

Statistica I - Lezione 1

Def: un campione / database è un insieme di punti dati
 $\{x_1, x_2, \dots, x_n\}$
dove $n \in \mathbb{N}$ è il numero di punti dato (o numerità del database).

Esempio: Compleanni

$\{09052004, 08062004, \dots\}$ $n \approx 250$

Esempio: Salari (in migliaia di euro)

$\{60, 123, 1350, \dots\}$ $n \approx 250$

Esempio: Test PCR

$\{-, -, +, -, +, \dots\}$


Esempio: Tempi di vita di lampadine prodotte da una fabbrica

$n = 200$

Item Lifetimes									
1,067	919	1,196	785	1,126	936	918	1,156	920	948
855	1,092	1,162	1,170	929	950	905	972	1,035	1,045
1,157	1,195	1,195	1,340	1,122	938	970	1,237	956	1,102
1,022	978	832	1,009	1,157	1,151	1,009	765	958	902
923	1,333	811	1,217	1,085	896	958	1,311	1,037	702
521	933	928	1,153	946	858	1,071	1,069	830	1,063
930	807	954	1,063	1,002	909	1,077	1,021	1,062	1,157
999	932	1,035	944	1,049	940	1,122	1,115	833	1,320
901	1,324	818	1,250	1,203	1,078	890	1,303	1,011	1,102
996	780	900	1,106	704	621	854	1,178	1,138	951
1,187	1,067	1,118	1,037	958	760	1,101	949	992	966
824	653	980	935	878	934	910	1,058	730	980
844	814	1,103	1,000	788	1,143	935	1,069	1,170	1,067
1,037	1,151	863	990	1,035	1,112	931	970	932	904
1,026	1,147	883	867	990	1,258	1,192	922	1,150	1,091
1,039	1,083	1,040	1,289	699	1,083	880	1,029	658	912
1,023	984	856	924	801	1,122	1,292	1,116	880	1,173
1,134	932	938	1,078	1,180	1,106	1,184	954	824	529
998	996	1,133	765	775	1,105	1,081	1,171	705	1,425
610	916	1,001	895	709	860	1,110	1,149	972	1,002

Esempio : Instagram network .

{(@audreameuconi, 10000),
 (@vladimirp, 2),
 (@fgholellstelle2, 50)}



Esempio : Temperature

[In Fahrenheit degrees. Airport data except as noted. Based on standard 30-year period, 1961 through 1990]

State	Station	Annual												
		Jan.	Feb.	Mar.	Apr.	May	June	July	Aug.	Sept.	Oct.	Nov.	Dec.	avg.
AL	Mobile	40.0	42.7	50.1	57.1	64.4	70.7	73.2	72.9	68.7	57.3	49.1	43.1	57.4
AK	Juneau	19.0	22.7	26.7	32.1	38.9	45.0	48.1	47.3	42.9	37.2	27.2	22.6	34.1
AZ	Phoenix	41.2	44.7	48.8	55.3	63.9	72.9	81.0	79.2	72.8	60.8	48.9	41.8	59.3
AR	Little Rock	29.1	33.2	42.2	50.7	59.0	67.4	71.5	69.8	63.5	50.9	41.5	33.1	51.0
CA	Los Angeles	47.8	49.3	50.5	52.8	56.3	59.5	62.8	64.2	63.2	59.2	52.8	47.9	55.5
	Sacramento	37.7	41.4	43.2	45.5	50.3	55.3	58.1	58.0	55.7	50.4	43.4	37.8	48.1
	San Diego	48.9	50.7	52.8	55.6	59.1	61.9	65.7	67.3	65.6	60.9	53.9	48.8	57.6
	San Francisco	41.8	45.0	45.8	47.2	49.7	52.6	53.9	55.0	55.2	51.8	47.1	42.7	49.0
CO	Denver	16.1	20.2	25.8	34.5	43.6	52.4	58.6	56.9	47.6	36.4	25.4	17.4	36.2
CT	Hartford	15.8	18.6	28.1	37.5	47.6	56.9	62.2	60.4	51.8	40.7	32.8	21.3	39.5
DE	Wilmington	22.4	24.8	33.1	41.8	52.2	61.6	67.1	65.9	58.2	45.7	37.0	27.6	44.8
DC	Washington	26.8	29.1	37.7	46.4	56.6	66.5	71.4	70.0	62.5	50.3	41.1	31.7	49.2
FL	Jacksonville	40.5	43.3	49.2	54.9	62.1	69.1	71.9	71.8	69.0	59.3	50.2	43.4	57.1
	Miami	59.2	60.4	64.2	67.8	72.1	75.1	76.2	76.7	75.9	72.1	66.7	61.5	69.0
GA	Atlanta	31.5	34.5	42.5	50.2	58.7	66.2	69.5	69.0	63.5	51.9	42.8	35.0	51.3
HI	Honolulu	65.6	65.4	67.2	68.7	70.3	72.2	73.5	74.2	73.5	72.3	70.3	67.0	70.0
ID	Boise	21.6	27.5	31.9	36.7	43.9	52.1	57.7	56.8	48.2	39.0	31.1	22.5	39.1
IL	Chicago	12.9	17.2	28.5	38.6	47.7	57.5	62.6	61.6	53.9	42.2	31.6	19.1	39.5
	Peoria	13.2	17.7	29.8	40.8	50.9	60.7	65.4	63.1	55.2	43.1	32.5	19.3	41.0
IN	Indianapolis	17.2	20.9	31.9	41.5	51.7	61.0	65.2	62.8	55.6	43.5	34.1	23.2	42.4
IA	Des Moines	10.7	15.6	27.6	40.0	51.5	61.2	66.5	63.6	54.5	42.7	29.9	16.1	40.0
KS	Wichita	19.2	23.7	33.6	44.5	54.3	64.6	69.9	67.9	59.2	46.6	33.9	23.0	45.0
KY	Louisville	23.2	26.5	36.2	45.4	54.7	62.9	67.3	65.8	58.7	45.8	37.3	28.6	46.0
LA	New Orleans	41.8	44.4	51.6	58.4	65.2	70.8	73.1	72.8	69.5	58.7	51.0	44.8	58.5
ME	Portland	11.4	13.5	24.5	34.1	43.4	52.1	58.3	57.1	48.9	38.3	30.4	17.8	35.8
MD	Baltimore	23.4	25.9	34.1	42.5	52.6	61.8	66.8	65.7	58.4	45.9	37.1	28.2	45.2
MA	Boston	21.6	23.0	31.3	40.2	49.8	59.1	65.1	64.0	56.8	46.9	38.3	26.7	43.6
MI	Detroit	15.6	17.6	27.0	36.8	47.1	56.3	61.3	59.6	52.5	40.9	32.2	21.4	39.0
	Sault Ste. Marie	4.6	4.8	15.3	28.4	38.4	45.5	51.3	51.3	44.3	36.2	25.9	11.8	29.8
MN	Duluth	-2.2	2.8	15.7	28.9	39.6	48.5	55.1	53.3	44.5	35.1	21.5	4.9	29.0
	Minneapolis-St. Paul	2.8	9.2	22.7	36.2	47.6	57.6	63.1	60.3	50.3	38.8	25.2	10.2	35.3
MS	Jackson	32.7	35.7	44.1	51.9	60.0	67.1	70.5	69.7	63.7	50.3	42.3	36.1	52.0
MO	Kansas City	16.7	21.8	32.6	43.8	53.9	63.1	68.2	65.7	56.9	45.7	33.6	21.9	43.7
	St. Louis	20.8	25.1	35.5	46.4	56.0	65.7	70.4	67.9	60.5	48.3	37.7	26.0	46.7
MT	Great Falls	11.6	17.2	22.8	31.9	40.9	48.6	53.2	52.2	43.5	35.8	24.3	14.6	33.1

Source: U.S. National Oceanic and Atmospheric Administration, Climatology of the United States, No. 81.

Esempio Topi

Germ-Free Mice		Conventional Mice	
1	58, 92, 93, 94, 95	1	59, 89, 91, 98
2	02, 12, 15, 29, 30, 37, 40, 44, 47, 59	2	35, 45, 50, 56, 61, 65, 66, 80
3	01, 01, 21, 37	3	43, 56, 83
4	15, 34, 44, 85, 96	4	03, 14, 28, 32
5	29, 37		
6	24		
7	07		
8	00		

2.2 Organizzazione e descrizione dei dati

e le corrett. globali

Per leggere, interpretare e copiare il contenuto di un database dobbiamo presentare il suo contenuto in maniera intellegibile.

→ rappresentiamo le frequenze (freq. assolute) nel database, cioè il numero di volte che un valore è osservato.

(efficiente se il numero di valori distinti è basso)

Queste possono essere rappresentate in diversi modi:

- Tabelle:

valore	v_1	v_i	v_3	v_4	...
frequenza	f_1	f_i	f_3	f_4	...

Esempio . (Stipendi)

Tabella 2.1 Stipendi annuali iniziali. Dati in migliaia di dollari.

Stipendio iniziale	Frequenza
27	4
28	1
29	3
30	5
31	8
32	10
34	5
36	2
37	3
40	1

$u = 42$

- Grafico a bastoncini / Grafico a barre.

Esempio (Stipendi)

Grafico a bastoncini




Grafico a barre






Grafico a linee



Esempio (twitter)

valore	2	3	...
# followers			
frequenza	10000	7000	



Talvolta il numero assoluto f di occorrenze di un valore ci interessa meno della sua frequenza relativa (frazione di volte che un valore appare in un database di ampiezza n), dato da

$$\frac{f_i}{n} \longrightarrow$$
 frequenza assoluta dell' i -esimo valore
 $n \longrightarrow$ numerosità del database.

Come nel caso delle frequenze assolute, le frequenze relative si possono rappresentare in

- tavelle
- grafici a barre
- grafici a bastoncini
- grafici a linee

Esempio


$n=42$

Tabella 2.2 Redditi annuali iniziali. Dati in migliaia di dollari.	
Stipendio iniziale	Frequenza relativa
27	$4/42 \approx 0.0952 = 9.52\%$
28	$1/42 \approx 0.0238 = 2.38\%$
29	$3/42 \approx 0.0714 = 7.14\%$
30	$5/42 \approx 0.1190 = 11.90\%$
31	$8/42 \approx 0.1905 = 19.05\%$
32	$10/42 \approx 0.2381 = 23.81\%$
34	$5/42 \approx 0.1190 = 11.90\%$
36	$2/42 \approx 0.0476 = 4.76\%$
37	$3/42 \approx 0.0714 = 7.14\%$
40	$1/42 \approx 0.0238 = 2.38\%$

Inoltre, un'altra rappresentazione possibile è quella tramite diagramma a torte


Esempio

Type of Cancer	Number of New Cases	Relative Frequency
Lung	42	.21
Breast	50	.25
Colon	32	.16
Prostate	55	.275
Melanoma	9	.045
Bladder	12	.06



I metodi esposti sopra perdono il loro senso se il numero di valori diversi è comparabile all'ampiezza del campione:

Controesempio




Se questo è il caso, possiamo dividere i dati in gruppi di valori contigui (classi) ed associare ogni punto data a una di esse.

TABLE 2.3 *Life in Hours of 200 Incandescent Lamps*

Item Lifetimes									
1,067	919	1,196	785	1,126	936	918	1,156	920	948
855	1,092	1,162	1,170	929	950	905	972	1,035	1,045
1,157	1,195	1,195	1,340	1,122	938	970	1,237	956	1,102
1,022	978	832	1,009	1,157	1,151	1,009	765	958	902
923	1,333	811	1,217	1,085	896	958	1,311	1,037	702
521	933	928	1,153	946	858	1,071	1,069	830	1,063
950	807	954	1,063	1,002	909	1,077	1,021	1,062	1,157
999	932	1,035	944	1,049	940	1,122	1,115	833	1,320
901	1,324	818	1,250	1,203	1,078	890	1,303	1,011	1,102
996	780	900	1,106	704	621	854	1,178	1,138	951
1,187	1,067	1,118	1,037	958	760	1,101	949	992	966
824	653	980	935	878	934	910	1,058	730	980
844	814	1,103	1,000	788	1,143	935	1,069	1,170	1,067
1,037	1,151	863	990	1,035	1,112	931	970	932	904
1,026	1,147	883	867	990	1,258	1,192	922	1,150	1,091
1,039	1,083	1,040	1,289	699	1,083	880	1,029	658	912
1,023	984	856	924	801	1,122	1,292	1,116	880	1,173
1,134	932	938	1,078	1,180	1,106	1,184	954	824	529
998	996	1,133	765	775	1,105	1,081	1,171	705	1,425
610	916	1,001	895	709	860	1,110	1,149	972	1,002

TABLE 2.4 *A Class Frequency Table*

Class Interval	Frequency (Number of Data Values in the Interval)
500–600	2
600–700	5
700–800	12
800–900	25
900–1000	58
1000–1100	41
1100–1200	43
1200–1300	7
1300–1400	6
1400–1500	1



- ⚠ La definizione delle classi gioca un ruolo importante!
 - se troppo poche \longrightarrow una colonna
 - se troppe \longrightarrow troppe colonne "grasse".

2.3 Le grandezze che sintetizzano i dati

Spesso i database a disposizione sono così grandi (milioni di punti dati, centinaia di categorie,...) che risulta necessario rappresentarli/sintetizzarli ulteriormente.

Esempio (Temperat.)

State	Station	Annual												
		Jan.	Feb.	Mar.	Apr.	May	June	July	Aug.	Sept.	Oct.	Nov.	Dec.	avg.
AL	Mobile	40.0	42.7	50.1	57.1	64.4	70.7	73.2	72.9	68.7	57.3	49.1	43.1	57.4
AK	Juneau	19.0	22.7	26.7	32.1	38.9	45.0	48.1	47.3	42.9	37.2	27.2	22.6	34.1
AZ	Phoenix	41.2	44.7	48.8	55.3	63.9	72.9	81.0	79.2	72.8	60.8	48.9	41.8	59.3
AR	Little Rock	29.1	33.2	42.2	50.7	59.0	67.4	71.5	69.8	63.5	50.9	41.5	33.1	51.0
CA	Los Angeles	47.8	49.3	50.5	52.8	56.3	59.5	62.8	64.2	63.2	59.2	52.8	47.9	55.5
	Sacramento	37.7	41.4	43.2	45.5	50.3	55.3	58.1	58.0	55.7	50.4	43.4	37.8	48.1
	San Diego	48.9	50.7	52.8	55.6	59.1	61.9	65.7	67.3	65.6	60.9	53.9	48.8	57.6
	San Francisco	41.8	45.0	45.8	47.2	49.7	52.6	53.9	55.0	55.2	51.8	47.1	42.7	49.0
CO	Denver	16.1	20.2	25.8	34.5	43.6	52.4	58.6	56.9	47.6	36.4	25.4	17.4	36.2
CT	Hartford	15.8	18.6	28.1	37.5	47.6	56.9	62.2	60.4	51.8	40.7	32.8	21.3	39.5
DE	Wilmington	22.4	24.8	33.1	41.8	52.2	61.6	67.1	65.9	58.2	45.7	37.0	27.6	44.8
DC	Washington	26.8	29.1	37.7	46.4	56.6	66.5	71.4	70.0	62.5	50.3	41.1	31.7	49.2
FL	Jacksonville	40.5	43.3	49.2	54.9	62.1	69.1	71.9	71.8	69.0	59.3	50.2	43.4	57.1
	Miami	59.2	60.4	64.2	67.8	72.1	75.1	76.2	76.7	75.9	72.1	66.7	61.5	69.0
GA	Atlanta	31.5	34.5	42.5	50.2	58.7	66.2	69.5	69.0	63.5	51.9	42.8	35.0	51.3
HI	Honolulu	65.6	65.4	67.2	68.7	70.3	72.2	73.5	74.2	73.5	72.3	70.3	67.0	70.0
ID	Boise	21.6	27.5	31.9	36.7	43.9	52.1	57.7	56.8	48.2	39.0	31.1	22.5	39.1
IL	Chicago	12.9	17.2	28.5	38.6	47.7	57.5	62.6	61.6	53.9	42.2	31.6	19.1	39.5
	Peoria	13.2	17.7	29.8	40.8	50.9	60.7	65.4	63.1	55.2	43.1	32.5	19.3	41.0
IN	Indianapolis	17.2	20.9	31.9	41.5	51.7	61.0	65.2	62.8	55.6	43.5	34.1	23.2	42.4
IA	Des Moines	10.7	15.6	27.6	40.0	51.5	61.2	66.5	63.6	54.5	42.7	29.9	16.1	40.0
KS	Wichita	19.2	23.7	33.6	44.5	54.3	64.6	69.9	67.9	59.2	46.6	33.9	23.0	45.0
NY	Albany	22.2	26.5	36.2	46.6	51.7	62.9	67.2	65.8	59.7	45.8	37.3	28.6	44.8


In questi casi vale la pena sintetizzare i dati tramite statistiche → grandezze calcolate a partire dai dati.

Un tipo importante di statistica è quello che serve ad identificare il valore "tipico" del campione, attorno al quale si "accumulano" i dati.

⚠ non esiste una definizione unica di tale statistica ma dipende dalla nostra interpretazione di "tipico" e "accumulano".

Infatti esistono (almeno) 3 tali statistiche:

Esempio



Troviamo quindi, per un campione $\{x_1, \dots, x_n\}$ di n elementi

Def1 Si dice media campionaria (denotata con \bar{x})

$$\bar{x} = \frac{1}{n} (x_1 + x_2 + \dots + x_n) = \frac{1}{n} \sum_{j=1}^n x_j$$

Richiamo (Sommatore): $\sum_{j=1}^{10} x_j = x_1 + x_2 + \dots + x_{10}$

Esempio: $\sum_{j=0}^5 2^j = 2^0 + 2^1 + 2^2 + 2^3 + 2^4 + 2^5 = 63$

Moto white: se $a, b \in \mathbb{R}$

- $\sum_{j=1}^{10} a \cdot x_j = (a x_1 + a x_2 + \dots + a x_{10}) = a \cdot (x_1 + x_2 + \dots + x_{10}) = a \cdot \sum_{j=1}^{10} x_j$
- $\sum_{j=1}^{10} (x_j + b) = (x_1 + b + x_2 + b + \dots + x_{10} + b) = (x_1 + x_2 + \dots + x_{10}) + 10 \cdot b = \sum_{j=1}^{10} x_j + 10b$

Esempio (Punteggio medio al campionato di golf):

$$\{284, 280, 277, 282, 279, 285, 281, 278, 277\}$$

x_1

possiamo calcolare la media

$$\bar{x} = \frac{1}{9} \cdot (284 + 280 + \dots + 277) = 280, \bar{3}$$

Motivazione: nel caso in cui l'insieme di dati è formato tramite le frequenze (assolute) dei suoi valori, si calcola la media campionaria pesando i valori per le loro frequenze

Esempio:

Età	15	16	17	18	19	20
frequ.	2	5	11	9	14	13

 $n = f_1 + f_2 + \dots + f_6 = 54$

affermo $\bar{x} = \frac{1}{54} \left(\frac{2 \cdot 15 + 5 \cdot 16 + 11 \cdot 17 + 9 \cdot 18 + 14 \cdot 19 + 13 \cdot 20}{f_1 \cdot v_1} \right) = 18,24$

In generale: per un insieme di dati con valori

$\{v_1, \dots, v_k\}$ e relative frequenze $\{f_1, \dots, f_k\}$

(il valore v_k ha freq. assoluta f_k)

• il numero complessivo di dati è $n = f_1 + \dots + f_k = \sum_{j=1}^k f_j$

• La media campionaria è

$$\bar{x} = \frac{1}{n} \sum_{j=1}^k v_j \cdot f_j = \frac{\underbrace{f_1 \cdot v_1 + f_2 \cdot v_2 + \dots + f_k \cdot v_k}_{\substack{\text{peso} \\ \text{valori}}}}{n}$$

Passiamo ora alla definizione di mediana, cioè il valore dell'elemento "al centro delle liste".

Def 2. Dato un insieme di dati di ampiezza n si ordinano dal minore al maggiore. La mediana campionaria è data da

- il valore del dato in posizione $\frac{n+1}{2}$ se n è dispari
- la media aritmetica fra i valori dei dati in posizione $\frac{n}{2}$ e $\frac{n}{2}+1$ se n è pari.

Esempio

Età	15	16	17	18	19	20
freq.	2	5	11	9	14	13

$$n = 54 \rightarrow \frac{n}{2} = 27$$

$$\frac{n}{2} + 1 = 28$$

27 esimo elemento ha valore 18

28 esimo elemento ha valore 19

$$\Rightarrow \text{mediana} = \frac{18+19}{2} = 18.5$$

Esempio (Topi)

Conventional Mice	
1	59, 89, 91, 98
2	35, 45, 50, 56, 61, 65, 66, 80
3	43, 56, 83
4	03, 14, 28, 32

Germ-Free Mice	
1	58, 92, 93, 94, 95
2	02, 12, 15, 29, 30, 37, 40, 44, 47, 59
3	01, 01, 21, 37
4	15, 34, 44, 85, 96
5	29, 37
6	24
7	07
8	00

Trorriamo che le medie sono

$$\left\{ \begin{array}{l} \bar{x}_{\text{steufe}} = 344.07 \\ \bar{x}_{\text{normale}} = 292.32 \end{array} \right.$$

Per le mediane mouse abbiamo

$$\left\{ \begin{array}{l} u_{\text{steufe}} = 29 \\ u_{\text{normale}} = 19 \end{array} \right.$$

$$\left\{ \begin{array}{l} \text{mediana steufe} = 259 \\ \text{mediana normale} = 265 \end{array} \right.$$

Le medie campionarie sono molto diverse a causa di pochi valori grandi nel primo campione (outliers)! Le mediane non "percepiscono" questi dati.

Giungiamo infine alle tue statistiche: la moda.

Def 3: La moda campionaria di un insieme di dati (se esiste) è l'unico valore che ha frequenza massima. Se non esiste un unico valore con frequenza massima ciascuno di essi è detto valore modale.

Esempio

Età	15	16	17	18	19	20
freq.	2	5	11	9	14	13

19 è la moda del dataset.


Varianza e deviazione standard

Invece di cercare il "centro" o valore "tipico" di un campione, a volte vogliamo sintetizzare quanto il campione sia "dispersione" attorno a tale valore.

In altre parole vorremo quantificare la "distanza tipica" dei punti dati dal loro centro.

Esempio

Salari per clienti di due prodotti.



Idea 1: (media delle differenze.)

$$\frac{1}{n} \sum_{j=1}^n (x_j - \bar{x}) ?$$

$$\frac{1}{n} \sum_{j=1}^n (x_j - \bar{x}) = \frac{1}{n} \sum x_j - \frac{1}{n} \cancel{n} \cdot \bar{x} = \frac{1}{n} \sum_{j=1}^n x_j - \bar{x} = \underline{\underline{0}}$$

Def: Assegnato un insieme di dati $\{x_1, \dots, x_n\}$ si dice varianza campionaria la quantità

$$s^2 = \frac{1}{n-1} \sum_{j=1}^n (x_j - \bar{x})^2$$

dove \bar{x} è la media campionaria.