


Statistica Sociale

10/04/2025



Analisi dell'associazione tra due variabili

| Secondo te la tua famiglia è: (valori %) | | | | | | | |
|--|-------|-------|---------------|---------------|-----------------|-------------------------|--------|
| | I | II | Famiglie con | Famiglie | Famiglie | Famiglie con più nuclei | |
| | GRADO | GRADO | solo 1 figlio | con più figli | monogenitoriali | o ricostituite | TOTALE |
| Ricca | 12,1 | 9,3 | 12,8 | 10,0 | 7,2 | 10,4 | 10,4 |
| Né ricca né povera | 80,4 | 80,1 | 79,4 | 80,7 | 79,6 | 80,7 | 80,2 |
| Povera | 2,1 | 4,6 | 2,5 | 3,2 | 7,0 | 3,2 | 3,7 |
| Non risponde | 5,4 | 6,0 | 5,3 | 5,7 | 6,2 | 5,7 | 5,7 |

Fonte: Istat, elaborazione del SPPS RAFVG

Indagine Istat 2021 "Bambini e ragazzi: comportamenti, atteggiamenti e progetti futuri", campione casuale nazionale di circa 41 mila alunni scuole secondarie di I e II grado. a.s. 2020/2021

FVG: oltre 2 mila bambini e ragazzi, (39,8% secondarie di I grado e 60,2% secondarie II grado; 16,1% con cittadinanza straniera)

SPPS: Servizio programmazione, pianificazione strategica, controllo di gestione e statistica della Direzione generale della Regione Autonoma Friuli Venezia Giulia (report VITA QUOTIDIANA A DISTANZA, 21/12/2023)

Analisi dell'associazione tra due variabili

L'obiettivo delle indagini statistiche che coinvolgono più variabili è quello di studiare l'**associazione** tra le variabili in esame

Associazione: quando una variabile cambia il suo valore, l'altra variabile tende ad assumere certi valori

Un'analisi tra due variabili è detta **bivariata**

C'è associazione tra:

- tipologia familiare e situazione economica?
- sesso e retribuzione?
- numero di ore passate all'aria aperta e l'età?

Utilizzando le **tabelle di contingenza** è possibile osservare la distribuzione dei soggetti secondo tutte le possibili combinazioni tra le modalità di due variabili

| Sesso | Orientamento Politico | | | Totale |
|---------|-----------------------|--------------|--------------|--------|
| | Democratici | Indipendenti | Repubblicani | |
| Femmine | 573 | 516 | 422 | 1511 |
| Maschi | 386 | 475 | 399 | 1260 |
| Totale | 959 | 991 | 821 | 2771 |

La tabella mostra la distribuzione degli intervistati al GSS 2004, secondo il sesso e l'orientamento politico

Tabelle di contingenza

Utilizzando le **tabelle di contingenza** è possibile osservare la distribuzione dei soggetti secondo tutte le possibili combinazioni tra le modalità di due variabili

| Unità | Sesso | Età | Statura | Colore occhi |
|-------|-------|-----|---------|--------------|
| 1 | F | 24 | 163 | Marrone |
| 2 | F | 21 | 165 | Azzurri |
| 3 | M | 34 | 185 | Azzurri |
| 4 | F | 22 | 164 | Marroni |
| 5 | F | 21 | 167 | Marroni |
| 6 | F | 22 | 175 | Verdi |
| 7 | M | 24 | 178 | Verdi |
| 8 | F | 21 | 155 | Marroni |

| Sesso | Numerosità | Colore occhi | Numerosità |
|-------|------------|--------------|------------|
| F | 6 | Azzurri | 2 |
| M | 2 | Marroni | 4 |
| | 8 | Verdi | 2 |

| Sesso/Colore occhi | Azzurri | Marroni | Verdi | |
|--------------------|---------|---------|-------|---|
| F | 1 | 4 | 1 | 6 |
| M | 1 | 0 | 1 | 2 |
| | 2 | 4 | 2 | 8 |

Dati due caratteri X e Y si definisce **distribuzione doppia di frequenze** l'insieme delle **frequenze congiunte** n_{ij} , ovvero le frequenze assolute delle unità che presentano congiuntamente la modalità i -esima della variabile X e la modalità j -esima della variabile Y

- Si possono costruire per tutti i tipi di variabili ma per migliorare la leggibilità della tabella è opportuno ricodificare la variabile in categorie o classi (soprattutto nel caso di caratteri quantitativi continui)

Possiamo identificare le **distribuzioni marginali** e le **distribuzioni condizionate**

- Una **distribuzione marginale** di una variabile corrisponde alla distribuzione di frequenza della singola variabile (totali di riga/totali di colonna)
- Una **distribuzione condizionata** di una variabile corrisponde alla distribuzione di frequenza di una variabile condizionata rispetto ad una o più modalità dell'altra variabile

| | | | | | | | | |
|---------------|-------|---|-----|----------|-----|----------|--|--|
| | | <u>Distribuzione condizionata della X data $Y=y_i$</u> | | | | | <u>Distribuzione marginale della X</u> | |
| | | Y | | | | | | |
| | | y_1 | ... | y_j | ... | y_H | Totale | |
| X | x_1 | n_{11} | ... | n_{1j} | ... | n_{1H} | $n_{1.}$ | |
| | ... | ... | ... | ... | ... | ... | ... | |
| | x_i | n_{i1} | ... | n_{ij} | ... | n_{iH} | $n_{i.}$ | |
| | ... | ... | ... | ... | ... | ... | ... | |
| | x_K | n_{K1} | ... | n_{Kj} | ... | n_{KH} | $n_{K.}$ | |
| Totale | | $n_{.1}$ | ... | $n_{.j}$ | ... | $n_{.H}$ | n | |
| | | <u>Distribuzione condizionata della Y data $X=x_i$</u> | | | | | <u>Distribuzione marginale della Y</u> | |

Distribuzione doppia, marginale e condizionata

| Sesso | Orientamento Politico | | | Totale |
|---------|-----------------------|--------------|--------------|--------|
| | Democratici | Indipendenti | Repubblicani | |
| Femmine | 573 | 516 | 422 | 1511 |
| Maschi | 386 | 475 | 399 | 1260 |
| Totale | 959 | 991 | 821 | 2771 |

Con riferimento alla tabella, individuare

- la distribuzione congiunta della variabile Sesso e Orientamento Politico:
- la distribuzione marginale della variabile Sesso:
- la distribuzione condizionata della variabile Orientamento Politico rispetto alla modalità Femmine:
- la distribuzione condizionata della variabile Sesso rispetto alla modalità Repubblicani:

Distribuzioni doppie

Distribuzione marginale della X

$$n_{i.} = \sum_{j=1}^H n_{ij} = n_{i1} + n_{i2} + \dots + n_{iH}, \text{ per } i = 1, \dots, K$$

Distribuzione marginale della Y

$$n_{.j} = \sum_{i=1}^K n_{ij} = n_{1j} + n_{2j} + \dots + n_{Kj}, \text{ per } j = 1, \dots, H$$

Numerosità campionaria

$$n = \sum_{i=1}^H \sum_{j=1}^K n_{ij} = \sum_{i=1}^K n_{i.} = \sum_{j=1}^H n_{.j}$$

Distribuzione marginale del Sesso

$$n_{1.} = 6$$

$$n_{2.} = 2$$

Distribuzione marginale del Colore degli occhi

$$n_{.1} = 2$$

| Sesso/Colore occhi | Azzurri | Marroni | Verdi | |
|--------------------|---------|---------|-------|---|
| F | 1 | 4 | 1 | 6 |
| M | 1 | 0 | 1 | 2 |
| | 2 | 4 | 2 | 8 |

Dividendo per il corrispondente totale si ottiene:

- la **distribuzione di frequenze doppie relative** f_{ij} (dividendo le frequenze congiunte per il totale n)

| Sesso/Colore occhi | Azzurri | Marroni | Verdi | |
|--------------------|---------|---------|-------|---|
| F | 1 | 4 | 1 | |
| M | 1 | 0 | 1 | |
| | | | | 8 |

| Sesso/Colore occhi | Azzurri | Marroni | Verdi | |
|--------------------|---------|---------|-------|---|
| F | 1/8 | 4/8 | 1/8 | |
| M | 1/8 | 0/8 | 1/8 | |
| | | | | 1 |

- le **distribuzioni marginali relative** (dividendo le frequenze marginali per il totale n)

| Sesso/Colore occhi | Azzurri | Marroni | Verdi | |
|--------------------|---------|---------|-------|---|
| F | | | | 6 |
| M | | | | 2 |
| | 2 | 4 | 2 | 8 |

| Sesso/Colore occhi | Azzurri | Marroni | Verdi | |
|--------------------|---------|---------|-------|-----|
| F | | | | 6/8 |
| M | | | | 2/8 |
| | 2/8 | 4/8 | 2/8 | 1 |

- le **distribuzioni relative condizionate** (dividendo le frequenze condizionate per il corrispondente totale di riga/colonna)

| Sesso/Colore occhi | Azzurri |
|--------------------|---------|
| F | 1 |
| M | 1 |
| | 2 |

| Sesso/Colore occhi | Azzurri |
|--------------------|---------|
| F | 1/2 |
| M | 1/2 |
| | 1 |

| Sesso/Colore occhi | Azzurri | Marroni | Verdi | |
|--------------------|---------|---------|-------|---|
| F | 1 | 4 | 1 | 6 |
| | | | | |
| Sesso/Colore occhi | Azzurri | Marroni | Verdi | |
| F | 1/6 | 4/6 | 1/6 | 1 |

Moltiplicando le frequenze relative per 100 otteniamo le corrispondenti frequenze percentuali

Tabella 6.2.3 Laureati del 2011 in lauree magistrali per condizione occupazionale nel 2015
(fonte ISTAT)

| Condizione occupazionale | Gruppo di corsi di laurea | | | Totale |
|---------------------------|---------------------------|----------------------|------------|--------|
| | Medico | Economico-statistico | Letterario | |
| Occupati | 9.090 | 14.787 | 7.361 | 31.238 |
| In cerca di lavoro | 126 | 1.534 | 2.146 | 3.806 |
| Non cercano lavoro | 202 | 350 | 522 | 1.074 |
| Totale | 9.418 | 16.671 | 10.029 | 36.118 |

Tabella 6.2.4 Distribuzioni doppie percentuali e distribuzioni percentuali condizionate

| Condizione occupazionale | Gruppo di corsi di laurea | | | Totale (%) |
|---------------------------|---------------------------|----------------------|------------|------------|
| | Medico | Economico-statistico | Letterario | |
| Occupati | (% totale) | 25,2 | 40,9 | 20,4 |
| | (% riga) | 29,1 | 47,3 | 23,6 |
| | (% colonna) | 96,5 | 88,7 | 73,4 |
| In cerca di lavoro | (% totale) | 0,3 | 4,2 | 5,9 |
| | (% riga) | 3,3 | 40,3 | 56,4 |
| | (% colonna) | 1,3 | 9,2 | 21,4 |
| Non cercano lavoro | (% totale) | 0,6 | 1,0 | 1,4 |
| | (% riga) | 18,8 | 32,6 | 48,6 |
| | (% colonna) | 2,1 | 2,1 | 5,2 |
| Totale | | 26,1 | 46,2 | 27,8 |

Distribuzione percentuale congiunta

Distribuzione condizionata della condizione occupazionale rispetto al gruppo di laurea

Distribuzione condizionata del gruppo di laurea rispetto alla condizione occupazionale

Distribuzione marginale percentuale

Medie condizionate

Per ogni distribuzione condizionata di un carattere quantitativo si può calcolare la media aritmetica condizionata

$$\bar{x}_{Y=y_j} = \frac{1}{n_{.j}} \sum_{i=1}^K x_i n_{ij} \quad \bar{y}_{X=x_i} = \frac{1}{n_{i.}} \sum_{j=1}^H y_j n_{ij}$$

Il numero di medie condizionate aumenta all'aumentare delle modalità del carattere

Nel caso di carattere quantitativo suddiviso in classi si può calcolare la media aritmetica approssimata utilizzando il valore centrale di ogni classe

The diagram illustrates a contingency table with the following structure:

| | | Y | | | | | Totale |
|--------|-------|----------|-----|----------|-----|----------|----------|
| | | y_1 | ... | y_j | ... | y_H | |
| X | x_1 | n_{11} | ... | n_{1j} | ... | n_{1H} | $n_{1.}$ |
| | ... | ... | ... | ... | ... | ... | ... |
| | x_i | n_{i1} | ... | n_{ij} | ... | n_{iH} | $n_{i.}$ |
| | ... | ... | ... | ... | ... | ... | ... |
| | x_K | n_{K1} | ... | n_{Kj} | ... | n_{KH} | $n_{K.}$ |
| Totale | | $n_{.1}$ | ... | $n_{.j}$ | ... | $n_{.H}$ | n |

Annotations and arrows in the diagram:

- Distribuzione condizionata della X data $Y=y_j$** : Points to the column of cells n_{1j}, n_{ij}, n_{Kj} .
- Distribuzione marginale della X**: Points to the row of marginal totals $n_{1.}, n_{i.}, n_{K.}$.
- Distribuzione condizionata della Y data $X=x_i$** : Points to the row of cells n_{i1}, n_{ij}, n_{iH} .
- Distribuzione marginale della Y**: Points to the column of marginal totals $n_{.1}, n_{.j}, n_{.H}$.

$$\bar{y}_{X=x_i} = \frac{1}{n_{i.}} \sum_{j=1}^H y_j n_{ij}$$

| | | Y Numero di case | | | |
|---------------------|---|------------------|----|---|---------------|
| | | 1 | 2 | 3 | |
| X Numero di auto | 1 | 21 | 8 | 0 | 29 = $n_{1.}$ |
| | 2 | 12 | 11 | 1 | 24 |
| | 3 | 7 | 6 | 2 | 15 |
| | | 40 | 25 | 3 | 68 |

$$\bar{y} = \frac{1}{68} (1 * 40 + 2 * 25 + 3 * 3) = 1,45$$

$$\bar{y}_{X=1} = 1,28$$

$$\bar{y}_{X=2} = 1,54$$

$$\bar{y}_{X=3} = 1,67$$

$$\bar{x}_{Y=1} = 1,65$$

$$\bar{x}_{Y=2} = 1,92$$

$$\bar{x}_{Y=3} = 2,67$$

$$\bar{x} = \frac{1}{18} (1 * 29 + 2 * 24 + 3 * 15) = 1,79$$

$$\bar{y}_{X=1} = \frac{1}{29} (1 * 21 + 2 * 8 + 3 * 0) = 1,28$$

$$\bar{y}_{X=2} = \frac{1}{24} (1 * 12 + 2 * 11 + 3 * 1) = 1,54$$

$$\bar{x}_{Y=1} = \frac{1}{40} (1 * 21 + 2 * 12 + 3 * 7) = 1,65$$

Calcola la media condizionata della variabile numero di case rispetto alle modalità 3 della variabile numero di auto:

Calcola le medie condizionate della variabile numero di auto rispetto alle modalità 2 e 3 della variabile numero di case:

Rappresentazione grafica

Se entrambi i caratteri sono **quantitativi** possiamo utilizzare il **grafico di dispersione**

Importazioni ed esportazioni dei paesi OCSE nel 2010 (fonte Nazioni Unite)

| Paese | Import. | Esport. | Paese | Import. | Esport. | Paese | Import. | Esport. |
|-------------|---------|---------|------------|---------|---------|-----------|---------|---------|
| Danimarca | 84,7 | 96,8 | Italia | 487,0 | 446,9 | Finlandia | 68,8 | 69,5 |
| Irlanda | 60,7 | 118,3 | Spagna | 315,5 | 246,3 | Svizzera | 166,9 | 185,8 |
| Inghilterra | 561,5 | 410,2 | Portogallo | 75,6 | 48,7 | Austria | 150,3 | 144,6 |
| Olanda | 440,6 | 440,6 | Grecia | 50,7 | 20,9 | Turchia | 140,9 | 185,5 |
| Belgio | 393,5 | 409,3 | Islanda | 3,9 | 4,6 | USA | 1.968,8 | 1.277,6 |
| Germania | 1.056,2 | 1.261,6 | Norvegia | 77,3 | 131,4 | Canada | 390,5 | 386,0 |
| Francia | 605,6 | 515,3 | Svezia | 148,5 | 158,1 | Giappone | 692,4 | 769,8 |

Grafico di dispersione delle importazioni e delle esportazioni dei paesi OCSE, 2010








Grafico di dispersione (scatterplot): esempi di relazione/1

Relazione Lineare



Relazione non lineare



Il grafico di dispersione fornisce un riscontro sul fatto che la relazione sia approssimativamente lineare o non lineare (curvilinea)

Grafico di dispersione (scatterplot): esempi di relazione/2









Grafico di dispersione (scatterplot): esempi di relazione/3

Nessuna relazione




Esempio: vendite e superficie negozio

| Volume vendite settimanali (*100 €) | Spazio espositivo (m ²) |
|--|-------------------------------------|
| 43,2 | 95 |
| 132,0 | 144 |
| 155,0 | 210 |
| 76,0 | 156 |
| 100,9 | 188 |
| 187,4 | 321 |
| 185,0 | 250 |
| 60,7 | 115 |
| 82,9 | 178 |
| 61,3 | 105 |

Rilevazione delle variabili su 10 negozi

Esempio: vendite e superficie negozio




E' ragionevole ipotizzare che a maggiori spazi espositivi tendano a corrispondere valori più elevati delle vendite.

La disposizione dei punti sembra essere approssimata bene da una retta.


Diagramma di dispersione (scatter plot) per esame grafico della relazione tra le variabili

Esempio: reddito e spesa mensile



Esempio: tasso di omicidi e di povertà

(50 stati USA + Washington DC = 51 osservazioni)



La disposizione dei punti sembra essere approssimata bene da una retta (n.b. un punto –DC– è lontano dal resto delle osservazioni).

Indipendenza statistica

Attraverso le tabelle di contingenza è possibile studiare l'eventuale dipendenza di una variabile dall'altra

È possibile verificare ciò attraverso la **presenza o meno di indipendenza**. Se due variabili categoriali non sono indipendenti, allora sono **associate**


Due variabili categoriali sono **statisticamente indipendenti** se nella popolazione le distribuzioni condizionate di una variabile rispetto a ciascuna categoria dell'altra sono identiche

Due variabili categoriali sono **statisticamente dipendenti** se nella popolazione le distribuzioni condizionate di una variabile rispetto a ciascuna categoria dell'altra non sono identiche

Molto utile è la **trasformazione delle frequenze in percentuali**, per agevolare la comprensione

| Gruppo Etnico | Orientamento Politico | | | Totale |
|---------------|-----------------------|-----------|-----------|-------------|
| | Dem | Indip | Repub | |
| Bianchi | 440 (44%) | 140 (14%) | 420 (42%) | 1000 (100%) |
| Neri | 44 (44%) | 14 (14%) | 42 (42%) | 100 (100%) |
| Ispanici | 110 (44%) | 35 (14%) | 105 (42%) | 250 (100%) |

Che tipo di distribuzioni sono?



Due variabili categoriali sono **statisticamente indipendenti** se nella popolazione le distribuzioni condizionate di una rispetto a ciascuna categoria dell'altra sono identiche

| Sesso | Orientamento Politico | | | Totale | n |
|---------|-----------------------|-------|-------|--------|------|
| | Dem | Indip | Repub | | |
| Femmine | 38% | 34% | 28% | 100% | 1511 |
| Maschi | 31% | 38% | 32% | 101% | 1260 |

| Gruppo Etnico | Orientamento Politico | | | Totale |
|---------------|-----------------------|-----------|-----------|-------------|
| | Dem | Indip | Repub | |
| Bianchi | 440 (44%) | 140 (14%) | 420 (42%) | 1000 (100%) |
| Neri | 44 (44%) | 14 (14%) | 42 (42%) | 100 (100%) |
| Ispanici | 110 (44%) | 35 (14%) | 105 (42%) | 250 (100%) |

L'indipendenza statistica è una proprietà **simmetrica** per le due variabili: se le distribuzioni condizionate per ogni riga sono identiche, sono identiche anche quelle per colonna

- Ad esempio per l'orientamento ed il gruppo etnico le distribuzioni condizionate del gruppo etnico rispetto alle modalità dell'orientamento politico sono:

- Dall'evidenza empirica, l'orientamento politico dipende dal sesso perché le distribuzioni condizionate percentuali sono diverse
- Nel campione osservato, l'orientamento politico non dipende dal gruppo etnico perché le distribuzioni condizionate percentuali sono uguali

Test chi-quadro di indipendenza

Il concetto di **indipendenza statistica** è riferito alla **popolazione**, in genere noi disponiamo di **dati campionari**. Le distribuzioni condizionate campionarie possono essere diverse pur essendo le variabili indipendenti a livello di popolazione

Per **verificare statisticamente** la reale esistenza di indipendenza tra due variabili categoriali (a livello di popolazione), possiamo applicare il **test** chi-quadro per l'indipendenza

Le **ipotesi** saranno:

- H_0 : le variabili sono statisticamente indipendenti.
- H_a : le variabili sono statisticamente dipendenti.

Requisiti minimi per l'applicazione del test: campionamento casuale o esperimento randomizzato e campione sufficientemente grande.

Frequenze attese per l'indipendenza

Il **test del chi-quadro** si basa sul confronto tra frequenze osservate e frequenze attese

La **frequenza attesa** n'_{ij} è quella che potremmo osservare in presenza di indipendenza tra le due variabili, corrisponde cioè alla numerosità attesa in una cella se le due variabili sono indipendenti:

$$n'_{ij} = \frac{n_{i.} \cdot n_{.j}}{n} = \frac{\text{totale di riga per la modalità } i * \text{totale di colonna per la modalità } j}{\text{numerosità campionaria totale}}$$

Nel caso di indipendenza tra sesso e orientamento politico avremo:

$$\begin{aligned} n'_{11} &= \frac{1511 * 959}{2771} = 522,9 & n'_{21} &= \frac{1260 * 959}{2771} = 436,1 \\ n'_{12} &= \frac{1511 * 991}{2771} = 540,4 & n'_{22} &= \frac{1260 * 991}{2771} = 450,6 \\ n'_{13} &= \frac{1511 * 821}{2771} = 447,7 & n'_{23} &= \frac{1260 * 821}{2771} = 373,3 \end{aligned}$$

| Sesso | Orientamento Politico | | | Totale |
|--------|-----------------------|-------------|-------------|--------|
| | Dem | Indip | Repub | |
| Donne | 573 (522.9) | 516 (540.4) | 422 (447.7) | 1511 |
| Uomini | 386 (436.1) | 475 (450.6) | 399 (373.3) | 1260 |
| Totale | 959 | 991 | 821 | 2771 |

Se c'è indipendenza, ci aspettiamo che le frequenze osservate siano «vicine» a quelle attese

Calcoliamo le differenze tra le frequenze osservate e quelle attese:

| Sesso | Orientamento Politico | | | Totale |
|--------|-----------------------|-------------|-------------|--------|
| | Dem | Indip | Repub | |
| Donne | 573 (522.9) | 516 (540.4) | 422 (447.7) | 1511 |
| Uomini | 386 (436.1) | 475 (450.6) | 399 (373.3) | 1260 |
| Totale | 959 | 991 | 821 | 2771 |

$$n_{11} - n'_{11} = 573 - 522,9 = 50,1$$

$$n_{12} - n'_{12} = 516 - 540,4 = -24,4$$

$$n_{13} - n'_{13} = 422 - 447,7 = -25,7$$

$$n_{21} - n'_{21} = 386 - 436,1 = -50,1$$

$$n_{22} - n'_{22} = 475 - 450,6 = 24,4$$

$$n_{23} - n'_{23} = 399 - 373,3 = 25,7$$

Riusciamo a valutare se le differenze sono grandi o piccole?

La statistica test del chi-quadro

Poichè in H_0 si è ipotizzata l'indipendenza tra le due variabili, il test statistico viene costruito con l'intenzione di evidenziare l'allontanamento da H_0

Si basa sulle differenze tra frequenze osservate e frequenze attese

La statistica test è la statistica chi-quadro χ^2 data da

$$\chi^2 = \sum_{i,j} \frac{(n_{ij} - n'_{ij})^2}{n'_{ij}}$$

Sommiamo per ogni cella, il rapporto tra differenza al quadrato tra frequenza attesa e osservata e la frequenza attesa

- Se $\chi^2 = 0$ le due variabili sono indipendenti (applicando il test a dati campionari, può bastare che sia sufficientemente piccolo)
- Al crescere del valore di χ^2 aumenta l'evidenza contro H_0
- χ^2 non può essere negativo

Questo valore viene confrontato con i valori della distribuzione teorica sotto l'ipotesi di indipendenza

Si ottiene il **p-value**, un valore che misura quanto i dati osservati sono compatibili con l'ipotesi di indipendenza

Valori soglia per il p-value sono in genere: 0,1; 0,05; 0,01

$$\begin{aligned}n_{11} - n'_{11} &= 573 - 522,9 = 50,1 \\n_{12} - n'_{12} &= 516 - 540,4 = -24,4 \\n_{13} - n'_{13} &= 422 - 447,7 = -25,7 \\n_{21} - n'_{21} &= 386 - 436,1 = -50,1 \\n_{22} - n'_{22} &= 475 - 450,6 = 24,4 \\n_{23} - n'_{23} &= 399 - 373,3 = 25,7\end{aligned}$$

$$\chi^2 = \left(\frac{50,1^2}{522,9} + \frac{(-24,4)^2}{540,4} + \dots + \frac{24,4^2}{450,6} + \frac{25,7^2}{373,3} \right) = 4,8 + \dots + 1,8 = 16,2$$

Il p-value in questo caso è pari a 0,0003

Concludiamo che c'è una forte evidenza empirica contro l'ipotesi di indipendenza H_0 , quindi le due variabili sesso e orientamento politico sembrano essere associate nella popolazione

Se le variabili fossero indipendenti, dovrebbe essere davvero inusuale per un campione casuale avere un valore della statistica χ^2 così elevato

Chi-quadro e associazione

Il test chi-quadro risponde alla domanda «C'è associazione?»

Esistono misure di associazione che sintetizzano la forza di dipendenza tra due variabili

Nel caso A della tabella vediamo un caso di indipendenza

Nel caso B vediamo un caso di dipendenza forte

| Caso A | Razze | Opinione | | Totale | Caso B | Opinione | | Totale |
|--------|---------|------------|-----------|--------|--------|------------|-----------|--------|
| | | Favorevole | Contrario | | | Favorevole | Contrario | |
| | Bianchi | 360 | 240 | 600 | | 600 | 0 | 600 |
| | Neri | 240 | 160 | 400 | | 0 | 400 | 400 |
| | Totale | 600 | 400 | 1000 | | 600 | 400 | 1000 |

La statistica chi-quadro indica quanta evidenza c'è a favore della dipendenza, non ne misura la forza (valori più grandi si verificano quando la numerosità è grande)

Chi-quadro e associazione

| | A | | | B | | | C | | |
|---------|---|-----|--------|---|-----|--------|---|--------|--------|
| | Sì | No | Totale | Sì | No | Totale | Sì | No | Totale |
| Bianchi | 49 | 51 | 100 | 98 | 102 | 200 | 4900 | 5100 | 10 000 |
| Neri | 51 | 49 | 100 | 102 | 98 | 200 | 5100 | 4900 | 10 000 |
| | 100 | 100 | 200 | 200 | 200 | 400 | 10 000 | 10 000 | 20 000 |
| | $\chi^2 = 0.08$ $P\text{-valore} = 0.78$ | | | $\chi^2 = 0.16$ $P\text{-valore} = 0.69$ | | | $\chi^2 = 8.0$ $P\text{-valore} = 0.005$ | | |

Il valore di χ^2 non fornisce una misura della forza dell'associazione, in quanto fortemente dipendente dalla dimensione campionaria.

Misura della correlazione per variabili quantitative

Coefficiente di correlazione

$$r_{XY} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

numeratore della
deviazione standard di X

$$s_x = \sqrt{\frac{\sum (x - \bar{x})^2}{n-1}}$$

e

$$s_y = \sqrt{\frac{\sum (y - \bar{y})^2}{n-1}}$$

numeratore della
deviazione standard di Y


- Indicato anche con: r , ρ , ρ o anche R
- Il coefficiente è simmetrico: $r_{xy} = r_{yx}$ e misura l'*interdipendenza* tra X e Y
- Il valore di r non risente dell'unità di misura e dell'ordine di grandezza di X e Y
- Assume valori compresi tra -1 e 1 (estremi inclusi)
- $r_{xy} = -1$ perfetta **relazione lineare inversa (negativa)** tra X e Y
- $r_{xy} = 1$ perfetta **relazione lineare concorde (positiva)** tra X e Y
- $r_{xy} = 0$ X e Y sono incorrelati (anche se non si può escludere una relazione **non lineare** - ad es. parabolica - tra X e Y)

Coefficiente di correlazione – Esempio

12 congelatori: capacità totale (in litri) e prezzo (in euro)

| Capacità totale | Prezzo | Capacità totale | Prezzo |
|--------------------|--------|--------------------|--------|
| 230 | 325 | 279 | 564 |
| 234 | 274 | 308 | 815 |
| 235 | 412 | 308 | 685 |
| 235 | 431 | 310 | 556 |
| 264 | 518 | 326 | 651 |
| 278 | 460 | 343 | 824 |

Grafico di dispersione



Esempio calcolo coefficiente di correlazione

| i | x_i | y_i | $x_i - \bar{x}$ | $y_i - \bar{y}$ | $(x_i - \bar{x})^2$ | $(y_i - \bar{y})^2$ | $(x_i - \bar{x})(y_i - \bar{y})$ |
|---------------|-------|-------|-----------------|-----------------|---------------------|---------------------|----------------------------------|
| 1 | 230 | 325 | -49.2 | -217.9 | 2'420.64 | 47'480.41 | 10'720.68 |
| 2 | 234 | 274 | -45.2 | -268.9 | 2'043.04 | 72'307.21 | 12'154.28 |
| 3 | 235 | 412 | -44.2 | -130.9 | 1'953.64 | 17'134.81 | 5'785.78 |
| 4 | 235 | 431 | -44.2 | -111.9 | 1'953.64 | 12'521.61 | 4'945.98 |
| 5 | 264 | 518 | -15.2 | -24.9 | 231.04 | 620.01 | 378.48 |
| 6 | 278 | 460 | -1.2 | -82.9 | 1.44 | 6'872.41 | 99.48 |
| 7 | 279 | 564 | -0.2 | 21.1 | 0.04 | 445.21 | -4.22 |
| 8 | 308 | 815 | 28.8 | 272.1 | 829.44 | 74'038.41 | 7'836.48 |
| 9 | 308 | 685 | 28.8 | 142.1 | 829.44 | 20'192.41 | 4'092.48 |
| 10 | 310 | 556 | 30.8 | 13.1 | 948.64 | 171.61 | 403.48 |
| 11 | 326 | 651 | 46.8 | 108.1 | 2'190.24 | 11'685.61 | 5'059.08 |
| 12 | 343 | 824 | 63.8 | 281.1 | 4'070.44 | 79'017.21 | 11'934.18 |
| Totale | | | | | 17'471.68 | 342'468.92 | 69'406.16 |

$$\sum_{i=1}^{12} (x_i - \bar{x})^2 = 17'471.68$$

$$\sum_{i=1}^{12} (y_i - \bar{y})^2 = 342'468.92$$

$$\bar{x} = 279.2$$

$$\bar{y} = 542.9$$

$$\sum_{i=1}^{12} (x_i - \bar{x})(y_i - \bar{y}) = 69'406.16$$

$$r_{XY} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{69'406.16}{\sqrt{17'471.68 \times 342'468.92}} = 0.897$$

Grafici a dispersione e diversi valori di r

