

## 5 Procjena parametara

### 5.1 Slučajni uzorak

Neka je  $X$  statističko obilježje koje izučavamo. Cilj statističke analize je da se na osnovi uzorka iz populacije izvedu određeni zaključci o distribuciji obilježja  $X$ .

Recimo da želimo raditi ispitivanje o zečevima (npr. duljini njihovih ušiju) u nekoj šumi. Populacija iz koje izabiremo uzorak su svi zečevi koji žive u toj šumi. Uzorak zečeva biramo slučajno način. Dvije su različite mogućnosti da to učinimo: nakon što ulovimo zeca i izmjerimo mu dužinu ušiju, možemo ga pustiti i tako omogućiti da ga još (bar) jednom ulovimo te da on uđe u uzorak (bar) dva puta. Druga mogućnost je da ga zadržimo dok ne izaberemo cijeli uzorak kako taj isti zec ne bi ušao u uzorak više od jednog puta.

Slučajni uzorak kojeg uzimamo tako da svaki član populacije može ući u uzorak više od jednog puta zovemo **jednostavni slučajni uzorak s ponavljanjem** (slučaj kada zečeve puštamo natrag u šumu), a ukoliko svaki član populacije može ući u uzorak točno jednom tada se radi o **jednostavnom slučajnom uzorku bez ponavljanja** (slučaj kada zečeve ne puštamo prije nego izaberemo ostatak uzorka).

Bitna razlika između ove dvije vrste biranja uzroka je u tome što je u jednom slučaju populacija konačna a u drugom beskonačna. Naime, ako uzimamo uzorak s vraćanjem, tada možemo uzeti uzorak proizvoljne veličine, veće čak i od ukupnog broja članova same populacije. To je dakako u slučaju uzimanja uzorka bez vraćanja, nemoguće. S druge strane, često se promatraju konačne populacije koje su dovoljno velike da ih s aspekta statističke analize možemo smatrati beskonačnim.

## 5.2 Procjena populacijskog očekivanja i populacijske varijance

Zanima nas statističko obilježje  $X$  neke promatrane populacije. Pretpostavimo da je  $X$  slučajna varijabla s konačnim očekivanjem  $\mu = E[X]$  i varijancom  $\sigma^2 = \text{Var}[X]$ .  $\mu$  i  $\sigma^2$  su parametri razdiobe od  $X$ . U ovom poglavlju zanimala nas procjena vrijednosti od  $\mu$  i  $\sigma^2$ . Razlikujemo točkovnu i intervalnu procjenu parametara.

Cilj **točkovnog procjenjivanja** je izvođenje jedinstvenog broja iz slučajnog uzorka za kojeg je razumno smatrati da je blizak nepoznatoj vrijednosti parametra populacije.

Označimo sa  $\Theta$  određeni parametar populacije. Promatramo **slučajne uzorke** koji se sastoje od  $n$  nezavisnih jednako distribuiranih slučajnih varijabli

$$X_1, X_2, \dots, X_n$$

s distribucijom jednakom distribuciji mjerenog statističkog obilježja.

Želimo formirati funkcije slučajnog uzorka (**statistike**)

$$f(X_1, X_2, \dots, X_n)$$

tako da kad izračunavamo vrijednost te funkcije na podacima iz uzorka (vrijednost statistike, realizacija statistike) dobijemo broj blizak određenom parametru populacije što je najviše moguće.

**Funkcije slučajnog uzorka nazivat ćemo statistikama** (to su slučajne varijable).

Statistika koja ima za cilj procijeniti određeni parametar  $\Theta$  nazivat ćemo **točkovnim procjeniteljem** ili samo procjeniteljem parametra  $\Theta$ .

Kako procijeniti parametre  $\mu$  i  $\sigma^2$  iz slučajnog uzorka

$$X_1, X_2, \dots, X_n.?$$

Označimo sa

$$\bar{X}_n = \frac{1}{n} (X_1 + \dots + X_n)$$

statistiku koju zovemo aritmetičkom sredinom uzorka (uzoračkom aritmetičkom sredinom).

Svojstva:

1.

$$\begin{aligned} E[\bar{X}_n] &= \text{linernost} = \frac{1}{n}(E[X_1] + \dots + E[X_n]) \\ &= \text{jednaka distribucija} = \frac{1}{n}n\mu = \mu, \end{aligned}$$

2.

$$\begin{aligned} \text{Var}[\bar{X}_n] &= \frac{1}{n^2}\text{Var}(X_1 + \dots + X_n) = \text{nezavisnost} \\ &= \frac{1}{n^2}(\text{Var}X_1 + \dots + \text{Var}X_n) = \text{jednaka distribucija} = \frac{1}{n^2}n\sigma^2 = \frac{\sigma^2}{n}. \end{aligned}$$

Slučajnu varijablu  $\bar{X}_n$  uzimamo za (točkovnog) procjenitelja partametra  $\mu$ . Prethodna svojstva (1) i (2) govore da je  $\bar{X}_n$  "dobar" procjenitelj za  $\mu$ .

**Za procjenitelj  $T_n = f(X_1, \dots, X_n)$  kažemo da je nepristrani procjenitelj za parametar  $\Theta$  ako je**

$$E[T_n] = \Theta.$$

**Za nepristrani procjenitelj  $T_n = f(X_1, \dots, X_n)$  parametra  $\Theta$  kažemo da je konzistentan procjenitelj ako je**

$$\lim_{n \rightarrow \infty} \text{Var}[T_n] = 0.$$

Iz prethodnog očito slijedi da  $\bar{X}_n$  nepristran i konzistentan procjenitelj parametra  $\mu$ .

Neka je sada definirana statistika

$$S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2.$$

Očito je

$$S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2 = \frac{1}{n-1} \left[ \sum_{i=1}^n X_i^2 - n\bar{X}_n^2 \right].$$

Prisjetimo se još da je  $E[X^2] = \text{Var}[X] + \mu^2$ . Imamo:

$$\begin{aligned} E[S_n^2] &= \frac{1}{n-1} \sum_{i=1}^n E[X_i^2] - \frac{n}{n-1} E[\bar{X}_n^2] \\ &= \frac{1}{n-1} n(\sigma^2 + \mu^2) - \frac{n}{n-1} \left( \frac{\sigma^2}{n} + \mu^2 \right) = \sigma^2. \end{aligned}$$

Zaključujemo da je statistika  $S_n^2$  (koju nazivamo uzoračka varijanca) nepristrani procjenitelj varijance  $\sigma^2$ . Može se pokazati da je  $S_n^2$  i konzistentan procjenitelj.

### 5.3 Pouzdani intervali za očekivanje normalne populacije

**Definicija 18** Neka su  $L_n = l(X_1, \dots, X_n)$  i  $D_n = d(X_1, \dots, X_n)$  slučajne varijable (statistike), funkcije slučajnog uzorka  $X_1, \dots, X_n$ .

Kažemo da je  $[L_n, D_n]$   $(1 - \alpha) \cdot 100\%$  **pouzdan interval** za parametar  $\tau$  ako vrijedi

$$P(L_n \leq t \leq D_n) \geq 1 - \alpha, \quad \alpha \in \langle 0, 1 \rangle$$

#### 5.3.1 Varijanca poznata

Neka je  $X$  slučajna varijabla s nepoznatim očekivanjem  $\mu$  i poznatom varijancom  $\sigma^2$ .

- imamo slučajni uzorak veličine  $n$  :  $X_1, \dots, X_n$
- $(1 - \alpha) \cdot 100\%$  pouzdan interval za  $\mu$  dobit ćemo ako promatramo uzoračku distribuciju statistike  $\bar{X}_n$  (aritmetička sredina uzorka):

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

(ona je normalno distribuirana ako je  $X$  normalno distribuirana i aproksimativno je normalna ako smo u uvjetima Centralnog graničnog teorema)

$$\Rightarrow \bar{X}_n^* = \frac{\bar{X}_n - \mu}{\sqrt{\frac{\sigma^2}{n}}} = \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$$

Vrijedi:

$$\Phi_0(z_{\frac{\alpha}{2}}) = \frac{1 - \alpha}{2}$$

i nadalje:

$$\begin{aligned} P(-z_{\frac{\alpha}{2}} \leq \bar{X}_n^* \leq z_{\frac{\alpha}{2}}) &= 1 - \alpha \\ \Leftrightarrow P(-z_{\frac{\alpha}{2}} \leq \frac{\bar{X}_n - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\frac{\alpha}{2}}) &= 1 - \alpha \\ \Leftrightarrow P\left(\bar{X}_n - z_{\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X}_n + z_{\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}}\right) &= 1 - \alpha \end{aligned}$$

$(1 - \alpha) \cdot 100\%$  pouzdan interval za očekivanje normalne populacije  
(varijanca poznata)

$$\bar{X}_n - z_{\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X}_n + z_{\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}}$$

**Zadatak 16** Vrijeme trajanja neke vrste elektronskih cijevi je normalno distribuirana slučajna varijabla  $X$  s nepoznatim očekivanjem  $\mu$  i standardnom devijacijom  $\sigma = 40h$ .

a) Uzet je uzorak od 30 elektronskih cijevi za koji je dobiveno prosječno vrijeme trajanje od 780h. Nađite 99% pouzdan interval za očekivanje  $\mu$  vremena trajanja ove vrste elektronskih cijevi.

b) Koliki uzorak treba uzeti da bi se s vjerojatnošću 0.99, sredina uzorka  $\bar{x}$  razlikovala od sredine  $\mu$  manje od 10h?

Rješenje:

$$X \sim N(\mu, 40^2)$$

a)  $n = 30, \quad \bar{x}_{30} = 780, \quad \alpha = 0.01$

$$\Phi_0(z_{\frac{\alpha}{2}}) = \Phi_0(z_{0.005}) = \frac{1 - \alpha}{2} = 0.495 \Rightarrow z_{0.005} = 2.58$$

99% pouzdan interval za očekivanje:

$$\begin{aligned}\bar{x}_{30} \pm z_{0.005} \cdot \frac{\sigma}{\sqrt{n}} &= 780 \pm 2.58 \cdot \frac{40}{\sqrt{30}} = 780 \pm 18.84 \\ \Rightarrow 761.16 &\leq \mu \leq 798.84\end{aligned}$$

b)  $P(|\bar{X}_n - \mu| < 10) = 0.99, \quad n = ?$

$$P(-10 < \bar{X}_n - \mu < 10) = P\left(-\frac{10}{\frac{\sigma}{\sqrt{n}}} < \frac{\bar{X}_n - \mu}{\frac{\sigma}{\sqrt{n}}} < \frac{10}{\frac{\sigma}{\sqrt{n}}}\right)$$

$$= P\left(-\frac{10\sqrt{n}}{40} < \bar{X}_n^* < \frac{10\sqrt{n}}{40}\right) = 0.99$$

$$\Rightarrow \Phi_0\left(\frac{\sqrt{n}}{4}\right) - \Phi_0\left(-\frac{\sqrt{n}}{4}\right) = 0.99 \Leftrightarrow 2\Phi_0\left(\frac{\sqrt{n}}{4}\right) = 0.99 \Leftrightarrow \Phi_0\left(\frac{\sqrt{n}}{4}\right) = 0.495$$

$$\Rightarrow \frac{\sqrt{n}}{4} = 2.58 \Leftrightarrow \sqrt{n} = 10.32 \Rightarrow n = 106.5$$

$$\Rightarrow n \geq 107, \quad \text{tj. treba uzeti uzorak duljine bar 107.}$$

□

**Zadatak 17 (DZ)** Neka mašina proizvodi kuglične ležajeve. Promjer kugličnog ležaja je normalna slučajna varijabla  $X$  s varijancom 1. Dužine 9 slučajno odabranih kugličnih ležajeva bile su

20.1, 19.9, 20.0, 19.8, 19.7, 20.2, 20.1, 23.1, 22.8.

Odredite 95% pouzdan interval za matematičko očekivanje slučajne varijable  $X$ .

### 5.3.2 Varijanca nepoznata

Neka je  $X \sim N(\mu, \sigma^2)$ ,  $\mu$  i  $\sigma^2$  nepoznati

- želimo naći  $(1 - \alpha) \cdot 100\%$  pouzdan interval za  $\mu$
- imamo slučajan uzorak veličine  $n : X_1, \dots, X_n$
- $\bar{X}_n$  : aritmetička sredina uzorka

- varijancu  $\sigma^2$  **procijenimo** pomoću  $S_n^2$

$$S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

( $S_n^2$  je nepristran i konzistentan procjenitelj za  $\sigma^2$ )

- standardiziranu varijablu

$$\bar{X}_n^* = \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n}$$

aproximativno zapisujemo pomoću procjene za  $\sigma^2$ :

$$T_n := \frac{\bar{X}_n - \mu}{S_n} \sqrt{n}$$

Statistika  $T_n$  ima **Studentovu ili t-distribuciju** s  $(n-1)$  stupnjeva slobode :  $T_n \sim t(n-1)$

Vrijedi:

$$\begin{aligned} P(-t_{\frac{\alpha}{2}}(n-1) \leq T_n \leq t_{\frac{\alpha}{2}}(n-1)) &= 1 - \alpha \\ \Leftrightarrow P\left(-t_{\frac{\alpha}{2}}(n-1) \leq \frac{\bar{X}_n - \mu}{\frac{S_n}{\sqrt{n}}} \leq t_{\frac{\alpha}{2}}(n-1)\right) &= 1 - \alpha \\ \Leftrightarrow P\left(\bar{X}_n - t_{\frac{\alpha}{2}}(n-1) \cdot \frac{S_n}{\sqrt{n}} \leq \mu \leq \bar{X}_n + t_{\frac{\alpha}{2}}(n-1) \cdot \frac{S_n}{\sqrt{n}}\right) &= 1 - \alpha \end{aligned}$$

$(1 - \alpha) \cdot 100\%$  pouzdan interval za očekivanje normalne populacije  
(varijanca nepoznata)

$$\bar{X}_n - t_{\frac{\alpha}{2}}(n-1) \cdot \frac{S_n}{\sqrt{n}} \leq \mu \leq \bar{X}_n + t_{\frac{\alpha}{2}}(n-1) \cdot \frac{S_n}{\sqrt{n}}$$

Napomena: Za  $n \rightarrow \infty$ , Studentova razdioba po distribuciji konvergira jediničnoj normalnoj razdiobi. Za broj stupnjeva slobode  $n-1 \geq 30$  možemo aproksimativno uzeti da je  $t(n-1) \approx N(0,1)$

**Zadatak 18** NASA testira komponente svojih raketa. Recimo da NASA želi procijeniti srednje vrijeme trajanja neke mehaničke komponente korištene

u raketi "Columbia". Zbog ograničenja troškova, u simuliranim uvjetima svemira mogu testirati samo 10 komponenti. Dobiveni su podaci za vrijeme trajanja tih komponenti (u satima):  $\bar{x}_{10} = 1173.6$ ,  $s_{10} = 36.3$ . Procijenite očekivanje vijeka trajanja tih mehaničkih komponenti s 95% pouzdanim intervalom (pretpostavite da je vrijeme trajanja mehaničkih komponenti normalno distribuirano).

Rješenje:

$$\begin{aligned}
 1 - \alpha = 0.95 &\Leftrightarrow \alpha = 0.05 \Leftrightarrow \frac{\alpha}{2} = 0.025 \\
 t_{0.025}(9) &= 2.262 \\
 \bar{x}_{10} \pm t_{0.025}(9) \cdot \frac{s_{10}}{\sqrt{n}} &= 1173.6 \pm 2.262 \frac{36.3}{\sqrt{10}} = 1173.6 \pm 25.97 \\
 \Rightarrow 1147.63 &\leq \mu \leq 1199.57
 \end{aligned}$$

□

**Zadatak 19 (DZ)** U svrhu istraživanja utjecaja toksičnih tvari koje luči jedna vrsta plijesni na kukuruz, biokemičar u 9 ekstrakata plijesni mjeri količinu toksičnih supstanci u mg. Dobiveni su rezultati: 1.2, 0.8, 0.6, 1.1, 1.2, 0.9, 1.5, 0.9, 1.0. Uz pretpostavku da su podaci iz normalne distribucije, procijenite 98% pouzdan interval za očekivanje te populacije.

## 5.4 Pouzdani intervali za očekivanje populacije na osnovi velikih uzoraka

- pretpostavimo da je zadan slučajni uzorak  $X_1, X_2, \dots, X_n$  velike duljine ( $n \rightarrow \infty$ ) za  $X$  općenito nepoznate razdiobe, ali konačne varijance
- neka je  $\mu$  parametar očekivanja i  $\sigma^2$  varijanča
- želimo konstruirati aproksimativni pouzdani interval za  $\mu$
- prema Centralnom graničnom teoremu,

$$\frac{\bar{X}_n - \mu}{\sigma} \sqrt{n} \xrightarrow{D} N(0, 1), \quad n \rightarrow \infty$$



- nadalje, zbog konzistentnosti,  $S_n \rightarrow \sigma$ , pa

$$\frac{\bar{X}_n - \mu}{S_n} \sqrt{n} \xrightarrow{D} N(0, 1), \quad n \rightarrow \infty$$

Dakle, za velike  $n$  ( $n \rightarrow \infty$ ) vrijedi

$$\frac{\bar{X}_n - \mu}{S_n} \sqrt{n} \stackrel{D}{\approx} N(0, 1)$$

pa se  $(1 - \alpha)100\%$  pouzdani interval konstruira kao u slučaju normalne populacije s poznatom varijancom (za  $\sigma \approx S_n$ )

$(1 - \alpha) \cdot 100\%$  pouzdan interval za očekivanje populacije

na osnovi velikih uzoraka

$$\bar{X}_n - z_{\frac{\alpha}{2}} \cdot \frac{S_n}{\sqrt{n}} \leq \mu \leq \bar{X}_n + z_{\frac{\alpha}{2}} \cdot \frac{S_n}{\sqrt{n}}$$

**Zadatak 20** Zoolog želi procijeniti očekivanu količinu šećera u krvi određene životinjske vrste nastale nakon ubrizgavanja određene količine adrenalina. Dobivena srednja vrijednost uzorka od 55 životinja je 126.9 mg/100 ml uz standardnu devijaciju uzorka od 10.5 mg /100 ml. Odredite 90% pouzdan interval za očekivanje.

Rješenje:

$$\begin{aligned} n &= 55, & \bar{x}_{55} &= 126.9, & s_{55} &= 10.5 \\ 1 - \alpha &= 0.9 \Leftrightarrow \alpha = 0.1 \Leftrightarrow \frac{\alpha}{2} = 0.05 \\ \Phi_0(z_{0.05}) &= \frac{0.9}{2} = 0.45 \Rightarrow z_{0.05} = 1.65 \\ 126.9 \pm 1.65 \cdot \frac{10.5}{\sqrt{55}} &= 126.9 \pm 2.34 \\ \Rightarrow 124.56 &\leq \mu \leq 129.24 \end{aligned}$$

#### 5.4.1 Pouzdan interval za parametar $p$ binomne razdiobe

Tražimo  $(1 - \alpha)100\%$  pouzdani interval za proporciju  $p$

$$X \sim B(n, p), \quad E[X] = np, \quad \text{Var}[X] = npq, \quad q = 1 - p$$

$\hat{P} = \frac{X}{n} = \bar{X}$  je nepristrani procjenitelj od  $p$ , tj.  $E[\hat{P}] = p$

$$\begin{aligned} E[\hat{P}] &= E\left[\frac{X}{n}\right] = \frac{1}{n} E[X] = \frac{1}{n} \cdot np = p \\ \text{Var}[\hat{P}] &= \text{Var}\left[\frac{X}{n}\right] = \frac{1}{n^2} \text{Var}[X] = \frac{1}{n^2} \cdot npq = \frac{pq}{n} \\ \Rightarrow \bar{X} = \hat{P} &\sim N\left(p, \frac{pq}{n}\right) \\ \Rightarrow \bar{X}^* &= \frac{\bar{X} - p}{\sqrt{\frac{pq}{n}}} \sim N(0, 1) \end{aligned}$$

Imamo:

$$\begin{aligned} P(-z_{\frac{\alpha}{2}} \leq \bar{X}^* \leq z_{\frac{\alpha}{2}}) &= 1 - \alpha \\ \Leftrightarrow P(-z_{\frac{\alpha}{2}} \leq \frac{\bar{X} - p}{\sqrt{\frac{pq}{n}}} \leq z_{\frac{\alpha}{2}}) &= 1 - \alpha \\ \Leftrightarrow P\left(\bar{X} - z_{\frac{\alpha}{2}} \cdot \sqrt{\frac{pq}{n}} \leq p \leq \bar{X} + z_{\frac{\alpha}{2}} \cdot \sqrt{\frac{pq}{n}}\right) &= 1 - \alpha \end{aligned}$$

Za veliki  $n$ , dobit ćemo dovoljno dobre rezultate ako zamijenimo  $p$  s  $\bar{X} = \hat{p}$ :

$$\boxed{\bar{X} - z_{\frac{\alpha}{2}} \cdot \sqrt{\frac{\bar{X}(1-\bar{X})}{n}} \leq p \leq \bar{X} + z_{\frac{\alpha}{2}} \cdot \sqrt{\frac{\bar{X}(1-\bar{X})}{n}}}$$

**Zadatak 21** Uzorak od 100 kućanstava nekog grada pokazao je da se u 55% kućanstava bar jedan član koristi Internetom.

a) Nađite 95% pouzdan interval za omjer kućanstava u tom gradu koja se služe Internetom.

b) Koliko kućanstava treba uzeti da bi s vjerojatnošću od 0.95 mogli tvrditi da se najmanje 50% kućanstava služi Internetom?

Rješenje:

$$\begin{aligned} \text{a)} \quad \hat{p} = \bar{x} &= 0.55, \quad n = 100 \\ 1 - \alpha &= 0.95 \Leftrightarrow \alpha = 0.05 \Leftrightarrow \frac{\alpha}{2} = 0.025 \\ z_{\frac{\alpha}{2}} &= z_{0.025} = 1.96 \end{aligned}$$

$$\hat{p} \pm z_{\frac{\alpha}{2}} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} = 0.55 \pm 1.96 \sqrt{\frac{0.55 \cdot 0.45}{100}} = 0.55 \pm 0.09751$$

$$\implies 0.4525 \leq p \leq 0.6475$$

b)  $n = ?$

$$P \left( 0.55 - 1.96 \sqrt{\frac{0.55 \cdot 0.45}{n}} \leq p \leq 0.55 + 1.96 \sqrt{\frac{0.55 \cdot 0.45}{n}} \right) = 0.95$$

želimo da vrijedi:  $p \geq 0.5$  pa odatle

$$0.55 - 1.96 \sqrt{\frac{0.55 \cdot 0.45}{n}} \geq 0.5 \Leftrightarrow \frac{0.9751}{\sqrt{n}} \leq 0.05$$

$$\Leftrightarrow \sqrt{n} \geq 19.502 \Rightarrow n \geq 380.328$$

$$\implies n \geq 381$$

□