

Regressione e correlazione

Regressione e correlazione

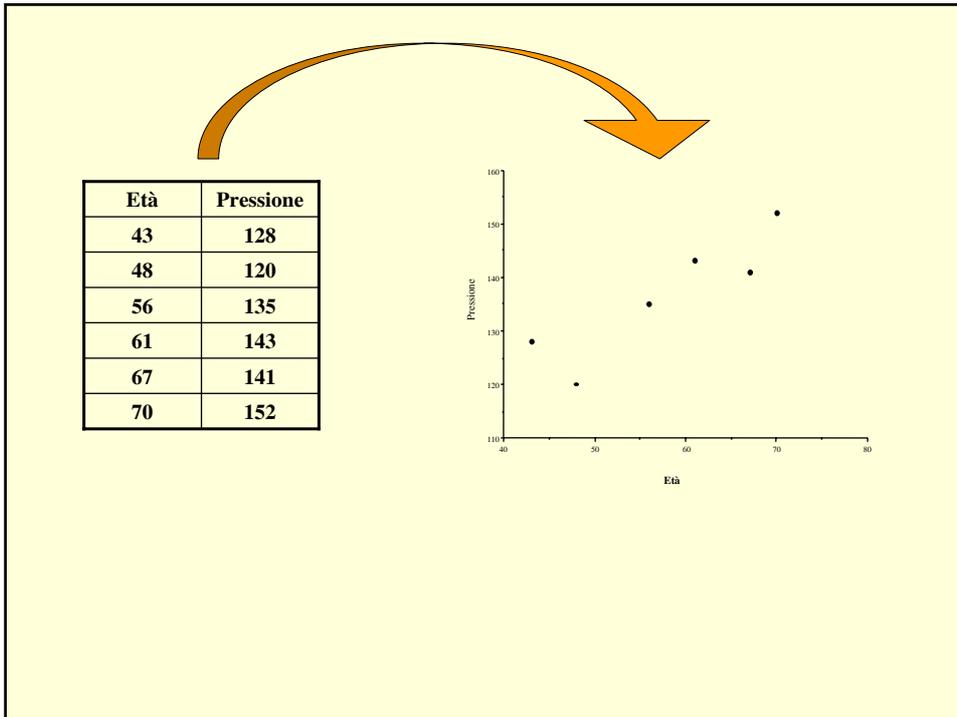
In molti casi si osservano grandezze che tendono a covariare, ma...

- (1) Se c'è una relazione di dipendenza fra due variabili, ovvero se il valore di una variabile (dipendente) si può determinare come funzione di una seconda variabile (indipendente), allora si può usare una **regressione**.

Esempio: la pressione arteriosa dipende dall'età del soggetto

- (2) Se non c'è una relazione di dipendenza fra le variabili, ovvero se nessuna delle due è causa delle variazioni dell'altra, la tendenza a covariare si misura in termini di **correlazione**.

Esempio: lunghezza e peso di un organismo

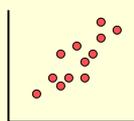


Per misurare l'intensità di una relazione (lineare) si usa il coefficiente di correlazione di Bravais-Pearson.

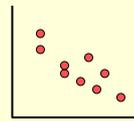
Per un campione: r

r e ρ variano fra +1 e -1

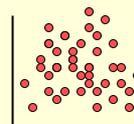
Per una popolazione: ρ (rho)



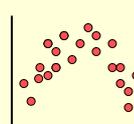
Proporzionalità diretta:
 r tende a +1



Proporzionalità inversa:
 r tende a -1



Nessuna relazione:
 r tende a 0



Nessuna relazione lineare: r tende a 0

$$r = \frac{n(\Sigma XY) - (\Sigma X)(\Sigma Y)}{\sqrt{[n(\Sigma X^2) - (\Sigma X)^2][n(\Sigma Y^2) - (\Sigma Y)^2]}}$$

Per l'esempio sulla pressione arteriosa:

Soggetto	Età(X)	PA(Y)	XY	X ²	Y ²
A	43	128	5504	1849	16384
B	48	120
C	56	135
D	61	143
E	67	141
F	70	152
	$\Sigma X=345$	$\Sigma Y=819$	$\Sigma XY=47634$	$\Sigma X^2=20399$	$\Sigma Y^2=112443$

$$r = .897$$

Cioè: forte relazione positiva

Se $r = .897$ indica una forte relazione positiva, si può affermare che questa relazione non è frutto del caso ed è quindi significativa?

Ipotesi da testare per la significatività di una correlazione:

$$H_0 : \rho = 0$$

$$H_1 : \rho \neq 0$$

$$t = r \sqrt{\frac{N-2}{1-r^2}} = 4.059$$

$$t_{\text{crit}(.05, \text{df}=1)} = 2.776$$

Poichè $t=4.059 > 2.776$, si rigetta H_0 e si conclude che esiste una correlazione positiva e significativa fra età e pressione arteriosa.

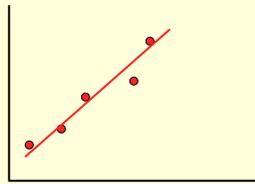
Attenzione!

Una correlazione positiva e significativa **non** implica un rapporto causale.

Regressione lineare

Analizza la natura e l'intensità di una relazione lineare fra due variabili, di cui una dipende dall'altra (o almeno una è misurata senza errore).

Interpoliamo una retta...

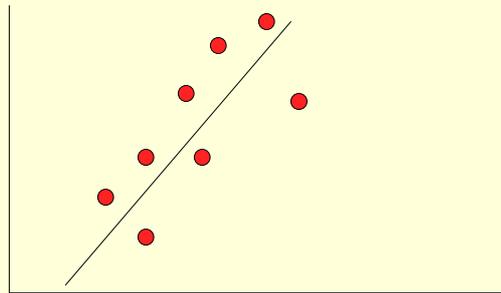


Una retta qualsiasi è descritta dall'equazione:

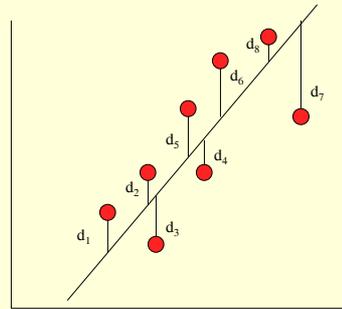
$$Y = a + bX \text{ (per un campione)}$$

$$Y = \alpha + \beta X \text{ (per una popolazione)}$$

Per determinare la retta che meglio si adatta ai dati, si usa il metodo dei *minimi quadrati*.



Per determinare la retta che meglio si adatta ai dati, si usa il metodo dei *minimi quadrati*.



Si calcola la distanza di ogni punto dalla retta nello spazio della variabile dipendente (Y)

La somma

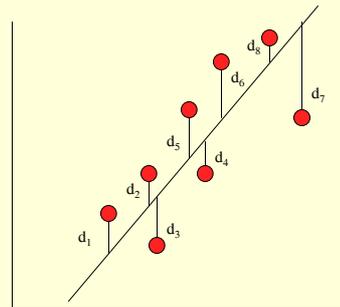
$$d_1^2 + d_2^2 + d_3^2 + d_4^2 + d_5^2 \dots d_8^2$$

ovvero

$$\Sigma[Y - f(\bar{X})]^2$$

deve essere minimizzata

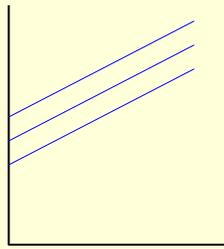
(N.B. Questa somma è una componente della somma dei quadrati – e quindi della varianza – della variabile Y)



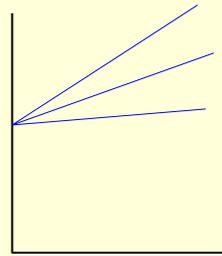
Nell'equazione $Y = a + bX$,

a è l'intercetta sull'asse Y

b è la pendenza della retta o coefficiente di regressione



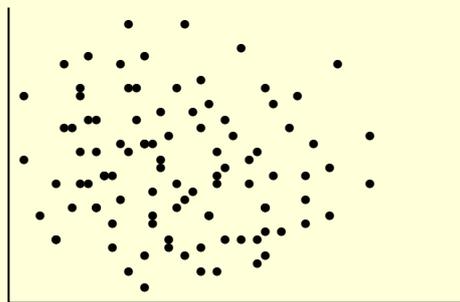
stessa b - differente a



stessa a - differente b

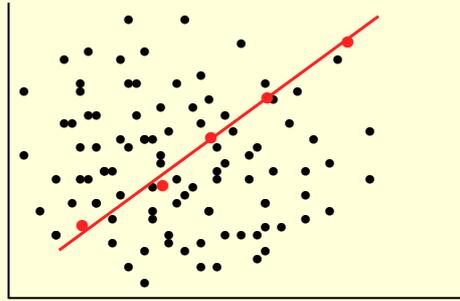
Esiste una retta di regressione per qualsiasi insieme di dati.

Immaginiamo una popolazione di dati per cui $\beta = 0 \dots$



Esiste una retta di regressione per qualsiasi insieme di dati.

Immaginiamo una popolazione di dati per cui $\beta = 0 \dots$

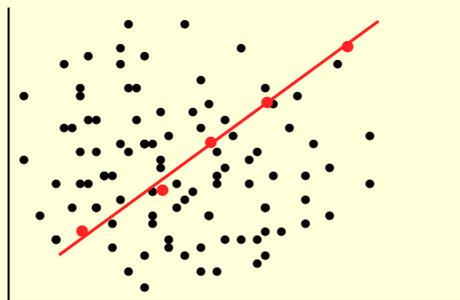


Se un campione casuale comprendesse i punti (•),
la retta $Y = a + bX$ che si interpolerebbe avrebbe $b \neq 0$

Qual'è la probabilità che l'insieme di punti in **rosso** sia stato estratto dalla popolazione studiata e che esso descriva accuratamente la relazione fra X e Y?

Definiamo l'ipotesi nulla e l'ipotesi alternativa:

$$H_0: \beta = 0$$
$$H_1: \beta \neq 0$$



Quindi usiamo un'ANOVA

- 1) Si calcola la somma dei quadrati ovvero la variabilità complessiva di Y

$$SS_T = \sum (Y_i - \bar{Y})^2$$

- 2) Si calcola la somma dei quadrati per la regressione (cioè per il modello usato)

$$SS_R = \frac{\left[\sum X_i Y_i - \frac{\sum X_i \sum Y_i}{n} \right]^2}{\sum X_i^2 - \frac{(\sum X_i)^2}{n}}$$

- 3) Si calcola la somma dei quadrati per i residui (scarti dalla regressione)

$$SS_D = SS_T - SS_R$$

- 4) Si calcolano i quadrati medi per la regressione e per i residui

$$MS_x = SS_x / df_x \quad \text{dove } df_T = n-1, df_R = 1, df_D = df_T - df_R$$

- 5) Si determina F: $F = MS_R / MS_D$

- 6) Si determina il valore di p corrispondente

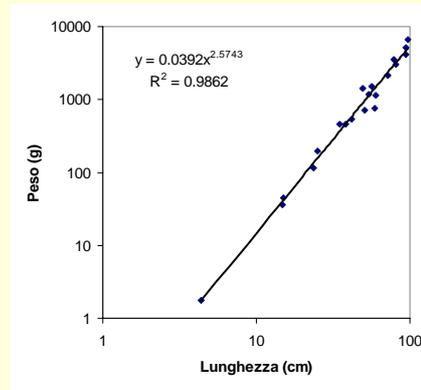
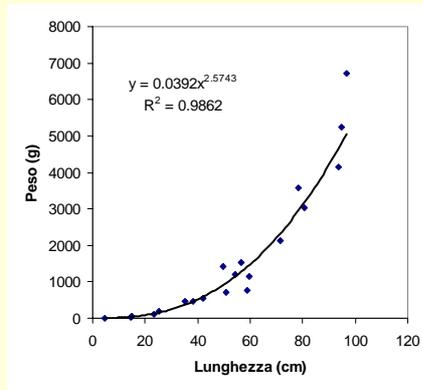
- 7) Il coefficiente di determinazione $r^2 = SS_R / SS_D$ è la proporzione di varianza totale spiegata dalla regressione

Relazioni non lineari

- Se una retta non descrive la relazione fra due variabili, si deve usare una funzione non lineare
- Spesso a questo fine si usano delle trasformazioni non lineari dei dati, per esempio in logaritmo
- Un caso tipico è quello di una relazione lineare fra i logaritmi delle due variabili, tale che la curva che si interpola è:

$$Y = a X^b \quad [\text{cioè } \log(Y) = a + b \log(X)]$$

- Esempio: relazioni peso-lunghezza in pesci



Una relazione peso-lunghezza si descrive con la regressione lineare log-log, ovvero con una funzione di potenza $Y=aX^b$

Domanda #1: il peso dipende dalla lunghezza?

Domanda #2: se accettiamo di usare la lunghezza come variabile indipendente (è più facile da misurare), possiamo affermare che l'errore di misura della lunghezza è nullo?

Domanda #3: possiamo affermare che l'errore di misura della lunghezza è \ll di quello del peso?

Il peso non dipende dalla lunghezza (e viceversa).

Cosa sappiamo:

- sono grandezze che covariano
- quindi i valori dell'una possono essere utili per stimare i valori dell'altra
- entrambe le misure sono affette da errore
- l'ordine di grandezza dell'errore nella stima della lunghezza (assunta come variabile indipendente) può variare in funzione del metodo di misura e degli organismi da misurare

Il peso non dipende dalla lunghezza (e viceversa).

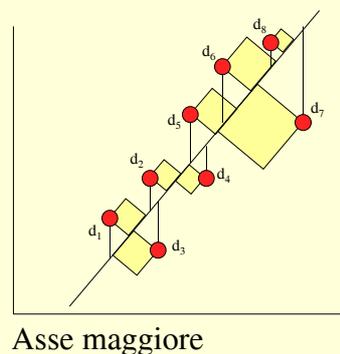
Quindi, la regressione lineare **non** è un metodo adatto a descrivere questa relazione, a meno che l'errore di misura della lunghezza non sia \ll di quello del peso.

Asse Maggiore e Asse Maggiore Ridotto

- Regola empirica: se la varianza delle X è $>1/3$ di quella delle Y , non si dovrebbe usare la regressione lineare
- L'Asse Maggiore considera sia l'errore della X che quello della Y : è la bisettrice dell'angolo formato dalla retta di regressione della X sulla Y con quella di regressione della Y sulla X .
- L'Asse Maggiore Ridotto è quasi concidente con l'Asse Maggiore, ma è più semplice da ottenere.

Asse Maggiore

- Si minimizza la somma dei quadrati delle proiezioni dei punti sull'Asse Maggiore
- Il calcolo implica:
 - Estrazione di autovalori ed autovettori dalla matrice di covarianza
oppure
 - Calcolo delle regressioni Y su X e X su Y e della bisettrice delle due rette



Asse Maggiore Ridotto

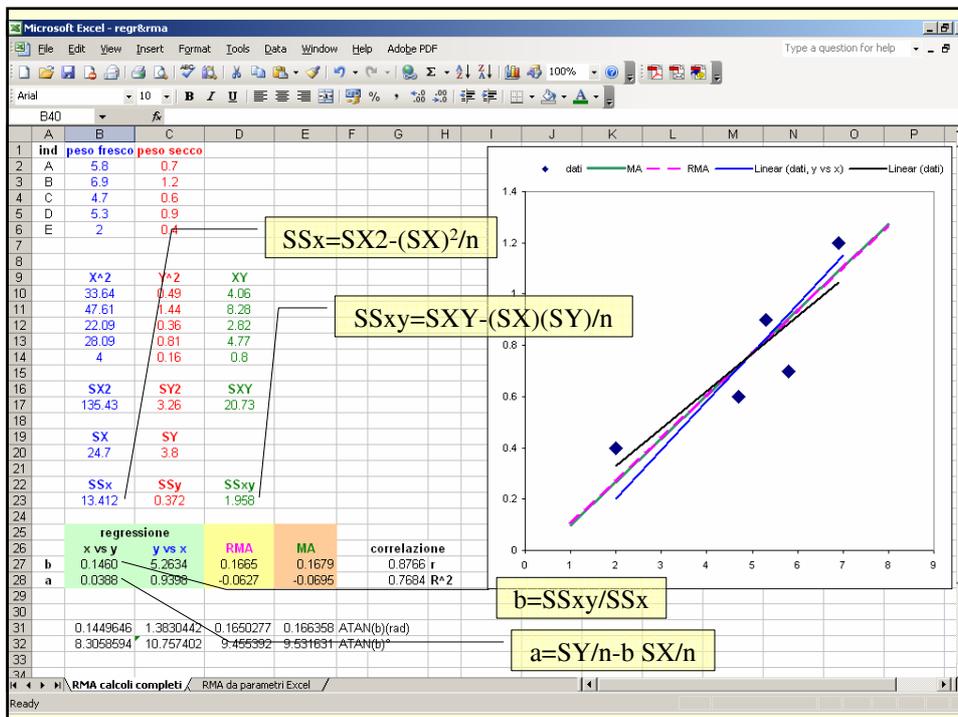
- In pratica, quasi coincide con l'Asse Maggiore
- Il calcolo implica:
 - Calcolo delle regressioni Y su X e X su Y e quindi

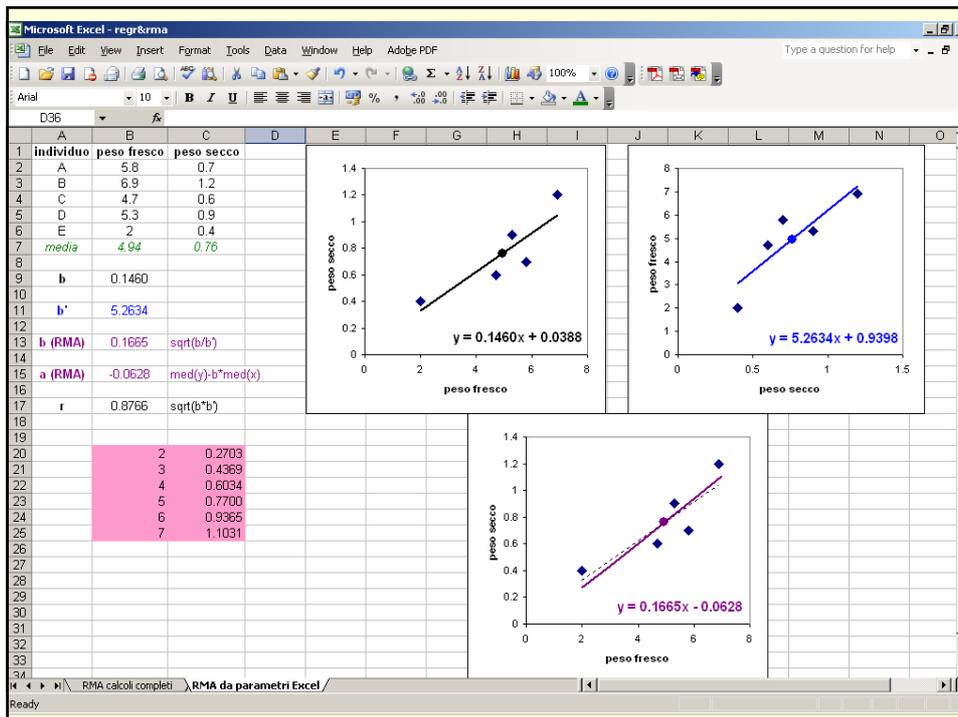
$$b_{RMA} = \sqrt{b_{Y=f(X)} / b_{X=f(Y)}}$$

- Calcolo delle somme dei quadrati SS_X e SS_Y o delle varianze

$$b_{RMA} = \sqrt{SS_Y / SS_X} = \sqrt{s_Y^2 / s_X^2}$$

- In ogni caso: $a_{RMA} = \bar{Y} - b_{RMA} \bar{X}$





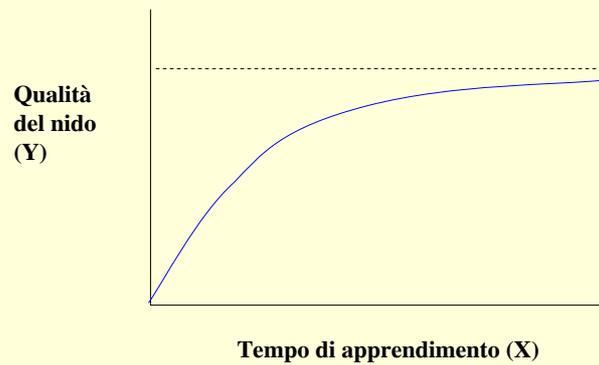
Dati ordinali e relazioni monotoniche: la correlazione di rango di Spearman

Esperimento:
valutare la relazione fra
qualità dei nidi costruiti e
tempo di apprendimento



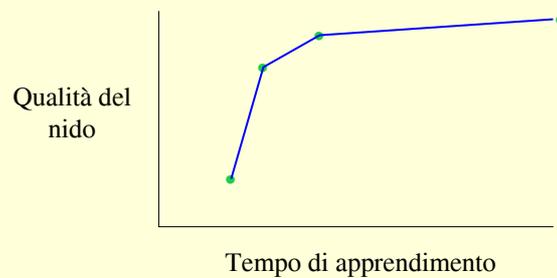
Cosa dobbiamo attenderci?

- una relazione non lineare (l'apprendimento non consente di migliorare all'infinito)
- una relazione monotonica (con l'apprendimento la qualità dei nidi non può peggiorare)



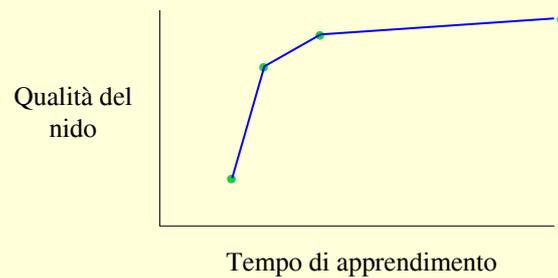
Dati (fittizi) :

Uccello	Tempo di apprendimento	Qualità del nido
A	4	9
B	2	2
C	10	10
D	3	8



Assegnamo dei ranghi ai dati :

Uccello	Tempo di apprendimento	Qualità del nido
A	4 → 3	9 → 3
B	2 → 1	2 → 1
C	10 → 4	10 → 4
D	3 → 2	8 → 2



Calcolo della correlazione di Spearman (metodo di base)

- 1) Si assegnano i ranghi ai valori di X e Y
- 2) Si calcola il coefficiente di Bravais-Pearson sui dati trasformati

Uccello	Tempo di apprendimento	Qualità del nido	XY
A	3	3	9
B	1	1	1
C	4	4	16
D	2	2	4

$$\Sigma X = 10 \quad \Sigma X^2 = 31 \quad \Sigma XY = 31$$

$$SS_x = \Sigma X^2 - \frac{(\Sigma X)^2}{n} = 6$$

$$\text{Analogamente, } SS_y = 6 \quad \text{e} \quad SP = \Sigma XY - \frac{(\Sigma X)(\Sigma Y)}{n} = 6$$

$$\text{Quindi } r_s = \frac{SP}{\sqrt{(SS_x)(SS_y)}} = 1.0$$

Calcolo di r_s dai ranghi

Se non ci sono ranghi assegnati ex-aequo, il calcolo può essere semplificato, essendo:

$$r_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n^3 - n}$$

dove d è la differenza fra il rango della i -ma osservazione per il descrittore j e quello per il descrittore k .

Calcolo di r_s dai ranghi

Se ci sono (molti) ranghi assegnati ex-aequo, il calcolo deve essere corretto come segue:

$$r_s = \frac{2n^3 - 2n - \sum_{h=1}^m (q_{hj}^3 - q_{hj}) - \sum_{h=1}^m (q_{hk}^3 - q_{hk}) - 12 \sum_{i=1}^n d_i^2}{2 \cdot \sqrt{n^3 - n - \sum_{h=1}^m (q_{hj}^3 - q_{hj})} \cdot \sqrt{n^3 - n - \sum_{h=1}^m (q_{hk}^3 - q_{hk})}}$$

dove m è il numero di ranghi e q_{hj} e q_{hk} sono il numero di osservazioni di rango h per il descrittore j e per quello k