

Indici di Dispersione

Si cercano indici di dispersione che:

- utilizzino tutti i dati $\{x_1, x_2, \dots, x_n\}$
- siano basati sulla nozione di **scarto** (distanza) dei dati
 - rispetto a un centro $d_i = |x_i - C|$
ad esempio, rispetto alla media aritmetica $d_i = |x_i - \bar{x}|$
 - rispetto a un dato $d_i = |x_i - x_j|$

con alcune proprietà generali:

- l'indice di dispersione non deve mai essere negativo
- assume il valore 0 se i dati sono tutti uguali
- non cambia se si aggiunge una costante ai dati

Varianza

Varianza: è la media aritmetica (*semplice o ponderata*) dei quadrati degli scarti.

- Dato l'insieme di valori $\{x_1, x_2, \dots, x_n\}$

$$\text{Var} = s^2 = \frac{1}{n} \cdot \sum_{i=1}^n (x_i - \bar{x})^2$$

- Dato l'insieme di valori $\{x_1, x_2, \dots, x_m\}$ con le rispettive frequenze assolute $\{f_1, f_2, \dots, f_m\}$

$$\text{Var} = s^2 = \frac{1}{n} \cdot \sum_{i=1}^m f_i \cdot (x_i - \bar{x})^2 \quad \text{dove } n = \sum_{i=1}^m f_i$$

Deviazione Standard

Deviazione standard (o scarto quadratico medio): è la radice quadrata della varianza.

$$s = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (x_i - \bar{x})^2} \quad \text{oppure} \quad s = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^m f_i \cdot (x_i - \bar{x})^2}$$

Consente di avere un indice di dispersione espresso nella stessa unità di misura dei dati.

Nota: applicando una trasformazione lineare ai dati

$$y_i = ax_i + b \quad \Rightarrow \quad s_y^2 = a^2 s_x^2, \quad s_y = |a| s_x$$

Statistiche Campionarie

Spesso gli *indici statistici* vengono applicati non all'intera *popolazione*, ma a un suo **campione**. Si cerca di stimare (**inferenza**) nel miglior modo possibile le caratteristiche dell'intera popolazione a partire dalle informazioni desunte da un **campione rappresentativo**.

In questo caso si utilizzano le seguenti formule modificate:



Varianza campionaria (*stimata*):

$$s^2 = \frac{1}{n-1} \cdot \sum_{i=1}^n (x_i - \bar{x})^2$$

Deviazione standard campionaria (*stimata*):

$$s = \sqrt{\frac{1}{n-1} \cdot \sum_{i=1}^n (x_i - \bar{x})^2}$$

Esempio Riassuntivo



Esempio Riassuntivo

Caso A

x_i	f_i	f_i/n
1	1	0.100
3	1	0.100
5	6	0.600
7	1	0.100
9	1	0.100
	10	1.000

media	5.00
mediana	5.00
varianza	4.00
varianza stimata	4.44
deviazione standard	2.00
deviazione standard stimata	2.11

Caso B

x_i	f_i	f_i/n
1	2	0.200
3	2	0.200
5	2	0.200
7	2	0.200
9	2	0.200
	10	1.000

media	5,00
mediana	5.00
varianza	8.00
varianza stimata	8.89
deviazione standard	2.83
deviazione standard stimata	2.98

Esercizi

Esercizio 1. Trovare media, mediana, moda, varianza e deviazione standard dei seguenti dati non ordinati e non raggruppati. Tracciare l'istogramma delle frequenze.

7 4 10 9 15 12 7 8 11 4 14 10 5 14 1 10 8 12 6 5

Esercizi

Soluzione: si costruisce la tabella della distribuzione di frequenza

x	1	4	5	6	7	8	9	10	11	12	14	15	
f_{ass}	1	2	2	1	2	2	1	3	1	2	2	1	20

$$\bar{x} = \frac{1}{20}(1 + 8 + 10 + 6 + 14 + 16 + 9 + 30 + 11 + 24 + 28 + 15) = 8.6$$

$$s^2 = \frac{1}{20}(57.76 + 42.32 + 25.92 + 6.76 + 5.12 + 0.72 + 0.16 + 5.88 + \\ + 5.76 + 23.12 + 58.33 + 40.96) \simeq 13.64$$

$$s \simeq 3.69$$

$$\text{moda} = 10.0$$

$$\text{mediana} = 8.5$$

Esercizi

Esercizio 2. Nel rilevare l'altezza in cm di un gruppo di reclute si è ottenuta la seguente tabella delle frequenze. Calcolare media, mediana e quartili.

Soluzione:

cm	f_{ass}	f_{cum}
166	1	1
168	3	4
169	6	10
170	11	21
171	8	29
172	6	35
173	4	39
174	3	42
175	1	43
178	1	44

$n = 44$ dimensione del campione

$\bar{x} \simeq 170.9$ media

$M_e = \frac{x_{22} + x_{23}}{2} = 171$ mediana

$q_1 = \frac{x_{11} + x_{12}}{2} = 170$ primo quartile

$q_3 = \frac{x_{33} + x_{34}}{2} = 172$ terzo quartile

$q_3 - q_1 = 2$ distanza interquartile

La distanza interquartile è un altro indice di dispersione, legato alla nozione di mediana. La mediana suddivide l'insieme dei dati ordinati $\{x_i\}$ in due parti ugualmente numerose. I quartili si ottengono suddividendo i dati ordinati in quattro parti ugualmente numerose.

Esercizi

Esercizio 3. Si consideri la seguente tabella relativa alle frequenze dei pesi in Kg di 100 individui adulti.

Peso p in Kg	f_{ass}
$50 \leq p < 55$	20
$55 \leq p < 60$	15
$60 \leq p < 65$	18
$65 \leq p < 70$	22
$70 \leq p < 75$	18
$75 \leq p < 80$	7

- le classi sono di uguale ampiezza
- supponiamo che i dati siano uniformemente distribuiti all'interno di ogni classe
- possiamo definire per ogni classe un rappresentante r_i (*class mark*)

Esercizi

Soluzione: calcoliamo la media e lo scarto quadratico medio utilizzando i valori dei rappresentanti.

Peso p in Kg	f_i	F_i	r_i
$50 \leq p < 55$	20	20	52.5
$55 \leq p < 60$	15	35	57.5
$60 \leq p < 65$	18	53	62.5
$65 \leq p < 70$	22	75	67.5
$70 \leq p < 75$	18	93	72.5
$75 \leq p < 80$	7	100	77.5

Calcoliamo il peso medio:

$$\bar{p} = \frac{1}{100} (20 \cdot 52.5 + 15 \cdot 57.5 + 18 \cdot 62.5 + 22 \cdot 67.5 + 18 \cdot 72.5 + 7 \cdot 77.5) = 63.7$$

Esercizi

Calcoliamo la varianza e lo scarto quadratico medio:

r_i	$r_i - \bar{p}$	$(r_i - \bar{p})^2$	f_i
52.5	-11.2	125.44	20
57.5	-6.2	38.44	15
62.5	-1.2	1.44	18
67.5	3.8	14.44	22
72.5	8.8	77.44	18
77.5	13.8	190.44	7

$$s^2 = \frac{1}{100}(20 \cdot 125.44 + 15 \cdot 38.44 + 18 \cdot 1.44 + 22 \cdot 14.44 + 18 \cdot 77.44 + 7 \cdot 190.44) \simeq 61.56 \text{ Kg}^2$$

$$s \simeq 7.85 \text{ Kg}$$

Media – Varianza – Deviazione Standard

\bar{x} media	$\frac{1}{n} \cdot \sum_{i=1}^n x_i$	$\frac{1}{n} \cdot \sum_{i=1}^m f_i x_i$
s^2 varianza	$\frac{1}{n} \cdot \sum_{i=1}^n (x_i - \bar{x})^2$	$\frac{1}{n} \cdot \sum_{i=1}^m f_i \cdot (x_i - \bar{x})^2$
s dev. standard	$\sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (x_i - \bar{x})^2}$	$\sqrt{\frac{1}{n} \cdot \sum_{i=1}^m f_i \cdot (x_i - \bar{x})^2}$
s^2 campionaria	$\frac{1}{n-1} \cdot \sum_{i=1}^n (x_i - \bar{x})^2$	$\frac{1}{n-1} \cdot \sum_{i=1}^m f_i \cdot (x_i - \bar{x})^2$
s campionaria	$\sqrt{\frac{1}{n-1} \cdot \sum_{i=1}^n (x_i - \bar{x})^2}$	$\sqrt{\frac{1}{n-1} \cdot \sum_{i=1}^m f_i \cdot (x_i - \bar{x})^2}$

Varianza – Deviazione Standard

Le espressioni della varianza (e della deviazione standard) possono essere riscritte come segue:

$$s^2 = \frac{1}{n} \cdot \left(\sum_{i=1}^n x_i^2 - n \bar{x}^2 \right) \quad \circ \quad s^2 = \frac{1}{n} \cdot \left(\sum_{i=1}^m f_i x_i^2 - n \bar{x}^2 \right)$$

Infatti,

$$\begin{aligned} \sum_{i=1}^n (x_i - \bar{x})^2 &= \sum_{i=1}^n (x_i^2 - 2x_i \bar{x} + \bar{x}^2) = \sum_{i=1}^n x_i^2 - 2\bar{x} \sum_{i=1}^n x_i + \sum_{i=1}^n \bar{x}^2 = \\ &= \sum_{i=1}^n x_i^2 - 2\bar{x}(n \bar{x}) + n \bar{x}^2 = \sum_{i=1}^n x_i^2 - n \bar{x}^2 \end{aligned}$$

Esercizio

Un'indagine su un campione di $n = 100$ studenti, che hanno sostenuto la prova scritta di matematica, ha prodotto il seguente risultato. Le votazioni in centesimi sono state raggruppate in quattro *classi*.

classe	f_i	f_i/n
20 – 40	10	0.10
40 – 60	20	0.20
60 – 80	50	0.50
80 – 100	20	0.20
	100	1.00

Le classi sono di uguale ampiezza e contigue.

Esercizio

Nell'ipotesi di *distribuzione uniforme*, è naturale associare a ciascuna classe, come *rappresentante*, il valore centrale r_i della classe stessa.


classe	r_i	f_i	F_i
20 – 40	30	10	10
40 – 60	50	20	30
60 – 80	70	50	80
80 – 100	90	20	100

$$\text{media} = \frac{1}{100} \cdot (10 \cdot 30 + 20 \cdot 50 + 50 \cdot 70 + 20 \cdot 90) = 66$$


$$\text{mediana} = 70 \quad (\text{guardando solo i rappresentanti})$$

$$\text{varianza} = \frac{1}{100} \cdot (10 \cdot 36^2 + 20 \cdot 16^2 + 50 \cdot 4^2 + 20 \cdot 24^2) = 21.44$$

Esercizio




Poligono delle frequenze



Ogiva di frequenza

Esercizio

Calcolo della mediana:




$$\text{area totale} = 20 \cdot (10 + 20 + 50 + 20) = 2000$$

Cerchiamo il valore $x = M_e$ tale che

$$20 \cdot 10 + 20 \cdot 20 + (x - 60) \cdot 50 = 1000 \quad \Rightarrow \quad x = 68 \quad \Rightarrow \quad M_e = 68$$

Esercizio



Calcolo della mediana: interpolazione lineare sui punti $A = (60, 30)$ e $B = (80, 80)$

$$\begin{cases} y = 50 \\ y - 30 = \frac{5}{2} \cdot (x - 60) \end{cases} \Rightarrow (50 - 30) = \frac{5}{2} \cdot (x - 60) \Rightarrow x = 68 \Rightarrow M_e = 68$$

Domande: (a) qual è il voto massimo preso dal primo 10% degli studenti (quelli che hanno preso il voto più basso)? [40]

(b) Calcolare i quartili dall'ogiva di frequenza. $[q_1 = 55, q_2 = 78]$

Esercizio

