

## Usporedba kvalitativnih podataka

Nora Nikolac  
Klinički zavod za kemiju  
KB "Sestre milosrdnice"

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu  
Biostatistika  
17.-19.11.2010.

 Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

### Što računamo...

- Deskriptivna analiza podataka
- Ispitivanje povezanosti među skupinama
- Ispitivanje postojanja razlike među skupinama



Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## Kvalitativni podaci

- Nominalni - ne uspoređuju se!

Spol		M = 1
		Ž = 0

- Ordinalni - mogu se uspoređivati!

Ocjene		= 1, 2, 3, 4, 5
		= A, B, C, D, E, F

 Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

### Statistička hipoteza - postupak testiranja

1. postavljanje hipoteze:  $H_0, H_1$
2. odabir statističkog testa
3. određivanje razine značajnosti:  $\alpha$
4. izračunavanje
5. zaključivanje: P



Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## 1. Postavljanje hipoteze

**Nulta hipoteza  $H_0$**  - **nema** statistički značajne razlike među skupinama

Ukoliko se odbaci nulta hipoteza, prihvata se alternativna hipoteza

**Alternativna hipoteza  $H_1$**  - **postoji** statistički značajna razlika među skupinama

 Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## 2. Odabir statističkog testa

- Za pravilan odabir testa moramo poznavati podatke koje testiramo:
  - Parni/Neparni uzorci
  - Broj skupina
  - Veličina uzorka



Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

Kvalitativni podaci

Nezavisni (Neparni)

Zavisni (Parni)

2 skupine:  
Hi-kvadrat test  
Fisherov egzaktni test3 i više skupina:  
Hi-kvadrat test

Parni Hi-kvadrat test (McNamerv test)

### 3. Određivanje razine značajnosti

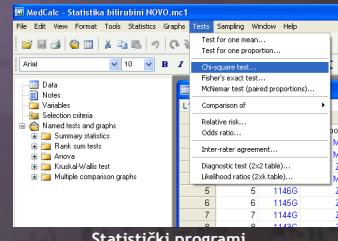
Značenje razine značajnosti:  
vjerojatnost odbacivanja istinite  $H_0$ .

- Najčešće:  $\alpha$  - razina značajnosti: 0,05
- Kod preliminarnih istraživanja može se odabratи veća razina značajnosti: 0,1 ili 0,2
- Kod pojedinih istraživanja razina značajnosti može biti i manja: 0,01 ili 0,001



Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

### 4. Izračunavanje



Ručno

Statistički programi



Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

### 5. Zaključivanje

$P > 0,05$  (ili druga postavljena razina značajnosti)



Prihvaćamo nultu hipotezu i zaključujemo:

Ne postoji statistički značajna razlika među skupinama



Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

### 5. Zaključivanje

$P < 0,05$  (ili druga postavljena razina značajnosti)



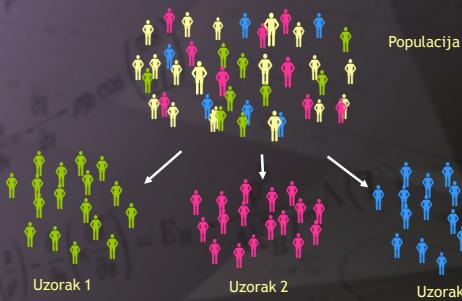
Odbacujemo nultu hipotezu, prihvaćamo alternativnu hipotezu i zaključujemo:

Postoji statistički značajna razlika među skupinama



Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

### Nezavisni uzorci



Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

### $\chi^2$ test

Ispitivanje razine značajnosti razlike između:

- Očekivane razdiobe podataka i dobivenih podataka (npr. genetika);
- Dviju ili više skupina nezavisnih kvalitativnih podataka.



Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## Ručni izračun parametara $\chi^2$ testa

- Izračun očekivanih frekvencija
- Izračun  $\chi^2$  vrijednosti
- Određivanje stupnjeva slobode (DF, engl. *degree of freedom*)
- Iščitavanje  $\chi^2$  vrijednosti za određenu razinu značajnosti
- Zaključivanje



Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## Kontingencijska tablica

Ispitivali smo razliku prema spolu između dvije skupine ispitanika. U prvoj je skupini od 120 ispitanika bilo 30% muškaraca, a u drugoj od 140 ispitanika 60% žena.

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## Kontingencijska tablica

	Skupina 1	Skupina 2	Ukupno
Muškarci	36	56	92
Žene	84	84	168
Ukupno	120	140	260

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## 1. Izračun očekivanih frekvencija

Svarne frekvencije			
	Skupina 1	Skupina 2	Ukupno
Muškarci	36	56	92
Žene	84	84	168
Ukupno	120	140	260

Očekivane frekvencije			
	Skupina 1	Skupina 2	Ukupno
Muškarci	42	50	92
Žene	78	90	168
Ukupno	120	140	260

M skupina 1  $0,354 \times 120 = 42$  M skupina 2  $0,354 \times 140 = 50$   
 Ž skupina 1  $0,646 \times 120 = 78$  Ž skupina 2  $0,646 \times 140 = 90$

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## 2. Izračun $\chi^2$ vrijednosti

$$\chi^2 = \sum [(f_{stv} - f_{oček})^2 / f_{oček}]$$

	f(stv)	f(oček)	f(stv) - f(oček)	$[f(stv) - f(oček)]^2 / f(oček)$
M (Skupina 1)	36	42	-6	36
M (Skupina 2)	56	50	6	36
Ž (Skupina 1)	84	78	6	36
Ž (Skupina 2)	84	90	-6	36

$\chi^2 = 2,4$

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## 3. Stupnjevi slobode

$$DF = (r-1) \times (s-1)$$

R = broj redaka; s = broj stupaca

$$DF = (2-1) \times (2-1) = 1$$

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## 4.Iščitavanje $\chi^2$ vrijednosti iz tablice

Iz tablice iščitamo  $\chi^2$  vrijednost za odabranu razinu značajnosti i odgovarajući broj stupnjeva slobode.

df	1,34	6,64	10,83
1	2,20	9,21	13,83
2	7,82	11,33	16,27
3	9,49	13,28	18,47
4	11,07	15,09	20,52
5	12,59	16,81	22,46

$\alpha = 0,05$   
 $DF = 1$   
 $\chi^2(\alpha) = 3,84$

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## 5.Zaključivanje

Ako je  $\chi^2 < \chi^2(\alpha)$   
 Prihvaćamo  $H_0$

Ako je  $\chi^2 > \chi^2(\alpha)$   
 Odbacujemo  $H_0$   
 Prihvaćamo  $H_1$

$\chi^2 = 2,4 < \chi^2(\alpha) = 3,84$

Ne postoji statistički značajna razlika u raspodjeli muškaraca i žena između skupina 1 i 2.

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## A može i jednostavnije...

$P = 0,1209 (P > 0,05)$

Prihvaćamo  $H_0$  i zaključujemo da nema statistički značajne razlike među skupinama.



Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## Dodatni uvjeti $\chi^2$ testa

Sve očekivane frekvencije moraju biti  $> 1$   
 Najviše 20% očekivanih frekvencija  $< 5$   
 Ukupan broj uzoraka  $> 100$

28	39	58	12	24
23	45	23	4	14
12	2	12	2	18

2 x 2 tablica      3 x 3 tablica  
 4 očekivane frekvencije  
 $20\% = 0,2 \times 4 = 0,8 \sim 1$       9 očekivanih frekvencija  
 $20\% = 0,2 \times 9 = 1,8 \sim 2$

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## Primjer pogrešne upotrebe testa

Postoji li razlika u učestalosti pojave bolesti između ispitanika koji su primili cjepivo i onih koji nisu?

	Cijepljenje -	Cijepljenje +
Bez bolesti	65	120
Bolest	7	3

$\chi^2$  test:  $P = 0,059$

Fisherov egzaktni test:  $P = 0,040$

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## Fisherov egzaktni test

Test za ispitivanje razine značajnosti razlike između dviju skupina nezavisnih kategoričkih podataka.  
 Koristi se kod malih uzoraka ( $N < 100$ ).  
 Očekivane frekvencije mogu biti  $\leq 1$ .

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## Zavisni uzorci

Vrijeme 1      Vrijeme 2      Vrijeme 3

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## Test

**Parni  $\chi^2$  test (McNemarov test):** ispitivanje razine značajnosti razlike između dvije skupine zavisnih kategoričkih podataka.

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## McNemarov test

Utječe li kava na stanje pospanosti studenata 1. godine FBF-a na kolegiju "Biostatistika"?

		Pospanost nakon kave		Ukupno
		DA	NE	
Pospanost prije kave	DA	30	80	110
	NE	12	50	62
Ukupno	42	130	172	

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## McNemarov test

$$\chi^2 = \frac{(|B-C| - 1)^2}{B + C} = \frac{(|80-12| - 1)^2}{80 + 12} = \frac{67^2}{92} = 48,8$$

B = prije intervencije POZ, nakon intervencije NEG

C = prije intervencije NEG, nakon intervencije POZ

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## Izračunavanje

Table of Chi-square statistics

df = 1	P = 0,01	P = 0,001
3,84	6,64	10,83
2,70	9,21	13,82
3,82	11,35	16,27
4,49	13,28	18,47
5,10	15,09	20,52
6,29	16,81	22,46

Odbacujemo  $H_0$   
Prihvaćamo  $H_1$

$\alpha = 0,05$   
 $DF = 1$   
 $\chi^2(\alpha) = 3,84 < \chi^2 = 48,8$

Postoji statistički značajna razlika u pospanosti prije i poslije ispijanja kave.

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

## Zadaci

1. Ispitivali smo postoji li statistički značajna razlika u učestalosti pohadanja predavanja između studenata prve i druge godine studija FBF-a. Ishod smo klasificirali kao **redovito pohada ili ne pohada redovito**. Kojim ćemo testom ispitati značajnost razlike ako smo:

- Ispitali status redovitog pohadanja predavanja na 100 studenata prve i 100 studenata druge godine?
- Ispitali status redovitog pohadanja predavanja na 100 studenata prve godine, te nakon godinu dana ponovno isptili status redovitosti?

???

Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu Biostatistika

**Zadaci**

2. Prikazane su tablice očekivanih frekvencija za nezavisne kvalitativne podatke. Možemo li ove podatke usporediti hi-kvadrat testom?

56	37	60
24	45	12
1	12	45

16	50
12	13

56	37	60
24	45	12
4	3	2

16	50
12	21
2	24
12	45



Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu *Biostatistika*

**Pitanja**

1. Postupak testiranja statističke hipoteze.
2. O čemu ovisi izbor statističkog testa?
3. Koje je značenje razine značajnosti  $\alpha$ ?
4. Kako interpretiramo rezultat testa obzirom na dobivenu P vrijednost?
5. Kada upotrebljavamo hi-kvadrat test (uvjeti, ograničenja)?
6. Kako se izračunava broj stupnjeva slobode u kontingencijskim tablicama?
7. Kako na osnovu hi-kvadrat vrijednosti za odabranu razinu značajnosti interpretiramo rezultat hi-kvadrat testa?
8. Kada upotrebljavamo Fisherov egzaktni test?
9. Kada upotrebljavamo parni hi-kvadrat test (McNamerov test)?
10. Koje frekvencije uzimamo u obzir kod izračuna parametara parnog hi-kvadrat testa?



Farmaceutsko-biokemijski fakultet Sveučilišta u Zagrebu *Biostatistika*