

NEPARAMETARSKA STATISTIKA

STATISTIČKI PRAKTIKUM 2

Zašto neparametarska statistika?

- ▶ skup testova i metoda
- ▶ provodimo statističku analizu podataka bez rigoroznih pretpostavki na distribuciju populacije (moguće manje restriktivne pretpostavke npr. diskretna ili neprekidna distribucija podataka, simetrična razdioba i sl.)
- ▶ 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, odnosno uzorku dobivenom sortiranjem početnog niza).

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 (ili ako varijanca nije konačna).

Ukoliko želimo dobiti egzaktne 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.

Pouzdaní interval za medijan

Medijan M je često promatrana vrijednost u neparametarskom okruženju (budući da, za razliku od aritmetičke sredine, nije jako osjetljiv na ekstremne podatke).

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

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

Na temelju varijable N^- konstruiramo pouzdani interval.

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

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

Ovu metodu možemo primijeniti i na ostale kvantile distribucije, uz $\#\{i : X_i < Q_p\} \sim B(n, p)$.

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 θ).

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 θ 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.

Test neosjetljiv na outliere.

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 α 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 R naredbu

```
binom.test( x, n, p = 0.5,  
            alternative = c("two.sided", "less", "greater"),  
            conf.level = 0.95 )
```

3. Wilcoxonov test za jednakost 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. On će uzeti u obzir veličinu odmaka od m_0 , ali sada imamo dodatne pretpostavke na distribuciju.

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* (za male n distribucija se može izračunati egzaktno, za $n > 12$ ju aproksimiramo CGT-om).

U R-u koristimo naredbu

```
> wilcox.test(x, y = NULL,  
              alternative = c("two.sided", "less", "greater"),  
              mu = 0, 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 testirati razliku između te dvije nezavisne populacije, odnosno provjeriti hipotezu da su populacije jednake:

$$H_0 : F = G.$$

Rangovi

Neka je $n := n_1 + n_2$.

Označimo združeni uzorak

$$\begin{aligned}Z_1 &:= X_1, \dots, Z_{n_1} := X_{n_1} \\ Z_{n_1+1} &:= Y_1, \dots, Z_n := Y_{n_2}.\end{aligned}$$

Neka su

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

uređene statistike.

Definiramo nove slučajne varijable $R_1, R_2, \dots, R_n$ kao rangove podataka u združenom uzorku.

Rangovi

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

$\vdots$

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

$\vdots$

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 $R_{n_1+1} = k_{n_1+1}$.

$\vdots$

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

Wilcoxonova statistika

Wilcoxonovu statistiku definiramo kao zbroj rangova drugog uzorka

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

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

Za $1 \leq s_1 < s_2 < \cdots < s_{n_2} \leq n$ vrijedi

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

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

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

pa p-vrijednosti i kritična područja dobivamo iz normalne distribucije.

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_i .

Sada se definiraju $S_1^*, \dots, S_{n_2}^*$ uređene statistike od $R_{n_1+1}^*, \dots, R_n^*$.

Prirodno se poopćuje Wilcoxonova statistika

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

čiju je distribuciju sada teže urediti pa odmah prelazimo na Mann-Whitney statistiku U^* .

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 istom 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.

Dakle, sada imamo uzorke za X i Y koji nisu više nezavisni.

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

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

Testiramo nultu hipotezu

$$H_0 : F_X = F_Y.$$

Nulta hipoteza je ekvivalentna hipotezi da je medijan distribucije razlika $\{Z_i\}$ jednak 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 izračunat distribuciju V -a za male n .

Što ako distribucije nisu neprekidne

Ako distribucije nisu neprekidne, može se dogoditi da imamo $|Z_i|$ s istim vrijednostima.

1. Neka je R_i^* podijeljen rang od $|Z_i|$ (promatramo samo vrijednosti $|Z_k|$ koje su različite od nule).
2. Tada je Wilcoxova 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 $K = \{H > \chi_{\alpha}^2(k-1)\} = [\chi_{\alpha}^2(k-1), \infty)$.

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.

Koristimo naredbu `kruskal.test` na podacima koji su spremljeni u *listu*.

```
> attach(airquality)
> lista <- list(Ozone[Month==5], Ozone[Month==6],
               Ozone[Month==7], Ozone[Month==8], Ozone[Month==9])
> kruskal.test(lista)
```

Kruskal-Wallis rank sum test

```
data: lista
Kruskal-Wallis chi-squared = 29.267, df = 4,
p-value = 6.901e-06
```

ili

```
> kruskal.test(Ozone~Month, data=airquality)
```

Postupanje s nedostupnim podacima (NA) odredimo naredbom `na.action`.

7. Friedmanov test

- ▶ Generalizacija Wilcoxonovog testa rangova za dva uzorka na više uzoraka
- ▶ Imamo uparene podatke u k uzoraka - zavisnost
- ▶ 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)
- ▶ Ako postoji razlika između barem 2 uzorka - tretman ima značajni efekt

Procedura

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

- ▶ Uredimo svaki od uzoraka zasebno, $X_{(1)}^{(i)}, \dots, X_{(n)}^{(i)}$, $i = 1, \dots, k$
- ▶ Odredimo rangove $R_i^{(j)}$ za svaki $X_i^{(j)}$ unutar **pojedinih** uređenog 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_α 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.

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