

Matematika i statistika

Doktorski studij Strojarskog fakulteta

Sveučilište u Slavonskom Brodu

Predavanje 2

Predavač:

izv.prof.dr.sc. Nenad Šuvak, Odjel za matematiku, Sveučilište u Osijeku

SLUČAJNA VARIJABLA - MOTIVACIJA

- ▶ varijable modeliramo kao **slučajne varijable** - karakterizirane skupom vrijednosti kojima se mogu realizirati, no u trenutku mjerjenja njihove vrijednosti ne možemo sagledati sve uvjete pod kojima će se realizirati neka od tih vrijednosti
- ▶ osnova za proučavanja slučajnih varijabli - **skup svih mogućih realizacija** ili **slika** slučajne varijable, oznaka $\mathcal{R}(X)$
- ▶ promotrimo neki neprazan skup i označimo ga Ω (za Ω možemo uzeti skup svih mogućih vrijednosti slučajne varijable, tj. $\mathcal{R}(X)$)

SLUČAJNA VARIJABLA - VJEROJATNOST

- ▶ **događaj** - podskup nepraznog skupa Ω
- ▶ mogućnost realizacije događaja interpretiramo kao "stupanj vjerovanja u realizaciju tog događaja"
- ▶ **vjerojatnost** - mjera koja modelira stupanj vjerovanja da će se realizirati događaj $A \subset \Omega$
- ▶ od određenih podskupova skupa Ω formiramo familiju događaja \mathfrak{F} (mora sadržavati Ω , biti zatvorena na komplement i uniju)
- ▶ vjerojatnost (oznaka P) je funkcija koja svakom događaju $A \in \mathfrak{F}$ pridružuje realan broj iz intervala $[0, 1]$ tako da vrijede sljedeći zahtjevi:
 - ▶ $P(\Omega) = 1$
 - ▶ ako su A_1 i A_2 događaji iz \mathfrak{F} koji nemaju zajedničkih elemenata, tj. $A_1, A_2 \in \mathfrak{F}$ i $A_1 \cap A_2 = \emptyset$, tada je

$$P(A_1 \cup A_2) = P(A_1) + P(A_2)$$

SLUČAJNA VARIJABLA - ZADAVANJE

- ▶ $\mathcal{R}(X)$ - skup svih mogućih realizacija slučajne varijable X
- ▶ \mathfrak{F} - familija događaja, tj. familija podskupova od $\mathcal{R}(X)$ na kojoj je definirana vjerojatnost P
- ▶ događaj $A \in \mathfrak{F}$ će se dogoditi (realizirati) ako se slučajna varijabla X realizira vrijednošću iz skupa A
- ▶ slučajna varijabla X je zadana ako je zadan skup $\mathcal{R}(X)$ i vjerojatnost P na familiji događaja \mathfrak{F} - kažemo da smo zadali **razdiobu (distribuciju) slučajne varijable X**
- ▶ za određivanje vjerojatnosti koristimo jedan od dvaju standardnih pristupa - **klasični i statistički**

SLUČAJNA VARIJABLA - PRIMJER

- ▶ neka slučajna varijabla X opisuje rezultat bacanja pravilne igraće kockice
- ▶ svi mogući ishodi jednog bacanja čine skup Ω :

$$\Omega = \{1, 2, 3, 4, 5, 6\}$$

- ▶ kako je kockica pravilna, znamo da je

$$P(X = 1) = \dots = P(X = 6) = \frac{1}{6}$$

- ▶ distribuciju slučajne varijable X pregledno zapisujemo tablicom

$$X \sim \begin{pmatrix} 1 & 2 & 3 & 4 & 5 & 6 \\ 1/6 & 1/6 & 1/6 & 1/6 & 1/6 & 1/6 \end{pmatrix}$$

- ▶ ovdje smo zapravo iskorsitili klasični pristup određivanju vjerojatnosti

VJEROJATNOST - KLASIČNI PRISTUP

- ▶ neka vrijedi sljedeće:
 - (1) skup $\Omega \neq \emptyset$ ima konačno mnogo elemenata
 $(\Omega = \{\omega_1, \dots, \omega_n\}, n \in \mathbb{N})$
 - (2) svi jednočlani podskupovi od Ω su jednakovjerojatni, tj.

$$P(\{\omega_i\}) = P(\{\omega_j\}), \quad \text{za sve } i, j \in \{1, \dots, n\}$$

- ▶ tada vjerojatnost događaja A definiramo na sljedeći način:

$$P(A) = \frac{\text{broj elemenata od } A}{\text{broj elemenata od } \Omega} = \frac{k(A)}{k(\Omega)},$$

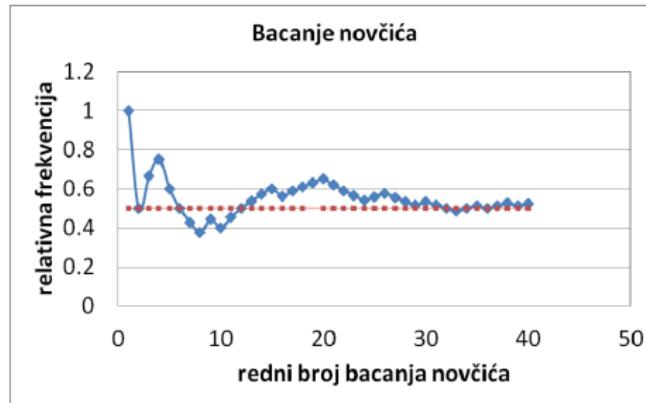
gdje je $k(\cdot)$ oznaka za broj elemenata skupa

- ▶ analogno za $\Omega = \mathcal{R}(X)$

VJEROJATNOST - STATISTIČKI PRISTUP

- ▶ temelji se na nezavisnom ponavljanju pokusa - činjenica da se neki događaj realizirao pri izvođenju pokusa nikako ne utječe na realizaciju bilo kojeg ishoda narednih izvođenja tog pokusa
- ▶ npr. bacanje igraće kockice dva puta čini dva nezavisna pokusa, ali izvlačenje drugog broja u igri loto pokus je koji nije nezavisno od izvlačenja prvog broja u toj igri
- ▶ ako je pokus takav da ga možemo nezavisno ponavljati mnogo puta, relativna frekvencija pojavljivanja događaja A će se s povećanjem broja ponavljanja pokusa stabilizirati oko nekog broja koji predstavlja statistički definiranu vjerojatnost realizacije tog događaja

VJEROJATNOST - STATISTIČKI PRISTUP



Grafički prikaz relativnih frekvencija pojavljivanja pisma za 40 bacanja pravilnog novčića

SLUČAJNA VARIJABLA - TIPOVI

- ▶ prije smo uočili bitnu razliku u opisu diskretnih i neprekidnih numeričkih varijabli
- ▶ iste razlike vidljive su u načinu zadavanja slučajnih varijabli kojima modeliramo diskrete i neprekidne numeričke varijable
- ▶ razlikovat ćemo dva tipa slučajnih varijabli:
 - ▶ diskretne
 - ▶ neprekidne

DISKRETKA SLUČAJNA VARIJABLA - ZADAVANJE

- ▶ ako je $\mathcal{R}(X)$ konačan ili prebrojiv skup kažemo da je slučajna varijabla X diskretna
- ▶ konačan $\mathcal{R}(X) = \{x_1, x_2, x_3, \dots, x_n\}$
- ▶ prebrojiv $\mathcal{R}(X) = \{x_1, x_2, x_3, \dots\}$
- ▶ za svaku pojedinu realizaciju x_i definiramo vjerojatnost $p_i = P\{X = x_i\}$
- ▶ DSV X je u potpunosti zadana skupom $\mathcal{R}(X)$ i pripadnim vjerojatnostima $p_i = P\{X = x_i\}$ za koje vrijede sljedeća svojstva:
 1. $p_i \geq 0$ za sve $x_i \in \mathcal{R}(X)$
 2. $\sum_{\text{svim } x_i \in \mathcal{R}(X)} p_i = 1$
- ▶ računanje vjerojatnosti da diskretna slučajna varijabla X primi vrijednosti iz nekog skupa $A \subseteq \mathcal{R}(X)$:

$$P(X \in A) = \sum_{x_i \in A} p_i$$

DISKRETKA SLUČAJNA VARIJABLA - TABLICA DISTRIBUCIJE

- distribucija DSV pregledno se zadaje **tablicom distribucije**:

$$X \sim \begin{pmatrix} x_1 & x_2 & \dots & x_n \\ p_1 & p_2 & \dots & p_n \end{pmatrix} \quad \text{tj.} \quad X \sim \begin{pmatrix} x_1 & x_2 & x_3 & \dots \\ p_1 & p_2 & p_3 & \dots \end{pmatrix}$$

- prva tablica odnosi se na DSV s konačnim skupom $\mathcal{R}(X)$, a druga na DSV s prebrojivim skupom $\mathcal{R}(X)$
- slučajna varijabla jednosznačno je zadana svojom distribucijom - često umjesto o slučajnim varijablama govorimo o distribucijama

DISKRETNE DISTRIBUCIJE - BERNOULLIJEVA I BINOMNA DISTRIBUCIJA

- ▶ Bernoullijeva distribucija - modelira (opisuje) rezultat pokusa koji ima samo dva moguća ishoda, uspjeh (oznaka 1) i neuspjeh (oznaka 0):

$$X \sim \begin{pmatrix} 0 & 1 \\ 1-p & p \end{pmatrix}, \quad p \in (0, 1)$$

- ▶ parametar $p \in (0, 1)$ je vjerojatnost da se X realizira vrijednošću 1
- ▶ binomna $\mathcal{B}(n, p)$ distribucija - služi za modeliranje broja realiziranih uspjeha (oznaka 1) pri n nezavisnih ponavljanja pokusa sa samo dva moguća ishoda, pri čemu se uspjeh u jednom izvođenju pokusa realizira s vjerojatnošću $p \in (0, 1)$

DISKRETNE DISTRIBUCIJE - PRIMJERI

Primjer

Ako imamo jako preciznu vagu i mjerimo masu šećera koji je pakiran u vrećice deklarirane mase 1 kg, hoćemo li dobiti točno 1 kg? Ako uzmemmo drugo pakiranje istog tipa, koliko vam se čini izvjesno da će masa biti ista kao u prethodno vaganom pakiranju? Očekujete li velika odstupanja? Ako masu šećera u toj seriji pakiranja modeliramo slučajnom varijablom X , koji biste skup uzeli za skup $\mathcal{R}(X)$?

Primjer

Poznato je da je u velikom skladištu trgovine informatičkom opremom vjerojatnost pojavljivanja prijenosnog računala s greškom nastalom u proizvodnji jednaka 0.02. Prepostavimo da iz tog skladišta nasumično biramo 10 prijenosnih računala. Poslodavca zanima je li manje od pet prijenosnih računala koje smo izabrali s greškom. Koju distribuciju i s kojim parametrima smatraste prikladnom za opis ovog problema? (R - primjer 1)

NEPREKIDNE DISTRIBUCIJE - MOTIVACIJA I DEFINICIJA

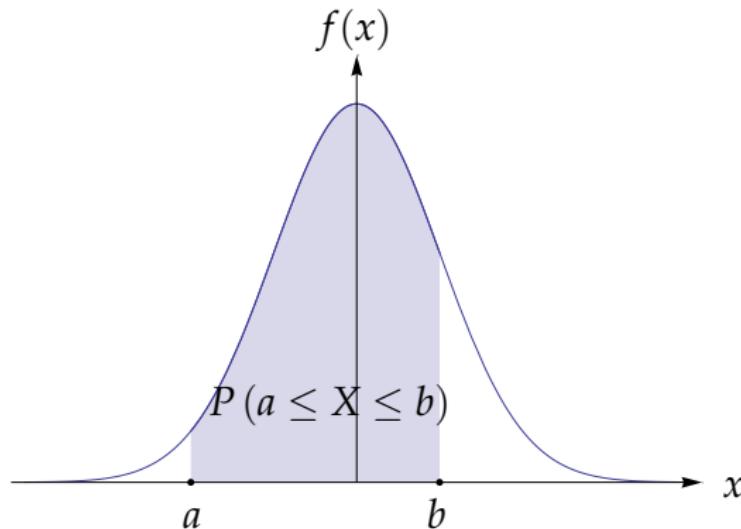
- ▶ model za **neprekidnu numeričku varijablu** je slučajna varijabla za koju je $\mathcal{R}(X)$ interval realnih brojeva ili je $\mathcal{R}(X) = \mathbb{R}$
- ▶ za slučajnu varijablu X kažemo da je **neprekidna** ako postoji funkcija $f: \mathbb{R} \rightarrow [0, \infty)$ takva da je vjerojatnost

$$P(a \leq X \leq b) = P(a < X \leq b)$$

jednaka površini između x -osi i grafa funkcije f nad intervalom $[a, b]$ (slika na sljedećem slide-u)

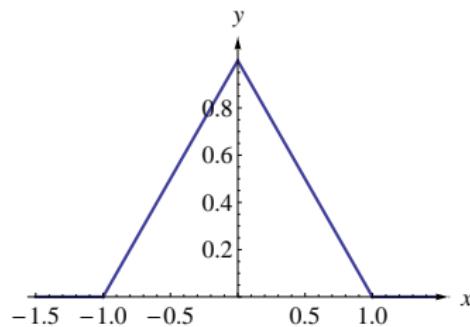
- ▶ takvu funkciju f zovemo **funkcija gustoće** NSV X
- ▶ NSV je zadana ako je poznata njena funkcija gustoće - tada kažemo da poznajemo **razdiobu** ili **distribuciju** NSV

NEPREKIDNE DISTRIBUCIJE - RAČUNANJE VJEROJATNOSTI



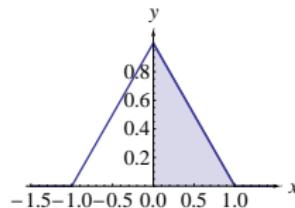
Vjerojatnost kao površina između x -osi i grafa funkcije f nad intervalom $[a, b]$

NEPREKIDNE DISTRIBUCIJE - RAČUNANJE VJEROJATNOSTI

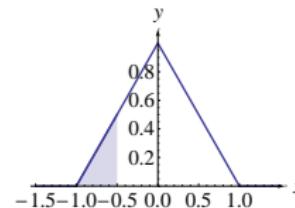


Graf funkcije gustoće jedne neprekidne distribucije

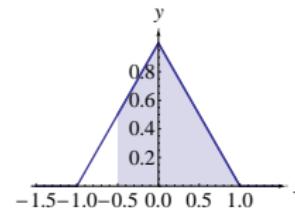
NEPREKIDNE DISTRIBUCIJE - RAČUNANJE VJEROJATNOSTI



$$(a) P(X \in (0, 1)) = \frac{1}{2}$$



$$(b) P(X \in (-1, -\frac{1}{2})) = \frac{1}{8}$$



$$(c) P(X \in (-\frac{1}{2}, 1)) = \frac{7}{8}$$

Računanjem površine ispod grafa funkcije gustoće slučajne varijable X određujemo vjerojatnost da se X realizira realnim brojem iz zadanog intervala

NORMALNA DISTRIBUCIJA

- ▶ normalna $X \sim \mathcal{N}(\mu, \sigma^2)$ distribucija je neprekidna distribucija za koju je

$$\mathcal{R}(X) = \mathbb{R},$$

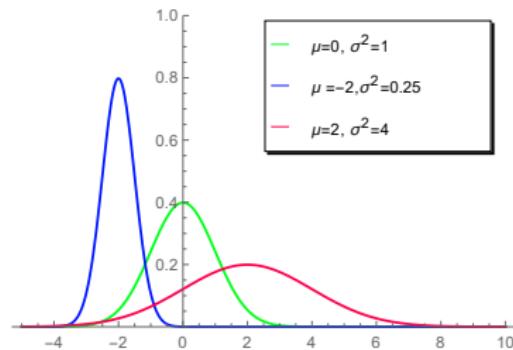
a funkcija gustoće definirana je izrazom

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad x \in \mathbb{R},$$

$\mu \in \mathbb{R}$ i $\sigma > 0$ zovemo parametrima te distribucije

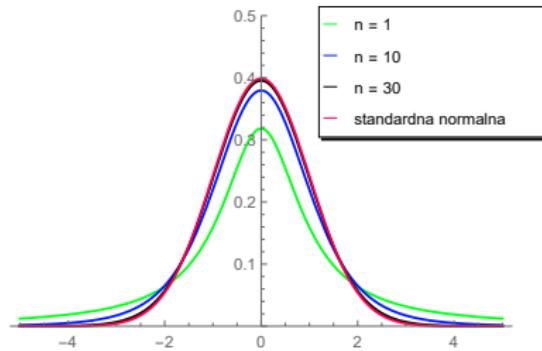
- ▶ $\mu = 0, \sigma^2 = 1$ - **standardna normalna distribucija**
- ▶ graf funkcije gustoće normalne distribucije ovisi o izboru parametara μ i σ^2 (slika na sljedećem slide-u)

NORMALNA DISTRIBUCIJA



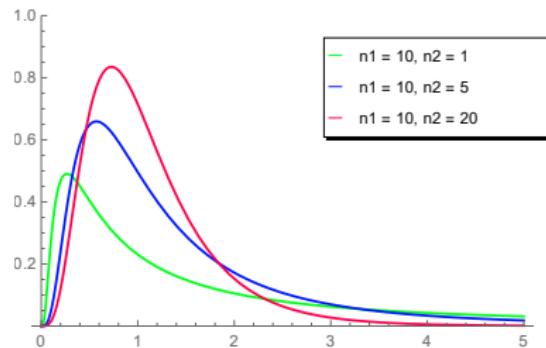
Graf funkcije gustoće normalne distribucije za različite μ and σ^2

STUDENTOVA DISTRIBUCIJA



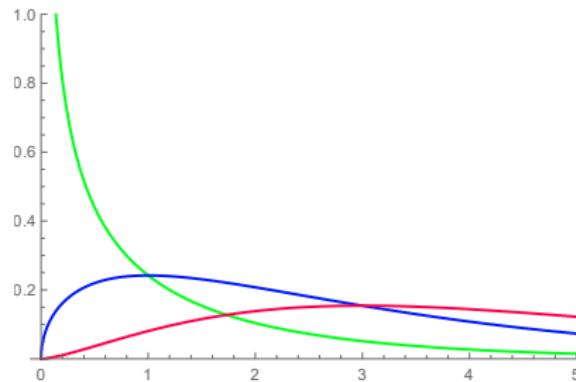
Graf funkcije gustoće Studentove distribucije za različite vrijednosti parametra

FISHEROVA ILI F DISTRIBUCIJA



Graf funkcije gustoće F distribucije za različite vrijednosti parametara

χ^2 DISTRIBUCIJA



Graf funkcije gustoće studentove distribucije za različite vrijednosti parametra ($n = 1, 3, 5$)

MJERE SREDINE - MEDIJAN

- **medijan** slučajne varijable X je realan broj m za kojega vrijedi da je

$$P(X \geq m) \geq \frac{1}{2} \quad \text{i} \quad P(X \leq m) \geq \frac{1}{2}$$

- medijan je također jedna mjera sredine
- ne mora biti jedinstven

MJERE SREDINE I RASPRŠENOSTI DSV

- **diskretna slučajna varijabla X** - ako postoji, **očekivanje** je realan broj

$$\mu = EX = \sum_{\text{svim } x_i \in \mathcal{R}(X)} x_i p_i,$$

a **varijanca** realan broj

$$\sigma^2 = Var X = \sum_{\text{svim } x_i \in \mathcal{R}(X)} (x_i - \mu)^2 p_i$$

- očekivanje - mjera sredine
- varijanca i standardna devijacija - mjere raspršenja vrijednosti slučajne varijable oko očekivanja

MJERE SREDINE I RASPRŠENOSTI NSV

- ▶ **neprekidna slučajna varijabla X** - ograničit ćemo se na normalnu slučajnu varijablu za koju je

$$EX = \mu, \quad Var X = \sigma^2$$

- ▶ **standardna devijacija σ** - kvadratni korijen iz varijance

ČEBIŠEVLJEVA NEJEDNAKOST

- ▶ neka je X slučajna varijabla s očekivanjem μ i standardnom devijacijom σ
- ▶ tada za svaki prirodan broj k vrijedi:

$$P\{|X - \mu| \geq k\sigma\} \leq \frac{1}{k^2}, \text{ tj.}$$

$$P\{|X - \mu| < k\sigma\} \geq 1 - \frac{1}{k^2}$$

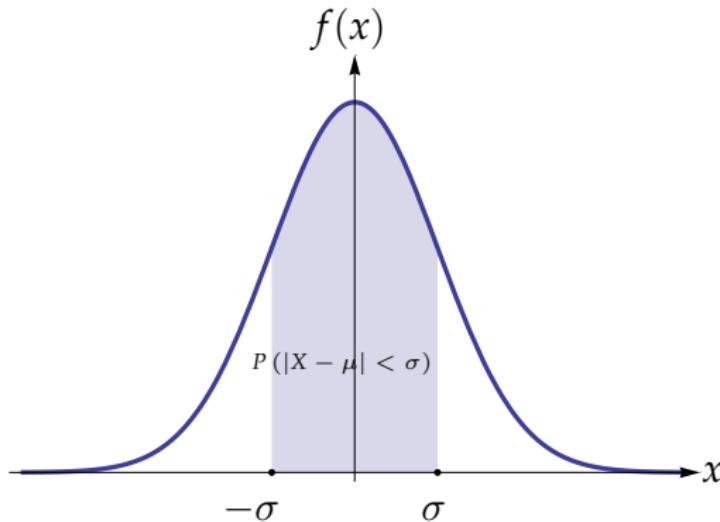
ČEBIŠEVLJEVA NEJEDNAKOST - INTERPRETACIJA

sljedeće tvrdnje vrijede za sve slučajne varijable koje imaju varijancu:

- ▶ vjerojatnost da se slučajna varijabla realizira vrijednostima koje su od očekivanja μ udaljene više ili jednako $k\sigma$ manja je ili jednaka $1/k^2$
- ▶ vjerojatnost da se slučajna varijabla realizira vrijednostima koje su od očekivanja μ udaljene manje od $k\sigma$ veća je od $1 - 1/k^2$
- ▶ uvrštavajući $k = 3$ vidimo da realizacija slučajne varijable upada u interval $(\mu - 3\sigma, \mu + 3\sigma)$ s vjerojatnošću većom od 0.88 (≈ 0.9)
- ▶ to praktično znači da se više od 88% realizacija slučajne varijable X nalazi u intervalu $(\mu - 3\sigma, \mu + 3\sigma)$

ČEBIŠEVLJEVA NEJEDNAKOST - GEOMETRIJSKA INTERPRETACIJA

$P(|X - \mu| < k\sigma)$ za $k = 1$ za standardnu normalnu slučajnu varijablu X

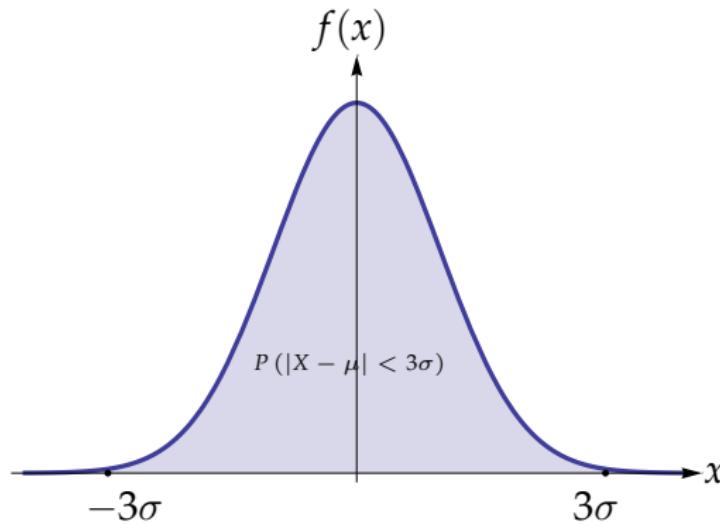


prema Čebiševljevoj nejednakosti je

$$P(|X - \mu| < \sigma) = P(X \in (\mu - \sigma, \mu + \sigma)) \geq 0$$

ČEBIŠEVLJEVA NEJEDNAKOST - GEOMETRIJSKA INTERPRETACIJA

$P(|X - \mu| < k\sigma)$ za $k = 3$ za standardnu normalnu slučajnu varijablu X



prema Čebiševljevoj nejednakosti je

$$P(|X - \mu| < 3\sigma) = P(X \in (\mu - 3\sigma, \mu + 3\sigma)) \geq \frac{8}{9}$$

NORMALNA DISTRIBUCIJA - PRIMJER

IZRAČUNAVANJA VJEROJATNOSTI

Primjer

Slučajna varijabla Z ima standardnu normalnu distribuciju, $Z \sim \mathcal{N}(0, 1)$. Pomoću R-a odredimo sljedeće vjerojatnosti (R - primjer 2):

1. $P(\mu - \sigma < Z < \mu + \sigma) = 0.68$
2. $P(\mu - 2\sigma < Z < \mu + 2\sigma) = 0.95$
3. $P(\mu - 3\sigma < Z < \mu + 3\sigma) = 0.9972$
4. $P(-0.5 \leq Z \leq 1.1) = 0.555796$
5. $P(-0.38 \leq Z \leq 1.72) = 0.605311$
6. $P(Z \geq 1.6) = 0.054799$
7. $P(Z \leq -1.8) = 0.035930$

PROBLEM PROCJENE

- ▶ **obilježja** obuhvaćena istraživanjem nazivamo **varijablama** - na razini populacije modeliramo ih **slučajnim varijablama**
- ▶ **vrijednosti varijable izmjerene na uzorku** (stupac baze podataka) - **nezavisne realizacije slučajne varijable**
- ▶ slučajna varijabla - u potpunosti zadana svojom **distribucijom**
- ▶ distribucija omogućuje izračunavanje **vjerojatnosti** vezanih uz realizacije slučajne varijable i njezinih **numeričkih karakteristika** (očekivanje, varijanca, standardna devijacija i sl.)
- ▶ **nepoznata distribucija** slučajne varijable - problem!

PROBLEM PROCJENE

- ▶ X - slučajna varijabla kojom modeliramo neko obilježje
- ▶ x - podatak, tj. vrijednost promatranog obilježja za jedinku iz uzorka, tj. jedna realizacija slučajne varijable X
- ▶ na uzorku koji se sastoji od n jedinki izmjerimo/zabilježimo n podataka x_1, \dots, x_n - svaki podatak x_i jedna je realizacija slučajne varijable X_i koja ima istu distribuciju kao slučajna varijabla X
- ▶ postupak prikupljanja podataka na uzorku mora biti takav da su mjerena međusobno nezavisna
- ▶ podaci (x_1, \dots, x_n) - realizacija n -torke slučajnih varijabli (X_1, \dots, X_n) koje su međusobno nezavisne i imaju istu distribuciju kao slučajna varijabla X
- ▶ (X_1, \dots, X_n) - **jednostavni slučajni uzorak (JSU)**
- ▶ (x_1, \dots, x_n) - realizacija JSU, zovemo ju samo **uzorak**

PROCJENA DISTRIBUCIJE DISKRETNE SLUČAJNE VARIJABLE

- ▶ **empirijska distribucija slučajne varijable** - procjena distribucije DSV
- ▶ npr. za DSV X sa slikom $\mathcal{R}(X) = \{y_1, \dots, y_m\}$ i nepoznatim vjerojatnostima $p_i = P(X = y_i)$ empirijska distribucija je dana tablicom

$$\begin{pmatrix} y_1 & y_2 & \dots & y_m \\ f_1/n & f_2/n & \dots & f_m/n \end{pmatrix},$$

gdje je n dimenzija uzorka, a f_i frekvencija pojavljivanja podatka/vrijednosti y_i u uzorku (x_1, \dots, x_n)

- ▶ veći broj podataka - opravdanije korištenje empirijske distribucije, u skladu sa statističkim pristupom modeliranju vjerojatnosti

PROCJENA DISTRIBUCIJE OPĆENITO

- ▶ empirijska distribucija slučajne varijable temeljena na uzorku (podacima) uvijek je diskretna
- ▶ temeljem poznavanja svojstava varijable koju proučavamo često možemo unaprijed odrediti tip neprekidne distribucije koju je opravdano koristiti za njezino modeliranje

PROCJENA OČEKIVANJA

- ▶ problem procjene očekivanja slučajne varijable X na temelju realizacije, tj. podataka, (x_1, \dots, x_n) jednostavnog slučajnog uzorka (X_1, \dots, X_n)
 - ▶ procjenitelj - aritmetička sredina JSU (X_1, \dots, X_n)

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

- ▶ procjena - aritmetička sredina uzorka (podataka) (x_1, \dots, x_n)

$$\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$$

- ▶ procjenitelj \bar{X}_n je slučajna varijabla s nekom distribucijom
- ▶ procjena \bar{x}_n je realan broj - realizacija procjenitelja \bar{X}_n

PROCJENA VARIJANCE

- ▶ problem procjene varijance slučajne varijable X na temelju realizacije, tj. podataka, (x_1, \dots, x_n) jednostavnog slučajnog uzorka (X_1, \dots, X_n)
 - ▶ procjenitelj - korigirana varijanca JSU (X_1, \dots, X_n)

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

- ▶ procjena - korigirana varijanca uzorka (podataka) (x_1, \dots, x_n)

$$s_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$$

- ▶ procjenitelj S_n^2 je slučajna varijabla s nekom distribucijom
- ▶ procjena s_n^2 je realan broj - realizacija procjenitelja S_n^2

INTERVALNA PROCJENA

- ▶ pri procjeni očekivanja i varijance jednim brojem treba uzeti u obzir slučajni karakter procjene - radi se o realizaciji slučajnih varijabli \bar{X}_n i S_n^2
- ▶ **intervalna procjena** - procjena parametra **intervalom unaprijed izabrane pouzdanosti γ** u kojemu se stvarna, nama nepoznata vrijednost parametra, nalazi s vjerojatnošću $100\gamma\%$
- ▶ **interval izabrane pouzdanosti γ** - interval koji ima slučajne varijable kao granice i određen je temeljem zahtjeva da se stvarna vrijednost parametra kojeg procjenjujemo nalazi u takvom, slučajnom, intervalu s vjerojatnošću barem γ
- ▶ npr. 95%-tni pouzdani interval - interval pouzdanosti $\gamma = 0.95$; s vjerojatnošću 0.95 sadrži stvarnu vrijednost nepoznatog parametra
- ▶ izračunavanje granica intervala pouzdanosti γ - na temelju podataka (x_1, \dots, x_n) izračunavamo običan interval s realnim brojevima kao granicama, koji u $100\gamma\%$ slučajeva sadrži stvarnu vrijednost karakteristike koju procjenjujemo ([simulacija u R-u](#))

INTERVALNA PROCJENA OČEKIVANJA

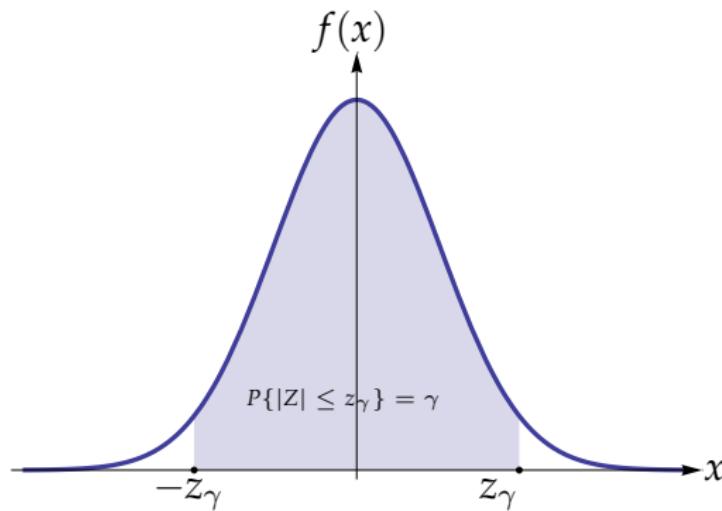
- ▶ \bar{X}_n - aritmetička sredina JSU (X_1, \dots, X_n) velike dimenzije n iz distribucije slučajne varijable X s nepoznatim očekivanjem μ i poznatom varijancom σ^2
- ▶ aritmetička sredina \bar{X}_n za veliki n ima približno normalnu distribuciju s očekivanjem μ i varijancom $\frac{\sigma^2}{n}$
- ▶ slučajna varijabla

$$Z' = \frac{\bar{X}_n - E\bar{X}_n}{\sqrt{Var(\bar{X}_n)}} = \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n}$$

ima **približno standardnu normalnu distribuciju** $\mathcal{N}(0, 1)$

- ▶ standardnu normalnu distribuciju označimo $Z \sim \mathcal{N}(0, 1)$
- ▶ neka je z_γ broj za koji vrijedi $P\{|Z| \leq z_\gamma\} = \gamma$
- ▶ vrijednost γ predstavljaju površinu ispod grafa funkcije gustoće standardne normalne distribucije nad intervalom $[-z_\gamma, z_\gamma]$

INTERVALNA PROCJENA OČEKIVANJA



vjerojatnost $P\{|Z| \leq z_\gamma\}$

INTERVALNA PROCJENA OČEKIVANJA

- ▶ uvrštavanjem izraza $Z' = \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n}$ u izraz $P\{|Z| \leq z_\gamma\}$ umjesto Z slijedi:

$$P\{|Z'| \leq z_\gamma\} = P\{-z_\gamma \leq Z' \leq z_\gamma\} =$$

$$= P\left\{-z_\gamma \leq \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n} \leq z_\gamma\right\} =$$

$$= P\left\{\bar{X}_n - z_\gamma \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X}_n + z_\gamma \frac{\sigma}{\sqrt{n}}\right\}$$

- ▶ slijedi da je

$$P\left\{\mu \in \left[\bar{X}_n - z_\gamma \frac{\sigma}{\sqrt{n}}, \bar{X}_n + z_\gamma \frac{\sigma}{\sqrt{n}}\right]\right\} \approx \gamma$$

- ▶ za velike uzorke procjenjujemo σ korijenom korigirane varijance uzorka, tj. brojem s_n

INTERVALNA PROCJENA OČEKIVANJA

ako je (x_1, \dots, x_n) realizacija JSU iz distribucije slučajne varijable X i $\gamma \in (0, 1)$, onda će u približno $100\gamma\%$ slučajeva interval izračunat po formuli

$$\left[\bar{x}_n - z_\gamma \frac{\sigma}{\sqrt{n}}, \bar{x}_n + z_\gamma \frac{\sigma}{\sqrt{n}} \right]$$

\bar{x}_n - aritmetička sredina uzorka (x_1, \dots, x_n)

σ - poznata standardna devijacija slučajne varijable X

z_γ - broj za koji vrijedi da je $P\{|Z| \leq z_\gamma\} = \gamma$

Z - standardna normalna slučajna varijabla

sadržavati stvarnu (nepoznatu) vrijednost očekivanja μ slučajne varijable X

R - primjeri 3 i 4

STATISTIČKE HIPOTEZE

- ▶ **statistička hipoteza \mathcal{H}** - prepostavka vezana uz distribuciju slučajne varijable kojom modeliramo neko obilježje populacije
- ▶ **testirati hipotezu** znači donijeti odluku o tome hoćemo li \mathcal{H} odbaciti ili ne
- ▶ zbog toga često govorimo o testiranju dvije hipoteze - **nul-hipoteze \mathcal{H}_0** i **alternativne hipoteze \mathcal{H}_1**
- ▶ **\mathcal{H}_1 prihvaćamo u slučaju odbacivanja \mathcal{H}_0**
- ▶ **nul-hipotezu \mathcal{H}_0 nikada ne možemo prihvatiti** jer se odlučivanje u statističkom testu provodi uz toleranciju malih vjerojatnosti pogrešne odluke

STATISTIČKE HIPOTEZE

- ▶ **odлука donesena temeljem statističkog testa može biti ili pogrešna ili ispravna**
- ▶ tipovi pogrešne odluke:
 - ▶ **pogreška I. tipa: odbaciti \mathcal{H}_0 ako je ona istinita**
 - ▶ **pogreška II. tipa: ne odbaciti \mathcal{H}_0 ako je \mathcal{H}_1 istinita**
- ▶ statistički test se dizajnira tako da dopušta izbor maksimalne vjerojatnosti pogreške prvog tipa (npr. 0.01, 0.05 ili 0.1)
- ▶ α - odabrana maksimalna vjerojatnost pogreške prvog tipa zove se **razina značajnosti statističkog testa**

TESTIRANJE HIPOTEZE O OČEKIVANJU - T -TEST

- ▶ hipoteze:

$$\mathcal{H}_0 : \mu = \mu_0$$

$$\mathcal{H}_1 : \mu > \mu_0 \text{ ili } \mathcal{H}_1 : \mu < \mu_0$$

- ▶ vrijednost test-statistika:

$$\hat{t} = \frac{\bar{x}_n - \mu_0}{s_n / \sqrt{n}},$$

gdje je n dimenzija uzorka, \bar{x}_n aritmetička sredina uzorka, a s_n standardna devijacija uzorka

- ▶ p -vrijednost testa:
 - ▶ $p = P\{T \geq \hat{t}\}$ ako je $\mathcal{H}_1 : \mu > \mu_0$
 - ▶ $p = P\{T \leq \hat{t}\}$ ako je $\mathcal{H}_1 : \mu < \mu_0$
- ▶ slučajna varijabla T ima Studentovu distribuciju s $(n - 1)$ stupnjeva slobode

TESTIRANJE HIPOTEZA O OČEKIVANJU - T -TEST

- ▶ p -vrijednost uspoređujemo s razinom značajnosti α :
 - ▶ ako je $p < \alpha$ odbacujemo \mathcal{H}_0 na razini značajnosti α i prihvaćamo \mathcal{H}_1
 - ▶ ako je $p > \alpha$ zaključujemo da nemamo dovoljno informacija koje bi poduprle odluku o odbacivanju \mathcal{H}_0
- ▶ ovaj test adekvatan je za male uzorke iz normalne distribucije ($n < 30$) te za velike uzorke iz nespecificirane distribucije s očekivanjem μ i varijancom σ^2
- ▶ R - primjeri 5 i 6

TESTIRANJE HIPOTEZA O VJEROJATNOSTI - BINOMNI TEST

- ▶ hipoteze:

$$\mathcal{H}_0 : p = p_0$$

$$\mathcal{H}_1 : p > p_0 \text{ ili } \mathcal{H}_1 : p < p_0$$

- ▶ iz podataka znamo broj realizacija događaja o čijoj vjerojatnosti zaključujemo - frekvencija uspjeha f_1
- ▶ pomoću f_1 procjenjujemo nepoznatu vjerojatnost tog događaja p relativnom frekvencijom (proporcijom) $\hat{p} = f_1/n$
- ▶ p -vrijednost testa
 - ▶ $p = P(B \geq f_1)$ ako je $\mathcal{H}_1 : p > p_0$
 - ▶ $p = P(B \leq f_1)$ ako je $\mathcal{H}_1 : p < p_0$
- ▶ $B \sim \mathcal{B}(n, p_0)$
- ▶ odluku donosimo usporedbom p -vrijednosti s razinom značajnosti α
- ▶ **R - primjeri 7 i 8**

TESTIRANJE HIPOTEZA O DISTRIBUCIJI - χ^2 TEST

- ▶ X slučajna varijabla s (nepoznatom) teorijskom distribucijom:

$$X \sim \begin{pmatrix} y_1 & y_2 & \dots & y_m \\ p_1 & p_2 & \dots & p_m \end{pmatrix}.$$

- ▶ testiranje hipoteze da podaci (x_1, \dots, x_n) dolaze iz distribucije slučajne varijable X zadane gornjom tablicom može se provesti χ^2 -testom:

\mathcal{H}_0 : distribucija iz koje dolaze podaci jednaka je teorijskoj
 \mathcal{H}_1 : distribucija iz koje dolaze podaci razlikuje se od teorijske

TESTIRANJE HIPOTEZA O DISTRIBUCIJI - χ^2 TEST

- ▶ vrijednost test-statistike

$$\hat{d} = \sum_{i=1}^m \frac{(np_i - f_i)^2}{np_i}$$

temeljena na odstupanju stvarnih frekvencija podataka $(f_i, i = 1, \dots, m)$ od teorijskih frekvencija $(np_i, i = 1, \dots, m)$

- ▶ p -vrijednost - $p \approx P(D > \hat{d})$
- ▶ ako je \mathcal{H}_0 istinita, za velike n slučajna varijabla D ima približno $\chi^2(m - 1)$ distribuciju
- ▶ korištenje χ^2 testa - prikladno ako su sve teorijske frekvencije veće od 5
- ▶ **R - primjer 9**

TESTIRANJE NORMALNOSTI OBILJEŽJA

- ▶ statističke hipoteze:

\mathcal{H}_0 : varijabla X ima normalnu distribuciju

\mathcal{H}_1 : varijabla X nema normalnu distribuciju,

- ▶ dva testa koji se mogu koristiti za testiranje hipoteze o normalnosti:
 - ▶ Lillieforsova inačica Kolmogorov-Smirnovljevog testa
 - ▶ Shapiro-Wilkov W test
- ▶ R - primjeri 10 i 11

LITERATURA

- ▶ Benšić, M. i Šuvak, N., *Primijenjena statistika*, Odjel za matematiku, Sveučilište J.J. Strossmayera, Osijek, 2013.
- ▶ Benšić, M. i Šuvak, N., *Uvod u vjerojatnost i statistiku*, Odjel za matematiku, Sveučilište J.J. Strossmayera, Osijek, 2014.