

ANALIZA TABLICA KONTINGENCIJE

TABLICA KONTINGENCIJE

- tablica koja u retcima i stupcima sadrži frekvencije atributivnih obilježja
- predstavlja empirijsku razdiobu frekvencija obilježja mjerenih nominalnom ili ordinalnom ljestvicom mjerenja



TABLICA S "JEDNIM ULAZOM" (1×k)

- opažanja su klasificirana samo po jednom obilježju

PRIMJER.

GODINA STUDIJA							UKUPNO
BROJ STUDENATA	I	II	III	IV	V	VI	205
	64	48	32	28	18	15	



TABLICA S "DVA ULAZA" (r×k)

- opažanja klasificirana po više atributa
- opažanja iz više uzoraka klasificirana po kategorijama jednog atributa

2×2najjednostavnija tablica s "dva ulaza"

obilježje A	obilježje B		UKUPNO
	DA	NE	
DA	n_{11}	n_{12}	n_{1y}
NE	n_{21}	n_{22}	n_{2y}
UKUPNO	n_{x1}	n_{x2}	n_{xy}

- može se promatrati kao:

- jedan uzorak (sa n_{xy} ispitanika)
- dva uzorka (sa n_{1y} , n_{2y} ispitanika)

TABLICA S "DVA ULAZA" (r × k)

Stručna spremna	Spol		UKUPNO
	Muški	Ženski	
Nezavršena osnovna škola	4	27	31
Osnovna škola	12	35	47
Srednja škola	46	32	78
Viša škola/bakalaureat	12	25	37
Visoka škola/magisterij	52	18	70
Doktorat	11	4	15
UKUPNO	137	141	278



χ^2 TEST

- ocjena slaganja s poznatom razdiobom
- ocjena razlike razdiobe kategoričkog svojstva u nezavisnim uzorcima
- ocjena razlike dihotomnog svojstva u zavisnim uzorcima



χ^2 TEST ZA OCJENU SLAGANJA S POZNATOM RAZDIOBOM

- uz unaprijed poznatu razdibu očekivanih frekvencija, test statistika

$$\chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i}$$

gdje je:
 O_i opažena frekvencija
 E_iočekivana frekvencija
 k broj kategorija

ima χ^2 razdibu s
 $df = k - 1 - m$ stupnjeva slobode

k ... broj kategorija
 m ... broj parametara u modelu koje treba procijeniti



za normalnu razdibu: $m = 2$:

$$df = k - 1 - 2 = k - 3$$

za binomnu:

$$m = 1$$

$$df = k - 1 - 1 = k - 2$$

ako je zadana razdiba (ništa ne moramo računati iz podataka):

$$m = 0$$

$$df = k - 1 - 0 = k - 1$$



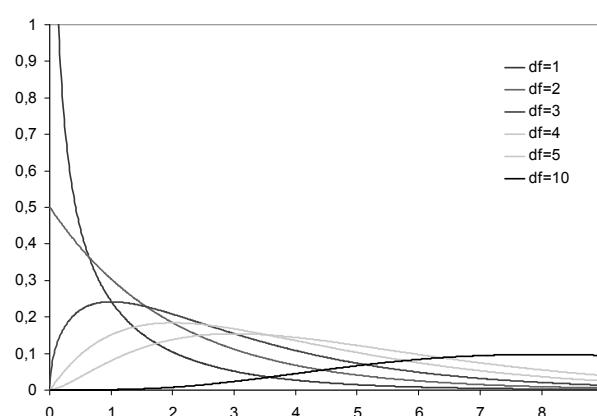
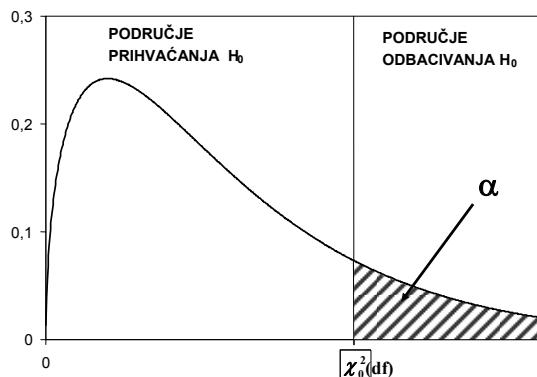
• uz

H_0 ... nema razlike u razdobi O_i i E_i

granični χ^2 za dani α i df

za $\chi^2 > \chi_\alpha^2 \Rightarrow P(\chi^2) < P(\chi_\alpha^2)$ ODBACI H_0

$\chi^2 < \chi_\alpha^2 \Rightarrow P(\chi^2) > P(\chi_\alpha^2)$ PRIHVATI H_0



Križanjem dviju vrsta biljki dobivena je u sljedećoj generaciji ova razdiba opaženih genotipova:

Genotip	Opažene frekvencije
Aa	53
AA	23
aa	24

Odgovara li ova razdiba očekivanoj razdobi 2:1:1 uz $\alpha = 0,01$?



genotip	O _i	E _i	O _i - E _i	(O _i - E _i) ²	$\frac{(O_i - E_i)^2}{E_i}$
Aa	53	50	3	9	0,18
AA	23	25	-2	4	0,16
aa	24	25	-1	1	0,04
					0,38

$\chi^2 = 0,38$ df = 3 - 1 = 2

k	α	0,01	0,02	0,05
1		6,635	5,412	3,841
2		9,210	7,824	5,991
3		11,345	9,837	7,815

za df = 2: $\chi^2_{(\alpha)} = \chi^2_{(0,01)} = 9,210$

$\chi^2 < \chi^2_{(0,01)} \Rightarrow P(\chi^2) > P(\chi^2_{(0,01)})$ PRIHVATI H_0

Kako dobiti točnu P vrijednost?

• kalkulator vjerojatnosti

- Excel

- WEB

- specijalizirani programi za analizu podataka

Excel

B4	=CHIDIST(B2;B3)
A	B
1	
2 Vrijednost χ^2	0.38
3 Broj stupnjeva slobode	2
4 P vrijednost	0.826959

<http://vassarstats.net/>

Calculators for Statistical Table Entries

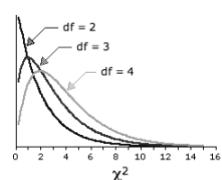
z to P chi-square to P t to P r to P F to P

Fisher r-to-z transformation critical values of Q odds & log odds

For values of degrees of freedom (df) between 1 and 20, inclusive, this unit will calculate the proportion of the relevant sampling distribution that falls to the right of a particular value of chi-square. To proceed, enter the values of chi-square and df in the designated cells and click the «Calculate» button.

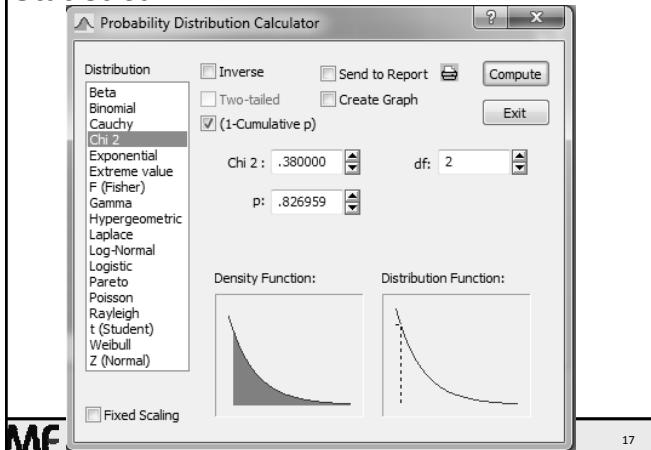
Chi-Square	df	P
0.38	2	0.826959

Calculate Reset



Entered values of df must be between 1 and 20, inclusive.

Statistica



MedCalc – radni list

Data		B3	A	B
1	Chi	0.38		
2	Df	2		
3	P	0.826959134		
4				
5				
6				

Izvještavanje rezultata

"Nije uočena razlika između razdiobe opaženih genotipova i očekivane razdiobe 2:1:1 (χ^2 test, $P = 0,827$)."

ili

"Nije uočena razlika između razdiobe opaženih genotipova i očekivane razdiobe 2:1:1 ($\chi^2 = 0,380$, 2 stupnja slobode, $P = 0,827$)."

χ^2 TEST ZA NEZAVISNE UZORKE

postupak:

- formirati tablicu kontingencije ($r \times k$)
- na osnovu postavljene hipoteze izračunati očekivane frekvencije
- test statistika dana je sa:

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^k \frac{(O_{ij} - E_{ij})^2}{E_{ij}}$$

gdje je: r broj redaka
 k broj stupaca

ima χ^2 razdiobu s

$df = (r - 1) \cdot (k - 1)$ stupnjeva slobode

VAŽNE NAPOMENE:

- a) u tablicu smijemo unijeti **SAMO APSOLUTNE FREKVENCije**
- b) uzorci moraju biti **nezavisni**
- c) u 2×2 tablici:
 - NITI JEDNA očekivana frekvencija **ne smije biti < 5**
 - Yatesova korekcija (umanjiti svaku razliku $O - E$ prije kvadriranja za 0,5) ili "N-1" Hi-kvadrat test (modificirana kratka formula)
- d) ako je u $r \times k$ tablici $E < 5$ u više od 20 % polja, **NE MOŽEMO KORISTITI χ^2 TEST**
rješenje:
 - spajanje susjednih razreda (frekvencija susjednih polja)
 - Fisherov egzaktni test

Pri istraživanju djelovanja nekog cjepiva, opažena je sljedeća učestalost oboljenja kod određene grupe ljudi:

	Cijepljeni	Necijepljeni	Ukupno
Oboljeli	5	10	15
Nisu oboljeli	159	117	276
Ukupno	164	127	291

Postoji li povezanost između učestalosti bolesti i cijepljenja (je li učestalost bolesti različita kod cijepljenih i necijepljenih) uz $\alpha = 0,01$?

H_0 učestalost je ista kod cijepljenih i necijepljenih

iz $H_0 \Rightarrow$ proporcije oboljelih trebaju biti jednake u obje skupine

ukupno oboljeli

zajednička proporcija oboljelih: $zpo = \frac{15}{291} = 0,051546$

sveukupno ispitanih

ukupno zdravi

zajednička proporcija zdravih: $zpz = \frac{276}{291} = 0,948454$

sveukupno ispitanih

E oboljelih: ukupno cijepljeni

u grupi cijepljenih..... $164 \cdot 0,051546 = 8,45$

zajednička proporcija oboljelih

u grupi necijepljenih.. $127 \cdot 0,051546 = 6,55$

ukupno necijepljeni

E zdravih:

ukupno cijepljeni

u grupi cijepljenih..... $164 \cdot 0,948454 = 155,55$

zajednička proporcija zdravih

u grupi necijepljenih.. $127 \cdot 0,948454 = 120,45$

ukupno necijepljeni

	Cijepljeni	Necijepljeni	Ukupno
Oboljeli	5 (8,45)	10 (6,55)	15
Nisu oboljeli	159 (155,55)	117 (120,45)	276
Ukupno	164	127	291

*



Oi	Ei	Oi - Ei	(Oi-Ei) ²	(Oi-Ei) ² /Ei
5	8,45	-3,45	11,9025	1,41
10	6,55	3,45	11,9025	1,82
159	155,55	3,45	11,9025	0,08
117	120,45	-3,45	11,9025	0,10
				$\chi^2 = 3,41$

Yates-ova korekcija:

Oi	Ei	$(O_i - E_i)_{corr}$	$(O_i - E_i)_{corr}^2$	$(O_i - E_i)_{corr}^2/E_i$
5	8,45	-2,95	8,7025	1,03
10	6,55	2,95	8,7025	1,33
159	155,55	2,95	8,7025	0,06
117	120,45	-2,95	8,7025	0,07
				$\chi^2 = 2,49$

$\chi^2 = 2,49$

za $\alpha = 0,01$ i df = 1: $\chi_0^2 = 6,635$

$\chi^2 < \chi_0^2 \Rightarrow P > 0,01$

⇒ ne postoji povezanost između učestalosti bolesti i cijepljenja

k \ \alpha	0,01	0,02	0,05	χ^2 RAZDIOBA
1	6,635	5,412	3,841	
2	9,210	7,824	5,991	
3	11,345	9,837	7,815	

*



točna P vrijednost.....

B4	A	B
1		
2	Vrijednost χ^2	3,41
3	Broj stupnjeva slobode	1
4	P vrijednost	0,064802

bez korekcije

B4	A	B
1		
2	Vrijednost χ^2	2,49
3	Broj stupnjeva slobode	1
4	P vrijednost	0,114572

s korekcijom

2 x 2 tablice – kratka formula za χ^2 test

- za tablicu 2 x 2 sa sljedećim oznakama:

Obilježje A	Obilježje B		UKUPNO
	0	1	
0	a	b	m
1	c	d	n
UKUPNO	r	s	N

$$\chi^2 = \frac{N(ad - bc)^2}{mnrs}$$


"N – 1" χ^2 test

Obilježje A	Obilježje B		UKUPNO
	0	1	
0	a	b	m
1	c	d	n
UKUPNO	r	s	N

$$"N - 1" \chi^2 = \frac{(N-1)(ad - bc)^2}{mnrs}$$

MF Medicinski fakultet Osijek
Katedra za medicinsku statistiku i medicinsku informatiku

30

χ^2 test (kratka formula) i "N – 1" χ^2 test za podatke iz primjera

	Cijepljeni	Necijepljeni	Ukupno
Oboljeli	5 (a)	10 (b)	15 (m)
Nisu oboljeli	159 (c)	117 (d)	276 (n)
Ukupno	164 (r)	127 (s)	291 (N)

$$\chi^2 = \frac{N(ad - bc)^2}{mnrs} = \frac{291 \cdot (5 \cdot 117 - 10 \cdot 159)^2}{15 \cdot 276 \cdot 164 \cdot 127} = \frac{293917275}{86227920} = 3,409$$

$$"N - 1" \chi^2 = \frac{(N-1)(ad - bc)^2}{mnrs} = \frac{290 \cdot (5 \cdot 117 - 10 \cdot 159)^2}{15 \cdot 276 \cdot 164 \cdot 127} = \frac{292907250}{86227920} = 3,397$$



točna P vrijednost.....

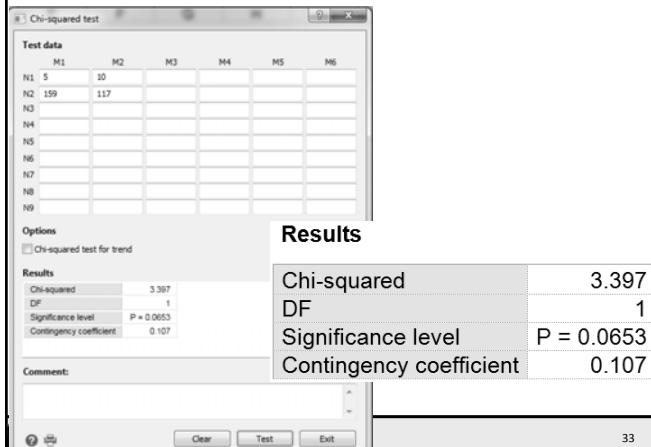
B4	=CHIDIST(B2:B3)
A	B
1	
2 Vrijednost χ^2	3.409
3 Broj stupnjeva slobode	1
4 P vrijednost	0.064842

kratka formula

B4	=CHIDIST(B2:B3)
A	B
1	
2 Vrijednost χ^2	3.397
3 Broj stupnjeva slobode	1
4 P vrijednost	0.065315

"N – 1" χ^2

MedCalc – za tablice 2 x 2 koristi "N – 1" χ^2 test



Izvještavanje rezultata

"Nije uočena povezanost učestalosti bolesti i cijepljenja (χ^2 test, P = 0,065)." ili

"Nije uočena razlika razdiobe obolijevanja u skupinama cijepljenih i necijepljenih ispitanika (χ^2 test, P = 0,065)." ili

Izvještavanje rezultata

"Nije uočena povezanost učestalosti bolesti i cijepljenja ($\chi^2 = 3,397$, 1 stupanj slobode, P = 0,065)." ili

"Nije uočena razlika razdiobe obolijevanja u skupinama cijepljenih i necijepljenih ispitanika ($\chi^2 = 3,397$, 1 stupanj slobode, P = 0,065)." ili



χ^2 TEST ZA ZAVISNE UZORKE (McNemarov test)

- testiranje značajnosti razlike (ili vjerojatnosti povezanosti) između podataka dobivenih na uzorcima parova

$$\chi^2 = \frac{(b - c)^2}{b + c}$$

Yatesova korekcija

b, c frekvencije parova koji se ne slažu po prisutnosti obilježja

OBILJEŽJE A	UZORAK I		
	DA	NE	
UZORAK II	DA	a	b
	NE	c	d

Skupina od 75 bolesnika praćena je tijekom 20 godina. Ispitanici su s obzirom na težinu svrstani u skupinu normalne i prekomjerne (overweight) težine.

TEŽINA		Nakon 20 godina		
		Normalna	Prekomjerna	Ukupno
Na početku	Normalna	26	14	40
	Prekomjerna	3	32	35
	Ukupno	29	46	75

Je li se težina ispitanika promjenila tijekom promatranog perioda uz $\alpha = 0,05$?



McNemarov test – pomoću tablica

$$\chi^2 = \frac{(|14 - 3| - 1)^2}{14 + 3} = \frac{10^2}{17} = 5,882$$

$$df = 1, \quad \alpha = 0,05$$

$$\chi_0^2 = 3,841$$

k	α	0,01	0,02	0,05
1		6,635	5,412	3,841
2		9,210	7,824	5,991
3		11,345	9,837	7,815

$$\chi^2 > \chi_0^2 \Rightarrow P < 0,05$$

točna P vrijednost.....

- za $\chi^2 = 5,882$ i 1 stupanj slobode:

B4	A	B
1		
2 Vrijednost χ^2		5,822
3 Broj stupnjeva slobode		1
4 P vrijednost		0,015827



MedCalc – McNemar test (binomni egzaktni test)



Izvještavanje rezultata

"Težina ispitanika se promjenila tijekom promatranog perioda (McNemarov test, $P = 0,013$)."

ili

"Težina ispitanika se promjenila tijekom promatranog perioda (razlika proporcija 14,7 %, 95 % raspon pouzdanosti od 3,0 % do 20,9 %, McNemarov test, $P = 0,013$)."

