

Sadržaj

Sadržaj	1
10 ZVB i CGT <i>tko želi znati više</i>	3
10.1 ČEBIŠEVLJEVA NEJEDNAKOST	5
10.2 ZAKON VELIKIH BROJAVA	9
10.3 CENTRALNI GRANIČNI TEOREM	13
10.4 Ponovimo	21

Poglavlje 10

ZAKONI VELIKIH BROJEVA CENTRALNI GRANIČNI TEOREM *tko želi znati više*

Najvažniji teoremi koji će se koristiti u matematičkoj statistici označeni su s *važno*. Preporučujemo i motivirajuće primjere za Čebiševljevu nejednakost, za zakon velikih brojeva i centralni granični teorem.

Čebiševljeva nejednakost, zakoni velikih brojeva i centralni granični teoremi su važan alati koji otkrivaju svojstva diskretnih ili kontinuiranih slučajnih varijabli koje imaju konačno očekivanje i varijancu ako nam i nije poznata njihova distribucija.

Čebiševljeva nejednakost daje ocjenu vjerojatnosti da se vrijednosti slučajne varijable razlikuje od očekivanja više od zadonog ε .

Zakoni velikih brojeva su skup teorema koji se odnosi na granične vrijednosti niza slučajnih varijabli.

Neka su X_1, X_2, \dots, X_n nezavisna mjerena slučajne varijable X u ponovljenim pokusima. Slučajne varijable X_1, X_2, \dots, X_n su nezavisne i sve imaju istu distribuciju kao i slučajna varijabla X .

Može se uočiti da njihova aritmetička sredina $\bar{X} = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$ ima svojstvo stabilnosti distribucije i da je vjerojatnost da se vrijednosti od \bar{X} razlikuje od očekivanja više od zadonog ε jednaka nuli kad $n \rightarrow \infty$.

Centralni granični teoremi se odnose na granične zakone distribucije niza slučajnih varijabli. Suma velikog broja slučajnih varijabli ima standardnu normalnu distribuciju. Teoremi daju različite uvjete na pribrojnice u toj sumi.

10.1 ČEBIŠEVLJEVA NEJEDNAKOST

MOTIV 10.1 Neka slučajna varijabla ima varijancu (disperziju)

$Var(X) = 0.001$. Kolika je vjerojatnost da slučajna varijabla odstupa od očekivanja manje od $\varepsilon = 0.1$?

TEOREM 10.1 (MARKOVLJEVA NEJEDNAKOST)

Neka je X slučajna varijabla s nenegativnim vrijednostima i konačnim očekivanjem $E(X)$.

Tada $\forall a > 0$ vrijedi

$$P(X \geq a) \leq \frac{E(X)}{a}$$

Dokaz:

Možemo pokazati za kontinuiranu slučajnu varijablu s funkcijom gustoće $f(x)$ (analogno za diskretnu).

Kako X poprima samo nenegativne vrijednosti uočimo one $x \in R(X)$, $0 \leq x < a$ i $x \geq a$.

Prema definiciji očekivanja: $E(X) = \int_0^\infty xf(x)dx = \int_0^a xf(x)dx + \int_a^\infty xf(x)dx$.

Budući su integrali pozitivni vrijedi nejednakost

$$E(X) \geq \int_a^\infty xf(x)dx.$$

Ako u podintegralnoj funkciji zamijenimo x s konstantom koja je uvijek manja od x , $a \leq x$, zadržat će se znak nejednakosti

$$E(X) \geq a \int_a^\infty f(x)dx.$$

Prema definiciji funkcije gustoće vjerojatnosti $f(x)$ dobivamo traženu nejednakost:

$$E(X) \geq a \cdot P(X \geq a).$$

TEOREM 10.2 (POOPĆENJE MARKOVLJEVE NEJEDNAKOSTI)

Neka je X slučajna varijabla i $h : R \rightarrow R$ nenegativna funkcija tako da postoji očekivanjem $E(h(X))$.

Tada $\forall a > 0$ vrijedi

$$P(h(X) \geq a) \leq \frac{E(h(X))}{a}$$

10.1. ČEBIŠEVLEVA NEJEDNAKOST

Dokaz:

Kako $h(X)$ poprima samo nenegativne vrijednosti uočimo one $x \in R(X)$,
 $0 \leq h(x) < a$, za $x \in D_1 \subseteq R$, i $h(x) \geq a$, za $x \in D_2 \subseteq R$:

Prema definiciji očekivanja funkcije slučajne varijable X :

$$E(h(X)) = \int_0^\infty h(x)f(x)dx = \int_{D_1} h(x)f(x)dx + \int_{D_2} h(x)f(x)dx.$$

Budući su integrali pozitivni vrijedi nejednakost

$$\begin{aligned} E(h(X)) &\geq \int_{D_2} h(x)f(x)dx \geq a \int_{D_2} f(x)dx \\ &\geq a \cdot P(h(X) \geq a). \end{aligned}$$

TEOREM 10.3 važno

(ČEBIŠEVLEVA NEJEDNAKOST, engl. Chebyshev's
inequality)

Neka je X slučajna varijabla s konačnom varijancom $Var(X)$.

Tada $\forall \varepsilon > 0$ vrijedi

$$P(|X - E(X)| \geq \varepsilon) \leq \frac{Var(X)}{\varepsilon^2},$$

$$P(|X - E(X)| < \varepsilon) \geq 1 - \frac{Var(X)}{\varepsilon^2}.$$

Ako označimo $Var(X) = \sigma^2$, $E(X) = \mu$, $\varepsilon = \lambda\sigma$, onda vrijedi

$$P(|X - \mu| \geq \lambda\sigma) \leq \frac{1}{\lambda^2},$$

$$P(|X - \mu| < \lambda\sigma) \geq 1 - \frac{1}{\lambda^2}.$$

Dokaz:

(a) Dokaz pomoću generalizirane Markovljeve nejednakosti.

Pretpostavka teorema je da X ima varijancu tj. ima očekivanje

$E((X - E(X))^2) = Var(X)$ pa možemo primjeniti teorem za nenegativnu funkciju $h(x) = (x - E(X))^2$.

Vrijedi nejednakost $P((X - E(X))^2 \geq a) \leq \frac{E((X - E(X))^2)}{a}$, $\forall a > 0$.

Budući je $P((x - E(X))^2 \geq a) = P(|X - E(X)| \geq \sqrt{a})$, vrijedi nejednakost

$$P(|X - E(X)| \geq \sqrt{a}) \leq \frac{E((X - E(X))^2)}{a}, \quad \forall a > 0.$$

10. ZVB i CGT *tko želi znati više*

Tada $\forall \varepsilon > 0$ vrijedi

$$P(|X - E(X)| \geq \varepsilon) \leq \frac{Var(X)}{\varepsilon^2}.$$

(b) Dokaz za diskretnu slučajnu varijablu (bez generalizirane Markovljeve nejednakosti)

Neka je X diskretna slučajna varijabla sa slikom $R(X) = \{x_1, x_2, \dots\}$ i neka je $f(x)$ njena funkcija vjerojatnosti.

Pretpostavka teorema je da X ima konačnu varijancu (i očekivanje).

$$Var(X) = \sum_{x_i} (x_i - (E(X))^2 f(x_i).$$

Uočimo one $x_i \in R(X)$ za koje je $|x_i - (E(X))| < \varepsilon$ i one za koje je $|x_i - (E(X))| \geq \varepsilon$.

$$\begin{aligned} Var(X) &\geq \sum_{x_i: |x_i - (E(X))| < \varepsilon} (x_i - (E(X))^2 f(x_i)) + \sum_{x_i: |x_i - (E(X))| \geq \varepsilon} (x_i - (E(X))^2 f(x_i)) \\ &\geq \sum_{x_i: |x_i - (E(X))| \geq \varepsilon} (x_i - (E(X))^2 f(x_i)). \end{aligned}$$

Zamjenom svakog člana sume s manjom konstantom ε , nejednakost se zadržava pa vrijedi:

$$Var(X) \geq \sum_{x_i: |x_i - (E(X))| \geq \varepsilon} \varepsilon^2 f(x_i) \geq \varepsilon^2 \cdot \sum_{x_i: |x_i - (E(X))| \geq \varepsilon} f(x_i).$$

Suma $\sum_{x_i: |x_i - (E(X))| \geq \varepsilon} f(x_i)$ je prema definiciji funkcije distribucije jednaka $P(|X - (E(X))| \geq \varepsilon)$ i dobivamo konačnu nejednakost:

$$Var(X) \geq \varepsilon^2 \cdot P(|X - (E(X))| \geq \varepsilon).$$

Prisjetimo se motivacijskog primjera:

PRIMJER 10.1 *motiv*

Neka slučajna varijabla ima varijancu (disperziju)

$Var(X) = 0.001$. Kolika je vjerojatnost da slučajna varijabla odstupa od očekivanja manje od $\varepsilon = 0.1$?

Rješenje:

Trebamo izračunati $P(|X - E(X)| < \varepsilon)$.

Koristimo Čebiševljevu nejednakost u obliku $P(|X - E(X)| < \varepsilon) \geq 1 - \frac{Var(X)}{\varepsilon^2}$,

$$P(|X - E(X)| < 0.1) \geq 1 - \frac{0.001}{0.1^2} \geq 0.9.$$

10.1. ČEBIŠEVLJEVA NEJEDNAKOST

PRIMJER 10.2 Slučajna varijabla ima očekivanje $\mu = 3$ i standardnu devijaciju $\sigma = 0.1$. Ocijenite $P(2.5 < X < 3.5)$.

Rješenje:

Zadano je očekivanje $\mu = 3$ i uočimo da je

$$P(2.5 < X < 3.5) = P(\mu - 0.5 < X < \mu + 0.5) = P(|X - \mu| < 0.5).$$

Koristimo Čebiševljevu nejednakost u obliku: $P(|X - \mu| < \varepsilon) \geq 1 - \frac{\sigma^2}{\varepsilon^2}$,
 $P(|X - \mu| < 0.5) \geq 1 - \frac{0.1^2}{0.5^2} = 0.96$,

$$P(2.5 < X < 3.5) \geq 0.96.$$

10.2 ZAKON VELIKIH BROJEVA

MOTIV 10.2 Kontrolor uzima uzorak veličine $m = 1000$ iz skupa uređaja. Vjerojatnost da je uređaj neispravan je $p = 0.03$. U kojim granicama će biti broj neispravnih uređaja u uzorku s vjerojatnošću $\gamma = 0.99$.

Definicija 10.1 (KONVERGENCIJA PO VJEROJATNOSTI)

Neka je (X_n) , $n \in N$ niz slučajnih varijabli. Ako postoji slučajna varijabla X takva da

$$\forall \varepsilon > 0 \quad \lim_{n \rightarrow \infty} P(|X_n - X| < \varepsilon) = 1$$

kažemo da niz (X_n) slučajnih varijabli konvergira slučajnoj varijabli X po vjerojatnosti i označavamo

$$(P) \lim_{n \rightarrow \infty} X_n = X.$$

Definicija 10.2 Za niz slučajnih varijabli (X_n) , $n \in N$ kažemo da zadovoljava zakon velikih brojeva ako postoji konstanta C takva da vrijedi

$$\forall \varepsilon > 0 \quad \lim_{n \rightarrow \infty} P(|X_n - C| < \varepsilon) = 1$$

i označavamo

$$(P) \lim_{n \rightarrow \infty} X_n = C.$$

TEOREM 10.4 važno

(ZAKON VELIKIH BROJEVA

(specijalan slučaj za aritmetičku sredinu))

Neka je $\{X_n\}$, $n \in N$ niz slučajnih varijabli takvih da za svaki n slučajne varijable X_1, X_2, \dots, X_n su nezavisne, imaju ograničenu varijancu

$Var(X_i) = \sigma^2 \leq M > 0$ i $E(X_i) = \mu$, $i = 1, \dots, n$.

Tada za aritmetičku sredinu

$$\bar{X} = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$$

vrijedi

$$\forall \varepsilon > 0 \quad \lim_{n \rightarrow \infty} P(|\bar{X} - \mu| < \varepsilon) = 1,$$

$$(P) \lim_{n \rightarrow \infty} \bar{X} = \mu.$$

Dokaz:

$$\bar{X} = \frac{1}{n}(X_1 + X_2 + \dots + X_n), E(\bar{X}) = \mu, Var(\bar{X}) = \frac{\sigma^2}{n}.$$

Koristimo Čebiševljevu nejednakost za slučajnu varijablu \bar{X} u obliku:

$$P(|\bar{X} - E(\bar{X})| < \varepsilon) \geq 1 - \frac{Var(\bar{X})}{\varepsilon^2},$$

$$P(|\bar{X} - \mu| < \varepsilon) \geq 1 - \frac{\sigma^2}{n \cdot \varepsilon^2},$$

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{1}{n}(X_1 + X_2 + \dots + X_n) - \mu\right| < \varepsilon\right) = 1.$$

TEOREM 10.5 (BERNOULLIJEV SLABI ZAKON VELIKIH BROJEVA - za rel.frekv binomne sl. varijable)

Neka je u Bernoullijevoj shemi slučajna varijabla X =broj uspjeha događaja A u m nezavisnih ponavljanja, $P(A) = p$. $X \sim B(m, p)$. Slučajna varijabla $Y = \frac{X}{m}$ zove se relativna frekvencija uspjeha događaja A u Bernoullijevoj shemi.

Tada vrijedi

$$\lim_{m \rightarrow \infty} \sum_{|\frac{k}{m} - p| < \varepsilon} \binom{m}{k} p^k (1-p)^{m-k} = \lim_{m \rightarrow \infty} P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) = 1,$$

$$(P) \lim_{m \rightarrow \infty} \frac{X}{m} = p.$$

Dokaz:

Za binomnu slučajnu varijablu $X \sim B(m, p)$, $E(X) = mp$,

$Var(X) = mp(1-p)$.

Za relativnu frekvenciju uspjeha $Y = \frac{X}{m}$ odredimo očekivanje i varijancu:

$$E\left(\frac{X}{m}\right) = p, \quad Var\left(\frac{X}{m}\right) = \frac{p(1-p)}{m}.$$

Primjenimo Čebiševljevu nejednakost za slučajnu varijablu $Y = \frac{X}{m}$ nejednakost u obliku: $P(|Y - E(Y)| < \varepsilon) \geq 1 - \frac{Var(Y)}{\varepsilon^2}$,

$$P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) \geq 1 - \frac{p(1-p)}{m \cdot \varepsilon^2},$$

$$\lim_{m \rightarrow \infty} P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) = 1.$$

10. ZVB i CGT *tko želi znati više*

Kako je funkcija vjerojatnosti binomne slučajne varijable

$$f(x) = \binom{m}{x} p^x (1-p)^{m-x}$$

$$\lim_{m \rightarrow \infty} \sum_{|\frac{k}{m} - p| < \varepsilon} \binom{m}{k} p^k (1-p)^{m-k} = \lim_{m \rightarrow \infty} P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) = 1.$$

NAPOMENA 10.1 *važno*

Oblik Bernoullijevog slabog zakona velikih brojeva

$$P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) \geq 1 - \frac{p(1-p)}{m \cdot \varepsilon^2}$$

često se koristi u zadacima za određivanje

(a) minimalnog broja pokusa m

(b) odstupanja ε

da bi za zadani γ , $P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) \geq \gamma$.

Rješenje:

$$(a) m \geq \frac{1}{1-\gamma} \cdot \frac{1}{\varepsilon^2} \cdot p(1-p).$$

$$(b) \varepsilon^2 \geq \frac{1}{1-\gamma} \cdot \frac{1}{m} \cdot p(1-p).$$

Ako je p nepoznato onda se procjenjuje da je $p(1-p) \leq \frac{1}{4}$, i

$$(a) m \geq \frac{1}{1-\gamma} \cdot \frac{1}{4 \cdot \varepsilon^2},$$

$$(b) \varepsilon^2 \geq \frac{1}{1-\gamma} \cdot \frac{1}{4 \cdot m}.$$

PRIMJER 10.3 U Bernoullijevoj shemi vjerojatnost događaja A je $p = P(A) = 1/3$. Odredite minimalan broj ponavljanja tako da s vjerojatnošću ne manjom od $\gamma = 0.99$ apsolutno ostupanje relativne frekvencije od p bude najviše $\varepsilon = 0.01$.

Rješenje:

Trebamo odrediti m tako da $P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) \geq 0.99$.

Koristimo Bernoullijev slabi zakon velikih brojeva: $P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) \geq 1 - \frac{p(1-p)}{m \cdot \varepsilon^2}$

$$P\left(\left|\frac{X}{m} - \frac{1}{3}\right| < 0.01\right) \geq 1 - \frac{\frac{2}{9}}{m \cdot 0.01^2}$$

10.2. ZAKON VELIKIH BROJEVA

Broj ponavljanja čemo odrediti iz zadane vjerojatnosti γ i uvjeta

$$1 - \frac{\frac{2}{9}}{m \cdot (0.01)^2} \geq 0.99$$

$$m \geq \frac{1}{1 - \gamma} \cdot \frac{1}{\varepsilon^2} \cdot p(1 - p) = \frac{2}{9} \cdot \frac{1}{1 - 0.99} \cdot \frac{1}{(0.01)^2} \Rightarrow m \geq 222222.$$

Napomena (zadatak čemo riješiti i koristeći Moivre-Laplaceov teorem-poslije).

Prisjetimo se motivacijskog primjera:

PRIMJER 10.4 *motiv*

Kontrolor uzima uzorak veličine $m = 1000$ iz skupa uređaja. Vjerojatnost da je uređaj neispravan je $p = 0.03$. U kojim granicama će biti broj neispravnih uređaja u uzorku s vjerojatnošću $\gamma = 0.99$.

Rješenje:

Treba oderditi a i b takve da za $X =$ broj neispravnih uređaja u uzorku veličine m , $X \sim B(m, p)$, $P(a < X < b) \geq 0.99$.

Koristimo Bernoullijev slabi zakon velikih brojeva:

$$P(|\frac{X}{m} - p| < \varepsilon) \geq 1 - \frac{p(1-p)}{m \cdot \varepsilon^2},$$

$$P(|\frac{X}{1000} - 0.03| < \varepsilon) \geq 1 - \frac{0.03(1 - 0.03)}{1000 \cdot \varepsilon^2}.$$

Odstupanje ε čemo odrediti iz zadane vjerojatnosti γ i uvjeta

$$1 - \frac{0.03(1 - 0.03)}{1000 \cdot \varepsilon^2} \geq 0.99.$$

$$\varepsilon^2 \geq \frac{1}{1 - \gamma} \cdot \frac{1}{m} \cdot p(1 - p) = \frac{1}{1 - 0.99} \cdot \frac{1}{1000} \cdot 0.03 \cdot (1 - 0.03) = 0.003.$$

$$\varepsilon \geq \sqrt{0.003} = 0.054 \Rightarrow |\frac{X}{1000} - 0.03| < 0.054 \Rightarrow 0 < X < 80.$$

Napomena (zadatak čemo riješiti i koristeći Moivre-Laplaceov teorem-poslije).

10.3 CENTRALNI GRANIČNI TEOREM

Motivirajući primjer je isti kao i poglavlju Zakon velikih brojeva, ali će se sad riješiti primjenom centralnog graničnog teorema (Moivre - Laplaceov teorem).

MOTIV 10.3 Kontrolor uzima uzorak veličine $m = 1000$ iz skupa uređaja. Vjerojatnost da je uređaj neispravan je $p = 0.03$. U kojim granicama će biti broj neispravnih uređaja u uzorku s vjerojatnošću $\gamma = 0.99$

TEOREM 10.6 (CENTRALNI GRANIČNI TEOREM-CGT; specijalni slučaj)

Neka je $\{X_n\}, n \in N$ niz slučajnih varijabli takvih da za svaki n slučajne varijable X_1, X_2, \dots, X_n su nezavisne, imaju ograničenu varijancu

$$\text{Var}(X_i) = \sigma^2 \leq M > 0 \text{ i } E(X_i) = \mu, \quad i = 1, \dots, n.$$

Tada

$$\lim_{n \rightarrow \infty} P\left(a < \frac{\sum_{i=1}^n X_i - n\mu}{\sqrt{n} \cdot \sigma} < b\right) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{1}{2}x^2} dx,$$

$$\frac{\sum_{i=1}^n X_i - n\mu}{\sqrt{n} \cdot \sigma} \sim N(0, 1), \quad n \rightarrow \infty.$$

Za velike n vrijedi

$$P\left(a < \frac{\sum_{i=1}^n X_i - n\mu}{\sqrt{n} \cdot \sigma} < b\right) \approx F^*(b) - F^*(a).$$

($F^*(x)$ funkcija distribucije standardne normale distribucije).

Dokaz: (literatura)

TEOREM 10.7 važno

(CGT za aritmetičku sredinu)

Neka je $\{X_n\}, n \in N$ niz slučajnih varijabli takvih da za svaki n slučajne varijable X_1, X_2, \dots, X_n su nezavisne, imaju ograničenu varijancu

$$\text{Var}(X_i) = \sigma^2 \leq M > 0 \text{ i } E(X_i) = \mu, \quad i = 1, \dots, n.$$

Tada za aritmetičku sredinu $\bar{X} = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$ vrijedi

$$\lim_{n \rightarrow \infty} P\left(a < \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} < b\right) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{1}{2}x^2} dx,$$

10.3. CENTRALNI GRANIČNI TEOREM

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

odnosno

$$\bar{X} \sim N(\mu, \frac{\sigma^2}{n}), \quad n \rightarrow \infty.$$

Za velike n vrijedi

$$P(a < \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} < b) \approx F^*(b) - F^*(a).$$

Dokaz:

Primijenimo CGT (specijalni slučaj) za $\bar{X} = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$.

PRIMJER 10.5 Neka su X_1, X_2, \dots, X_n nezavisne slučajne varijable, imaju ograničenu varijancu $Var(X_i) = \sigma^2 = 2$ i $E(X_i) = \mu = 3$, $i = 1, \dots, n = 3200$. Za aritmetičku sredinu $\bar{X} = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$ odredite $P(2.95 < \bar{X} < 3.075)$.

Rješenje:

Prema CGT za aritmetičku sredinu n slučajnih varijabli

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

$$\lim_{n \rightarrow \infty} P(a < \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} < b) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{1}{2}x^2} dx.$$

$$\begin{aligned} P(2.95 < \bar{X} < 3.075) &= P\left(\frac{2.95 - \mu}{\frac{\sigma}{\sqrt{n}}} < \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} < \frac{3.075 - \mu}{\frac{\sigma}{\sqrt{n}}}\right) \\ &= P\left(\frac{2.95 - 3}{\frac{\sqrt{2}}{\sqrt{3200}}} < \frac{\bar{X} - 3}{\frac{\sqrt{2}}{\sqrt{3200}}} < \frac{3.075 - 3}{\frac{\sqrt{2}}{\sqrt{3200}}}\right) \\ &= P(-2 < \frac{\bar{X} - 3}{\frac{\sqrt{2}}{\sqrt{3200}}} < 3) = F^*(3) - F^*(-2) = 0.975. \end{aligned}$$

TEOREM 10.8 (integralni MOIVRE - LAPLACEOV TEOREM, CGT za binomnu sl. varijablu)

Neka je u Bernoullijevoj shemi slučajna varijabla $X = \text{broj uspjeha događaja } A \text{ u } m \text{ nezavisnih ponavljanja } P(A) = p$. $X \sim B(m, p)$.

Tada vrijedi

$$\lim_{m \rightarrow \infty} P(a < \frac{X - m \cdot p}{\sqrt{mp(1-p)}} < b) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{1}{2}x^2} dx,$$

$$\frac{X - m \cdot p}{\sqrt{mp(1-p)}} \sim N(0, 1), \quad m \rightarrow \infty,$$

odnosno

$$X \sim N(mp, mp(1-p)), \quad m \rightarrow \infty.$$

Za velike n vrijedi

$$P(a < \frac{X - m \cdot p}{\sqrt{mp(1-p)}} < b) \approx F^*(b) - F^*(a),$$

odnosno

$$P(a < X < b) \approx F^*\left(\frac{b - mp}{\sqrt{mp(1-p)}}\right) - F^*\left(\frac{a - mp}{\sqrt{mp(1-p)}}\right).$$

Dokaz:

Promatrajmo slučajne varijable $X_i \sim B(1, p)$, $i = 1, \dots, m$, kad $m \rightarrow \infty$.

$Var(X_i) = p(1-p)$ i $E(X_i) = p$, $i = 1, \dots, m$.

Integralni Moivre-Laplaceov teorem je specijalan slučaj CGT za niz slučajnih varijabli $X_i = 1, \dots, m$, kad $m \rightarrow \infty$

$$\lim_{m \rightarrow \infty} P\left(a < \frac{\sum_{i=1}^m X_i - m\mu}{\sqrt{m \cdot \sigma}} < b\right) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{1}{2}x^2} dx,$$

$$\lim_{m \rightarrow \infty} P\left(a < \frac{\sum_{i=1}^m X_i - mp}{\sqrt{m \cdot p(1-p)}} < b\right) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{1}{2}x^2} dx.$$

Slučajna varijabla $X = \text{broj uspjeha događaja A u } m \text{ nezavisnih ponavljanja}$ $P(A) =$

p . $X \sim B(m, p)$. Tada je $X = \sum_{i=1}^m X_i$ pa vrijedi

$$\lim_{m \rightarrow \infty} P\left(a < \frac{X - mp}{\sqrt{m \cdot p(1-p)}} < b\right) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{1}{2}x^2} dx.$$

PRIMJER 10.6 Neka je X binomna slučajna varijabla $X \sim B(m, p)$,

$m = 3200$, $p = \frac{1}{2}$. Izračunajte vjerojatnost da slučajna varijabla poprimi vrijednosti u intervalu (1550, 1650).

10.3. CENTRALNI GRANIČNI TEOREM

Rješenje:

Trebamo izračunati $P(1550 < X < 1650)$.

Prema integralnom Moivre-Laplaceovom teoremu $\frac{X-m-p}{\sqrt{mp(1-p)}} \sim N(0, 1)$,

$m \rightarrow \infty$,

i vrijedi aproksimacija: $P(a < X < b) \approx F^*\left(\frac{b-mp}{\sqrt{mp(1-p)}}\right) - F^*\left(\frac{a-mp}{\sqrt{mp(1-p)}}\right)$.

$$\begin{aligned} P(1550 < X < 1650) &\approx F^*\left(\frac{1650 - 3200 \cdot 0.5}{\sqrt{3200 \cdot 0.25}}\right) - F^*\left(\frac{1550 - 3200 \cdot 0.5}{\sqrt{3200 \cdot 0.25}}\right) \\ &= F^*(1.767) - F^*(-1.767) = 2F^*(1.767) - 1 \\ &= 2 \cdot 0.961 - 1 = 0.922. \end{aligned}$$

PRIMJER 10.7 Vjerojatnost da novorođenče bude muško ili žensko je $1/2$. Kolika je vjerojatnost da među 1000 novorođenčadi bude barem 490 muških?

Rješenje: $X \sim B(m, p)$, $m = 1000$, $p = \frac{1}{2}$

Trebamo izračunati $P(X \geq 490) = 1 - P(X \leq 490)$.

Prema integralnom Moivre-Laplaceovom teoremu $\frac{X-m-p}{\sqrt{mp(1-p)}} \sim N(0, 1)$,

$m \rightarrow \infty$,

i vrijedi aproksimacija: $P(a < X < b) \approx F^*\left(\frac{b-mp}{\sqrt{mp(1-p)}}\right) - F^*\left(\frac{a-mp}{\sqrt{mp(1-p)}}\right)$.

$$\begin{aligned} P(X \leq 490) &\approx F^*\left(\frac{490 - 1000 \cdot 0.5}{\sqrt{1000 \cdot 0.25}}\right) = F^*\left(-\frac{10}{\sqrt{250}}\right) = 1 - F^*\left(\frac{10}{\sqrt{250}}\right) \\ &= 1 - F^*(0.63) = 1 - 0.7357 = 0.2643. \end{aligned}$$

$$P(X \geq 490) = 1 - P(X \leq 490) \approx 1 - 0.2643 = 0.7357.$$

TEOREM 10.9 (integralni MOIVRE - LAPLACEOV TEOREM za rel. frekv. binomne sl. varijable) CGT za binomnu =Bernoullijev slabi ZVB za rel. frekvencije binomne

Neka je u Bernoullijevoj shemi slučajna varijabla X =broj uspjeha događaja A u m nezavisnih ponavljanja, $P(A) = p$. $X \sim B(m, p)$. Slučajna varijabla $Y = \frac{X}{m}$ zove se relativna frekvencija uspjeha događaja A u Bernoullijevoj shemi.

Tada vrijedi

$$\lim_{m \rightarrow \infty} P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) = \lim_{m \rightarrow \infty} 2F^*\left(\varepsilon \sqrt{\frac{m}{p(1-p)}}\right) - 1 = 1.$$

Za velike m vrijedi

$$P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) \approx 2F^*\left(\varepsilon \sqrt{\frac{m}{p(1-p)}}\right) - 1.$$

10. ZVB i CGT *tko želi znati više*

Dokaz: $P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) = P\left(-\varepsilon \sqrt{\frac{m}{p(1-p)}} < \frac{X - mp}{\sqrt{mp(1-p)}} < \varepsilon \sqrt{\frac{m}{p(1-p)}}\right)$

Koristimo Integralni Moivre-Laplaceov teorem; za $X \sim B(m, p)$ je

$$P(a < \frac{X - mp}{\sqrt{mp(1-p)}} < b) \approx F^*(b) - F^*(a),$$

$$P\left(-\varepsilon \sqrt{\frac{m}{p(1-p)}} < \frac{X - mp}{\sqrt{mp(1-p)}} < \varepsilon \sqrt{\frac{m}{p(1-p)}}\right) \approx F^*(b) - F^*(a),$$

$$\text{gdje je } b = -a = \varepsilon \sqrt{\frac{m}{p(1-p)}}.$$

Koristimo svojstvo $F^*(x) = 1 - F^*(-x)$

$$P\left(-\varepsilon \sqrt{\frac{m}{p(1-p)}} < \frac{X - mp}{\sqrt{mp(1-p)}} < \varepsilon \sqrt{\frac{m}{p(1-p)}}\right) \approx 2F^*(b) - 1,$$

i dobivamo željenu tvrdnju

$$P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) \approx 2F^*\left(\varepsilon \sqrt{\frac{m}{p(1-p)}}\right) - 1.$$

PRIMJER 10.8 Kolika je vjerojatnost da se prilikom bacanja simetričnog novčića $m = 3600$ puta relativna frekvencija pojavljivanja pisma po absolutnoj vrijednosti razlikuje od $p = 1/2$ za $\varepsilon = 0.01$?

Rješenje:

X =broj pojavljivanja pisma u Bernoullijevoj shemi bacanja novčića

$$X \sim B(m, p), m = 3600, p = \frac{1}{2}.$$

Trebamo izračunati $P\left(\left|\frac{X}{3600} - \frac{1}{2}\right| < 0.01\right)$.

Primijenit ćemo integralni Moivre-Laplaceov teorem za rel. frekv. binomne sl. varijable u obliku $P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) \approx 2F^*\left(\varepsilon \sqrt{\frac{m}{p(1-p)}}\right) - 1$.

$$\begin{aligned} P\left(\left|\frac{X}{3600} - \frac{1}{2}\right| < 0.01\right) &\approx 2F^*\left(\varepsilon \sqrt{\frac{m}{p(1-p)}}\right) - 1 = 2F^*\left(0.01 \sqrt{\frac{3600}{\frac{1}{2} \cdot \frac{1}{2}}}\right) - 1 \\ &= 2F^*(1.2) - 1 = 2 \cdot 0.8849 - 1 = 0.7698. \end{aligned}$$

NAPOMENA 10.2 važno

Oblik integralnog Moivre-Laplaceovog teorema

$P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) \approx 2F^*\left(\varepsilon \sqrt{\frac{m}{p(1-p)}}\right) - 1$ često se koristi u zadacima za određivanje

(a) minimalnog broja pokusa m i

10.3. CENTRALNI GRANIČNI TEOREM

(b) odstupanja ε

da bi za zadani γ , $P(|\frac{X}{m} - p| < \varepsilon) \geq \gamma$.

Rješenje:

$$(a) m \geq \frac{\left(\frac{z_{1+\gamma}}{2}\right)^2}{\varepsilon^2} \cdot p(1-p), \quad F^*\left(z_{\frac{1+\gamma}{2}}\right) = \frac{1+\gamma}{2},$$

$$(b) \varepsilon^2 \geq \frac{\left(z_{\frac{1+\gamma}{2}}\right)^2}{m} \cdot p(1-p).$$

Ako je p nepoznato onda se procjenjuje da je $p(1-p) \leq \frac{1}{4}$:

$$(a) m \geq \frac{\left(\frac{z_{1+\gamma}}{2}\right)^2}{4\varepsilon^2}, \quad F^*\left(z_{\frac{1+\gamma}{2}}\right) = \frac{1+\gamma}{2},$$

$$(b) \varepsilon^2 \geq \frac{\left(z_{\frac{1+\gamma}{2}}\right)^2}{4m}.$$

PRIMJER 10.9 U Bernoullijevoj shemi vjerojatnost događaja A je $p = P(A) = 1/3$. Odredite minimalan broj ponavljanja tako da s vjerojatnošću ne manjom od $\gamma = 0.99$ apsolutno ostupanje relativne frekvencije od p bude najviše $\varepsilon = 0.01$.

Rješenje:

Trebamo odrediti m tako da $P(|\frac{X}{m} - p| < \varepsilon) \geq 0.99$.

Koristimo Integralni Moivre-Laplaceov teorem za relativnu frekvenciju $\frac{X}{m}$ u Bernoullijevoj shemi.

$$P(|\frac{X}{m} - p| < \varepsilon) \approx 2F^*\left(\varepsilon \sqrt{\frac{m}{p(1-p)}}\right) - 1,$$

$$P\left(|\frac{X}{m} - \frac{1}{3}| < 0.01\right) \approx 2F^*(0.01 \sqrt{\frac{m}{\frac{2}{9}}}) - 1.$$

Broj ponavljanja ćemo odrediti iz zadane vjerojatnosti γ i uvjeta

$$2F^*(0.01 \sqrt{\frac{m}{\frac{2}{9}}}) - 1 \geq 0.99 \Rightarrow F^*(0.01 \sqrt{\frac{m}{\frac{2}{9}}}) \geq 0.995,$$

$$F^*(z) = 0.995 \Rightarrow z = 2.6 \Rightarrow 0.01 \sqrt{\frac{m}{\frac{2}{9}}} \geq 2.6,$$

$$m \geq \frac{\left(z_{\frac{1+\gamma}{2}}\right)^2}{\varepsilon^2} \cdot p(1-p) = \frac{2.6^2}{0.01^2} \cdot \frac{2}{9} \Rightarrow m \geq 15022.$$

(Bernoullijev SZVB za rel. frekv. dao je ocjenu $m \geq 222222$.)

PRIMJER 10.10 Koliko puta treba baciti simetričnu kocku da bi relativna frekvencija pojavljivanja broja 6 bila između $\frac{19}{120}$ i $\frac{21}{120}$ s vjerojatnošću $\gamma = 0.95$.

10. ZVB i CGT *tko želi znati više*

Rješenje:

X =broj pojavljivanja 6 u Bernoullijevoj shemi bacanja kocke

$$X \sim B(m, p), m, p = \frac{1}{6}.$$

Trebamo odrediti m tako da $P\left(\frac{19}{120} < \frac{X}{m} < \frac{21}{120}\right) \geq 0.95$.

$$\begin{aligned} P\left(\frac{19}{120} < \frac{X}{m} < \frac{21}{120}\right) &= P\left(\frac{19}{120} - \frac{1}{6} < \frac{X}{m} - \frac{1}{6} < \frac{21}{120} - \frac{1}{6}\right) \\ &= P\left(-\frac{1}{120} < \frac{X}{m} - \frac{1}{6} < \frac{1}{120}\right) = P\left(\left|\frac{X}{m} - \frac{1}{6}\right| < \frac{1}{120}\right). \end{aligned}$$

Koristimo Integralni Moivre-Laplaceov teorem za relativnu frekvenciju $\frac{X}{m}$ u Bernoul- lijevoj shemi.

$$P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) \approx 2F^*\left(\varepsilon \sqrt{\frac{m}{p(1-p)}}\right) - 1,$$

$$P\left(\left|\frac{X}{m} - \frac{1}{6}\right| < \frac{1}{120}\right) \approx 2F^*\left(\frac{1}{120} \sqrt{\frac{m}{\frac{5}{36}}}\right) - 1$$

Broj ponavljanja čemo odrediti iz zadane vjerojatnosti γ i uvjeta

$$2F^*\left(\frac{1}{120} \sqrt{\frac{m}{\frac{5}{36}}}\right) - 1 \geq 0.95 \Rightarrow F^*\left(\frac{1}{120} \sqrt{\frac{m}{\frac{5}{36}}}\right) \geq 0.975$$

$$F^*(z) = 0.975 \Rightarrow z = 1.96 \Rightarrow \frac{1}{120} \sqrt{\frac{m}{\frac{5}{36}}} \geq 1.96,$$

$$m \geq \frac{(z_{\frac{1+\gamma}{2}})^2}{\varepsilon^2} \cdot p(1-p) = \frac{1.96^2}{(\frac{1}{120})^2} \cdot \frac{5}{36} = 7684 \Rightarrow m \geq 7684.$$

PRIMJER 10.11 Simetričnu kocku bacamo $m = 4500$ puta. U kojim granicama s vjerojatnošću $\gamma = 0.9$ treba očekivati relativne frekvencije pojavljivanja boja 6?

Rješenje:

X =broj pojavljivanja 6 u Bernoullijevoj shemi bacanja kocke,

$$X \sim B(m, p), m, p = \frac{1}{6}.$$

Treba odrediti a i b takve da za X =broj 6 u m bacanja $P(a < \frac{X}{m} < b) \geq 0.9$.

Koristimo Integralni Moivre-Laplaceov teorem za relativnu frekvenciju $\frac{X}{m}$

u Bernoullijevoj shemi $P\left(\left|\frac{X}{m} - p\right| < \varepsilon\right) \approx 2F^*\left(\varepsilon \sqrt{\frac{m}{p(1-p)}}\right) - 1$.

$$P\left(\left|\frac{X}{4500} - \frac{1}{6}\right| < \varepsilon\right) \approx 2F^*\left(\varepsilon \sqrt{\frac{4500}{\frac{1}{6}(1-\frac{1}{6})}}\right) - 1$$

Odstupanje ε čemo odrediti iz zadane vjerojatnosti γ i uvjeta

$$2F^*\left(\varepsilon \sqrt{\frac{4500}{\frac{5}{36}}}\right) - 1 \geq 0.9 \Rightarrow F^*\left(\varepsilon \sqrt{36 \cdot 900}\right) \geq 0.95.$$

$$F^*(z) = 0.9 \Rightarrow z = 1.65 \Rightarrow \varepsilon \sqrt{36 \cdot 900} \geq 1.65 \Rightarrow \varepsilon \geq 0.0091$$

10.3. CENTRALNI GRANIČNI TEOREM

Prema formuli $\varepsilon^2 \geq \frac{(z_{1+\gamma})^2}{m} \cdot p(1-p) = \frac{1.65^2}{4500} \cdot \frac{5}{36} = 7.566 \times 10^{-5}$

$$\varepsilon \geq \frac{1.65}{30} \cdot \frac{1}{6} = 9.1667 \times 10^{-3} \Rightarrow \varepsilon \geq 9.1667 \times 10^{-3}.$$

Odredili smo ε tako da $P(|\frac{X}{4500} - \frac{1}{6}| < 0.00916) \geq 0.9$.

$$\begin{aligned} |\frac{X}{4500} - \frac{1}{6}| &< 0.00916 \Rightarrow \frac{1}{6} - 0.00916 < \frac{X}{4500} < \frac{1}{6} + 0.00916 \\ &\Rightarrow 0.15751 < \frac{X}{4500} < 0.17583. \end{aligned}$$

Prisjetimo se motivacijskog primjera:

PRIMJER 10.12 *motiv*

Kontrolor uzima uzorak veličine $m = 1000$ iz skupa uređaja. Vjerovatnost da je uređaj neispravan je $p = 0.03$. U kojim granicama će biti broj neispravnih uređaja u uzorku s vjerovatnošću $\gamma = 0.99$

Rješenje:

Treba odrediti a i b takve da za $X =$ broj neispravnih uređaja u uzorku veličine m , $X \sim B(m, p)$, $P(a < X < b) \geq 0.99$.

Koristimo Integralni Moivre-Laplaceov teorem za relativnu frekvenciju $\frac{X}{m}$ u Bernoullijevoj shemi $P(|\frac{X}{m} - p| < \varepsilon) \approx 2F^*(\varepsilon \sqrt{\frac{m}{p(1-p)}}) - 1$,

$$P(|\frac{X}{1000} - 0.03| < \varepsilon) \approx 2F^*(\varepsilon \sqrt{\frac{1000}{0.03(1-0.03)}}) - 1.$$

Odstupanje ε ćemo odrediti iz zadane vjerovatnosti γ i uvjeta

$$2F^*(\varepsilon \sqrt{\frac{1000}{0.03(1-0.03)}}) - 1 \geq 0.99 \Rightarrow F^*(\varepsilon \sqrt{\frac{1000}{0.03(1-0.03)}}) \geq 0.995.$$

$$F^*(z) = 0.995 \Rightarrow z = 2.6 \Rightarrow \varepsilon \sqrt{\frac{1000}{0.03(1-0.03)}} \geq 2.6.$$

Prema formuli $\varepsilon^2 \geq \frac{(z_{1+\gamma})^2}{m} \cdot p(1-p) = \frac{2.6^2}{1000} \cdot 0.03 \cdot (1-0.03) = 1.9672 \times 10^{-4}$

$$\varepsilon \geq 0.014$$

Odredili smo ε tako da $P(|\frac{X}{1000} - 0.03| < 0.014) \geq 0.99$.

$$|\frac{X}{1000} - 0.03| < 0.014 \Rightarrow 16 < X < 44.$$

(Bernoullijev SZVB za rel. frekv. dao je ocjenu $0 < X < 80$.)

10.4 Ponovimo

ČEBIŠEVLJEVA NEJEDNAKOST

za svaki $\varepsilon > 0$	$P(X - E(X) \geq \varepsilon) \leq \frac{Var(X)}{\varepsilon^2},$
za svaki λ	$P(X - \mu \geq \lambda\sigma) \leq \frac{1}{\lambda^2},$

ZAKONI VELIKIH BROJAVA (ZVB)

ZVB za \bar{X}	$\lim_{n \rightarrow \infty} P(\bar{X} - \mu < \varepsilon) = 1,$
ZVB za $X \sim B(m, p)$	$\lim_{n \rightarrow \infty} P\left(\left \frac{\bar{X}}{m} - p\right < \varepsilon\right) = 1,$
Bernoull. slab ZVB	$P\left(\left \frac{\bar{X}}{m} - p\right < \varepsilon\right) \geq 1 - \frac{p(1-p)}{m \cdot \varepsilon^2}$

CENTRALNI GRANIČNI TEOREMI (CGT)

CGT za niz nez. sl, var. X_i	$n \rightarrow \infty,$
	$\frac{\sum_{i=1}^n X_i - n\mu}{\sqrt{n} \cdot \sigma} \sim N(0, 1)$
CTG za \bar{X}	$n \rightarrow \infty,$
	$\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$
CTG za $X \sim B(m, p), m \rightarrow \infty$	= Moivre-Laplace
$\frac{X - mp}{\sqrt{mp(1-p)}} \sim N(0, 1),$	$P(a < X < b) \approx F^*\left(\frac{b-mp}{\sqrt{mp(1-p)}}\right) - F^*\left(\frac{a-mp}{\sqrt{mp(1-p)}}\right)$
CGT za rel. frekv. od $X \sim B(m, p)$	= Moivre-Laplace za rel. frekv.
$\frac{\frac{X}{m} - p}{\sqrt{\frac{p(1-p)}{m}}} \sim N(0, 1),$	$P\left(\left \frac{\bar{X}}{m} - p\right < \varepsilon\right) \approx 2F^*\left(\varepsilon \sqrt{\frac{m}{p(1-p)}}\right) - 1$