

# TESTIRANJE HIPOTEZA O DISTRIBUCIJI

# Pearsonov $\chi^2$ test

Istraživač je slučajno izabrao uzorak od 100 ispitanika.

U uzorak je izabrano 55 muških i 45 ženskih osoba.

Nakon provedenog istraživanja recenzent mu je prigovorio da udio žena i muškaraca u uzorku nije jednak i da je to utjecalo na rezultate istraživanja.

Je li recenzent u pravu?

Je li disproporcija u uzorku posljedica slučajnog izbora ili pristranosti istraživača?

Udio žena u populaciji je 0.5.

Očekivana frekvencija žena i muškaraca u uzorku je 50.

Da li frekvencija spola u uzorku odgovara populaciji?

Promatramo diskretno obilježje s konačno mnogo vrijednosti:

$x_1, x_2, \dots, x_k$ .

Slučajnim izborom iz populacije definirana je slučajna varijabla  $X$  s distribucijom

$$P(X = x_i) = p_i, \quad i = 1, \dots, k$$

gdje  $p_i$  odgovara relativnim frekvencijama obilježja u populaciji.

Za uzorak veličine  $n$ :  $X_1, X_2, \dots, X_n$  distribucija slučajne varijable  $X_i$  je

$$X_i \sim \begin{pmatrix} x_1 & x_2 & \dots & x_k \\ p_1 & p_2 & \dots & p_k \end{pmatrix}$$

Želimo usporediti frekvenciju obilježja na uzorku s distribucijom obilježja u populaciji.

# Jednostruka klasifikacija

Problem jednostrukе klasifikacije - unaprijed su zadane teorijske proporcije za pojedine kategorije.

Cilj nam je ustvrditi da li razdioba obilježja u populaciji jednako zadanoj razdiobi.

Hipoteza:

distribucija obilježja u populaciji jednaka je zadanoj distribuciji:

$$\begin{pmatrix} x_1 & x_2 & \dots & x_k \\ p_1 & p_2 & \dots & p_k \end{pmatrix}$$

Za zadanu razdiobu

$$\begin{pmatrix} x_1 & x_2 & \dots & x_k \\ p_1 & p_2 & \dots & p_k \end{pmatrix}$$

i uzorak veličine  $n$  definiramo **teorijske frekvencije**:

$$E_i = n \cdot p_i.$$

S  $F_i$  ćemo označiti frekvencije u uzorku ( **opažene frekvencije**).

Rezultat možemo prikazati tablično

Kategorija	Frekvencije	
	Opažena	Teorijska
$x_1$	$F_1$	$E_1$
$x_2$	$F_2$	$E_2$
$\vdots$	$\vdots$	$\vdots$
$x_k$	$F_k$	$E_k$
Ukupno	$n$	$n$

Ukoliko je hipoteza točna, tada je statistika

$$\chi^2 = \sum_i \frac{(F_i - E_i)^2}{E_i}$$

distribuirana prema  $\chi^2$  razdiobi s  $k - 1$  stupnjeva slobode:

$$\chi^2 \sim \chi^2(k - 1).$$

**Prepostavka  $\chi^2$  testa:**

**Barem 80 % očekivanih frekvencije u klijetkama trebaju biti veće ili jednake od 5 a sve moraju biti veće ili jednake od 1.**

**Primjer.** Da li je uzorak iz uvodnog primjera (55 muškaraca i 45 žena) iz populacije s jednakim udjelom muškaraca i žena.

Varijabla spol → Vrijednosti  $x_1 = M$ ,  $x_2 = \check{Z}$ .

Udjeli:  $p_1 = 0.5$ ,  $p_2 = 0.5$

Očekivane frekvencije:

$$E_1 = n \cdot p_1 = 100 \cdot 0.5 = 50,$$

$$E_2 = n \cdot p_2 = 100 \cdot 0.5 = 50$$

Opažene frekvencije:  $F_1 = 55$ ,  $F_2 = 45$

Tablica:

Kategorija	Frekvencije	
	Opažena	Teorijska
M	55	50
$\check{Z}$	45	50
Ukupno	100	100

Računamo statistiku:

$$\chi^2 = \sum_i \frac{(F_i - E_i)^2}{E_i} = \frac{(55 - 50)^2}{50} + \frac{(45 - 50)^2}{50} = \frac{25}{50} + \frac{25}{50} = 1$$

Broj vrijednosti:  $k = 2$ .  $\rightarrow$  Broj stupnjeva slobode:  $k - 1 = 1$

Distribucija:  $\chi^2(1)$ .

$$\chi^2_{0.95}(1) = 3.84$$

$\chi^2 = 1 < 3.84 = \chi^2_{0.95}(1)$   $\rightarrow$  Hipotezu ne odbacujemo.

Primjedba recenzenta nema osnove.

Razlika u proporcijama je posljedica slučajnog izbora.

**Napomena.** Ovu hipotezu smo mogli testirati i  $t$ -testom za proporcije (hipoteza  $p = 0.5$ ).

Za dihotomne varijable  $t$ -test i  $\chi^2$ -test su ekvivalentni.

Kod  $\chi^2$ -testa s dvije kategorije očekivana frekvencija treba biti veća od 10 u svakoj klijetki.

**Primjer.** Istraživač za slučajni izbor u uzorak koristi igraču kocku. Prije početka izbora uzorka htio je provjeriti je li njegova kocka simetrična (svi brojevi imaju iste vjerojatnosti). Kocku je bacio 120 puta i zabilježio frekvencije brojeva:

Vrijednost	Opažena frekvencija
1	23
2	15
3	16
4	28
5	17
6	21
Ukupno	120

Da li je kocka simetrična?

Ukoliko je kocka simetrična, vjerojatnost pojedinog broja je  $p_i = 1/6$ .

Za  $n = 120$  bacanja, očekivane frekvencije pojedinog broja su jednake  $E_i = n \cdot p_i = 120 \cdot 1/6 = 20$ .

Tablica:

Vrijednost	Frekvencije	
	Opažena	Teorijska
1	23	20
2	15	20
3	16	20
4	28	20
5	17	20
6	21	20
Ukupno	120	120

Računanje statistike:

$$\begin{aligned}
 \chi^2 &= \sum_i \frac{(F_i - E_i)^2}{E_i} = \\
 &= \frac{(23 - 20)^2}{20} + \frac{(15 - 20)^2}{20} + \frac{(16 - 20)^2}{20} + \\
 &\quad + \frac{(28 - 20)^2}{20} + \frac{(17 - 20)^2}{20} + \frac{(21 - 20)^2}{20} = \\
 &= \frac{9}{20} + \frac{25}{20} + \frac{16}{20} + \frac{64}{20} + \frac{9}{20} + \frac{1}{20} = 6.2
 \end{aligned}$$

Broj vrijednosti:  $k = 6$ .  $\rightarrow$  Broj stupnjeva slobode:  $k - 1 = 5$

Distribucija:  $\chi^2(5)$ .

$$\chi^2_{0.95}(5) = 11.07$$

$$\chi^2 = 6.2 < 11.07 = \chi^2_{0.95}(5) \rightarrow \text{Hipotezu ne odbacujemo.}$$

Kocka je simetrična.

# Rješenje primjera u Statistici



Podaci:

Data: Spreadsheet1\* ...


	1 F	2 E
1	23	20
2	15	20
3	16	20
4	28	20
5	17	20
6	21	20

Zadaju se frekvencije!


## Izbor analize:



## Definiranje varijabli - opažene i očekivane frekvencije



## Rezultat



served vs. Expected Frequencies (Spreadsheet1)

Case	Observed vs. Expected Frequencies (Spreadsheet1)				
	observed F	expected E	O - E	(O-E)**2 /E	
C: 1	23,0000	20,0000	3,00000	0,450000	
C: 2	15,0000	20,0000	-5,00000	1,250000	
C: 3	16,0000	20,0000	-4,00000	0,800000	
C: 4	28,0000	20,0000	8,00000	3,200000	
C: 5	17,0000	20,0000	-3,00000	0,450000	
C: 6	21,0000	20,0000	1,00000	0,050000	
Sum	120,0000	120,0000	0,00000	6,200000	

**Primjer.** Istraživač je bilježio broj zgoditaka na uzorku od 200 nogometnih utakmica. Dobio je sljedeći rezultat:

Broj zgoditaka	0	1	2	3	4	5	6	7	Ukupno
Frekvencija	22	53	58	39	20	5	2	1	200

Može li se na osnovu ovih podataka zaključiti da Poissonova razdioba adekvatno opisuje razdiobu broja zgoditaka?

Poissonova razdioba ( $X \sim Po(\lambda)$ ):

$$P(X = i) = p_i = \frac{\lambda^i}{i!} e^{-\lambda}$$

$\lambda$  nije zadan pa ga procjenjujemo iz podataka.

Za  $X \sim Po(\lambda)$  je  $E(X) = \lambda$ .

$\lambda$  ćemo procijeniti s  $\bar{X}$ :  $\lambda = \bar{X} = 2.05$

Provjeravamo da li se radi o  $Po(2.05)$  razdiobi.

Izračunamo vjerojatnosti i očekivane frekvencije:

Br. zgod.	0	1	2	3	4	5	6	7+
$p_i$	0,129	0,264	0,271	0,185	0,095	0,039	0,013	0,005
$E_i$	25.75	52.78	54.10	36.97	18.95	7.77	<b>2.65</b>	<b>1.03</b>

Preko 20% klijetki ima očekivanu frekvenciju manju od 5.  
Spajamo kategorije.

Br. zgod.	0	1	2	3	4	5+	Ukupno
$F_i$	22	53	58	39	20	8	200
$E_i$	25,75	52,78	54,10	36,97	18,95	11,46	200

Statistika:  $\chi^2 = \sum_i \frac{(F_i - E_i)^2}{E_i} = 2.04$

Broj stupnjeva slobode:

- 6 kategorija
- 1 parametar procijenjen iz podataka
- broj stupnjeva slobode = broj kategorija - broj procijenjenih parametara = 6-1=5

Distribucija.  $\chi^2(5)$

$p$ -vrijednost:  $p = 0.843629$

Ne odbacujemo hipotezu.

Broj zgoditaka je dobro opisan Poissonovom distribucijom.

# Testiranje hipoteza o nezavisnosti i homogenosti

## Dvostruka klasifikacija.

### Testiranje homogenosti

Želimo provjeriti hipotezu da je (diskretno) obilježje jednako distribuirano u više populacija.

$c$  - broj populacija u kojem promatramo obilježje  $X$ .

$X_j$  - rezultat mjerenja obilježja  $X$  u  $j$ -toj populaciji

$$X_j \sim \begin{pmatrix} x_1 & x_2 & \dots & x_k \\ p_{1j} & p_{2j} & \dots & p_{cj} \end{pmatrix}, \quad j = 1, \dots, c$$

Želimo provjeriti da li su sve ove slučajne varijable jednakodistribuirane, tj. da li vrijedi

Hipoteza o homogenosti:

$$p_{i1} = p_{i2} = p_{i3} = \dots = p_{ik} \quad \text{za } i = 1, \dots, k.$$

Da bismo provjerili hipotezu, u svakoj populaciji izaberemo uzorak.

Veličine uzoaraka:  $n_{y1}, n_{y2}, \dots, n_{yc}$

U svakom uzorku odredimo frekvencije  $n_{ij}$  - broj pojavljivanja obilježja  $x_i$  u  $j$ -toj populaciji.

Rezultat prikazujemo u **kontigencijskoj tablici**:

	1	2	3	...	c
$x_1$	$n_{11}$	$n_{12}$	$n_{13}$	...	$n_{1c}$
$x_2$	$n_{21}$	$n_{22}$	$n_{23}$	...	$n_{2c}$
$x_3$	$n_{31}$	$n_{32}$	$n_{33}$	...	$n_{3c}$
:	:	:	:		:
$x_k$	$n_{k1}$	$n_{k2}$	$n_{k3}$	...	$n_{kc}$
<b>Ukupno</b>	$n_{y1}$	$n_{y2}$	$n_{y3}$	...	$n_{yc}$

Za svako obilježje  $x_i$  prebrojimo broj pojavljivanja (frekvencije)  $n_{xi}$  u svih  $c$  uzoraka:

	1	2	3	...	c	Ukupno
$x_1$	$n_{11}$	$n_{12}$	$n_{13}$	...	$n_{1c}$	$n_{x1}$
$x_2$	$n_{21}$	$n_{22}$	$n_{23}$	...	$n_{2c}$	$n_{x2}$
$x_3$	$n_{31}$	$n_{32}$	$n_{33}$	...	$n_{3c}$	$n_{x3}$
:	:	:	:		:	
$x_k$	$n_{k1}$	$n_{k2}$	$n_{k3}$	...	$n_{kc}$	$n_{xc}$
<b>Ukupno</b>	$n_{y1}$	$n_{y2}$	$n_{y3}$	...	$n_{yc}$	$n$

Budući da pretpostavljamo jednaku razdiobu u svim populacijama:

$$\textcolor{red}{p_i} = p_{i1} = p_{i2} = p_{i3} = \dots = p_{ik} \quad \text{za} \quad i = 1, \dots, k.$$

$p_i$  procjenjujemo na osnovu cijelog uzorka s  $\frac{n_{xi}}{n}$ .

Sada je očekivana frekvencija vrijednosti  $x_i$  u  $j$ -tom uzorku dana s:

$$\textcolor{red}{E_{ij}} = \frac{n_{xi}}{n} n_{yj}.$$

Ukoliko je hipoteza točna, statistika

$$\chi^2 = \sum_i \sum_j \frac{(n_{ij} - E_{ij})^2}{E_{ij}}$$

distribuirana prema  $\chi^2$  razdiobi.

## Broj stupnjeva slobode

U svakom stupcu imamo  $k - 1$  stupanj slobode (jer je suma  $n_{yi}$  fiksirana)

→ sve skupa  $c \cdot (k - 1)$  stupnjeva slobode

Iz uzorka određujemo  $k$  parametara  $n_{x1}, n_{x2}, \dots, n_{xk}$ .

Jer je  $\sum_i n_{xi} = n \rightarrow k - 1$  stupnjeva slobode u parametrima

Ukupno je

$$\text{d.f.} = c \cdot (k - 1) - (k - 1) = (\textcolor{red}{c - 1}) \cdot (k - 1).$$

Statistika  $\chi^2$  je distribuirana:

$$\chi^2 \sim \chi^2((\textcolor{red}{c - 1}) \cdot (k - 1))$$

**Primjer.** Provedena je anketa da bi se ustanovila pojavnost alkoholizma u različitim sportovima. Intervjuirani su slučajni uzorci sportaša iz 4 sporta. Dobiveni rezultati su prikazani u tablici

	Alkoholičari	Nealkoholičari	Veličina uzorka
Sport 1	32	268	300
Sport 2	51	199	250
Sport 3	67	233	300
Sport 4	83	267	350

Konstruirajte test da biste provjerili da li je udio alkoholičara jednak u sva 4 sporta

Izračunajmo očekivane frekvencije:

	Alkoholičari	Nealkoholičari	Veličina uzorka
Sport 1	32 (58.25)	268 (241.75)	300
Sport 2	51 (48.54)	199 (201.46)	250
Sport 3	67 (58.25)	33 (241.75)	300
Sport 4	83 (67.96)	267 (282.04)	350
Ukupno	233	967	1200

U zagradama su prikazane očekivane frekvencije dobivene množenjem suma stupca i redka te podijeljenih s ukupnom veličinom uzorka (1200).

Ukoliko s  $p_1, p_2, p_3, p_4$  označimo udio alkoholičara u pojedinom sportu, želimo testirati hipotezu

$$H_0 : p_1 = p_2 = p_3 = p_4.$$

Računamo vrijednost statistike

$$\chi^2 = \frac{(32 - 58.25)^2}{58.25} + \frac{(268 - 241.75)^2}{241.75} + \dots + \frac{(267 - 282.04)^2}{282.04} = 20.59$$

Budući da je  $d.f. = (2 - 1) \cdot (4 - 1) = 3$ , za  $\alpha = 0.05$  je

$$\chi^2_{0.95}(3) = 7.815.$$

Jer je  $\chi^2 > \chi^2_{0.95}(3)$  hipotezu o jednakosti proporcija odbacujemo.

Nakon odbacivanja hipoteze, poželjno je provjeriti zbog čega je ona odbačena.

Pogledajmo doprinos svake grupe  $\chi^2$  statistici:

	$n_{ij} - E_{ij}$		$(n_{ij} - E_{ij})^2 / E_{ij}$	
	Alk.	Nealk.	Alk.	Nealk.
Sport 1	-26.25	26.25	11.83	2.85
Sport 2	2.46	-2.46	0.12	0.03
Sport 3	8.75	-8.75	1.31	0.32
Sport 4	15.04	-15.04	3.33	0.80

Najveći doprinos daje dio koji odgovara udjelu alkoholičara u Sportu 1.

Odstupanje od homogenosti je u najvećoj mjeri uzrokovano malim udjelom alkoholičara u Sportu 1.


## Rješenje primjera u Statistici

Podaci:



	1	2
	Sport	Alk
1	1	1
2	1	1
3	1	1
4	1	1
5	1	1
6	1	1
7	1	1
8	1	1
9	1	1
10	1	1
11	1	1
12	1	1
13	1	1
14	1	1
15	1	1

Izbor testa.


## Izbornik Basic Statistics and Tables



# Definiranje varijabli.




U izborniku Options definiramo tražene testove:



## Kontigencijska tablica.

### Summary



## Summary Frequency Table (primjer-6-3.sta)

Marked cells have counts &gt; 10

(Marginal summaries are not marked)

Sport	Alk 1	Alk 2	Row Totals
1	32	268	300
2	51	199	250
3	67	233	300
4	83	267	350
All Grps	233	967	1200

Rezultati testova.

Advanced. - Detailed two-way tables.

Statistic	Statistics: Sport(4) x Alk(2) (primjer-6-3.sta)		
	Chi-square	df	p
Pearson Chi-square	20,59675	df=3	p=.00013
M-L Chi-square	22,56667	df=3	p=.00005

# Testiranje hipoteze o nezavisnosti

**Primjer.** Na uzorku od 95 osoba promatrana je boja očiju i boja kose. Rezultati su prikazani u tablici:

		Boja kose		Ukupno
		Svjetla	Tamna	
Boja očiju	Plave	32	12	44
	Smeđe	14	22	36
	Ostalo	6	9	15
	Ukupno	52	43	95

Jesu li boja očiju i boja kose povezani?

Promatramo dva obilježja,  $X$  i  $Y$  koja poprimaju vrijednosti  $x_1, \dots, x_k$  i  $y_1, \dots, y_c$ .

U uzorku od  $n$  jedinki promatramo frekvencije pojavljivanja svih kombinacija  $(x_i, y_j)$  i označimo ih s  $n_{ij}$

Promatramo i frekvencije svakog obilježja posebno:

- $n_{xi}$  frekvencija za  $x_i$
- $n_{yj}$  frekvencija za  $y_j$

Vrijedi

$$n_{xi} = \sum_j n_{ij} \quad \text{i} \quad n_{yj} = \sum_i n_{ij}$$

Rezultat prebrojavanja se prikazuje u kontigencijskoj tablici:

		<b>Y</b>						
		$y_1$	$y_2$	$y_3$	...	$y_c$	<b>Ukupno</b>	
<b>X</b>	$x_1$	$n_{11}$	$n_{12}$	$n_{13}$	...	$n_{1c}$	$n_{x1}$	
	$x_2$	$n_{21}$	$n_{22}$	$n_{23}$	...	$n_{2c}$	$n_{x2}$	
	$x_3$	$n_{31}$	$n_{32}$	$n_{33}$	...	$n_{3c}$	$n_{x3}$	
	:	:	:	:		:	:	
	$x_k$	$n_{k1}$	$n_{k2}$	$n_{k3}$	...	$n_{kc}$	$n_{xk}$	
	<b>Ukupno</b>	$n_{y1}$	$n_{y2}$	$n_{y3}$	...	$n_{yc}$	$n$	

Slučajnim izvlačenjem definirane su slučajne varijable  $X$  i  $Y$ .

Njihova razdioba je dana s

$$X \sim \begin{pmatrix} x_1 & x_2 & \dots & x_k \\ p_{x1} & p_{x2} & \dots & p_{xk} \end{pmatrix} \quad \text{i} \quad Y \sim \begin{pmatrix} y_1 & y_2 & \dots & y_c \\ p_{y1} & p_{y2} & \dots & p_{yc} \end{pmatrix}.$$

Označimo

$$p_{ij} = P(X = x_i, Y = y_j).$$

- $\frac{n_{ij}}{n}$  je procjenitelj za  $p_{ij}$ .
- $\frac{n_{xi}}{n}$  je procjenitelj za  $p_{xi}$ .
- $\frac{n_{yj}}{n}$  je procjenitelj za  $p_{yj}$ .

Obilježja  $X$  i  $Y$  ne ovise jedno o drugome

$\longleftrightarrow$  Slučajne varijable  $X$  i  $Y$  su nezavisne:

$$p_{ij} = P(X = x_i, Y = y_j) = P(X = x_i) \cdot P(Y = y_j) = p_{xi} \cdot p_{yj}.$$

Testiramo hipotezu:

Hipoteza o nezavisnosti:

$$H_0 : p_{ij} = p_{xi} \cdot p_{yj} \quad \text{za sve } i, j.$$

Za testiranje hipoteze edfiniramo očekivane frekvencije

$$E_{ij} = n \cdot \frac{n_{xi}}{n} \cdot \frac{n_{yj}}{n} = \frac{n_{xi} \cdot n_{yj}}{n}$$

Ovdje smo iskoristili pretpostavku o nezavisnosti slučajnih varijabli  $X$  i  $Y$ .

Ukoliko je hipoteza točna tada je statistika

$$\chi^2 = \sum_i \sum_j \frac{(n_{ij} - E_{ij})^2}{E_{ij}}$$

distribuirana prema  $\chi^2$  razdiobi.

## Broj stupnjeva slobode

Za test smo procijenili parametre  $p_{x1}, p_{x2}, \dots, p_{xk}$  i  $p_{y1}, p_{y2}, \dots, p_{yc}$ .

No kako je

$$\sum_i p_{xi} = 1 \quad \text{i} \quad \sum_j p_{yj} = 1$$

imamo samo  $k - 1$  i  $c - 1$  stupnjeva slobode, tj.  $k + c - 2$  procijenjenih parametara.

Ukupno imamo  $k \cdot c$  frekvencija ( $n_{ij}$ ).

Jer je

$$\sum_i \sum_j n_{ij} = n$$

to daje  $k \cdot c - 1$  stupnjeva slobode.

Ukupan broj stupnjeva slobode je

$$\text{d.f.} = k \cdot c - 1 - (k + c - 2) = k \cdot c - k - c + 1 = (c - 1) \cdot (k - 1).$$

Statistika  $\chi^2$  je distribuirana:

$$\chi^2 \sim \chi^2((c - 1) \cdot (k - 1))$$

Uočimo da su testovi za homogenost i nezavisnost isti.

Razlikuju se po interpretaciji i načinu određivanja uzorka.

- test homogenosti -  $n_{yj}$  je zadan (veličina uzorka)
- test nezavisnosti -  $n_{yj}$  je izračunat iz uzorka

U Statistici se za oba testa koristi ista procedura.

Vratimo se primjeru s početka.

Izračunamo očekivane frekvencije  $E_{ij} = \frac{n_{xi} \cdot n_{yj}}{n}$  (prikazane u zagradama).

		Boja kose		
		Svetla	Tamna	Ukupno
Boja očiju	Plave	32 (24.1)	12 (19.9)	44
	Smeđe	14 (19.7)	22 (16.3)	36
	Ostalo	6 (8.2)	9 (6.8)	15
	Ukupno	52	43	95

$$\chi^2 = \frac{7.9^2}{24.1} + \frac{(-7.9)^2}{19.9} + \frac{(-5.7)^2}{19.7} + \frac{5.7^2}{16.3} + \frac{(-2.2)^2}{8.2} + \frac{2.2^2}{6.8} = 10.67.$$

$$d.f. = (3 - 1) \cdot (2 - 1) = 2$$

$$\chi^2_{0.95}(2) = 5.99$$

Jer je  $\chi^2 > \chi^2_{0.95}(2)$  odbacujemo hipotezu o nezavisnosti.

Boja očiju i boja kose su povezani.

# Narušavanje pretpostavki $\chi^2$ testa

Pretpostavka  $\chi^2$  testa:

Barem 80 % očekivanih frekvencije u klijetkama trebaju biti veće ili jednake od 5 a sve moraju biti veće ili jednake od 1.

Pretpostavka  $2 \times 2 \chi^2$  testa:

Sve frekvencije su veće ili jednake od 5.

Ukoliko pretpostavke nisu zadovoljene treba koristiti **Fisherov egzaktni test**.

Ili spojiti kategorije da bismo povećali očekivane frekvencije.

Statistica koristi Fisherov egzaktni test samo za  $2 \times 2$  tablice.

Crosstabulation Tables Results: primjer-6-3.sta

Quick | Advanced | Options

Compute tables

Highlight counts >

Expected frequencies

Residual frequencies

Percentages of total count

Percentages of row counts

Percentages of column counts

Statistics for two-way tables

Pearson & M-L Chi-square

Fisher exact, Yates, McNemar (2 x 2)

Phi (2x2 tables) & Cramér's V & C

Kendall's tau-b & tau-c

Gamma

Spearman rank order correlation

Somer's d

Uncertainty coefficients

Summary

Cancel

Options

By Group...

To compute Max. Likelihood Chi-squares and to analyze multi-way frequency tables use the Log-Linear module.

# Testiranje hipoteze o normalnosti

Normalna distribucija obilježja u populaciji je osnovna prepostavka  $t$ -testa i ANOVA testa.

Kako provjeriti ovu prepostavku?

**Primjer.** Promatrat čemo dva primjera mjerjenja:

V1	V2	V1	V2
3.32304	6.35024	5.93744	4.52704
4.69216	7.83632	4.42384	10.30624
1.86448	1.38976	4.00416	9.47376
3.83904	1.62368	2.79328	5.39392
1.89888	1.80944	5.0568	3.63264
4.58208	2.65568	2.73824	2.3736
3.32304	3.59824	3.27488	3.19232
3.08224	9.79024	2.18784	3.8528
6.03376	1.19024	1.4448	2.6144
7.0864	2.48368	3.13728	
1.86448			

# Deskriptivna statistika

The screenshot shows the SPSS Output Viewer window titled "Workbook4\* - Descriptive Statistics (primjer-6-4.sta)". The left pane displays a tree structure of the project: "Workbook4\*", "Basic Statistics/Ta...", and "Descriptive st...". The right pane contains a table titled "Descriptive Statistics (primjer-6-4.sta)" with the following data:



Variable	Valid N	Mean	Minimum	Maximum	Std.Dev.	Skewness	Kurtosis
Var1	21	3,647055	1,444800	7,08640	1,522592	0,615484	-0,175884
Var2	19	4,426013	1,190240	10,30624	2,953967	0,967397	-0,330334

Za normalnu razdiobu je

- zakošenost = 0
- spljoštenost = 0 (kurtosis je 3 ali se koristi pomak od -3)



## Grafički prikaz

### Normalna krivulja



## Normalni plot

Normalna razdioba je prikazana kao pravac.





# Kolmogorov-Smirnov test



Na osnovu uzorka odredimo eksperimentalnu funkciju distribucije.

Izračunamo  $\bar{X}$  i  $S^2$ .


Usporedimo eksperimentalnu funkciju distribucije s funkcijom distribucije normalne razdiobe  $N(\bar{X}, S^2)$ .



## Funkcija gustoće i funkcija distribucije



Kolmogorov-smirnov test koristi statistiku  $D$ =najveće odstupanje eksperimentalne funkcije distribucije i očekivane normalne funkcije distribucije.



Kolmogorov-Smirnov test se može koristiti za proizvoljnu razdiobu.

**Shapiro-Wilkov test** - testira hipotezu o normalnosti populacije.

Snaga je veća nego kod Kolmogorov-Smirnov testa.

## Izbor statistike (Deskriptivna statistika)

Descriptive Statistics: primjer-6-4.sta

Variables: ALL

Quick | Advanced | Robust | Normality | Prob. & Scatterplots | Categ. plots | Options |

Distribution

Frequency tables  Histograms

Categorization

Number of intervals: 10

Integer intervals (categories)

Normal expected frequencies

Kolmogorov-Smirnov & Lilliefors test for normality

Shapiro-Wilk's W test

Use Distribution Fitting, Process Analysis, or Graphs (P-P or Q-Q) to fit other distributions; use Survival Analysis to fit distributions to censored data.

Stem and leaf

3D histograms, bivariate distributions  Stem & leaf plot  Compressed

By Group...

Summary | Cancel | Options | SELECT CASES | S | W | Wghtd moments | DF = | W-1 | N-1 | MD deletion | Casewise | Pairwise



## Frequency table

Category	Frequency table: Var1 (primjer-6-4.sta)					
	Count	Cumulative Count	Percent of Valid	Cumul % of Valid	% of all Cases	Cumulative % of All
0,000000<x<=1,000000	0	0	0,00000	0,0000	0,00000	0,0000
1,000000<x<=2,000000	4	4	19,04762	19,0476	19,04762	19,0476
2,000000<x<=3,000000	3	7	14,28571	33,3333	14,28571	33,3333
3,000000<x<=4,000000	6	13	28,57143	61,9048	28,57143	61,9048
4,000000<x<=5,000000	4	17	19,04762	80,9524	19,04762	80,9524
5,000000<x<=6,000000	2	19	9,52381	90,4762	9,52381	90,4762
6,000000<x<=7,000000	1	20	4,76190	95,2381	4,76190	95,2381
7,000000<x<=8,000000	1	21	4,76190	100,0000	4,76190	100,0000
Missing	0	21	0,00000		0,00000	100,0000

Category	Frequency table: Var2 (primjer-6-4.sta)					
	Count	Cumulative Count	Percent of Valid	Cumul % of Valid	% of all Cases	Cumulative % of All
0,000000<x<=2,000000	4	4	21,05263	21,0526	19,04762	19,0476
2,000000<x<=4,000000	8	12	42,10526	63,1579	38,09524	57,1429
4,000000<x<=6,000000	2	14	10,52632	73,6842	9,52381	66,6667
6,000000<x<=8,000000	2	16	10,52632	84,2105	9,52381	76,1905
8,000000<x<=10,00000	2	18	10,52632	94,7368	9,52381	85,7143
10,00000<x<=12,00000	1	19	5,26316	100,0000	4,76190	90,4762
Missing	2	21	10,52632		9,52381	100,0000





## Graphs 1



Ako populacija nije normalna:

- izabrati test koji nema pretpostavku o normalnosti populacije (neparametarski testovi)
- transformirati podatke (npr. logaritamska transformacija, Box-Coxova transformacija, korijen, inverzna transformacija, . . . )

Za ilustraciju čemo logaritmirati drugi set podataka iz primjera (V2)



# Normal plot

