

Analisi di relazioni tra variabili

- Correlazione: analizza se esiste una relazione tra due variabili (come e quanto due variabili variano insieme)
- Regressione: analizza la forma della relazione tra variabili

MISURE DI ASSOCIAZIONE TRA 2 VARIABILI QUANTITATIVE

- Covarianza
- Coefficiente di correlazione



Esempio: Consideriamo i dati relativi alla pressione sistolica arteriosa e al peso di 59 soggetti:


Peso	Pressione arteriosa sistolica	Peso	Pressione Arteriosa sistolica
55	100	72	121
58	90	74	120
60	98	75	104
61	95	75	102
61	108	75	109
61	89	75	107
62	97	76	115
62	96	77	111
62	110	78	108
64	95	78	107
64	97	79	112
65	105	81	110
65	104	82	100
65	113	83	105
66	98	83	118
66	101	85	114
66	91	87	105
67	107	87	110
67	112	90	110
67	94	90	120
68	119	95	121
69	102	95	119
69	102	99	110
69	118	102	117
69	109	104	131
70	114	104	132
70	106	111	127
71	100	118	133



Quale relazione tra i dati?

DIAGRAMMA DI DISPERSIONE

- Riportiamo su un diagramma cartesiano in ascissa (X) i valori del peso e in ordinata (Y) i valori della pressione arteriosa



Commenti



Il grafico precedente ci mostra che:

- Peso e pressione sistolica arteriosa sono "positivamente associate": i soggetti che hanno peso più elevato, hanno anche valori della pressione arteriosa maggiori
- La relazione tra le due variabili, ad una prima osservazione, sembra essere lineare



Quanto sono "associate"?
Qual è la forza della relazione?
Che tipo di relazione tra le variabili?



Covarianza

$$Cov(X, Y) = s_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n - 1}$$


Dove (x_i, y_i) sono i dati disponibili per due variabili numeriche
 \bar{x}, \bar{y} indicano le due medie aritmetiche



Covarianza positiva


* Considera i valori: $(x_i - \bar{x})(y_i - \bar{y})$

$(x_i - \bar{x}) > 0$ e $(y_i - \bar{y}) > 0$
 $(x_i - \bar{x}) < 0$ e $(y_i - \bar{y}) < 0$ } \rightarrow Il prodotto è positivo \rightarrow La covarianza è positiva




Covarianza negativa

$(x_i - \bar{x}) > 0$ e $(y_i - \bar{y}) < 0$
 $(x_i - \bar{x}) < 0$ e $(y_i - \bar{y}) > 0$ } \rightarrow Il prodotto è negativo \rightarrow La covarianza è negativa




Covarianza nulla

$$\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \left\} \begin{array}{l} \text{La somma} \\ \text{dei} \\ \text{prodotti è} \\ \text{nulla} \end{array} \right. \longrightarrow \text{La covarianza è nulla} \\ \text{Nessuna relazione}$$



Esercizio: rappresentare graficamente i dati riportati in tabella e ricavare il valore della covarianza. Commentare i risultati ottenuti.

statura (cm) (X)	peso (Kg) (Y)	(x-171.7)	(y-69.5)	(x-171.7)(y-69.5)	xy
172	63	0.3	-6.5	-1.95	10836
174	73	2.3	3.5	8.05	12702
171	77	-0.7	7.5	-5.25	13167
175	85	3.3	15.5	51.15	14875
168	64	-3.7	-5.5	20.35	10752
170	55	-1.7	-14.5	24.65	9350
Totale:	1030	417		97	71682
Media:	171.7	69.5			



Cov(X,Y)=19,4

- La covarianza ha segno positivo: peso e altezza sono due variabili positivamente associate: a valori maggiori dell'altezza, corrispondono valori maggiori del peso.

NB: Se l'altezza fosse stata espressa in m, anziché in cm la covarianza sarebbe risultata pari a **0,194**

La covarianza è dipende dalla scala di misura in cui sono espresse le variabili



Coefficiente di correlazione di Bravais-Pearson

r(XY) non dipende dalla scala di misura delle variabili

$$r_{xy} = \frac{s_{xy}}{s_x s_y}$$

s_{xy} = covarianza tra X e Y
 s_x = deviazione standard di X
 s_y = deviazione standard di Y

Massima correlazione lineare negativa



$$-1 \leq r_{xy} \leq 1$$

Massima correlazione lineare positiva

$$r_{xy} = 0$$

Nessuna correlazione





Esempio: Utilizzando i dati dell'esempio relativo a peso e pressione arteriosa, ricaviamo il valore della covarianza e del coefficiente di correlazione:

Sapendo che: $\sum x = 4310$, $n = 57$
 $\sum y = 6158$, $s(x) = 14.3$
 $\sum xy = 471976$, $s(y) = 10.6$

$$s_{xy} = \frac{1}{n-1} \left(\sum_{i=1}^n (x_i y_i) - \frac{1}{n} \sum_{i=1}^n x_i \sum_{i=1}^n y_i \right) = \frac{1}{57-1} (471976 - (1/57) * 6158 * 4310) = 113.3$$

$$r_{xy} = \frac{s_{xy}}{s_x s_y} = \frac{113.3}{14.3 * 10.6} = 0.75$$

- Come si poteva osservare graficamente, peso e pressione sono positivamente associate.
- r è molto elevato: tra le due variabili c'è relazione lineare

Coefficiente di correlazione di Bravais-Pearson

La correlazione è significativa?

- Il valore di r è **stato calcolato da un campione** e non dalla popolazione (ρ)
- Ipotesi nulla: $\rho = 0$ (ρ è il coefficiente di correlazione della popolazione, r del campione).
- Il valore calcolato indica una correlazione significativa?

Coefficiente di correlazione di Bravais-Pearson

OK: la correlazione è significativa ma....

- Le 2 variabili sono distribuite normalmente?
- La relazione tra le 2 variabili è lineare?
- Ricordarsi che anche se c'è correlazione non vuol dire che c'è nesso di causa-effetto ...