

## Multivarijatna analiza podataka

Mladen Petrovečki  
Martina Mavrinac



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

## Multivarijatna analiza podataka

- statistička obradba podataka:
  - univarijatna
  - bivarijatna
  - multivarijatna



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Multivarijatni modeli

- multivarijatni ili multidimenzionalni modeli, engl. *multivariate*
  - najmanje dvije zavisne varijable (varijate)
  - broj veza među pokazateljima (m):
    - $m = k(k-1)/2 \Leftrightarrow (k = \text{broj pokazatelja})$
    - npr. osam pokazatelja ( $m = 8 \Rightarrow k = 28$ )
- dvosmjerna analiza varijance
- višestruka regresijska analiza, logistička regresija, Coxov regresijski test
- diskriminacijska analiza
- faktorska analiza
- klasterska analiza
- meta-analiza



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Dvosmjerna analiza varijance

- dvosmjerna ANOVA
- npr. analiza vrijednosti glukoze prema dobnim skupinama i spolu ispitanika:
  - razina glukoze (mmol/L)
  - dobna skupina ( $<20, 20-50, >50$  god.)
  - spol (M, Ž)
- uvijek
  - jedan brojčani pokazatelj  $\Leftrightarrow$  zavisni
  - dva skupna pokazatelja  $\Leftrightarrow$  nezavisni



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Multipla regresijska analiza

- linearna matematička povezanost više pokazatelja
  - $x_1-x_n \Leftrightarrow$  nezavisne varijable (prediktori)
  - $y \Leftrightarrow$  zavisna brojčana varijabla (kriterij)
- koliko promjena svakog x određuje promjenu y:  
$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n$$
- kolinearnost – pojava visoke korelacije nezavisnih varijabla (loš!)
- R – multipli koeficijent korelacija
- $R^2$  – multipli koeficijent determinacije



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Posebnosti multiple regresije

- postupci odabira pokazatelja u završnu jednadžbu (*model building*):
  - svi (*all, enter*)
  - biranje sprjeda (*forward selection*)
  - unatražno isključivanje (*backward elimination*)
  - postepeno biranje (*stepwise selection*)
  - sve moguće s traženjem najvećeg  $R^2$
- polinomska multipla regresija:  
$$y = b_0 + b_1x + b_2x^2 + \dots$$



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Primjer

- povezanost TIBC (*total iron binding capacity*) s UIBC (*unsaturated iron binding capacity*), Fe, feritinom i dobi ispitanika
- statistička obradba podataka:
 

| Parametar | b <sub>0</sub> | b <sub>1</sub> | t      | P |
|-----------|----------------|----------------|--------|---|
| konstanta | 4,5±4,3        | 0,96           | 0,341  |   |
| UIBC      | 0,8±0,1        | 11,68          | <0,001 |   |
| Fe        | 1,0±0,1        | 11,01          | <0,001 |   |
| feritin   | 0,01±0,01      | 0,31           | 0,760  |   |
| dob       | 0,01±0,03      | -0,97          | 0,338  |   |
- N = 87; P = 0,027; R = 0,38; R<sup>2</sup> = 0,144
- TIBC = 0,8×UIBC + 1×Fe (matematički)
- TIBC = 0,8±0,1×UIBC + 1±0,1×Fe (statistički)



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Logistička regresija

- povezanost više pokazatelja:
  - x<sub>1</sub>-x<sub>n</sub> ⇒ nezavisne varijable (prediktori)
  - y ⇒ binarna zavisna brojčana varijabla (binarni kriterij)
- međusobno nezavisna mjerena
- koliko promjena svakog od x određuje promjenu binarne varijable y:
$$\log(p) = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n$$
- e<sup>b</sup> = omjer izgleda (OR, *odds ratio*)



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Primjer

- odnos TIBC (*total iron binding capacity*), UIBC (*unsaturated iron binding capacity*), Fe, feritina i dobi ispitanika sa spolom ispitanika
- statistička obradba podataka:
 

| Param.  | b     | SE(b) | P     | OR (95% CI)        |
|---------|-------|-------|-------|--------------------|
| konst.  | 1,60  | 0,49  | 0,003 |                    |
| TIBC    | 0,05  | 0,09  | 0,563 |                    |
| UIBC    | -0,05 | 0,09  | 0,615 |                    |
| Fe      | -0,03 | 0,11  | 0,757 |                    |
| feritin | -0,02 | 0,01  | 0,006 | 0,98 (0,96 – 0,99) |
| dob     | -0,02 | 0,02  | 0,421 |                    |



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Coxov regresijski test

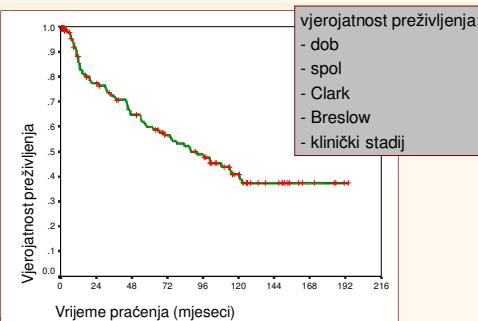
- povezanost više pokazatelja:
  - x ⇒ nezavisne varijable (prediktori)
  - y ⇒ zavisna varijabla (kriterij) = mjera rizika
- međusobno nezavisna mjerena
- koliko promjena x određuje y:
$$\lambda_i(t) = \lambda_0(t) \exp(b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n)$$
- e<sup>b</sup> = omjer rizika (RH, *relative hazard*)



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Primjer (polipoidni melanom)



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Primjer

- odnos dobi i spola bolesnika te kliničkog stadija melanoma i stadija po Breslowu
- statistička obradba podataka:
 

| Param.   | b    | SE  |
|----------|------|-----|
| spolm    | 0,02 | 0,0 |
| klin_st  | 1,75 | 0,3 |
| (1)      | 3,70 | 0,5 |
| clark_st |      |     |
| bres_st  |      |     |



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Diskriminacijska analiza

- metoda klasifikacije ispitanika ili objekata po skupinama
- analiza varijabli koje razlikuju (diskriminiraju) dvije ili više skupina ispitanika
  - utvrđuje koje se skupine razlikuju u odnosu na aritmetičke sredine određenih varijabla
- uporaba: predviđanje nominalne ili kategoričke varijable
- primjer:
  - prikupljaju se podaci o načinu života i obiteljskoj anamnezi pušača na odvikanju od pušenja
  - razlog: ustvrditi koje će varijable najbolje predvidjeti:
    - potpuni prestanak pušenja (skupina 1)
    - smanjenje broja popušenih cigareta (skupina 2)
    - nepromjenjenu učestalost pušenja (skupina 3)



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Faktorska analiza

- skup statističko-matematičkih postupaka s pomoću kojih se raščlanjuje povezanost između većeg broja varijabli s ciljem da se:
  - smanji broj varijabli
  - odredi faktorska struktura
- sve varijable su nezavisne
- dva modela faktorske analize:
  - eksplanatorni – opisuje međusobnu povezanost varijabli sa faktorom
  - konfirmatorni – potvrđuje ili odbacuje hipoteze ili modele povezanosti



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Primjer

- oblikuje se upitnik o korištenju dopunskog zdravstvenog osiguranja (DZO)
  - sadrži 20 čestica (pitanja, varijabla, engl. item)
  - testiranje: ispunjava ga N = 200 ispitanika
- izračunaju se korelacije među česticama
- odrede se logička grupiranja
  - npr. grupiranje u dvije skupine (dvo-faktorska struktura)
- obrađba podataka o korelacionima  $\Rightarrow$  cilj: dobivanje linearnih kombinacija, tj. faktora, npr.:
  - faktor 1 = prednosti DZO
  - faktor 2 = nedostaci DZO
- određuje se broj čestica dovoljan za tumačenje pojedinih faktora
  - npr. 5 čestica za svaki faktor



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Primjer, rezultat

- upitnik o prednostima i nedostacima dopunskog zdravstvenog osiguranja
- deset čestica na dva faktora
  - broj čestica određen je uvjetom povezanosti čestica i faktora
  - engl. *factor loading*
  - istovjetan koeficijentu korelacije r
  - npr.  $r > 0,54$
  - rezultat  $\Rightarrow$

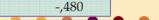
| Čestice | Komponenta 1 | Komponenta 2 |
|---------|--------------|--------------|
| v7      | .767         |              |
| v8      | .661         |              |
| v3      | .585         |              |
| v16     | .549         |              |
| v10     | .541         |              |
| v19     | .527         |              |
| v18     | .510         |              |
| v15     | .502         |              |
| v4      | .474         |              |
| v20     | .444         |              |
| v5      | .358         |              |
| v17     | .345         |              |
| v14     | .305         |              |
| v9      |              | .719         |
| v11     |              | .698         |
| v12     |              | .691         |
| v13     |              | .666         |
| v2      |              | .553         |
| v6      |              | .518         |
| v1      |              | -.480        |

faktor 1

faktor 2



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Klusterska analiza

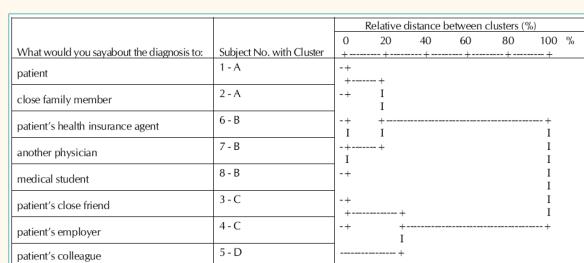
- postupak klasifikacije pojedinaca ili objekata u skupine
- ne zahtjeva poznavanje skupina pripadnosti niti konačni broj skupina (kao diskriminacijska analiza)
- pronalazi sličnosti kod ispitanika po kojima ih svrstava u skupine, ne tumači zašto
- sve varijable su nezavisne
- grafički prikaz klastera  $\Rightarrow$  dendrogram
- primjer:
  - što reći o dijagnozi neizlječive bolesti: istinu, laž ili prešutjeti odgovor?
  - kome: bolesniku, njegovu prijatelju, kolegi, poslodavcu, članu obitelji, povjereniku zdravstvenog osiguranja, drugom liječniku, studentu medicine?



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Primjer, dendrogram



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Meta-analiza

- zdrživanje srodnih rezultata više nezavisnih istraživanja istog sadržaja
- podrijetlo statističkog postupka  $\Rightarrow$  analiza sustavnih preglednih članaka
- tehnika: Gene V. Glass, 1977.
- temeljne mogućnosti:
  - povećanje statističke snage povećanjem broja ispitanika
  - jasnija procjena utjecaja istraživanog čimbenika
  - razrješenje nesigurnih spoznaja
  - odgovaranje na pitanja koja izvorne studije ne postavljaju
- Cochrane Database of Systematic Reviews
  - najpoznatija kolekcija cjelovitih radova koji rabe meta-analizu
  - sadrži više od 4.800 radova



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Postupci meta-analize

- analiza proporcija – omjer izgleda
  - hipoteza (usporedba proporcija): omjer izgleda (OR, *odds ratio*) nije značajno različit među studijama
- test heterogenosti (*heterogeneity test*)
  - $P \geq \alpha$  (npr.  $P \geq 0,05$ )  $\Rightarrow$  studije su homogene  $\Rightarrow$  model utvrđenog učinka (*fixed effects model*)
  - $P < \alpha$   $\Rightarrow$  studije bi mogle biti heterogene  $\Rightarrow$  model slučajnog učinka (*random effects model*)
- testiranje  $H_0$ : Mantel-Haenszelov test
- analiza brojčanih podataka – standardizirana razlika
  - hipoteza (usporedba prosječnih vrijednosti): standardizirana razlika prosjeka (SMD, *standardized mean difference*) nije značajno različita među studijama
  - test heterogenosti (v. gore)
  - testiranje: Hedgesov g-test

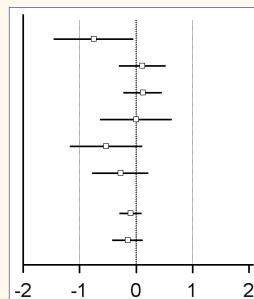


Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Grafički prikaz

- trakasti grafikon
  - forest plot*
  - blobbogram*
  - grafikon granica pouzdanosti



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Primjer 1: OR (podatci)

- djelovanje antibiotika A u liječenju upale paranasalnih sinusa specifičnim uzročnikom B u ljudi
- pretraživanje literature (antibiotik A, upala paranasalnih sinusa, uzročnik B):
  - 214 istraživanja
  - 24 komparativna istraživanja u ljudi
  - 12 kontroliranih kliničkih pokusa
  - 5 cjelovitih pregleda svih efekata liječenja
- temeljni rezultati istraživanja:

| Oznaka | N <sub>sk</sub> | EF <sub>sk</sub> | N <sub>kont</sub> | EF <sub>kont</sub> |
|--------|-----------------|------------------|-------------------|--------------------|
| 12     | 73              | 15               | 23                | 3                  |
| 14     | 35              | 7                | 32                | 2                  |
| 59     | 20              | 8                | 20                | 2                  |
| 174    | 12              | 3                | 10                | 1                  |
| 197    | 42              | 6                | 42                | 3                  |

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Primjer: OR

| No.      | Skupina | Kontrola | OR (95% CI)          |
|----------|---------|----------|----------------------|
| 12       | 15/73   | 3/23     | 1,724 (0,452–6,583)  |
| 14       | 7/35    | 2/32     | 3,750 (0,717–19,599) |
| 59       | 8/20    | 2/20     | 6,000 (1,082–33,275) |
| 174      | 3/12    | 1/10     | 3,000 (0,260–34,576) |
| 197      | 6/42    | 3/42     | 2,167 (0,504–9,312)  |
| $\Sigma$ | 39/182  | 11/127   |                      |

Utvrđen učinak (*fixed effect*) 2,806 (1,363–5,778)

Slučajni učinak (*random effect*) 2,781 (1,347–5,744)

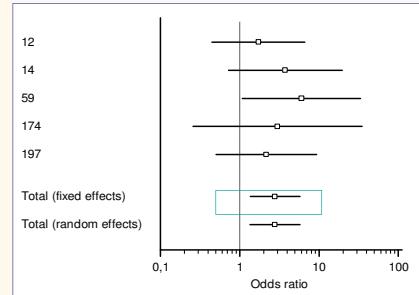
Test heterogenosti:  $Q = 1,506$ ; DF = 4;  $P = 0,826$



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Primjer: grafički prikaz OR



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Primjer 2: SMD (podatci)

- djelovanje dvaju hipoglikemika A (noviji) i B (tradicionalni) na snižavanje koncentracije glukoze u krvi
- pretraživanje literaturе (hipoglikemik A, hipoglikemik B, glukoza u krvi, hiperglikemija, dijabetes):
  - 180 istraživanja
  - 54 komparativna istraživanja u ljudi
  - 9 kontroliranih kliničkih pokusa
  - 6 cjelovitih pregleda svih efekata liječenja
- temeljni rezultat istraživanja (glukoza, mmol/L):

| Ozn. | N <sub>sk</sub> | X ± SD    | N <sub>kont</sub> | X ± SD    |
|------|-----------------|-----------|-------------------|-----------|
| 1    | 19              | 4,7 ± 1,2 | 17                | 5,9 ± 1,9 |
| 2    | 45              | 4,9 ± 1,6 | 47                | 4,7 ± 1,9 |
| 3    | 67              | 5,2 ± 2,1 | 67                | 4,9 ± 2,8 |
| 4    | 20              | 4,4 ± 0,9 | 20                | 4,4 ± 1,8 |
| 5    | 24              | 4,6 ± 1,8 | 18                | 5,6 ± 1,9 |
| 6    | 32              | 4,9 ± 2,1 | 33                | 5,5 ± 2,2 |

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Primjer: SMD

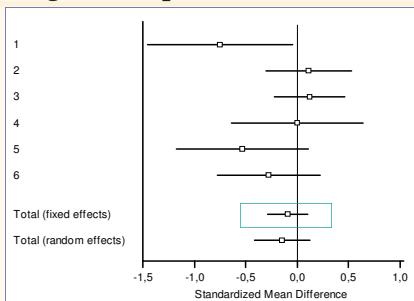
| No. | N <sub>1</sub> | N <sub>2</sub> | Σ   | SMD (95% CI)               |
|-----|----------------|----------------|-----|----------------------------|
| 1   | 19             | 17             | 36  | -0,748 (-1,452 do -0,0434) |
| 2   | 45             | 47             | 92  | 0,113 (-0,302 do 0,527)    |
| 3   | 67             | 67             | 134 | 0,121 (-0,222 do 0,463)    |
| 4   | 20             | 20             | 40  | 0,000 (-0,640 do 0,640)    |
| 5   | 24             | 18             | 42  | -0,532 (-1,174 do 0,110)   |
| 6   | 32             | 33             | 65  | -0,276 (-0,774 do 0,223)   |
| Σ   | 207            | 202            | 409 |                            |

Utvrdeni učinak -0,093 (-0,288 do 0,103)  
 Slučajni učinak -0,147 (-0,415 do 0,122)  
 Test heterogenosti: Q = 8,599; DF = 5; P = 0,1262

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Primjer: grafički prikaz SMD



Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku



## Podatci u primjerima

- Šimundić AM, ur. Osnove biostatistike u svakodnevnoj praksi – tečaj trajnog usavršavanja medicinskih biokemičara, priručnik. Medicinska naklada, Zagreb, 2008.
- Knežević F, Petrovečki M, Šeparović V. Histological types of polypoid cutaneous melanoma. Croat Med J 1992;33:220-4.
- Statistical methods for multiple variables. U: Dawson-Saunders B, Trapp RG. Basic & clinical biostatistics. Lange Medical Books/McGraw-Hill, New York – Toronto, 2004. Str. 245-279.
- MedCalc for Windows, Statistics for biomedical research – Software manual v 11.2. MedCalc Software, Mariakerke, 2010.
- Patrick Holford and His Own Reality: Part 1, the blobbogram. Dostupno sa: <http://holfordwatch.info/2008/04/10/patrick-holford-and-his-own-reality-part-1-the-blobbogram/>.
- Pulanić D, Vražić H, Čuk M, Petrovečki M. Ethics in Medicine: Students' Opinions on Disclosure of True Diagnosis. Croat Med J 2002;43(1):75-79.

Medicinski fakultet Sveučilišta u Rijeci Katedra za medicinsku informatiku

