

ANALIZA TABLICA KONTINGENCIJE

TABLICA KONTINGENCIJE

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

TABLICA S "JEDNIM ULAZOM" (1×k)

- opažanja su klasificirana samo po jednom obilježju

PRIMJER.

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

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 razdiju očekivanih frekvencija, test statistika

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

gdje je:
 O_iopažena frekvencija
 E_iočekivana frekvencija
 kbroj kategorija

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

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

za normalnu razdiju: $m = 2$

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

za binomnu: $m = 1$

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

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

$$m = 0$$

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

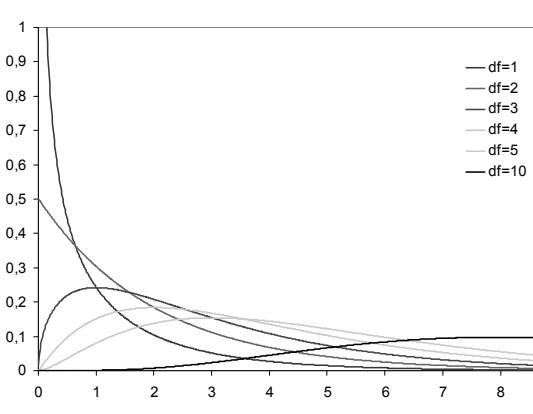
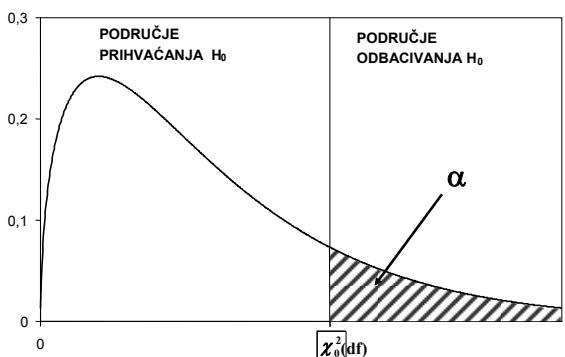
- UZ

H_0 ... nema razlike u razdiji O_i i E_i

granični χ^2 za dani α i df

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

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



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

Genotip	Opažene frekvencije
Aa	53
AA	23
aa	24

Odgovara li ova razdija očekivanoj razdiji 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: $\chi^2_{(\alpha)} = \chi^2_{(0,01)} = 9,210$

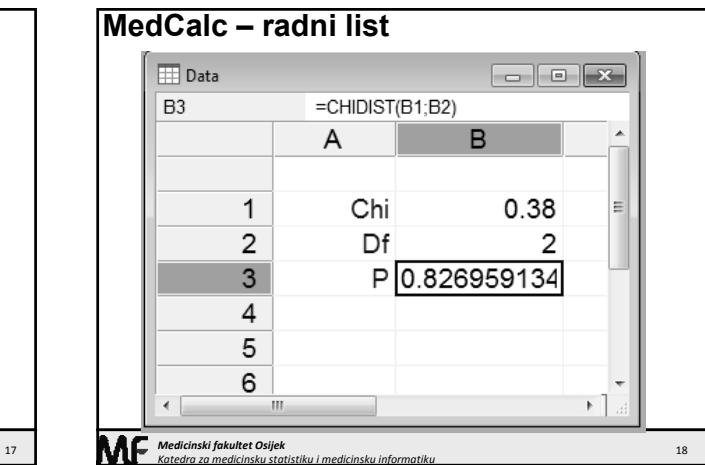
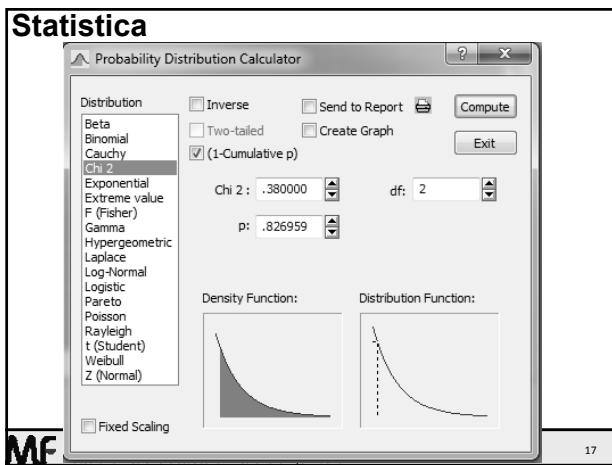
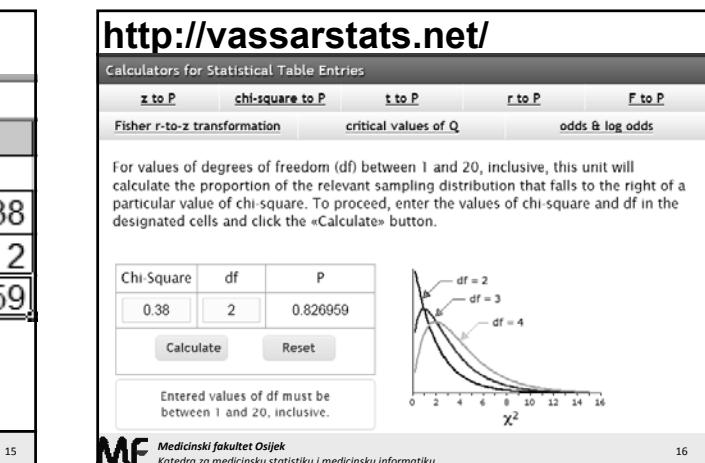
$\chi^2 < \chi^2_{(0,01)} \Rightarrow P(\chi^2) > P(\chi^2_{(0,01)})$ PRIHVATI H_0

Kako dobiti točnu P vrijednost?

- kalkulator vjerojatnosti
 - Excel
 - WEB
 - specijalizirani programi za analizu podataka

Excel		
B4	f	=CHIDIST(B2:B3)
A	B	
1		
2	Vrijednost χ^2	0,38
3	Broj stupnjeva slobode	2
4	P vrijednost	0,826959

MF Medicinski fakultet Osijek
Katedra za medicinsku statistiku i medicinsku informatiku



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 x 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: rbroj redaka
kbroj stupaca

ima χ^2 razdiobu s
 $df = (r - 1) \cdot (k - 1)$ stupnjeva slobode

VAŽNE NAPOMENE:

- u tablicu smijemo unijeti **SAMO APSOLUTNE FREKVENCIE**
- uzorci moraju biti **nezavisni**
- 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)
- 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

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

sveukupno ispitanih

ukupno oboljni

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

sveukupno ispitanih

ukupno zdravi

2

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

Katedra za medicinsku statistiku i medicinsku informatiku

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)

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

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

MF Medicinski fakultet Osijek
Katedra za medicinsku statistiku i medicinsku informatiku

31

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

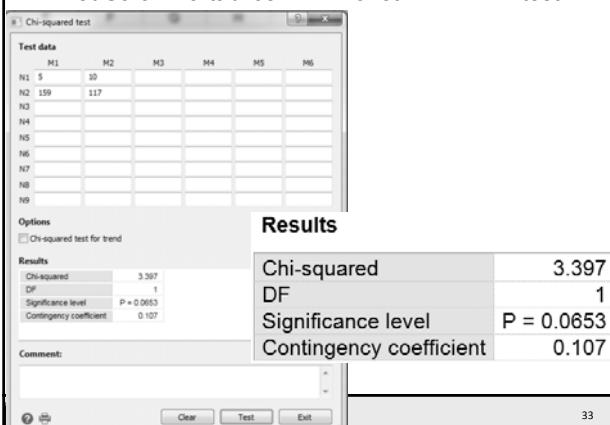
B4	=CHIDIST(B2:B3)
A	B
1	
2 Vrijednost χ^2	3.397
3 Broj stupnjeva slobode	1
4 P vrijednost	0.065315

"N – 1" χ^2

MF Medicinski fakultet Osijek
Katedra za medicinsku statistiku i medicinsku informatiku

32

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



33

Izvještavanje rezultata

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

ili

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

MF Medicinski fakultet Osijek
Katedra za medicinsku statistiku i medicinsku informatiku

34

Izvještavanje rezultata

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

ili

"Nije uočena razlika razdiobe oboljevanja u skupinama cijepljenih i necijepljenih ispitanika (χ^2 = 3,397, 1 stupanj slobode, P = 0,065)."

MF Medicinski fakultet Osijek
Katedra za medicinsku statistiku i medicinsku informatiku

35

χ^2 TEST ZA ZAVISNE UZORKE (McNemarов test)

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

$$\chi^2 = \frac{(|b - c| - 1)^2}{b + c}$$

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

MF Medicinski fakultet Osijek
Katedra za medicinsku statistiku i medicinsku informatiku

36

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 \ \alpha	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

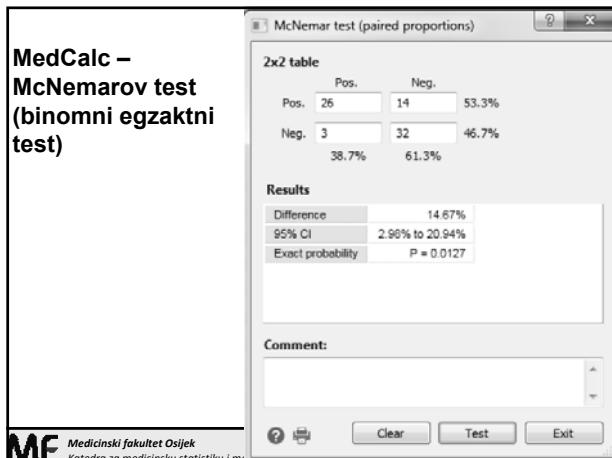
$$\chi^2 > \chi_0^2 \Rightarrow P < 0,05$$

točna P vrijednost.....

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

B4	f(x) =CHIDIST(B2;B3)
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)."

OCJENA PROCJENE I ANALIZA TABLICA KONTINGENCIJE

STANDARDNA POGREŠKA ARITMETIČKE SREDINE (SEM-standard error of the mean)

$$S_{\bar{x}} = \frac{s}{\sqrt{n}}$$

STANDARDNA POGREŠKA PROPORCIJE

$$S_p = \sqrt{\frac{p \cdot q}{n}}$$

RASPON POUZDANOSTI ARITMETIČKE SREDINE

$$\bar{x} - Z \cdot S_{\bar{x}} \leq \mu \leq \bar{x} + Z \cdot S_{\bar{x}}$$

POGREŠKA PROCJENE

$$p - Z \cdot S_p \leq \Pi \leq p + Z \cdot S_p$$

RASPON POUZDANOSTI PROPORCIJE

MF Medicinski fakultet Osijek Katedra za medicinsku statistiku i medicinsku informatiku 43

ZADATAK 1:

U studiji objavljenoj 2004. godine izmjerena je težina 98 prijevremeno rođene djece i dobivena aritmetička sredina 1.31kg sa standardnom devijacijom od 0.42kg. Izračunajte pogrešku procjene aritmetičke sredine i raspon pouzdanosti uz pouzdanost od:

- a) 90%
- b) 95%
- c) Kolika je pogreška procjene za standardnu devijaciju od 0.20 kg i 0.60kg, uz pouzdanost 95%?
- d) Kolika je pogreška procjene uz pouzdanost od 95% i standardnu devijaciju od 0.6 za uzorke veličine 200 i 300 prijevremeno rođene djece?

ZADATAK 1:

n=98 $\bar{x} = 1.31$ s=0.42

a) 90%

b) 95%

MF Medicinski fakultet Osijek Katedra za medicinsku statistiku i medicinsku informatiku 45

ZADATAK 1:

n=98

c) Kolika je pogreška procjene za standardnu devijaciju od 0.20 kg i 0.60kg?

s₁=0.20

s₂=0.60

ZADATAK 1:

d) Kolika je pogreška procjene uz pouzdanost od 95% i standardnu devijaciju od 0.6 za uzorke veličine 200 i 300 prijevremeno rođene djece?

n₁=200

n₂=300

MF Medicinski fakultet Osijek Katedra za medicinsku statistiku i medicinsku informatiku 47

ZADATAK 2:

Farmaceutska tvrtka predlaže novi lijek za ublažavanje simptoma PMS-a. U prvim kliničkim istraživanjima lijek se pokazao učinkovit kod 7 od 10 žena.

- a) izračunajte pogrešku procjene proporcije populacije uz pouzdanost od 95%
- b) konstruirajte 95% raspon pouzdanosti za proporciju populacije
- c) izračunajte pogrešku procjene i konstruirajte 95% raspon pouzdanosti proporcije populacije za istu proporciju dobivenu iz uzorka od 100 ispitaničica.

ZADATAK 2:

$$n=10 \quad p=7/10=0.7 \quad q=1-0.7=0.3$$

- a) izračunajte pogrešku procjene proporcije populacije uz pouzdanost od 95%
- b) konstruirajte 95% raspon pouzdanosti za proporciju populacije

ZADATAK 2:

- c) izračunajte pogrešku procjene i konstruirajte 95% raspon pouzdanosti proporcije populacije za istu proporciju dobivenu iz uzorka od 100 ispitanica.

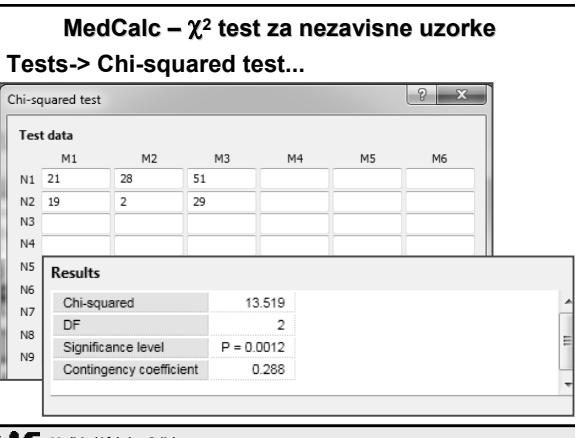
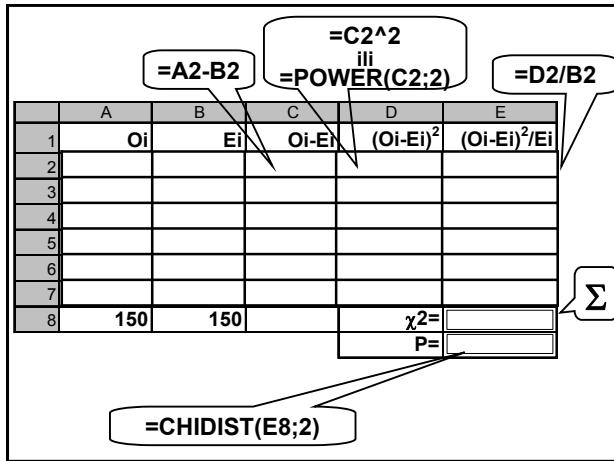
$$n=100 \quad p=0.7 \quad q=1-0.7=0.3$$

ZADATAK 3:

Ispitivana je čud (benignost/malignost) tumora mozga prema lokalizaciji. Od 100 bolesnika s benignim tumorom, tumor je bio kod 21 lociran na frontalnom, kod 28 na temporalnom, a kod ostalih na drugim režnjevima mozga. Od 50 bolesnika s malignim tumorom kod 19 se radilo o tumoru frontalnog, kod 2 temporalnog a kod 29 o tumoru ostalih režnjeva mozga. Ocijenite postoji li povezanost malignosti s lokalizacijom tumora na mozgu na razini značajnosti od 0.05.

OPOŽENE FREKVENCIJE	Frontalni	Temporalni	Ostali	Ukupno
Benigni				
Maligni				
Ukupno				

OČEKIVANE FREKVENCIJE	Frontalni	Temporalni	Ostali	Ukupno
Benigni				
Maligni				
Ukupno				



Izvještavanje rezultata

"Čud tumora povezana je s lokalizacijom (χ^2 test, $P=0,001$)."

ili

"Razdioba lokalizacija tumora u skupinama ispitanika s malignim i benignim tumorom se razlikuje (χ^2 test, $P=0,001$)."



ZADATAK 4:

Pri križanju dviju jedinki tipa Aa i tipa Bb teorijske vjerojatnosti pojavljivanja kombinacija jesu:

$$p(AB)=9/16$$

$$p(Ab)=3/16$$

$$p(aB)=3/16$$

$$p(ab)=1/16.$$

Ako su u 160 nezavisnih promatranja dobivene frekvencije 86, 35, 26, 13 testirati hipotezu da su podaci suglasni sa teorijskom raspodjelom uz nivo značajnosti 0.01.

tip	O _i	p _i	E _i =p _i *n	O _i -E _i	(O _i -E _i) ²	(O _i -E _i) ² /E _i
AB	86	9/16				
Ab	35	3/16				
aB	26	3/16				
ab	13	1/16				
n=	160	1	160		$\chi^2=$	

H₀ nema razlike

k =

m =

df =

$\alpha = 0.01$

P=

