


Lezione 8

Relazioni Statistiche





Struttura Generale

Distribuzioni doppie

c modalità del carattere Y

X / Y	y_1	y_2	y_j	y_c	Totale
x_1	n_{11}	n_{12}	n_{1j}	n_{1c}	$n_{1\circ}$
x_2	n_{21}	n_{22}	n_{2j}	n_{2c}	$n_{2\circ}$
\vdots	\vdots
x_i	n_{i1}	n_{i2}	n_{ij}	n_{ic}	$n_{i\circ}$
\vdots	\vdots
x_r	n_{r1}	n_{r2}	n_{rj}	n_{rc}	$n_{r\circ}$
Totale	$n_{\circ 1}$	$n_{\circ 2}$	$n_{\circ j}$	$n_{\circ c}$	N

↑ *r* modalità del carattere X ↑ *c* modalità del carattere Y
↑ Numero totale di unità statistiche ↑ Frequenza congiunta (assoluta) con cui si osserva la modalità i-ima di X congiuntamente alla modalità j-ima di Y, ossia la coppia (x_i, y_j) è osservata n_{ij} volte!!



Tabelle a doppia entrata

Dopo il disastro, una commissione d'inchiesta del *British Board of Trade* ha compilato una lista di tutti i 1316 passeggeri del Titanic con alcune informazioni aggiuntive riguardanti: l'esito (salvato, non salvato), la classe (I, II, III) in cui viaggiavano, il sesso, l'eta, . . .

Passeggero	Classe	Esito
nome 1	II	salvato
nome 2	III	non salvato
nome 3	I	non salvato
:	:	:
nome 1316	III	salvato

Distribuzioni marginali

c modalità del carattere Y

X / Y	y_1	y_2	y_j	y_c	Totale
x_1	n_{11}	n_{12}	n_{1j}	n_{1c}	$n_{1\circ}$
x_2	n_{21}	n_{22}	n_{2j}	n_{2c}	$n_{2\circ}$
\vdots
x_i	n_{i1}	n_{i2}	n_{ij}	n_{ic}	$n_{i\circ}$
\vdots
x_r	n_{r1}	n_{r2}	n_{rj}	n_{rc}	$n_{r\circ}$
Totale	$n_{\circ 1}$	$n_{\circ 2}$	$n_{\circ j}$	$n_{\circ c}$	N

r modalità del carattere X

Distribuzione marginale di X, ossia numero di volte che si osservano le modalità di X Indipendentemente dal valore di Y.

Distribuzione marginale di Y, ossia numero di volte che si osservano le modalità di Y Indipendentemente dal valore di X.

- Quindi avremo:

$$n_{i \cdot} = \sum_{j=1}^c n_{ij}$$

Frequenze marginali di X

$$n_{\cdot j} = \sum_{i=1}^r n_{ij}$$

Frequenze marginali di Y

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

La numerosità del colletivo è data dalla somma di tutte le frequenze congiunte, o di tutte le frequenze marginali.



Indici di Connessione

Un **operatore statistico bivariato** è una procedura di calcolo che considera due variabili e sintetizza l'informazione sulla loro distribuzione congiunta in uno scalare.

Gli operatori di connessione producono uno scalare sempre positivo; assumono valore zero in assenza di connessione e maggiore di zero in presenza di connessione tra le due variabili.



La natura della relazione deve essere ipotizzata dal ricercatore

Quello che dobbiamo notare è che la natura della relazione causale tra due o più variabili discende da un ragionamento che si pone a livello teorico e non a livello empirico: un operatore statistico di per sé non informa sulla natura logica di una relazione causale tra le variabili empiriche.



L'indice Chi-quadrato

Il più importante operatore di connessione che rappresenta l'intensità della relazione tra due variabili categoriali è chiamato “chi quadrato” (χ^2).

Per costruire un operatore di connessione tra le due variabili prendiamo come modello di riferimento *l'assenza di relazione* e calcoliamo quanto le frequenze osservate si discostano dalle frequenze teoriche calcolate sulla base dell'ipotesi di completa indipendenza.



L'indice Chi-quadrato

Più le frequenze empiriche si allontanano dalle frequenze teoriche più è elevato il grado di connessione tra le variabili.

L'operatore **chi quadrato** si basa proprio sulla differenza tra frequenze empiriche e teoriche.
Più le precisamente, l'operatore chi quadrato si calcola come:

$$X^2 = \sum_{i=1}^I \sum_{j=1}^J \frac{(n_{ij} - \hat{n}_{ij})^2}{\hat{n}_{ij}}$$



Frequenze Teoriche

Le frequenze teoriche (\hat{n}_{ij}) sono riportate tra parentesi e sono calcolate come:

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



Campo di variazione

- L'operatore chi quadrato assume come valore minimo zero e come valore massimo il minore dei seguenti due valori: $N(I - 1)$ e $N(J - 1)$.
- Il valore massimo dipende dunque dall'ampiezza del collettivo e dal numero di righe e colonne della tabella.




Misure basate sul chi quadrato

Una misura di connessione basata sul chi quadrato e indipendente dal numero dei casi è stata proposta da Pearson e si calcola come:

$$\Phi^2 = \frac{X^2}{N}$$

Questa misura di connessione viene chiamata phi quadrato, assume come valore minimo 0. Il suo valore massimo è funzione del numero di modalità delle variabili:

- $\min (I - 1; J - 1)$



Misure basate sul chi quadrato

Un'altra misura di connessione è data dal T di Tschuprov:

$$T = \frac{\Phi^2}{\sqrt{(J-1)(I-1)}}$$

Il T di Tschuprov assume il valore di 1 (con tabelle quadrate) nel caso di dipendenza reciproca perfetta.



Misure basate sul chi quadrato

Un ultimo operatore basato sulla relativizzazione del chi quadrato è il V di Cramer:

$$V = \frac{\chi^2}{N \times \min[(J-1);(I-1)]}$$

Assume sempre valori compresi tra 0 e 1.



Dipendenza in media

		Medie parziali				
		10	20	30	40	
XY	A	7	11	6	3	27
	B	8	11	15	18	52
		15	22	21	21	79

E' possibile determinare la media totale e le medie parziali

$$\bar{y}_i = \sum \frac{y_j n_{ij}}{n_{i*}}$$

$$\bar{y} = \frac{\sum_j y_j n_{*j}}{n}$$

		Medie parziali				
		10	20	30	40	
X/Y	A	7	11	6	3	27
	B	8	11	15	18	52
		15	22	21	21	79

E' possibile determinare la media totale e le medie parziali

$$\bar{y}_A = \frac{(10 \times 7) + (20 \times 11) + (30 \times 6) + (40 \times 3)}{27} = 21.85$$

$$\bar{y}_B = \frac{(10 \times 8) + (20 \times 11) + (30 \times 15) + (40 \times 18)}{52} = 28.26$$

$$\bar{y} = \frac{(10 \times 15) + (20 \times 22) + (30 \times 21) + (40 \times 21)}{79} = 26.07$$

Medie parziali

Si può notare che...

$$\bar{y} = \frac{(\bar{y}_1 \times n_{1*}) + (\bar{y}_2 \times n_{2*})}{n} =$$
$$= \frac{(21.85 \times 27) + (28.26 \times 52)}{79} = 26.07$$

Esempio

X/Y	1	2	3	
M	8	3	3	14
F	5	3	0	8
	13	6	3	22

Y=numero universitari in famiglia
X= genere

Calcoliamo la media totale e le medie parziali

$$\bar{y} = \frac{13 + 12 + 9}{22} = 1.54$$

$$\bar{y}_M = \frac{8 + 6 + 9}{14} = 1.65 \quad \bar{y}_F = \frac{5 + 6 + 0}{8} = 1.375$$

Devianza e sua scomposizione

$$\begin{aligned}
 Dev(Y) &= \sum_i \sum_j (y_j - \bar{y})^2 n_{ij} = \\
 &= \sum_i \sum_j (y_j - \bar{y}_i + \bar{y}_i - \bar{y})^2 n_{ij} = \\
 &= \sum_i \sum_j (y_j - \bar{y}_i)^2 n_{ij} + \sum_i \sum_j (\bar{y}_i - \bar{y})^2 n_{ij} + \\
 &\quad + 2 \sum_i \sum_j (y_j - \bar{y}_i)(\bar{y}_j - \bar{y}_i) n_{ij} = \\
 &\quad \xrightarrow{\text{0}}
 \end{aligned}$$

Devianza e sua scomposizione

$$\begin{aligned} &= \sum_i \left[\sum_j (\gamma_j - \bar{\gamma}_i)^2 n_{ij} \right] + \\ &\quad + \sum_i (\bar{\gamma}_i - \bar{\gamma})^2 \sum_j n_{ij} = \\ &= \sum_i [Dev(Y | X = x_i)] + \sum_i (\bar{\gamma}_i - \bar{\gamma})^2 n_{i*} \Rightarrow \end{aligned}$$

$$Dev(Y) = Dev(W) + Dev(B)$$

Rapporto di correlazione

$$\eta_{y/x}^2 = \frac{Dev(B)}{Dev(Y)} = \frac{\sum_i (\bar{y}_i - \bar{y}) n_{i*}}{\sum_j (y_j - \bar{y}) n_{*j}}$$

$$\eta_{x/y}^2 = \frac{Dev(B)}{Dev(X)} = \frac{\sum_i (\bar{x}_j - \bar{x}) n_{*j}}{\sum_i (x_i - \bar{x}) n_{i*}}$$

$$\eta_{y/x}^2 \neq \eta_{x/y}^2$$

In generale

Il rapporto di
correlazione è un
indice NON
SIMMETRICO