

POGLAVLJE 13



PROSTA LINEARNA REGRESIJA

13.1 PROST LINEARNI REGRESIONI MODEL

- Prosta regresija
- Linearna regresija

Prosta regresija

Definicija

Regresioni model je matematički model koji opisuje vezu između dvije ili više promjenljivih.

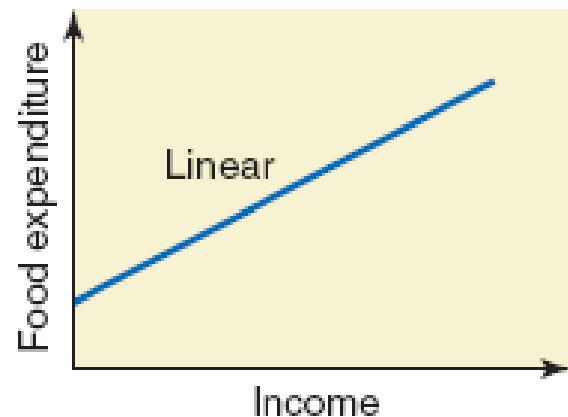
Prost regresioni model obuhvata samo dvije promjenljive: jednu objašnjavajuću i jednu zavisnu. Zavisna promjenljiva je promjenljiva čije varijacije treba da objasnimo na osnovu kretanja objašnjavajuće promjenljive.

Linearna regresija

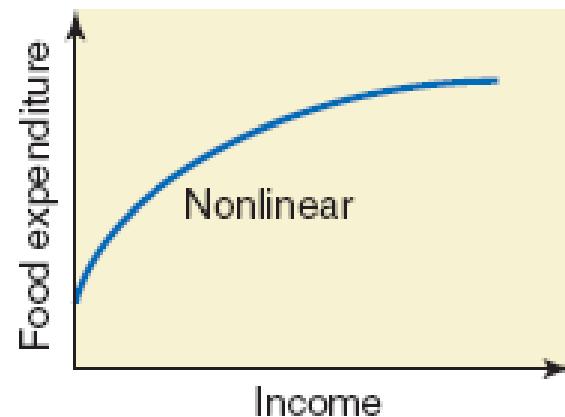
Definicija

Regresioni model kojim se opisuje linearna međuzavsinost između dvije promjenljive naziva se **prost linearne regresioni** model.

Slika 13.1 Veza između izdataka za hranu i dohotka. (a) Linearna veza. (b) Nelinearna veza.

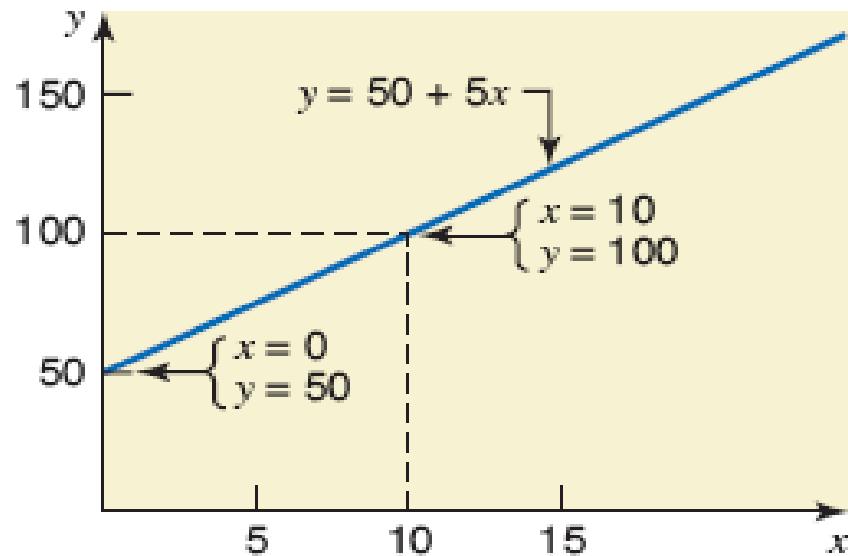


(a)

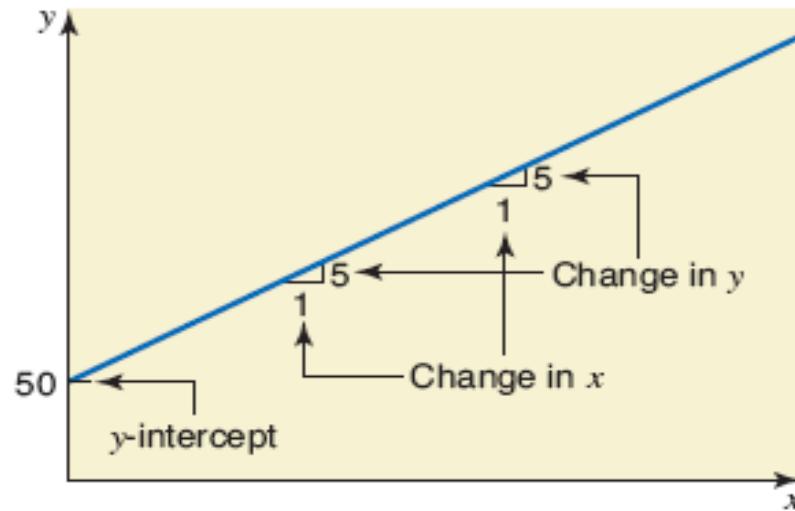


(b)

Slika 13.2 Grafički prikaz jednačine prave.



Slika 13.3 Odsječak i nagib prave linije.



13.2 PROSTA LINEARNA REGRESIONA ANALIZA

- Dijagram raspršenosti (rasturanja)
- Metod najmanjih kvadrata
- Interpretacija ocijenjenih vrijednosti a i b
- Pretpostavke prostog linearног regresionог modelа

PROSTA LINEARNA REGRESIONA ANALIZA

$$y = A + Bx$$

Constant term or y-intercept Slope
 ↓ ↓
 y x
 ↑ ↑
 Dependent variable Independent variable

PROSTA LINEARNA REGRESIONA ANALIZA

Definicija

U regresionom modelu $y = A + Bx + \varepsilon$, A je odsječak ili konstanta, B koeficijent nagiba, a ε slučajna greška. Zavisna i objašnjavajuća promjenljiva su y i x , respektivno.

PROSTA LINEARNA REGRESIONA ANALIZA

Definicija

U regresionom modelu uzorka $\hat{y} = a + bx$, koeficijenti a i b nazivaju se **ocjene parametara A i B**, respektivno.

Tabela 13.1 Dohodak (u stotinama dolara) i izdaci za hranu sedam domaćinstava

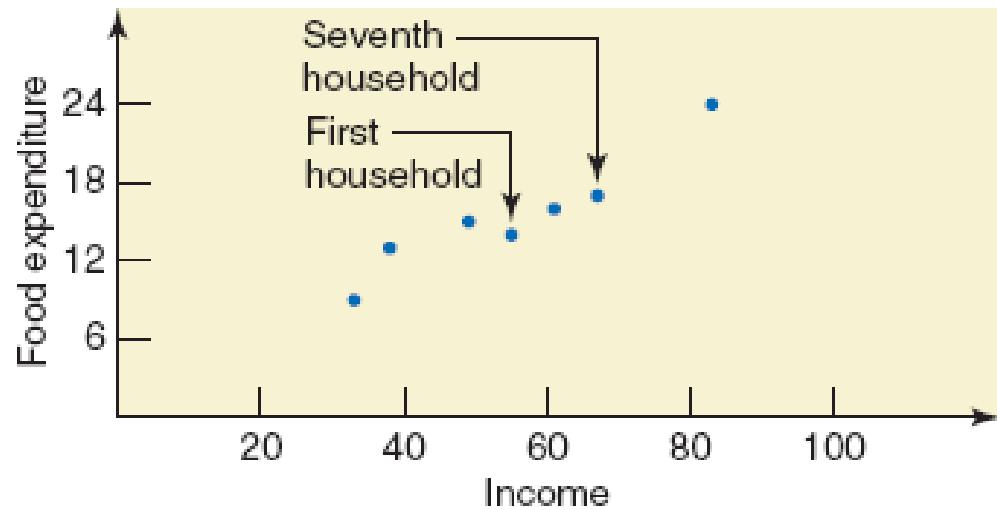
Income	Food Expenditure
55	14
83	24
38	13
61	16
33	9
49	15
67	17

Dijagram raspršenosti (rasturanja)

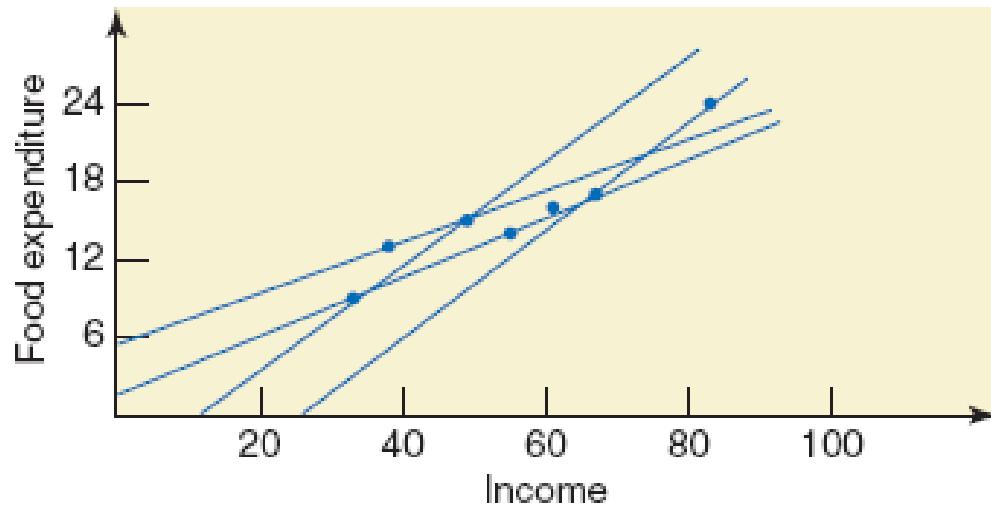
Definicija

Grafički prikaz parova podataka X i Y u osnovnom skupu (ili uzorku) naziva se **dijagram raspršenosti (rasturanja)**.

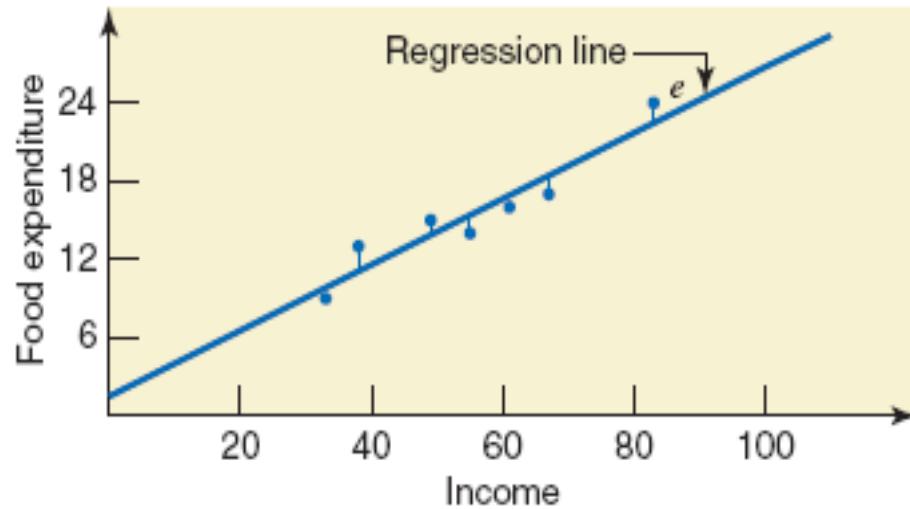
Slika 13.4 Dijagram raspršenosti.



Slika 13.5 Dijagram raspršenosti i regresione prave.



Slika 13.6 Regresiona prava i reziduali.



Suma kvadrata reziduala (SSE)

Suma kvadrata reziduala, u oznaci SSE, je

$$\text{SSE} = \sum e^2 = \sum (y - \hat{y})^2$$

Minimiziranjem sume kvadrata reziduala dobijaju se a i b kao ocjene regresionih parametara A i B , a regresiona prava koja se na osnovu tih ocjena dobija naziva se regresiona prava uzorka.

Linija regresije uzorka

Koeficijenti regresione prave uzorka
 $\hat{y} = a + bx$, odnosno ocjene po metodu
najmanjih kvadrata glase:

$$b = \frac{\text{SS}_{xy}}{\text{SS}_{xx}} \quad \text{i} \quad a = \bar{y} - b\bar{x}$$

Linija regresije uzorka

gdje je

$$ss_{xy} = \sum xy - \frac{(\sum x)(\sum y)}{n} \quad \text{ i } \quad ss_{xx} = \sum x^2 - \frac{(\sum x)^2}{n}$$

i gdje SS označava odgovarajuću "sumu kvadrata". Linija regresije uzorka $\hat{y} = a + bx$ se takođe naziva regresija od y na x .

Primjer 13-1

Na osnovu podataka slučajnog uzorka od sedam domaćinstava, prikazanih u Tabeli 13.1, ocijenite regresioni model primjenom metoda najmanjih kvadrata.

Objašnjavajuća promjenljiva je dohodak, a zavisna promjenljiva izdaci za hranu.

Tabela 13.2

Income <i>x</i>	Food Expenditure <i>y</i>	<i>xy</i>	<i>x</i> ²
55	14	770	3025
83	24	1992	6889
38	13	494	1444
61	16	976	3721
33	9	297	1089
49	15	735	2401
67	17	1139	4489
$\Sigma x = 386$	$\Sigma y = 108$	$\Sigma xy = 6403$	$\Sigma x^2 = 23,058$

Primjer 13-1: Rješenje

$$\sum x = 386$$

$$\sum y = 108$$

$$\bar{x} = \sum x / n = 386 / 7 = 55.1429$$

$$\bar{y} = \sum y / n = 108 / 7 = 15.4286$$

Primjer 13-1: Rješenje

$$SS_{xy} = \sum xy - \frac{(\sum x)(\sum y)}{n} = 6403 - \frac{(386)(108)}{7} = 447.5714$$

$$SS_{xx} = \sum x^2 - \frac{(\sum x)^2}{n} = 23,058 - \frac{(386)^2}{7} = 1772.8571$$

Primjer 13-1: Rješenje

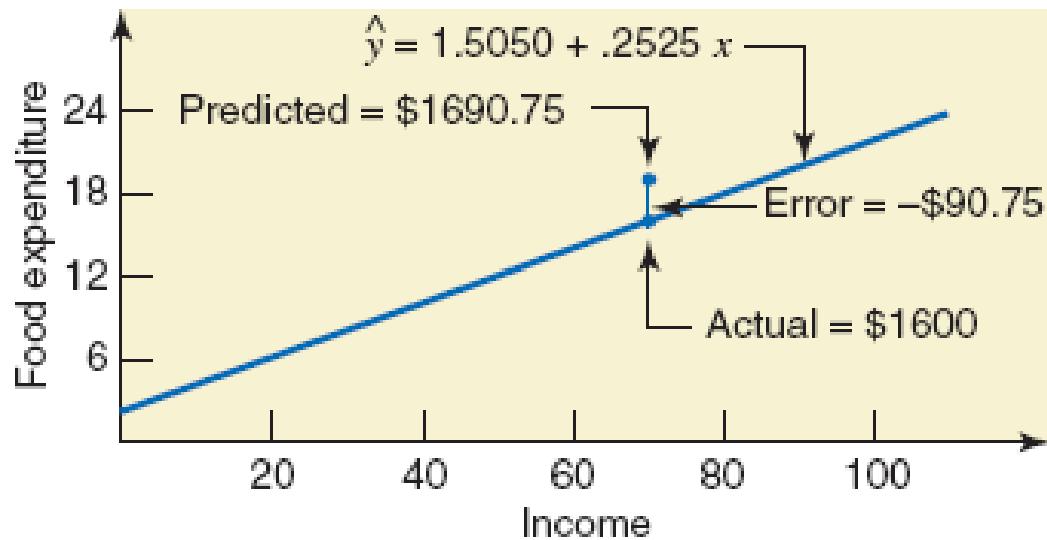
$$b = \frac{SS_{xy}}{SS_{xx}} = \frac{447.5714}{1772.8571} = .2525$$

$$a = \bar{y} - b\bar{x} = 15.4286 - (.2525)(55.1429) = 1.5050$$

Dakle, ocijenjeni regresioni model glasi

$$\hat{y} = 1.5050 + 0.2525 x$$

Slika 13.7 Rezidual.



Interpretacija ocijenjenih vrijednosti a i b

Interpretacija ocijenjene vrijednosti a

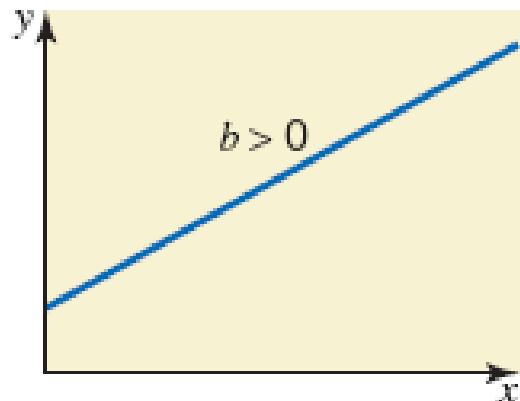
- Ukoliko razmatramo domaćinstvo sa nultim nivoom dohotka, na osnovu ocijenjene regresione prave iz primjera 13-1, dobijamo ocijenjenu vrijednost y za $x=0$:
 - $\hat{y} = 1.5050 + 0.2525(0) = \1.5050 stotina
- Dakle, možemo zaključiti da domaćinstvo koje ne ostvaruje nikakav dohodak troši \$150.50 mjesечно na hranu
- Regresiona prava važi samo za vrijednosti x između 33 i 83

Interpretacija ocijenjenih vrijednosti a i b

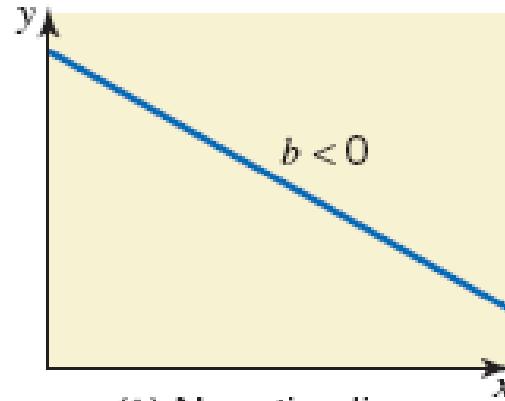
Interpretacija ocijenjene vrijednosti b

- Vrijednost b u regresionom modelu pokazuje koliko se u prosjeku promijeni y (zavisna promjenljiva) ako se x (objašnjavajuća promjenljiva) poveća za jednu svoju jedinicu.
- Možemo zaključiti, u prosjeku, da će rast dohotka od \$100 (ili \$1) imati za rezultat porast izdataka za hranu za \$25.25 (ili \$0.2525).

Slika 13.8 Pozitivna i negativna linearna veza između x i y.



(a) Positive linear relationship



(b) Negative linear relationship

Prepostavke prostog linearног regresionог modelа

Prepostavka 1:

Očekivana vrijednost slučajne greške ϵ jednaka je nuli za svaku vrijednost promjenljive x

Prepostavka 2:

Slučajne greške različitih opservacija su međusobno nezavisne

Prepostavke prostog linearног regresionог modelа

Prepostavka 3:

Za datu vrijednost promjenljive x ,
raspodjela slučajnih grešaka je normalna

Prepostavka 4:

Slučajne greške za svaku vrijednost
promjenljive x imaju konstantnu
standardnu devijaciju σ_ϵ

13.3 STANDARDNA DEVIJACIJA SLUČAJNE GREŠKE

Broj stepeni slobode u prostom linearном regresionom modelu

Broj stepeni slobode u prostom linearном regresionom modelu je

$$df = n - 2$$

STANDARDNA GREŠKA REGRESIJE

Standardna greška regresije izračunava se kao

$$s_e = \sqrt{\frac{SS_{yy} - bSS_{xy}}{n - 2}}$$

gdje

$$SS_{yy} = \sum y^2 - \frac{(\sum y)^2}{n}$$

Primjer 13-2

Na osnovu podataka datih u Tabeli 13.1, izračunajte standardnu grešku regresije.

Tabela 13.3

Income <i>x</i>	Food Expenditure <i>y</i>	<i>y</i> ²
55	14	196
83	24	576
38	13	169
61	16	256
33	9	81
49	15	225
67	17	289
$\Sigma x = 386$	$\Sigma y = 108$	$\Sigma y^2 = 1792$

Primjer 13-2: Rješenje

$$SS_{yy} = \sum y^2 - \frac{(\sum y)^2}{n} = 1792 - \frac{(108)^2}{7} = 125.7143$$

$$s_e = \sqrt{\frac{SS_{yy} - bSS_{xy}}{n-2}} \sqrt{\frac{125.7143 - .2525(447.5714)}{7-2}} = 1.5939$$

KOEFICIJENT DETERMINACIJE

Koeficijent determinacije

Koeficijent determinacije, označen sa r^2 , predstavlja učešće objašnjjenog u ukupnom varijabilitetu, odnosno r^2 je

$$r^2 = \frac{b \ SS_{xy}}{SS_{yy}}$$

i $0 \leq r^2 \leq 1$

Primjer 13-3

Na osnovu podataka u Tabeli 13.1 o mjesечноj dohotku i izdacima za hranu, izračunati koeficijent determinacije.

Primjer 13-3: Rješenje

- Na osnovu rezultata iz primjera 13-1 i 13-2,
- $b = 0.2525$, $SS_{xx} = 447.5714$, $SS_{yy} = 125.7143$

$$r^2 = \frac{b \ SS_{xy}}{SS_{yy}} = \frac{(.2525)(447.5714)}{125.7143} = .90$$

13.5 STATISTIČKO ZAKLJUČIVANJE O PARAMETRU B

Interval povjerenja za parametar B
 $(1 - \alpha)100\%$ interval povjerenja za parametar B glasi

gdje je
$$s_b = \frac{b \pm ts_b}{\sqrt{SS_{xx}}}$$

Vrijednost t statistike dobijamo iz Tablice Studentove t raspodjele za površinu od $\alpha/2$ na oba kraja raspodjele i $n-2$ stepena slobode.

Primjer 13-4

Formirati 95% interval povjerenja za parametar B za podatke o dohotku i izdacima za hranu sedam domaćinstava datim u Tabeli 13.1.

Primjer 13-4: Rješenje

$$s_b = \frac{s_e}{\sqrt{SS_{xx}}} = \frac{1.5939}{\sqrt{1772.8571}} = .0379$$

$$df = n - 2 = 7 - 2 = 5$$

$$\alpha / 2 = (1 - .95) / 2 = .025$$

$$t = 2.571$$

$$\begin{aligned} b \pm ts_b &= .2525 \pm 2.571(.0379) \\ &= .2525 \pm .0974 = .155 \quad \text{do} \quad .350 \end{aligned}$$

Testiranje hipoteze o regresionom parametru B

Statistika testa za b

vrijednost **statistike testa t za b** računa se kao

$$t = \frac{b - B}{s_b}$$

Vrijednost regresionog parametra B u prethodnom izrazu zamjenjuje se hipotetičkom vrijednošću koja je definisana nultom hipotezom.

Primjer 13-5

Testirati pri nivou značajnosti 1% da li je koeficijent nagiba regresione prave osnovnog skupa za primjer o dohotku i izdacima za hranu sedam domaćinstava statistički značajan.

Primjer 13-5: Rješenje

- Etapa 1:
 - $H_0: B = 0$ (regresioni parametar je nula)
 - $H_1: B \neq 0$ (regresioni parametar je statistički značajan)

- Etapa 2:
 - σ_{ϵ} nije poznato
 - Dakle, koristimo t raspodjelu za test o B

Primjer 13-5: Rješenje

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

Primjer 13-5: Rješenje

Etapa 4:

$$t = \frac{b - B}{s_b} = \frac{.2525 - 0}{.0379} = 6.662$$

Iz H_0

Primjer 13-5: Rješenje

- Etapa 5:
- Vrijednost statistike testa $t = 6.662$
 - Veća je od kritične vrijednosti $t = 4.032$
 - Nalazi se u oblasti odbacivanja nulte hipoteze
- Dakle, odbacujemo nultu hipotezu
- Zaključujemo da promjenljiva x (dochodak) statistički značajno utiče na promjenljivu y (izdaci za hranu).

13.6 LINEARNA KORELACIJA

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

Koeficijent linearne korelacije

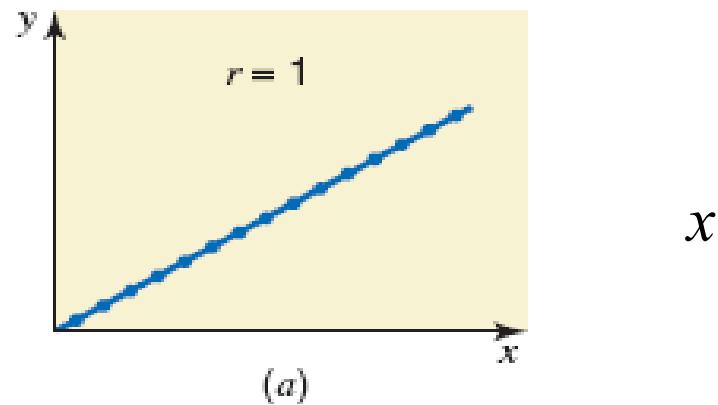
Vrijednost koeficijenta proste linearne korelacije

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

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

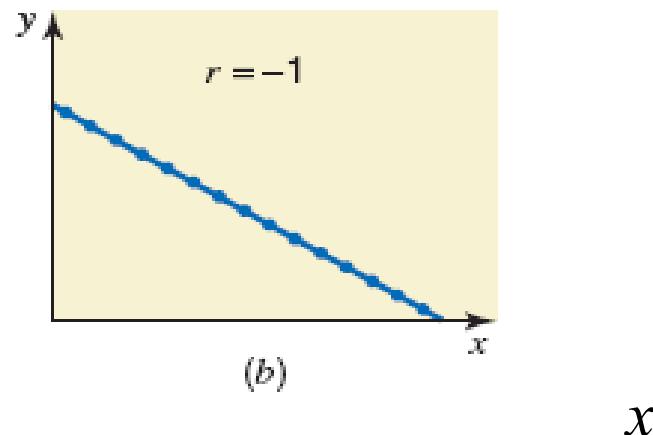
Slika 13.18 Linearna korelacija između dvije promjenljive.

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



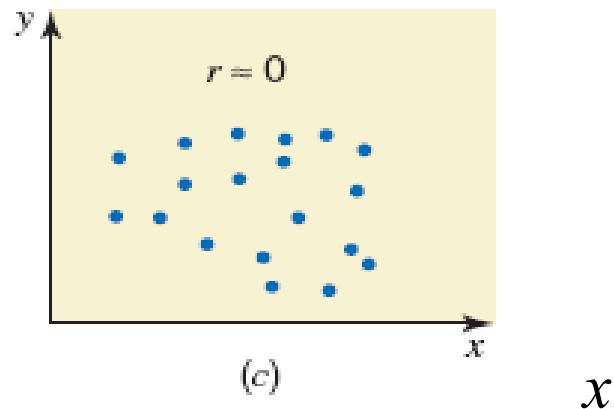
Slika 13.18 Linearna korelacija između dvije promjenljive.

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

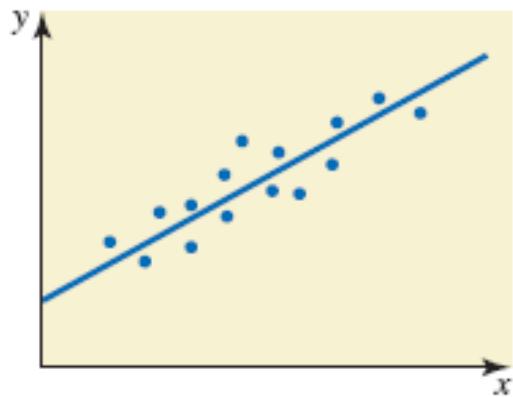


Slika 13.18 Linearna korelacija između dvije promjenljive.

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

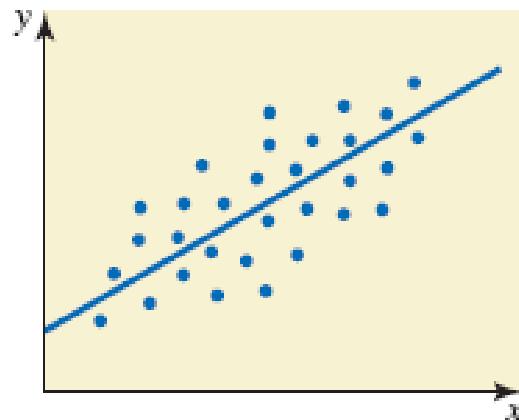


Slika 13.19 Linearna korelacija između dvije promjenljive.



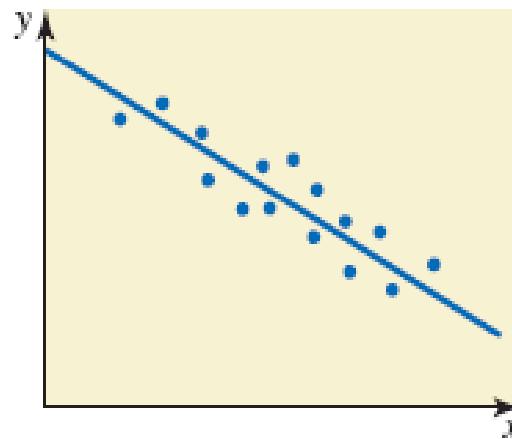
(a) Strong positive linear correlation
(r is close to 1)

Slika 13.19 Linearna korelacija između dvije promjenljive.



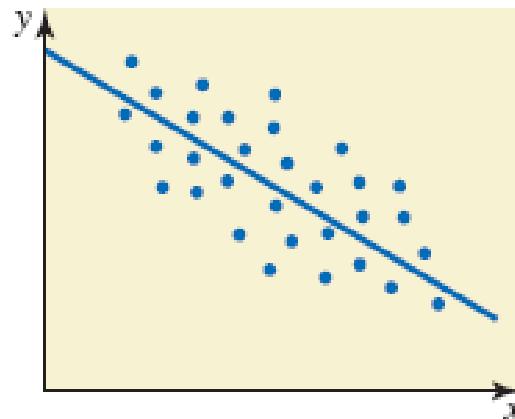
(b) Weak positive linear correlation
(r is positive but close to zero)

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 oznaka $n - 2$ 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 statistički značajan)

- 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 statistički značajna pozitivna veza između dohotka i izdataka za hranu.