

Korelacija

Opšte karakteristike

- Statistička tehnika koja se koristi da za opisivanje odnosa između **dvije varijable**
- Za računanje potrebna **dva seta vrijednosti** za svaku pojedinačnu opservaciju
- Intervalne mjere
- Korelacija je numerička vrijednost koja opisuje 3 karakteristike odnosa između dvije varijable (X i Y): ***smjer, oblik i snagu.***

Smjer

- **SMJER:** obilježen je znakom ispred vrijednosti korelacije (pozitivna ili negativna)
- Pozitivna korelacija (+) – dvije pojave imaju tendenciju da se mijanjaju u istom smjeru. Kada raste X onda raste Y, ali sa smanjenjem X takođe vidimo i opadanje vrijednosti Y.
- Negativna korelacija (-) – dvije pojave imaju tendenciju da idu u suprotnom smjeru. Na primjer, sa porastom X smanjuje se Y.



Person	Family Income (in \$1000)	Student's Average Grade
A	31	72
B	38	86
C	42	81
D	44	78
E	49	85
F	56	80
G	58	91
H	65	89
I	70	94
J	90	83
K	92	90
L	106	97
M	135	89
N	174	95

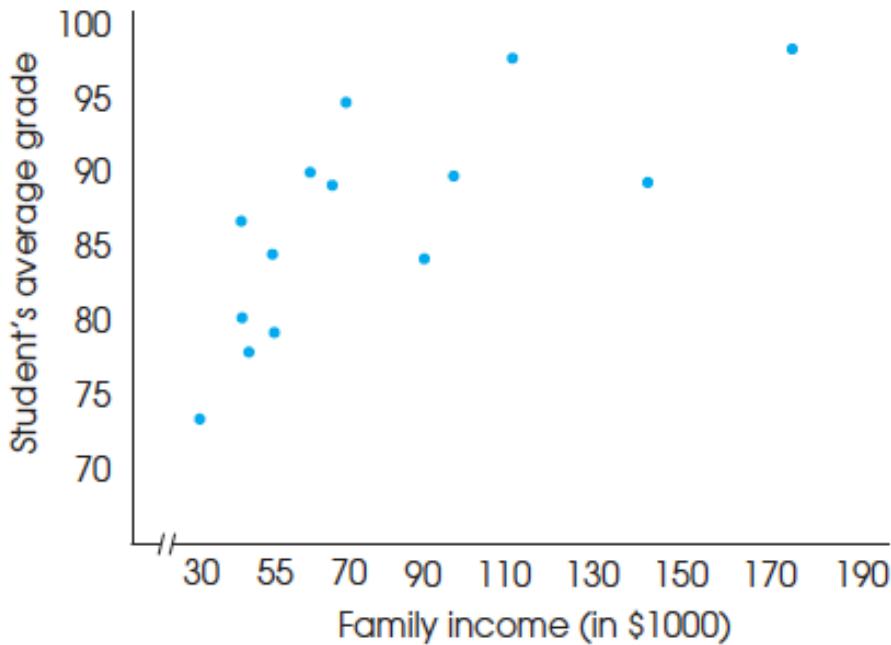


FIGURE 14.1

Correlational data showing the relationship between family income (X) and student grades (Y) for a sample of $n = 14$ high school students. The scores are listed in order from lowest to highest family income and are shown in a scatter plot.

Oblik

□ OBLIK:

- Linearan odnos – vrijednosti imaju tendenciju da budu grupisane oko prave linije. Korelacijske se najčešće koriste upravo za linearne relacije.
- Krivolinijski odnos – npr. vrijednosti se grupišu u obliku slova “U” ili obrnutog slova “U”. U slučaju ovakve distribucije, koeficijent korelacijske je neprecizna mera relacije između dvije varijable.



Univ

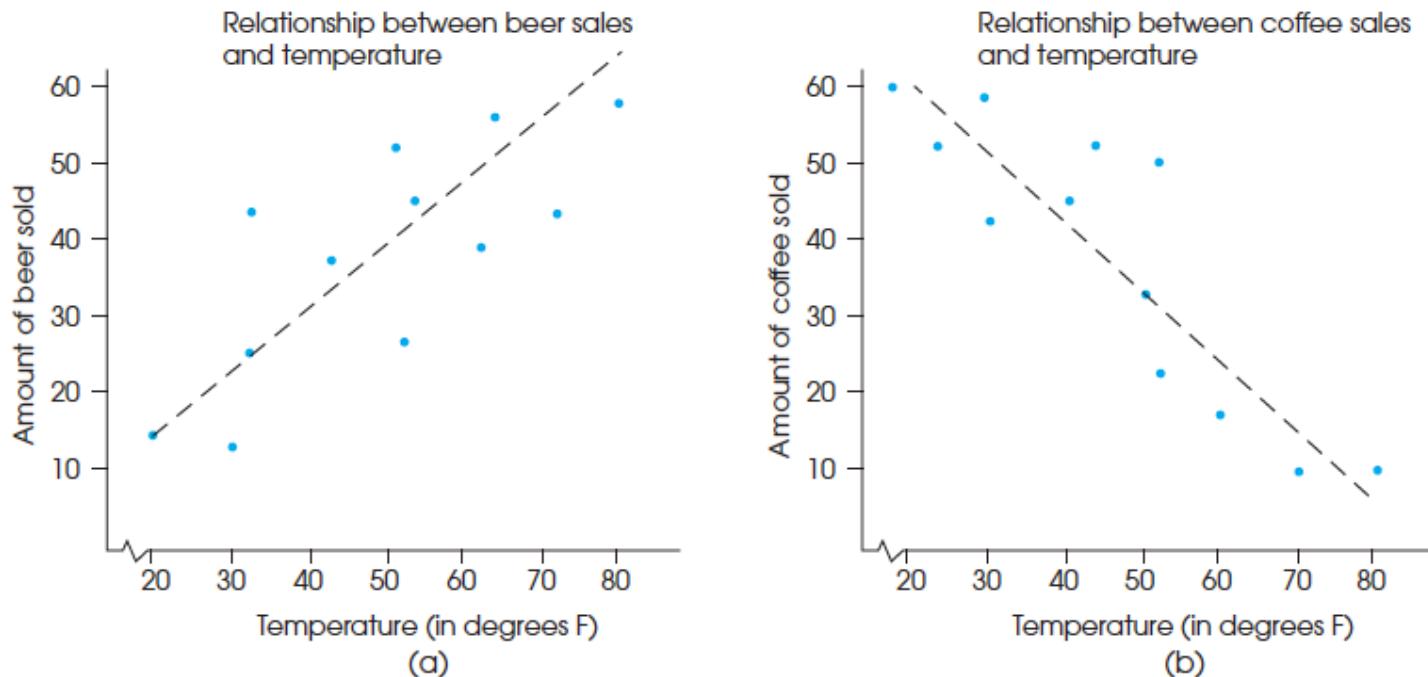


FIGURE 14.2

Examples of positive and negative relationships. (a) Beer sales are positively related to temperature. (b) Coffee sales are negatively related to temperature.

Snaga odnosa

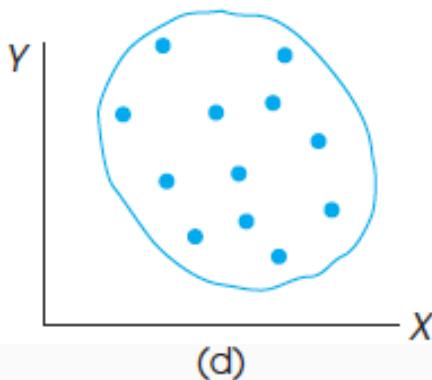
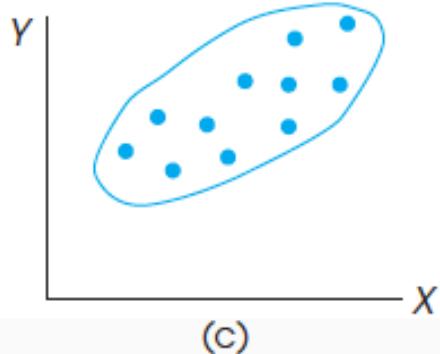
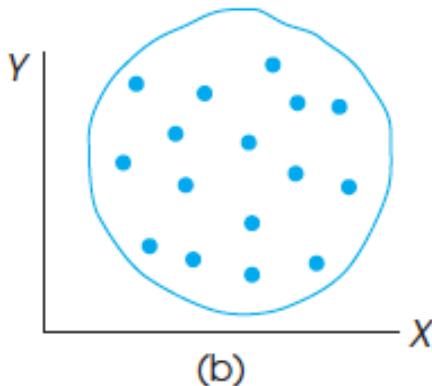
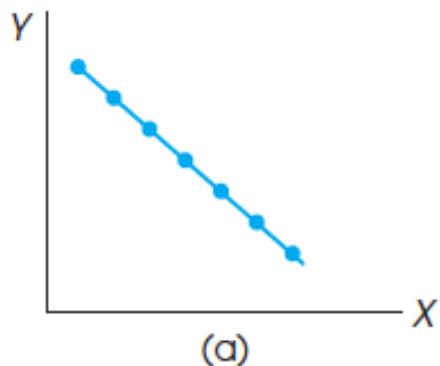
SNAGA:

- Mjeri koliko je odnos između dvije varijable konsistentan. Drugim riječima, koliko prava linija precizno opisuje odnos
- Vrijednosti se kreću od -1 do + 1
- Rijetko (nikad) smo u prilici da analiziramo savršenu korelaciju
- Nepovezanost između dvije pojave opisuje se vrijednošću - 0



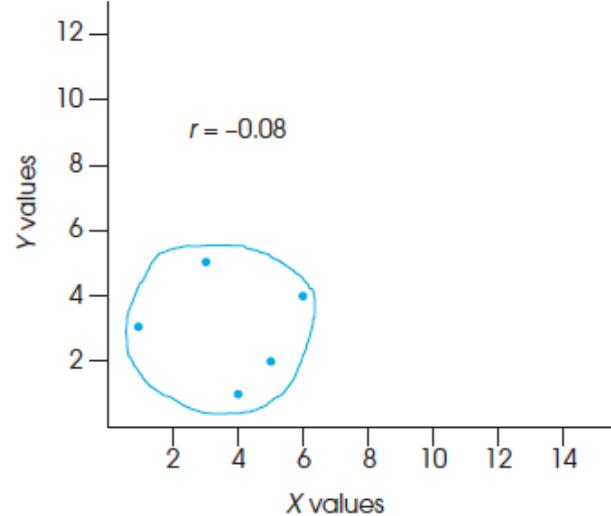
FIGURE 14.3

Examples of different values for linear correlations: (a) a perfect negative correlation, -1.00; (b) no linear trend, 0.00; (c) a strong positive relationship, approximately +0.90; (d) a relatively weak negative correlation, approximately -0.40.



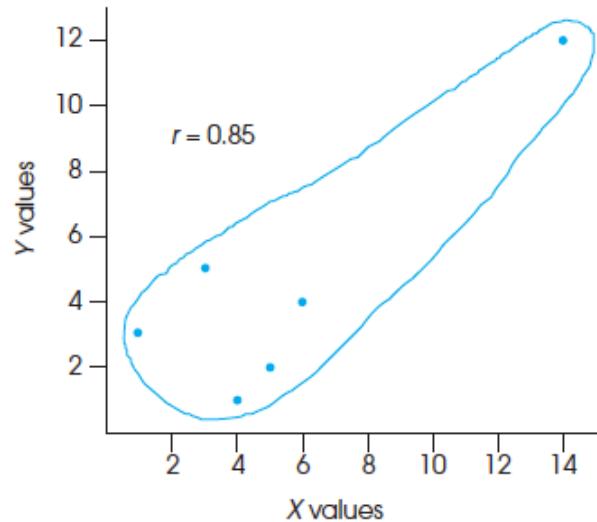


Univ



Original Data		
Subject	X	Y
A	1	3
B	3	5
C	6	4
D	4	1
E	5	2

(a)



Data with Outlier Included		
Subject	X	Y
A	1	3
B	3	5
C	6	4
D	4	1
E	5	2
F	14	12

(b)

FIGURE 14.7

A demonstration of how one extreme data point (an outlier) can influence the value of a correlation.

Zadatak za vježbu

- Za sljedeću set vrijednosti nacrtaj tačkasti grafik i izračunaj Pirsonovu korelaciju.

X	Y
0	2
10	6
4	2
8	4
8	6

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

Zadatak za vježbu

- Za sljedeću set vrijednosti nacrtaj tačkasti grafik i izračunaj Pirsonovu korelaciju.

X	Y
0	2
10	6
4	2
8	4
8	6

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

$$SS_{xy} = \sum (x_i - \bar{x})(y_i - \bar{y})$$

Zadatak za vježbu

- Za sljedeću set vrijednosti nacrtaj tačkasti grafik i izračunaj Pirsonovu korelaciju.

X	Y	$X - \bar{X}$	$Y - \bar{Y}$	$(X - \bar{X})^2$	$(Y - \bar{Y})^2$	$(X - \bar{X})(Y - \bar{Y})$
0	2	-6	-2	36	4	+12
10	6	+4	+2	16	4	+8
4	2	-2	-2	4	4	+4
8	4	+2	0	4	0	0
8	6	+2	+2	4	4	+4
				$SS_{XX} = 64$	$SS_{YY} = 16$	$SS_{XY} = 28$

Zadatak za vježbu

- Za sljedeću set vrijednosti nacrtaj tačkasti grafik i izračunaj Pirsonovu korelaciju.

X	Y	$X - \bar{X}$	$Y - \bar{Y}$	$(X - \bar{X})^2$	$(Y - \bar{Y})^2$	$(X - \bar{X})(Y - \bar{Y})$
0	2	-6	-2	36	4	+12
10	6	+4	+2	16	4	+8
4	2	-2	-2	4	4	+4
8	4	+2	0	4	0	0
8	6	+2	+2	4	4	+4
				$SS_{XX} = 64$	$SS_{YY} = 16$	$SS_{XY} = 28$

$$R = 0.875$$