupe s obzirom na promatrano obilježje koje se ispituje, tako da jedinice izabrane iz tih grupa budu što homogenije.
- Takve grupe su disjunktne podskupovi i nazivaju se stratumima.
- Stratuma može biti više i ne moraju biti jednakih veličina

# Uzorak skupina

- Često se primjenjuje u istraživanju tržišta (segmentacija potrošača)
- Formira se u dva koraka:
  - Cijela se populacija podijeli na konačan broj skupina (klastera) te se na slučajan način izabiru određene skupine (klasteri).
  - Zatim se iz svake izabrane skupine na slučajan način izabiru jedinice

# Procjenitelj parametra, vrijednost procjene i sampling-distribucija procjenitelja

- Postupak procjenjivanja nepoznatog parametra populacije provodi se s pomoću procjenitelja
- Procjenitelj (engl. *estimator*) je slučajna varijabla kojom se procjenjuje parametar populacije, dok se konkretna vrijednost procjenitelja, dobivena na uzorku podataka, naziva procjenom (engl. *estimate*).
- “Kvaliteta” procjenitelja ovisi o njegovim svojstvima.
- Ako se želi odrediti koja svojstva ima procjenitelj određenog parametra, treba poznavati distribuciju vjerojatnosti tog procjenitelja

# Sampling-distribucija procjenitelja

- Konkretni vrijednosti procjenitelja određenog parametara razlikovat će se od uzorka do uzorka.
- Prosječno odstupanje vrijednosti procjenitelja od stvarne vrijednosti parametra populacije kreće se u granicama slučajnih varijacija.
- Te varijacije se nazivaju sampling-varijacije, a distribucija vjerojatnosti procjenitelja se naziva **sampling-distribucija**
- Poželjno je da se vrijednosti procjenitelja na izabranim uzorcima “gomilaju” oko stvarne vrijednosti parametra populacije (nepristranost)
- Da je prosječno odstupanje od stvarne vrijednosti parametra populacije što manje (efikasnost).
- Ponekad je dovoljno da statistička svojstva vrijede asimptotski, tj. da s porastom veličine uzorka  $n$  procjenitelj ima navedena svojstva

# Procjena aritmetičke sredine populacije

# Standardna pogreška procjene aritmetičke sredine

- Standardna devijacija procjenitelja  $\bar{X}$  je prosječno odstupanje aritmetičkih sredina uzoraka od sredine populacije

$$\sigma_{\bar{X}} = \sqrt{Var(\bar{X})} = \sqrt{\frac{\sigma^2}{n}} = \frac{\sigma}{\sqrt{n}}$$

- Kada se slučajni uzorak izabire bez ponavljanja iz konačne populacije, rezultati izbora jedinica u uzorak nisu nezavisni, tj. kovarijance između varijabli uzorka  $X_1, X_2, \dots, X_n$  nisu jednake nuli. U tom slučaju je standardna pogreška aritmetičke sredine

$$\sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}} \sqrt{\frac{N-n}{N-1}}$$

- Faktor korekcije za konačne populacije  $\sqrt{\frac{N-n}{N-1}}$

- Izostavlja se ako je

$$\frac{n}{N} < 0,05$$

# Sampling-distribucija procjenitelja $\bar{X}$

- Ako je jednostavni slučajni uzorak izabran iz normalno distribuirane populacije sampling-distribucija procjenitelja  $\bar{X}$  je normalna distribucija (za bilo koju veličinu uzorka  $n$ )

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

- Ako populacija nije normalno distribuirana, sampling-distribucija procjenitelja  $\bar{X}$  bit će približno normalnog oblika samo za velike uzorke ( $n > 30$ ), što je posljedica **centralnog graničnog teorema**



# Procjena aritmetičke sredine populacije kada je varijanca populacije poznata

- Intervalna procjena
- Razina pouzdanosti (engl. *confidence level*):  $1 - \alpha$

$$P(-z_{\alpha/2} < Z < +z_{\alpha/2}) = P\left(-z_{\alpha/2} < \frac{\bar{X} - \mu}{\sigma_{\bar{X}}} < +z_{\alpha/2}\right) = 1 - \alpha.$$

# Procjena aritmetičke sredine populacije kada je varijanca populacije poznata

- Interval procjene sredine  $\mu$  normalno distribuirane populacije s poznatom varijancom  $\sigma^2$ , uz razinu pouzdanosti  $1 - \alpha$

$$P\left(\bar{x} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} < \mu < \bar{x} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$

# Primjer 6.11. Procjena parametra $\mu$ jednim brojem i intervalom na temelju velikog uzorka, poznata standardna devijacija populacije

- Bahovec i Erjavec (2015.) str. 262

# Procjena aritmetičke sredine populacije kada varijanca populacije nije poznata

$$P(\bar{x} - t_{\alpha/2}\sigma_{\bar{X}} < \mu < \bar{x} + t_{\alpha/2}\sigma_{\bar{X}}) = 1 - \alpha$$

# Procjena proporcije populacije

Proporcija populacije	Procjenitelj proporcije	Procjena proporcije jednim brojem
$p$	$\hat{p} = \frac{\sum_{i=1}^n X_i}{n}$	$\hat{p} = \frac{m}{n}$

- Potrebno je utvrditi svojstva procjenitelja od  $p$ , te odrediti sampling-distribuciju standardiziranog procjenitelja od  $p$

# Svojstva procjenitelja proporcije populacije

- Pretpostavlja se da je varijabla  $X$  Bernoullijeva slučajna varijabla s nepoznatom očekivanom vrijednosti,  $p$ , koja se procjenjuje na temelju jednostavnog slučajnog uzorka.
- Varijable uzorka  $X_1, X_2, \dots, X_n$  su nezavisne i jednako distribuirane.
- Varijable uzorka  $X_1, X_2, \dots, X_n$  također su Bernoullijeve slučajne varijable koje su nezavisne, te mogu poprimiti vrijednosti 0 ili 1.
- Procjenitelj parametra  $p$  definira se kao aritmetička sredina varijabli uzorka

$$\hat{p} = \frac{\sum_{i=1}^n X_i}{n} = \frac{X_1 + X_2 + \dots + X_n}{n},$$

$$X_i \sim B(1, p)$$

# Svojstva procjenitelja proporcije populacije

- Zbroj  $n$  Bernullijevih nezavisnih slučajnih varijabli je slučajna varijabla koja ima binomnu distribuciju
- Očekivana vrijednost i varijanca procjenitelja  $\hat{p}$

# Svojstva procjenitelja proporcije populacije

- Sampling-distribucija procjenitelja  $\hat{p}$  je binomna distribucija
- Procjena proporcije populacije jednim brojem

$$\hat{p} = \frac{m}{n}, \hat{q} = 1 - \hat{p}$$

- Standardna pogreška procjene proporcije je

$$\sigma_{\hat{p}} = \sqrt{\frac{\hat{p}\hat{q}}{n-1}}$$

- Ako je  $\frac{n}{N} \geq 0,05$  tada je standardna pogreška procjene proporcije

$$\sigma_{\hat{p}} = \sqrt{\frac{\hat{p}\hat{q}}{n-1} \cdot \frac{N-n}{N-1}}$$



# Procjena proporcije populacije s pomoću velikog uzorka

- Proporcija populacije može se procijeniti jednim brojem i intervalom.
- Postupak procjenjivanja proporcije populacije intervalom provodi se samo za velike uzorke.
- Za velike uzorke ( $n > 30$ ) sampling-distribucija procjenitelja  $\hat{p}$  se dobro aproksimira normalnom distribucijom
- Interval procjene proporcije  $p$  s pomoću velikog uzorka je

$$P(\hat{p} - z_{\alpha/2}\sigma_{\hat{p}} < p < \hat{p} + z_{\alpha/2}\sigma_{\hat{p}}) = 1 - \alpha$$

# Primjer 6.22. Interval procjene proporcije populacije

- Bahovec i Erjavec (2015.) str. 279