



# Statistica per le scienze sociali

Seconda edizione

Enrica Amaturò, Biagio Aragona, Maria Gabriella Grassia,  
Carlo Natale Lauro, Marina Marino



# 5

## Analisi delle relazioni tra due caratteri

Rappresentazione congiunta di una coppia di fenomeni statistici: Distribuzioni doppie di frequenze

Analisi delle relazioni tra due caratteri

Misure di dipendenza

Le relazioni fra variabili quantitative

Le relazioni lineari

Capitolo a cura di  
M.G. Grassia, C.N. Lauro, M. Marino



# Statistica per le scienze sociali

Seconda edizione

Enrica Amatore, Biagio Aragona, Maria Gabriella Grassia,  
Carlo Natale Lauro, Marina Marino



# 5

## Analisi delle relazioni tra due caratteri

Rappresentazione congiunta di una coppia di fenomeni statistici: Distribuzioni doppie di frequenze

Analisi delle relazioni tra due caratteri

Misure di dipendenza

Le relazioni fra variabili quantitative

Le relazioni lineari

Capitolo a cura di  
M.G. Grassia, C.N. Lauro, M. Marino

# Analisi delle relazioni

---

Quale indice misura la relazione  
tra due variabili osservate?



Che tipo di variabili?

Che tipo di relazione supporre?

# Analisi delle relazioni

---

Che tipo di variabili?

$X$  e  $Y$  variabili qualitative

$X$  variabile qualitativa e  $Y$  variabile quantitativa

$X$  e  $Y$  variabili quantitative

# Analisi delle relazioni

Che tipo di relazione supporre ?

La scelta dell'indice di associazione dipende dal **tipo di relazione logica supponibile** tra i due caratteri osservati

*Analisi della dipendenza e analisi dell'interdipendenza*

*Y dipende da X*  
 $X \longrightarrow Y$   
antecedente logico      conseguente logico

*oppure*  
 $Y \longrightarrow X$   
antecedente logico      conseguente logico

*Legame unidirezionale*  
**Analisi della dipendenza**

*Y dipende da X*  
 $X \longleftrightarrow Y$   
*X dipende da Y*

*Legame bidirezionale*  
**Analisi dell' interdipendenza**

# Analisi delle relazioni

Quale indice misura la relazione tra due variabili osservate?

Che tipo di relazione supporre?

Che tipo di variabili?

	2 mutabili	1 variabile 1 mutabile	2 variabili
Approccio simmetrico (interdipendenza)			
Approccio asimmetrico (dipendenza)			

# Analisi delle relazioni

Quale indice misura la relazione tra due variabili osservate?

Che tipo di relazione supporre?

Che tipo di variabili?

	2 mutabili	1 variabile 1 mutabile	2 variabili
Approccio simmetrico (interdipendenza)	$\chi^2, \Phi^2, V$	$\chi^2, \Phi^2, V$	$\rho$
Approccio asimmetrico (dipendenza)	$\lambda$	$\eta^2$	Modello di Regressione

# Analisi delle relazioni

Quale indice misura la relazione tra due variabili osservate?

Che tipo di relazione supporre?

Che tipo di variabili?

	2 mutabili	1 variabile 1 mutabile	2 variabili
Approccio simmetrico (interdipendenza)	$\chi^2, \Phi^2, V$	$\chi^2, \Phi^2, V$	
Approccio asimmetrico (dipendenza)			

# Analisi delle relazioni

---

**Indipendenza statistica** = *la conoscenza della modalità di uno dei due caratteri non migliora la "previsione" della modalità dell'altro*



Se  $X$  è indipendente da  $Y$  allora anche  $Y$  è indipendente da  $X$

# Associazione tra variabili

**Indipendenza statistica** = *la conoscenza della modalità di uno dei due caratteri non migliora la “previsione” della modalità dell’altro*



Indipendenza in distribuzione

Tutti i profili riga identici e uguali alla distribuzione marginale di colonna

Tutti i profili colonna identici e uguali alla distribuzione marginale di riga

# Associazione tra variabili

## Indipendenza in distribuzione

Tutti i **profili riga** identici e uguali alla distribuzione marginale di colonna

		Gruppo di corsi di laurea			
		gruppo medico	gruppo economico	gruppo letterario	Totale (%)
Occupati stabilmente	(% riga)	35.25	22.90	41.85	100
	(% riga)	35.25	22.90	41.85	100
Occupati precariamente	(% riga)	35.25	22.90	41.85	100
	(% riga)	35.25	22.90	41.85	100
Non lavorano	(% riga)	35.25	22.90	41.85	100
	(% riga)	35.25	22.90	41.85	100
Totale (%)		35.25	22.90	41.85	100

$$\frac{n_{ij}}{n_{i.}} * 100 = \frac{n_{.j}}{N} * 100 \implies \frac{n_{ij}}{n_{i.}} = \frac{n_{.j}}{N} \implies n_{ij} = \frac{n_{i.} \cdot n_{.j}}{N}$$

# Associazione tra variabili

## Indipendenza in distribuzione

Tutti i **profili colonna** identici e uguali alla distribuzione marginale di riga

Condizione occupazionale		Gruppo di corsi di laurea			
		gruppo medico	gruppo economico	gruppo letterario	Totale (%)
Occupati stabilmente	(% colonna)	60.80	60.80	60.80	60.80
Occupati precariamente	(% colonna)	31.29	31.29	31.29	31.29
Non lavorano	(% colonna)	7.90	7.90	7.90	7.90
	Totale (%)	100	100	100	100

$$\frac{n_{ij}}{n_{.j}} * 100 = \frac{n_{i.}}{N} * 100 \implies \frac{n_{ij}}{n_{.j}} = \frac{n_{i.}}{N} \implies n_{ij} = \frac{n_{i.} \cdot n_{.j}}{N}$$

# Associazione tra variabili

Indipendenza – dipendenza statistica

(assoluta o in distribuzione)

1. Due caratteri sono **indipendenti** se la generica frequenza congiunta è uguale a:

$$n_{ij}^* = \frac{n_{i.} \cdot n_{.j}}{n}$$

2. C'è **Dipendenza perfetta** di Y da X se ad ogni modalità di X è associata una sola modalità di Y
3. C'è **Interdipendenza perfetta** tra X e Y se ad ogni modalità di X corrisponde una sola modalità di Y e viceversa

# Associazione tra variabili

Indipendenza – dipendenza statistica  
(assoluta o in distribuzione)

Due caratteri sono **indipendenti** se la generica frequenza congiunta è uguale a:

$$n_{ij}^* = \frac{n_{i.} \cdot n_{.j}}{n}$$

## Indipendenza

		Y			Totale
		y <sub>1</sub>	y <sub>2</sub>	y <sub>3</sub>	
X	x <sub>1</sub>	1	4	5	<b>10</b>
	x <sub>2</sub>	2	8	10	<b>20</b>
	x <sub>3</sub>	2	8	10	<b>20</b>
	x <sub>4</sub>	1	4	5	<b>10</b>
	Totale	<b>6</b>	<b>24</b>	<b>30</b>	<b>60</b>

# Associazione tra variabili

Indipendenza – dipendenza statistica

(assoluta o in distribuzione)

C'è **Dipendenza perfetta** di Y da X se ad ogni modalità di X è associata una sola modalità di Y

**Y dipende perfettamente da X**

		Y			Totale
		$y_1$	$y_2$	$y_3$	
X	$x_1$	43	0	0	43
	$x_2$	0	0	15	15
	$x_3$	0	0	20	20
	$x_4$	0	52	0	52
	Totale	43	52	35	130

# Associazione tra variabili

Indipendenza – dipendenza statistica

(assoluta o in distribuzione)

C'è **Interdipendenza perfetta** tra X e Y se ad ogni modalità di X corrisponde una sola modalità di Y e viceversa

## Interdipendenza perfetta

		Y			Totale
		$y_1$	$y_2$	$y_3$	
X	$x_1$	43	0	0	43
	$x_2$	0	0	15	15
	$x_3$	0	52	0	52
Totale		43	52	15	110

# Associazione tra variabili

## Indipendenza – dipendenza statistica

(assoluta o in distribuzione)

In condizioni di **indipendenza assoluta** le distribuzioni condizionate di un carattere non mutano al variare delle modalità dell'altro carattere e, quindi, le frequenze teoriche sono uguali alle frequenze osservate.

Se tale uguaglianza non è soddisfatta per tutti i valori di  $i$  e  $j$  si dice che i due caratteri sono connessi.

La connessione risulta tanto più marcata quanto maggiori sono le differenze tra le frequenze osservate e le frequenze teoriche

$$C_{ij} = n_{ij} - n_{ij}^*$$

Se la connessione è positiva

$$n_{ij} > n_{ij}^*$$

Se la connessione è negativa

$$n_{ij} < n_{ij}^*$$

# Associazione tra variabili

## Indice del Chi quadrato

Indipendenza – dipendenza statistica  
(assoluta o in distribuzione)

- Si considera una tabella a doppia entrata
- Si calcolano le **contingenze**  $c_{ij} = n_{ij} - n_{ij}^*$
- Si calcolano i quadrati delle contingenze e si rapportano alla rispettiva frequenza teorica

$$\frac{c_{ij}^2}{n_{ij}^*} = \frac{(n_{ij} - n_{ij}^*)^2}{n_{ij}^*}$$

- Si sommano le contingenze al quadrato rapportate alle frequenze teoriche

$$\chi^2 = \sum_{i=1}^h \sum_{j=1}^k \frac{c_{ij}^2}{n_{ij}^*} \geq 0$$

# Associazione tra variabili

## Proprietà dell'Indice del Chi quadrato

Indipendenza – dipendenza statistica

(assoluta o in distribuzione)

- ✿ L'indice  $\chi^2$  ha un limite inferiore che è pari a 0 (caso di indipendenza). Non ammette un limite superiore e pertanto non è possibile quantificare la dipendenza
- ✿ L'indice  $\chi^2$  è un **indice simmetrico** nel senso che misura contemporaneamente la dipendenza tra  $X, Y$
- ✿ **Può essere calcolato per tutti i tipi di tabella, contingenza, correlazione, mista (per variabili di qualsiasi natura). E' l'unico indice calcolabile con variabili entrambe qualitative**

# Associazione tra variabili

## Indice del Chi quadrato

Indipendenza – dipendenza statistica

(assoluta o in distribuzione)

Tuttavia, l'indice  $\chi^2$  dipende fortemente dalla numerosità del collettivo, per cui tende ad assumere valori tanto più grandi quanto maggiore è la numerosità del collettivo.



### L'indice del Chi-quadrato

- ✓ È uguale o maggiore di 0
- ✓ Cresce al crescere di N
- ✓ Cresce al crescere delle modalità

# Associazione tra variabili

## Indice relativo (V di Cramer)

Indipendenza – dipendenza statistica  
(assoluta o in distribuzione)

Indice di **contingenza quadratica**:

$$\Phi^2 = \chi^2 / N$$

Indice **V di Cramer**:

$$V = \sqrt{\frac{\Phi^2}{\min[(h - 1), (k - 1)]}}$$

- Varia tra 0 e 1
- Vale 0 nel caso di indipendenza.
- Vale 1 se:
  - i due caratteri sono perfettamente associati e il numero di righe della tabella è uguale al numero di colonne ( $k = h$ );
  - $X$  dipende perfettamente da  $Y$  ed il numero di righe della tabella è maggiore del numero di colonne ( $k > h$ );
  - $Y$  dipende perfettamente da  $X$  ed il numero di righe della tabella è minore del numero di colonne ( $k < h$ ).

# Associazione tra variabili

## Esempio

La seguente tabella riporta la distribuzione degli occupati per settori di attività economica e per posizione professionale.

<b>Settori</b>	<b>Posizione Professionale</b>	
	Dipendenti	Autonomi
Agricoltura	485	776
Industria	4147	956
Altre attività	4941	2546

Si vuole calcolare il grado di associazione tra i due caratteri mediante un indice appropriato.

# Associazione tra variabili

## Esempio

La seguente tabella riporta la distribuzione degli occupati per settori di attività economica e per posizione professionale.

Settori	Posizione Professionale	
	Dipendenti	Autonomi
Agricoltura	485	776
Industria	4147	956
Altre attività	4941	2546

Si vuole calcolare il grado di associazione tra i due caratteri mediante un indice appropriato.

Settore è una variabile  
qualitativa sconnessa

Posizione professionale è una variabile  
qualitativa sconnessa

Test del chi-quadro  $\chi^2$

# Associazione tra variabili

## Esempio

$n_{ij}$

Settori	Posizione Professionale		Totale
	Dipendenti	Autonomi	
Agricoltura	485	776	1261
Industria	4147	956	5103
Altre attività	4941	2546	7487
Totale	9573	4278	13851

$n_{ij}^*$

Settori	Posizione Professionale		Totale
	Dipendenti	Autonomi	
Agricoltura			1261
Industria			5103
Altre attività			7487
Totale	9573	4278	13851

$$n_{ij}^* = \frac{n_{i.} \cdot n_{.j}}{n}$$

# Associazione tra variabili

## Esempio

$n_{ij}$

Settori	Posizione Professionale		Totale
	Dipendenti	Autonomi	
Agricoltura	485	776	1261
Industria	4147	956	5103
Altre attività	4941	2546	7487
Totale	9573	4278	13851

$n_{ij}^*$

Settori	Posizione Professionale		Totale
	Dipendenti	Autonomi	
Agricoltura	871,5		1261
Industria			5103
Altre attività			7487
Totale	9573	4278	13851

$$n_{ij}^* = \frac{n_{i.} \cdot n_{.j}}{n}$$

# Associazione tra variabili

## Esempio

$n_{ij}$

Settori	Posizione Professionale		Totale
	Dipendenti	Autonomi	
Agricoltura	485	776	1261
Industria	4147	956	5103
Altre attività	4941	2546	7487
Totale	9573	4278	13851

$n_{ij}^*$

Settori	Posizione Professionale		Totale
	Dipendenti	Autonomi	
Agricoltura	871,5	389,5	1261
Industria	3527	1576	5103
Altre attività	5174,5	2312,5	7487
Totale	9573	4278	13851

$$n_{ij}^* = \frac{n_{i.} \cdot n_{.j}}{n}$$

← Valori in caso di indipendenza

# Associazione tra variabili

## Esempio

$n_{ij}$	$n_{ij}^*$	$c_{ij} = n_{ij} - n_{ij}^*$	$c_{ij} = (n_{ij} - n_{ij}^*)^2$	$c_{ij} = (n_{ij} - n_{ij}^*)^2 / n_{ij}^*$
485	871,5			
4147	3527			
4941	5174,5			
776	389,5			
956	1576			
2546	2312,5			
<b>Totale</b>				

# Associazione tra variabili

## Esempio

$n_{ij}$	$n_{ij}^*$	$c_{ij} = n_{ij} - n_{ij}^*$	$c_{ij} = (n_{ij} - n_{ij}^*)^2$	$c_{ij} = (n_{ij} - n_{ij}^*)^2 / n_{ij}^*$
485	871,5	-386,5		
4147	3527	620		
4941	5174,5	-233,5		
776	389,5	386,5		
956	1576	-620		
2546	2312,5	233,5		
<b>Totale</b>				

# Associazione tra variabili

## Esempio

$n_{ij}$	$n_{ij}^*$	$c_{ij} = n_{ij} - n_{ij}^*$	$c_{ij} = (n_{ij} - n_{ij}^*)^2$	$c_{ij} = (n_{ij} - n_{ij}^*)^2 / n_{ij}^*$
485	871,5	-386,5	149382,25	
4147	3527	620	384400	
4941	5174,5	-233,5	54522,25	
776	389,5	386,5	149382,25	
956	1576	-620	384400	
2546	2312,5	233,5	54522,25	
<b>Totale</b>				

# Associazione tra variabili

## Esempio

$n_{ij}$	$n_{ij}^*$	$c_{ij} = n_{ij} - n_{ij}^*$	$c_{ij} = (n_{ij} - n_{ij}^*)^2$	$c_{ij} = (n_{ij} - n_{ij}^*)^2 / n_{ij}^*$
485	871,5	-386,5	149382,25	171,4
4147	3527	620	384400	109
4941	5174,5	-233,5	54522,25	10,54
776	389,5	386,5	149382,25	383,5
956	1576	-620	384400	243,9
2546	2312,5	233,5	54522,25	23,6
<b>Totale</b>				<b>941,94</b>

$$\chi^2 = \sum_{i=1}^h \sum_{j=1}^k \frac{c_{ij}^2}{n_{ij}^*} \geq 0 \quad \chi^2 = 941,94$$

# Associazione tra variabili

## Esempio

$$\chi^2 = 941,94$$



$\chi^2 > 0$   
↓  
associazione  
tra le due variabili



Ma quanto è  
forte questa  
associazione?



$$V = \sqrt{\frac{\chi^2}{n [\min(H - 1), (K - 1)]}}$$

$$V = \sqrt{\frac{941,94}{13.851}} = 0,26$$



Dall'analisi della V di Cramér emerge che i due caratteri non sono completamente indipendenti, ma esiste una debole associazione.

# Associazione tra variabili

## Proviamo insieme

Si vuole calcolare il livello di associazione esistente tra scelta del *mezzo di trasporto* e *condizioni meteorologiche* della giornata.

		mezzo di trasporto			
		bicicletta	autobus	automobile	Totale
condizioni metereologiche	sereno	84	26	11	<b>121</b>
	variabile	29	98	29	<b>156</b>
	pioggia	7	26	55	<b>88</b>
	Totale	<b>120</b>	<b>150</b>	<b>95</b>	<b>365</b>

# Associazione tra variabili

## Proviamo insieme

Si vuole calcolare il livello di associazione esistente tra scelta del *mezzo di trasporto* e *condizioni meteorologiche* della giornata.

		mezzo di trasporto			
		bicicletta	autobus	automobile	Totale
condizioni meteorologiche	sereno	84	26	11	<b>121</b>
	variabile	29	98	29	<b>156</b>
	pioggia	7	26	55	<b>88</b>
	Totale	<b>120</b>	<b>150</b>	<b>95</b>	<b>365</b>

$$\chi^2 = 169,18$$

$$\Phi^2 = 169,18/365 = 0,4635$$

$$V = \sqrt{\frac{0,4635}{\min(3 - 1; 3 - 1)}} = 0,481$$

Tra i due caratteri sussiste un livello medio di associazione



# Statistica per le scienze sociali

Seconda edizione

Enrica Amaturò, Biagio Aragona, Maria Gabriella Grassia,  
Carlo Natale Lauro, Marina Marino

**UTET**  
UNIVERSITÀ  
TECNOLOGIA