

Università di Cassino

Esercitazione di Statistica 1 del 6 novembre 2006

Dott.ssa Simona Balzano

Considerando il DATASET STUDENTI risolvere i seguenti quesiti:

- 1) L'altezza degli studenti iscritti al corso di laurea in fisica è uguale a 170 cm più il 5% dell'altezza degli iscritti in informatica. Sapendo che la varianza dell'altezza degli informatici è pari a 41,8, qual è la varianza dell'altezza dei fisici?
- 2) Calcolare per il carattere PESO lo scostamento semplice medio dalla media e lo scostamento semplice medio dalla mediana.
- 3) Per il carattere quantitativo ISCRITTI osservato nei 3 corsi di laurea ($n = 3$) misurare la mutua variabilità attraverso la differenza semplice media e quadratica.
- 4) Verificare la proprietà di scomponibilità della devianza per la distribuzione del carattere PESO rispetto al CORSO LAUREA.
- 5) Calcolare il grado di concentrazione del carattere ISCRITTI a partire dalla seguente distribuzione:

osservazione	x_i
B	540
I	2473
M	480
F	516
C	642

e costruire il diagramma di Lorenz.

Soluzione

1)

L'altezza dei fisici è legata a quella degli informatici dalla relazione lineare:

$$\text{ALTEZZA}_F = 170 + 0,05 \text{ ALTEZZA}_I$$

La varianza di una variabile $Y = a + bX$ può essere ottenuta a partire dalla varianza di X come:

$$\sigma_y^2 = b^2 \sigma_x^2$$

Quindi:

$$\begin{aligned} \sigma_F^2 &= b^2 \sigma_I^2 = \\ &= 0,05^2 \times 41,8 = 0,104 \end{aligned}$$

2)

$$S(\mu) = \frac{\sum_{i=1}^N |x_i - \mu|}{N}; \quad S(\text{Me}) = \frac{\sum_{i=1}^N |x_i - \text{Me}|}{N}$$

La media del carattere PESO è 64,05.
La mediana è 65.

A. Scostamento semplice medio dalla media

$$S(\mu) = \frac{|65 - 64,05| + |62 - 64,05| + \dots + |49 - 64,05|}{20} = \frac{200,9}{20} = \mathbf{10,045}$$

B. Scostamento semplice medio dalla mediana

$$S(\text{Me}) = \frac{|47 - 65| + |48 - 65| + \dots + |86 - 65|}{20} = \frac{199}{20} = \mathbf{9,95}$$

3)

Il carattere quantitativo ISCRITTI osservato rispetto alle 3 modalità del carattere qualitativo corso di laurea da origine alla seguente distribuzione semplice di $n = 3$ unità:

osservazione	x_i
B	1
I	7
M	12

la cui media aritmetica è data da:

$$\mu = \frac{\sum_{i=1}^3 x_i}{3} = \frac{1 + 12 + 7}{3} = 6,67$$

Per il calcolo della **differenza media semplice**:

$$D = \frac{\sum_{i=1}^n \sum_{j=1}^n |x_i - x_j|}{n(n-1)} = \frac{2 \sum_{i>j} |x_i - x_j|}{n(n-1)}$$

può essere di aiuto costruire la seguente tabella delle differenze in valore assoluto tra tutte le coppie (x_i, x_j) :

	1	7	12	
1	0	6	11	44
7	6	0	5	
12	11	5	0	

la cui somma è pari a 44 e da cui si ricava:

$$D = \frac{\sum_{i=1}^n \sum_{j=1}^n |x_i - x_j|}{n(n-1)} = \frac{44}{3(3-1)} = \frac{44}{6} = 7,33$$

$$\Delta_{MAX} = 2\mu = 2 \times 6,67 = 13,34$$

Differenza media semplice normalizzata $0 \leq R \leq 1$:

$$R = \frac{\Delta}{\Delta_{max}} = \frac{7,33}{13,34} = 0,55$$

Conclusione: R ha un valore intermedio tra 0 ed 1 → le osservazioni si differenziano l'una dall'altra ma non in misura molto elevata.

La differenza media quadratica è data da:

$$D = \frac{\sum_{i=1}^n \sum_{j=1}^n (x_i - x_j)^2}{n(n-1)} = \frac{2 \sum_{i>j} (x_i - x_j)^2}{n(n-1)}$$

La tabella dei quadrati delle differenze è:

	1	7	12
1	0	36	121
7	36	0	25
12	121	25	0

Quindi:

$$D = \frac{\sum_{i=1}^n \sum_{j=1}^n (x_i - x_j)^2}{n(n-1)} = \frac{364}{3(3-1)} = 60,67$$

4)

La verifica della proprietà della scomponibilità può essere effettuata indifferentemente rispetto alla devianza o alla varianza.

Di seguito sono riportati entrambi i procedimenti affiancati, per i quali si riportano in rosso i risultati relativi alla devianza ed in blu quelli relativi alla varianza.

Le modalità del carattere CORSO DI LAUREA definiscono 3 gruppi, di seguito riportati con i rispettivi valori del carattere PESO:

B	I	I	I	I	I	I	I	I	I	I	I	I	M	M	M	M	M	M	M
49	65	62	50	49	68	85	56	72	65	75	70	80	47	48	56	59	73	86	66

Calcolo di devianza e varianza totale indicate con **dev(X)** e σ_X^2 :

$$\mu = \frac{\sum_{i=1}^{20} x_i}{20} = 64,05$$

Devianza totale	Varianza totale
$\text{dev}(X) = \sum_{i=1}^{20} (x_i - \mu)^2 = \mathbf{2852,95}$	$\sigma_X^2 = \frac{\sum_{i=1}^{20} (x_i - \mu)^2}{20} = \frac{2852,95}{20} = \mathbf{142,6475}$

Calcolo delle medie dei gruppi:

$$\mu_{\text{BIO}} = 49$$

$$\mu_{\text{INF}} = \frac{\sum_{i=1}^{n_{\text{INF}}} x_{\text{INF}_i}}{n_{\text{INF}}} = \frac{797}{12} = 66,41667$$

$$\mu_{\text{MAT}} = \frac{\sum_{i=1}^{n_{\text{MAT}}} x_{\text{MAT}_i}}{n_{\text{MAT}}} = \frac{435}{7} = 62,14286$$

Calcolo di devianza e varianza tra i gruppi o esterna indicate con **dev_{EXT}** o **dev_B** (between) e σ_{EXT}^2 :

Devianza esterna	Varianza esterna
$\text{dev}_{\text{EXT}} = \sum_{i=1}^G (\mu_i - \mu)^2 n_i =$ $(49 - 64,05)^2 \times 1 +$ $+ (66,41 - 64,05)^2 \times 12 +$ $+ (62,143 - 64,05)^2 \times 7 = \mathbf{319,17619}$	$\sigma_{\text{EXT}}^2 = \frac{\sum_{i=1}^G (\mu_i - \mu)^2 n_i}{n} =$ $\frac{1}{20} \left[(49 - 64,05)^2 \times 1 + (66,41 - 64,05)^2 \times 12 + \right.$ $\left. + (62,143 - 64,05)^2 \times 7 \right] = \frac{319,17619}{20} = \mathbf{15,95881}$

Calcolo di devianza e varianza entro i gruppi o interna, indicate con **dev_{INT}** o **dev_w** (within) e σ_{INT}^2 :

Devianza interna	Varianza interna
$\text{dev}_{INT} = \sum_{i=1}^G \sum_{j=1}^{n_i} (x_{ij} - \mu_i)^2 =$ $= [(49 - 49)^2] +$ $+ [(65 - 66,41667)^2 + \dots + (80 - 66,41667)^2] +$ $+ [(47 - 62,14286)^2 + \dots + (66 - 62,14286)^2] =$ $= \mathbf{2533,77381}$	$\sigma_{INT}^2 = \frac{\sum_{i=1}^G \sum_{j=1}^{n_i} (x_{ij} - \mu_i)^2}{20} =$ $= \frac{1}{20} \{ [(49 - 49)^2] +$ $+ [(65 - 66,41667)^2 + \dots + (80 - 66,41667)^2] +$ $+ [(47 - 62,14286)^2 + \dots + (66 - 62,14286)^2] \} =$ $= \frac{2533,77381}{20} = \mathbf{126,68869}$

✓ La devianza interna può essere calcolata come **somma** delle devianze entro ciascun gruppo, ossia:

$$\text{dev}(\text{BIO}) = 0$$

$$\text{dev}(\text{INF}) = \sum_{i=1}^{12} (x_{INF_i} - \mu_{INF})^2 = 1354,917$$

$$\text{dev}(\text{MAT}) = \sum_{i=1}^7 (x_{MAT_i} - \mu_{MAT})^2 = 1178,857$$

la cui somma è proprio **2533,77381**

✓ La varianza interna può essere calcolata come **media** delle devianze entro ciascun gruppo, ossia:

$$\sigma_{INT}^2 = \frac{\sum_{i=1}^G \text{dev}_i}{n} = \frac{\text{dev}(\text{BIO}) + \text{dev}(\text{INF}) + \text{dev}(\text{MAT})}{20} = \mathbf{126,68869}$$

Verifica della proprietà della scomponibilità:

Per la devianza:

$$\text{dev}_{\text{EXT}} + \text{dev}_{\text{INT}} = \text{dev}(X)$$

$$319,17619 + 2533,77381 = 2852,95$$

Per la varianza:

$$\sigma_{\text{EXT}}^2 + \sigma_{\text{INT}}^2 = \sigma_X^2$$

$$15,95881 + 126,68869 = 142,64750$$

5)

Per il calcolo del rapporto di concentrazione di Gini sono necessarie le seguenti quantità:

osservazione	x_i	p_i	A_i	q_i	$p_i - q_i$
M	480	0,2	480	0,103	0,097
F	516	0,4	996	0,214	0,186
B	540	0,6	1536	0,330	0,270
C	642	0,8	2178	0,468	0,332
I	2473	-	4651		
	4651	2			0,884

Da cui si ricava:

$$R = \frac{\sum_{i=1}^{n-1} (p_i - q_i)}{\sum_{i=1}^{n-1} p_i} = \frac{0,884}{2} = \mathbf{0,44}$$

La rappresentazione grafica del rapporto di Gini è la curva di Lorentz, dove l'area compresa tra la spezzata di concentrazione e la retta di equidistribuzione è pari ad R

