

TAČNE I ASIMPTOTSKE RASPODJELE
NEKIH UZORAČKIH STATISTIKA

Aleksandra Vasilić

Prirodno-matematički fakultet
Banja Luka, Mladena Stojanovića br. 2
E-mail: avasilic@blic.net

Uvod

Predmet razmatranja u matematičkoj statistici je *populacija* ili generalni skup elemenata. Kvantitativna ili kvalitativna karakteristika elemenata populacije zove se *obilježje*. Pod statističkim eksperimentom se podrazumijeva registriranje vrijednosti obilježja X na nekom podskupu populacije, koji se naziva *uzorak*.

Bitno je da uzorak bude reprezentativan tj. elemente uzorka treba birati na slučajan način, tako da se neutrališe svaka moguća zavisnost između posmatranog obilježja i uzorka.

Osnovni cilj matematičke statistike je da se na osnovu statističkog eksperimenta dođe do zaključaka o nepoznatoj raspodjeli $F(x)$ obilježja X , radi prognoziranja budućih rezultata i eventualnog preduzimanja mjera da ti rezultati budu što povoljniji.

Neka se na populaciji statističkim eksperimentom bira element i registruje vrijednost obilježja. Rezultat eksperimenta je slučajna promjenljiva X . Ponašajući eksperiment n puta složeni eksperiment se opisuje n - dimenzionalnom slučajnom promjenljivom (X_1, X_2, \dots, X_n) koja predstavlja slučajni uzorak. U daljem ćemo posmatrati takozvane *proste slučajne uzorke*.

Definicija 1 *Prost slučajan uzorak obima n , iz populacije na kojoj obilježje X ima funkciju raspodjele $F(x)$, je slučajni vektor (X_1, X_2, \dots, X_n) , pri čemu su X_1, X_2, \dots, X_n nezavisne slučajne veličine sa istom funkcijom raspodjele $F(x)$ kao i obilježje X . Funkcija raspodjele slučajnog vektora (X_1, X_2, \dots, X_n) je:*

$$\begin{aligned} F(x_1, x_2, \dots, x_n) &= P\{X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n\} \\ &= P\{X_1 \leq x_1\}P\{X_2 \leq x_2\} \dots P\{X_n \leq x_n\} \\ &= \prod_{k=1}^n F(x_k) \end{aligned}$$

U realizovanom statističkom eksperimentu slučajni vektor (X_1, X_2, \dots, X_n) predstavlja n -torku brojeva (x_1, x_2, \dots, x_n) i zove se *realizacija uzorka*.

Definicija 2 Neka je $f : \mathbb{R}^n \rightarrow \mathbb{R}$ Borelova funkcija i (X_1, X_2, \dots, X_n) uzorak uzet iz raspodjele F . Tad se slučajna veličina $f(X_1, X_2, \dots, X_n)$ zove statistika.

Ovim radom opisane su tačne i asimptotske raspodjele sledećih statistika:

1. Empirijska funkcija raspodjele;
2. Uzorački momenti (specijalno: uzoračka sredina i uzoračka disperzija);
3. Statistike poretka (minimalna, maksimalna ili proizvoljnog reda);
4. Uzoračka medijana i kvantili;

1 Empirijska funkcija raspodjele

Empirijska funkcija raspodjele $F_n(x)$ predstavlja uzorački ekvivalent teorijskoj funkciji raspodjele $F(x) = P\{X \leq x\}$. Prije definisanja empirijske funkcije raspodjele potrebno je podsjetiti se na slučajnu veličinu *indikatora događaja*:

$$I(X \leq x) = \begin{cases} 1, & \text{za } X \leq x \\ 0, & \text{za } X > x \end{cases} \quad (1.1)$$

sa dvotačkastom raspodjelom *nula-jedan*:

$$I : \begin{pmatrix} 1 & 0 \\ F(x) & 1 - F(x) \end{pmatrix} \quad (1.2)$$

Definicija 3 Neka je (X_1, X_2, \dots, X_n) prost slučajni uzorak iz raspodjele F . Slučajna veličina $F_n : \mathbb{R} \rightarrow \mathbb{R}$ data sa

$$F_n(x) = \frac{1}{n} \sum_{k=1}^n I(X_k \leq x), \quad -\infty < x < \infty \quad (1.3)$$

zove se *empirijska funkcija raspodjele*.

Kako su matematičko očekivanje i disperzija indikatora događaja dati sa:

$$EI(X_k \leq x) = F(x)$$

i

$$DI(X_k \leq x) = F(x)(1 - F(x)), \quad k = 0, 1, \dots, n$$

i kako slučajna veličina

$$nF_n(x) = \sum_{k=1}^n I(X_k \leq x) \quad (1.4)$$

predstavlja sumu od n nezavisnih jednako raspodijeljenih slučajnih veličina sa dvotačkastom nula-jedan raspodjelom, to slučajna veličina (1.4) ima binomnu $\mathcal{B}(n, F(x))$ raspodjelu.

Odatle slijedi da je za $k = 0, 1, \dots, n$:

$$\begin{aligned} P\{nF_n(x) = k\} &= P\{F_n(x) = \frac{k}{n}\} \\ &= \binom{n}{k} (F(x))^k (1 - F(x))^{n-k} \end{aligned} \quad (1.5)$$

sa matematičkim očekivanjem:

$$E(F_n(x)) = F(x) \quad (1.6)$$

i disperzijom:

$$D(F_n(x)) = \frac{1}{n} F(x)(1 - F(x)) \quad (1.7)$$

Ako uzoračke vrijednosti X_1, X_2, \dots, X_n poredamo u neopadajući poredak

$$X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$$

tada se niz $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ zove *varijacioni niz*.

Realizaciju $x_{(1)}, x_{(2)}, \dots, x_{(n)}$ varijacionog niza posmatramo na realizovanom uzorku, te za nju analogno vrijedi

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}.$$

Empirijska funkcija raspodjele može se odrediti na sledeći način:

$$F_n(x) = \begin{cases} 0, & \text{ako je } x < x_{(1)} \\ \frac{k}{n}, & \text{ako je } x_{(k)} \leq x < x_{(k+1)}, \quad 1 \leq k \leq n-1 \\ 1, & \text{ako je } x \geq x_{(n)}. \end{cases} \quad (1.8)$$

Fundamentalna značaj empirijske funkcije raspodjele $F_n(x)$ je u tome što ona, u svakoj fiksiranoj tački x , dobro aproksimira nepoznatu teorijsku funkciju raspodjele $F(x)$ obilježja X , kad obim uzorka neograničeno raste.

Naime, na osnovu jakog Borelovog zakona velikih brojeva za svaku fiksiranu tačku x vrijedi skoro sigurna konvergencija

$$F_n(x) \xrightarrow{s.s.} F(x), \quad n \rightarrow \infty \quad (1.9)$$

Sledeća teorema, nazvana *centralnom teoremom matematičke statistike*, tvrdi da je gore navedena skoro sigurna konvergencija uniformna po x (vidi [6]).

Teorema 1.1 (Glivenko-Kanteli) *Neka je $\{F_n\}_{n \in \mathbb{N}}$ niz empirijskih funkcija raspodjele dobijenih na uzorku obima n , uzetog iz raspodjele F . Vrijedi jednakost:*

$$P\left\{\lim_{n \rightarrow \infty} \sup_{x \in \mathbb{R}} |F_n(x) - F(x)| = 0\right\} = 1 \quad (1.10)$$

Graničnu raspodjelu statistike maksimalnog odstupanja empirijske od teorijske funkcije raspodjele:

$$D_n \equiv D_n(X_1, X_2, \dots, X_n) = \sup_{x \in \mathbb{R}} |F_n(x) - F(x)|, \quad x \in \mathbb{R} \quad (1.11)$$

uz pretpostavku da je F neprekidna funkcija, odredio je A.N. Kolmogorov 1933. godine. Sledećom teoremom je pokazano da granična raspodjela statistike D_n ne zavisi od funkcije F .

Teorema 1.2 *Ako je F neprekidna funkcija, tada je*

$$\begin{aligned} \lim_{n \rightarrow \infty} P\{\sqrt{n}D_n \leq t\} &= \sum_{k=-\infty}^{\infty} (-1)^k e^{-2k^2 t^2} \\ &= 1 + 2 \sum_{k=1}^{\infty} (-1)^k e^{-2k^2 t^2}, \quad t > 0 \end{aligned} \quad (1.12)$$

Teorema 1.2 koristi se za provjeravanje statističke hipoteze da obilježje X ima pretpostavljenu funkciju raspodjele.

Još jedna interesantna teorema govori o osobinama empirijskih funkcija raspodjela. To je teorema Smirnova iz 1944.godine, a koristi se za testiranje statističke hipoteze da su dva uzorka uzeta iz iste raspodjele.

Teorema 1.3 (Smirnov) *Neka su $F_{1n_1}(x)$ i $F_{2n_2}(x)$ empirijske funkcije raspodjela definisane na nezavisnim uzorcima $(X_{11}, X_{12}, \dots, X_{1n_1})$ i $(X_{21}, X_{22}, \dots, X_{2n_2})$, uzetih iz iste populacije na kojoj obilježje X ima raspodjelu F , i neka je statistika njihovih maksimalnih odstupanja*

$$D_{n_1 n_2} = \sup_{x \in \mathbb{R}} |F_{1n_1}(x) - F_{2n_2}(x)|.$$

Ako je funkcija raspodjele F neprekidna, onda za svaki pozitivan broj t vrijedi:

$$\lim_{n_1, n_2 \rightarrow \infty} P\left\{\sqrt{\frac{n_1 n_2}{n_1 + n_2}} D_{n_1 n_2} \leq t\right\} = K(t) = 1 + 2 \sum_{k=1}^{\infty} (-1)^k e^{-2k^2 t^2}. \quad (1.13)$$

2 Uzorački momenti

Posmatrajmo uzorak (X_1, X_2, \dots, X_n) uzet iz raspodjele F .

Definicija 4 *Uzoračka sredina je statistika koja predstavlja aritmetičku sredinu komponenti uzorka:*

$$\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k \quad (2.14)$$

Statistika \bar{X}_n predstavlja uzorački ekvivalent matematičkom očekivanju $E(X)$ kod teorijske raspodjele obilježja X .

Definicija 5 *Uzoračka disperzija je statistika*

$$\bar{S}_n^2 = \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X}_n)^2 \quad (2.15)$$

gdje je sa \bar{X}_n označena uzoračka sredina.

Statistika \bar{S}_n^2 predstavlja uzorački ekvivalent disperziji $D(X) = E(X - EX)^2$ kod teorijske raspodjele obilježja X .

Statistike \bar{X}_n i \bar{S}_n^2 su specijalni slučajevi sledećih uzoračkih momenata.

Definicija 6 *Obični uzorački moment reda k je statistika*

$$A_{nk} = \frac{1}{n} \sum_{i=1}^n X_i^k \quad (2.16)$$

Statistika A_{nk} predstavlja uzorački ekvivalent teorijskom običnom momentu reda k definisanom sa $m_k = E(X^k)$.

Definicija 7 *Centralni uzorački moment reda k je statistika*

$$B_{nk} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^k \quad (2.17)$$

Statistika B_{nk} predstavlja uzorački ekvivalent teorijskom centralnom momentu reda k definisanom sa $\mu_k = E(X - EX)^k$.

Na osnovu gornjih definicija je očigledno $A_{n1} = \bar{X}_n$ i $B_{n2} = \bar{S}_n^2$.

U vezi sa uzoračkim momentima razmotrićemo nekoliko pitanja:

1. Numeričke karakteristike uzoračkih momenata;
2. Tačna zajednička raspodjela statistika \bar{X}_n i \bar{S}_n^2 kod uzorka iz normalne raspodjele
3. Granične raspodjele uzoračkih momenata, pri $n \rightarrow \infty$.

2.1 Numeričke karakteristike uzoračkih momenata

Neka je X obilježje sa funkcijom raspodjele F , za koje vrijedi

$$E(X) = m, \quad D(X) = \sigma^2, \quad E(X^k) = m_k, \quad E(X - m)^k = \mu_k$$

(vidi se da je $m_1 = m$ i $\mu_2 = \sigma^2$) i neka je (X_1, X_2, \dots, X_n) uzorak uzet iz raspodjele F .

Primjer 2.1 Odrediti $E(\bar{X}_n)$ i $D(\bar{X}_n)$.

Rješenje:

$$\begin{aligned} E(\bar{X}_n) &= E\left(\frac{1}{n} \sum_{k=1}^n X_k\right) \\ &= \frac{1}{n} \sum_{k=1}^n E(X_k) \\ &= \frac{1}{n} nm \\ &= m. \end{aligned} \tag{2.18}$$

$$\begin{aligned} D(\bar{X}_n) &= D\left(\frac{1}{n} \sum_{k=1}^n X_k\right) \\ &= \frac{1}{n^2} \sum_{k=1}^n D(X_k) \\ &= \frac{1}{n^2} n\sigma^2 \\ &= \frac{\sigma^2}{n} \blacklozenge \end{aligned} \tag{2.19}$$

Primjer 2.2 Odrediti $E(\bar{S}_n^2)$ i $D(\bar{S}_n^2)$.

Rješenje:

$$\begin{aligned} E(\bar{S}_n^2) &= E\left(\frac{1}{n} \sum_{k=1}^n (X_k - \bar{X}_n)^2\right) \\ &= \frac{1}{n} \sum_{k=1}^n E(X_k - \bar{X}_n)^2 \\ &= \frac{1}{n} \sum_{k=1}^n E(X_k)^2 - E(\bar{X}_n^2) \\ &= \frac{1}{n} n(\sigma^2 + m^2) - \left(\frac{\sigma^2}{n} + m^2\right) \\ &= \sigma^2 - \frac{\sigma^2}{n} \\ &= \frac{n-1}{n} \sigma^2 \end{aligned} \tag{2.20}$$

Da bismo odredili $D(\bar{S}_n^2)$ prvo nađimo $E(\bar{S}_n^2)^2$.

$$E(\bar{S}_n^2)^2 = E\left(\frac{1}{n} \sum_{k=1}^n (X_k - \bar{X}_n)^2\right)^2$$

$$\begin{aligned}
&= E\left(\frac{1}{n} \sum_{k=1}^n X_k^2 - \bar{X}_n^2\right)^2 \\
&= E\left(\frac{1}{n} \sum_{k=1}^n X_k^2 - \frac{1}{n^2} \left(\sum_{k=1}^n X_k\right)^2\right)^2 \\
&= E\left(\frac{n-1}{n^2} \sum_{k=1}^n X_k^2 - \frac{2}{n^2} \sum_{k<j} X_k X_j\right)^2 \\
&= E\left(\frac{(n-1)^2}{n^4} \sum_{k=1}^n X_k^4 + \frac{2(n-1)^2 + 4}{n^4} \sum_{k<j} X_k^2 X_j^2\right) \\
&= \frac{(n-1)^2}{n^3} \mu_4 + \frac{2(n-1)^2 + 4}{n^3} (n-1) \mu_2 \tag{2.21}
\end{aligned}$$

Sada je

$$\begin{aligned}
D(\bar{S}_n^2) &= E(\bar{S}_n^2)^2 - (E(\bar{S}_n^2))^2 \\
&= \frac{(n-1)^2}{n^3} \left(\mu_4 - \frac{n-3}{n-1} \mu_2^2\right) \blacklozenge \tag{2.22}
\end{aligned}$$

Primjer 2.3 Odrediti $E(A_{nk})$ i $D(A_{nk})$.

Rješenje:

$$\begin{aligned}
E(A_{nk}) &= E\left(\frac{1}{n} \sum_{i=1}^n X_i^k\right) \\
&= \frac{1}{n} \sum_{i=1}^n E(X_i^k) \\
&= \frac{1}{n} n m_k \\
&= m_k. \tag{2.23}
\end{aligned}$$

$$\begin{aligned}
D(A_{nk}) &= D\left(\frac{1}{n} \sum_{i=1}^n X_i^k\right) \\
&= \frac{1}{n^2} \sum_{i=1}^n D(X_i^k) \\
&= \frac{1}{n^2} \sum_{i=1}^n E(X_i^k - m_k)^2 \\
&= \frac{1}{n^2} \sum_{i=1}^n (E(X_i^k)^2 - 2E(X_i^k)m_k + m_k^2) \\
&= \frac{1}{n^2} n(m_{2k} - m_k^2) \\
&= \frac{m_{2k} - m_k^2}{n} \blacklozenge \tag{2.24}
\end{aligned}$$

Zadatak 2.1 Pokazati da je

$$E(B_{nk}) = \mu_k$$

i

$$D(B_{nk}) = \frac{1}{n}(\mu_{2k} - 2k\mu_{k-1}\mu_{k+1} - \mu_k^2 + k^2\mu_2\mu_{k-1}^2)$$

2.2 Zajednička raspodjela statistika \bar{X}_n i \bar{S}_n^2 kod uzorka iz normalne raspodjele

Za početak navedimo samo definicije dva tipa raspodjela bitnih za razumijevanje pomenute zajedničke raspodjele iz naslova.

Definicija 8 (χ^2 - raspodjela) Raspodjela $\Gamma(\frac{1}{2}, \frac{n}{2})$ određena gustinom

$$f_n(x) = \begin{cases} \frac{1}{2^{n/2}\Gamma(n/2)}x^{n/2-1}e^{-x/2}, & \text{ako je } x > 0 \\ 0, & \text{ako je } x \leq 0 \end{cases} \quad (2.25)$$

zove se χ^2 - raspodjela sa n stepeni slobode i označava sa χ_n^2 .

Metodom karakterističnih funkcija lako se dokazuje da ako su X_1, X_2, \dots, X_n nezavisne slučajne veličine iz $\mathcal{N}(0, 1)$ raspodjele, onda zbir njihovih kvadrata ima χ_n^2 -raspodjelu, tj. važi jednakost:

$$\chi_n^2 = X_1^2 + X_2^2 + \dots + X_n^2.$$

Definicija 9 (Studentova t raspodjela) Neka su $X_0, X_1, X_2, \dots, X_n$ nezavisne slučajne veličine sa $\mathcal{N}(0, 1)$ raspodjelom. Raspodjela slučajne veličine

$$t_n = \frac{X_0}{\sqrt{\frac{1}{n}(X_1^2 + X_2^2 + \dots + X_n^2)}} = \frac{X_0}{\sqrt{\frac{1}{n}\chi_n^2}}$$

zove se Studentova t raspodjela sa n stepeni slobode, i označava sa t_n .

Gustina t_n raspodjele je određena formulom

$$f_n(x) = \frac{\Gamma(\frac{n+1}{2})}{\sqrt{n\pi}\Gamma(\frac{n}{2})}\left(1 + \frac{x^2}{n}\right)^{-(n+1)/2}, \quad x \in \mathbb{R} \quad (2.26)$$

Poznavanje zajedničke raspodjele statistika \bar{X}_n i \bar{S}_n^2 , u slučaju kada obilježje X ima normalnu raspodjelu, ima veliku primjenu u matematičkoj statistici na primjer prilikom ocjenjivanja ili testiranja hipoteza o parametrima normalne raspodjele. Teoremu koja slijedi dokazao je Fišer još 1925. godine, a njen dokaz se može pronaći u većini udžbenika statistike (vidi npr.[9]).

Teorema 2.1 (Fišer) Neka je uzorak (X_1, X_2, \dots, X_n) uzet iz normalne raspodjele $\mathcal{N}(m, \sigma^2)$. Tada vrijede tvrdnje:

1. Slučajne veličine \bar{X}_n i \bar{S}_n^2 su nezavisne.
2. Slučajna veličina $\frac{\bar{X}_n - m}{\sigma} \sqrt{n}$ ima $\mathcal{N}(0, 1)$ raspodjelu.
3. Slučajna veličina $\frac{n\bar{S}_n^2}{\sigma^2}$ ima χ_{n-1}^2 raspodjelu.

Koristeći prethodnu Teoremu 2.1 i Definiciju 9 dokazuje se još jedna vrlo važna i često korištena zajednička raspodjela statistika \bar{X}_n i \bar{S}_n^2 . Opisana je sledećim primjerom.

Primjer 2.4 Neka je uzorak (X_1, X_2, \dots, X_n) uzet iz normalne raspodjele $\mathcal{N}(m, \sigma^2)$. Odrediti raspodjelu slučajne veličine $\frac{\bar{X}_n - m}{\bar{S}_n} \sqrt{n-1}$.

Rješenje:

Ako je uzorak (X_1, X_2, \dots, X_n) uzet iz normalne raspodjele $\mathcal{N}(m, \sigma^2)$, tada slučajna veličina \bar{X}_n ima $\mathcal{N}(m, \frac{\sigma^2}{n})$ raspodjelu, odnosno kao što tvrdi prethodna teorema, slučajna veličina $\frac{\bar{X}_n - m}{\sigma} \sqrt{n}$ ima $\mathcal{N}(0, 1)$ raspodjelu. Sem toga, prema tvrdnji prethodne teoreme, slučajna veličina $\frac{n\bar{S}_n^2}{\sigma^2}$ ima χ_{n-1}^2 raspodjelu. Posmatrajmo količnik:

$$t = \frac{\frac{\bar{X}_n - m}{\sigma} \sqrt{n}}{\sqrt{\frac{1}{n-1} \frac{n\bar{S}_n^2}{\sigma^2}}} = \frac{\bar{X}_n - m}{\bar{S}_n} \sqrt{n-1} \quad (2.27)$$

Iz Definicije 9 slijedi zaključak da slučajna veličina

$$t = \frac{\bar{X}_n - m}{\bar{S}_n} \sqrt{n-1} \quad (2.28)$$

ima t_{n-1} raspodjelu.

2.3 Granične raspodjele uzoračkih momenata

Za određivanje graničnih raspodjela gornjih statistika koristimo granične teoreme teorije vjerovatnoće. Za formulisanje ovih teorema potrebno je definisati konvergencije nizova slučajnih veličina.

2.3.1 Konvergencije nizova slučajnih vličina

Razlikujemo 4 osnovna tipa konvergencija (vidi [5]):

- konvergencija skoro sigurno
- konvergencija u srednjem reda p ($0 < p < \infty$)
- konvergencija u vjerovatnoći
- konvergencija u raspodjeli

Neka je X_1, X_2, \dots niz slučajnih veličina definisanih na istom prostoru vjerovatnoća, sa istom funkcijom raspodjele $F(x)$.

Definicija 10 Niz slučajnih veličina (X_n) **konvergira skoro sigurno** ka slučajnoj veličini X , ako važi:

$$P\{\omega : \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)\} = 1 \quad (2.29)$$

Ova konvergencija se označava sa $X_n \xrightarrow{s.s.} X, n \rightarrow \infty$.

Definicija 11 Niz slučajnih veličina (X_n) **konvergira u srednjem reda p** (za $0 < p < \infty$) ka slučajnoj veličini X , ako je $E|X|^p < \infty$ i vrijedi:

$$\lim_{n \rightarrow \infty} E(|X_n - X|)^p = 0 \quad (2.30)$$

Ova konvergencija se označava sa $X_n \xrightarrow{L^p} X, n \rightarrow \infty$.

Specijalno, konvergencija u srednjem reda $p = 2$ zove se **konvergencija u srednje-kvadratnom**, i označava sa $X_n \xrightarrow{s.k.} X, n \rightarrow \infty$.

Definicija 12 Niz slučajnih veličina (X_n) **konvergira u vjerovatnoći** ka slučajnoj veličini X , ako važi:

$$(\forall \varepsilon > 0) \lim_{n \rightarrow \infty} P\{\omega : |X_n(\omega) - X(\omega)| \geq \varepsilon\} = 0 \quad (2.31)$$

Ova konvergencija se označava sa $X_n \xrightarrow{P} X, n \rightarrow \infty$.

Definicija 13 Niz funkcija raspodjele (F_n) slabo konvergira ka funkciji raspodjele F , ako u svakoj tački neprekidnosti funkcije F vrijedi:

$$\lim_{n \rightarrow \infty} F_n(x) = F(x) \quad (2.32)$$

U tom slučaju se kaže da niz slučajnih veličina (X_n) , sa odgovarajućim funkcijama raspodjele $F_n(x) = P\{X_n \leq x\}$, **konvergira u raspodjeli** ka slučajnoj veličini X , kojoj odgovara funkcija raspodjele $F(x) = P\{X \leq x\}$.

Ova konvergencija se označava sa $X_n \xrightarrow{D} X, n \rightarrow \infty$.

2.3.2 Kratak pregled graničnih teorema

Kaže se da za niz (X_n) slučajnih veličina važi **slabi zakon velikih brojeva** ako vrijedi:

$$\frac{1}{n} \sum_{k=1}^n X_k - \frac{1}{n} \sum_{k=1}^n E(X_k) \xrightarrow{P} 0, n \rightarrow \infty, \quad (2.33)$$

a za niz (X_n) vrijedi **jaki zakon velikih brojeva** ako je:

$$\frac{1}{n} \sum_{k=1}^n X_k - \frac{1}{n} \sum_{k=1}^n E(X_k) \xrightarrow{s.s.} 0, n \rightarrow \infty, \quad (2.34)$$

Sledeće teoreme daju potrebne, a neke i dovoljne uslove da za posmatrani niz slučajnih veličina (X_n) važi neki zakon velikih brojeva.

Teorema 2.2 (Čebišov) Ako niz nezavisnih slučajnih veličina (X_n) ima konačne disperzije, ograničene istom konstantom, tj.

$$(\exists C > 0)(\forall n \in \mathbb{N})DX_n \leq C \quad (2.35)$$

tad za njega važi slabi zakon velikih brojeva (2.33).

Teorema 2.3 (Hinčin) Ako je (X_n) niz nezavisnih i jednako raspodijeljenih slučajnih veličina sa konačnim matematičkim očekivanjem $EX_n = m$ tad za niz vrijedi slabi zakon velikih brojeva :

$$\frac{1}{n} \sum_{k=1}^n X_k \xrightarrow{P} m, \quad n \rightarrow \infty \quad (2.36)$$

Teorema 2.4 (Borel) Neka je S_n broj uspjeha posmatranog događaja u n nezavisnih eksperimenata, pri čemu je vjerovatnoća uspjeha u svakom od eksperimenata jednaka p . Tada vrijedi:

$$P\left\{\lim_{n \rightarrow \infty} \frac{S_n}{n} = p\right\} = 1. \quad (2.37)$$

Teorema 2.5 (1. teorema Kolmogorova)

Ako je (X_n) niz nezavisnih slučajnih veličina, koje imaju konačne disperzije, i koji zadovoljava uslov:

$$\sum_{k=1}^n \frac{DX_k}{n^2} < \infty \quad (2.38)$$

tad za njega vrijedi jaki zakon velikih brojeva (2.34).

Teorema 2.6 (2. teorema Kolmogorova)

Ako je (X_n) niz nezavisnih slučajnih veličina sa istom raspodjelom i konačnim matematičkim očekivanjem $E(X_n) = m$, tad za njega vrijedi jaki zakon velikih brojeva (2.34):

$$\frac{1}{n} \sum_{k=1}^n X_k \xrightarrow{s.s.} m, \quad n \rightarrow \infty \quad (2.39)$$

Teorema 2.7 (Centralna granična teorema Lindeberg-Levija) Neka je (X_n) niz nezavisnih slučajnih veličina sa istom raspodjelom, matematičkim očekivanjem $E(X_n) = m$ i konačnom disperzijom $D(X_n) = \sigma^2 > 0$. Ako je $S_n = \sum_{k=1}^n X_k$ onda za svako $x \in \mathbb{R}$, pri $n \rightarrow \infty$ vrijedi:

$$P\left\{\frac{S_n - nm}{\sigma\sqrt{n}} \leq x\right\} \rightarrow \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-t^2/2} dt \quad (2.40)$$

Gornja teorema se može formulirati i ovako:

$$\frac{S_n - E(S_n)}{\sqrt{D(S_n)}} \xrightarrow{D} \mathcal{N}(0,1), \quad n \rightarrow \infty \quad (2.41)$$

odnosno niz funkcija raspodjela rastućeg niza standardizovanih suma (S_n) nezavisnih slučajnih veličina konvergira ka normalnoj Gausovoj funkciji raspodjele. Više o graničnim teoremama može da se vidi u [5].

Primjenom gore navedenih slabih i jakih zakona velikih brojeva mogu se dokazati sledeće konvergencije statistika koje smo razmatrali na početku rada.

Primjer 2.5 Dokazati da vrijedi: $A_{nk} \xrightarrow{s.s.} m_k, \quad n \rightarrow \infty$

Rješenje:

Ako je (X_1, X_2, \dots, X_n) uzorak uzet iz raspodjele F , tada su sve X_i jednako raspodijeljene, nezavisne i sa istim matematičkim očekivanjem $E(X_i) = m, \quad i = 1, \dots, n$. Prema teoremi Hinčina (2.36) za niz (X_n) vrijedi slabi zakon velikih brojeva:

$$A_{nk} = \frac{1}{n} \sum_{i=1}^n X_i^k \xrightarrow{P} m_k, \quad n \rightarrow \infty \quad (2.42)$$

Čak štaviše, prema drugoj teoremi Kolmogorova (2.39) za niz (X_n) vrijedi i jaki zakon velikih brojeva:

$$A_{nk} = \frac{1}{n} \sum_{i=1}^n X_i^k \xrightarrow{s.s.} m_k, \quad n \rightarrow \infty \quad \blacklozenge \quad (2.43)$$

Napomena 1 Specijalan slučaj iz prethodnog primjera za $k = 1$ daje rezultat:

$$A_{n1} = \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{s.s.} m, \quad n \rightarrow \infty$$

odnosno uzoračka sredina skoro sigurno konvergira ka matematičkom očekivanju obilježja X , kad obim uzorka neograničeno raste. \blacklozenge

Zadatak 2.2 Dokazati da vrijedi: $B_{nk} \xrightarrow{s.s.} \mu_k, \quad n \rightarrow \infty$

Napomena 2 Specijalan slučaj iz prethodnog zadatka za $k = 2$ daje rezultat:

$$B_{n2} = \bar{S}_n^2 = \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X}_n)^2 \xrightarrow{s.s.} \sigma^2, \quad n \rightarrow \infty \quad \blacklozenge$$

odnosno uzoračka disperzija skoro sigurno konvergira ka disperziji obilježja X , kad obim uzorka neograničeno raste. \blacklozenge

Primjenom centralne granične i ostalih graničnih teorema, u nekoliko sledećih primjera se dokazuju asimptotske raspodjele statistika A_{nk} i B_{nk} .

Primjer 2.6 Dokazati da vrijedi: $A_{nk} \sim \mathcal{N}(m_k, (m_{2k} - m_k^2)/n)$, pri $n \rightarrow \infty$

Rješenje:

Statistika $n \cdot A_{nk} = \sum_{i=1}^n X_i^k$ predstavlja sumu n nezavisnih i jednako raspodijeljenih slučajnih veličina X_i^k , sa matematičkim očekivanjem $E(X_i^k) = m_k$ i disperzijom $D(X_i^k) = m_{2k} - m_k^2$ (vidi Primjer 2.3).

Prema tome, normirana suma

$$\begin{aligned} \frac{n \cdot A_{nk} - E(n \cdot A_{nk})}{\sqrt{D(n \cdot A_{nk})}} &= \frac{\sum_{i=1}^n X_i^k - E(\sum_{i=1}^n X_i^k)}{\sqrt{D(\sum_{i=1}^n X_i^k)}} \\ &= \frac{n \cdot A_{nk} - n \cdot m_k}{\sqrt{n(m_{2k} - m_k^2)}} \end{aligned}$$

ima pri $n \rightarrow \infty$ graničnu normalnu raspodjelu $\mathcal{N}(0, 1)$, na osnovu centralne granične teoreme (Teorema 2.7).

Odatle slijedi da statistika A_{nk} ima asimptotski normalnu raspodjelu $\mathcal{N}(m_k, (m_{2k} - m_k^2)/n)$ pri $n \rightarrow \infty$, čime je tvrdnja dokazana \blacklozen

Napomena 3 Specijalan slučaj u prethodnom primjeru za $k = 1$ dovodi do niza jednakosti:

$$\begin{aligned} \frac{n \cdot \bar{X}_n - E(n \cdot \bar{X}_n)}{\sqrt{D(n \cdot \bar{X}_n)}} &= \frac{n \cdot A_{n1} - E(n \cdot A_{n1})}{\sqrt{D(n \cdot A_{n1})}} \\ &= \frac{\sum_{i=1}^n X_i - E(\sum_{i=1}^n X_i)}{\sqrt{D(\sum_{i=1}^n X_i)}} \\ &= \frac{n \cdot \bar{X}_n - n \cdot m}{\sqrt{n\sigma^2}} \end{aligned}$$

odnosno

$$\bar{X}_n \sim \mathcal{N}(m, \sigma^2/n), \quad n \rightarrow \infty$$

kao i

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

To znači da uzoračka sredina ima asimptotski normalnu raspodjelu $\mathcal{N}(m, \sigma^2/n)$ pri $n \rightarrow \infty$, a asimptotska raspodjela normalizovane vrijednosti uzoračke sredine je normalna $\mathcal{N}(0, 1)$ raspodjela \blacklozen

Primjer 2.7 Dokazati da vrijedi:

$$B_{nk} \sim \mathcal{N}(\mu_k, (\mu_{2k} - 2k\mu_{k-1}\mu_{k+1} - \mu_k^2 + k^2\mu_2\mu_{k-1}^2)/n), \quad n \rightarrow \infty \quad (2.44)$$

Rješenje:

Polazi se od razlaganja

$$\begin{aligned}
B_{nk} &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^k \\
&= \frac{1}{n} \sum_{i=1}^n \left[\binom{k}{0} X_i^k - \binom{k}{1} X_i^{k-1} \bar{X}_n + \binom{k}{2} X_i^{k-2} \bar{X}_n^2 - \binom{k}{3} X_i^{k-3} \bar{X}_n^3 + \dots + (-1)^k \bar{X}_n^k \right] \\
&= A_{nk} - \binom{k}{1} A_{n(k-1)} \bar{X}_n + \binom{k}{2} A_{n(k-2)} \bar{X}_n^2 - \binom{k}{3} A_{n(k-3)} \bar{X}_n^3 + \dots + (-1)^k \bar{X}_n^k
\end{aligned} \tag{2.45}$$

Uvedimo normirane promjenljive C_k na sledeći način :

$$C_k = \frac{A_{nk} - m_k}{\sigma_k} \sqrt{n} \tag{2.46}$$

gdje je

$$m_k = EX^k$$

i

$$\begin{aligned}
\sigma_k^2 &= DX^k = E(X^k - m_k)^2 \\
&= E(X^{2k} - 2X^k m_k + m_k^2) \\
&= m_{2k} - 2m_k^2 + m_k^2 \\
&= m_{2k} - m_k^2
\end{aligned}$$

odnosno

$$\sigma_k^2 = E(n(A_{nk} - m_k)^2) = m_{2k} - m_k^2$$

Tada je $E(C_k) = 0$ i

$$D(C_k) = E\left(\frac{A_{nk} - m_k}{\sigma_k} \sqrt{n}\right)^2 = \frac{1}{\sigma_k^2} E(n(A_{nk} - m_k)^2) = \frac{\sigma_k^2}{\sigma_k^2} = 1$$

a mješoviti momenti su

$$\begin{aligned}
E(C_k C_j) &= E\left(\frac{A_{nk} - m_k}{\sigma_k} \sqrt{n} \cdot \frac{A_{nj} - m_j}{\sigma_j} \sqrt{n}\right) \\
&= \frac{n}{\sigma_k \sigma_j} E[(A_{nk} - m_k)(A_{nj} - m_j)] \\
&= \frac{1}{\sigma_k \sigma_j} E[n(A_{nk} - m_k)(A_{nj} - m_j)] \\
&= \frac{\sigma_{kj}}{\sigma_k \sigma_j}
\end{aligned}$$

gdje su

$$\sigma_{kj} = E[n(A_{nk} - m_k)(A_{nj} - m_j)] = m_{k+j} - m_k \cdot m_j, \quad k \neq j$$

mješoviti momenti drugog reda.

Iz prethodnih rezultata slijedi da

$$C_k = \frac{A_{nk} - m_k}{\sigma_k} \sqrt{n} \sim \mathcal{N}(0, 1), \quad n \rightarrow \infty$$

Dalje se vrštavanjem izraza za momente B_{nk} (iz 2.45) i $\mu_k = E(X - m)^k$ nakon obimnih transformacija dobija sledeća jednakost:

$$\sqrt{n}(B_{nk} - \mu_k) = \sigma_k C_k - k\sigma_1 \mu_{k-1} C_1 + \frac{L}{\sqrt{n}} \quad (2.47)$$

pri čemu za veličinu L dobijenu u gornjim transformacijama, kao ostatak od izdvojene linearne kombinacije veličina C_k i C_1 , vrijedi konvergencija $\frac{L}{\sqrt{n}} \xrightarrow{P} 0$, $n \rightarrow \infty$. Kako C_1 i C_k imaju zajedničku asimptotski normalnu raspodjelu, a linearna kombinacija normalno raspodijeljenih slučajnih veličina takođe ima normalnu raspodjelu, to iz (2.47) slijedi dokaz tražene asimptotske normalne raspodjele za statistiku B_{nk} iz (2.44) ♦

Napomena 4 Specijalan slučaj u prethodnom primjeru za $k = 2$ dovodi do rezultata:

$$B_{n2} \sim \mathcal{N}(\mu_2, (\mu_4 - 4\mu_1\mu_3 - \mu_2^2 + 4\mu_2\mu_1^2)/n)$$

tj.

$$\overline{S}_n^2 \sim \mathcal{N}(\sigma^2, (\mu_4 - \sigma^2)/n), \quad n \rightarrow \infty$$

To znači da statistika \overline{S}_n^2 ima asimptotski normalnu raspodjelu $\mathcal{N}(\sigma^2, (\mu_4 - \sigma^2)/n)$, pri $n \rightarrow \infty$ ♦

Primjer 2.8 Dokazati da zajednička raspodjela ma kog skupa promjenljivih $\sqrt{n}(A_{nk} - m_k)$ teži normalnoj raspodjeli sa nultim matematičkim očekivanjem i drugim momentima:

$$\sigma_{kk} = \sigma_k^2 = E[n(A_{nk} - m_k)^2] = m_{2k} - m_k^2 \quad (2.48)$$

$$\sigma_{kj} = E[n(A_{nk} - m_k)(A_{nj} - m_j)] = m_{k+j} - m_k \cdot m_j \quad (2.49)$$

Rješenje:

Primjenom CGT za dvodimenzionalne raspodjele (vidjeti [4]) na par statistika $nA_{nk} = \sum_{i=1}^n X_i^k$ i $nA_{nj} = \sum_{i=1}^n X_i^j$ pokazuje se da zajednička raspodjela slučajnih veličina $\sqrt{n}(A_{nk} - m_k)$ i $\sqrt{n}(A_{nj} - m_j)$ konvergira nekoj dvodimenzionalnoj normalnoj raspodjeli, pri $n \rightarrow \infty$.

Primjenjujući centralnu graničnu teoremu za višedimenzionalne raspodjele (vidi npr. [10]) pokazuje se da npr. r slučajnih veličina

$$\sqrt{n}(A_{nk} - m_k), \sqrt{n}(A_{nj} - m_j), \dots, \sqrt{n}(A_{nq} - m_q)$$

ima asimptotski r -dimenzionalnu normalnu raspodjelu sa nultim matematičkim očekivanjem i drugim momentima određenim relacijama (2.48) i (2.49) ♦

3 Statistike poretka

Članovi varijacionog niza $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ zovu se *statistike poretka (ranga)*. Pri tom ako je $X_j = X_{(k)}$ onda je rang $X_j = k$.

Ekstremne statistike poretka su *statistika maksimuma i minimuma*:

$$X_{(n)} = M_n = \max\{X_1, X_2, \dots, X_n\} \quad (3.50)$$

$$X_{(1)} = m_n = \min\{X_1, X_2, \dots, X_n\} \quad (3.51)$$

kao i *širina (raspon) uzorka*:

$$R_{(n)} = X_{(n)} - X_{(1)}$$

3.1 Raspodjele statistika poretka

Neka je obilježje X apsolutno-naprekidnog tipa sa funkcijom raspodjele $F(x)$ i gustinom $f(x)$.

Ako je funkcija raspodjele k -te donje statistike ranga $X_{(k)}$, $1 \leq k \leq n$ određena sa $F_{X_{(k)}}(x) = P\{X_{(k)} \leq x\}$, tada se gustina statistike $X_{(k)}$ može odrediti na sledeći način (vidi [1] i [3]):

$$\begin{aligned} f_{X_{(k)}}(x) &= F'_{X_{(k)}}(x) = \frac{\partial}{\partial x} P\{X_{(k)} \leq x\} \\ &= \frac{\partial}{\partial x} P\{\text{najmanje } k \text{ od } n \text{ slučajnih veličina } X_s \text{ je } \leq x\} \\ &= \frac{\partial}{\partial x} P\{\geq k \text{ uspjeha u } n \text{ pokušaja}\} \\ &= \frac{\partial}{\partial x} \sum_{j=k}^n \binom{n}{j} P\{X_1 \leq x\}^j (1 - P\{X_1 \leq x\})^{n-j} \\ &= \frac{\partial}{\partial x} \sum_{j=k}^n \binom{n}{j} F^j(x) \cdot (1 - F(x))^{n-j} \\ &= \sum_{j=k}^n \binom{n}{j} (jF^{j-1}(x)f(x)(1 - F(x))^{n-j} + \\ &\quad + F^j(x)(n - j)(1 - F(x))^{n-j-1}(-f(x))) \\ &= nf(x) \left(\sum_{j=k-1}^{n-1} \binom{n-1}{j} F^j(x)(1 - F(x))^{(n-1)-j} - \right. \\ &\quad \left. \sum_{j=k}^n \binom{n-1}{j} F^j(x)(1 - F(x))^{(n-1)-j} \right) \end{aligned}$$

Kako se svi članovi u gornjim sumama poništavaju, osim prvog u prvoj sumi i poslednjeg u drugoj sumi, to imamo:

$$= nf(x) \left[\binom{n-1}{k-1} F^{k-1}(x)(1 - F(x))^{(n-1)-(k-1)} - \right.$$

$$\begin{aligned}
& - \underbrace{\binom{n-1}{n} F^n(x)(1-F(x))^{(n-1)-n}}_{=0} \\
& = nf(x) \binom{n-1}{k-1} F^{k-1}(x)(1-F(x))^{n-k} \\
& = \frac{n!}{(k-1)!(n-k)!} F^{k-1}(x)(1-F(x))^{n-k} f(x) \tag{3.52}
\end{aligned}$$

Specijalni slučajevi:

1) Za $k = n$ funkcija raspodjele statistike maksimuma je:

$$\begin{aligned}
F_{X_{(n)}}(x) &= P\{X_{(n)} \leq x\} \\
&= P\{\max\{X_1, X_2, \dots, X_n\} \leq x\} \\
&= P\{X_1 \leq x, X_2 \leq x, \dots, X_n \leq x\} \\
&= P\left(\bigcap_{i=1}^n \{X_i \leq x\}\right) \\
&= \prod_{i=1}^n P\{X_i \leq x\} \quad (\text{iz uslova nezavisnosti } X_i) \\
&= \prod_{i=1}^n F_{X_{(i)}}(x) \\
&= F^n(x)
\end{aligned}$$

te je gustina za $X_{(n)}$ određena sa :

$$f_{X_{(n)}}(x) = F'_{X_{(n)}}(x) = nF^{n-1}(x)f(x) \tag{3.53}$$

što se može dobiti i iz (3.52) za $k = n$.

2) Za $k = 1$ funkcija raspodjele statistike minimuma je:

$$\begin{aligned}
F_{X_{(1)}}(x) &= P\{X_{(1)} \leq x\} \\
&= P\{\min\{X_1, X_2, \dots, X_n\} \leq x\} \\
&= 1 - P\{\min\{X_1, X_2, \dots, X_n\} > x\} \\
&= 1 - P\{X_1 > x, X_2 > x, \dots, X_n > x\} \\
&= 1 - P\left(\bigcap_{i=1}^n \{X_i > x\}\right) \\
&= 1 - \prod_{i=1}^n P\{X_i > x\} \quad (\text{iz uslova nezavisnosti } X_i) \\
&= 1 - \prod_{i=1}^n (1 - P\{X_i \leq x\})
\end{aligned}$$

$$\begin{aligned}
&= 1 - \prod_{i=1}^n (1 - F_{X(i)}(x)) \\
&= 1 - (1 - F(x))^n
\end{aligned}$$

te je gustina za $X_{(1)}$ određena sa :

$$\begin{aligned}
f_{X_{(1)}}(x) &= F'_{X_{(1)}}(x) \\
&= -n(1 - F(x))^{n-1}(-f(x)) \\
&= nf(x)(1 - F(x))^{n-1}
\end{aligned} \tag{3.54}$$

što se može dobiti i iz (3.52) za $k = 1$.

Zajednička gustina raspodjele za slučajni vektor svih statistika ranga na uzorku $(X_{(1)}, X_{(2)}, \dots, X_{(n)})$ je:

$$f_{(X_{(1)}, X_{(2)}, \dots, X_{(n)})}(x_1, x_2, \dots, x_n) = n! \prod_{k=1}^n f(x_k) \tag{3.55}$$

za $x_1 < x_2 < \dots < x_n$, za što se dokaz može vidjeti u [10].

Iz ove gustine mogu da se dobiju marginalne gustine za bilo koju statistiku ranga, kao i gustine za bilo koji podskup statistika ranga.

Na primjer, gustina podvektora $(X_{(k_1)}, X_{(k_2)}, \dots, X_{(k_r)})$, gdje je $1 \leq k_1 < k_2 < \dots < k_r \leq n$, $1 < r \leq n$, slučajnog vektora $(X_{(1)}, X_{(2)}, \dots, X_{(n)})$, dobija se integracijom gustine iz (3.55) po preostalim promjenljivim:

$$\begin{aligned}
&f_{(X_{(k_1)}, X_{(k_2)}, \dots, X_{(k_r)})}(x_{k_1}, x_{k_2}, \dots, x_{k_r}) \\
&= n! F(x_{k_1})^{k_1-1} \cdot [F(x_{k_2}) - F(x_{k_1})]^{k_2-k_1-1} \cdot \\
&\quad \dots [F(x_{k_r}) - F(x_{k_{r-1}})]^{k_r-k_{r-1}-1} \cdot \\
&\quad \cdot [1 - F(x_{k_r})]^{n-k_r} \cdot f(x_{k_1}) f(x_{k_2}) \cdot \dots \cdot f(x_{k_r}) / [(k_1 - 1) \cdot \\
&\quad \cdot (k_2 - k_1 - 1) \cdot \dots \cdot (k_r - k_{r-1} - 1) \cdot (n - k_r)]
\end{aligned} \tag{3.56}$$

za $x_{k_1} < x_{k_2} < \dots < x_{k_n}$.

Specijalan slučaj u (3.56) je npr. marginalna gustina za statistiku $X_{(k)}$, $1 \leq k \leq n$:

$$f_{X_{(k)}}(x_k) = \frac{n!}{(k-1)!(n-k)!} F^{k-1}(x_k) (1 - F(x_k))^{n-k} f(x) \tag{3.57}$$

što je u skladu sa dobijenim rezultatom u (3.52).

3.2 Asimptotske raspodjele statistika poretka

Razmotrimo asimptotske ponašanje raspodjela ekstremnih statistika ranga, maksimuma $M_n = X_{(n)}$ i minimuma $m_1 = X_{(1)}$, pri $n \rightarrow \infty$ za niz $\{X_i\}$, $i = \overline{1, n}$ nezavisnih slučajnih veličina sa istom funkcijom raspodjele $F(x)$. Ovom problematikom se bavi teorija ekstremnih vrijednosti.

Pokazano je da je raspodjela maksimuma data sa

$$P\{M_n \leq x\} = F^n(x)$$

Niže navedeni rezultati odnose se na maksimume, ali se jednostavnim transformacijama mogu prilagoditi i minimalnim vrijednostima pojava koje razmatramo, jer vrijedi:

$$P\{m_n \leq x\} = 1 - (1 - F(x))^n$$

i

$$\min\{X_1, X_2, \dots, X_n\} = -\max\{-X_1, -X_2, \dots, -X_n\}$$

Pri ispitivanju asimptotskog ponašanja maksimuma, osnovno pitanje je da li postoje nizovi realnih konstanti $a_n > 0$ i $b_n \in \mathbb{R}$, za koje vrijedi

$$\lim_{n \rightarrow \infty} P\left\{\frac{M_n - b_n}{a_n} \leq x\right\} = F^n(a_n x + b_n) = G(x) \quad (3.58)$$

za svaku tačku neprekidnosti x neke nedegenerisane funkcije raspodjele $G(x)$. Ako takvi nizovi postoje zovu se normirajuće konstante, a funkcija $G(x)$ je granična raspodjela linearno normiranog maksimuma M_n .

Definicija 14 *Funkcija raspodjele $F(x)$ pripada oblasti privlačenja nedegenerisane funkcije raspodjele $G(x)$ ako postoje nizovi realnih brojeva $a_n > 0$ i b_n , $n \in \mathbb{N}$, tako da vrijedi:*

$$\lim_{n \rightarrow \infty} F^n(a_n x + b_n) = G(x) \quad (3.59)$$

za svaku tačku neprekidnosti funkcije $G(x)$.

Ovu pripadnost označavamo sa $F \in D(G)$.

Pitanje koje se nametalo je koje funkcije $G(x)$ se mogu pojaviti kao granične funkcije raspodjele linearno normiranog maksimuma niza od n nezavisnih slučajnih veličina, sa istom funkcijom raspodjele $F(x)$, pri $n \rightarrow \infty$? Dokazano je da je funkcija $G(x)$ istog tipa ¹ kao funkcije iz parametarske familije:

Generalizovane raspodjela ekstremnih vrijednosti (GREV)

$$G_\gamma(x) = \begin{cases} e^{-(1+\gamma x)^{-\frac{1}{\gamma}}}, & 1 + \gamma x > 0, \gamma \neq 0 \\ e^{-e^{-x}}, & x \in \mathbb{R}, \gamma = 0 \end{cases} \quad (3.60)$$

$$\lim_{\gamma \rightarrow 0} G_\gamma(x) = G_0(x) \text{ (Gumbelova raspodjela)}$$

Parametar γ zove se **indeks raspodjele ekstremnih vrijednosti**. Jednparametarska familija $G_\gamma(x)$, za različite vrijednosti γ , svodi se na jednu od tri familije, koje zavise od **parametra oblika** $\alpha > 0$:

Za $\gamma = 0$ dobija se Gumbelova raspodjela (slika 1).

Za $\gamma > 0$ dobija se Frešeova raspodjela (smjena $\gamma = 1/\alpha$, slika 2).

¹Funkcije raspodjele G_1 i G_2 su istog tipa ako postoje konstante $a > 0$ i b , takve da za svaki realan x vrijedi $G_2(x) = G_1(ax + b)$

Za $\gamma < 0$ dobija se Weibulova raspodjela (smjena $\gamma = -1/\alpha < 0$, slika 3). Ove raspodjele definišu se funkcijama raspodjela:

1. Gumbelova raspodjela

$$G_0(x) = e^{-e^{-x}}, \quad -\infty < x < \infty \quad (3.61)$$

2. Freševa raspodjela ($\alpha > 0$)

$$G_{1,\alpha}(x) = \begin{cases} 0 & , \text{ za } x < 0 \\ e^{-x^{-\alpha}} & , \text{ za } x \geq 0 \end{cases} \quad (3.62)$$

3. Weibulova raspodjela ($\alpha > 0$)

$$G_{2,\alpha}(x) = \begin{cases} e^{-(-x)^\alpha} & , \text{ za } x < 0 \\ 1 & , \text{ za } x \geq 0 \end{cases} \quad (3.63)$$

Više o osobinama raspodjela ekstremnih vrijednosti može da se vidi u [8]. U vezi sa raspodjelama $G_\gamma(x)$ je još jedna familija raspodjela ekstremnih vrijednosti

$$H_\gamma(x) = 1 + \log G_\gamma(x)$$

koja se definiše kao:

Generalizovana Paretova raspodjela (GPR)

$$H_\gamma(x) = \begin{cases} 1 - (1 + \gamma x)^{-\frac{1}{\gamma}}, & 1 + \gamma x > 0, \gamma \neq 0 \\ 1 - e^{-x}, & x \in \mathbb{R}, \gamma = 0 \end{cases} \quad (3.64)$$

$$\lim_{\gamma \rightarrow 0} H_\gamma(x) = H_0(x) \text{ (eksponencijalna raspodjela)}$$

Korištenje familije raspodjela GPR je sugerisano u radu Balkema i de Haan (1974), kao i u radu Pickands III (1975), koji su pokazali da je F u oblasti privlačenja $D(G_\gamma)$, ako i samo ako je rep raspodjele F u određenom smislu 'blizak' repu raspodjele H_γ . Više o klasi ovih raspodjela ekstremnih vrijednosti može da se vidi u [7].

Familija $H_\gamma(x)$ za različite vrijednosti γ svodi se na jednu od tri familije:

Za $\gamma = 0$ dobija se eksponencijalna raspodjela (slika 4).


Za $\gamma > 0$ dobija se Paretova raspodjela (smjena $\gamma = 1/\alpha$, slika 5).

Za $\gamma < 0$ dobija se Beta raspodjela (smjena $\gamma = -1/\alpha < 0$, slika 6).


γ - parametrizacija navedenih familija raspodjela može se uopštiti uvođenjem parametra *položaja* μ i *razmjere* $\sigma > 0$ pri čemu se dobijaju kompletna GREV, odnosno kompletna GPR:

$$G_{\gamma,\mu,\sigma}(x) = G_\gamma\left(\frac{x - \mu}{\sigma}\right) \quad (3.65)$$

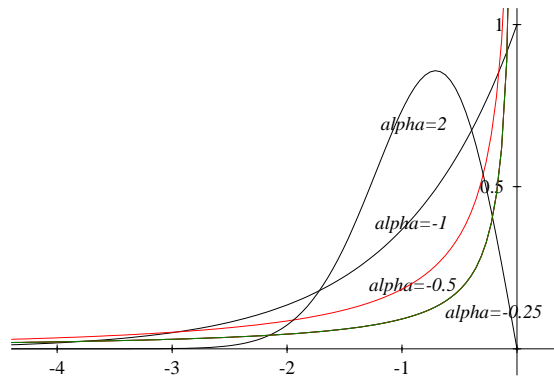
$$H_{\gamma,\mu,\sigma}(x) = H_\gamma\left(\frac{x - \mu}{\sigma}\right) \quad (3.66)$$




Slika 1: Grafici gustine $g_{0,\mu,\sigma}(x) = \frac{1}{\sigma} \exp(-\frac{x-\mu}{\sigma}) \cdot G_{0,\mu,\sigma}(x)$ Gumbelove raspodjele, za $\mu = -2, 0, 2$ i $\sigma = 1$.




Slika 2: Grafici gustine $g_{1,\alpha}(x) = \alpha x^{-(1+\alpha)} e^{-x^{-\alpha}}$ Freševove raspodjele, za $\alpha \in \{1, 2\}$, $\mu = 0$, $\sigma = 1$.




Slika 3: Grafici gustine $g_{2,\alpha}(x) = \alpha(-x)^{\alpha-1}e^{-(-x)^\alpha}$ Weibulove raspodjele, za $\alpha \in \{-0.25, -0.5, -1, -2\}$, $\mu = 0$, $\sigma = 1$.



Slika 4: Grafici gustina $h_{0,\mu,\sigma}(x) = 1 - e^{-\frac{x-\mu}{\sigma}}$ eksponencijalne raspodjele sa različitim parametrima mjesta i razmjere.



Slika 5: Grafici gustine $h_{1,\alpha,\mu,\sigma}(x) = \frac{1}{\sigma} \left(1 + \frac{x-\mu}{\sigma\alpha}\right)^{-\alpha-1}$ Paretove raspodjele, za $\alpha \in \{0.5, 1, 2\}$ i $\mu = 0, \sigma = 1$.



Slika 6: Grafici gustine $h_{2,\alpha,\mu,\sigma}(x) = \frac{1}{\sigma} \left(1 - \frac{x-\mu}{\sigma\alpha}\right)^{\alpha-1}$ Beta raspodjele, za $\alpha \in \{-0.25, -0.5, -1, -3\}$ i $\mu = 0, \sigma = 1$.

Ne ograničavajući se na ekstremne statistike poretka tj. razmatrajući u opštem slučaju k -tu donju statistiku ranga $X_{(k)}$ i k -tu gornju statistiku ranga $X_{(n-k+1)}$ u varijacionom nizu, dobija se rezultat da statistike

$$Y_{(k)} = nF_{X_{(k)}}$$

i

$$Z_{(k)} = n(1 - F_{X_{(n-k+1)}})$$

imaju asimptotski pri $n \rightarrow \infty$ gama raspodjelu određenu gustinom

$$g(x; p, q) = \frac{q^p}{\Gamma(p)} x^{p-1} e^{-qx}, \quad x > 0 \quad (3.67)$$

u kojoj su parametri $q = 1$, $p = k$, te je

$$g(x; 1, k) = \frac{1}{\Gamma(k)} x^{k-1} e^{-x}, \quad x > 0 \quad (3.68)$$

4 Uzoračka medijana i kvantili

Neka je (X_1, X_2, \dots, X_n) uzorak uzet iz populacije sa funkcijom raspodjele $F(x)$ i gustinom $f(x)$. Neka je $0 < p < 1$ i neka je x_p kvantil reda p raspodjele obilježja X , tj. $F(x_p) = p$. Pretpostavimo da je funkcija gustine $f(x)$ neprekidna i pozitivna u x_p .

Pomoću statistika ranga $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ definiše se **uzorački kvantil** K_p reda p kao statistika ranga $X_{(k)}$ kod koje je $k = [np] + 1$.

Raspodjela uzoračkih kvantila za obilježja apsolutno-neprekidnog tipa može da se dobije iz (3.57).

Asimptotski, pri $n \rightarrow \infty$, uzorački kvantil K_p ima graničnu normalnu raspodjelu:

$$K_p \rightarrow \mathcal{N}(x_p, p(1-p)n(f(x_p))^2), \quad n \rightarrow \infty \quad (4.69)$$

tj.

$$\sqrt{n}(K_p - x_p) \rightarrow \mathcal{N}(0, p(1-p)(f(x_p))^2), \quad n \rightarrow \infty \quad (4.70)$$

Uzoračka medijana predstavlja specijalan slučaj uzoračkih kvantila K_p , $0 < p < 1$, za $p = \frac{1}{2}$.

Pomoću statistika ranga $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ uzoračka medijana definiše se na sledeći način:

$$Me = \begin{cases} X_{(k+1)} & , \text{ za } n = 2k + 1 \\ \frac{X_{(k)} + X_{(k+1)}}{2} & , \text{ za } n = 2k. \end{cases} \quad (4.71)$$

Raspodjela uzoračke medijane za obilježja apsolutno-neprekidnog tipa može takođe da se dobije iz (3.57).

Asimptotski, pri $n \rightarrow \infty$, medijana ima graničnu normalnu raspodjelu:

$$Me(x) \sim \mathcal{N}\left(x_{\frac{1}{2}}, \frac{1}{4}nf^2(x_{\frac{1}{2}})\right) \quad (4.72)$$

gdje je $x_{\frac{1}{2}}$ medijana za odgovarajuću teorijsku raspodjelu obilježja, tj. $F(x_{\frac{1}{2}}) = \frac{1}{2}$. Asimptotsku raspodjelu uzoračkih kvantila proučavao je još Laplas prije skoro 200 godina. O novijim rezultatima vezanim za ovu raspodjelu može se vidjeti u [11].

NAPOMENA: O nekim karakteristikama raspodjela pomenutih u ovom radu i njihovim graficima gustina, više može da se sazna iz Atlasa raspodela (vidi [2]).

Literatura

- [1] **Arnold, B.C.**(1988): Bounds on the expected maximum, *Comm. Statist. Theory and Methods* 17(7), 2135-2150
- [2] **Djorić, D.,Jevremović, V.,Mališić, J.,Nikolić-Đorić, V.**(2007): Atlas raspodela, *Građevinski fakultet*, Beograd
- [3] **Caraux, G.,Gascuel,O.**(1992): Bounds on distribution functions of order statistics for dependent variates, *Statistics and Probability Letters* 14 North-Holland, 103-105
- [4] **Cramer, H.**(1946): Mathematical Methods of statistics, *Princeton*
- [5] **Ivanović, B.** (1977): Teorija verovatnoće, *Naučna knjiga*, Beograd, 268-284
- [6] **Ivković, Z.**(1989): Teorija verovatnoća sa matematičkom statistikom, *Naučna knjiga*, Beograd, 141-143
- [7] **Marohn, F.** (2000): Testing Extreme Value Models, *Extremes*, 3:4, 363-384
- [8] **Mladenović, P.**(2002): Ekstremne vrednosti slučajnih nizova, *Matematički fakultet*, Beograd, 53-92
- [9] **Mladenović, P.**(1995): Verovatnoća i statistika, *VESTA - Matematički fakultet*, Beograd, 240-242
- [10] **Stojanović, M. S.**(1980): Matematička statistika, *Naučna knjiga*, Beograd, 54-59
- [11] **Thomas S. Ferguson:** Asymptotic Joint Distribution of Sample Mean and a Sample Quantile, *UCLA*
- [12] <http://home.jesus.ox.ac.uk/~clifford/a5/chap2/node8.html>
- [13] <http://en.wikipedia.org/wiki/Order-statistic>