

# Intervali poverenja

Danijel Subotic

## INTERVALI POVERENJA

Želimo da nađemo takve statistike  $U_n$  i  $V_n$  da za nepoznati parametar Teta i za vrednost beta (unapred zadatom) važi:

$$P\{U_n \leq \Theta \leq V_n\} = \beta$$

beta nazivamo nivo poverenja.

- (1) Naći 95%-tni interval poverenja za parametar “ $m$ ”, ako je naša slučajna veličina  $X \sim \mathcal{N}(m, \sigma^2)$ . Poznato nam je  $\sigma^2$  i  $n$  - broj elemenata u prostom slučajnom uzorku. I neka su to  $n = 64$ ,  $\bar{x}_n = 118$ ,  $\beta = 0.95$  i  $\sigma^2 = 100$ .

Rešenje:

Imamo da važi sledeće

$$T = \frac{\bar{X}_n - m}{\sigma} \sqrt{n} \sim \mathcal{N}(0, 1)$$

to  $T$  ce da nam služi kao pomocna statistika za odredjivanje statistika  $U_n$  i  $V_n$ .

Kako je  $T$  iz normalne raspodele to uvek mozemo naci konstantu  $c$  tako da vazi

$$P\{|T| \leq c\} = \beta$$

i to je  $c = \Phi^{-1}\left(\frac{1+\beta}{2}\right)$ .

Dalje iz nejednakosti u verovatnoci dobijamo sledece

$$U_n = \bar{X}_n - \frac{c \cdot \sigma}{\sqrt{n}} \leq m \leq \bar{X}_n + \frac{c \cdot \sigma}{\sqrt{n}} = V_n$$

```
#
n=64
x_sr=118
beta=0.95
sigma_kv= 100 # - poznata vrednost

# Resenje:
c=qnorm((1+beta)/2, 0, 1) # isto sto i qnorm((1+beta)/2) isto sto i qnorm(0.975)
c

## [1] 1.959964

interval_1=x_sr-c*sqrt(sigma_kv/n)
interval_2=x_sr+c*sqrt(sigma_kv/n)
interval_1
```

```
## [1] 115.55
```

```
interval_2
```

```
## [1] 120.45
```

```
(interval_poverenja=c(interval_1, interval_2))
```

```
## [1] 115.55 120.45
```

(1\*) U slučaju da nije poznato da je  $\sigma_{kv}=100$ , moramo oceniti disperziju. Pretpostavimo da je vrednost ocenjene disperzije jednaka takodje 100. Naci interval poverenja u tom slucaju.

Rešenje: jedina razlika u izvođenju u odnosu na prethodni zadatak je u tome što sada nije reč o normalnoj raspodeli za pomoćnu statistiku  $T$ , već je Studentova sa  $n - 1$  stepeni slobode.

```
c = qt(p = (1+beta)/2, df = n-1) # inverzna funkcija raspodele za studentovu  
c
```

```
## [1] 1.998341
```

```
ocenjena_sigma_kv = 100  
interval_1=x_sr-c*sqrt(ocenjena_sigma_kv/n)  
interval_2=x_sr+c*sqrt(ocenjena_sigma_kv/n)
```

```
c(interval_1, interval_2)
```

```
## [1] 115.5021 120.4979
```

(2) Naci 95%-tni interval poverenja za  $m$  na osnovu uzorka obima  $n$  ako je  $X \sim \mathcal{N}(m, \sigma^2)$ ,  $\sigma^2$  - nepoznato. Vrednosti su  $n = 25$ ,  $\bar{x}_n = 2.6$ ,  $\bar{s}_n = 170.36$  i  $\beta = 0.95$ .

Resenje:

```
n=25  
x_sr=2.6  
ocena_sigma_kv=170.36  
beta=0.95
```

```
c=qt((1+beta)/2, n-1) #qt - kvantili studentove raspodele, drugi argument predstavlja broj stepeni slob  
print(c)
```

```
## [1] 2.063899
```

```
#Dok je interval jednak:  
(interval_poverenja=c(x_sr-c*sqrt(ocena_sigma_kv/n), x_sr+c*sqrt(ocena_sigma_kv/n) ))
```

```
## [1] -2.787685 7.987685
```

U slučaju da primenimo ovakav interval poverenja i na prvi zadatak. Moramo da dobijemo nesto širi

```
n=64  
x_sr=118  
beta=0.95  
sigma_kv= 100 # ovde sada smatramo da je to ocenjena vrednost
```

```
c1=qt((1+beta)/2, n-1)  
c1
```

```
## [1] 1.998341
```

```

interval_1=x_sr-c1*sqrt(sigma_kv/n)
interval_2=x_sr+c1*sqrt(sigma_kv/n)
(interval_poverenja=c(interval_1, interval_2))

```

```
## [1] 115.5021 120.4979
```

```
# I zaista vidimo da je ova malcice siri interval poverenja.
```

U prva dva zadatka smo pominjali intervale poverenja u slucaju normalne raspodele  $\mathcal{N}(m, \sigma^2)$  za parametar “ $m$ ”.

To je sve bilo za slucaj kada se ocenjuje parametar  $m$ . Dok ako zelimo da intervalno ocenimo  $\sigma^2$  tu je prica malo drugacija.

Statistika koja se koristi za to je:

$$W = \frac{(n-1)\tilde{S}_n^2}{\sigma^2} \sim \chi_{n-1}^2$$

tj Hi-kvadrat sa  $n-1$  stepeni slobode. gde je:  $n$  - obim uzorka,  $\tilde{S}_n^2$  - popravljena uzoracka disperzija,  $\sigma^2$  - parametar koji ocenjujemo.

I sasvim je prirodno da ta statistika, kojom se ocenjuje parametar  $\sigma^2$  ima neku nenegativnu raspodelu, kao sto je Hi-kvadrat.

Za razliku od ocene za “ $m$ ”, gde su u oba slucaja statistike imale simetricne raspodele oko nule, hi-kvadrat nije simetricna, i stavise nenegativna je. Iz tog razloga na vise nacina se moze prirodno definisati interval poverenja za  $\sigma^2$ . kao na primer:

Napomena: sve granice intervala koje cu da navodim dole, tj  $(A_n, B_n, U_n, V_n)$  su zapravo granice za statistiku(!) ne i za parametar. A tek kad se dobiju granice za stistiku - moramo da nadjemo bas Interval poverenja za trazeni parametar  $\sigma^2$ .

- (a) Donji interval, tj  $(0, A_n]$ , tj da pocinje uvek od nule, pa ide do vrednosti gde se dostigne trazena  $\beta$ , gde se  $A_n$  nalazi bas iz:

$$P\{W \leq A_n\} = \beta \implies A_n = F^{-1}(\beta),$$

gde je  $F^{-1}$  inverzna funkcija za funkciju raspodele koju ima statistika  $W$ . sto se u R-u poziva na sledeci nacin:  $A_n = qchisq(beta, n-1)$  gde je  $qchisq()$  - funkcija pomocu koje dobijamo kvantile hi-kvadrat raspodele.

- (b) Dvostrani interval:  $[U_n, V_n]$ , gde se granice biraju tako da je levo i desno od tog intervala ista površina koja je jednaka  $(1-\beta)/2$ , za dato “ $\beta$ ”. Nalazimo ih pomocu:

$$P\{W \leq U_n\} = (1-\beta)/2 \implies U_n = qchisq((1-\beta)/2, n-1).$$

$$P\{W \leq V_n\} = (1+\beta)/2 \implies V_n = qchisq((1+\beta)/2, n-1).$$

Ovde je  $(1+\beta)/2$ , jer je prosto površina koja je pre vrednosti  $V_n$  mora da bude  $\beta + (1-\beta)/2$  sto je bas jednako  $(1+\beta)/2$ .

- (v) Gornji interval: slicno kao donji, smo sto nije ogranicen sa gornje strane pa je interval  $[B_n, +\infty)$ .  $B_n$  iz formule:

$$P\{W \leq B_n\} = 1-\beta \implies B_n = qchisq(1-\beta, n-1).$$

- (3) Neka je dato:  $X \sim \mathcal{N}(m, \sigma^2)$ .  $n = 20$ ,  $\tilde{S}_n^2 = 21.12$  - popravljena uzoracka disperzija. Naci dvostrani interval poverenja za parametar  $\sigma^2$  za nivo poverenja  $\beta = 0.99$ .

Resenje:

Potrebno je naci interval oblika:

$$W = \frac{(n-1)\tilde{S}_n^2}{\sigma^2} \sim \chi_{n-1}^2$$

$$P\{U_n \leq W \leq V_n\} = 0.99$$

Prema gore navedenoj teoriji: vrednost za  $V_n$  mora za bude vrednost  $F^{-1}\left(\frac{1.99}{2}\right)$ .  $v_n = qchisq(1.99/2, 19)$

Vrednost za  $U_n$  mora za bude vrednost  $F^{-1}\left(\frac{0.01}{2}\right)$   $u_n = qchisq(0.01/2, 19)$

Odakle dobijamo sledeci izraz iz kojeg moramo da nadjemo interval poverenja.

$$P\{6.85 \leq (n-1)\tilde{S}_n^2/\sigma^2 \leq 38.6\}$$

$$P\{6.85 \leq (n-1)\tilde{S}_n^2/\sigma^2 \leq 38.6\}$$

Sto je dalje jednako:  $P\{(n-1) * 21.12/38.6 \leq \sigma^2 \leq (n-1) * 21.12/6.85\}$

Donja vrednost intervala poverenja:  $a = (n-1)*21.12/v\_n$

Gornja vrednost intervala poverenja:  $b = (n-1)*21.12/u\_n$

`n=20`

```
v_n = qchisq(1.99/2, n-1)
```

```
u_n = qchisq(0.01/2, n-1)
```

```
a = (n-1)*21.12/v_n
```

```
b = (n-1)*21.12/u_n
```

```
(interval=c(a,b)) # trazeni interval poverenja
```

```
## [1] 10.40064 58.63262
```

Probajte da uradite gornji i donji interval poverenja za ovaj primer.

Jos jedna vrsta intervala poverenja, koju cemo da razmotrimo su intervali poverenja za parametar  $p$  u Bernulijevoj raspodeli. Neka je  $X \sim Ber(p) = Bin(1, p)$  i zelimo da ocenimo parametar  $p$ .

Tada to mozemo oceniti intervalno pomocu statistike:

$$Z = (\bar{X}_n - p)\sqrt{n}/\sqrt{p(1-p)} \sim \mathcal{N}(0, 1).$$

I dalje je ocenjivanje jako slicno kao za parametar “ $m$ ” sto smo imali, s tim sto ovde imamo “malo vise” javljanja parametra “ $p$ ” u datoj statistici, nego sto je to bilo u slucaju parametra “ $m$ ”.

Stoga u opstem slucaju moracemo da resavamo kvadratnu nejednacinu i da pazimo da granice ne izadju izvan intervala  $(0, 1)$  - jer ocenjujemo parametar  $p$  - koji predstavlja verovatnocu nekog dogadjaja!

Dok u nekim specijalnim slucajevima mozemo umesto  $p(1-p)$  koristiti  $\bar{X}_n(1-\bar{X}_n)$ . Za to mora da bude ispunjeno: - parametar  $p$  - ne sme da bude blizu 0 ili 1. -  $n \geq 100$ , tj da imamo dovoljno mnogo elemenata uzorka. U tom slucaju vise nemamo kvadratne nejednacine vec direktne vrednosti koje cemo da ubacimo i brzo izrazimo i dobijemo trazeni interval poverenja.

- (4) Od 500 ljudi, 185 se izjasnilo protiv. Naci 90% interval poverenja za verovatnocu da se slucajno odabrana osoba izjasni protiv.

Resenje:

Kako se ta statistika aproksimira normalnom raspodelom, odmah nadjemo trazenu vrednost za “ $c$ ”. Primitimo da je  $(1 + \beta)/2 = (1 + 0.9)/2 = 0.95$  Dalje imamo:

$$P\{-c \leq (\bar{X}_n - p)/\sqrt{p(1-p)}\sqrt{n} \leq c\}$$

mozemo da aproksimiramo sa  $\bar{x}_n(1 - \bar{x}_n)$  jer je  $n=500 > 100$  i  $p \sim 0.57$

```
c=qnorm(0.95) c
```

```
c=qnorm(0.95)
c
```

```
## [1] 1.644854
```

```
n=500
x_sr=185/500
x_sr
```

```
## [1] 0.37
```

```
# dalje nadjemo donju, odnosno gornju vrednost intervala:
```

```
a=x_sr-c*sqrt(x_sr*(1-x_sr))/sqrt(n)
b=x_sr+c*sqrt(x_sr*(1-x_sr))/sqrt(n)
```

```
# trazeni interval poverenja za "p":
(interval=c(a,b))
```

```
## [1] 0.3344849 0.4055151
```

- (5) Istrazivac procenjuje procenat gojaznih osoba sa visokim krvnim pritiskom. Od 25 ispitanika - 20 ima visok pritisak. Naci 95% interval poverenja za parametar  $p$ , koji predstavlja verovatnocu da gojazna osoba ima visok krvni pritisak.

Resenje:

Ovde ne mozemo da primenimo aproksimaciju, jer  $n=25 < 100$ . Zato moramo da resimo kvadratnu nejednacinu. Ali pre toga vrednost za c:

```
beta=0.95
c=qnorm((1+beta)/2)
c
```

```
## [1] 1.959964
```

```
#
x_sr=20/25
# P{-c <= (X_{sr} - p) / sqrt(p*(1-p)) * sqrt(n) <= c}
# = P{-1.96 <= (0.8 - p) / sqrt(p*(1-p)) * 5 <= 1.96}
# = P{|0.8 - p| <= 1.96 * sqrt(p*(1-p)) / 5} sto sada kvadriramo:
# = P{0.8^2 - 1.6*p + p^2 <= 1.96^2 * (p - p^2) / 25}
# odakle klasicnim metodama dobijamo:
# (vrednosti su zaokružene na dve decimale)
a=0.61
b=0.91
(interval=c(a,b))
```

```
## [1] 0.61 0.91
```

- (6) Naci 90% i 80% interval poverenja za istrazivanje u kojem je ucestvovalo 100 ljudi i srednja vrednost je 0.45.

Resenje:

Mozemo iskoristiti aproksimacije za parametar  $p$  zbog velicine uzorka.

```
X_sr = 0.45
```

```

# Z = (X_sr - p) / sqrt[X_sr(1-X_sr)] * sqrt(n)
c_90 = qnorm((1+0.9)/2) # 1.64
c_80 = qnorm((1+.8)/2) # 1.28

(interval_90 = c(0.45 - c_90*sqrt(0.45*.55) / 10, 0.45 + c_90*sqrt(0.45*.55) / 10 ) )

## [1] 0.3681696 0.5318304

(interval_80 = c(0.45 - c_80*sqrt(0.45*.55) / 10, 0.45 + c_80*sqrt(0.45*.55) / 10 ) )

## [1] 0.3862436 0.5137564

```

(7) Student zeli da istrazi procenat levorukih osoba. Ispitano je 100 ljudi od kojih je samo 5 levorukih. Ako se nadje 90% interval poverenja da li ce on sadrzati vrednost 0.1? Ako ne - koliko-procentni interval poverenja treba da trazimo?

Da li 0.1 pripada (a, b) , ako  $P(a \leq p \leq b) = 0.9$ ?

Resenje:  $p \sim 5\%$ , sto jeste blizu nule. Ovde ne smemo da koristimo aproksimaciju za disperziju uzorka.

Test statistika nam je

$$Z = \sqrt{n} \frac{\bar{X}_n - p}{\sqrt{p(1-p)}}$$

tj. dalje imamo:

$$P\{a \leq p \leq b\} = 0.9$$

i

$$P\{-c \leq Z \leq c\} = 0.9$$

Odakle imamo

$$c = \Phi^{-1}(0.95)$$

Odnosno imamo

$$P\{|\bar{X}_n - p| \leq c\sqrt{p(1-p)/n}\} = P\{\bar{X}_n^2 - 2p\bar{X}_n + p^2 \leq c^2p(1-p)/n\}$$

I resavanjem ove kvadratne nejednacine po  $p$  dobijamo trazene granice intervala poverenja.

```

a = 0.025
b = 0.099
(interval_1 = c(a, b) )

```

```
## [1] 0.025 0.099
```

```
# ne upada 0.1
```

```

# ali za beta = 0.91 vec upada jer je c tada
c = qnorm((1+0.91)/2) # 1.69
# i interval je (0.024, 0.10001) otprilike.

```

(8) Od poslednjih 10 puta kada je tostirani sendvic pao - devet puta je pao na "ukusnu stranu". Ako je uzorak iz Bernulijeve raspodele sa parametrom  $p$ , naci 80% interval poverenja da sendvic pada na "ukusnu stranu".

Resenje:

$\bar{X}_{10} = 0.9$  sto nije dovoljno daleko od 1, a i  $n = 10$  je bas malo. Test statistika je

$$Z = \frac{\bar{X}_{10} - p}{\sqrt{p(1-p)/10}}$$

I opet resavanjem odgovarajuce kvadratne nejednacine dobijamo granice intervala poverenja za  $p$ .

Kod:

```
#P{a<=p<=b} = P{-c <= Z <= c} = 0.8
c = qnorm(1.8/2) # 1.28
a = 0.72
b = 0.97
interval = c(a, b)
```

Ukoliko ipak primenimo aproksimaciju:

```
(interval = c(0.9 - c*sqrt(0.1*0.9/10), 0.9 + c*sqrt(0.1*0.9/10) ) )
```

```
## [1] 0.7784213 1.0215787
```

```
# Moramo da izbacimo ove vrednost preko 1 iz intervala poverenja.
```

```
(interval = c(max(0, 0.9 - c*sqrt(0.1*0.9/10)), min(1, 0.9 + c*sqrt(0.1*0.9/10))))
```

```
## [1] 0.7784213 1.0000000
```

```
# Dobijamo skroz drugacije intervale.
```

- (9) Izvrшено je ispitivanje 250 ljudi, ocenjeno p odgovora je 0.45. Isto istrazivanje je ponovljeno na 1000 ljudi i dobijen isti odnos. Naci 95% interval poverenja u oba slucaja. Koliko puta je drugi manji od prvog? Koliko veliko treba da bude n u istrazivanju da bi 95% interval poverenja bio duzine ne vece od 0.01.

Resenje:

$$Z = \frac{\bar{X}_n - p}{\sqrt{\bar{X}_n(1 - \bar{X}_n)/n}}$$

```
c_95 = qnorm(0.975) # 1.96
```

```
interval_250 = c(0.45 - c_95*sqrt(0.45*0.55/250), 0.45 + c_95*sqrt(0.45*0.55/250))
# (0.39, 0.51)
diff(interval_250) # 0.12334
```

```
## [1] 0.1233377
```

```
interval_1000 = c(0.45 - c_95*sqrt(0.45*0.55/1000), 0.45 + c_95*sqrt(0.45*0.55/1000))
interval_1000
```

```
## [1] 0.4191656 0.4808344
```

```
# (0.42, 0.48)
```

```
diff(interval_1000) # 0.06167
```

```
## [1] 0.06166883
```

```
# Bolje u obliku funkcije da se zapise.
duzina_intervala <- function(n)
{
  interval_1000 = c(0.45 - c_95*sqrt(0.45*0.55/n), 0.45 + c_95*sqrt(0.45*0.55/n))
  return(diff(interval_1000))
}
duzina_intervala(38031)
```

```
## [1] 0.009999927
```

```
# Trazeno n nalazimo na sledeci nacin:
(duzina_intervala(250)/0.01)^2*250
```

```
## [1] 38030.44
```

```
# ~38031
```