

Elementi di statistica

Federico Bellisardi

Università di Bologna - FABIT

federico.bellisardi2@unibo.it

A.A. 2023 - 2024

Popolazione Statistica

Un insieme su cui viene effettuato lo studio di un fenomeno.

- ES. Insieme degli studenti di una classe.

Popolazione Statistica

Un insieme su cui viene effettuato lo studio di un fenomeno.

- ES. Insieme degli studenti di una classe.

Variabile Statistica

Una caratteristica assegnata a ogni elemento di una popolazione statistica data. Definiamo **variabile statistica** una rilevazione di una variabile sulla popolazione oppure su un campione, cioè un sottoinsieme della popolazione in cui è possibile stimare la caratteristica che si vuole rilevare.

Popolazione Statistica

Un insieme su cui viene effettuato lo studio di un fenomeno.

- ES. Insieme degli studenti di una classe.

Variabile Statistica

Una caratteristica assegnata a ogni elemento di una popolazione statistica data. Definiamo **variabile statistica** una rilevazione di una variabile sulla popolazione oppure su un campione, cioè un sottoinsieme della popolazione in cui è possibile stimare la caratteristica che si vuole rilevare.

Sia N il numero di elementi nel campione, una variabile statistica è identificata da

$$Y = (y_1, y_2, \dots, y_N) \quad (1)$$

- ES. I valori rilevati per l'altezza, il peso, i voti, il colore degli occhi.

Modalità e Frequenza assoluta

Sia $Y = (y_1, y_2, \dots, y_N)$ una variabile statistica discreta. Definiamo

- **modalità** i valori distinti tra (y_1, y_2, \dots, y_N) ;
- **frequenza assoluta** di una modalità il numero di volte che viene osservata nell'espressione della variabile statistica.

Frequenze Assolute e in Percentuale

Modalità e Frequenza assoluta

Sia $Y = (y_1, y_2, \dots, y_N)$ una variabile statistica discreta. Definiamo

- **modalità** i valori distinti tra (y_1, y_2, \dots, y_N) ;
- **frequenza assoluta** di una modalità il numero di volte che viene osservata nell'espressione della variabile statistica.

Frequenza Relativa e Frequenza in Percentuale

Sia $Y = (y_1, y_2, \dots, y_N)$ una variabile statistica discreta e f la frequenza assoluta della modalità z . Definiamo

- **frequenza relativa** della modalità z il rapporto f/N , dove N è il numero di elementi del campione;
- **frequenza percentuale** $f_{relativa} * 100$.

Esempio

Considerare la variabile statistica rappresentante il voto ad un esame di N studenti iscritti al primo anno di università:

$$Y = (18, 20, 26, 30, 30, 24, 25, 21, 24, 19, 24, 22, 22, 27, 30, 18, 24, 24, 28, 27)$$

- Qual è il numero di studenti del campione?

Esempio

Considerare la variabile statistica rappresentante il voto ad un esame di N studenti iscritti al primo anno di università:

$$Y = (18, 20, 26, 30, 30, 24, 25, 21, 24, 19, 24, 22, 22, 27, 30, 18, 24, 24, 28, 27)$$

- Qual è il numero di studenti del campione? **20**
- Esprimere in termini di modalità, frequenza assoluta, frequenza relativa e frequenza percentuale il campione.

Esempio

Considerare la variabile statistica rappresentante il voto ad un esame di N studenti iscritti al primo anno di università:

$$Y = (18, 20, 26, 30, 30, 24, 25, 21, 24, 19, 24, 22, 22, 27, 30, 18, 24, 24, 28, 27)$$

- Qual è il numero di studenti del campione? **20**
- Esprimere in termini di modalità, frequenza assoluta, frequenza relativa e frequenza percentuale il campione.

Modalità	18	20	26	30	24	...	25
Freq. Assoluta	2	1	1	3	5	...	1
Freq. Relativa	0.1	0.05	0.05	0.15	0.25	...	0.05
Freq. Percentuale	10	5	5	15	25	...	5

Esempio

Considerare la variabile statistica rappresentante il voto ad un esame di N studenti iscritti al primo anno di università:

$$Y = (18, 20, 26, 30, 30, 24, 25, 21, 24, 19, 24, 22, 22, 27, 30, 18, 24, 24, 28, 27)$$

- Qual è il numero di studenti del campione? **20**
- Esprimere in termini di modalità, frequenza assoluta, frequenza relativa e frequenza percentuale il campione.

Modalità	18	20	26	30	24	...	25
Freq. Assoluta	2	1	1	3	5	...	1
Freq. Relativa	0.1	0.05	0.05	0.15	0.25	...	0.05
Freq. Percentuale	10	5	5	15	25	...	5

E se avessimo un campione di 300 studenti?

Anziché rappresentare la variabile statistica attraverso i suoi 300 valori (cioè i voti conseguiti dagli studenti), utilizziamo una separazione in classi, dove arbitrariamente consideriamo intervalli di 2 punti.

Classi	[18,20)	[20,22)	[22,24)	[24,26)	[26,28)	[28, 30)
Freq. Assoluta	80	55	65	40	35	25
Freq. Relativa	0.27	0.18	0.22	0.13	0.12	0.08

Anziché rappresentare la variabile statistica attraverso i suoi 300 valori (cioè i voti conseguiti dagli studenti), utilizziamo una separazione in classi, dove arbitrariamente consideriamo intervalli di 2 punti.

Classi	[18,20)	[20,22)	[22,24)	[24,26)	[26,28)	[28, 30)
Freq. Assoluta	80	55	65	40	35	25
Freq. Relativa	0.27	0.18	0.22	0.13	0.12	0.08

Quanti studenti hanno ottenuto un voto inferiore a 24?

Anziché rappresentare la variabile statistica attraverso i suoi 300 valori (cioè i voti conseguiti dagli studenti), utilizziamo una separazione in classi, dove arbitrariamente consideriamo intervalli di 2 punti.

Classi	[18,20)	[20,22)	[22,24)	[24,26)	[26,28)	[28, 30)
Freq. Assoluta	80	55	65	40	35	25
Freq. Relativa	0.27	0.18	0.22	0.13	0.12	0.08

Quanti studenti hanno ottenuto un voto inferiore a 24?

$$\frac{(27 + 18 + 22)}{100} \times 300 \approx 200$$

Rappresentazione Grafica dei Dati

Consideriamo le diverse altezze degli studenti rilevate in centimetri:

Altezza	157	160	165	173	168	176	184
Freq.Ass	1	2	6	4	3	3	1

- Grafico a Bastoncini;

Rappresentazione Grafica dei Dati

Consideriamo le diverse altezze degli studenti rilevate in centimetri:

Altezza	157	160	165	173	168	176	184
Freq.Ass	1	2	6	4	3	3	1

- Grafico a Bastoncini;
- Grafico Poligonale;

Consideriamo le diverse altezze degli studenti rilevate in centimetri:

Altezza	157	160	165	173	168	176	184
Freq.Ass	1	2	6	4	3	3	1

- Grafico a Bastoncini;
- Grafico Poligonale;
- Aerogramma:

Se q_i sono le frequenze in percentuale, i settori circolari avranno ampiezza:

$$\frac{q_i}{100} \times 360^\circ$$

Rappresentazione Grafica dei Dati

Consideriamo le diverse altezze degli studenti rilevate in centimetri:

Altezza	157	160	165	173	168	176	184
Freq.Ass	1	2	6	4	3	3	1

- Grafico a Bastoncini;
- Grafico Poligonale;
- Aerogramma:

Se q_i sono le frequenze in percentuale, i settori circolari avranno ampiezza:

$$\frac{q_i}{100} \times 360^\circ$$

- Istogramma:
Classi modali con le rispettive frequenze.

Rappresentazione Grafica dei Dati

▶ Link

Grafico a Bastoncini







Grafico Poligonale



Aerogramma



Istogramma



Moda

Definiamo la moda di una variabile statistica come la modalità con frequenza più alta. Se le modalità sono raggruppate in classi, la classe modale è la classe con la frequenza più alta.

Moda

Definiamo la moda di una variabile statistica come la modalità con frequenza più alta. Se le modalità sono raggruppate in classi, la classe modale è la classe con la frequenza più alta.

Media Aritmetica

Sia $Y = (y_1, \dots, y_N)$ una variabile statistica. Definiamo media aritmetica la quantità:

$$\bar{y} = \frac{1}{N}(y_1 + \dots + y_N)$$

Moda

Definiamo la moda di una variabile statistica come la modalità con frequenza più alta. Se le modalità sono raggruppate in classi, la classe modale è la classe con la frequenza più alta.

Media Aritmetica

Sia $Y = (y_1, \dots, y_N)$ una variabile statistica. Definiamo media aritmetica la quantità:

$$\bar{y} = \frac{1}{N}(y_1 + \dots + y_N)$$

Media Geometrica

Sia $Y = (y_1, \dots, y_N)$ una variabile statistica. Definiamo media geometrica la quantità:

$$\bar{y}_{geom} = \sqrt[N]{y_1 \cdot y_2 \cdot \dots \cdot y_N}$$

Media Pesata

Data la variabile statistica $Y = (y_1, \dots, y_N)$, definiamo media pesata (o ponderata) di Y la quantità:

$$\bar{y}_\omega = \frac{\omega_1 y_1 + \omega_2 y_2 + \dots + \omega_N y_N}{\omega_1 + \omega_2 + \dots + \omega_N}$$

dove i valori ω_i , $i \in [1, N]$ sono detti *pesi*.

Media Pesata

Data la variabile statistica $Y = (y_1, \dots, y_N)$, definiamo media pesata (o ponderata) di Y la quantità:

$$\bar{y}_\omega = \frac{\omega_1 y_1 + \omega_2 y_2 + \dots + \omega_N y_N}{\omega_1 + \omega_2 + \dots + \omega_N}$$

dove i valori ω_i , $i \in [1, N]$ sono detti *pesi*.

Mediana

La mediana di una variabile statistica $Y = (y_1, \dots, y_N)$, ove i valori siano ordinati in modo crescente, cioè $y_1 \leq \dots \leq y_N$, è calcolata nel seguente modo:

- Se N è dispari, la mediana è pari al valore $y_{\frac{N+1}{2}}$;
- Se N è pari, la mediana è pari alla media aritmetica dei due valori $y_{\frac{N}{2}}$, $y_{\frac{N}{2}+1}$.

Esempio

Consideriamo il libretto accademico dello studente X che presenta 7 voti:

Voto	22	28	24	30	18	27	30
CFU	6	3	5	10	12	15	3

Calcolare la media aritmetica, la media geometrica e la media pesata.

Esempio

Consideriamo il libretto accademico dello studente X che presenta 7 voti:

Voto	22	28	24	30	18	27	30
CFU	6	3	5	10	12	15	3

Calcolare la media aritmetica, la media geometrica e la media pesata.
Si ha:

$$\bar{y} = \frac{1}{7}(22 + 28 + 24 + 30 + 18 + 27 + 30) = 25.6$$

$$\bar{y}_{geom} = \sqrt[7]{22 \cdot 28 \cdot 24 \cdot 30 \cdot 18 \cdot 27 \cdot 30} = 25.2$$

$$\begin{aligned}\bar{y}_w &= \frac{6 \times 22 + 3 \times 28 + 5 \times 24 + 10 \times 30 + 12 \times 18 + 15 \times 27 + 3 \times 30}{6 + 3 + 5 + 10 + 12 + 15 + 3} = \\ &= 24.9\end{aligned}$$

Varianza e Scarto Quadratico Medio

La *varianza* esprime la "variabilità" dei dati che abbiamo a disposizione.

Varianza e Scarto Quadratico Medio

La *varianza* esprime la "variabilità" dei dati che abbiamo a disposizione.

Varianza

Sia $Y = (y_1, \dots, y_N)$ una variabile statistica con media aritmetica \bar{y} . Si definisce **varianza** di Y la media degli scarti quadratici, cioè delle quantità $(y_i - \bar{y})^2$, con i compreso tra 1 e N .

$$\sigma^2 = \frac{1}{N} \left[(y_1 - \bar{y})^2 + \dots + (y_N - \bar{y})^2 \right]$$

Varianza e Scarto Quadratico Medio

La *varianza* esprime la "variabilità" dei dati che abbiamo a disposizione.

Varianza

Sia $Y = (y_1, \dots, y_N)$ una variabile statistica con media aritmetica \bar{y} . Si definisce **varianza** di Y la media degli scarti quadratici, cioè delle quantità $(y_i - \bar{y})^2$, con i compreso tra 1 e N .

$$\sigma^2 = \frac{1}{N} \left[(y_1 - \bar{y})^2 + \dots + (y_N - \bar{y})^2 \right]$$

Deviazione Standard

Definiamo **deviazione standard** o **scarto quadratico medio**, la radice quadrata della varianza.

$$\sigma = \frac{1}{\sqrt{N}} \sqrt{(y_1 - \bar{y})^2 + \dots + (y_N - \bar{y})^2}$$

NOTA: Dalla definizione della varianza si nota che più la varianza è piccola e più i dati sono concentrati "vicino" al valore medio.

NOTA: Dalla definizione della varianza si nota che più la varianza è piccola e più i dati sono concentrati "vicino" al valore medio.

Proposizione

La varianza di una variabile statistica è la differenza tra la media aritmetica dei quadrati delle modalità e il quadrato della media aritmetica delle modalità:

$$\sigma^2 = \bar{y}^2 - \bar{y}^2$$

Vedi Esempio

Quartile e Distanza Interquartile

- I quartili sono tre valori che dividono i dati ordinati in quattro parti, ciascuna con un numero uguale di osservazioni. I quartili sono un tipo di quantile.

Quartile e Distanza Interquartile

- I quartili sono tre valori che dividono i dati ordinati in quattro parti, ciascuna con un numero uguale di osservazioni. I quartili sono un tipo di quantile.



Quartile e Distanza Interquartile

- I quartili sono tre valori che dividono i dati ordinati in quattro parti, ciascuna con un numero uguale di osservazioni. I quartili sono un tipo di quantile.



- La distanza interquartile è la differenza tra $Q3$ e $Q1$: $\Delta = Q3 - Q1$. In altri termini la distanza interquartile taglia via il 25% dei valori più bassi e il 25% di quelli più alti.

Quartile e Distanza Interquartile - Esempio

Supponiamo di condurre uno studio sullo sviluppo del linguaggio nei bambini da 1-6 anni. E ottenere la seguente tabella:

Anni	1	2	3	4	5	6
Frequenza	2	3	4	1	2	2

Quartile e Distanza Interquartile - Esempio

Supponiamo di condurre uno studio sullo sviluppo del linguaggio nei bambini da 1-6 anni. E ottenere la seguente tabella:

Anni	1	2	3	4	5	6
Frequenza	2	3	4	1	2	2

- Contiamo il numero di osservazioni:

$$N = 2 + 3 + 4 + 1 + 2 + 2 = 14$$

Quartile e Distanza Interquartile - Esempio

Supponiamo di condurre uno studio sullo sviluppo del linguaggio nei bambini da 1-6 anni. E ottenere la seguente tabella:

Anni	1	2	3	4	5	6
Frequenza	2	3	4	1	2	2

- Contiamo il numero di osservazioni:

$$N = 2 + 3 + 4 + 1 + 2 + 2 = 14$$

- Ordiniamo le osservazioni in ordine crescente:

$$[1, 1, 2, 2, 2, 3, 3, 3, 3, 4, 5, 5, 6, 6]$$

Quartile e Distanza Interquartile - Esempio

Supponiamo di condurre uno studio sullo sviluppo del linguaggio nei bambini da 1-6 anni. E ottenere la seguente tabella:

Anni	1	2	3	4	5	6
Frequenza	2	3	4	1	2	2

- Contiamo il numero di osservazioni:

$$N = 2 + 3 + 4 + 1 + 2 + 2 = 14$$

- Ordiniamo le osservazioni in ordine crescente:

$$[1, 1, 2, 2, 2, 3, 3, 3, 3, 4, 5, 5, 6, 6]$$

- Troviamo il primo quartile

$$N \times \left(\frac{1}{4}\right) = 14 \times \left(\frac{1}{4}\right) = 3.5$$

3.5 non è intero, pertanto la posizione del primo quartile è la quarta:
 $Q1 = 2$ anni.

Quartile e Distanza Interquartile - Esempio

Supponiamo di condurre uno studio sullo sviluppo del linguaggio nei bambini da 1-6 anni. E ottenere la seguente tabella

Anni	1	2	3	4	5	6
Frequenza	2	3	4	1	2	2

- Troviamo il secondo quartile (**mediana**)

$$N \times \left(\frac{2}{4}\right) = 14 \times \left(\frac{2}{4}\right) = 7$$

7 è un intero, pertanto Q_2 è la media aritmetica tra la settima e l'ottava posizione: $Q_2 = (3 + 3)/2 = 3$ anni.

Quartile e Distanza Interquartile - Esempio

Supponiamo di condurre uno studio sullo sviluppo del linguaggio nei bambini da 1-6 anni. E ottenere la seguente tabella

Anni	1	2	3	4	5	6
Frequenza	2	3	4	1	2	2

- Troviamo il secondo quartile (**mediana**)

$$N \times \left(\frac{2}{4}\right) = 14 \times \left(\frac{2}{4}\right) = 7$$

7 è un intero, pertanto Q_2 è la media aritmetica tra la settima e l'ottava posizione: $Q_2 = (3 + 3)/2 = 3$ anni.

- Troviamo il terzo quartile

$$N \times \left(\frac{3}{4}\right) = 14 \times \left(\frac{3}{4}\right) = 10.5$$

10.5 non è un intero, pertanto Q_3 è il valore alla undicesima posizione: $Q_3 = 5$ anni.

Distribuzione Normale

Definiamo **distribuzione normale** la seguente funzione:

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{(x - \mu)^2}{2\sigma^2} \right\}$$


dove

- μ si dice *valore atteso* o *medio*;
- $\sigma^2 \neq 0$ è la *varianza*.

Il grafico della distribuzione normale prende il nome di *curva gaussiana*.

Curva Normale

Rappresentiamo la distribuzione di Gauss centrata nell'origine dell'asse x , ovvero con $\mu = 0$ per diversi valori di σ .





Bisi, Fiorese (2022)

Metodi matematici per le scienze applicate

Fine