

Modeli s ponovljenim mjeranjima. MANOVA

STATISTIČKI PRAKTIKUM 2

Do sada

1. $Y = \alpha_0 + \alpha_1 x_1 + \cdots + \alpha_p x_p + \varepsilon, \quad \varepsilon \sim N(0, \sigma^2), x_1, \dots, x_p$ kvantitativne varijable prediktori
2. prediktori mogu biti i faktorske varijable (paralelni pravci), npr.
$$Y = \alpha_0 + \alpha_1 x_1 + \alpha_2 d_1 + \alpha_3 d_2 + \varepsilon$$
3. uvodimo interakciju između prediktora
$$Y = \alpha_0 + \alpha_1 x_1 + \alpha_2 d_1 + \alpha_3 d_2 + \alpha_4 x_1 d_1 + \alpha_5 x_1 d_2 + \varepsilon$$
4. generalizirani linearni modeli (dozvoljavamo ne-Gaussovsku i diskretnu strukturu varijable Y)
5. Y višedimenzionalna, prediktori x_1, \dots, x_k utječu na cijeli niz varijabli

Analiza varijance ponovljenih mjerena

Dizajn analize varijance u kojima se provode ponovljena mjerena (različiti tretmani) na istim subjektima čime se postiže ekonomičnost (na jednom subjektu se primjenjuje više tretmana - trebamo manje subjekata) te se grešku na svakom subjektu može bolje objasniti (imamo više informacija).

Kao i ranije, imamo prepostavku nezavisnosti unutar jednog ponavljanja te prepostavku nezavisnosti između subjekata (ljudi), dok je očito da će postojati korelacija unutar bloka odnosno da će različita mjerena nad istim subjektom biti povezana - tu variabilnost ćemo moći bolje objasniti.

Model je *balansiran* ako za svakog subjekta imamo mjerena na svim razinama.

Jednofaktorski model s ponavljanim mjeranjima

Model je sljedeći:

$$X_{i,j} = \mu + \xi_i + \delta_j + \varepsilon_{i,j},$$

gdje je

- ▶ μ .. ukupna aritmetička sredina
- ▶ ξ_i .. efekt subjekta (definira osobu koju promatramo), donosi varijabilnost između subjekata (zato što su promatrani subjekti različiti)
- ▶ δ_j .. efekt j -tog tretmana, donosi varijabilnost unutar svakog subjekta
- ▶ $\varepsilon_{i,j}$.. greška, normalno distribuirana

Prepostavke:

1. *normalnost*: za svaki nivo tretmana, greške su normalno distribuirane, a sami nivoi imaju multivarijatnu normalnu razdiobu (tj. ponovljena mjerena za svaki subjekt možemo promatrati kao model s multivarijatnom normalnom razdiobom)
2. *homogenost*: greške su jednakom distribuirane (s očekivanjem 0 i konstantnom varijancom), a za svaki subjekt, varijanca razlike između svaka dva podatka je konstantna (sferičnost kovarijacijske matrice)
3. *nezavisnost*: subjekti su međusobno nezavisni (i odabrani su na slučajan način) te su razlike između sredina po nivoima tretmana međusobno nezavisne

Primjer

Provedeno je istraživanje o utjecaju 4 vrste lijeka na čovjeka. U istraživanju je sudjelovalo 5 ljudi. Nakon što im je dan lijek, mjereno je koliko im je vremena potrebno da obave niz standardiziranih fizičkih radnji koje su im prije objašnjene. Podaci se nalaze u datoteci `lijekovi.txt`. Imamo 5 osoba i 4 lijeka, ukupno 20 podataka. Dizajn je balansiran.

Koristeći naredbu `aov` testirajte efekt lijeka na sposobnosti čovjeka.

Rješenje

```
> lijekovi = read.table("lijekovi.txt", header=T)
> lijekovi$lijek = as.factor(lijekovi$lijek)
> lijekovi$osoba = as.factor(lijekovi$osoba)

> model1 = aov(vrijeme ~ lijek + Error(osoba/lijek),
   data=lijekovi)
```

```
> summary(model1)
```

Error: osoba

Df	Sum Sq	Mean Sq	F value	Pr(>F)
Residuals	4	680.8	170.2	

Error: osoba:lijek

Df	Sum Sq	Mean Sq	F value	Pr(>F)
lijek	3	698.2	232.7	24.76 1.99e-05 ***
Residuals	12	112.8	9.4	

Dakle, postoji značajna razlika među tretmanima (tj. utjecaj lijeka je značajan).

Također, moguće je provesti i test značajnosti modela (kao i ranije) čija je p-vrijednost jako mala pa možemo zaključiti da je model značajan.

Error(subject/value) ... razdvaja podatke za svaku osobu, tj. definira podatke koji pripadaju istoj osobi kroz varijablu subject (tipa factor)

Ako želimo izračunati očekivanja za svaku razinu djelujućeg faktora (odnosno ako nas zanima kako pojedina razina faktora utječe na zavisnu varijablu), možemo koristiti naredbu

```
> model.tables(model1, "means")
```

```
Tables of means
```

```
Grand mean
```

```
24.9
```

```
lijek
```

```
lijek
```

	1	2	3	4
--	---	---	---	---

26.4	25.6	15.6	32.0
------	------	------	------

Dvofaktorski model s ponavljanim mjeranjima

Model je sljedeći:

$$X_{i,j} = \mu + \xi_i + \delta_j + \xi\delta_{i,j} + \varepsilon_{i,j},$$

gdje je $\xi\delta_{i,j}$ interakcija između dva faktora i mjeri je li utjecaj faktora δ konstantan za svaku osobu.

U ovom slučaju bismo pokrenuli naredbu aov slično kao ranije: nezavisne varijable povezujemo veznikom *, a kroz faktor Error reguliramo rezultate koji su dobiveni za istu osobu.

MANOVA

MANOVA služi za provođenje statističkih testova s više od jedne zavisne varijable. Radi se o tzv. *analizi nezavisnosti*, odnosno, testira se pretpostavka o uzročno–posljedičnoj vezi između 1 ili više prediktora i 2 ili više varijabli odaziva.

Test MANOVA je u principu generalizacija tzv. jednofaktorske ili dvofaktorske ANOVE.

Neka imamo p promatralih zavisnih varijabli (obilježja) Y_1, \dots, Y_p na koje djeluje nezavisna faktorska varijabla sa s razina. Za svaku razinu faktora i promatramo n_i subjekata i za svakog od njih mjerimo svih p obilježja, tj. imamo uzorak oblika $Y_{i,j,k}$, gdje je $i = 1, \dots, s, j = 1, \dots, n_i$, a $k = 1, \dots, p$.

Promatrani slučajni vektori $Y_{i,j}$ moraju zadovoljavati uobičajene pretpostavke:

1. $Y_{i,1}, \dots, Y_{i,n_i}$ imaju multivarijatnu normalnu razdiobu, za $i = 1, \dots, s$ (jer su $\varepsilon_{i,j} \sim N(0, \Sigma)$)
2. sva mjerena su međusobno nezavisna.

Testiramo hipotezu:

$$H_0 : \mu_1 = \dots = \mu_s$$

H_a : barem dvije aritmetičke sredine su različite

Primjer

Provedena je kemijska analiza 26 posuda pronađenih u iskapanjima u Velikoj Britaniji na 4 različita mjesta. Podaci su dani u datoteci pottery.txt. Analizirao se postotak nekoliko vrsta metala u svakoj posudi. Možemo li tvrditi da mjesto pronalaska posude utječe na kemijski sastav posude?

Rješenje

```
> podaci = read.table("pottery.txt", header=T)

> mod2 = manova(cbind(Al,Fe,Mg,Ca,Na) ~ Site,
                 data=podaci)
> summary(mod2)

Df Pillai approx F num Df den Df      Pr(>F)
Site       3 1.5539   4.2984     15      60 2.413e-05 ***
Residuals 22
```

Za testiranje prepostavki modela možemo koristiti ranije naučene metode (npr. Bartlettov test za homogenost varijanci).