

Università di Cassino
Corso di Statistica 1
Esercitazione del 09/11/2006
Dott. Alfonso Piscitelli

Esercizio 1

Il seguente *data set* riporta la rilevazione di alcuni caratteri su un collettivo di 20 soggetti.

Soggetto	Sesso	Età	Reddito (Migliaia di €)	Titolo di studio	Nucleo familiare	Statura (cm)	Colore degli occhi
1	M	22	0,7	Diploma	3	173	NERO
2	F	18	0,2	Lic. Media	4	168	MARRONE
3	F	34	1,6	Diploma	2	165	MARRONE
4	M	42	2,5	Laurea	5	180	NERO
5	F	50	3,2	Diploma	3	163	AZZURRO
6	F	12	0,1	Lic. Elementare	4	160	NERO
7	M	46	3,8	Lic. Media	4	177	MARRONE
8	M	72	1,3	Nessun Titolo	2	164	VERDE
9	F	27	1,2	Laurea	3	158	AZZURRO
10	F	48	1,7	Lic. Media	5	170	NERO
11	F	35	1,9	Laurea	1	167	NERO
12	M	84	0,8	Nessun Titolo	1	159	MARRONE
13	F	21	0,4	Diploma	5	174	AZZURRO
14	F	44	1,8	Diploma	4	164	VERDE
15	M	56	1,9	Lic. Media	2	177	NERO
16	F	58	3,2	Lic. Media	3	172	NERO
17	F	37	2,1	Diploma	1	166	MARRONE
18	F	16	0,1	Lic. Media	4	160	MARRONE
19	M	73	1,6	Lic. Elementare	2	170	AZZURRO
20	M	64	2,2	Lic. Elementare	3	184	VERDE

- a) Data la distribuzione del carattere **Reddito** dei soli maschi, si analizzi la mutua variabilità e si calcoli il Rapporto di Concentrazione di Gini.
- b) Si calcoli l'indice di Eterogeneità di Gini per il carattere **Colore degli occhi**.
- c) Calcolare l'indice di Asimmetria di Fisher per il carattere **Età** suddiviso in 4 classi equiampie.

In modo da calcolare facilmente le differenze di tutte le possibili coppie

	0,7	0,8	1,3	1,6	1,9	2,2	2,5	3,8
0,7	0	0,1	0,6	0,9	1,2	1,5	1,8	3,1
0,8	0,1	0	0,5	0,8	1,1	1,4	1,7	3
1,3	0,6	0,5	0	0,3	0,6	0,9	1,2	2,5
1,6	0,9	0,8	0,3	0	0,3	0,6	0,9	2,2
1,9	1,2	1,1	0,6	0,3	0	0,3	0,6	1,9
2,2	1,5	1,4	0,9	0,6	0,3	0	0,3	1,6
2,5	1,8	1,7	1,2	0,9	0,6	0,3	0	1,3
3,8	3,1	3	2,5	2,2	1,9	1,6	1,3	0

Effettuando la somma degli elementi di ogni colonna (marginale di colonna) si ha:

	9,2	8,6	6,6	6	6	6,6	7,8	15,6
--	------------	------------	------------	----------	----------	------------	------------	-------------

Effettuando la somma dei marginali di colonna si ottiene il valore **66,4** che corrisponde al numeratore dell'indice Delta Δ .

Adesso disponiamo di tutti i dati per poter calcolare l'indice.

$$\Delta = \frac{\sum_{i \neq j=1}^n |x_i - x_j|}{n(n-1)} = \frac{66,4}{56} = 1,1857$$

Quando tutte le modalità coincidono, l'indice Delta assume valore zero ($\Delta = 0$).

L'indice Delta assume il valore massimo quando tutte le modalità tranne una sono nulle ($\Delta = 2\mu$).

Il **Rapporto di Concentrazione (R)** di Gini si ottiene dividendo Delta per il suo valore massimo.

$$R = \frac{\Delta}{2\mu}$$

Si tratta di un indice relativo che varia tra 0 ed 1. $0 \leq R \leq 1$

R=0 si ha concentrazione minima.

R=1 si ha concentrazione massima.

Nel nostro esercizio, la media del reddito dei Maschi sarà:

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i = \frac{14,8}{8} = 1,85$$

Quindi il massimo valore che può assumere Delta sarà:

$$2\mu = 3,7$$

Per cui il **Rapporto di Concentrazione (R)** di Gini sarà:

$$R = \frac{\Delta}{2\mu} = \frac{1,1857}{3,7} = 0,3204$$

b) Nel caso di variabili qualitative la variabilità del carattere è espressa in termini di **mutabilità**, definita come l'attitudine di un carattere ad assumere differenti modalità qualitative.

Quando tutte le unità statistiche assumono la stessa modalità, si ha una **perfetta omogeneità**. (minima eterogeneità)

Quando le modalità del carattere hanno tutte la stessa frequenza assoluta o relativa, si ha la **massima disomogeneità**.

L'Eterogeneità misura la variabilità delle frequenze delle k modalità del carattere.

L'**Indice di Eterogeneità (G)** di Gini si basa sulle frequenze relative.

$$G = 1 - \sum_{i=1}^k f_i^2$$

Si tratta di un indice relativo che varia tra $0 \leq G \leq 1 - \frac{1}{k}$

$G=0$ si ha la minima eterogeneità.

$G=1 - \frac{1}{k}$ si ha la massima eterogeneità.

La distribuzione di frequenza della variabile **Colore degli occhi** è:

Colore degli occhi	n_i	f_i
Nero	7	0,35
Marrone	6	0,3
Azzurro	4	0,2
Verde	3	0,15

Tot: 20 1

Colore degli occhi	f_i	$(f_i)^2$
Nero	0,35	0,1225
Marrone	0,3	0,09
Azzurro	0,2	0,04
Verde	0,15	0,0225

Tot: 1 0,275

Quindi **G** sarà:

$$G = 1 - \sum_{i=1}^k f_i^2 = 1 - 0,275 = 0,725$$

Volendo normalizzare G si divide il valore ottenuto per il suo massimo $1 - \frac{1}{k}$ ottenendo così G^*

$$G^* = \frac{G \cdot k}{k-1} = 0,9667$$

Si può dire che siamo molto vicini al caso di massima eterogeneità.

c) L'indice di Fisher, è un indice di forma basato sui momenti terzi standardizzati:

$$\gamma = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma} \right)^3 n_i$$

$\gamma > 0 \rightarrow$ *AsimmetricaPositiva*;
 $\gamma = 0 \rightarrow$ *Simmetrica*;
 $\gamma < 0 \rightarrow$ *AsimmetricaNegativa*;

Partendo dalla distribuzione in classi del carattere **Età**

Età	n_i	X_i^c
12- 30	6	21
30- 48	6	39
48- 66	5	57
66- 84	3	75

Tot: 20

si calcola prima la media aritmetica

$$\mu = \frac{1}{N} \sum_{i=1}^c x_i^c * n_i = 43,5$$

e poi lo scarto quadratico medio

$$\sigma = \sqrt[2]{\frac{1}{N} \sum_{i=1}^c (x_i^c - \mu)^2 * n_i} = \sqrt[2]{\sigma^2} = \sqrt{352,4} = 18,77$$

Fatto ciò, si hanno tutti gli elementi per calcolare l'indice di asimmetria di Fisher

Età	n_i	X_i^c	$(x_i^c - \mu)$	$Z_i = \frac{(x_i^c - \mu)}{\sigma}$	$Z_i = \left(\frac{(x_i^c - \mu)}{\sigma} \right)^3$	$(Z_i)^3 * n_i$
12- 30	6	21	-22,5	-1,19872	-1,72248	-10,3349
30- 48	6	39	-4,5	-0,23974	-0,01378	-0,08268
48- 66	5	57	13,5	0,719233	0,372056	1,860281
66- 84	3	75	31,5	1,67821	4,726491	14,17947

Tot: 20

5,622182

$$\gamma = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma} \right)^3 n_i = \frac{5,622182}{20} = 0,2811$$

Possiamo concludere che la distribuzione è caratterizzata da un'asimmetria positiva (indice maggiore di zero).

Tale risultato è confermato dal confronto tra la mediana e la media aritmetica.

$$\mu = 43,5 > M_e = 42$$