

# Inferencijalna statistika i intervali pouzdanosti

Od uzorka do zaključka o populaciji

Bojan B.

EFBL/FPN

20. april 2026.

- 1 Šta je inferencijalna statistika?
- 2 Distribucija uzorkovanja
- 3 Interval pouzdanosti za proporciju
- 4 Distribucija uzorkovanja srednje vrijednosti
- 5 Interval pouzdanosti za srednju vrijednost
- 6 Sažetak i praktična pitanja

# Od uzorka do populacije

## Inferencijalna statistika — osnovna ideja

Inferencijalna statistika donosi **zaključke o populaciji** na osnovu podataka prikupljenih iz uzorka. Uvijek postoji neizvjesnost — ne posmatramo cijelu populaciju.

## Tipična pitanja

- Koji procenat zaposlenih žena ima fakultetsku diplomu?
- Koliko je srednje vrijeme preživljavanja za pacijente s ovom vrstom raka?
- Koji udio birača podržava određenu politiku?
- Koja je prosječna plata u sektoru?

## Parametar vs. statistika

**Parametar** — broj koji opisuje populaciju  
Oznaka:  $\mu$  (sredina),  $p$  (proporcija)

**Statistika** — broj izračunat iz uzorka  
Oznaka:  $\bar{x}$  (sredina),  $\hat{p}$  (proporcija)


Statistiku *znamo* (iz podataka).

Parametar *procjenjujemo* (cilj analize).

## Ključna razlika od deskriptivne statistike

Deskriptivna statistika *opisuje* uzorak koji imamo. Inferencijalna statistika *zaključuje* o populaciji koju nismo u potpunosti posmatrali.

# Lanac zaključivanja: od podataka do zaključka



## Šta znamo

- Statistiku iz uzorka ( $\hat{p}$  ili  $\bar{x}$ )
- Veličinu uzorka  $n$
- Da je uzorak slučajan (SRS)

## Šta procjenjujemo

- Parametar populacije ( $p$  ili  $\mu$ )
- S određenim **nivoom pouzdanosti** (95%, 99%...)
- U obliku **intervala**, ne tačke

# Distribucija uzorkovanja proporcije

## Formalna definicija


**Distribucija uzorkovanja** statistike je distribucija vrijednosti koje statistika uzima u *svim mogućim uzorcima* iste veličine iz iste populacije.

## Distribucija uzorkovanja $\hat{p}$

Uzmimo SRS veličine  $n$  iz populacije s proporcijom  $p$ .

Kada je  $n$  dovoljno veliko:

- $\hat{p}$  prati **normalnu distribuciju**
- Sredina distribucije uzorkovanja:  $\mu_{\hat{p}} = p$
- Standardna greška:  $SE = \sqrt{\frac{p(1-p)}{n}}$



95% svih uzoraka daje  $\hat{p}$  unutar  $2 \cdot SE$  od  $p$ .

# Primjer: Planovi apsoluta za postdiplomski studij

## Postavljanje problema

Istina o populaciji:  $p = 0,215$  (21,5% apsoluta planira postdiplomski).

Veličina uzorka:  $n = 23.915$ .

## Izračun standardne greške

$$\begin{aligned} SE &= \sqrt{\frac{p(1-p)}{n}} = \sqrt{\frac{0,215 \times 0,785}{23.915}} \\ &= \sqrt{\frac{0,16878}{23.915}} = \sqrt{0,00000706} = 0,00266 \end{aligned}$$

Pravilo 68-95-99,7:

95% uzoraka daje  $\hat{p}$  između:

$$0,215 - 2(0,00266) = 0,2097$$

$$0,215 + 2(0,00266) = 0,2203$$

## Šta ovo znači?

- SE je mali jer je  $n$  velik
- Skoro svi uzorci daju  $\hat{p}$  blisko pravom  $p$
- 95% uzoraka pada u raspon  $[0,210; 0,220]$

## Stabilnost SE

SE se malo mijenja s  $p$ :

$p$	SE
0,20	0,00259
0,215	0,00266

# Šta je interval pouzdanosti?

## Definicija

**Interval pouzdanosti nivoa  $C$**  za parametar je interval izračunat iz podataka uzorka koji “hvata” pravu vrijednost parametra u  $C\%$  ponavljanih uzorkovanja.

## Formula za proporciju

$$\hat{p} \pm z^* \cdot \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}$$

gdje je:

- $\hat{p}$  — proporcija uzorka
- $z^*$  — kritična vrijednost za nivo  $C$
- $n$  — veličina uzorka

**Napomena:** Koristimo  $\hat{p}$  jer  $p$  ne znamo — to je upravo ono što procjenjujemo. Za veliki  $n$  ovo je dobra aproksimacija.

## Kritične vrijednosti $z^*$

Nivo pouzdanosti	$z^*$
90%	1,645
95%	1,960
99%	2,576

*Koristimo  $\hat{p}$  umjesto  $p$  jer  $p$  ne znamo. Za veliki  $n$ , ovo je dobra aproksimacija.*

# Primjer: 95% interval pouzdanosti za proporciju

## Podaci

NSSE anketa:  $n = 23.915$  apsoluta, od kojih 5.038 planira postdiplomski.

$$\hat{p} = 5038/23915 = 0,211$$

## Izračun 95% intervala

$$SE = \sqrt{\frac{0,211 \times 0,789}{23915}} = \sqrt{0,000006970} = 0,00264$$

$$\hat{p} \pm z^* \cdot SE = 0,211 \pm 1,960 \times 0,00264 \\ = 0,211 \pm 0,0052$$

**Interval:** [0,2058; 0,2162]

## Tumačenje

95% smo uvjereni da između **20,58%** i **21,62%** svih apsoluta u SAD i Kanadi planira postdiplomski studij.

Drugim riječima: metoda koja daje ovakve intervale "hvata" pravi  $p$  u 95% slučajeva pri ponovljenom uzorkovanju.

Važno! Interval *ne* znači da postoji 95% vjerovatnoća da  $p$  leži u ovom konkretnom intervalu. Pravi  $p$  je fiksna vrijednost, nije slučajan.

# Razumijevanje intervala pouzdanosti

**Ključna ideja: šta bi se desilo pri ponovljenom uzorkovanju?**

Svaki uzorak daje *drugačiji* interval. Nivo pouzdanosti 95% znači da bi 95 od 100 takvih intervala “uhvatilo” pravi parametar.



## Dva konkretna uzorka

**Uzorak 1:**  $\hat{p} = 0,211$

$\Rightarrow$  interval:  $0,211 \pm 0,0053 = [0,206; 0,216]$

**Uzorak 2:**  $\hat{p} = 0,208$

$\Rightarrow$  interval:  $0,208 \pm 0,0052 = [0,203; 0,213]$

Oba intervala su različita, ali oba “hvataju” pravi  $p \approx 0,215$ .

Pouzdanost metode, ne intervala Govorimo o pouzdanosti **metode**, ne o pouzdanosti jednog konkretnog intervala. 95% intervala napravljenih ovom metodom sadrži pravi parametar.

# Različiti nivoi pouzdanosti

## Opšta formula s kritičnom vrijednošću $z^*$

Za bilo koji nivo pouzdanosti  $C$  između 0 i 1, postoji  $z^*$  takav da normalna distribucija ima vjerovatnoću  $C$  unutar  $z^*$  standardnih devijacija od sredine.

$$\hat{p} \pm z^* \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}$$


### Primjer: 99% interval (NSSE)

$n = 23.915$ ,  $\hat{p} = 0,211$ ,  $z^* = 2,576$

$$\begin{aligned} & \hat{p} \pm 2,576 \times 0,00264 \\ & = 0,211 \pm 0,0068 \end{aligned}$$

**Interval:** [0,2042; 0,2178]

99% smo uvjereni da između 20,42% i 21,78% apsoluta planira postdiplomski.



Viša pouzd.  $\Rightarrow$  širi int.  $\Rightarrow$  manje prec.

# Distribucija uzorkovanja srednje vrijednosti $\bar{x}$

## Teorija

Odaberemo SRS veličine  $n$  iz populacije sa sredinom  $\mu$  i SD  $\sigma$ . Neka je  $\bar{x}$  srednja vrijednost uzorka.

- Distribucija uzorkovanja  $\bar{x}$  je **aproximativno normalna** za velik  $n$
- Sredina distribucije uzorkovanja:  $\mu_{\bar{x}} = \mu$  i standardna greška:  $SE_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$

## Dvije važne posljedice

### 1. Manja varijabilnost:

Sredina više opservacija je *manje varijabilna* od pojedinačnih opservacija.

### 2. Normalnost:

Distribucija sredine je normalija od distribucije pojedinačnih opservacija.

## Standardna greška se smanjuje s $n$


$n$	$SE = \sigma/\sqrt{n}$	vs. $n = 1$
1	$\sigma$	$\times 1$
4	$\sigma/2$	$\times 0,50$
25	$\sigma/5$	$\times 0,20$
100	$\sigma/10$	$\times 0,10$

Da bismo prepolovili SE, trebamo  $4\times$  veći uzorak.

# Centralna granična teorema

## Centralna granična teorema (CGT)

Kako uzimamo sve više i više nasumičnih opservacija iz *bilo koje* populacije, distribucija srednje vrijednosti tih opservacija se **sve više približava normalnoj distribuciji**.



### Praktično pravilo

- $n \geq 15$ : adekvatno za većinu distribucija (bez ekstremnih outliera)
- $n \geq 40$ : dovoljna za jasno iskošene distribucije bez outliera
- Veći  $n$  = sigurnija normalna aproksimacija

## Zašto je CGT važna?

Čak i kada ne znamo oblik distribucije populacije, za dovoljno velik  $n$  možemo koristiti normalne metode za intervale pouzdanosti!

# Interval pouzdanosti za srednju vrijednost $\mu$

## Formula

Odaberemo SRS veličine  $n$  iz populacije sa nepoznatom sredinom  $\mu$ .

Neka je  $\bar{x}$  sredina uzorka,  $s$  standardna devijacija uzorka.

Aproximativni interval pouzdanosti nivoa  $C$  za  $\mu$ :

$$\bar{x} \pm z^* \cdot \frac{s}{\sqrt{n}}$$

## Analogija s proporcijom

	Proporcija	Sredina
Parametar	$p$	$\mu$
Statistika	$\hat{p}$	$\bar{x}$
SE	$\sqrt{\hat{p}(1 - \hat{p})/n}$	$s/\sqrt{n}$
Interval	$\hat{p} \pm z^* \cdot \text{SE}$	$\bar{x} \pm z^* \cdot \text{SE}$

## Napomene

- Ne znamo  $\sigma$  (populacijska SD), pa koristimo  $s$  (SD uzorka) - valjano za velik  $n$
- Za mali  $n$  koristimo  $t$ -distribuciju (napredni kurs)
- Recept vrijedi samo za SRS!

# Primjer: NAEP test iz matematike

## Podaci

NAEP 2015:  $n = 13.200$  maturanta,  $\bar{x} = 152$  (rezultat),  $s = 34$ , raspon 0–300.


## Izračun 95% intervala

$$SE = \frac{s}{\sqrt{n}} = \frac{34}{\sqrt{13200}} = \frac{34}{114,9} = 0,296$$

$$\begin{aligned}\bar{x} \pm z^* \cdot SE &= 152 \pm 1,960 \times 0,296 \\ &= 152 \pm 0,58\end{aligned}$$

**Interval:** [151,42; 152,58]

95% smo sigurni da je srednji rezultat svih maturanta između **151,42** i **152,58**.



## Uočite preciznost

Margina greške je samo  $\pm 0,58$  boda!

To je jer je  $n = 13.200$  veoma velik.

Veći  $n \Rightarrow$  uži interval  $\Rightarrow$  preciznija procjena.

# Sažetak: Sve u jednoj tablici

Situacija	Parametar	Interval	SE
Proporcija	$p$ (nepoznat)	$\hat{p} \pm z^* \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$	$\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$
Sredina	$\mu$ (nepoznat)	$\bar{x} \pm z^* \frac{s}{\sqrt{n}}$	$\frac{s}{\sqrt{n}}$

## Uvjeti za valjanost

- Uzorak je **SRS** (slučajni)
- Veličina uzorka **dovoljno velika**  
( $n \geq 15$  za sredinu,  $n\hat{p} \geq 10$  za proporciju)
- Populacija znatno veća od uzorka

## Česte greške u tumačenju

- “95% šanse da pravi parametar leži u intervalu”  
— pogrešno (parametar nije slučajni)
- “95% podataka je u intervalu” — pogrešno  
(interval nije za podatke)
- Ispravno: 95% je *pouzdanost metode*

# Praktično pitanje 1: Podrška politici

## Scenarij

Anketiramo SRS od  $n = 1.500$  odraslih građana. Od njih,  $n_{da} = 825$  podržava određenu ekonomsku politiku.

$$\hat{p} = 825/1500 = 0,550$$

## Zadaci

- 1 Izračunaj 95% interval pouzdanosti za  $p$ .
- 2 Izračunaj 99% interval pouzdanosti za  $p$ .
- 3 Može li se tvrditi da *više od polovine* građana podržava politiku? Zašto?
- 4 Kako bi se rezultat promijenio da je  $n = 400$ ?

## Rješenja

$$SE = \sqrt{\frac{0,55 \times 0,45}{1500}} = \sqrt{0,0001650} = 0,01285$$

$$(1) 0,550 \pm 1,960 \times 0,01285 = 0,550 \pm 0,025$$

Interval: [0,525; 0,575]

$$(2) 0,550 \pm 2,576 \times 0,01285 = 0,550 \pm 0,033$$

Interval: [0,517; 0,583]

(3) Da — oba intervala su *iznad* 0,50.

$$(4) SE = \sqrt{0,55 \times 0,45/400} = 0,0249$$

Mnogo širi interval:  $0,550 \pm 0,049$

## Praktično pitanje 2: Prosječna plata

### Scenarij

SRS od  $n = 400$  zaposlenih u sektoru IT. Prosječna plaća uzorka:  $\bar{x} = 2.850$  KM, standardna devijacija uzorka:  $s = 520$  KM.

### Zadaci

- 1 Izračunaj standardnu grešku  $\bar{x}$ .
- 2 Izračunaj 95% interval pouzdanosti za  $\mu$ .
- 3 Tumači interval u kontekstu.
- 4 Medijski naslov kaže "prosječna IT plaća je 2.900 KM". Je li ovo kompatibilno s vašim intervalom?

### Rješenja

- (1)  $SE = \frac{520}{\sqrt{400}} = \frac{520}{20} = 26$  KM
- (2)  $2850 \pm 1,960 \times 26 = 2850 \pm 50,96$   
Interval: [2799; 2901] KM
- (3) 95% smo sigurni da je prosječna IT plaća između 2.799 i 2.901 KM.
- (4) 2.900 KM *leži unutar* intervala [2799; 2901] — tvrdnja iz naslova je kompatibilna s našim podacima.

## Praktično pitanje 3: Veličina uzorka i pouzdanost

### Zadatak za razumijevanje

Istraživač želi 95% interval pouzdanosti za proporciju  $p$  koji ima marginu greške **ne veću od 0,03** (3 procentna poena). Koliki uzorak je potreban?

### Rješenje

Margina greške:  $z^* \cdot SE \leq 0,03$

$$1,960 \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} \leq 0,03$$

Najgori slučaj:  $\hat{p} = 0,5$  (maksimalni SE)

$$1,960 \times \sqrt{\frac{0,25}{n}} \leq 0,03$$

$$\sqrt{\frac{0,25}{n}} \leq \frac{0,03}{1,960} = 0,01531$$

$$n \geq \frac{0,25}{0,01531^2} = \frac{0,25}{0,000234} \approx 1068$$

### Opća formula za veličinu uzorka

$$n \geq \left( \frac{z^*}{ME} \right)^2 \hat{p}(1 - \hat{p})$$

Za nepoznato  $\hat{p}$ , koristimo  $\hat{p} = 0,5$  (daje najkonzervativniju — najveću — procjenu  $n$ ).

### Zaključak

Trebamo barem  $n = 1068$  ispitanika za marginu greške  $\leq 3\%$  pri 95% pouzdanosti.



# Hvala na pažnji!

Pitanja i diskusija

“Nikada ne možemo biti 100% sigurni — ali možemo biti 95%.”

— *osnovna ideja intervala pouzdanosti*