

13.6 LINEARNA KORELACIJA

- Koeficijent linearne korelaciјe
- Testiranje hipoteze o koeficijentu proste linearne korelaciјe

Koeficijent linearne korelacije

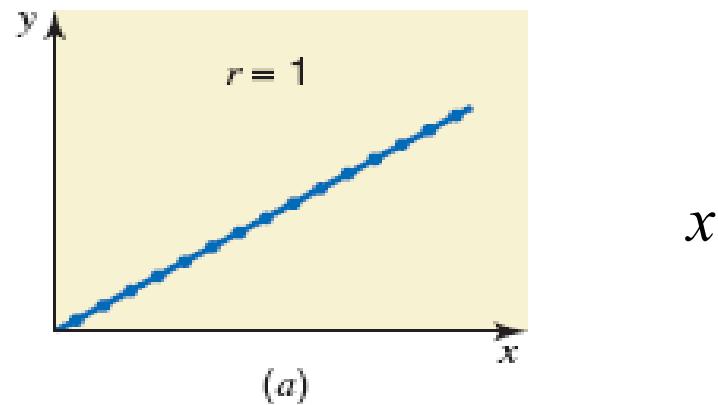
Vrijednost koeficijenta proste linearne korelacije

Vrijednost koeficijenta proste linearne korelacije je uvijek u intervalu od -1 do 1; odnosno,

$$-1 \leq \rho \leq 1 \quad \text{i} \quad -1 \leq r \leq 1$$

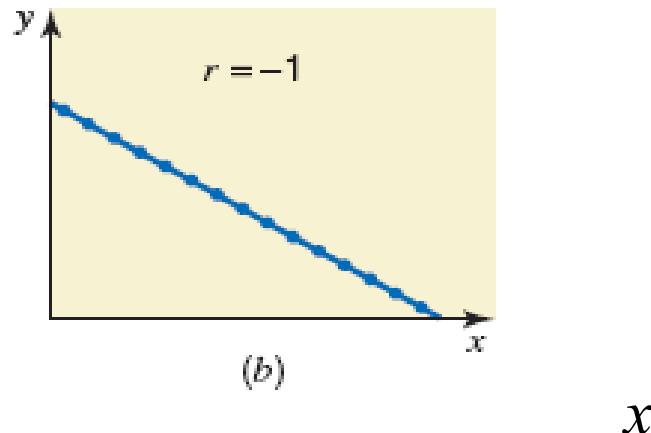
Slika 13.18 Linearna korelacija između dvije promjenljive.

(a) Perfektna pozitivna linearna korelacija, $r = 1$



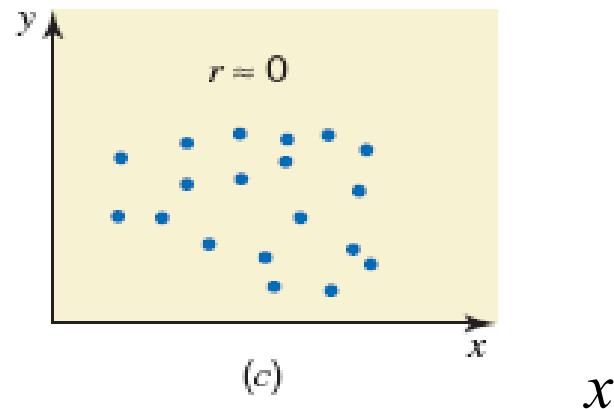
Slika 13.18 Linearna korelacija između dvije promjenljive.

(b) Perfektna negativna linearna korelacija, $r = -1$

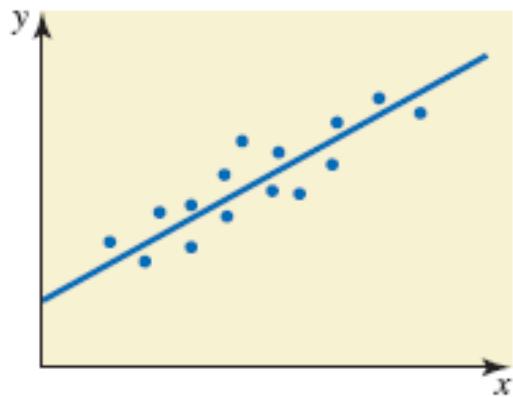


Slika 13.18 Linearna korelacija između dvije promjenljive.

(c) Nepostojanje linearne korelacijske, $r \approx 0$

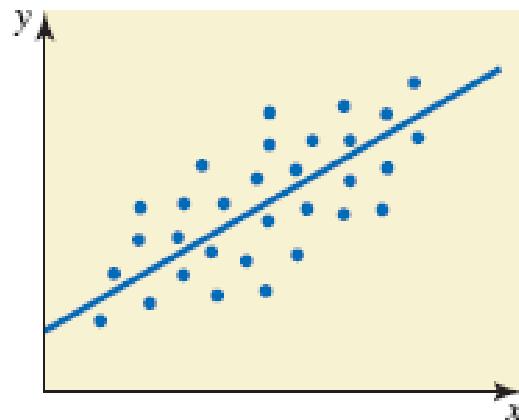


Slika 13.19 Linearna korelacija između dvije promjenljive.



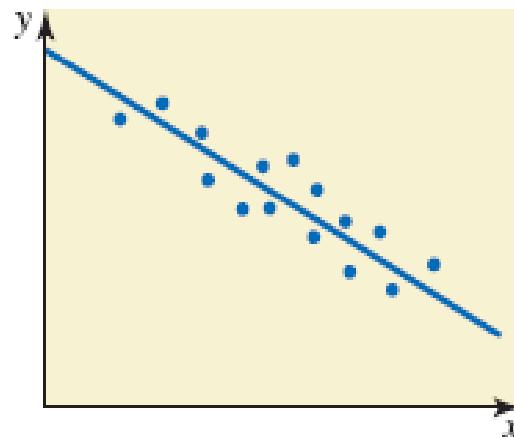
(a) Strong positive linear correlation
(r is close to 1)

Slika 13.19 Linearna korelacija između dvije promjenljive.



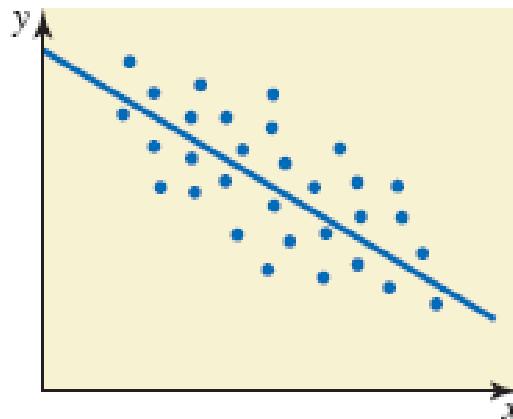
(b) Weak positive linear correlation
(r is positive but close to zero)

Slika 13.19 Linearna korelacija između dvije promjenljive.



(c) Strong negative linear correlation
(r is close to -1)

Slika 13.19 Linearna korelacija između dvije promjenljive.



(d) Weak negative linear correlation
(r is negative and close to zero)

Koeficijent proste linearne korelaciјe

Koeficijent proste linearne korelaciјe

Koeficijent proste linearne korelaciјe, označen sa r, mjeri jačinu linearne veze između dvije promjenljive u uzorku i glasi:

$$r = \frac{SS_{xy}}{\sqrt{SS_{xx} SS_{yy}}}$$

Primjer 13-6

Izračunati koeficijent korelacijske za primjer o dohotku i izdacima za hranu sedam domaćinstava.

Primjer 13-6: Rješenje

$$r = \frac{SS_{xy}}{\sqrt{SS_{xx} SS_{yy}}}$$
$$= \frac{447.5714}{\sqrt{(1772.8571)(125.7143)}} = .95$$

Testiranje hipoteze o koeficijentu proste linearne korelaciјe

Statistika testa za r

Pod pretpostavkom da je zajednički raspored dvije promjenljive normalan i za $H_0: \rho = 0$, statistika t testa glasi

$$t = r \sqrt{\frac{n-2}{1-r^2}}$$

Ovdje označka $n - 2$ predstavlja stepene slobode.

Primjer 13-7

Koristeći nivo značajnosti 1% i podatke iz primjera 13-1, testirati da li je koeficijent linearne korelacije između dohotka i izdataka za hranu statistički značajan. Pretpostavka je da je zajednička raspodjela dvije promjenljive normalna.

Primjer 13-7: Rješenje

- Etapa 1:
- $H_0: \rho = 0$ (koeficijent linearne korelacijske je jednak nuli)
- $H_1: \rho \neq 0$ (koeficijent linearne korelacijske je različit od nule)

- Etapa 2: Pod pretpostavkom da je zajednička raspodjela dvije promjenljive normalna, za testiranje hipoteze o koeficijentu proste linearne korelacijske koristimo t raspodjelu.

Primjer 13-7: Rješenje

- Etapa 3:
- Površina na oba kraja raspodjele = $0.01/2$
= 0.005
- $df = n - 2 = 7 - 2 = 5$
- Kritična vrijednost $t = 4.032$

Primjer 13-7: Rješenje

Etapa 4:

$$t = r \sqrt{\frac{n - 2}{1 - r^2}}$$

$$= .95 \sqrt{\frac{7 - 2}{1 - (.95)^2}} = 6.803$$

Primjer 13-7: Rješenje

- Etapa 5:
- Vrijednost statistike testa $t = 6.803$
 - Veća je od kritične vrijednosti $t=4.032$
 - Nalazi se u oblasti odbacivanja
- Dakle, odbacujemo nultu hipotezu
- Zaključujemo da postoji pozitivna veza između dohotka i izdataka za hranu.

13.7 REGRESIONA ANALIZA: **KOMPLETAN PRIMJER**

Primjer 13-8

Izabran je slučajan uzorak od osam vozača koji posjeduju polise auto osiguranja. U sledećoj tabeli nalaze se podaci o vozačkom iskustvu (u godinama) i iznosu mjesecne premije auto osiguranja (u dolarima).

Primjer 13-8

Driving Experience (years)	Monthly Auto Insurance Premium (\$)
5	64
2	87
12	50
9	71
15	44
6	56
25	42
16	60

Primjer 13-8

- a) Da li premija osiguranja zavisi od vozačkog iskustva ili vozačko iskustvo zavisi od premije osiguranja? Da li očekujete pozitivnu ili negativnu vezu između ove dvije promjenljive?
- b) Izračunajte SS_{xx} , SS_{yy} i SS_{xy} .
- c) Odrediti regresionu pravu po metodu najmanjih kvadrata na osnovu identifikovane objašnjavajuće i zavisne promjenljive u dijelu zadatka pod a.
- d) Objasnite značenje dobijenih ocijenjenih vrijednosti a i b izračunatih u dijelu pod c.

Primjer 13-8

- e) Nacrtajte dijagram raspršenosti i ucrtajte ocijenjenu regresiju pravu.
- f) Izračunajte koeficijente r i r^2 i objasnite njihovo značenje.
- g) Ocijenite mjesecnu premiju auto osiguranja vozača sa 10 godina iskustva u vožnji.
- h) Izračunajte standardnu grešku regresije.
- i) Formirajte 90% interval povjerenja za parametar B .
- j) Testirati sa nivoom značajnosti od 5% da li je B statistički značajno.
- k) Uz $\alpha = 0.05$, testirati da li se koeficijent ρ značajno razlikuje od nule.

Primjer 13-8: Rješenje

- a) Na osnovu teorije i intuitivno, očekujemo da će premija osiguranja zavisiti od vozačkog iskustva
- Premija osiguranja je zavisna promjenljiva
 - Vozačko iskustvo je objašnjavajuća promjenljiva

Tabela 13.5

Experience	Premium			
x	y	xy	x^2	y^2
5	64	320	25	4096
2	87	174	4	7569
12	50	600	144	2500
9	71	639	81	5041
15	44	660	225	1936
6	56	336	36	3136
25	42	1050	625	1764
16	60	960	256	3600
$\Sigma x = 90$	$\Sigma y = 474$	$\Sigma xy = 4739$	$\Sigma x^2 = 1396$	$\Sigma y^2 = 29,642$

Primjer 13-8: Rješenje

$$\text{b) } \bar{x} = \sum x / n = 90 / 8 = 11.25$$

$$\bar{y} = \sum y / n = 474 / 8 = 59.25$$

$$SS_{xy} = \sum xy - \frac{(\sum x)(\sum y)}{n} = 4739 - \frac{(90)(474)}{8} = -593.5000$$

$$SS_{xx} = \sum x^2 - \frac{(\sum x)^2}{n} = 1396 - \frac{(90)^2}{8} = 383.5000$$

$$SS_{yy} = \sum y^2 - \frac{(\sum y)^2}{n} = 29,642 - \frac{(474)^2}{8} = 1557.5000$$

Primjer 13-8: Rješenje

c)

$$b = \frac{SS_{xy}}{SS_{xx}} = \frac{-593.5000}{383.5000} = -1.5476$$

$$a = \bar{y} - b\bar{x} = 59.25 - (-1.5476)(11.25) = 76.6605$$

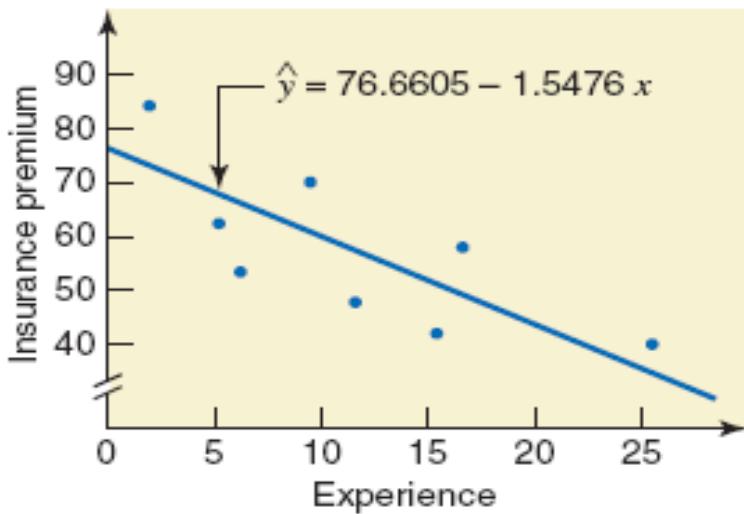
$$\hat{y} = 76.6605 - 1.547x$$

Primjer 13-8: Rješenje

- d) Ocijenjena vrijednost $a = 76.6605$ predstavlja vrijednost \hat{y} za $x = 0$; odnosno, prosječni mjesecni nivo premije osiguranja za vozača bez vozačkog iskustva.
- Ocijenjena vrijednost $b = -1.5476$ pokazuje da sa porastom vozačkog iskustva za 1 godinu, mjesecna premija osiguranja u prosjeku opada za \$1.55.

Slika 13.21 Dijagram raspršenosti i regresiona prava.

e) Regresiona prava je opadajuća.



Primjer 13-8: Rješenje

f)

$$r = \frac{SS_{xy}}{\sqrt{SS_{xx} SS_{yy}}} = \frac{-593.5000}{\sqrt{(383.5000)(1557.5000)}} = -.77$$

$$r^2 = \frac{bSS_{xy}}{SS_{yy}} = \frac{(-1.5476)(-593.5000)}{1557.5000} = .59$$

Primjer 13-8: Rješenje

f) Vrijednost $r = -0.77$ pokazuje da između vozačkog iskustva i mjesecne premije auto osiguranja postoji jaka negativna korelaciona veza.

Vrijednost $r^2 = 0.59$ pokazuje da je 59% ukupnih varijacija mjesecne premije objašnjeno vozačkim iskustvom, dok je ostatak od 41% rezultat uticaja drugih faktora.

Primjer 13-8: Rješenje

- g) Na osnovu regresione prave uzorka, ocijenjena vrijednost y za $x = 10$ iznosi

$$\hat{y} = 76.6605 - 1.5476(10) = \$61.18$$

Dakle, očekujemo da će mjesecni iznos premije auto osiguranja vozača sa 10 godina vozačkog iskustva biti \$61.18.

Primjer 13-8: Rješenje

h)

$$\begin{aligned}s_e &= \sqrt{\frac{SS_{yy} - bSS_{xy}}{n-2}} \\&= \sqrt{\frac{1557.5000 - (-1.5476)(-593.5000)}{8-2}} \\&= 10.3199\end{aligned}$$

Primjer 13-8: Rješenje

i) $s_b = \frac{s_e}{\sqrt{SS_{xx}}} = \frac{10.3199}{\sqrt{383.5000}} = .5270$

$$\alpha/2 = .5 - (.90/2) = .05$$

$$df = n - 2 = 8 - 2 = 6$$

$$t = 1.943$$

$$\begin{aligned} b \pm ts_b &= -1.5476 \pm 1.943(.5270) \\ &= -1.5476 \pm 1.0240 = -2.57 \text{ to } -.52 \end{aligned}$$

Primjer 13-8: Rješenje

j)

- Etapa 1:
- $H_0: B = 0$ (B je jednak nuli)
- $H_1: B \neq 0$ (B je različito od nule)

Primjer 13-8: Rješenje

- Etapa 2: Budući da standardna devijacija slučajne greške nije poznata, koristimo t raspodjelu za testiranje

- Etapa 3:
- Površina na oba kraja raspodjele = $\alpha/2 = 0.05/2 = 0.025$
- $df = n - 2 = 8 - 2 = 6$
- Kritične vrijednosti t su -2.447 i 2.447

Primjer 13-8: Rješenje

Etapa 4:

$$t = \frac{b - B}{s_b} = \frac{-1.5476 - 0}{.5270} = -2.937$$

Iz H_0

Primjer 13-8: Rješenje

- Etapa 5:
- Vrijednost statistike testa $t = -2.937$
 - Nalazi se u oblasti odbacivanja
- Dakle, odbacujemo nultu hipotezu i zaključujemo da je parametar B statistički značajan
- Mjesečni iznos premije auto osiguranja u osnovnom skupu vozača u prosjeku opada sa povećanjem vozačkog iskustva.

Primjer 13-8: Rješenje

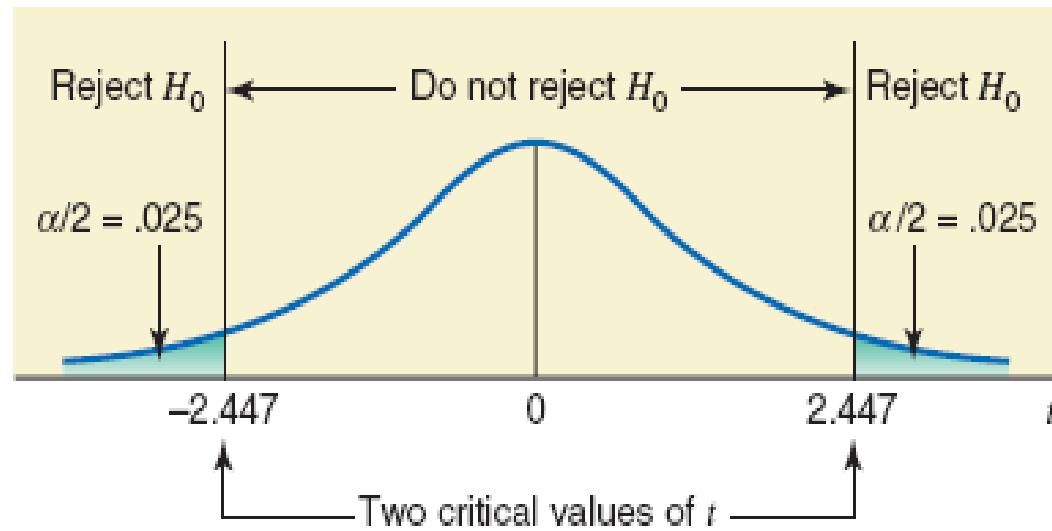
k)

- Etapa 1:
- $H_0: \rho = 0$ (koeficijent linearne korelacijske je jednak nuli)
- $H_1: \rho \neq 0$ (koeficijent linearne korelacijske je različit od nule)

Primjer 13-8: Rješenje

- Etapa 2: Pod pretpostavkom da je zajednička raspodjela dvije promjenljive x i y normalna, za testiranje hipoteze o koeficijentu linearne korelacije koristimo t raspodjelu.
- Etapa 3:
- Površina na svakom kraju = $0.05/2 = 0.025$
- $df = n - 2 = 8 - 2 = 6$
- Kritične vrijednosti t su -2.447 i 2.447

Slika 13.23



Primjer 13-8: Rješenje

Etapa 4:

$$t = r \sqrt{\frac{n - 2}{1 - r^2}}$$
$$= -.77 \sqrt{\frac{8 - 2}{1 - (-.77)^2}} = -2.956$$

Primjer 13-8: Rješenje

- Etapa 5:
- Vrijednost statistike testa $t = -2.956$
 - Nalazi se u oblasti odbacivanja
- Dakle, odbacujemo nultu hipotezu
- Zaključujemo da se koeficijent proste linearne korelacije između godina vozačkog iskustva i visine premije osiguranja u osnovnom skupu vozača statistički značajno razlikuje od nule.

13.9 PROBLEMI U KORIŠĆENJU REGRESIONOG MODELA

- Ekstrapolacija: Regresiona prava ocijenjena na osnovu uzorka odnosi se samo na opseg vrijednosti x koje su obuhvaćene uzorkom.

- Uzročnost: Regresiona prava ne pokazuje uzročnost između dvije promjenljive: odnosno, ne predviđa da je promjena y uzrokovana promjenom x .