

Primijenjena i inženjerska matematika

Statistika - predavanje 5

Statističko zaključivanje - dvije varijable

Zaključivanje o razlikama u očekivanjima i proporcijama

10.11.2023.





Razlike u distribuciji između dviju varijabli

- dolazi li do promjene obilježja koje proučavamo zbog provođenja neke aktivnosti, u nekom drugom trenutku ili općenito u nekim drugim uvjetima?
- **nevezani** i **vezani uzorci** (zavisni) - [primjeri 6.1, 6.2 i 6.3](#)
- jesu li ove razlike uočene na uzorcima statistički značajne ili ne?
- kažemo da analiziramo jedno obilježje u dva **tretmana**
- cilj je utvrditi mogu li se razlike koje uočavamo pripisati samo slučajnosti ili ima razloga vjerovati da su izazvane postojanjem razlika između stvarnih distribucija promatranih slučajnih varijabli (razlike su **statistički značajne**)



Usporedba očekivanja - nevezani uzorci

- pretpostavimo da imamo dva nezavisna slučajna uzorka:
 - $X_1^{(1)}, \dots, X_{n_1}^{(1)}$ slučajan uzorak iz slučajne varijable $X^{(1)}$
 - $X_1^{(2)}, \dots, X_{n_2}^{(2)}$ slučajan uzorak iz slučajne varijable $X^{(2)}$
- želimo usporediti očekivanje μ_1 slučajne varijable $X^{(1)}$ i očekivanje μ_2 slučajne varijable $X^{(2)}$
- uzorci ne sadrže iste jedinice



Usporedba očekivanja - nezavisni uzorci iz normalno distribuiranih populacija s poznatim varijancama (z -test)

- pretpostavke:
 - $X^{(1)} \sim \mathcal{N}(\mu_1, \sigma_1^2)$
 - $X^{(2)} \sim \mathcal{N}(\mu_2, \sigma_2^2)$
 - σ_1^2 i σ_2^2 poznati
- nul-hipoteza:

$$H_0 : \mu_1 = \mu_2$$

- test-statistika:

$$Z = \frac{\bar{X}_{n_1} - \bar{X}_{n_2}}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$$

gdje su n_1 i n_2 veličine uzoraka, \bar{X}_{n_1} i \bar{X}_{n_2} su aritmetičke sredine

- 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



Usporedba očekivanja - nezavisni uzorci iz normalno distribuiranih populacija s poznatim varijancama (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 $H_1 : \mu_1 > \mu_2$
 - $p = P(Z \leq \hat{z})$ ako je alternativna hipoteza oblika $H_1 : \mu_1 < \mu_2$
 - $p = P(Z \in \langle -\infty, -|\hat{z}| \rangle \cup [|\hat{z}|, \infty))$ ako je alternativna hipoteza oblika $H_1 : \mu_1 \neq \mu_2$

- 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 α :
 - ako je $p \leq \alpha$ odbacujemo nul-hipotezu na razini značajnosti α
 - ako je $p > \alpha$ ne odbacujemo nul-hipotezu na razini značajnosti α

- **zadatak**



Usporedba očekivanja - nezavisni uzorci iz normalno distribuiranih populacija s nepoznatim varijancama (Welchov t -test)

- u praktičnim problemima σ_1 i σ_2 gotovo nikad nisu poznati
- pretpostavke:
 - $X^{(1)} \sim \mathcal{N}(\mu_1, \sigma_1^2)$
 - $X^{(2)} \sim \mathcal{N}(\mu_2, \sigma_2^2)$
 - σ_1^2 i σ_2^2 nepoznate
- nul-hipoteza:

$$H_0 : \mu_1 = \mu_2$$



Usporedba očekivanja - nezavisni uzorci iz normalno distribuiranih populacija s nepoznatim varijancama (Welchov t -test)

- test-statistika:

$$T = \frac{\bar{X}_{n_1} - \bar{X}_{n_2}}{s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$

gdje su n_1 i n_2 veličine uzoraka, \bar{X}_{n_1} i \bar{X}_{n_2} su aritmetičke sredine i

$$s_p^2 = \frac{(n_1 - 1)s_{n_1}^2 + (n_2 - 1)s_{n_2}^2}{n_1 + n_2 - 2}$$

- ako H_0 vrijedi, T ima Studentovu t -distribuciju s brojem stupnjeva slobode koji se određuje aproksimativno (ako je poznato da su varijance jednake onda je broj stupnjeva slobode $(n_1 + n_2 - 2)$)
- na temelju podataka izračunamo vrijednost za T – označit ćemo je \hat{t}
- ako je H_0 istinita, očekujemo da je \hat{t} blizu 0



Usporedba očekivanja - nezavisni uzorci iz normalno distribuiranih populacija s nepoznatim varijancama (Welchov 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 $H_1 : \mu_1 > \mu_2$
 - $p = P(T \leq \hat{t})$ ako je alternativna hipoteza oblika $H_1 : \mu_1 < \mu_2$
 - $p = P(T \in \langle -\infty, -|\hat{t}| \rangle \cup [|\hat{t}|, \infty)) = 2P(T \geq \hat{t})$ ako je alternativna hipoteza oblika $H_1 : \mu_1 \neq \mu_2$
- tako izračunatu p -vrijednost uspoređujemo s razinom značajnosti α :
 - ako je $p \leq \alpha$ odbacujemo nul-hipotezu na razini značajnosti α
 - ako je $p > \alpha$ ne odbacujemo nul-hipotezu na razini značajnosti α
- primjer 6.5



Usporedba očekivanja - nevezani veliki uzorci

- u slučaju velikih uzoraka možemo koristiti Welchov t -test
- **zadatak 6.5**





Usporedba očekivanja - vezani uzorci

- često u praksi imamo potrebu za uspoređivanjem varijabli u vezanim tretmanima - npr. ako želimo uspoređivati rezultate testa za iste bolesnike prije i nakon liječenja
- slučajevi se moraju pratiti u paru
- zaključci se donose na temelju razlika varijabli u pojedinim tretmanima

ispitanik	tretman 1	tretman 2	razlika
1	x_1	y_1	$d_1 = x_1 - y_1$
2	x_2	y_2	$d_2 = x_1 - y_2$
\vdots	\vdots	\vdots	\vdots
n	x_n	y_n	$d_n = x_1 - y_n$

Table 1: Razlike vrijednosti varijabli u promatranim tretmanima



Usporedba očekivanja - vezani uzorci

- neka je X_1, \dots, X_n slučajan uzorak prije tretmana iz slučajne varijable s očekivanjem μ_1 i Y_1, \dots, Y_n slučajan uzorak poslije tretmana iz slučajne varijable s očekivanjem μ_2
- želimo testirati

$$H_0 : \mu_1 = \mu_2$$

nasuprot jednoj od alternativnih hipoteza:

$$H_1 : \mu_1 > \mu_2 \quad H_1 : \mu_1 < \mu_2 \quad H_1 : \mu_1 \neq \mu_2$$



Usporedba očekivanja - vezani uzorci

- slučajne varijable razlika $D_i = X_i - Y_i$, $i \in \{1, \dots, n\}$,
- očekivanje slučajne varijable razlika $D_i = X_i - Y_i$, $i \in \{1, \dots, n\}$, može se dobiti kao razlika očekivanja μ_1 i μ_2 slučajnih varijabli X_i i Y_i , tj.

$$\mu_D = \mu_1 - \mu_2.$$

- testiranje hipoteze

$$H_0 : \mu_1 = \mu_2$$

može se svesti na testiranje ekvivalentne hipoteze $H_0 : \mu_D = 0$ koja se odnosi na očekivanje slučajne varijable razlika

- test se može koristiti za velike uzorke, a za male uzorke ako su razlike normalno distribuirane
- primjer 6.6





Usporedba proporcija - nevezani veliki uzorci

- želimo testirati jednakost proporcija (ili vjerojatnosti događaja) u dvije nevezane populacije
- nul-hipoteza:

$$H_0 : p_1 = p_2$$

- test-statistika:

$$Z' = \frac{\hat{p}_1 - \hat{p}_2}{\sqrt{\hat{p}(1 - \hat{p})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}}, \quad \hat{p} = \frac{n_1\hat{p}_1 + n_2\hat{p}_2}{n_1 + n_2}$$

gdje su n_1 i n_2 veličine uzoraka, \hat{p}_1 i \hat{p}_2 su relativne frekvencije "uspjeha" u prvom odnosno drugom uzorku

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



Usporedba proporcija - nevezani veliki uzorci

- p -vrijednost – vjerojatnost da test-statistika bude jednaka ili ekstremnija od \hat{z} :
 - $p = P(Z \geq \hat{z})$ ako je alternativna hipoteza oblika $H_1 : p_1 > p_2$
 - $p = P(Z \leq \hat{z})$ ako je alternativna hipoteza oblika $H_1 : p_1 < p_2$
 - $p = P(Z \in \langle -\infty, -|\hat{z}| \rangle \cup [|\hat{z}|, \infty)) = 2P(Z \geq \hat{z})$ ako je alternativna hipoteza oblika $H_1 : p_1 \neq p_2$
- tako izračunatu p -vrijednost uspoređujemo s razinom značajnosti α :
 - ako je $p \leq \alpha$ odbacujemo nul-hipotezu na razini značajnosti α
 - ako je $p > \alpha$ ne odbacujemo nul-hipotezu na razini značajnosti α
- primjer 6.8

