

Statistika

Tačkasto ocjenjivanje nepoznatog parametra

1. Neka je (X_1, \dots, X_n) (prost slučajni) uzorak obilježja X s konačnim očekivanjem m i disperzijom σ^2 .

(a) Dokazati da je $\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$ nepristrasna (centrirana) i postojana ocjena za m .

(b) Ispitati nepristrasnost ocjene $\bar{S}_n^2 = \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X}_n)^2$ za disperziju σ^2 .

(c) Odrediti konstantu c tako da $T_n = c \sum_{k=1}^{n-1} (X_{k+1} - X_k)^2$ bude centrirana ocjena za σ^2 .

◀

(a)

$$\mathbb{E} \bar{X}_n = \mathbb{E} \left(\frac{1}{n} \sum_{k=1}^n X_k \right) = \frac{1}{n} \sum_{k=1}^n \mathbb{E} X_k = \frac{1}{n} \cdot nm = m.$$

Slijedi da je \bar{X}_n centrirana ocjena parametra m .

$$\mathbb{D} \bar{X}_n = \mathbb{D} \left(\frac{1}{n} \sum_{k=1}^n X_k \right) = \frac{1}{n^2} \sum_{k=1}^n \mathbb{D} X_k = \frac{1}{n^2} \cdot n\sigma^2 = \frac{\sigma^2}{n}.$$

Postojanost slijedi na osnovu Hinčinovog zakona velikih brojeva.

Dokažimo po definiciji. Neka je $\varepsilon > 0$ proizvoljan broj. Tada, koristeći Čebišovljevu nejednakost, dobijamo:

$$\mathbb{P} \{ |\bar{X}_n - m| > \varepsilon \} = \mathbb{P} \{ |\bar{X}_n - \mathbb{E} \bar{X}_n| > \varepsilon \} \leq \frac{\mathbb{D} \bar{X}_n}{\varepsilon^2} = \frac{\sigma^2}{n\varepsilon^2} \rightarrow 0, \text{ pri } n \rightarrow \infty,$$

pa slijedi da $\bar{X}_n \xrightarrow{\text{P}} m$, pri $n \rightarrow \infty$, odnosno \bar{X}_n je postojana ocjena parametra m .

(b) Važi

$$\begin{aligned}\bar{S}_n^2 &= \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X}_n)^2 = \frac{1}{n} \sum_{k=1}^n (X_k^2 - 2X_k \bar{X}_n + \bar{X}_n^2) \\ &= \frac{1}{n} \sum_{k=1}^n X_k^2 - 2\bar{X}_n \cdot \frac{1}{n} \sum_{k=1}^n X_k + \bar{X}_n^2 \\ &= \frac{1}{n} \sum_{k=1}^n X_k^2 - 2\bar{X}_n^2 + \bar{X}_n^2 \\ &= \frac{1}{n} \sum_{k=1}^n X_k^2 - \bar{X}_n^2,\end{aligned}$$

pa je

$$\begin{aligned}\mathbb{E} \bar{S}_n^2 &= \mathbb{E} \left(\frac{1}{n} \sum_{k=1}^n X_k^2 - \bar{X}_n^2 \right) = \frac{1}{n} \sum_{k=1}^n \mathbb{E} X_k^2 - ((\mathbb{E} \bar{X}_n)^2 + D \bar{X}_n) \\ &= \frac{1}{n} \cdot n \cdot \mathbb{E} X^2 - (\mathbb{E} X)^2 - \frac{\sigma^2}{n} \\ &= \sigma^2 - \frac{\sigma^2}{n} \\ &= \sigma^2 \left(1 - \frac{1}{n} \right) < \sigma^2 \text{ za } n > 1.\end{aligned}$$

Slijedi da \bar{S}_n^2 nije centrirana ocjena za σ^2 , ali jeste asimptotski centrirana, jer važi

$$\mathbb{E} \bar{S}_n^2 = \sigma^2 \left(1 - \frac{1}{n} \right) \rightarrow \sigma^2, \text{ pri } n \rightarrow \infty.$$

Primijetimo da iz $\mathbb{E} \bar{S}_n^2 = \sigma^2 \cdot \frac{n-1}{n}$ slijedi

$$\mathbb{E} \left(\frac{n}{n-1} \cdot \bar{S}_n^2 \right) = \sigma^2,$$

pa je

$$\hat{S}_n^2 := \frac{n}{n-1} \cdot \bar{S}_n^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X}_n)^2$$

centrirana ocjena za σ^2 .

(c)

$$\begin{aligned}\mathbb{E} T_n &= c \sum_{k=1}^{n-1} \mathbb{E} (X_{k+1} - X_k)^2 = c(n-1) \mathbb{E} (X_2 - X_1)^2 \\ &= c(n-1) (\mathbb{E} X_1^2 - 2\mathbb{E} (X_1) \mathbb{E} (X_2) + \mathbb{E} X_2^2) \\ &= c(n-1) (2\mathbb{E} X^2 - 2(\mathbb{E} X)^2) \\ &= 2c(n-1) \sigma^2.\end{aligned}$$

Da bi ocjena T_n bila centrirana treba da važi $2c(n-1) = 1$, odnosno $c = \frac{1}{2(n-1)}$.

►

- 2.** U kutiji se nalazi N kuglica numerisanih brojevima od 1 do N , N je nepoznato. Iz kutije se po modelu sa vraćanjem izvlače dvije kuglice. Neka je X_1 broj na prvoizvučenoj, a X_2 broj na drugoizvučenoj kuglici. Nepoznato N ocjenjuje se statistikom

$$V = \frac{3}{2} \max\{X_1, X_2\} - \frac{3}{4}.$$

Naći EV.



Neka je $Y_2 = \max\{X_1, X_2\}$ uzorački maksimum.

Raspodjela slučajne veličine Y_2 je:

$$P\{Y_2 = k\} = \frac{k^2 - (k-1)^2}{N^2} = \frac{2k-1}{N^2}, \quad k = 1, \dots, N.$$

Očekivanje za Y_2 :

$$\begin{aligned} EY_2 &= \sum_{k=1}^N k \cdot \frac{2k-1}{N^2} = \frac{2}{N^2} \sum_{k=1}^N k^2 - \frac{1}{N^2} \sum_{k=1}^N k \\ &= \frac{2}{N^2} \cdot \frac{N(N+1)(2N+1)}{6} - \frac{1}{N^2} \cdot \frac{N(N+1)}{2} \\ &= \frac{2}{3}N + \frac{1}{2} - \frac{1}{6N}. \end{aligned}$$

Slijedi

$$\begin{aligned} EV &= \frac{3}{2} EY_2 - \frac{3}{4} \\ &= \frac{3}{2} \left(\frac{2}{3}N + \frac{1}{2} - \frac{1}{6N} \right) - \frac{3}{4} \\ &= N - \frac{1}{4N}. \end{aligned}$$



- 3.** U kutiji se nalaze bijele i crne kuglice i znamo da ih ukupno ima $N > 1$. Iz kutije se (a) po modelu sa vraćanjem (b) po modelu bez vraćanja izvlači n kuglica (u slučaju (b) pretpostaviti $n \leq N$). Neka je μ_n broj bijelih kuglica u uzorku od n izvučenih, a M nepoznati broj bijelih kuglica u kutiji (prije izvlačenja). Vjerovatnoća $p = \frac{M}{N}$ se ocjenjuje statistikom $p_n^* = \frac{\mu_n}{n}$. Izračunati $E p_n^*$ i $D p_n^*$.



(a) Očigledno $\mu_n : \mathcal{B}(n, p)$, pa je

$$E p_n^* = \frac{1}{n} E \mu_n = \frac{1}{n} \cdot np = p$$

i

$$D p_n^* = \frac{1}{n^2} D \mu_n = \frac{1}{n^2} \cdot np(1-p) = \frac{p(1-p)}{n}.$$

(b) U ovom slučaju je $\mu_n : \mathcal{H}(M, N - M, n)$. Koristeći indikatore (uraditi za vježbu!) dobija se $E\mu_n = \frac{nM}{N}$ i $D\mu_n = \frac{nM(N-M)(N-n)}{N^2(N-1)}$, pa je

$$E p_n^* = \frac{1}{n} E\mu_n = \frac{M}{N} = p$$

i

$$D p_n^* = \frac{1}{n^2} D\mu_n = \frac{1}{n^2} \cdot \frac{nM(N-M)(N-n)}{N^2(N-1)} = \frac{p(1-p)}{n} \cdot \frac{N-n}{N-1}.$$

►

4. Obilježje X ima $\mathcal{U}(0, 2\theta)$, $\theta > 0$, raspodjelu, θ je nepoznati parametar. Parametar θ se na osnovu uzorka (X_1, \dots, X_{2n+1}) ocjenjuje statistikom Y_{n+1} ($n+1$ -va po veličini u datom uzorku). Dokazati da je ocjena Y_{n+1} postojana.

◀

Gustinu k -te statistike poretka Y_k smo izvodili na predmetu Teorija vjerovatnoće (pogledati Primjer 2.5.42.).

Potražimo k -tu statistiku poretka uzorka (X_1, \dots, X_n) apsolutno-neprekidnog obilježja X čija je funkcija raspodjele $F(\cdot)$ i funkcija gustine $f(\cdot)$, na nešto drugačiji način.

Neka je $W_x = \{j : X_j < x\}$. Tada važi

$$F_{Y_k}(x) = P\{Y_k < x\} = P\{|W_x| \geq k\} = \sum_{j=k}^n \binom{n}{j} (F(x))^j (1 - F(x))^{n-j}.$$

Diferenciranjem dobijamo

$$\begin{aligned} f_{Y_k}(x) &= \sum_{j=k}^n \binom{n}{j} \cdot (j \cdot (F(x))^{j-1} (1 - F(x))^{n-j} f(x) - (F(x))^j (n-j) (1 - F(x))^{n-j-1} f(x)) \\ &= f(x) \left(\sum_{j=k}^n j \binom{n}{j} (F(x))^{j-1} (1 - F(x))^{n-j} - \sum_{j=k}^{n-1} (n-j) \binom{n}{j} (F(x))^j (1 - F(x))^{n-j-1} \right). \end{aligned}$$

Koristeći poznate binomne identitete

$$j \binom{n}{j} = n \binom{n-1}{j-1} \quad \text{i} \quad (n-j) \binom{n}{j} = n \binom{n-1}{j},$$

dobijamo

$$\begin{aligned} f_{Y_k}(x) &= n f(x) \left(\sum_{j=k}^n \binom{n-1}{j-1} (F(x))^{j-1} (1 - F(x))^{n-1-(j-1)} - \sum_{j=k}^{n-1} \binom{n-1}{j} (F(x))^j (1 - F(x))^{n-1-j} \right) \\ &= n f(x) \binom{n-1}{k-1} (F(x))^{k-1} (1 - F(x))^{n-k}. \end{aligned}$$

Za dobijanje posljednje jednakosti smo uočili da je

$$\sum_{j=k}^{n-1} \binom{n-1}{j} (F(x))^j (1-F(x))^{n-1-j} = \sum_{j=k+1}^n \binom{n-1}{j-1} (F(x))^{j-1} (1-F(x))^{n-1-(j-1)}.$$

Dakle,

$$f_{Y_k}(x) = \frac{n!}{(k-1)!(n-k)!} (F(x))^{k-1} (1-F(x))^{n-k} f(x).$$

Gustina $(n+1)$ -ve statistike poretka uzorka (X_1, \dots, X_{2n+1}) obilježja $X : \mathcal{U}(0, 2\theta)$ je:

$$\begin{aligned} f_{Y_{n+1}}(x; \theta) &= \frac{(2n+1)!}{n!n!} (F(x; \theta))^n (1-F(x; \theta))^n f(x; \theta) \\ &= \begin{cases} \frac{(2n+1)!}{n!n!} \left(\frac{x}{2\theta}\right)^n \left(1 - \frac{x}{2\theta}\right)^n \frac{1}{2\theta}, & x \in [0, 2\theta], \\ 0, & \text{inače.} \end{cases} \end{aligned}$$

Podsjetnik iz Analize.

Beta funkcija $B(r, s)$, $r, s > 0$, definiše se kao

$$B(r, s) := \int_0^1 t^{r-1} (1-t)^{s-1} dt.$$

Pokazuje se da važi

$$B(r, s) = \frac{\Gamma(r)\Gamma(s)}{\Gamma(r+s)},$$

gdje je sa Γ označena gama funkcija $\Gamma(a) := \int_0^{+\infty} t^{a-1} e^{-t} dt$, $a > 0$.

Potražimo očekivanje i disperziju za Y_{n+1} :

$$\begin{aligned} \mathbb{E}Y_{n+1} &= \frac{(2n+1)!}{n!n!} \int_0^{2\theta} \left(\frac{x}{2\theta}\right)^{n+1} \left(1 - \frac{x}{2\theta}\right)^n dx \\ &= \frac{(2n+1)!}{n!n!} \cdot 2\theta \int_0^1 t^{n+1} (1-t)^n dt \\ &= \frac{(2n+1)!}{n!n!} \cdot 2\theta \cdot B(n+2, n+1) \\ &= \frac{(2n+1)!}{n!n!} \cdot 2\theta \cdot \frac{\Gamma(n+2)\Gamma(n+1)}{\Gamma(2n+3)} \\ &= \frac{(2n+1)!}{n!n!} \cdot 2\theta \cdot \frac{(n+1)!n!}{(2n+2)!} \\ &= \theta; \end{aligned}$$

$$\begin{aligned}
\mathbb{E}Y_{n+1}^2 &= \frac{(2n+1)!}{n!n!} \cdot 2\theta \int_0^{2\theta} \left(\frac{x}{2\theta}\right)^{n+2} \left(1 - \frac{x}{2\theta}\right)^n dx \\
&= \frac{(2n+1)!}{n!n!} \cdot 4\theta^2 \int_0^1 t^{n+2}(1-t)^n dt \\
&= \frac{(2n+1)!}{n!n!} \cdot 4\theta^2 \cdot B(n+3, n+1) \\
&= \frac{(2n+1)!}{n!n!} \cdot 4\theta^2 \cdot \frac{\Gamma(n+3)\Gamma(n+1)}{\Gamma(2n+4)} \\
&= \frac{(2n+1)!}{n!n!} \cdot 4\theta^2 \cdot \frac{(n+2)!n!}{(2n+3)!} \\
&= \frac{2n+4}{2n+3} \theta^2,
\end{aligned}$$

pa je

$$DY_{n+1} = \frac{2n+4}{2n+3} \theta^2 - \theta^2 = \frac{\theta^2}{2n+3}.$$

Neka je $\varepsilon > 0$ proizvoljan broj. Tada, koristeći Čebišovljevu nejednakost, dobijamo:

$$P\{|Y_{n+1} - \theta| > \varepsilon\} = P\{|Y_{n+1} - \mathbb{E}Y_{n+1}| > \varepsilon\} \leq \frac{DY_{n+1}}{\varepsilon^2} = \frac{\theta^2}{(2n+3)\varepsilon^2} \rightarrow 0, \text{ pri } n \rightarrow \infty,$$

pa važi $Y_{n+1} \xrightarrow{P} \theta$, pri $n \rightarrow \infty$, odnosno Y_{n+1} je postojana ocjena parametra θ .

►