

# NEPARAMETARSKA STATISTIKA

## STATISTIČKI PRAKTIKUM 2

### 7. VJEŽBE

# Zašto neparametarska statistika?

- ▶ provodimo statističku analizu podataka bez rigoroznih pretpostavki na distribuciju populacije
- ▶ korisna kada je pripadnost određenoj distribuciji teško provjeriti ili je distribucija nepoznata
- ▶ kod uzoraka male duljine
- ▶ izbjegavamo neopravdanu pretpostavku normalnosti

# Jakost neparametarske statistike

U situaciji kada je parametarski model za uzorak nedostupan, neparametarske metode su idealne. Parametarski testovi su općenito jači od neparametarskih (iako ne značajno), ali njihova snaga drastično pada ukoliko pretpostavke o populacijskom modelu nisu zadovoljene.

# Procedura

U većini slučajeva potrebne su minimalne pretpostavke o modelu (jednakost varijanci/distribucije među populacijama, neprekidnost distribucije i sl.), ali kako je riječ o jednostavnim pretpostavkama manja je mogućnost grešaka u zaključivanju.

Većina neparametarskih metoda se bazira na *uređajnoj statistici*; umjesto samih vrijednosti mjerenja promatramo njihove *rangove* (poziciju u uređenom uzorku).

# Rangovi

Za slučajni uzorak  $X_1, \dots, X_n$  promatramo uređajnu statistiku  $X_{(1)}, \dots, X_{(n)}$  (takvu permutaciju slučajnog uzorka da vrijedi  $X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$ )

Rangovi su niz slučajnih varijabli duljine  $n$ :  $R_1, \dots, R_n$  takvi da vrijedi:

- ▶  $R_i = \text{rang podatka } X_i \text{ u uređenom uzorku.}$

# 1. Procjena pouzdanih intervala

Za uzorke velike duljine korištenjem CGT-a možemo dobiti asimptotske pouzdane intervale za parametre pripadne distribucije. No kako asimptotika ovisi o brzini konvergencije prema normalnoj distribuciji, ova metoda nije pouzdana za uzorke male duljine i specifične distribucije.

Ukoliko želimo dobiti egzaktnu pouzdane intervale za male uzorke potrebne su određene pretpostavke na distribuciju populacije koje nije uvijek jednostavno provjeriti ili koje su neopravdane.

Također, zanimaju nas i metode za procjenu pouzdanih intervala za vrijednosti koje nisu parametri određene vjerojatnosne distribucije.

## Pouzdan interval za medijan

*Medijan*  $M$  je često promatrana vrijednost u neparametarskom okruženju, uz pretpostavku neprekidnosti distribucije  $F$  vrijedi

$$F(M) = \frac{1}{2}.$$

Za uzorak  $X_1, \dots, X_n$  iz distribucije  $F$ , vjerojatnost da je svaki element veći (odnosno manji) od medijana je  $\frac{1}{2}$ . Tada je

$$N^- = \#\{i : X_i < M\} \sim B\left(n, \frac{1}{2}\right).$$

# Procedura

Za  $\alpha \in \langle 0, 1 \rangle$  odredimo  $(1 - \alpha) \cdot 100\%$  - pouzdani interval za  $M$

- ▶ Odaberemo  $a, b \in \{0, \dots, n\}$  t.d.

$$\mathbb{P}(N^- \leq a) = \mathbb{P}(N^- \geq b) = \frac{\alpha}{2}.$$

- ▶ Ukoliko nije moguće postići jednakost, odaberemo vrijednost  $a$  t.d. je gornja vjerojatnost najbliža  $\frac{\alpha}{2}$  i  $b = n + 1 - a$ .
- ▶ Za uređeni uzorak  $X_{(1)} < X_{(2)} < \dots < X_{(n)}$  vrijedi

$$\mathbb{P}(X_{(a)} < M < X_{(b)}) = (\approx) 1 - \alpha$$



# Zadatak 1 - Srčani puls

U datoteci `heartrate.txt` nalaze se izmjerene promjene pulsa grupe pacijenata nakon primanja određenog lijeka.

1. Provjerite dolaze li podaci iz normalne razdiobe.
2. Konstruirajte 98% pouzdani interval za medijan.

## Pouzdaní intervali dobiveni bootstrap metodom

Ideja: uz dani uzorak  $X_1, \dots, X_n$  bez dodatnih pretpostavki na populaciju iz koje dolazi, sve poznate informacije o distribuciji sadržane su u uzorku. Uzorak tretiramo kao populaciju i ponavljamo *resampling* iz tog uzorka. Na temelju tih novih uzoraka procjenjujemo vrijednosti promatrane statistike (parametra  $\theta$ ).

U R-u:

```
> boot.out=boot(data, statistic,...)
> boot.ci(boot.out, conf = 0.95, type = "all", ...)
```

gdje je *type* tip bootstrap intervalne procjene. Jedna od metoda je "perc" koja  $(1 - \alpha) \cdot 100$  - pouzdani interval za  $\theta$  određuje kao

$$\left[ \hat{\theta}_{\alpha/2}, \hat{\theta}_{1-\alpha/2} \right].$$

## 2. Binomni test

Test jednakosti medijana, neparametarska verzija t-testa za jednakost očekivanja.

Promotrimo uzorak  $X_1, \dots, X_n$  i hipoteze

$$H_0 : M = m_0$$

$$H_1 : M > m_0$$

Uredimo uzorak  $X_{(1)}, \dots, X_{(n)}$  i promotrimo broj elemenata uzorka većih od  $m_0$ ,

$$N^+ = \#\{i : X_{(i)} > m_0\}.$$

Ukoliko je hipoteza  $H_0$  točna statistika  $N^+$  ima binomnu distribuciju  $B(n, \frac{1}{2})$ .

*Napomena:* Elemente uzorka koji su jednaki  $m_0$  izbacimo iz uzorka.

# Procedura

Imamo realizaciju uzorka  $x_1, \dots, x_n$  i razinu značajnosti  $\alpha \in \langle 0, 1 \rangle$

1. Odredimo  $n^+$ , broj elemenata većih od  $m_0$ .
2. Izračunamo p-vrijednost

$$\gamma = \mathbb{P}(N^+ \geq n^+ | H_0) = \sum_{i=[n^+]}^n \binom{n}{i} \left(\frac{1}{2}\right)^n$$

3. Kritično područje za test na razini značajnosti  $\alpha$  je  $K = \{\gamma < \alpha\}$

## Moguće alternativne hipoteze

▶  $H_1 : M < m_0$

$$\gamma = \mathbb{P}(N^- \leq n^- | H_0),$$
$$K = \{\gamma > \alpha\}$$

▶  $H_1 : M \neq m_0$

$$\gamma_i = \mathbb{P}(N^{+(-)} > (<)n^{+(-)} | H_0)/2,$$
$$K_i = \{\gamma \geq (\leq)\alpha/2\},$$
$$i = 1, 2$$

## Zadatak 2.

Dani su rezultati mjerenja visine devetero osnovnoškolske djece

1.51 1.35 1.69 1.48 1.29 1.27 1.54 1.39 1.45

Na razini značajnosti od 5% testirajte je li medijan veći od 1.4.

1. Test iskodirajte sami.
2. Koristite naredbu `binom.test` u R-u.

### 3. Wilcoxonov test za enakost medijana

Promatramo uzorak  $X_1, \dots, X_n$  iz populacije sa simetričnom neprekidnom distribucijom. Želimo testirati hipotezu:

$$H_0 : M = m_0$$

$$H_1 : M \neq m_0$$

Wilcoxonov test je neparametarska alternativa jednostranom t-testu.

# Procedura

1. Odredimo  $Z_i = |X_i - m_0|$ , uredimo uzorak  $Z$  te za svaki  $Z_i$  odredimo njegov rang  $R_i$ ;

$$R_i = j \text{ ako je } Z_{(j)} = Z_i$$

2. Za svaki od  $Z_i$ -eva provjerimo je li pripadni  $X_i$  veći ili manji od  $m_0$
3. Sa  $W^+$  ( $W^-$ ) označimo sumu rangova  $Z$ -ova čiji su pripadni  $X$ -evi veći (manji) od  $m_0$
4. Ukoliko je nulta hipoteza točna statistika  $W$  ima *Wilcoxonovu distribuciju*.



U R-u koristimo naredbu

```
> wilcox.test(x, y = NULL, alternative = c("two.sided",  
"less", "greater"), paired = FALSE, exact = NULL,  
conf.level = 0.95, ...)
```

Varijabla `exact` određuje računamo li p-vrijednosti preko Wilcoxonove distribucije ili njene normalne aproksimacije. Kako je

$$\mathbb{E}W^+ = \frac{n(n+1)}{4}$$
$$\text{Var}W^+ = \frac{n(n+1)(2n+1)}{24} < \infty$$

Wilcoxonova distribucija zadovoljava CGT.

## Zadatak 3.

U datoteci `rent.txt` nalaze se podaci o mjesečnoj cijeni najma (u \$) za 25 slučajno odabranih kućanstava u Bostonu. Testirajte na razini značajnosti od 5% hipotezu da je prosječni mjesečni najam veći od 750\$

# Napomena

Wilcoxonov test odbacuje jednake vrijednosti unutar uzorka. Kako veličina uzorka značajno utječe na  $p$ -vrijednost, ne bismo smjeli odbaciti više od 10% elemenata uzorka. U slučaju da je to nužno treba razmotriti alternativu testu, npr. s korekcijama.

### 3. Mann - Whitney - Wilcoxonov test za medijane dviju populacija

Imamo dva međusobno nezavisna slučajna uzorka  $X_1, \dots, X_{n_1}$  i  $Y_1, \dots, Y_{n_2}$  redom iz distribucija  $F$  i  $G$ .

Želimo provjeriti hipotezu da su populacije jednake tj.

$$H_0 : F = G.$$

# Rangovi

Neka je  $n := n_1 + n_2$ . Označimo  $Z_1 := X_1, \dots, Z_{n_1} := X_{n_1}$ ,  
 $Z_{n_1+1} = Y_1, \dots, Z_n = Y_{n_2}$ . Neka su

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

uređene statistike. Definiramo nove slučajne varijable  
 $R_1, R_2, \dots, R_n$ .

# Rangovi

Ako je  $X_1 = Z_{(k_1)}$ , onda je  $R_1 = k_1$ .

⋮

Ako je  $X_j = Z_{(k_j)}$ , onda je  $R_j = k_j$ .

⋮

Ako je  $X_{n_1} = Z_{(k_{n_1})}$ , onda je  $R_{n_1} = k_{n_1}$

Ako je  $Y_1 = Z_{(k_{n_1+1})}$ , onda je  $R_{n_1+1} = k_{n_1+1}$ .

⋮

Ako je  $Y_{n_2} = Z_{(k_n)}$ , onda je  $R_n = k_n$ .

# Wilcoxonova statistika

Wilcoxonovu statistiku definiramo kao zbroj rangova drugog uzorka

$$W := R_{n_1+1} + R_{n_1+2} + \dots + R_n.$$

Neka su sada  $S_1 \leq S_2 \leq \dots \leq S_{n_2}$  uređene statistike rangova  $R_{n_1+1}, \dots, R_n$  slučajnih varijabli  $Y_1, \dots, Y_{n_2}$ .

Neka su sada  $1 \leq s_1 < s_2 < \dots < s_{n_2} \leq n$ . Vrijedi

$$\mathbb{P}_{H_0}(S_1 = s_1, \dots, S_{n_2} = s_{n_2}) = \binom{n}{n_2}^{-1}.$$

# Mann - Whitneyjeva statistika

Za  $i \in \{1, 2, \dots, n_1\}$ ,  $j \in \{1, 2, \dots, n_2\}$  definiramo slučajnu varijablu

$$U_{ij} := \mathbf{1}_{(X_i < Y_j)}.$$

Mann - Whitneyjeva statistika je

$$U = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} U_{ij}.$$

Dakle,  $U$  predstavlja broj parova  $(X_i, Y_j)$  za koje vrijedi  $X_i < Y_j$ .  
Vrijedi

$$U = W - \frac{1}{2}n_2(n_2 + 1).$$



## Što vrijedi uz pretpostavku $H_0$

Uz pretpostavku  $H_0$  vrijedi

$$\mathbb{E}_{H_0} U = \frac{n_1 n_2}{2},$$

$$\text{Var}_{H_0} U = \frac{1}{12} n_1 n_2 (n + 1) < \infty.$$

Nadalje, uz pretpostavku  $H_0$  vrijedi iz CGT-a

$$\frac{U - \frac{n_1 n_2}{2}}{\sqrt{\frac{1}{12} n_1 n_2 (n + 1)}} \xrightarrow{d} N(0, 1), \quad \min\{n_1, n_2\} \rightarrow \infty.$$

## Što ako su neke vrijednosti iste?

Ako su neke vrijednosti iste određuju se *podijeljeni rangovi*:

Za vrijednost od  $X_i$ , je  $R_i$  aritmetička sredina svih rangova  $k$  za koje je  $Z_{(k)} = X_i$ , tj.

$$R_i^* := \frac{1}{\#\{k : X_i = Z_{(k)}\}} \sum_{k=1}^n k \mathbf{1}_{(X_i = Z_{(k)})}.$$

Analogno se definiraju rangovi za  $Y_j$ . Sada se definiraju  $S_1^*, \dots, S_{n_2}^*$  uređene statistike od  $R_{n_1+1}^*, \dots, R_n^*$ . Prirodno se poopćuje Wilcoxonova statistika

$$W^* = S_1^* + \dots + S_{n_2}^* = R_{n_1+1}^* + \dots + R_n^*$$

## Što ako su neke vrijednosti iste?

Za  $i \in \{1, 2, \dots, n_1\}$ ,  $j \in \{1, 2, \dots, n_2\}$  definiramo slučajnu varijablu

$$U_{ij}^* := \mathbf{1}_{(X_i = Y_j)}.$$

Mann - Whitneyjeva statistika je

$$U^* = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} (U_{ij} + \frac{1}{2} U_{ij}^*).$$

Dakle,  $U$  predstavlja broj parova  $(X_i, Y_j)$  za koje vrijedi  $X_i < Y_j$  i polovicu broja parova  $(X_i, Y_j)$  za koje vrijedi  $X_i = Y_j$ .

Ponovo vrijedi

$$U^* = W^* - \frac{1}{2} n_2 (n_2 + 1).$$

Slično vrijedi asimptotska normalnost.

## Alternativne hipoteze

Jedna od mogućih alternativnih hipoteza je

$$H_1 : F \neq G.$$

Druga mogućnost je da testiramo da je neka stohastički veća od druge. Za slučajnu varijablu  $X$  kažemo da je **stohastički veća** od slučajne varijable  $Y$  ako za svaki  $t \in \mathbb{R}$  vrijedi

$$\mathbb{P}(X \geq t) \geq \mathbb{P}(Y \geq t) \Leftrightarrow F_Y(t) \geq F_X(t).$$

Stoga bi mogli testirati i

$$H_1 : F < G \quad \text{ili} \quad H_1 : F > G.$$

Možemo testirati je li neka pojava (distribuirana sa  $F$ ) stohastički veća ili manja od druge (distribuirane sa  $G$ ). Ako je  $F > G$  očekujemo da Wilcoxonova statistika bude veća, u suprotnom manja.

Statistike  $W$  ( $W^*$ ) i  $U$  ( $U^*$ ) su ekvivalentne. Njihova distribucija se može izračunati uz pretpostavku  $H_0$  (za zadane podatke), što se i radi za manje brojeve, a za veće se koristi asimptotska normalnost. Ovisno o alternativnoj hipotezi imamo dvostrano ili jednostrano testiranje.

## Mann - Whitney - Wilcoxonov test u R-u

Neka je  $x$  vektor podataka dobiven kao slučajna realizacija od  $F$  i vektor  $y$  vektor podataka dobiven kao slučajna realizacija od  $G$  nezavisno od  $x$ .

Alternativne hipoteze  $F \neq G$ ,  $F < G$ ,  $F > G$  testiramo na sljedeći način:

- > `wilcox.test(x,y)`
- > `wilcox.test(x,y,al="gre")`
- > `wilcox.test(x,y,al="less")`

## Zadatak 4.

U datoteci `smrt.txt` zabilježeni su podaci s gradskih groblja u Zagrebu o dobi umrlih i njihovom spolu. Je li dob koju dožive žene *veća* od dobi koju dožive muškarci? U ovom slučaju testirat ćemo tvrdnju da se pod *veća* podrazumijeva *stohastički veća*. Svoje rezultate potkrijepite i grafičkim prikazom.

# Wilcoxonova statistika rangova s predznacima

Pretpostavimo da imamo  $2n$  opažanja, po dva od svakog  $n$  subjekata. Primjerice, imamo  $n$  parova bolesnika s sitom bolešću, pri čemu bolesnici u paru imaju iste simptome bolesti. Za svaki par na jednom članu primijenimo tretman novim lijekom, a drugog tretiramo na stari način.

Opažanja kod člana  $i$ -tog para tretiranog novim lijekom označimo s  $X_i$ , a opažanja kod člana tretiranog starim načinom  $Y_i$ . Zanima postoji li razlika između ove dvije skupine.



# Pretpostavke

Želimo testirati pokazuju li pacijenti tretirani novim lijekom da su se prije oporavili. Pretpostavka je da smo od populacije parova na slučajan način odabrali njih  $n$  i da smo među njima slučajno odabrali kojeg ćemo liječiti novim lijekom, a kojeg starom metodom. Tada su

$$(X_1, Y_1), \dots, (X_n, Y_n),$$

nezavisni jednako distribuirani vektori, gdje su  $X_i$  distribuirani sa  $F_X$ , a  $Y_i$  sa  $F_Y$ .

Promatramo razlike  $Z_i = Y_i - X_i$ , koje su nezavisne i jednako distribuirane.

# Postupak

1. Neka je  $R_i$  rang od  $|Z_i|$ .
2. Tada je Wilcoxova statistika

$$V = \sum_{k=0}^n \mathbf{1}_{(Z_i > 0)} R_i.$$

$$H_0 : F_X = F_Y$$

Nulta hipoteza je ekvivalentna hipotezi da je medijan distribucije razlika  $\{Z_i\}$  0.

Pokazuje se (uz pretpostavku da su distribucije neprekidne) da je

$$\mathbb{E}_{H_0} V = \frac{n(n+1)}{4}, \quad \text{Var}_{H_0} V = \frac{n(n+1)(2n+1)}{24} < \infty$$

Stoga kad je  $n$  velik možemo koristiti asimptotsku normalnost (CGT). Možemo i egzaktno izračunati distribuciju  $V$ -a za male  $n$ .

## Što ako distribucije nisu neprekidne

1. Neka je  $R_i^*$  podijeljen rang od  $|Z_i|$  (promatramo samo vrijednosti  $|Z_k|$  koje su različite od nule).
2. Tada je Wilcoxonova statistika

$$V^* = \sum_{k=0}^n \mathbf{1}_{(Z_i > 0)} R_i^*.$$

$$\mathbb{E}_{H_0} V^* = \frac{n(n+1) - d_0(d_0+1)}{4},$$

$$\text{Var}_{H_0} V^* = \frac{n(n+1)(2n+1) - d_0(d_0+1)(2d_0+1)}{24} - \frac{\sum_{k=1}^g d_k(d_k^2 - 1)}{48}.$$

Dakle za velike  $n$  koristimo asimptotsku normalnost.

## Zadatak 5.

Promatramo dva kolegija *Programiranje 2* i *Strukture podataka i algoritmi*. Prvi kolegij je nužni prethodnik za drugi. Njima vježbe drže dva asistenta  $X$  i  $Y$ .

Odabrali smo po jedan par studenata koji su iz Programiranja 2 imali ocjenu dovoljan i izvrstan, i po 2 para s ocjenama dobar i vrlo dobar. Te smo očitali rezultate s njihova 1. kolokvija iz SPA.

Dobili smo sljedeće rezultate

>  $x=c(15, 12, 24, 11.5, 13, 22.5)$

>  $y=c(17, 12, 22, 13, 12, 16)$

Ispitajte jesu li asistenti jednako uspješni u držanju vježbi.

## 6. Kruskal-Wallis test

- ▶ generalizacija Mann-Whitney-Wilcoxonovog testa za dva uzorka na više uzoraka
- ▶ jednako jak kao i ANOVA, u slučaju nenormalnosti podataka ili outliera i jači
- ▶ promatramo  $k \geq 2$  nezavisnih uzoraka i želimo usporediti pripadne distribucije, ali bez pretpostavki o samoj familiji distribucija.

Promatramo hipoteze

$$H_0 : M_1 = M_2 = \dots = M_k$$

$$H_1 : \text{ne } H_0$$

# Procedura

Promatramo  $k$  uzoraka:  $X_1^{(i)}, \dots, X_{n_i}^{(i)}$ ,  $i = 1, \dots, k$ ,  $n = \sum_{i=1}^k n_i$ .

- ▶ Svih  $k$  uzoraka uredimo u rastući niz  $Z_1 < Z_2 < \dots < Z_n$
- ▶ Odredimo rangove  $R_i^{(j)}$  za svaki  $X_i^{(j)}$  unutar **cjelokupnog** uređenog uzorka
- ▶ Odredimo sumu i prosjek rangova po uzorcima

$$R^{(j)} = \sum_{i=1}^{n_j} R_i^{(j)}, \quad \bar{R}^{(j)} = \frac{R^{(j)}}{n_j}$$

(Uočimo da je  $R = \sum_{j=1}^k R^{(j)} = \frac{n(n+1)}{2}$  i  $\bar{R} = \frac{n+1}{2}$ )

- ▶ Izračunamo Kruskal-Wallis statistiku

$$\begin{aligned} H &= \frac{12}{n(n+1)} \sum_{j=1}^k n_j (\bar{R}^{(j)} - \bar{R})^2 = \\ &= \frac{12}{n(n+1)} \sum_{j=1}^k \frac{(R^{(j)})^2}{n_j} - 3(n+1) \end{aligned}$$

- ▶ Točnu distribuciju statistike  $H$  je teško odrediti (ovisi o vrijednostima  $k, n_1, \dots, n_k$ ) i egzaktne vrijednosti su poznate samo za mali broj slučajeva. Za velike duljine uzoraka distribucija se može aproksimirati s  $\chi^2(k-1)$
- ▶ Kritično područje testa je  $K = \{H > \chi_{\alpha}^2(k-1)\}$



## Zadatak 6. - Ozon

Podaci `airquality` sadrže dnevna mjerenja kvalitete zraka u New Yorku od svibnja do rujna 1973.g. Gustoća ozona u zraku dana je u stupcu `Ozone`. Na nivou značajnosti od 5% provjerite razlikuje li se dnevna razina ozona po mjesecima.

## 6. Friedmanov test

- ▶ Generalizacija Wilcoxonovog testa rangova za dva uzorka na više uzoraka
- ▶ Niz uređenih  $k$ -torki je nezavisan (moguća zavisnost među  $k$ -torkama)
- ▶ Pogodan model za promatranje jedne *jedinke* kroz više nivoa *tretmana* (tj. jednak broj mjerenja za svaki uzorak)

## Procedura

Promatramo  $k$  uzoraka:  $X_1^{(i)}, \dots, X_n^{(i)}$ ,  $i = 1, \dots, k$  iste duljine.

- ▶ Uredimo svaki od uzoraka zasebno,  $X_{(1)}^{(i)}, \dots, X_{(n_i)}^{(i)}$ ,  $i = 1, \dots, k$
- ▶ Odredimo rangove  $R_i^{(j)}$  za svaki  $X_i^{(j)}$  unutar **pojedinih** uređenih uzorka
- ▶ Odredimo sumu rangova po uzorcima

$$R^{(j)} = \sum_{i=1}^n R_i^{(j)}$$

te Friedmanovu statistiku

$$\begin{aligned} S &= \frac{12}{nk(k+1)} \sum_{j=1}^k \left( R^{(j)} - \frac{n(k+1)}{2} \right)^2 = \\ &= \frac{12}{nk(k+1)} \sum_{j=1}^k (R^{(j)})^2 - 3n(k+1) \end{aligned}$$

- ▶ Kritično područje testa je  $K = \{H > a_\alpha\}$  gdje je  $a_\alpha$  kvantil razdiobe statistike  $S$
- ▶ Egzaktna distribucija statistike  $S$  izračunata je za male  $n$  i  $k$ , za veće vrijednosti koristi se aproksimacija  $\chi^2(k)$  distribucijom.

## Zadatak 7. - Benzin

U datoteci `gasoline.txt` nalaze se podaci o prijeđenoj kilometraži četiri modela automobila za tri marke benzina. Na razini značajnosti 2% testirajte postoji li značajna razlika u trima markama benzina.

Koristimo naredbu `friedman.test` u R-u.