


Premessa

La distribuzione di frequenze è il risultato della raccolta dati che in essa sono organizzati e semplificati.



Rimangono però ancora tante le informazioni ed è nostro obiettivo riassumerne gli aspetti salienti in pochi valori numerici (indici statistici)

Essi consentono il confronto tra distribuzioni relative a variabili diverse oppure relative allo stessa variabile osservate in epoche, luoghi ed occasioni diverse.

A.T. Fecit

Concetto di media


Individua il livello di maggiore addensamento delle modalità ovvero la categoria o il valore (espresso nella stessa unità di misura) intorno alla quale sembra ruotare l'intera rilevazione.

Non è necessario che appartenga al dominio della variabile (può essere un valore fittizio).

Bisogna e basta che rispetti la condizione di internalità:

$$X_{\min} \leq \text{Media} \leq X_{\max}$$

Per scale almeno ordinali



A.T. Fecit

Esempi

Esempio.
Carattere qualitativo

Linguaggio	Parlanti (in milioni)
Mandarino	740
Inglese	403
Russo	277
Spagnolo	266
Indostano	264
Arabo	160
Bengalese	155
	2265

Carattere quantitativo.


Numeri di albi in famiglie di 5 figli	Numero di famiglie
1	25
2	23
3	10
4	1
5	1
	60

Nel primo caso la "media" può essere qualsiasi modalità (interna od esterna al dominio), nel secondo può essere solo un numero compreso tra 1 e 5

A.T. Fecit

Mancanza di univocità

Il processo di estrema sintesi che porta al collassamento della distribuzione di frequenza su di un singolo valore, costituisce il limite degli indici di posizione perché:



Distribuzioni molto diverse possono presentare la stessa "media". Conoscendo questa non è univocamente nota la situazione che l'ha determinata.

A.T. Fecit

La moda


E' l'indice di posizione più facile da calcolare, ma anche quello più grezzo. Si identifica con la modalità corrispondente alla frequenza relativa maggiore:

$$M_o = \{x_m \mid f_m \geq f_i \text{ per } i=1,2, \dots, k \}$$

Esempio.

Classificazione del molare inferiore destro per numero di canali su 1000 soggetti.

Canali x_i	Soggetti n_i	Freq. Rel. f_i
1	2	0.0002
2	914	0.9140
3	76	0.0076
4	8	0.0008
	1000	1.0000

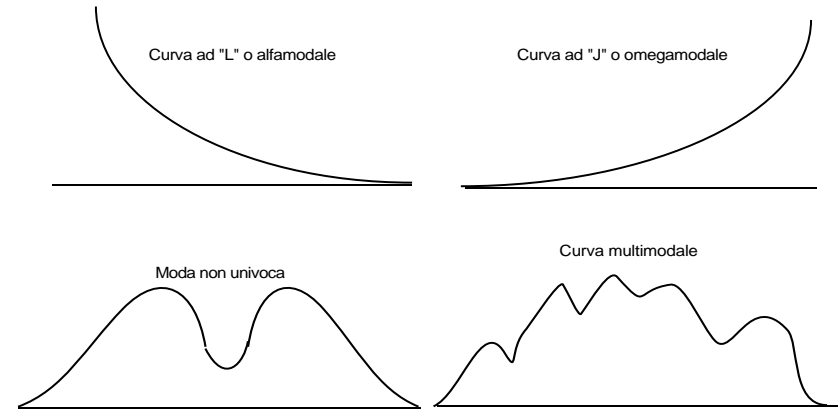


La determinazione della Moda è influenzata solo dai rapporti ordinali tra le frequenze

A.T. Fecit

Amodalità e multimodalità

La moda può essere assente dalla distribuzione.



La frequenza massima può non corrispondere ad un valore unico.

Inoltre, pur esistendo, la moda può non essere significativa, cioè le frequenze relative potrebbero differire troppo poco

A.T. Fecit

Difetto

Poiché non usa tutti i dati la moda può dare indicazioni fuorvianti

ESEMPIO:

n=20 uomini arrestati per violenza in famiglia furono sottoposti a vigilanza speciale per 2 anni. Ecco la distribuzione degli arresti alla fine del periodo:

Arresti	Criminali
0	8
1	1
2	1
3	1
4	2
5	4
6	3
	20

La moda è $M_o=0$ arresti.

La frequenza modale è elevata (doppia della 2^a in ordine di grandezza)

Tuttavia dire che zero arresti è tipico nasconderebbe un gruppo di criminali che ha reiterato il reato 5 o 6 volte

A.T. Fecit

Modalità in classi


La frequenza relativa più elevata individuerà la classe modale.

Metodo N. 1

I valori della classe modale hanno uguale frequenza. La Moda è il valore centrale della classe:

$$M_o = c_m = \frac{U_m + L_m}{2}$$

$$f_m \geq f_i \quad \forall i$$



Metodo N. 2

La moda è più vicina all'estremo L_m o U_m che confina con la classe con più frequenza (che esercita maggiore "attrazione")

$$M_o = L_m + \frac{(f_m - f_{m-1})}{[(f_m - f_{m-1}) + (f_m - f_{m+1})]} * (U_m - L_m)$$

A.T. Fecit

Esempio

Ordinazioni per importi

Importi	Ordini	f_i	d_i	h_i
0.0	1.9	102	0.1726	1.9
2.0	3.9	175	0.2961	1.9
4.0	5.9	208	0.3519	1.9
6.0	7.9	76	0.1286	1.9
8.0	9.9	23	0.0389	1.9
10.0	11.9	7	0.0118	1.9
		591	1.0000	

Classe modale: (4 - 5.9);

Valore centrale classe modale:

$$\frac{4.0 + 5.9}{2} \cong 5$$

Attrazione: $4.0 + \left[\frac{0.1852 - 0.1558}{(0.1852 - 0.1558) + (0.1852 - 0.0677)} \right] * 1.9 = 4.38$

A.T. Fecit

Ampiezze diverse

Se le modalità sono espresse in classi si impone la considerazione della loro eventuale differenza di ampiezza.

L_i	U_i	n_i	d_i	h_i	c_i
3	5	8	2	4	4
5	11	18	6	3	8

In questi casi occorre fare riferimento non più alle frequenze relative, bensì alle densità di frequenza ovvero alle altezze già viste nella costruzione degli istogrammi:

$$M_o = c_m = \frac{L_m + U_m}{2} \quad \text{dove } (h_m \geq h_i \text{ per } i=1,2, \dots, k)$$

$$M_o = L_m + \frac{(h_m - h_{m-1})}{[(h_m - h_{m-1}) + (h_m - h_{m+1})]} * (U_m - L_m)$$

A.T. Fecit

Esempio

Una radiografia è stata scomposta in pixel e su ciascuno di questi si è misurato il tono di grigio

Riflettenza	Pixel	f_i	d_i	h_i
0	30	54	0.0113	30.0
31	49	613	0.1277	18.0
50	98	421	0.0877	48.0
99	127	716	0.1492	28.0
128	160	432	0.0900	32.0
161	191	798	0.1663	30.0
192	240	1579	0.3290	48.0
241	255	187	0.0390	14.0
		4800	1.0000	

Classe modale: (31-49);

Valore centrale classe modale:

$$\frac{31 + 49}{2} = 40$$

Attrazione: $31 + \left[\frac{0.0071 - 0.0004}{(0.0071 - 0.0004) + (0.0071 - 0.0018)} \right] * 18 = 41.05$

A.T. Fecit

La mediana

La Mediana è la modalità che è preceduta e seguita dalle altre con uguale frequenza, si trova cioè in posizione centrale nella graduatoria delle modalità.

ESEMPIO:

Soldati schierati in ordine di altezza: la fila posta al centro è quella mediana

Ricordando che, se non altrimenti indicato, le modalità sono ordinate in senso crescente, la Mediana di "n" osservazioni è data da:

$$M_e = \begin{cases} X_{\left(\frac{n+1}{2}\right)} & \text{se "n" è dispari} \\ \frac{X_{(n/2)} + X_{(n/2)+1}}{2} & \text{se "n" è pari} \end{cases}$$

A.T. Fecit

Esempio

Si considerino i seguenti dati relativi ai costi di estrazione dollaro/barile.

Usa/Alaska	7.5	Canada	5.0
Messico	6.0	Venezuela	6.2
Argentina	15.1	Medio Oriente	2.5
Indonesia	10.7	Africa	7.4
Nord Europa	17.5	URSS	6.3

I dati ordinati sono:

$$\{2.5, 5.0, 6.0, 6.2, 6.3, 7.4, 7.5, 10.7, 15.1, 17.5\}$$

Poichè n=10 (cioè n è pari)

$$M_e = \frac{X_{\left(\frac{10}{2}\right)} + X_{\left(\frac{10}{2}+1\right)}}{2} = \frac{X_{(5)} + X_{(6)}}{2} = \frac{6.3 + 7.4}{2} = 6.85$$

A.T. Fecit

Proprietà della mediana

La Mediana rende minima la somma dei moduli degli scarti delle modalità

$$Q(A) = \sum_{i=1}^k |X_i - A| f_i$$

è minima se $A = M_e$.

$$\begin{aligned} Q(A) &= \sum_{X_{(i)} > A} (X_{(i)} - A) f_{(i)} + \sum_{X_{(i)} \leq A} (A - X_{(i)}) f_{(i)} \\ &= \sum_{X_{(i)} > A} X_{(i)} f_{(i)} - \sum_{X_{(i)} > A} A f_{(i)} + \sum_{X_{(i)} \leq A} A f_{(i)} - \sum_{X_{(i)} \leq A} X_{(i)} f_{(i)} \\ &= \sum_{X_{(i)} > A} X_{(i)} f_{(i)} - A \left(\sum_{X_{(i)} > A} f_{(i)} \right) + A \left(\sum_{X_{(i)} \leq A} f_{(i)} \right) - \sum_{X_{(i)} \leq A} X_{(i)} f_{(i)} \\ &= \sum_{X_{(i)} > A} X_{(i)} f_{(i)} + \sum_{X_{(i)} \leq A} X_{(i)} f_{(i)} - A [1 - F(A)] + AF(A) - 2 \sum_{X_{(i)} \leq A} X_{(i)} f_{(i)} \\ &= \mu - A [1 - 2F(A)] - 2 \sum_{X_{(i)} \leq A} X_{(i)} f_{(i)} \end{aligned}$$

dove μ è non dipende da "A".

$Q(A)$ è decrescente per A tale che $F(A) < 0.5$ ed è crescente per $F(A) > 0.5$; il minimo è perciò raggiunto per $F(A) = 0.5$ che corrisponde a $A = M_e$.

A.T. Fecit

La mediana per dati raggruppati

La mediana corrisponde alla modalità più piccola tra quelle che hanno frequenza relativa cumulata è maggiore o uguale a 0.5

$$\text{Min} \{x \in S | F(x) \geq 0.5\}$$

ESEMPIO:

Classificazione dei clienti di un punto vendita per numero di acquisti effettuati nel mese

Acquisti	Clients	f_i	F_i
0	40	0.0964	0.0964
1	69	0.1663	0.2627
2	95	0.2289	0.4916
3	111	0.2675	0.7590
4	74	0.1783	0.9373
5	26	0.0627	1.0000
415		1.0000	


La Mediana è "3 acquisti"

A.T. Fecit

Modalità in classi

E' possibile individuare solo la classe mediana, ovvero quella cui corrisponde la frequenza relativa cumulata di 0.5.

Per calcolare la mediana si ipotizza che le unità siano uniformi nella classe mediana per cui i segmenti della curva di graduazione sono rette ascendenti.



La retta AB ha equazione

$$X = L_e + \frac{(F - F_{e-1})}{h_e}$$

$$M_e = L_e + \frac{(0.5 - F_{e-1})}{h_e}; \quad \text{per "e" tale che } F_e = \text{Min}_{1 \leq j \leq k} \{F_j \geq 0.5\}$$

A.T. Fecit

Esempio

Uno studio di consulenza ha classificato le operazioni di auditing per la revisione dei conti annuali secondo la durata in giorni. Calcolo della mediana

Durata	Revisioni	f_i	F_i
5	7	5	0.0595
8	10	9	0.1667
10	14	14	0.3333
15	19	18	0.2143
20	24	15	0.1786
25	29	12	0.1429
30	34	11	0.1310
	84	1.0000	

$$M_e = 15 + \frac{(0.5 - 0.3333)}{0.2143/4} = 18.11$$

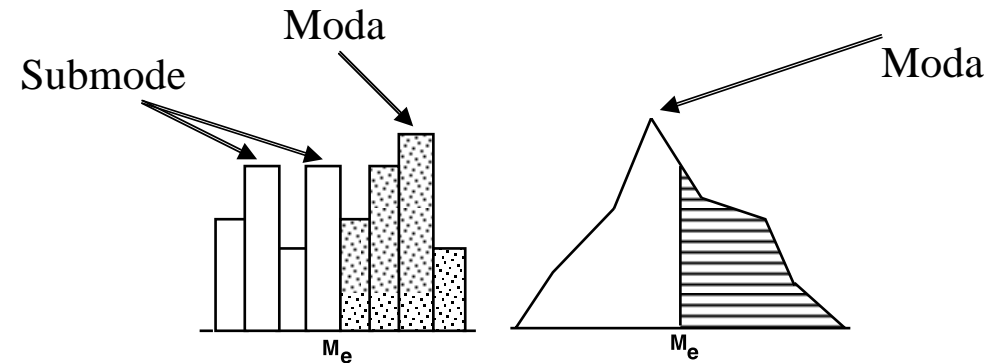
Il calcolo della mediana avviene in due passi:

- 1) Si individua la classe mediana
- 2) Si interpola per ottenere il valore puntuale.

A.T. Fecit

Individuazione grafica

La mediana corrisponde alla retta $X=M_e$ che separa due parti uguali dell'istogramma o dell'area sottesa al poligono di frequenza (se le classi hanno uguale ampiezza).



A.T. Fecit

I quantili

L'idea di valori di soglia che suddividano le modalità in particolari gruppi può essere generalizzata definendo il quantile di ordine "p"

Modalità discrete

$$X_p = (1 - \gamma)X_{(i)} + \gamma X_{(i+1)}, \quad 0 < p < 1; \quad i \leq np < i+1; \quad \gamma = \begin{cases} 0.5 & \text{se } [np] = np \\ 1 & \text{se } [np] < np \end{cases}$$

Modalità continue non in classi

$$X_p = (1 - \gamma)X_{(i)} + \gamma X_{(i+1)} \quad i = [np + 0.5]; \quad \gamma = np + 0.5 - i$$

Modalità dense o continue in classi

$$X_p = (1 - \gamma)L_i + \gamma U_i = L_i + \gamma(U_i - L_i); \quad F_{i-1} \leq p < F_i; \quad \gamma = \frac{p - F_{i-1}}{F_i - F_{i-1}}$$

il quantile supera il p% delle modalità ed è superato dall' (1-p)%

A.T. Fecit

Esempi

Discrete o dense singole

Consideriamo le n=18 rilevazioni degli arrivi di auto ad un punto di imbarco e calcoliamo il quantile del 17%.

$$n * p = 18 * 0.17 = 3.06 \Rightarrow [np] < np \Rightarrow \gamma = 1$$

$$X_{0.17} = 0 * X_{(3)} + 1 * X_{(4)} = X_{(4)} = 744$$

612	623	666	744	883	898
964	970	983	1003	1016	1022
1029	1058	1085	1088	1122	1135

Continue singole

Principali coltivazioni agricole delle Marche. Anno 1998. Valori in ettari. Calcolo del quantile di ordine 0.60

$$n * p = 9 * 0.60 = 5.4 \Rightarrow i = [5.4 + 0.5] = [5.9] = 5;$$

$$\gamma = 5.9 - 5 = 0.9$$

$$X_{0.6} = 0.1 * X_{(5)} + 0.9 * X_{(6)} = 23'300.$$

Coltivazione	Superficie		
Pomodoro	1'304	Mais ibrido	14'558
Pesca	1'486	Uva da vino	24'272
Cavolfiore	1'967	Grano tenero	36'553
Olivo	6'218	Girasole	38'281
		Grano duro	123'049

A.T. Fecit

Esempi

Modalità in classi

Dimensioni delle operazioni di fusione e di acquisizione in Italia per fatturato.
Calcolo di $X_{0.80}$.

Fatturato	Operazioni	f_i	F_i
1	5	30	0.2804
5	20	36	0.6168
20	40	14	0.7477
40	60	10	0.8411
60	100	12	0.9533
100	150	5	1.0000
	107	1.0000	


$$X_{0.80} = 40 + \frac{(0.80 - 0.7477)}{(0.0935 / 40)} = 51.19$$

A.T. Fecit

Uso dei quantili

In genere, i quantili si utilizzano come soglie di separazione delle modalità in gruppi di numerosità prestabilita.

Fra i più usati sono da annoverare i **tre quartili** che suddividono le modalità in quattro gruppi ciascuno comprendente il 25% delle modalità:



Q1 supera il 25% ed è superato del 75%, Q2 coincide con la mediana ed è superato da tante unità quante ne supera esso stesso; Q3 supera il 75% delle unità ed è superato dal restante 25%.

Tra due soglie è sempre compreso il 25% di unità.

A.T. Fecit

Esempio

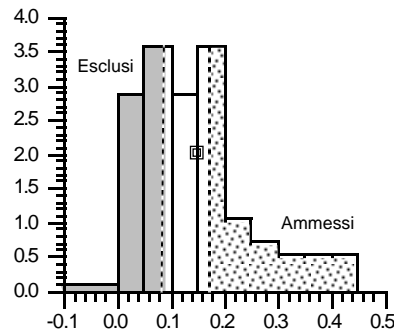
L'esito di una selezione per l'ammissione ad un corso universitario a numero chiuso è riassunto nella tabella.

La commissione decide di ammettere il 40% con punteggio più alto, di escludere il 25% inferiore e di sottoporre il restante 35% a dei test supplementari. Quali sono le soglie di divisione?

$$X_{0.25} = 0.05 + \left(\frac{0.25 - 0.152}{0.205} \right) (0.10 - 0.05) = 0.0843;$$

$$X_{0.60} = 0.15 + \left(\frac{0.60 - 0.536}{0.143} \right) (0.20 - 0.15) = 0.1724$$

Punteggio	Candidati	f_i	F_i
<0.00	1	0.009	0.009
0.00	0.05	16	0.143
0.05	0.10	23	0.205
0.10	0.15	20	0.179
0.15	0.20	16	0.143
0.20	0.25	20	0.179
0.25	0.30	6	0.054
0.30	0.35	4	0.036
0.35	0.40	3	0.027
>0.40	3	0.027	1.000
	112	1.000	



A.T. Fecit


La media aritmetica

E' la media per antonomasia, quella che si sottintende se non si qualifica ulteriormente il termine di media.

$$\bar{X} = \sum_{i=1}^k X_i f_i = X_1 f_1 + X_2 f_2 + \dots + X_k f_k$$

La media aritmetica è il punto di equilibrio fisico delle modalità spaziate in base al loro valore numerico e pesate con le frequenze relative:

x_i	n_i	f_i
-5	1	1/9
-1	1	1/9
0	1	1/9
3	1	1/9
4	1	1/9
5	1	1/9
7	3	3/9
	9	



A.T. Fecit

Esempio

Numero di figli maschi in famiglie di otto figli

Maschi x_i	Famiglie n_i	Freq. Rel. f_i	Prodotti $x_i f_i$
0	161	0.0042	0.0000
1	152	0.0304	0.0304
2	3957	0.1043	0.2086
3	7603	0.2004	0.6012
4	10263	0.2705	1.0821
5	8498	0.2240	1.1200
6	4984	0.1314	0.7883
7	1055	0.0278	0.1947
8	264	0.0070	0.0557
	37937	1.0000	4.0809

Da notare che si può calcolare moltiplicando le modalità per le frequenze assolute e poi dividendo l'ammontare ottenuto per il totale delle frequenze

A.T. Fecit

Proprietà della media aritmetica

La media aritmetica, se sostituita alle modalità, mantiene inalterato l'ammontare complessivo nella rilevazione.

Il totale delle modalità è infatti: $T = \sum_{i=1}^k x_i n_i$

Se al posto di X_i si pone la media aritmetica si ottiene

$$\sum_{i=1}^n \bar{X} n_i = \bar{X} \sum_{i=1}^n n_i = \bar{X} n = \frac{T}{n} n = T$$

Quindi la media aritmetica è quella quantità che ciascuna unità avrebbe se tutte avessero la stessa parte di variabile.

A.T. Fecit

Internalità

Considerando le modalità in senso ascendente saranno vere le relazioni:

$$\sum_{i=1}^k X_{\min} f_i \leq \sum_{i=1}^k X_i f_i \leq \sum_{i=1}^k X_{\max} f_i$$

Ogni addendo della prima somma è inferiore o uguale ad ognuno della seconda che a loro volta sono inferiori o uguali a quelli della terza.

Ne consegue che:

$$X_{\min} \sum_{i=1}^k f_i \leq \sum_{i=1}^k X_i f_i \leq X_{\max} \sum_{i=1}^k f_i \Rightarrow X_{\min} \leq \sum_{i=1}^k X_i f_i \leq X_{\max}$$

A.T. Fecit

Somma nulla degli scarti

La media aritmetica rende nulla la somma degli scarti tra le modalità e la media.

$$\sum_{i=1}^k (X_i - \bar{X}) f_i = \sum_{i=1}^k X_i f_i - \sum_{i=1}^k \bar{X} f_i = \sum_{i=1}^k X_i f_i - \bar{X} \sum_{i=1}^k f_i = \sum_{i=1}^k X_i f_i - \bar{X} n = \bar{X} n - \bar{X} n = 0$$

ESEMPIO

Numero di dipendenti formati nei comuni e nelle province per settori.

Area	Dipendenti	Scarto
Interventi settoriali	15913	5887
Managerialità	10801	775
Organizzazione	10711	685
Controllo di gestione	9362	-664
Informatizzazione	3938	-6088
Gestione del personale	9431	-595
Totale	60156	0

La media aritmetica è $\bar{X} = 10026$ che, annullando la somma degli scarti, si conferma valore di equilibrio per la distribuzione.

A.T. Fecit

Minimo della somma degli scarti al quadrato

$$\begin{aligned} \sum_{i=1}^k (X_i - A)^2 f_i &= \sum_{i=1}^k [(X_i - \bar{X}) + (\bar{X} - A)]^2 f_i \\ &= \sum_{i=1}^k [(X_i - \bar{X})^2 + (\bar{X} - A)^2 + 2(\bar{X} - A)(X_i - \bar{X})] f_i \\ &= \sum_{i=1}^k (X_i - \bar{X})^2 f_i + \sum_{i=1}^k (\bar{X} - A)^2 f_i + 2(\bar{X} - A) \sum_{i=1}^k (X_i - \bar{X}) f_i \\ &= \sum_{i=1}^k (X_i - \bar{X})^2 f_i + \sum_{i=1}^k (\bar{X} - A)^2 f_i \end{aligned}$$

Il terzo termine risulta nullo per la proprietà già dimostrata della media aritmetica di annullare la somma degli scarti semplici.

$$= \sum_{i=1}^k (X_i - \bar{X})^2 f_i + (\bar{X} - A)^2$$

il primo addendo non dipende da "A" il 2° è semplicemente un quadrato che ha il minimo nello zero raggiunto per $A = \bar{X}$

A.T. Fecit

Riproducibilità per trasformazioni lineari

Quando la variabile x subisce una trasformazione lineare del tipo $y = a + bx$ lo stesso succede alla media aritmetica.

$$\text{Infatti: } \bar{Y} = \sum_{i=1}^k Y f_i = \sum_{i=1}^k (a + bX_i) f_i = \sum_{i=1}^k a f_i + b \sum_{i=1}^k X_i f_i = a + b\bar{X}$$

ESEMPIO

Bilancio delle principali squadre di calcio di serie A (in milioni). Conversione in migliaia di dollari.

Squadre	M. Lire	m. Dollari
Juventus	1847	947.18
Milan	-27093	-13893.85
Inter	-21442	-10995.90
Roma	504	258.46
Parma	-25418	-13034.87
Lazio	251	128.72
Fiorentina	-10579	-5425.13
Sampdoria	-879	-450.77
Bologna	-8822	-4524.10
	-10181.22	-5221.14

il rapporto di conversione tra milioni di lire e migliaia di dollari è:

$$a = 0.0, \quad b = \frac{1000}{1950} = 0.512821$$

$$\bar{X} = -10181.22, \quad \bar{Y} = 0.512821 * (-10181.22) = -5221.14$$

A.T. Fecit

Proprietà associativa

Supponiamo di individuare "g" gruppi. Le modalità sono individuate con due indici: il primo per il gruppo ed il secondo per le unità del gruppo:

Gruppi	Valori		Unità	
G_1	X_{11}	X_{12}	X_{1k_1}	n_1
G_2	X_{21}	X_{22}	X_{2k_2}	n_2
\vdots				
G_g	X_{g1}	X_{g2}	X_{gk_g}	n_g

$\sum_{i=1}^g n_i = n$

Per ogni gruppo si può calcolare la propria media aritmetica

$$\mu_i = \frac{\sum_{j=1}^{n_i} X_{ij}}{n_i}; \quad i = 1, 2, \dots, g$$

A.T. Fecit

Proprietà associativa/2

La proprietà associativa consente di ricavare la media aritmetica complessiva:

$$\mu = \frac{\sum_{i=1}^g \sum_{j=1}^{n_i} X_{ij}}{n} = \frac{\sum_{i=1}^g n_i \frac{\sum_{j=1}^{n_i} X_{ij}}{n_i}}{n} = \frac{\sum_{i=1}^g n_i \mu_i}{n} = \sum_{i=1}^g \mu_i f_i$$

ESEMPIO

Per tre diverse aree si è considerato il consumo medio annuo di zucchero.

Aree	Unità	Medie
Zona_A	647	115
Zona_B	173	80
Zona_C	435	75
totale	1255	?

$$\bar{X} = \frac{647}{1255} * 115 + \frac{173}{1255} * 80 + \frac{435}{1255} * 75 = 96.31$$

A.T. Fecit

Modalità raggruppate in classi

E' un caso particolare della proprietà associativa.

Purtroppo le medie aritmetiche di classe non sono note ed occorre stimarle.

La tecnica più usata è quella di adoperare il valore centrale delle classi:

$$\bar{X}_i = \frac{1}{2}L_i + \frac{1}{2}U_i \quad i = 1, 2, \dots, k$$

ESEMPIO

Casi di epatite A in un comune.

Età	Pazienti	c_i	f_i	Xif_i
≤9	662	6.75	0.5400	3.6448
10 - 19	420	14.50	0.3426	4.9674
20 - 29	117	24.50	0.0954	2.3381
30 - 39	18	34.50	0.0147	0.5065
40 - 49	5	44.50	0.0041	0.1815
≥50	4	52.25	0.0033	0.1705
	1226		1.0000	11.8087

Le classi estreme hanno un'ampiezza pari alla metà delle ampiezza delle classi loro continue.

A.T. Fecit

Le medie di potenze

La media aritmetica rientra in una classe che fornisce una espressione dell'ordine di grandezza del fenomeno a partire da tutti i valori riscontrati:

$$M(X_1, \dots, X_k; f_1, \dots, f_k; \alpha) = \left\{ \sum_{i=1}^k X_i^\alpha f_i \right\}^{1/\alpha}$$

Che scaturiscono dal principio di Chisini:

La misura di centralità deve lasciare invariato un particolare aspetto del fenomeno allorché al posto di ogni X_i si sostituisce "M":

Ad esempio, la media aritmetica posta in vece di ciascuna modalità lascia invariato l'ammontare complessivo delle rilevazioni

$$\sum_{i=1}^k \bar{X} n_i = \bar{X} \sum_{i=1}^k n_i = \frac{\sum_{i=1}^k X_i n_i}{n} * n = \sum_{i=1}^k X_i n_i = T$$

A.T. Fecit

La media geometrica

E' una media particolarmente adatta come misura di centralità per fenomeni evolutivi che si realizzano proporzionalmente al livello già raggiunto.

Formula classica

$$M_g = \prod_{i=1}^k x_i^{f_i} = x_1^{f_1} * x_2^{f_2} * \dots * x_k^{f_k} \quad \text{per } x_i > 0$$

Formula per il calcolo

$$M_g = e^{\left\{ \frac{\sum_{i=1}^k f_i \ln(x_i)}{n} \right\}}$$

Esempio.

x_i	n_i	f_i	$\ln(x_i)$	$f_i \ln(x_i)$
1	2	2/10	0.0000	0.0000
3	1	1/10	1.0986	0.1099
4	1	1/10	1.3863	0.1386
5	1	1/10	1.6094	0.1609
6	1	1/10	1.7918	0.1792
7	1	1/10	1.9459	0.1946
9	3	3/10	2.1972	0.6592
	10			1.4424

$$M_g = e^{1.4424} = 4.2308$$

A.T. Fecit

Proprietà della media geometrica

E' meno soggetta a variazioni rispetto alla loro media aritmetica:

X_i	2	4	8	16	32	64	128	256	512	1024	2048
$\log(X_i)$	0.3010	0.6021	0.9031	1.2041	1.5051	1.8062	2.1072	2.4082	2.7093	3.0103	3.3113

G=45.25 supera ed è superata dallo stesso numero di valori rispetto alla media aritmetica: $\mu=204$ che ne supera sette ed è superata solo da tre.

A.T. Fecit

La media armonica

Si tratta di un indice posizione da utilizzare soprattutto per misurare la centralità in situazioni in cui interessa il contributo delle modalità alla composizione di un tutto.

$$H = \frac{1}{\sum_{i=1}^k \frac{f_i}{X_i}}; \text{ per } X_i \neq 0$$

Figli	Famiglie	f_i	$(1/X_i)f_i$
1	185	0.5362	0.5362
2	78	0.2261	0.1130
3	33	0.0957	0.0319
4	25	0.0725	0.0181
5	13	0.0377	0.0075
6	8	0.0232	0.0039
7	3	0.0087	0.0012
345		1.0000	0.7119

Per calcolare la media armonica si calcola prima la media aritmetica di reciproci e di questa si calcola il reciproco:

$$H = \frac{1}{0.7119} = 1.4047$$

Valori anomali e medie

La presenza di valori isolati rispetto al resto della distribuzione ha una incidenza diversa a secondo della media che si usa

A	5	8	9	9	10	11	12	15	20	← valore isolato
B	5	8	9	9	10	12	12	15	2013	

μ passa da 11 a 210

La media geometrica cresce, ma meno della media aritmetica e più della armonica.

La mediana, non cambia (al massimo si sposta di una posizione)

La moda non cambia (il valore isolato per definizione non può fare moda)

Valori remoti (outlier)

sono valori (uno o più) che appaiono inusuali senza che li si possa ritenere errati

Ciò dipende dal contesto:

{5, 13, 2, **291**, 11, 6}

Non è un outlier né un errore tipografico: numero di clienti in coda ad uno sportello

{3.6, 2.7, 2.8, 3.9, 2.1, **85.8**, 3.4, 2.8}

Peso alla nascita di un campione di neonati. E' anomalo se si tratta di persone

Valori remoti /2

Dato un insieme di modalità quantitative, una di esse sarà maggiore delle altre ed un'altra sarà minore;

se gli estremi sono molto remoti nascerà il sospetto di disfunzioni:

Attenzione! Se un fenomeno può produrre modalità estremamente piccole e/o estremamente grandi è inevitabile che qualcuno si mostri prima o poi.

una ASL ha storicamente richiesto il rimborso di un numero mensile di parti cesarei con complicazioni che oscilla tra i 20 ed i 30. Un dato mese, richiede rimborsi per 120.



Questo non necessariamente è un dato anomalo, ma è la spia di un cambiamento nel meccanismo dei rimborsi o nel management della ASL.