

# Primijenjena i inženjerska matematika

Statistika - predavanje 4

*Statističko zaključivanje - jedna varijabla*

3.11.2023.





## Varijable baze podataka i slučajne varijable

- varijabla baze podataka – sadrži **vrijednosti obilježja** promatranog na jedinkama neke populacije obuhvaćenim nekim istraživanjem (stupac baze podataka)
- slučajna varijabla – model za **obilježje cijele populacije**
- jedna varijabla baze podataka sadrži podatke  $x_1, \dots, x_n$  – **uzorak**
- **svaki podatak iz varijable baze podataka je realizacija jedne slučajne varijable**



## Varijable baze podataka i slučajne varijable

varijabla baze podataka	slučajne varijable
$x_1$	$\leftarrow X_1$
$x_2$	$\leftarrow X_2$
$\vdots$	$\vdots$
$x_n$	$\leftarrow X_n$

- niz slučajnih varijabli  $X_1, \dots, X_n$  nazivamo **slučajni uzorak**



## Varijable baze podataka i slučajne varijable

- podaci varijable baze podataka  $x_1, \dots, x_n$  dolaze iz iste populacije
- zato pretpostavljamo da su  $X_1, \dots, X_n$  sve **jednako distribuirane** i to kao neka slučajna varijabla  $X$ :

$$P(X_1 \in C) = P(X_2 \in C) = \dots = P(X_n \in C) = P(X \in C)$$

za sve događaje  $C$

- $X$  modelira obilježje u cijeloj populaciji



## Varijable baze podataka i slučajne varijable

- postupak prikupljanja podataka mora biti takav da su mjerenja međusobno nezavisna –  $X_1, \dots, X_n$  nezavisne slučajne varijable
- **jednostavan slučajni uzorak** –  $X_1, \dots, X_n$  nezavisne slučajne varijable i jednako distribuirane kao  $X$  (kraće ćemo govoriti samo slučajni uzorak)
- u tom smislu **varijabla baze podataka (uzorak) dolazi iz slučajne varijable  $X$**



## Statističko zaključivanje

- distribucija slučajne varijable  $X$  je nepoznata – ne možemo računati  $P(X \in C)$
- **statističko zaključivanje** – na osnovu podataka želimo zaključivati o distribuciji slučajne varijable  $X$

$x_1, \dots, x_n$        $\dashrightarrow$       distribucija od  $X$

- na osnovu podataka možemo **procijeniti** distribuciju slučajne varijable  $X$ , a onda procijeniti i vjerojatnosti oblika  $P(X \in C)$
- osim distribucije mogu nas zanimati i neke numeričke karakteristike slučajne varijable  $X$  (npr. očekivanje i varijanca) koje su također nepoznate



# Procjena distribucije, očekivanja i varijance

## Procjena distribucije

- procijeniti distribuciju znači procijeniti vjerojatnosti oblika  $P(X \in [a, b])$  za  $a, b \in \mathbb{R}$
- empirijskom distribucijom možemo procijeniti  $P(X \in [a, b])$
- veći broj podataka – opravdanije korištenje empirijske distribucije za računanje vjerojatnosti
- **empirijska distribucija** je **procjena** za nepoznatu distribuciju slučajne varijable  $X$
- nedostatak: empirijska distribucija uvijek je diskretna
- nekad distribuciju (npr. normalnu) možemo naslutiti iz histograma podataka



# Procjena distribucije, očekivanja i varijance

## Procjena očekivanja

- za procjenu očekivanja koristimo aritmetičku sredinu uzorka

$x_1, x_2, \dots, x_n$

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

## Procjena varijance

- za procjenu varijance koristimo korigiranu varijancu uzorka

$x_1, x_2, \dots, x_n$

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

primjer 5.1, primjer 5.2





## Procjenitelj

- uzorak  $x_1, \dots, x_n$  je realizacija slučajnog uzorka  $X_1, \dots, X_n$
- procjenu neke numeričke karakteristike slučajne varijable  $X$  računamo na osnovu uzorka  $x_1, \dots, x_n$  — tako je i procjena realizacija slučajne varijable koju nazivamo **procjenitelj**
- na konkretnoj realizaciji procjenitelj poprima jednu vrijednost
- procjenitelj za očekivanje je slučajna varijabla

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

- procjenitelj za varijancu je slučajna varijabla

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

- primjer 5.3





## Pouzdaní intervali

- nepoznatu numeričku karakteristiku procjenjujemo brojem – ne daje informaciju o pouzdanosti takve procjene (ne uzima u obzir raspršenost)
- Primjer: neka su zadana tri uzroka
  - $0, 0, -1, 1$
  - $-200, 100, 200, -100$
  - $0, 0, -1, 1, 0, -1, 1$

Procjena očekivanja je 0 u sva tri slučaja, no u kojem slučaju je *pouzdanija*?



## Pouzdanost intervali

- procjenu možemo napraviti i intervalom – procjenjujemo interval koji sadrži nepoznatu numeričku karakteristiku
- odaberemo  $\gamma \in (0, 1)$ , npr.  $\gamma = 0.95$  ili  $\gamma = 0.99$  – **pouzdanost**
- $\gamma$ -**pouzdanost interval** (ili interval pouzdanosti  $\gamma$ ) je slučajan interval (granice su mu slučajne varijable) takav da se stvarna vrijednost numeričke karakteristike koju procjenjujemo nalazi u takvom intervalu s vjerojatnošću barem  $\gamma$
- jedna **realizacija pouzdanog intervala** određena na osnovu prikupljenog uzorka je običan interval realnih brojeva




## Pouzdaní interval

- na osnovu podataka i formula za određivanje granica intervala pouzdanosti  $\gamma$  izračunavamo običan interval s realnim brojevima kao granicama
- ne možemo reći da baš taj interval sadrži stvarnu vrijednost numeričke karakteristike
- možemo samo reći da ako bi računanje ponavljali na uzorcima iz iste populacije, tada bi izračunati interval realnih brojeva u približno  $100\gamma\%$  slučajeva sadržavao stvarnu vrijednost karakteristike koju procjenjujemo



# Procjena oćekivanja pouzdanim intervalom normalno distribuirana populacija, poznata varijanca



**Figure 1:** Realizacije pouzdanih intervala za oćekivanje izraćunatih na 100 uzoraka iz  $\mathcal{N}(0, 1)$  distribucije – približno 95% njih sadrži stvarnu vrijednost parametra (0)



## Procjena očekivanja pouzdanim intervalom normalno distribuirana populacija, poznata varijanca

- neka je  $X_1, \dots, X_n$  slučajan uzorak iz slučajne varijable  $X$  i pretpostavimo da znamo da  $X \sim \mathcal{N}(\mu, \sigma^2)$  pri čemu je očekivanje  $\mu$  nepoznato, a  $\sigma^2$  poznato
- $\bar{X}_n$  - aritmetička sredina uzorka veličine  $n$

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

- vrijedi

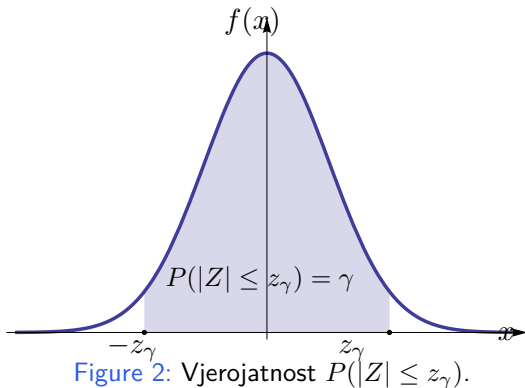
$$Z = \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n} \sim \mathcal{N}(0, 1)$$

- odredimo broj  $z_\gamma$  za koji vrijedi

$$P(|Z| \leq z_\gamma) = P(-z_\gamma \leq Z \leq z_\gamma) = \gamma$$



# Procjena očekivanja pouzdanim intervalom normalno distribuirana populacija, poznata varijanca





## Procjena očekivanja pouzdanim intervalom normalno distribuirana populacija, poznata varijanca

- $z_\gamma$  je  $\frac{1-\gamma}{2} + \gamma = \frac{1+\gamma}{2}$  kvantil slučajne varijable  $Z$  (možemo ga izračunati u Probability calculatoru)
- sada imamo:

$$\begin{aligned}\gamma &= P(|Z| \leq z_\gamma) \\ &= P\left(-z_\gamma \leq \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n} \leq z_\gamma\right) \\ &= P\left(\bar{X}_n - z_\gamma \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X}_n + z_\gamma \frac{\sigma}{\sqrt{n}}\right)\end{aligned}$$

odnosno

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





## Procjena očekivanja pouzdanim intervalom normalno distribuirana populacija, poznata varijanca

- pouzdani interval (***z*-interval**)

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

- to je slučajni interval koji sadrži očekivanje  $\mu$  s vjerojatnošću  $\gamma$



## Procjena očekivanja pouzdanim intervalom normalno distribuirana populacija, poznata varijanca

- na osnovu uzorka  $x_1, \dots, x_n$  iz slučajne varijable  $X$  (realizaciju) pouzdanog intervala računamo 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

$\sigma$  - standardna devijacija slučajne varijable  $X$

$z_\gamma$  - broj za koji vrijedi da je  $P(|Z| \leq z_\gamma) = \gamma$

$Z$  - standardna normalna slučajna varijabla

- u približno  $100\gamma\%$  slučajeva tako izračunati interval će sadržavati stvarnu vrijednost očekivanja  $\mu$  slučajne varijable  $X$
- primjer 5.4



## Procjena očekivanja pouzdanim intervalom normalno distribuirana populacija, nepoznata varijanca

- u praktičnim problemima  $\sigma$  gotovo nikad nije poznat
- neka je  $X_1, \dots, X_n$  slučajan uzorak iz slučajne varijable  $X$  i pretpostavimo da znamo da  $X \sim \mathcal{N}(\mu, \sigma^2)$  pri čemu su očekivanje  $\mu$  i varijanca  $\sigma^2$  nepoznati
- procjenitelj za standardnu devijaciju

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

- vrijedi

$$T = \frac{\bar{X}_n - \mu}{S_n} \sqrt{n} \sim \mathcal{T}_{n-1}$$

gdje je  $\mathcal{T}_{n-1}$  Studentova distribucija ( $t$ -distribucija) s  $n - 1$  stupnjeva slobode



## Procjena očekivanja pouzdanim intervalom normalno distribuirana populacija, nepoznata varijanca

- odredimo broj  $t_{\gamma, n-1}$  za koji vrijedi

$$P(|T| \leq t_{\gamma, n-1}) = P(-t_{\gamma, n-1} \leq T \leq t_{\gamma, n-1}) = \gamma$$

- $t_{\gamma, n-1}$  je  $\frac{1-\gamma}{2} + \gamma = \frac{1+\gamma}{2}$  kvantil slučajne varijable  $T$  (možemo ga izračunati u Probability calculatoru)
- slijedi

$$P\left(\mu \in \left[\bar{X}_n - t_{\gamma, n-1} \frac{S_n}{\sqrt{n}}, \bar{X}_n + t_{\gamma, n-1} \frac{S_n}{\sqrt{n}}\right]\right) = \gamma$$



## Procjena očekivanja pouzdanim intervalom normalno distribuirana populacija, nepoznata varijanca

- pouzdani interval (***t*-interval**):

$$\left[ \bar{X}_n - t_{\gamma, n-1} \frac{S_n}{\sqrt{n}}, \bar{X}_n + t_{\gamma, n-1} \frac{S_n}{\sqrt{n}} \right]$$

- to je slučajni interval koji sadrži očekivanje  $\mu$  s vjerojatnošću  $\gamma$



## Procjena očekivanja pouzdanim intervalom normalno distribuirana populacija, nepoznata varijanca

- na osnovu uzorka  $x_1, \dots, x_n$  iz slučajne varijable  $X$  (realizaciju) pouzdanog intervala računamo po formuli

$$\left[ \bar{x}_n - t_{\gamma, n-1} \frac{s_n}{\sqrt{n}}, \bar{x}_n + t_{\gamma, n-1} \frac{s_n}{\sqrt{n}} \right]$$

$\bar{x}_n$  - aritmetička sredina uzorka

$s_n$  - standardna devijacija uzorka

$t_{\gamma, n-1}$  - broj za koji vrijedi da je  $P(|T| \leq t_{\gamma, n-1}) = \gamma$

$T$  - slučajna varijabla sa Studentovom distribucijom  
s  $n - 1$  stupnjeva slobode

- u približno  $100\gamma\%$  slučajeva tako izračunati interval će sadržavati stvarnu vrijednost očekivanja  $\mu$  slučajne varijable  $X$
- zadatak



## Procjena očekivanja pouzdanim intervalom veliki uzorci

- neka je  $X_1, \dots, X_n$  slučajan uzorak iz slučajne varijable  $X$  s očekivanjem  $\mu$  i varijancom  $\sigma^2$  nepoznatima
- i za velike uzorke možemo koristiti  $t$ -interval kao pouzdani interval za očekivanje
- primjer 5.5





## Procjena vjerojatnosti događaja pouzdanim intervalom veliki uzorci

- neka je  $X_1, \dots, X_n$  slučajan uzorak iz Bernoullijeve slučajne varijable

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

pri čemu je  $p$  nepoznat

- procjenitelj za  $p$ : relativna frekvencija "uspjeha" (jedinice) u uzorku:

$$\hat{p} = \frac{f_1}{n},$$

gdje je  $f_1$  frekvencija jedinice u uzorku

- uočimo:  $\hat{p}$  je aritmetička sredina uzorka





## Procjena vjerojatnosti događaja pouzdanim intervalom veliki uzorci

- a osnovu uzorka  $x_1, \dots, x_n$  iz slučajne varijable  $X$  (realizaciju) pouzdanog intervala računamo po formuli

$$\left[ \hat{p} - z_\gamma \sqrt{\frac{\hat{p}\hat{q}}{n}}, \hat{p} + z_\gamma \sqrt{\frac{\hat{p}\hat{q}}{n}} \right],$$

$\hat{p}$  - relativna frekvencija jedinice (uspjeha) u uzorku

$\hat{q}$  - relativna frekvencija nula (neuspjeha) u uzorku,  $\hat{q} = 1 - \hat{p}$

$z_\gamma$  - broj za koji vrijedi  $P(|Z| \leq z_\gamma) = \gamma$

$Z$  - standardna normalna slučajna varijabla

- u približno  $100\gamma\%$  slučajeva tako izračunati interval će sadržavati stvarnu vrijednost vjerojatnosti  $p$
- primjer 5.7





## Testiranje statističkih hipoteza

- hipoteze koje želimo testirati treba izraziti kao hipoteze o distribuciji slučajne varijable
- **statistička hipoteza** – slutnja koja se odnosi na distribuciju slučajnog uzorka
- statističku hipotezu standardno označavamo s  $H$  ili  $\mathcal{H}$
- **statistički test** – pravilo na osnovu kojeg donosimo odluku o *odbacivanju* ili *ne odbacivanju* hipoteze
- kod testiranja postoje dvije hipoteze: **nul-hipoteza** –  $H_0$  i **alternativna hipoteza** –  $H_1$
- alternativna hipoteza je ona koju prihvaćamo u slučaju odbacivanja nul-hipoteze (suprotno od  $H_0$ )



## Testiranje statističkih hipoteza

- Hipoteze se uvijek postavljaju tako da se prije provođenja testa smatra da vrijedi nul-hipoteza  $H_0$ . Ako ne odbacimo  $H_0$ , ništa se neće dogoditi. Osim toga, hipoteze biramo tako da alternativna hipoteza odgovara tvrdnji koju želimo dokazati.
- To možemo usporediti sa suđenjem: Nitko nije kriv dok mu se ne dokaže krivnja.  
U tom slučaju hipoteze su

$H_0$  : optuženi nije kriv

$H_1$  : optuženi je kriv



## Testiranje statističkih hipoteza

- Uvijek govorimo o **odbacivanju** (postoji dovoljno dokaza za krivnju) ili **ne odbacivanju** (ne postoji dovoljno dokaza za krivnju) nul-hipoteze.
- Nije dobro reći *prihvaćamo* nul-hipotezu - to bi značilo da je ona točna samo zato jer je nismo uspjeli opovrgnuti (nije dokazano da je osoba nevinna, već samo da ne postoji dovoljno dokaza da se proglasi krivom)
- Kod odbacivanja, često kažemo *odbacujemo hipotezu  $H_0$  u korist hipoteze  $H_1$*



## Pogreške statističkog testa

- sve odluke temeljene na uzorcima iz populacije nisu 100% pouzdane pa ni zaključak testa ne mora biti 100% pouzdan
- odluka koja je donesena statističkim testom može biti ili pogrešna ili ispravna

istina	zaključak testa	
	ne odbaciti $H_0$	odbaciti $H_0$
$H_0$	dobra odluka	pogreška I. tipa
$H_1$	pogreška II. tipa	dobra odluka

**pogreška I. tipa: odbaciti  $H_0$  ako je ona istinita**  
**pogreška II. tipa: ne odbaciti  $H_0$  ako je  $H_1$  istinita.**



## Pogreške statističkog testa

- za primjer:  
pogreška I. tipa - osuditi nevinu osobu  
pogreška II. tipa - osloboditi osobu koja je stvarno kriva
- statistički test se dizajnira tako da dopušta izbor maksimalne vjerojatnosti pogreške prvog tipa (npr. 0.01, 0.05 ili 0.1)
- odabrana maksimalna vjerojatnost pogreške prvog tipa zove se **razina značajnosti testa** (ili nivo signifikantnosti), oznaka  $\alpha$

Zaključak testa može biti:

- odbacujemo  $H_0$  na razini značajnosti  $\alpha$  i prihvaćamo hipotezu  $H_1$
- ne odbacujemo  $H_0$  na razini značajnosti  $\alpha$  (nema dovoljno dokaza da  $H_0$  ne vrijedi)



## Rezultat statističkog testa

- kao rezultat testiranja dobit ćemo  **$p$ -vrijednost**
- **$p$ -vrijednost** – vjerojatnost da, pod pretpostavkom da  $H_0$  vrijedi, dobijemo uzorak jednak ili ekstremniji od onoga koji smo dobili (jednako ili manje vjerojatan)
- ako je ta vjerojatnost mala (manja od razine značajnosti), onda  $H_0$  možemo odbaciti, u suprotnom nemamo razloga za odbacivanje
- vjerojatnost ćemo računati na temelju distribucije neke funkcije uzorka – **test statistike**

Pomoću  $p$ -vrijednosti možemo zaključiti sljedeće:

- ♣ ako je  $p \leq \alpha$  odbacujemo  $H_0$  na razini značajnosti  $\alpha$
- ♣ ako je  $p > \alpha$  ne odbacujemo  $H_0$  na razini značajnosti  $\alpha$



## Testiranje hipoteza o očekivanju

- testiramo je li očekivanje uzorka  $\mu$  jednako nekoj unaprijed zadanoj vrijednosti  $\mu_0$
- nul-hipoteza:

$$H_0 : \mu = \mu_0$$

- alternativne hipoteze mogu biti:
  - $H_1 : \mu > \mu_0$
  - $H_1 : \mu < \mu_0$
  - $H_1 : \mu \neq \mu_0$
- odabir testa ovisi o pretpostavkama koje uzorak zadovoljava





## Normalno distribuirana populacija, poznata varijanca ( $z$ -test)

- neka je  $X_1, \dots, X_n$  slučajan uzorak iz slučajne varijable  $X$  i pretpostavimo da znamo da  $X \sim \mathcal{N}(\mu, \sigma^2)$  pri čemu je očekivanje  $\mu$  nepoznato, a  $\sigma^2$  poznato
- test-statistika:

$$Z = \frac{\bar{X}_n - \mu_0}{\sigma} \sqrt{n}$$

- ako  $H_0$  vrijedi,  $Z \sim \mathcal{N}(0, 1)$
- na temelju podataka izračunamo vrijednost za  $Z$  – označit ćemo je  $\hat{z}$
- ako je  $H_0$  istinita, očekujemo da je  $\hat{z}$  blizu 0, npr.
  - 95% realizacija od  $Z$  je u intervalu  $(-\infty, 1.6448]$
  - 95% realizacija od  $Z$  je u intervalu  $[-1.6448, \infty)$
  - 95% realizacija od  $Z$  je u intervalu  $[-1.96, 1.96]$



## Normalno distribuirana populacija, poznata varijanca ( $z$ -test)

- $p$ -vrijednost – vjerojatnost da test-statistika bude jednaka ili ekstremnija od  $\hat{z}$ :
  - $p = P(Z \geq \hat{z})$  ako je alternativna hipoteza oblika  $H_1 : \mu > \mu_0$
  - $p = P(Z \leq \hat{z})$  ako je alternativna hipoteza oblika  $H_1 : \mu < \mu_0$
  - $p = P(Z \in \langle -\infty, -|\hat{z}| \rangle \cup [|\hat{z}|, \infty))$  ako je alternativna hipoteza oblika  $H_1 : \mu \neq \mu_0$

- uočimo:

$$\begin{aligned}P(Z \in \langle -\infty, -|\hat{z}| \rangle \cup [|\hat{z}|, \infty)) &= P(Z \geq |\hat{z}|) + P(Z \leq -|\hat{z}|) \\ &= 2P(Z \geq |\hat{z}|) = 2P(Z \leq -|\hat{z}|)\end{aligned}$$

$p$ -vrijednost dvostranog testa je dvostruka  $p$ -vrijednost jednostranog testa

- tako izračunatu  $p$ -vrijednost uspoređujemo s razinom značajnosti  $\alpha$ :
  - ako je  $p \leq \alpha$  odbacujemo nul-hipotezu na razini značajnosti  $\alpha$
  - ako je  $p > \alpha$  ne odbacujemo nul-hipotezu na razini značajnosti  $\alpha$

- **zadatak**



## Normalno distribuirana populacija, nepoznata varijanca ( $t$ -test)

- u praktičnim problemima  $\sigma$  gotovo nikad nije poznat
- neka je  $X_1, \dots, X_n$  slučajan uzorak iz slučajne varijable  $X$  i pretpostavimo da znamo da  $X \sim \mathcal{N}(\mu, \sigma^2)$  pri čemu su očekivanje  $\mu$  i varijanca  $\sigma^2$  nepoznati
- test-statistika:

$$T = \frac{\bar{X}_n - \mu_0}{S_n} \sqrt{n} \sim \mathcal{T}_{n-1}$$

- ako  $H_0$  vrijedi,  $T \sim \mathcal{T}_{n-1}$  gdje je  $\mathcal{T}_{n-1}$  Studentova distribucija ( $t$ -distribucija) s  $n - 1$  stupnjeva slobode
- na temelju podataka izračunamo vrijednost za  $T$  – označit ćemo je  $\hat{t}$
- ako je  $H_0$  istinita, očekujemo da je  $\hat{t}$  blizu 0, npr. za  $n = 100$ 
  - 95% realizacija od  $T$  je u intervalu  $(-\infty, 1.6604]$
  - 95% realizacija od  $T$  je u intervalu  $[-1.6604, \infty)$
  - 95% realizacija od  $T$  je u intervalu  $[-1.9842, 1.9842]$



## Normalno distribuirana populacija, nepoznata varijanca ( $t$ -test)

- $p$ -vrijednost – vjerojatnost da test-statistika bude jednaka ili ekstremnija od  $\hat{t}$ :
  - $p = P(T \geq \hat{t})$  ako je alternativna hipoteza oblika  $H_1 : \mu > \mu_0$
  - $p = P(T \leq \hat{t})$  ako je alternativna hipoteza oblika  $H_1 : \mu < \mu_0$
  - $p = P(T \in \langle -\infty, -|\hat{t}| \rangle \cup [|\hat{t}|, \infty)) = 2P(T \geq |\hat{t}|)$  ako je alternativna hipoteza oblika  $H_1 : \mu \neq \mu_0$
- tako izračunatu  $p$ -vrijednost uspoređujemo s razinom značajnosti  $\alpha$ :
  - ako je  $p \leq \alpha$  odbacujemo nul-hipotezu na razini značajnosti  $\alpha$
  - ako je  $p > \alpha$  ne odbacujemo nul-hipotezu na razini značajnosti  $\alpha$
- **zadatak**



- neka je  $X_1, \dots, X_n$  slučajan uzorak iz slučajne varijable  $X$  s očekivanjem  $\mu$  i varijancom  $\sigma^2$  nepoznatima
- i za velike uzorke možemo koristiti  $t$ -test





## Testiranje hipoteza o vjerojatnosti događaja veliki uzorci

- neka je  $X_1, \dots, X_n$  slučajan uzorak iz Bernoullijeve slučajne varijable

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

pri čemu je  $p$  nepoznat

- nul-hipoteza:

$$H_0 : p = p_0$$

- test-statistika:

$$Z' = \frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}}$$

gdje je  $n$  dimenzija uzorka, a  $\hat{p}$  relativna frekvencija "uspjeha"

- ako  $H_0$  vrijedi,  $Z'$  ima približno  $\mathcal{N}(0, 1)$  distribuciju
- na temelju podataka izračunamo vrijednost za  $Z'$  – označit ćemo je  $\hat{z}$
- ako je  $H_0$  istinita, očekujemo da je  $\hat{z}$  blizu 0



## Testiranje hipoteza o vjerojatnosti događaja veliki uzorci

- $p$ -vrijednost – vjerojatnost da test-statistika bude jednaka ili ekstremnija od  $\hat{z}$ :
  - $p$ -vrijednost =  $P(Z \geq \hat{z})$  ako je alternativna hipoteza oblika  $H_1 : p > p_0$
  - $p$ -vrijednost =  $P(Z \leq \hat{z})$  ako je alternativna hipoteza oblika  $H_1 : p < p_0$
  - $p$ -vrijednost =  $P(Z \in \langle -\infty, -|\hat{z}| \rangle \cup [|\hat{z}|, \infty)) = 2P(Z \geq |\hat{z}|)$  ako je alternativna hipoteza oblika  $H_1 : p \neq p_0$
- tako izračunatu  $p$ -vrijednost uspoređujemo s razinom značajnosti  $\alpha$ :
  - ako je  $p$ -vrijednost  $\leq \alpha$  odbacujemo nul-hipotezu na razini značajnosti  $\alpha$
  - ako je  $p$ -vrijednost  $> \alpha$  ne odbacujemo nul-hipotezu na razini značajnosti  $\alpha$
- primjer 5.10





## Testiranje hipoteza o distribuciji diskretne distribucije

- kao procjenu za stvarnu (nepoznatu) distribuciju slučajne varijable koristimo empirijsku distribuciju određenu na temelju podataka
- želimo testirati ima li slučajna varijabla neku pretpostavljenu **teorijsku distribuciju**
- testiranje hipoteze da podaci dolaze iz pretpostavljene teorijske distribucije može se provesti tzv.  $\chi^2$ -testom
- neka je teorijska distribucija

$$\begin{pmatrix} x_1 & x_2 & \dots & x_k \\ p_1 & p_2 & \dots & p_k \end{pmatrix}$$

- test se provodi usporedbom opaženih i teorijskih frekvencija
- opažene (eksperimentalne) frekvencije

$x_1$	$x_2$	$\dots$	$x_k$
$f_1$	$f_2$	$\dots$	$f_k$

$$\sum_{i=1}^k f_i = n$$





# Testiranje hipoteza o distribuciji diskretne distribucije

- teorijske (očekivane) frekvencije

$x_1$	$x_2$	$\dots$	$x_k$
$np_1$	$np_2$	$\dots$	$np_k$

- hipoteze  $\chi^2$ -testa:

$H_0$  : distribucija iz koje dolaze podaci jednaka je teorijskoj

$H_1$  : distribucija iz koje dolaze podaci razlikuje se od teorijske

- primjer 5.11





## Testiranje hipoteza o distribuciji normalna distribucija

- za prvi uvid u moguća odstupanja od normalne distribucije možemo koristiti razne mjere deskriptivne statistike i grafičke prikaze (npr. histograme relativnih frekvencija), no to nije dovoljno za donošenje zaključka o normalnoj distribuiranosti varijable
- Shapiro-Wilk  $W$  test - statistički test koji se mogu koristiti za testiranje sljedećih hipoteza:

$H_0$  : varijabla ima normalnu distribuciju

$H_1$  : varijabla nema normalnu distribuciju

- primjer 5.12

