

Università di Cassino
Corso di Statistica 1
Esercitazione del 19/11/2007
Dott. Alfonso Piscitelli

Esercizio 1

Un'indagine del 2005, sulle iscrizioni universitarie di due città, rileva i seguenti dati:

Città	Facoltà		
	Umanistica	Scientifica	Totale
Milano	250	170	420
Napoli	180	220	400
Totale	430	390	820

Si stabilisca se la scelta del tipo di facoltà è indipendente dal luogo di residenza e si commenti il risultato.

L'indice più opportuno per lo studio della relazione tra due mutabili è il χ^2 , in quanto si tratta di due variabili entrambe di natura qualitativa e quindi non possiamo studiare altro legame che la connessione.

$$\chi^2 = \sum_{i=1}^R \sum_{j=1}^C \frac{c_{ij}^2}{n_{ij}}$$

Dove R sono le righe e C le colonne della Tabella; n_{ij} la frequenza doppia;
 $n_{i.}$ la frequenza marginale di riga; $n_{.j}$ la frequenza marginale di
colonna;

$$c_{ij} = n_{ij} - n_{ij}^{\cdot} \quad \text{e} \quad n_{ij}^{\cdot} = \frac{(n_{i.} \cdot n_{.j})}{N}$$

Calcolo delle frequenze teoriche n_{ij}^{\cdot} :

Città	Facoltà		
	Umanistica	Umanistica	Totale
Milano	$(420 \cdot 430) / 820 = 220,24$	$(420 \cdot 390) / 820 = 199,76$	420
Napoli	$(400 \cdot 430) / 820 = 209,76$	$(400 \cdot 390) / 820 = 190,24$	400
Totale	430	390	820

Riportando le frequenze osservate e le frequenze teoriche in un'unica tabella si passa al calcolo del χ^2

	n_{ij}	n'_{ij}	$(n_{ij} - n'_{ij})^2 / n'_{ij}$
	250	220,24	4,02
	170	199,76	4,43
	180	209,76	4,22
	220	190,24	4,65
Totale (N)	820	820	

χ^2	17,32
----------	-------

L'indice χ^2 dipende dalla numerosità del collettivo, cosicché, a parità di associazione, il suo valore aumenta all'aumentare di N.

Generalmente si preferisce utilizzare degli indici "normalizzati" che diano misure non dipendenti dalla numerosità.

Perarson:

$$\Phi^2 = \frac{\chi^2}{N} = 0,021$$

In caso di indipendenza assume il suo valore minimo che è zero. Il valore massimo è pari a 1 solo quando il numero di righe o il numero di colonne è uguale a 2, altrimenti risulta maggiore di 1.

Cramer:

$$V = \frac{\Phi^2}{\min[(R-1), (C-1)]} = 0,021$$

Proprietà:

$$0 \leq V \leq 1$$

V=0 se vi è indipendenza assoluta o stocastica o in distribuzione tra i caratteri.

V=1 se vi è massima connessione tra i caratteri.

Esercizio 2

La tabella che segue riporta la durata in anni di 125 fotografie stampate su tre diversi supporti fotografici.

Supporti	Durata			Totale
	10 anni	12 anni	13 anni	
Supporto A	15	16	14	45
Supporto B	12	14	13	39
Supporto C	14	14	13	41
Totale	41	44	40	125

Si studi la relazione statistica tra il supporto e la durata della stampa.

L'indice più opportuno per lo studio della relazione tra una variabile qualitativa ed una quantitativa, dove la variabile quantitativa dipende da quella qualitativa, è

l'indice η^2 .

$$\eta^2 = \frac{Dev.(B)}{Dev.(T)}$$

Il rapporto è dato dalla *devianza tra i gruppi (Between)*, indicata con Dev.(B) sulla *devianza totale* indicata con Dev.(T).

Se la variabile quantitativa dipendente è posta in colonna valgono le seguenti formule:

$$Dev.(B) = \sum_{i=1}^R (\mu_{y|x_i} - \mu_y)^2 n_{i.} \quad Dev.(W) = \sum_{i=1}^R \left[\sum_{J=1}^C (y_j - \mu_{y|x_i})^2 n_{ij} \right]$$

$$Dev.(T) = \sum_{J=1}^C (y_j - \mu_y)^2 n_{.j}$$

Calcolo della media Generale:

$$\mu_y = \frac{1}{N} \sum_{j=1}^C y_j n_{.j}$$

y_j	$n_{.j}$	$(y_j * n_{.j})$
10	41	410
12	44	528
13	40	520
	125	1458

$$\mu_y = \frac{1458}{125} = 11,66$$

Calcolo delle medie parziali:

$$\mu_{y|x_i} = \sum_{j=1}^c \frac{y_j n_{ij}}{n_i}$$

nel nostro esercizio sono tre: la media del supporto A, la media del supporto B, la media del supporto C

y_j	n_{ij}	$(y_j * n_{ij})$
10	15	150
12	16	192
13	14	182
	45	524

y_j	n_{ij}	$(y_j * n_{ij})$
10	12	120
12	14	168
13	13	169
	39	457

y_j	n_{ij}	$(y_j * n_{ij})$
10	14	140
12	14	168
13	13	169
	41	477

$$\mu_{y|x_A} = \frac{524}{45} = 11,64$$

$$\mu_{y|x_B} = \frac{457}{39} = 11,72$$

$$\mu_{y|x_C} = \frac{477}{41} = 11,63$$

Calcolo della Devianza Totale:

y_j	n_j	$(y_j - \mu_y)^2 n_j$
10	41	112,98
12	44	5,09
13	40	71,82
Totale (n)	125	
Devianza Totale		189,89

Calcolo della Devianza Between:

μ_y	n_i	$(\mu_{y x_i} - \mu_y)^2 n_i$
11,64	45	0,018
11,72	39	0,140
11,63	41	0,037
Totale (n)	125	
Devianza Between		0,195

$$\eta^2 = \frac{0,195}{189,89} = 0,001$$

Si può affermare che vi è una indipendenza, in media, della durata dal tipo di supporto.

Anche se non è necessario ai fini dell'esercizio, possiamo effettuare un **controllo sui calcoli** delle devianze utilizzando il "Teorema di decomposizione della devianza"

$$\text{Dev. (T)} = \text{Dev. (B)} + \text{Dev. (W)}$$

Calcolo della Devianza Within:

	y_j	n_{ij}	$(y_j - \mu_{y x_i})^2 n_{ij}$
	10	15	40,34
	12	16	2,07
	13	14	25,89
$n_{i.}$		45	
Devianza Gruppo A			68,3

	y_j	n_{ij}	$(y_j - \mu_{y x_i})^2 n_{ij}$
	10	12	35,5
	12	14	1,1
	13	13	21,3
$n_{i.}$		39	
Devianza Gruppo B			57,9

	y_j	n_{ij}	$(y_j - \mu_{y x_i})^2 n_{ij}$
	10	14	37,2
	12	14	1,9
	13	13	24,4
$n_{i.}$		41	
Devianza Gruppo C			63,5

$$\text{Dev. (W)} = 68,3 + 57,9 + 63,5 = 189,7$$

$$\text{Dev. (T)} = \text{Dev. (B)} + \text{Dev. (W)} = 0,195 + 189,7 = 189,895$$