

TESTIRANJE HIPOTEZA O DISTRIBUCIJI

Pearsonov χ^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 jednostruke 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	
	Opazena	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 χ^2 razdiobi s $k - 1$ stupnjeva slobode:

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

Pretpostavka χ^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 \rightarrow 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: $\chi^2(1)$.

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

$\chi^2 = 1 < 3.84 = \chi_{0.95}^2(1) \rightarrow$ 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 χ^2 -test su ekvivalentni.

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

Primjer. Istraživač za slučajni izbor u uzorak koristi igraću 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	
	Opazena	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: $\chi^2(5)$.

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

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

Kocka je simetrična.

Rješenje primjera u R-u

```
chisq.test(x, p)
```

- x - vektor opaženih frekvencija
- p - vektor teorijskih (očekivanih) proporcija

```
> observed <- c(23, 15, 16, 28, 17, 21)
> expected <- c(1/6, 1/6, 1/6, 1/6, 1/6, 1/6)
> chisq.test(x=observed,p=expected)
```

Chi-squared test for given probabilities

```
data:  observed
```

```
X-squared = 6.2, df = 5, p-value = 0.2872
```

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 ($X \sim \text{Po}(\lambda)$):

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

λ nije zadan pa ga procjenjujemo iz podataka.

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

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

Provjeravamo da li se radi o $\text{Po}(2.05)$ 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	2.65	1.03

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

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

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

Hipoteza o homogenosti:

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

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 **kontingencijskoj 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}
\vdots	\vdots	\vdots	\vdots		\vdots
x_k	n_{k1}	n_{k2}	n_{k3}	...	n_{kc}
Ukupno	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}
\vdots	\vdots	\vdots	\vdots		\vdots	
x_k	n_{k1}	n_{k2}	n_{k3}	...	n_{kc}	n_{xk}
Ukupno	n_{y1}	n_{y2}	n_{y3}	...	n_{yc}	n

Budući da pretpostavljamo jednaku razdiobu u svim populacijama:

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

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:

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

Ukoliko je hipoteza točna, statistika

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

distribuirana prema χ^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

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

Statistika χ^2 je distribuirana:

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

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)	233 (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

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

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

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

Pogledajmo doprinos svake grupe χ^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 R-u

Podaci:

```
> podaci <- matrix(c(32, 268, 51, 199, 67, 233, 83,
267), ncol=2, byrow=TRUE)

> colnames(podaci) <- c("Alk", "Nealk")

> rownames(podaci) <- c("Sport 1", "Sport 2", "Sport
3", "Sport 4")
```

Treba nam tip *table*:

```
> data <- as.table(podaci)
```

```
> podaci
```

```
      Alk Nealk
```

```
Sport 1  32 268
```

```
Sport 2  51 199
```

```
Sport 3  67 233
```

```
Sport 4  83 267
```

χ^2 -test:

```
> chisq.test(podaci)
```

```
Pearson's Chi-squared test
```

```
data: podaci
```

```
X-squared = 20.597, df = 3, p-value = 0.0001277
```

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 kontingencijskoj tablici:

		Y					Ukupno
		y_1	y_2	y_3	...	y_c	
X	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}
	\vdots	\vdots	\vdots	\vdots		\vdots	\vdots
	x_k	n_{k1}	n_{k2}	n_{k3}	...	n_{kc}	n_{xk}
Ukupno		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 definiramo očekivane frekvencije

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

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 χ^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 χ^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				Ukupno
		Svjetla		Tamna		
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

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

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

$$\chi_{0.95}^2(2) = 5.99$$

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

Boja očiju i boja kose su povezani.

Narušavanje pretpostavki χ^2 testa

Pretpostavka χ^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 2×2 χ^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.

Fisherov egzaktni test

```
> fisher.test(podaci )
```

Fisher's Exact Test for Count Data

data: podaci

p-value = 5.281e-05

alternative hypothesis: two.sided

χ^2 -test:

```
> chisq.test(podaci)
```

Pearson's Chi-squared test

data: podaci

X-squared = 20.597, df = 3, p-value = 0.0001277

Testiranje hipoteze o normalnosti

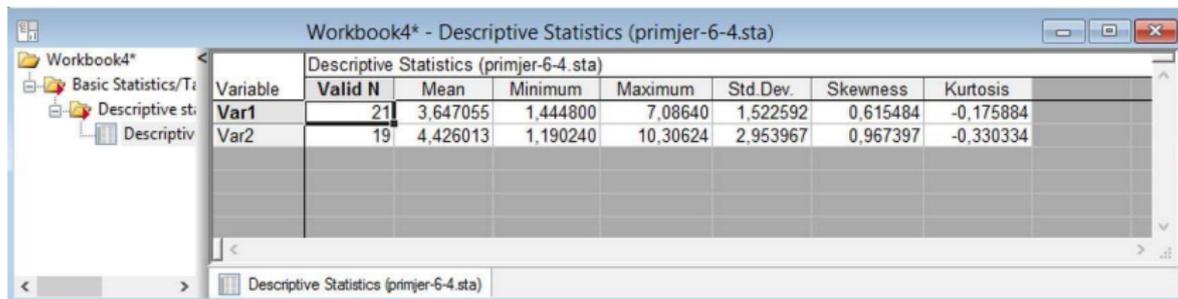
Normalna distribucija obilježja u populaciji je osnovna pretpostavka t -testa i ANOVA testa.

Kako provjeriti ovu pretpostavku?

Primjer. Promatrat ćemo dva primjera mjerenja:

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



Workbook4* - Descriptive Statistics (primjer-6-4.sta)

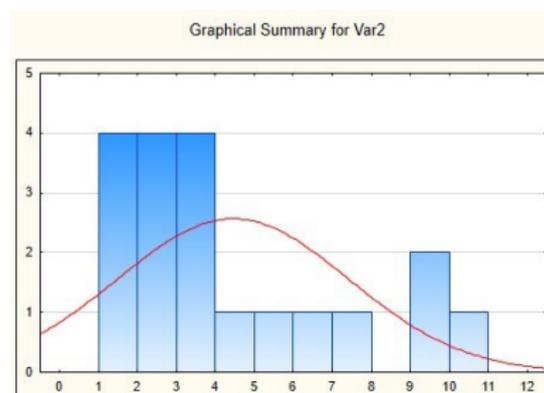
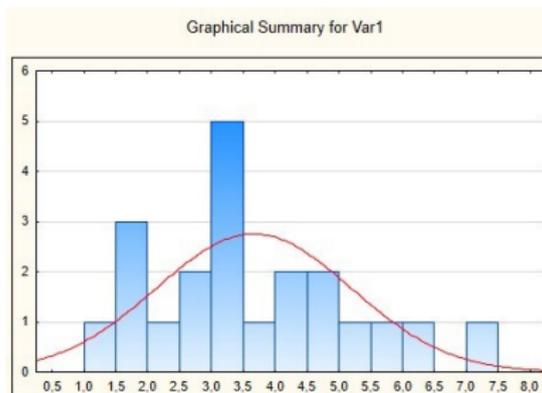
Variable	Valid N	Mean	Minimum	Maximum	Std.Dev.	Skewness	Kurtosis
Var1	21	3,647055	1,444800	7,08640	1,522592	0,615484	-0,175884
Var2	19	4,426013	1,190240	10,30624	2,953967	0,967397	-0,330334

Za normalnu razdiobu je

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

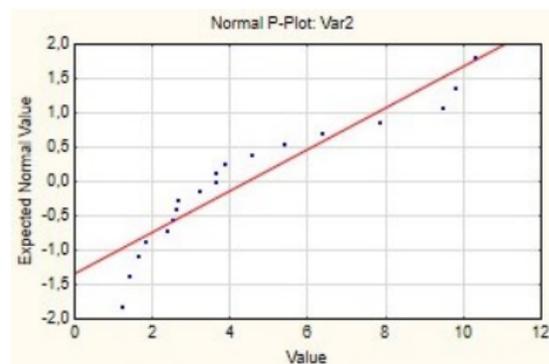
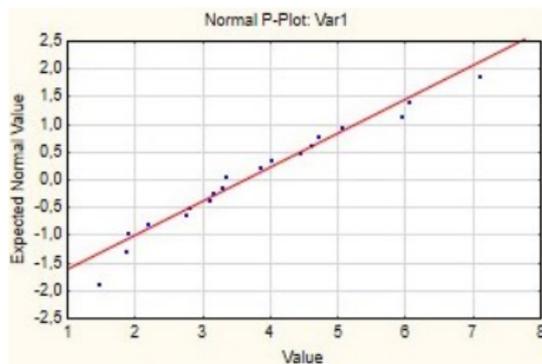
Grafički prikaz

Normalna krivulja



Normalni plot

Normalna razdioba je prikazana kao pravac.

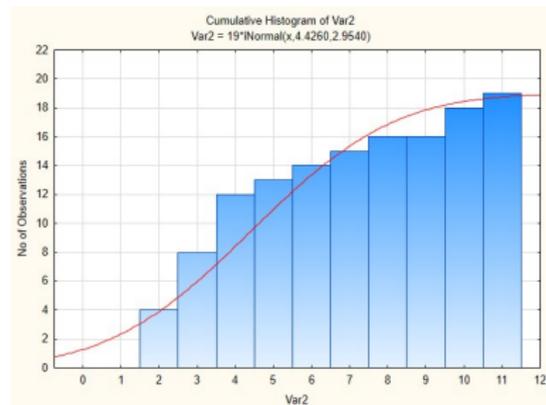
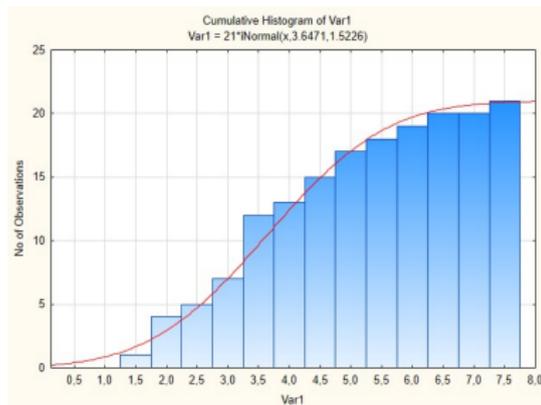


Kolmogorov-Smirnov test

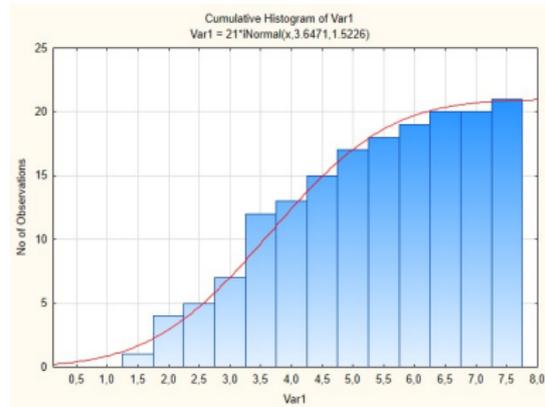
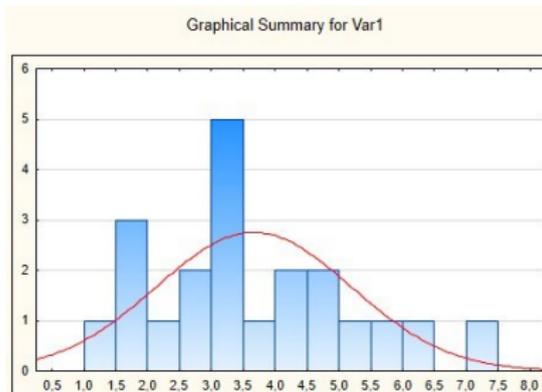
Na osnovu uzorka odredimo eksperimentalnu funkciju distribucije.

Izračunamo \bar{X} i S^2 .

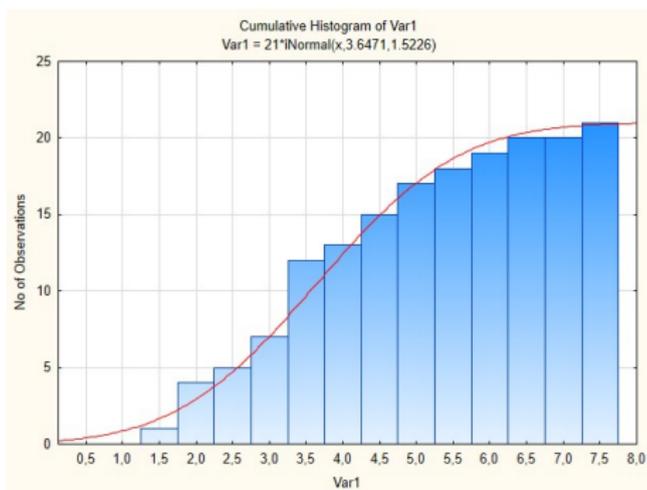
Usporedimo eksperimentalnu funkciju distribucije s funkcijom distribucije normalne razdiobe $N(\bar{X}, S^2)$.



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.

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, ...)