

STATISTICA 1 - Analisi Bivariate

Riccardo Corradin, Andrea Gilardi

Introduzione

- Le metodologie statistiche presentate finora rientrano nella cosiddetta **statistica descrittiva univariata**: p caratteri sono rilevati in una popolazione ed essi vengono studiati **separatamente uno alla volta**.
- E' però ragionevole supporre che possano esistere delle **relazioni** tra le caratteristiche degli individui in una popolazione. Ad esempio, l'altezza ed il genere di una persona sono tipicamente legati al peso.
- L'obiettivo della statistica (descrittiva) **multivariata** è quello di esplorare tali relazioni per capire i pattern ed i nessi presenti nei dati.
- In questo corso ci concentreremo sulla statistica descrittiva **bivariata**, cioè analizzeremo i caratteri **due alla volta**.

Example



La seguente tabella^a riassume il *numero di interventi* e la *percentuale di sopravvivenza a 30 giorni* per gli interventi effettuati sui bambini di età minore di un anno negli ospedali britannici che, nel periodo 1991-95, avevano un reparto di cardiocirurgia infantile:

| Ospedale | Num. Interventi | Perc. Sopravvivenza a 30 giorni |
|------------------|-----------------|---------------------------------|
| Birmingham | 581 | 90% |
| Bristol | 143 | 71.3 |
| Brompton | 301 | 89.7% |
| Great Ormond St. | 482 | 89% |
| Guys | 164 | 84.8% |
| Harefield | 177 | 85.9% |
| ... | ... | ... |

^aFonte: *D.J. Spiegelhalter et al., Commissioned Analysis of Surgical Performance Using Routine Data: Lessons from the Bristol Inquiry.* [Link](#).


Example

I seguenti istogrammi riassumono le due distribuzioni **singolarmente**:



Example

E' tuttavia interessante visualizzare il **legame^a** tra queste due variabili:



Notazione



Tabella a doppia entrata

- Supponiamo di aver osservato un **primo** carattere X che assume modalità x_1, \dots, x_r ed un **secondo** carattere Y che assume modalità y_1, \dots, y_c .
- Tipicamente X e Y rappresenteranno due variabili *qualitative*.
- La **distribuzione congiunta** (i.e. la relazione) di X e Y può venire riassunta da una **tabella a doppia entrata** come segue:

| $X \backslash Y$ | y_1 | ... | y_j | ... | y_c | Totale |
|------------------|---------------|----------|---------------|----------|---------------|--------------|
| x_1 | n_{11} | ... | n_{1j} | ... | n_{1c} | $n_{1\cdot}$ |
| \vdots | \vdots | \vdots | \vdots | \vdots | \vdots | \vdots |
| x_i | n_{i1} | ... | n_{ij} | ... | n_{ic} | $n_{i\cdot}$ |
| \vdots | \vdots | \vdots | \vdots | \vdots | \vdots | \vdots |
| x_r | n_{r1} | ... | n_{rj} | ... | n_{rc} | $n_{r\cdot}$ |
| | $n_{\cdot 1}$ | ... | $n_{\cdot j}$ | ... | $n_{\cdot c}$ | N |

- Il simbolo n_{ij} indica le **frequenze assolute congiunte**: quante unità statistiche presentano **congiuntamente** le modalità x_i e y_j .
- $n_{i.}$ indica la **somma** delle frequenze assolute congiunte poste sulla i -esima **riga**: $n_{i.} = \sum_{j=1}^c n_{ij}$.
- $n_{.j}$ indica la **somma** delle frequenze assolute congiunte poste sulla j -esima **colonna**: $n_{.j} = \sum_{i=1}^r n_{ij}$.
- Le frequenze $n_{i.}$ e $n_{.j}$ vengono denominate **frequenze assolute marginali**.
- Valgono le seguenti uguaglianze

$$\sum_{i=1}^r \sum_{j=1}^c n_{ij} = \sum_{i=1}^r n_{i.} = \sum_{j=1}^c n_{.j} = N$$

- E' anche possibile definire le **frequenze relative congiunte** (f_{ij}) e le **frequenze relative marginali** ($f_{i\cdot}$ e $f_{\cdot j}$) come segue:

$$f_{ij} = \frac{n_{ij}}{N}; \quad f_{i\cdot} = \frac{n_{i\cdot}}{N}; \quad f_{\cdot j} = \frac{n_{\cdot j}}{N}$$

- Di conseguenza, una tabella a doppia entrata riassume **tre** distribuzioni: **una distribuzione congiunta** e **due distribuzioni marginali**.

| $X \setminus Y$ | y_1 | ... | y_j | ... | y_c | Totale |
|-----------------|---------------|----------|---------------|----------|---------------|--------------|
| x_1 | n_{11} | ... | n_{1j} | ... | n_{1c} | $n_{1\cdot}$ |
| \vdots | \vdots | \vdots | \vdots | \vdots | \vdots | \vdots |
| x_i | n_{i1} | ... | n_{ij} | ... | n_{ic} | $n_{i\cdot}$ |
| \vdots | \vdots | \vdots | \vdots | \vdots | \vdots | \vdots |
| x_r | n_{r1} | ... | n_{rj} | ... | n_{rc} | $n_{r\cdot}$ |
| | $n_{\cdot 1}$ | ... | $n_{\cdot j}$ | ... | $n_{\cdot c}$ | N |

Notazione

- Oltre a queste, è possibile studiare altre $r + c$ distribuzioni univariate ottenute esaminando **singolarmente** la i -esima riga o la j -esima colonna.
- Supponiamo di **restringere** le analisi alla prima riga della tabella. In tal caso, il totale è pari a $n_{1\cdot}$ diviso tra c gruppi: $\{n_{11}, \dots, n_{1j}, \dots, n_{1c}\}$:

| $X \setminus Y$ | y_1 | ... | y_j | ... | y_c | Totale |
|-----------------|----------|----------|----------|----------|----------|--------------|
| x_1 | n_{11} | ... | n_{1j} | ... | n_{1c} | $n_{1\cdot}$ |
| \vdots | \vdots | \vdots | \vdots | \vdots | \vdots | \vdots |

- Tenendo fissa la prima riga, possiamo definire le **frequenze relative del carattere Y condizionate a $X = x_1$** come

$$f(y_j|x_1) = \frac{n_{1j}}{n_{1\cdot}}; \quad j = 1, \dots, c.$$

Esse rappresentano la proporzione di unità che cadono nella classe (i, j) **condizionandoci** al fatto che il carattere X sia pari a x_1 .

- Possiamo generalizzare tale definizione a qualsiasi riga i della tabella:

$$f(y_j|x_i) = \frac{n_{ij}}{n_{i.}}; \quad j = 1, \dots, c; i = 1, \dots, r.$$

- Analogamente possiamo studiare **singolarmente** le colonne della tabella, definendo le **frequenze relative del carattere X condizionate a $Y = y_j$** :

$$f(x_i|y_j) = \frac{n_{ij}}{n_{.j}}; \quad i = 1, \dots, r; j = 1, \dots, c$$

- Esistono quindi **r distribuzioni condizionate per il carattere Y** (una per ogni possibile valore X condizionante) e **c distribuzioni condizionate per il carattere X** (una per ogni possibile valore Y condizionante).
- Vale¹ inoltre che

$$\sum_{j=1}^c f(y_j|x_i) = 1 \quad \sum_{i=1}^r f(x_i|y_j) = 1$$

¹Si provi a dimostrare le due uguaglianze come esercizio.

Example

Nel fantastico mondo di Flatlandia è tempo di eleggere il nuovo Presidente del Consiglio delle Forme. Gli abitanti sono divisi in: *Quadrati*, *Cerchi*, e *Rettangoli* e i tre candidati sono: *Archimede*, *Euclide*, e *Pitagora*. Da un campione casuale di $N = 120$ elettori si ricava che:

- tra i Quadrati, 15 voteranno Archimede, 10 Euclide e 15 Pitagora;
- tra i Cerchi, 20 voteranno Archimede, 5 Euclide e 5 Pitagora;
- tra i Rettangoli, 10 voteranno Archimede, 15 Euclide e 25 Pitagora.

Dopo aver costruito un'opportuna tabella a doppia entrata ed aver brevemente elencato tutte le distribuzioni riassunte in essa, si risponda alle seguenti:

1. Qual è la frequenza assoluta congiunta della coppia (*Cerchi*, *Archimede*)?
2. Qual è la frequenza relativa marginale dei voti per *Pitagora*?
3. Quanto vale la freq. relativa marginale dei voti per Archimede e la freq. relativa dei voti per Archimede condizionata alla popolazione dei Cerchi?

Si interpretino i risultati ottenuti.

Example

Conessione

(Assenza di) Connessione

Un carattere X viene definito **indipendente in distribuzione** (o **non-connesso**) dal carattere Y se, per ogni $j = 1, \dots, c$, tutte le frequenze relative condizionate di X dato $Y = y_j$ sono **identiche fra loro**:

$$f(x_i|y_1) = f(x_i|y_2) = \dots = f(x_i|y_c) \quad \forall i = 1, \dots, r$$

Example

La seguente tabella a doppia entrata

| $X \setminus Y$ | y_1 | y_2 | y_3 | |
|-----------------|-------|-------|-------|----|
| x_1 | 5 | 10 | 15 | 30 |
| x_2 | 3 | 6 | 9 | 18 |
| x_3 | 2 | 4 | 6 | 12 |
| | 10 | 20 | 30 | 60 |

mostra un carattere X che è **indipendente in distribuzione** da Y . Infatti ...

(Assenza di) Connessione - Proprietà

- Se X è **indipendente in distribuzione** da Y allora le sue frequenze relative condizionate sono pari alla corrispondente frequenza relativa marginale:

$$f(x_i|y_1) = f(x_i|y_2) = \dots = f(x_i|y_c) = f_i. \quad \forall i = 1, \dots, r$$

- Se X è indipendente in distribuzione da Y allora **anche Y è indipendente in distribuzione da X** . In altre parole, se

$$f(x_i|y_1) = f(x_i|y_2) = \dots = f(x_i|y_c) = f_i. \quad \forall i = 1, \dots, r$$

allora necessariamente vale anche che

$$f(y_j|x_1) = f(y_j|x_2) = \dots = f(y_j|x_r) = f_j \quad \forall j = 1, \dots, c.$$

- Se X e Y sono indipendenti in distribuzione allora

$$n_{ij} = \frac{n_{i.} \cdot n_{.j}}{N}$$

NB: Cosa implica la terza proprietà sulla distribuzione degli 0 in una tabella a doppia entrata?

Example

Data la seguente tabella a doppia entrata (che è la medesima della slide 13)

| X \ Y | y_1 | y_2 | y_3 | |
|-------|-------|-------|-------|----|
| x_1 | 5 | 10 | 15 | 30 |
| x_2 | 3 | 6 | 9 | 18 |
| x_3 | 2 | 4 | 6 | 12 |
| | 10 | 20 | 30 | 60 |

verifichiamo empiricamente le proprietà elencate in precedenza.

Example

Massima Connessione

- Si parla di **massima connessione unilaterale** di un carattere X da un carattere Y la situazione in cui se di una unità statistica è nota la modalità di Y allora è univocamente determinata anche la sua modalità di X :

| $X \setminus Y$ | y_1 | y_2 | y_3 | y_4 |
|-----------------|-------|-------|-------|-------|
| x_1 | 0 | 3 | 0 | 0 |
| x_2 | 5 | 0 | 0 | 2 |
| x_3 | 0 | 0 | 4 | 0 |

- Si parla di **massima connessione bilaterale** la situazione in cui si ha **massima connessione unilaterale** di X da Y e, al contempo, **massima connessione unilaterale** di Y da X .

| $X \setminus Y$ | y_1 | y_2 | y_3 |
|-----------------|-------|-------|-------|
| x_1 | 0 | 3 | 0 |
| x_2 | 5 | 0 | 0 |
| x_3 | 0 | 0 | 4 |

Example

Consideriamo due caratteri X e Y aventi le seguenti distribuzioni marginali:

| $X \setminus Y$ | y_1 | y_2 | y_3 | |
|-----------------|-------|-------|-------|----|
| x_1 | | | | 10 |
| x_2 | | | | 8 |
| x_3 | | | | 7 |
| | 8 | 7 | 10 | 25 |

Completare la tabella a doppia entrata nei due seguenti casi:

1. X e Y sono indipendenti in distribuzione;
2. X e Y sono massimamente connessi.

Contingenze

- Data una tabella di frequenze, è sempre possibile calcolare le quantità

$$\hat{n}_{ij} = \frac{n_{i.} \cdot n_{.j}}{N}.$$

Esse rappresentano le **frequenze assolute teoriche in caso di indipendenza in distribuzione**.

- Una eventuale *discrepanza* tra n_{ij} e \hat{n}_{ij} è **sintomo** di connessione tra X e Y . Definiamo quindi le **contingenze assolute** come

$$C_{ij} = n_{ij} - \hat{n}_{ij}$$

e le **contingenze relative** come

$$\rho_{ij} = \frac{C_{ij}}{\hat{n}_{ij}} = \frac{n_{ij} - \hat{n}_{ij}}{\hat{n}_{ij}}.$$

- Interpretazione:
 - Se $C_{ij} \simeq 0$ allora X e Y sono *indipendenti in distribuzione*;
 - Se $C_{ij} > 0$ allora X e Y presentano una certa *attrazione*;
 - Se $C_{ij} < 0$ allora X e Y presentano una certa *repulsione*.

Example

Data la seguente tabella a doppia entrata

| $X \setminus Y$ | y_1 | y_2 | y_3 | |
|-----------------|-------|-------|-------|-----|
| x_1 | 15 | 10 | 15 | 40 |
| x_2 | 20 | 5 | 5 | 30 |
| x_3 | 10 | 15 | 25 | 50 |
| | 45 | 30 | 45 | 120 |

si calcolino le **contingenze relative** ρ_{ij} .

Indice quadratico di connessione di Pearson

- L'**indice quadratico di connessione di Pearson** sintetizza le contingenze relative tramite una media quadratica con pesi pari alle frequenze teoriche in caso di indipendenza, \hat{n}_{ij} :

$$M_2(\rho) = \sqrt{\frac{1}{N} \sum_{j=1}^c \sum_{i=1}^r \hat{n}_{ij} \rho_{ij}^2} = \sqrt{\frac{1}{N} \sum_{j=1}^c \sum_{i=1}^r \frac{(n_{ij} - \hat{n}_{ij})^2}{\hat{n}_{ij}}}$$

- E' possibile dimostrare che tale indice è anche esprimibile come

$$M_2(\rho) = \sqrt{\frac{1}{N} \chi^2} \text{ dove}$$

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^c \frac{n_{ij}^2}{\hat{n}_{ij}} - N.$$

Questa formulazione evita il calcolo delle differenze $n_{ij} - \hat{n}_{ij}$.

- E' inoltre possibile dimostrare che $M_2(\rho) \leq \sqrt{\min(r-1, c-1)}$, il che ci permette di definire un **indice normalizzato**:

$$\tilde{M}_2(\rho) = \frac{M_2(\rho)}{\sqrt{\min(r-1, c-1)}}$$

Indice quadratico di connessione di Pearson

Example

Calcolare l'indice quadratico di connessione di Pearson (nella sua versione standard e normalizzata) per la seguente tabella a doppia entrata

| $X \setminus Y$ | y_1 | y_2 | y_3 | |
|-----------------|-------|-------|-------|-----|
| x_1 | 15 | 10 | 15 | 40 |
| x_2 | 20 | 5 | 5 | 30 |
| x_3 | 10 | 15 | 25 | 50 |
| | 45 | 30 | 45 | 120 |

Dipendenza in media

Dipendenza in media

- Gli strumenti presentati finora vengono solitamente usati quando i caratteri di interesse sono di tipo *qualitativo* (nominale o ordinale). Se almeno uno dei due è di tipo *quantitativo* abbiamo a disposizione anche altre analisi.
- Sia X un carattere **quantitativo** e sia Y un carattere **qualitativo** che assume valori y_1, \dots, y_c con frequenze $n_1, \dots, n_j, \dots, n_c$. Il carattere Y divide naturalmente le N osservazioni in c gruppi.

Suddivisione di N unità statistiche in c gruppi



Dipendenza in media

- Se esiste una connessione tra X e Y (i.e. se non sono **indipendenti in distribuzione**), possiamo studiare come varia la *media* di X rispetto ai gruppi definiti da Y . Per ciascun gruppo j possiamo definire

$$M_1(X|y_j) = \bar{x}_j = \frac{1}{n_{.j}} \sum_{i=1}^r x_i \cdot n_{ij} = \sum_{i=1}^r x_i f(x_i|y_j).$$

- Diciamo che X è **indipendente in media** da Y se

$$M_1(X|y_1) = M_1(X|y_2) = \dots = M_1(X|y_c) = M_1(X)$$

dove $M_1(X) = \bar{x} = \frac{1}{N} \sum_{i=1}^r x_i n_{i.}$. Se ciò non è verificato, diciamo che X **dipende in media** da Y .

Proprietà:

- 1 - La dipendenza in media non è l'unica forma di dipendenza tra variabili quantitative e qualitative. Possiamo anche parlare di *dipendenza in mediana*, *dipendenza in varianza* . . .

Dipendenza in media

2 - L'indipendenza in media **non** è una proprietà **simmetrica**. Infatti, data la loro natura, non ha senso chiedersi se Y dipende in media da X .

3 - L'indipendenza in distribuzione **implica** l'indipendenza in media:

Indipendenza in Distribuzione \Rightarrow Indipendenza in media

Come mostra il seguente esempio, il viceversa **non è vero**.

Example

Si dimostri che nella seguente tabella vi è **indipendenza in media** tra X e Y :

| $X \setminus Y$ | A | B | C | D |
|-----------------|-----|-----|-----|-----|
| 4 | 2 | 0 | 3 | 3 |
| 8 | 4 | 4 | 1 | 3 |
| 12 | 4 | 4 | 1 | 3 |
| 16 | 2 | 0 | 3 | 3 |

E' possibile che X e Y siano **indipendenti in distribuzione**?

- Dopo aver stabilito che X e Y non sono indipendenti in media, potremmo anche essere interessati a misurare la *forza* di questa dipendenza.
- Il **Rapporto di correlazione di Pearson** raggiunge questo scopo:

$$\eta_{(X|Y)}^2 = \frac{\text{Devianza fra i gruppi}}{\text{Devianza totale}}$$

dove

$$\text{Devianza fra i gruppi} = \sum_{j=1}^c n_{.j} (\bar{x}_j - \bar{x})^2$$

e

Devianza totale = Devianza nei gruppi + Devianza fra i gruppi

$$= \sum_{j=1}^c \left(\sum_{i=1}^r (x_i - \bar{x}_j)^2 \cdot n_{ij} \right) + \sum_{j=1}^c n_{.j} (\bar{x}_j - \bar{x})^2$$

NB: Pensate alla *Devianza* come ad una *Varianza* che non viene divisa per N .

Dipendenza in media

L'indice $\eta^2_{(X|Y)}$ gode di alcune proprietà.

- L'indice è naturalmente **normalizzato**, cioè $0 \leq \eta^2_{(X|Y)} \leq 1$.

Analizziamo ora le due situazioni estreme.

- L'indice vale 0 se e solo se tutte le medie nei gruppi sono uguali a \bar{x} :

$$\sum_{j=1}^c n_{.j} (\bar{x}_j - \bar{x})^2 = 0 \iff \bar{x}_j = \bar{x} \quad \forall j = 1, \dots, c.$$

Questa è esattamente la definizione di **indipendenza in media**. Quindi

$$\eta^2_{(X|Y)} = 0 \iff X \text{ e } Y \text{ sono indipendenti in media}$$

- L'indice vale 1 se e solo se la devianza nei gruppi è nulla, il che succede solamente quando tutte le distribuzioni condizionate di X assumono un solo valore che è forzatamente pari a \bar{x}_j . Di conseguenza

$$\eta^2_{(X|Y)} = 1 \iff X \text{ e } Y \text{ sono } \mathbf{\text{massimamente connessi}}$$

- Inoltre, come già detto,

$$M_2(\rho) = 0 \Rightarrow \eta_{(X|Y)}^2 = 0$$

$$\eta_{(X|Y)}^2 = 0 \not\Rightarrow M_2(\rho) = 0$$

Example

In uno studio di mineralogia si vogliono studiare tre tipi di roccia differenti (Y) misurandone il numero di cristalli per unità di volume standard (X). I dati raccolti sono riassunti nella seguente tabella:

| Roccia | Misurazioni |
|---------|----------------|
| Granito | 15, 18, 14, 17 |
| Basalto | 8, 7, 9, 10 |
| Calcere | 4, 5, 6, 5 |


Si calcoli il **rapporto di correlazione di Pearson**, $\eta_{(X|Y)}^2$, commentandone il valore ottenuto.

Covarianza e Correlazione

- Supponiamo ora che X e Y rappresentino due caratteri **quantitativi** rilevati **congiuntamente** su una popolazione di N unità. Siano

$$\{(x_1, y_1), \dots, (x_N, y_N)\}$$

le coppie di osservazioni. Come già commentato, la relazione tra X e Y può essere esplorata graficamente tramite *diagrammi a dispersione*:



Covarianza

La **covarianza** tra due caratteri numerici X e Y è un indice che misura la forza della relazione **lineare** ed è definito come

$$\text{cov}(x, y) = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y}).$$

Proprietà

- Se $\text{cov}(x, y) = 0$, allora i due caratteri si dicono essere **incorrelati**.
- La covarianza è un indice **simmetrico**: $\text{cov}(x, y) = \text{cov}(y, x)$.
- La covarianza di un indice X con se stesso è pari alla sua **varianza**. La covarianza di X e $-X$ è pari alla varianza cambiata di segno:

$$\text{cov}(x, x) = \text{var}(x) \quad \text{cov}(x, -x) = -\text{var}(x).$$

- La covarianza viene tipicamente **calcolata** sfruttando la seguente formula

$$\text{cov}(x, y) = \frac{1}{N} \sum_{i=1}^N x_i y_i - \bar{x} \bar{y}.$$

- Se i dati di un problema sono espressi tramite una **tabella a doppia entrata**, allora possiamo calcolare $\text{cov}(x, y)$ come

$$\text{cov}(x, y) = \frac{1}{N} \sum_{i=1}^r \sum_{j=1}^c n_{ij} (x_i - \bar{x})(y_j - \bar{y})$$

o, sfruttando la formula precedente,

$$\text{cov}(x, y) = \frac{1}{N} \sum_{i=1}^r \sum_{j=1}^c n_{ij} x_i y_j - \bar{x} \bar{y}.$$

- Siano $V = \alpha_1 + \beta_1 X$ e $W = \alpha_2 + \beta_2 Y$ due trasformazioni lineari dei caratteri X e Y . Allora

$$\text{cov}(v, w) = \beta_1 \beta_2 \text{cov}(x, y)$$


- Se $\eta_{(X|Y)}^2 = 0$ oppure $\eta_{(Y|X)}^2 = 0$ **allora** $\text{cov}(x, y) = 0$. C

Domanda: Che relazione può sussistere tra indipendenza in distribuzione e incorrelazione?

Covarianza

La covarianza assume valori

- **positivi** se i termini $(x_i - \bar{x})$ e $(y_i - \bar{y})$ sono **concordi** (stesso segno);
- **prossimi a 0** se i termini $(x_i - \bar{x})$ e $(y_i - \bar{y})$ sono **in egual misura concordi e discordi** così da compensarsi;
- **negativi** se i termini $(x_i - \bar{x})$ e $(y_i - \bar{y})$ sono **discordi** (segni diversi).



Example

Supponiamo di aver intervistato $N = 5$ persone e di aver chiesto loro le seguenti informazioni: $X =$ 'Reddito Annuo' (in migliaia di euro) e $Y =$ 'Superficie della casa in mq²'. La seguente tabella riporta le informazioni rilevate

| ID | 1 | 2 | 3 | 4 | 5 |
|----------------|----|----|----|----|-----|
| Reddito (X) | 28 | 42 | 33 | 85 | 66 |
| Superficie (Y) | 52 | 65 | 64 | 84 | 102 |

Rappresentare la relazione tra X e Y tramite un grafico opportuno e calcolare $\text{cov}(x, y)$ commentando il risultato ottenuto.

- Come si evince dal precedente esempio, è chiaro come interpretare il **segno** di una covarianza ma non il suo esatto **valore numerico**...
- Sarebbe utile poter definire una versione **normalizzata** di questo indice!! Siamo fortunati poichè è possibile dimostrare che

$$-\text{sqm}(x)\text{sqm}(y) \leq \text{cov}(x, y) \leq \text{sqm}(x)\text{sqm}(y)$$

dove $\text{sqm}(x)$ e $\text{sqm}(y)$ rappresentano, rispettivamente, lo **scarto quadratico medio** dei caratteri X e Y , indicati anche come σ_X e σ_Y .

Esercizio

Si dimostri empiricamente la proprietà di massimo e minimo della covarianza utilizzando i dati della slide precedente.


Correlazione

La covarianza nella sua versione **normalizzata** viene chiamata **correlazione** ed è definita come

$$\rho_{XY} = \text{cor}(x, y) = \frac{\text{cov}(x, y)}{\text{sqm}(x)\text{sqm}(y)}$$


Proprietà:

- Per definizione, si ha che $-1 \leq \rho_{XY} \leq 1$.
- Inoltre, sempre per definizione, $\text{cor}(x, x) = 1$ e $\text{cor}(x, -x) = -1$. Quando si verifica quindi che $|\rho_{XY}| = 1$?



Correlazione

La **covarianza** e la **correlazione** misurano il legame **lineare** tra due variabili! In entrambi i seguenti casi si ha che $\rho_{XY} \simeq 0$ tuttavia...



This keeps happening. How heavy are cats?



Example

Nel 1886 Francis Galton ha pubblicato un articolo^a in cui studiava come variassero le caratteristiche individuali da una generazione all'altra. In particolare egli era interessato a capire la relazione tra l'altezza dei genitori e quella dei loro figli (da adulti). La seguente tabella contiene un estratto dei dati pubblicati da Galton.

| | | | | | |
|-----------------------------|-------|-------|-------|-------|-----|
| Altezza media genitori (cm) | 176.5 | 168.9 | 171.5 | 168.9 | 174 |
| Altezza figli (cm) | 180.8 | 175.7 | 165.6 | 173.3 | 173 |


Dopo aver rappresentato i dati tramite un istogramma, si calcoli la correlazione tra le due misure interpretando il risultato ottenuto.

^aGalton, F. (1886). Regression Towards Mediocrity in Hereditary Stature Journal of the Anthropological Institute, 15, 246-263

Regressione lineare semplice

Regressione lineare semplice

La seguente figura mostra il grafico a dispersione della statura dei figli maschi rispetto ai loro padri usando i dati pubblicati da Galton.



Regressione lineare semplice

- I dati hanno un legame lineare positivo mediamente forte ($\rho_{XY} = 0.48$). Potremmo quindi essere interessati a rispondere alla seguente domanda:

Come prevedere la statura dei figli conoscendo quella dei genitori?

- Adottiamo per il momento una ipotesi di **linearità**:

$$\text{AltFigli} = \alpha + \beta(\text{AltGenitori}) + (\text{Errore})$$


La componente di **Errore** cattura la randomicità nell'altezza dei figli non spiegabile tramite le altezze dei genitori.

- I termini α e β rappresentano rispettivamente l'**intercetta** ed il **coefficiente angolare** della **retta di regressione**.
- Entrambi sono parametri ignoti che vanno **stimati** tramite i dati osservati. I valori stimati verranno indicati come $\hat{\alpha}$ e $\hat{\beta}$.

Regressione lineare semplice


Siano $\{(x_1, y_1), \dots, (x_N, y_N)\}$ le altezze osservate sulle N unità statistiche (i.e. coppie padre/figlio). Esistono **infinite rette** del tipo

$$\text{AltFigli} = \hat{\alpha} + \hat{\beta}(\text{AltGenitori})$$



Regressione lineare semplice

Ogni retta che scegliamo creerà un **residuo** (le linee verticali tratteggiate): la **differenza** tra la statura di un figlio ed il valore risultante se usassimo **la retta per prevedere la statura a partire dall'altezza dei genitori**.



- Per stimare i valori **ottimi** di α e β **minimizziamo** la somma dei residui al **quadrato**:

$$\arg \min_{\alpha, \beta} \sum_{i=1}^N (y_i - \alpha - \beta x_i)^2.$$

- E' possibile dimostrare che la **soluzione ottima** a questo problema è

$$\hat{\alpha} = \bar{y} - \hat{\beta} \bar{x}; \quad \hat{\beta} = \frac{\text{cov}(x, y)}{\text{var}(x)}$$

- Nel caso dei dati di Galton si ha che

$$\bar{x} = 175.632; \quad \bar{y} = 175.85; \quad \text{cov}(x, y) = 14.482; \quad \text{var}(x) = 20.305$$

così che

$$\hat{\beta} = \frac{14.482}{20.305} \simeq 0.7; \quad \hat{\alpha} = 175.85 - 0.7 \cdot 175.632 \simeq 50.$$

Regressione lineare semplice

Ma perchè la **regressione lineare semplice** si chiama **regressione**? E' colpa di Francis Galton e del fenomeno denominato **regressione verso la media**.

