

A dark blue vertical bar is positioned on the left side of the slide, partially overlapping the title box.

Elementi di statistica

A light blue vertical bar is positioned on the left side of the slide, below the title box.

Popolazione statistica e campione casuale

- ▶ Si chiama **popolazione statistica** l'insieme di tutti gli elementi che si vogliono studiare (individui, animali, vegetali, cellule, caratteristiche delle collettività ..) e può avere un numero finito o infinito di elementi.

Es: insieme degli abitanti di una città, di una nazione; insieme delle altezze di una popolazione di fascia di età fissata.

- ▶ Problema: non sempre si possono raccogliere dati su tutti gli elementi della popolazione, quindi se ne considera un sottoinsieme rappresentativo, il campione.
- ▶ Si chiama **campione casuale** una sequenza di elementi scelti a caso dalla popolazione in modo che ogni elemento abbia la stessa probabilità di far parte del campione.



Statistica descrittiva e inferenziale

- ▶ **Statistica descrittiva** : se l'indagine è sulla totalità della popolazione, sintesi quantitativa completa del fenomeno studiato (es. censimento)
- ▶ **Statistica inferenziale**: studia come e con quale precisione si possono descrivere le caratteristiche di una popolazione se l'indagine viene effettuata su un campione, vi è quindi incertezza.



Variabili statistiche

- ▶ Fissata una popolazione si chiamano **variabili statistiche** tutte le caratteristiche che variano al variare dei componenti della popolazione.
- ▶ Le variabili che sono espresse qualitativamente sono dette **attributi** (colore degli occhi, della pelliccia, ecc..); quelle che sono espresse quantitativamente sono dette **misurabili** (temperatura a Cagliari alle 8:00 am)



Dati (informazioni empiriche) e rappresentazioni dei dati

Esempio. Rappresentiamo su un **diagramma di punti**, su un **istogramma (diagramma a blocchi)**, su un **aerogramma** i dati raccolti su una tabella

- ▶ Campione: 10 esemplari di gatto.
- ▶ Variabile misurabile: numero di cuccioli partoriti in un dato periodo.


gatto	1	2	3	4	5	6	7	8	9	10
n.cuccioli	2	1	3	3	4	2	2	1	2	3

- ▶ **diagramma di punti**: in un sistema di riferimento cartesiano ogni punto è rappresentato dalla coppia ordinata (g, n.cuccioli)
- ▶ **istogramma (diagramma a canne)**: i dati sono rettangoli di base costante (ciascuna rappresenta un individuo) altezza uguale al numero di cuccioli di ciascun individuo.




Dati (informazioni empiriche) e rappresentazioni dei dati

gatto	1	2	3	4	5	6	7	8	9	10
n.cuccioli	2	1	3	3	4	2	2	1	2	3



$(g_i, n.cuccioli)$



$(g_i, n.cuccioli)$

Possiamo organizzare e rappresentare i dati in un diverso istogramma? Quale il senso e il procedimento per la rappresentazione su un **aerogramma** ?



Frequenze assolute e relative

N : dimensione del campione, numero totale dei dati raccolti

$X_1, X_2, \dots, X_N$: i dati, cioè i valori assunti nel campione dalla variabile statistica X

In molti casi i dati sono ripetuti, cioè assumono un numero finito di valori discreti distinti $x_1, x_2, \dots, x_n$, $n \leq N$. Indichiamo con

F_i : il numero di dati uguali ad x_i , cioè la **frequenza assoluta**

$f_i = \frac{F_i}{N}$: la **frequenza relativa**, dove si prende in considerazione la numerosità del campione



Frequenza assoluta e relativa

F_i : **frequenza assoluta**

$f_i = F_i/N$: **frequenza relativa**

► Esempio: determinare la frequenza assoluta e relativa dei dati:

gatto	1	2	3	4	5	6	7	8	9	10
n.cuccioli	2	1	3	3	4	2	2	1	2	3

Variabile misurabile X : *numero di cuccioli partoriti in un dato periodo.*

Valori assunti dalla variabile X : $X_2 = X_8 = 1$; $X_1 = X_6 = X_7 = X_9 = 2$;
 $X_3 = X_4 = X_{10} = 3$; $X_5 = 4$;

I valori distinti che assume X sono 4: $x_1 = 1$, $x_2 = 2$, $x_3 = 3$, $x_4 = 4$

Le corrispondenti frequenze assolute sono : $F_1 = 2, F_2 = 4, F_3 = 3, F_4 = 1$



Le corrispondenti frequenze relative sono : $f_1 = \frac{2}{10}, f_2 = \frac{4}{10}, f_3 = \frac{3}{10}, f_4 = \frac{1}{10}$

► Esercizio: scrivere le frequenze relative in percentuale



Istogrammi e aerogrammi

rappresentazione dell'aerogramma e dell'istogramma delle frequenze



Il 20% delle gatte ha 1 cucciolo
Il 40% ha 2 cuccioli
Il 30% ha 3 cuccioli
Il 10% ha 4 cuccioli

I dati saranno generalizzabili a tutta la popolazione dei gatti?

Raccoglimento in classi

Misurando le altezze di 100 ragazze al primo anno di ingegneria sono stati ricavati i seguenti dati:

1 ragazza è alta 150 cm;	5 ragazze sono alte 160 cm;
2 ragazze sono alte 153 cm;	12 ragazze sono alte 161 cm;
5 ragazze sono alte 155 cm;	15 ragazze sono alte 162 cm;
3 ragazze sono alte 156 cm;	8 ragazze sono alte 163 cm;
2 ragazze sono alte 157 cm;	3 ragazze sono alte 164 cm;
4 ragazze sono alte 158 cm;	10 ragazze sono alte 165 cm;
3 ragazze sono alte 159 cm;	10 ragazze sono alte 166 cm;
	7 ragazze sono alte 167 cm;
	5 ragazze sono alte 168 cm;
	5 ragazze sono alte 169 cm;

Come si possono rappresentare questi dati in modo efficiente?
Conviene raggruppare i dati in **classi**.




Indici di tendenza centrale: moda e classe modale

- ▶ Riassumere e organizzare i dati: indici numerici che riassumono le principali caratteristiche matematiche dei dati.
- ▶ Se i dati sono espressi mediante la loro appartenenza a diverse classi (sottoinsiemi), si chiama **classe modale** la classe di frequenza massima, se le classi sono individuate da numeri, il numero che contraddistingue la classe modale prende il nome di **moda**.

Esempio: determinare moda (o classe modale), frequenza relativa e disegnare l'istogramma delle frequenze assolute.

Altezze in centimetri di un campione di ragazze suddivise in classi
 $I_1 = [150, 154]$ $I_2 = [155, 159]$ $I_3 = [160, 164]$ $I_4 = [165, 169]$

frequenza $F_1 = 3, F_2 = 17, F_3 = 43, F_4 = 37$



Classe modale: I_3
che ha frequenza 43

Indici di tendenza centrale: media

Data una variabile statistica X con $X_1, X_2, \dots, X_N$ i dati numerici relativi ad un campionamento, si chiama **media campionaria** di X la media aritmetica dei dati

$$m_X = \frac{1}{N} \sum_{k=1}^N X_k$$

Se i dati distinti sono $x_1, x_2, x_3, \dots, x_n$ $n \leq N$ e assumono frequenze F_i si può scrivere in modo equivalente

$$m_X = \frac{1}{N} \sum_{i=1}^n F_i x_i = \sum_{i=1}^n \frac{F_i}{N} x_i = \sum_{i=1}^n f_i x_i$$

Si può talvolta preferire la media pesata o ponderata.

Se i dati hanno variazioni esponenziali, l'indice più adatto è **la media geometrica**

Indici di tendenza centrale: media geometrica

Data una variabile statistica X con $X_1, X_2, \dots, X_N$ i valori campionari numerici (positivi) relativi ad un campionamento.

Si chiama **media geometrica**

$$GM_X = \sqrt[N]{X_1 \cdot X_2 \cdot \dots \cdot X_N}$$

Se i dati distinti sono $x_1, x_2, \dots, x_n, n \leq N$ e assumono frequenze assolute F_i si può scrivere in modo equivalente

$$GM_X = \sqrt[N]{x_1^{F_1} x_2^{F_2} \dots x_n^{F_n}}$$

Quando la media non è una buona stima riassuntiva, si può usare la mediana

Indici di tendenza centrale: sintesi

Sia X una variabile statistica, indichiamo con

$X_1, X_2, \dots, X_N$ i dati numerici relativi ad un campionamento

$x_1, x_2, x_3, \dots, x_n, n \leq N$, i dati distinti che vengono assunti con frequenze $F_1, \dots, F_n$

Indici di posizione:

► **Media:**

aritmetica $m_X = \frac{1}{N} \sum_{k=1}^N X_k \quad m_X = \frac{1}{N} \sum_{i=1}^n F_i x_i = \sum_{i=1}^n \frac{F_i}{N} x_i = \sum_{i=1}^n f_i x_i$

geometrica $GM_X = \sqrt[N]{X_1 \cdot X_2 \cdot \dots \cdot X_N} \quad GM_X = \sqrt[N]{x_1^{F_1} x_2^{F_2} \dots x_n^{F_n}}$

► **Moda (o classe modale)** : valore numerico (o classe) di frequenza massima

► **Mediana**



Indici di tendenza centrale: mediana

Siano $X_1, X_2, \dots, X_N$ i valori campionari numerici **ordinati in modo crescente** (non decrescente). La **mediana** è il **valore centrale** (che separa in due parti uguali l'insieme dei dati) che si ottiene con la seguente regola:

Se N è dispari, la mediana è il **valore del dato** che corrisponde all'intero successivo a $\frac{N}{2}$.
Se N è pari, è la **media aritmetica dei valori dei dati** al posto $N/2$ e al posto successivo.

Scrivere in formula il valore della mediana per N pari.

Calcolare la mediana nel caso delle tre successioni di dati assegnate

A	3,5	4,2	3,25	4,12
B	3,5	8,2	3,25	4,12
C	35	4,2	3,25	4,12

e verificare che la mediana, contrariamente alla media, risente poco della presenza di dati estremi (o di eventuali errori)

Frequenza relativa cumulata

Siano $x_1, x_2, \dots, x_n$ i valori campionari numerici distinti e $F_1, F_2, \dots, F_n$ le rispettive frequenze. Determinare la **frequenza relativa cumulata** di x_i (somma delle frequenze relative dei dati da 1 a n_i) fornisce informazioni sul valore della mediana.


Esempio. A partire dai dati della tabella determinare la media, la mediana e l'istogramma delle frequenze relative e cumulate (fc) espresse in percentuale.

Dati	2	4	6	7
F	1	2	5	6
f	1/14	2/14	5/14	6/14
fc	1/14	3/14	8/14	14/14
f in %				
fc in %				

Media	5.85
Mediana	6

Esempio. A partire dai dati della tabella determinare la media, la mediana e l'istogramma delle frequenze relative e cumulate (fc) espresse in percentuale

frequenze cumulate



La mediana si ha in corrispondenza del 50% e infatti risulta essere 6

Indici di tendenza centrale

Siano $X_1, X_2, \dots, X_N$ i valori campionari numerici raccolti in N osservazioni e rappresentati nella seguente tabella

1	0	3	2	0	4	5	6	4	0	2
5	2	6	2	9	9	3	4	9	2	1

Esercizio.

Determinare la **media aritmetica**, la **media geometrica**, la **moda**, la **mediana** e rappresentare l'**istogramma** delle **frequenze relative** espresse in percentuale e quello delle **frequenze cumulate**.

Rappresentare media aritmetica e mediana nei due istogrammi.

Varianza e deviazione standard

Sia X una variabile statistica, la **varianza campionaria** di N dati $X_1, X_2, \dots, X_N$ aventi media campionaria m_X è il numero

$$s_X^2 = \frac{(X_1 - m_X)^2 + (X_2 - m_X)^2 + \dots + (X_N - m_X)^2}{N - 1}$$

che valuta la distanza media al quadrato dei dati dalla media, cioè la loro **dispersione**

Se i dati assumono un numero finito di valori discreti distinti $x_1, x_2, x_3, \dots, x_n$ $n \leq N$ e con frequenza assoluta F_i si definisce **varianza campionaria**

La radice quadrata della varianza

$$s_X^2 = \frac{\sum_{i=1}^n F_i (x_i - m_X)^2}{N - 1}$$

$s_X = \sqrt{s_X^2}$ è la **deviazione standard campionaria**

Varianza e deviazione standard

Si eseguono alcune misure di una grandezza X e si rilevano i seguenti risultati con le frequenze indicate sotto

X	0	1.3	1.2	0.3	3.4	0.5	1.6	4.7	0.8	2.9
F	2	6	12	9	19	39	42	39	21	11

Calcolare la media, la varianza campionaria e la deviazione standard

Varianza e deviazione standard

Se i dati a disposizione riguardano un'intera popolazione (non un campione) si usano simboli differenti nelle definizioni degli indici di tendenza centrale.

Indichiamo con $y_1, y_2, \dots, y_M$ i dati relativi a tutti gli individui di una popolazione

la **media** di popolazione è il numero

$$\mu = \frac{1}{M} \sum_{i=1}^M y_i$$

la **varianza** di popolazione è il numero

$$\sigma^2 = \frac{1}{M} \sum_{i=1}^M (y_i - \mu)^2$$

la **deviazione standard** di popolazione, chiamata anche **scarto quadratico medio** è $\sigma = \sqrt{\sigma^2}$

Per N abbastanza grande la diversità tra la **varianza campionaria** (varianza stimata) e la **varianza** di popolazione (varianza) diventa trascurabile.

Analogo risultato si ha per la deviazione standard.

Varianza e deviazione standard

Esempio: Calcoliamo le deviazioni standard dei seguenti dati considerati come dati di un'intera popolazione.

Sia X l'insieme delle altezze degli atleti di una squadra di calcetto

$$X = \{176, 181, 168, 176, 172\}.$$

Calcolare la media, la varianza e la deviazione standard

Media $\mu = \frac{1}{M} \sum_{i=1}^M y_i \quad \mu = \frac{1}{5} (176 + 181 + 168 + 176 + 172) = 174.6$

Varianza $\sigma^2 = \frac{1}{M} \sum_{i=1}^M (y_i - \mu)^2 \quad \sigma^2 = \frac{1}{5} (1.4^2 + 6.4^2 + (-6.6)^2 + 1.4^2 + (-2.6)^2)$

$$\sigma^2 = \frac{1}{5} (1.96 + 40.96 + 43.56 + 1.96 + 6.76) = \frac{95.6}{5} = 19.1$$

Deviazione standard $\sigma = \sqrt{\sigma^2} = \sqrt{19.1} = 4.37$



Varianza e deviazione standard

La **varianza** si può anche calcolare con la formula (di König)

$$\sigma^2 = \frac{1}{M} \sum_{i=1}^M (y_i - \mu)^2 \qquad \sigma^2 = \left(\frac{1}{M} \sum_{i=1}^M y_i^2 \right) - \left(\frac{1}{M} \sum_{i=1}^M y_i \right)^2$$

Verificare l'uguaglianza a partire dai dati $X = \{176, 181, 168, 176, 172\}$.
□

N dati considerati come dati di un'intera popolazione $X = \{X_1, X_2, \dots, X_N\}$, o di N osservazioni empiriche possono essere considerati come **vettori**.

Gli indici di tendenza centrale, o di dispersione definiti utilizzando gli strumenti dell'algebra dei vettori.

Gli stessi indici possono anche essere definiti in termini probabilistici.

La trattazione in questi diversi ambiti matematici non è oggetto di questa trattazione.