



I FONDAMENTALI

*Le parole dell'epidemia spiegate dai docenti
di Scienze Statistiche di Padova*

**Valutazione dei fattori di rischio
per la salute
(correlazione e regressione)**



UNIVERSITÀ
DEGLI STUDI
DI PADOVA



DIPARTIMENTO
DI SCIENZE
STATISTICHE

Prof.ssa
LAURA VENTURA

docente di
STATISTICA MEDICA
e di
MODELLI STATISTICI



I FONDAMENTALI

*Le parole dell'epidemia spiegate dai docenti
di Scienze Statistiche di Padova*

**Valutazione dei fattori di rischio
per la salute
(correlazione e regressione)**



UNIVERSITÀ
DEGLI STUDI
DI PADOVA



Caso di studio: Misurazioni relative a uno studio *osservazionale* su un gruppo di $n = 300$ pazienti ricoverati per Covid-19.

Variabile di interesse: Durata della degenza.

Età	Sesso	Intubazione	Febbre	Tosse	Dimissione	Durata degenza
88	m	no	si	no	casa	6
72	M	si	si	no	decesso	5
62	M	no	si	si	decesso	3
66	F	NO	si	si	decesso	11
48	M	no	si	si	altra struttura	8
48	F	si	si	si	altra struttura	9
71	F	no	si	si	decesso	2
56	M	no	si	si	decesso	6
61	F	no	si	si	decesso	19
78	m	si	si	si	altra struttura	7
56	f	no	si	si	decesso	6
45	m	no	si	no	casa	23
65	m	si	si	si	casa	10
56	m	si	si	si	altra struttura	10
54	f	no	si	si	decesso	12
78	m	no	si	si	decesso	1
56	m	si	si	si	decesso	5
88	f	no	si	si	ancora ricoverato	7
43	m	no	si	si	decesso	4
85	m	si	si	si	decesso	2
80	f	no	si	si	altra struttura	10
76	f	si	si	si	altra struttura	8
78	m	si	si	si	decesso	11
68	m	no	si	si	decesso	1
56	m	si	si	si	decesso	9
45	m	no	si	si	altra struttura	5
76	f	no	si	no	decesso	5
68	m	no	si	no	casa	2
89	m	no	si	si	casa	2
66	m	no	si	si	altra struttura	15
76	m	no	si	si	decesso	1
67	f	no	si	si	decesso	5
54	f	no	si	si	decesso	9
78	m	no	si	si	altra struttura	10
56	f	no	si	si	decesso	9
56	M	si	si	si	casa	1

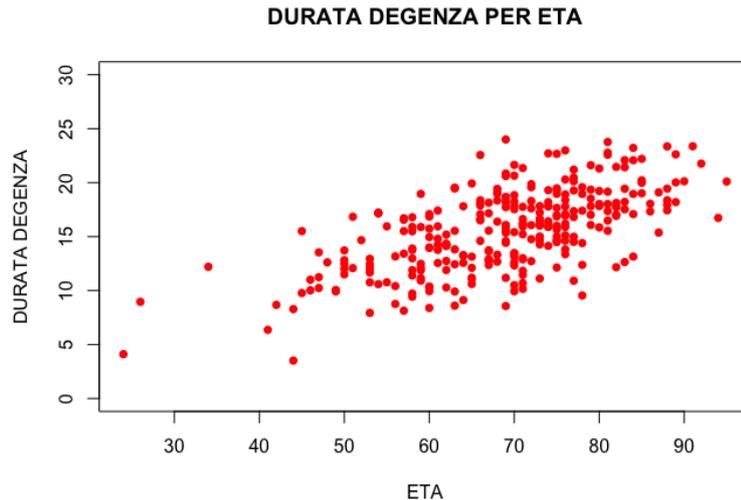
Obiettivo
Si vuole studiare
l'associazione
tra **età** dei pazienti
e **durata** del ricovero.

STUDIO DELLA RELAZIONE TRA DUE VARIABILI QUANTITATIVE

Quando le due variabili (causa e risposta) sono espresse attraverso valori numerici, la relazione che le lega può essere rappresentata graficamente in un piano cartesiano mediante un **diagramma di dispersione** (o a nuvola di punti):

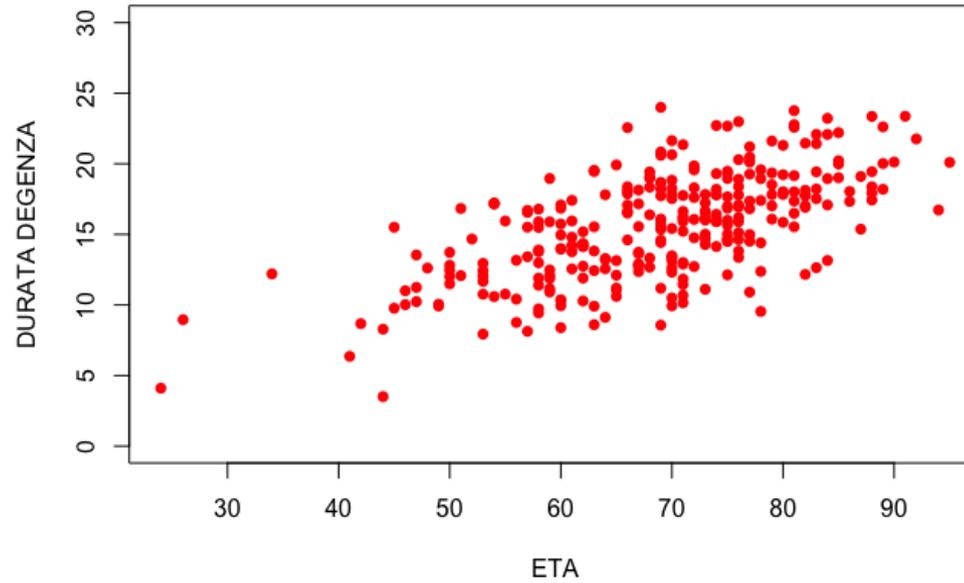
- la variabile indipendente (causa) sull'asse X
- la variabile dipendente (risposta) sull'asse Y .

Nel nostro caso di studio: $X = \text{ETA}$ e $Y = \text{DURATA}$.



Nel grafico sono riportate le coppie (x_i, y_i) per $i = 1, \dots, n = 300$

DURATA DEGENZA PER ETA



Dal diagramma di dispersione si possono osservare:

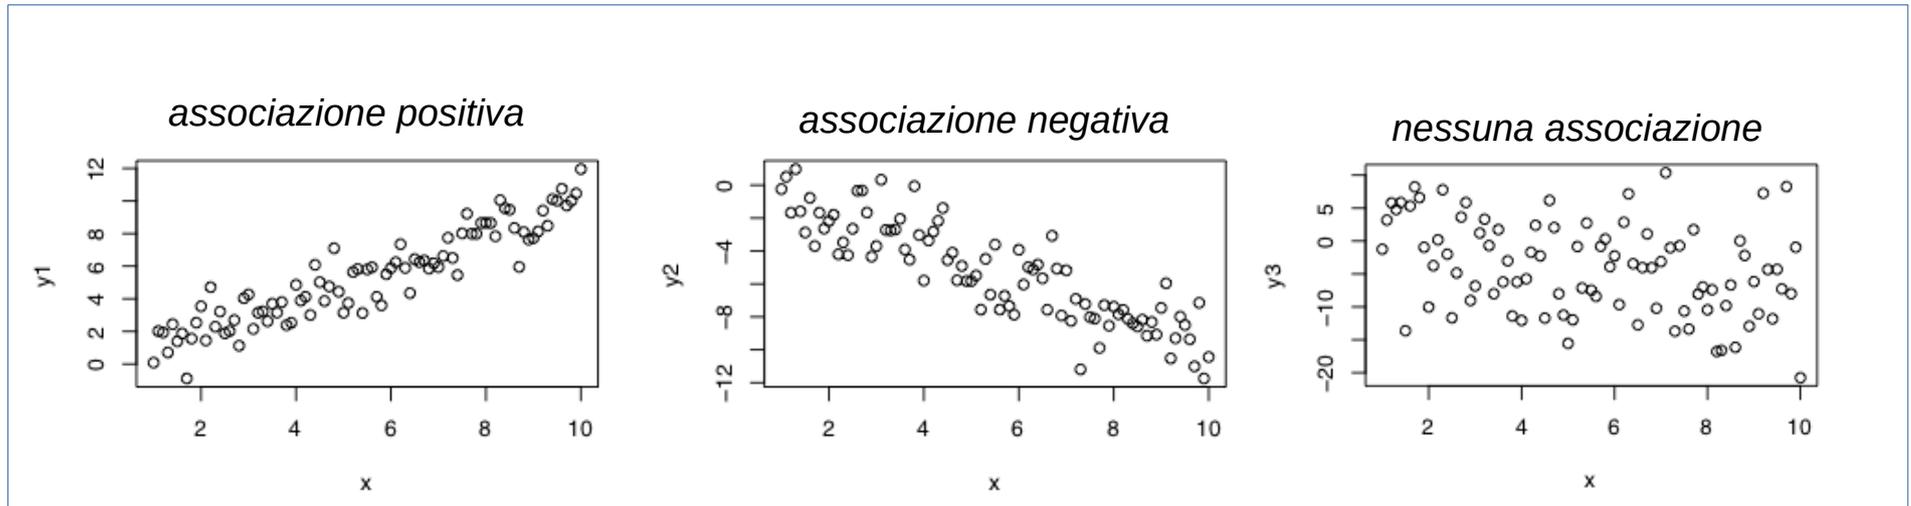
- la **direzione** della relazione
- la **forma** della relazione
- la **forza** della relazione

DIREZIONE

Si ha una **associazione positiva** quando al crescere dei valori della X crescono anche i valori della Y .

Viceversa, si ha **associazione negativa** quando al decrescere dell'una decrescono anche i valori dell'altra.

Se i punti del diagramma sono dispersi casualmente nel piano, non c'è associazione tra le due variabili.

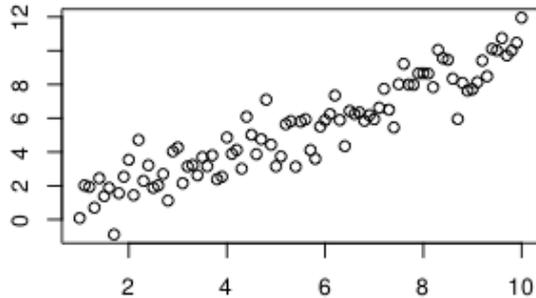


FORMA

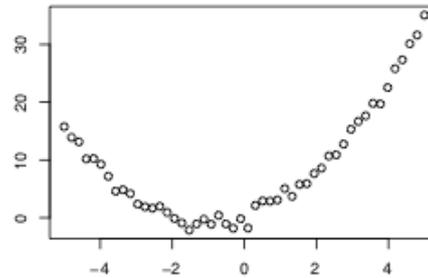
La forma viene desunta dalla disposizione dei punti nel diagramma.

Si parla di **relazione lineare** quando i punti si dispongono approssimativamente in linea retta.

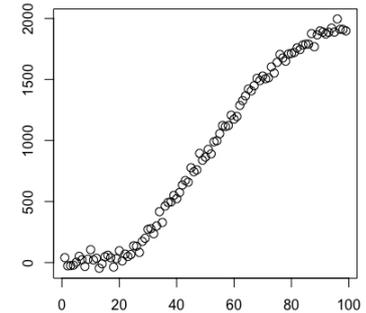
relazione lineare



relazione quadratica



relazione non-lineare

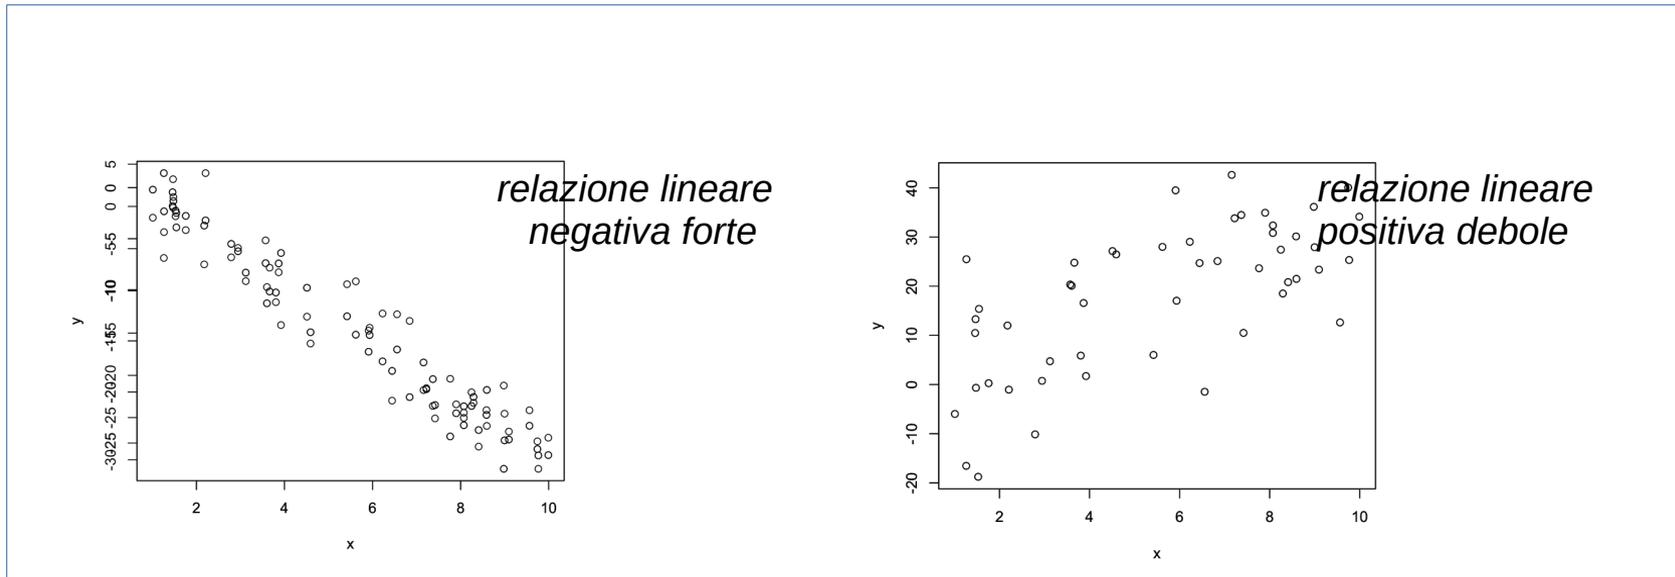


FORZA

La forza si può desumere dalla dispersione dei punti nel diagramma.

Se i punti sono molto dispersi tra loro, la relazione tra le due variabili è debole.

Se invece i punti sono poco dispersi, allora la relazione è forte.

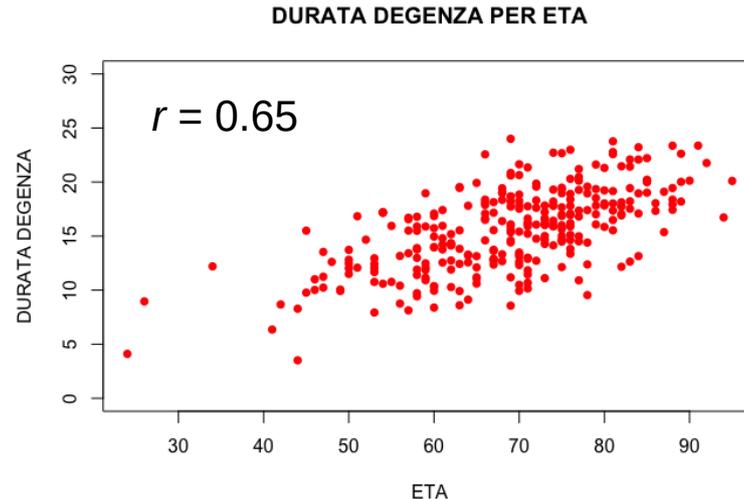
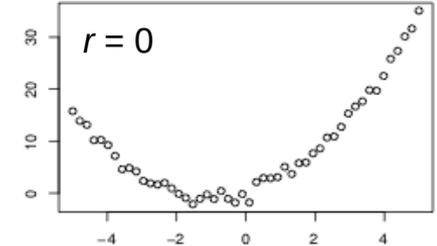
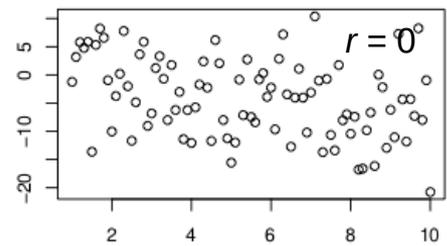
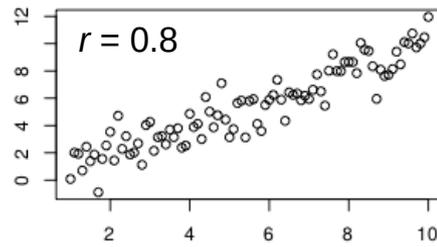
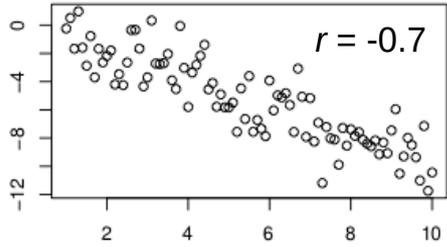


CORRELAZIONE

Per avere una valutazione analitica del grado di **associazione lineare** tra due variabili quantitative, esiste un indice che misura la direzione e la forza di una relazione lineare: l'**indice di correlazione r** , che assume valori nell'intervallo $[-1,1]$:

- se $r = \pm 1$: correlazione positiva/negativa perfetta (tutti i punti su una retta: crescente o decrescente, rispettivamente)
- se $r > 0$: correlazione positiva
- se $r < 0$: correlazione negativa
- se $r = 0$: assenza di relazione lineare

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad \text{con} \quad \bar{x} = \frac{1}{n} \sum x_i \quad \text{e} \quad \bar{y} = \frac{1}{n} \sum y_i$$

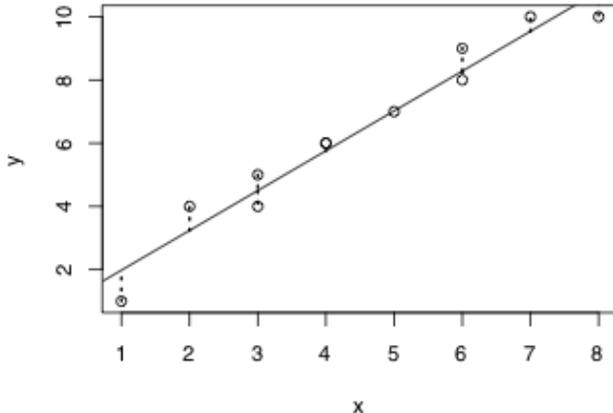


LA RETTA DI REGRESSIONE

- La regressione lineare si usa quando le variabili in studio hanno fra loro una relazione lineare, e quindi i punti del diagramma a dispersione tendono a disporsi secondo una linea retta.

Qual è la retta $Y = a + bX$ "giusta"?

- La retta ottimale è quella più "vicina" a tutti i punti del diagramma.
- Poichè le distanze positive e negative (punti sopra e punti sotto la retta *ideale*) si compensano, la loro somma, e quindi la media delle distanze, è nulla.
- Si considerano allora le distanze al quadrato. La retta "giusta" è allora quella che rende minima la somma delle distanze al quadrato.
- Per questo, tale metodo si chiama **metodo dei minimi quadrati**.

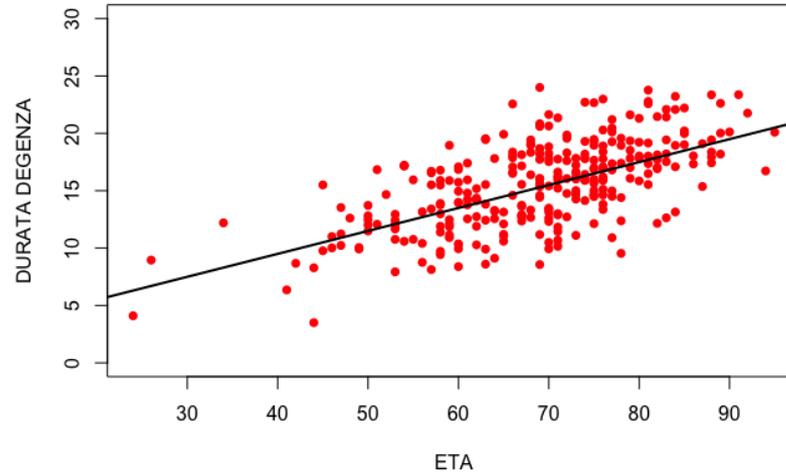


$$\text{distanza} = \sum (y_i - a - bx_i)^2$$

minima

$$b = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2}$$
$$a = \bar{y} - b\bar{x}$$

DURATA DEGENZA PER ETA



Nel caso di studio che stiamo considerando, si trova: **$DURATA = 1.5 + 0.2 \text{ ETA}$**

Si deduce che:

- esiste una relazione lineare tra ETA' e DURATA della degenza
- l'associazione è positiva (a un aumento dell'età corrisponde un aumento della durata)
- l'associazione è *moderatamente* forte ($r = 0.65$)
- la pendenza della retta ($b = 0.2$) ci dice con quale velocità la degenza cresce con l'età

Per un paziente di 60 anni, la degenza è in media di 13.5 giorni ($Y = 1.5 + 0.2 \times 60 = 13.5$).