

Statistica 1 - Teoria



Lezione 1 - 4/10/21

Intro : **cos'è la Statistica**

: disciplina che tratta, con linguaggio matematico, principi e metodi che sono d ausilio all'**indagine sperimentale**, condotta da altre discipline.

Interviene, in modo astratto e generale, rispetto ai risultati sperimentali (per ottenerli/interpretarli), a prescindere dai contenuti delle altre discipline.

La variabilità accidentale per fenomeni ripetibili

La statistica studia fenomeni aleatori **ripetibili**

possono manifestarsi più volte rimanendo **fissi** nei loro aspetti essenziali

Le manifestazioni risultano però **diverse** di volta in volta e in modo **imprevedibile**, in base agli aspetti fissi e noti

presentano **variabilità accidentale**

Si distinguono due classi di fenomeni aleatori ripetibili:

A Fenomeni caratterizzati da **ripetibilità virtuale**

: possono manifestarsi idealmente infinite volte, in base ad un meccanismo che li genera, che chiamiamo circostanze, il quale nonostante sia costante (per quanto si sappia) produce risultati variabili.

Esempio: lancio della moneta:

- ① se la si lancia a mano, l'esito sarà circa 50 e 50; le circostanze tuttavia non sono davvero costanti, in quanto non è possibile garantire uguali lanci a mano successivi.
- ② assumiamo allora di lanciare tramite una macchina: il lancio ora sarà costante, la variabilità accidentale ridotta, ma non annullata, in quanto l'esito del fenomeno dipenderà anche da altri elementi, come densità dell'aria e irregolarità del piano.
- ③ ipotizziamo allora la macchina sottovuoto e il piano perfettamente liscio: elimineremo altra variabilità, ma comunque non del tutto. Ss

Morale : origine della variabilità accidentale : le circostanze si assumono costanti quando in realtà non lo sono realmente

Eliminare variabilità accidentale \Leftrightarrow descrivere e conoscere con estrema precisione il fenomeno

(a volte può essere inutile e/o molto costoso

Due approcci:

① Punto di vista **deterministico**

Si cerca di eliminare la variabilità (necessario in alcuni problemi es. sicurezza centrali nucleari)

② Punto di vista **statistico**

Si accetta la variabilità accidentale e si cerca di creare un modello di previsione delle future manifestazioni che tengono conto delle circostanze che si conoscono e della potenziale variabilità

Ibrido: in molti casi reali, se la variabilità è eccessiva la si cerca di ridurla ad un livello accettabile eliminandone alcune cause, poi si crea il modello.

B Fenomeni caratterizzati da **ripetibilità attuale**

fenomeni aleatori ripetibile le cui realizzazioni si sono già manifestate all'istante di inizio dello studio

es. demografia: se studio caratteristiche antropometriche di un gruppo di individui, esse si sono già "manifestate", in quanto si trovano come dati anagrafici su Istat ecc.

In questo caso, a generare variabilità accidentale è l'**incompletezza** delle specificazioni: le specificazioni che non sono conosciute allo statistico ma che influenzano la manifestazione del fenomeno

es. fenomeno da studiare = reddito di operai: dipende da molti fattori; magari quelli a disposizione dello statistico non sono sufficienti a spiegare la variabilità del reddito (=manifestazione del fenomeno)

⇒ si ha variabilità accidentale (concettualmente uguale a ripetibilità virtuale)

reciproco di circostanze

Anche qui due approcci: ① approfondire tantissimo lo studio per avere tutte le informazioni necessarie a spiegare la variabilità (molto costoso / impossibile)

② accettare la variabilità accidentale

Quindi: la statistica tenta di scoprire la componente **strutturale** di un fenomeno ripetibile, accettando la variabilità accidentale causata dall'incompletezza di informazioni/conoscenza.

Tipologie di variabili/caratteri/dati

Qualitativo = esprime una caratteristica del fenomeno qualitativamente, attraverso sostantivi, **aggettivi** (in generale: a parole)

Ordinabile = le modalità del carattere possono essere espresse in scala ordinale, secondo un criterio "naturale", o comunque universalmente riconosciuto.
es: titolo di studio, piramide aziendale, ...

Scnesso = le modalità del carattere sono esprimibili su scala nominale, o comunque non secondo criteri di ordine "naturale" o universalmente riconosciuto.
es: comune di residenza, colori, sesso, punti cardinali, ...

Si usano due scale per i caratteri qualitativi:

- ① Scala **nominale**: le modalità sono aggettivi (/ sostantivi/avverbi)
NON ORDINABILI (qual. sconnessi)
(non posso dire $x_1 \geq x_2$, ma solo se $x_1 = x_2$ o $x_1 \neq x_2$)
- ② Scala **ordinale**: le modalità sono " "
ORDINABILI (qual. ordinabili)
(posso dire $x_1 \geq x_2$)

Quantitativo = modalità espresse da numeri reali, nella forma di misurazioni o conteggi. Descrivono una proprietà oggettiva dell'unità statistica.

Continuo = definito in un insieme di numeri reali
es: peso, statura, tempo, ...

Discreto = definito in un insieme di numeri interi

Per definizione vi è un **ordinamento** delle modalità.

Con i caratteri quantitativi, è possibile ^{ha senso} effettuare le seguenti operazioni:

Siano x_i = modalità del carattere X ; allora hanno senso le operazioni:

$$x_1 = x_2 ; x_1 \neq x_2 ; x_1 \geq x_2 ; \text{distanza} = |x_2 - x_1| = |x_1 - x_2|$$

Si possono adottare, con i caratteri quantitativi, due diverse scale:

- ① **Scala a intervalli**:
 - lo zero è convenzionale, arbitrario (intervallare)
 - es: temperatura in scala Celsius, Fahrenheit : lo 0 è diverso

Non ha senso valutare gli incrementi percentuale: $\frac{x_2}{x_1}$

- ② **Scala di rapporti** (proporzionali):
 - lo zero è oggettivo, ed indica assenza di quantità
 - il valore della modalità è sempre $\neq 0$

es: grandezze fisiche, valuta*, ... Infatti: $0 \text{ kg} = 0 \text{ libbre}$; $0 \text{ €} = 0 \text{ \$}$

Ha senso valutare la variazione percentuale $\frac{x_2}{x_1}$

*NB: la valuta diventa negativo, ma in realtà se le mie spese superano le entrate è possibile perché auro preso in prestito

Lezione 3 - 7/10/21

Spoglio dei dati

: organizzazione dei dati in tabelle sintetiche.

Consideriamo per ora una variabile alla volta : statistica UNIVARIATA.

Tabella-tipo riportante la **DISTRIBUZIONE DI FREQUENZE** :

x_i	n_i	$f_i = n_i/n$
x_1	n_1	$n_1/n = f_1$
x_2	n_2	$n_2/n = f_2$
...
x_m	n_m	$n_m/n = f_m$
Totale	n	1

x_i : MODALITÀ assunte dal carattere X
= manifestazioni della variabile statistica X

n_i : FREQUENZE ASSOLUTE per ogni modalità x_i ;
conta quante volte appare la modalità i-esima

f_i : FREQUENZE RELATIVE per ogni modalità x_i ;
misura relativa della frequenza di manifestazione della modalità i-esima

Freq. **assolute** n_i $\left\{ \begin{array}{l} n_i \geq 0 \\ \sum_{i=1}^m n_i = n = \text{numero totale di osservazioni} \end{array} \right.$

Freq. **relative** $f_i = \frac{n_i}{n}$ $\left\{ \begin{array}{l} 0 \leq f_i \leq 1 \\ \sum_{i=1}^m f_i = 1 \end{array} \right.$

Freq. relative **PERCENTUALI** $p_i\% = f_i \cdot 100$ $\left\{ \begin{array}{l} 0 \leq p_i \leq 100 \\ \sum_{i=1}^m p_i = 100 \end{array} \right.$

NB : a volte una variabile qualitativa viene chiamata MUTABILE.

Es.

X = categoria

(qualitativa ordinabile
=> in tabella si mettono rispettando l'ordine)*

x_i	n_i	f_i	$p_i\%$
Dettagliante	6	0,3	30
Grande distr.	4	0,2	20
Grossista	10	0,5	50
	20	1	100

Es.

X = unità vendute a singolo cliente

L) Quantitativa discreta

x_i	n_i	f_i	$p_i\%$
3	3	3/20	
4	8	8/20	
5	9	9/20	
	20	1	100

* Per le qualitative sconnesse, si mettono in tabella "a caso", in un ordine arbitrario

Per le quantitative continue, bisogna costruire delle CLASSI all'interno dell'intervallo $x_{min} \text{ H } x_{max}$

di AMPIEZZA VARIABILE o FISSA

I_i	n_i	$f_i = n_i/n$	N_i^*	d_i	a_i
$x_0 \text{ H } x_1$	n_1	f_1	$N_1 = n_1$	d_1	a_1
$x_1 \text{ H } x_2$ <i>escluso!</i> <i>incluso!</i>	n_2	f_2	$N_2 = n_1 + n_2$	d_2	a_2
...
$x_{i-1} \text{ H } x_i$	n_i	f_i	$N_i = \sum_{j=1}^i n_j$	d_i	a_i
...
$x_{m-1} \text{ H } x_m$	n_m	f_m	$N_m = n$	d_m	a_m
	n	1			

* N_i = Frequenze CUMULATE ASSOLUTE (prossima pagina)

DENSITÀ DI FREQUENZA $d_i = \frac{n_i}{a_i}$

AMPIEZZA della CLASSE $a_i = x_i - x_{i-1}$

DENSITÀ DI FREQUENZA RELATIVA $d_i^* = \frac{f_i}{a_i}$ (meglio usare d_i)

NB: all'esame sarà richiesto esplicitare la formula che si usa (es. $d_3 = \frac{n_3}{a_3}$)

A volte si usa anche il VALORE CENTRALE DELLA CLASSE $x_{ic} = \frac{x_i - x_{i-1}}{2}$

Es.

X = fatturato

Ampiezza costante delle classi

I_i	n_i	a_i	d_i	x_{ic}
0 - 10	4	10	4/10	5
10 - 20	8	10	8/10	15
20 - 30	4	10	4/10	25
30 - 40	3	10	3/10	35
40 - 50	1	10	1/10	45
	20			

Ampiezza variabile delle classi

I_i	n_i	a_i	d_i
0 - 10	4	10	4/10 = 0,4
10 - 20	8	10	8/10 = 0,8
20 - 30	4	10	4/10 = 0,4
30 - 50	4	20	4/20 = 0,2
	20		

NB! Notare come nel caso:

- di ampiezza costante, le d_i non danno alcuna informazione in più
- di ampiezza variabile, le d_i sono molto rilevanti!

Lezione 4 - 11/10/21

Frequenze cumulate

(i) Assolute N_i : $\{n_i ; i=1, \dots, k\}$

$$N_1 = n_1, \quad N_2 = n_1 + n_2, \quad \dots, \quad N_k = n_1 + n_2 + \dots + n_k = n$$

(ii) Relative F_i : $\{f_i ; i=1, \dots, k\}$

$$F_1 = f_1, \quad F_2 = f_1 + f_2, \quad \dots, \quad F_k = f_1 + f_2 + \dots + f_k = 1$$

NB: usiamo sempre 3 decimali

In formule:

a) Formula compatta : $N_i = \sum_{j=1}^i n_j$ con $j=1, \dots, i, \dots, k$ ↳ indica fino a dove devo sommare
⇒ limite superiore della Σ b) Formula ricorsiva : $N_i = N_{i-1} + n_i$ per $i=2, \dots, k$

Esempio

I_i	n_i	N_i	f_i	F_i
0 - 10	4	4	0,2	0,2
10 - 20	8	12	0,4	0,6
20 - 30	4	16	0,2	0,8
30 - 40	3	19	0,15	0,95
40 - 50	1	20	0,05	1
	20		1	

Grafici

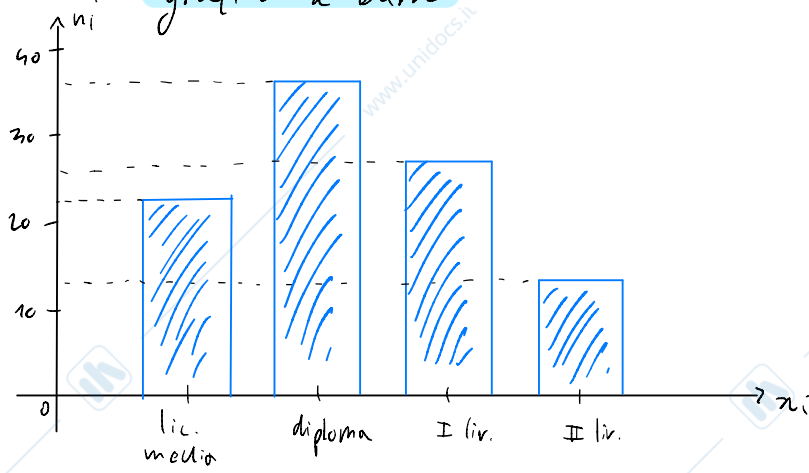
Abbiamo ad ogni tipo di carattere una sola rappresentazione grafica.

NB Consideriamo le frequenze assolute per costruire il grafico; per le relative basta riscalcarlo.

- Qualitativo ordinabile

grafico a barre

x_i	h_i
lic. media	23
diploma	36
laurea 1° liv.	27
laurea 2° liv.	14




Le x_i sono equidistanti, quindi non posso quantificare la distanza, il che mi va bene data la natura qualitativa del carattere.

Il grafico a barre preserva l'ordinamento delle modalità, ma non ne quantifica la distanza.

Qualitativo sconnesso

grafico a torta

x_i	h_i	α_i°
lic. classico	30	62,43°
lic. scientifico	39	81,16°
artistico	16	33,30°
ragioneria	46	95,22°
ist. prof.	42	87,40°
	173	360°




$$\alpha_i^\circ = h_i : n = \alpha_i^\circ : 360^\circ$$

$$\alpha_i^\circ = \frac{h_i \cdot 360^\circ}{n}$$

Quantitativo discreto

grafico a bastoncini

x_i	h_i
0	2
1	2
2	4
3	1
4	1
5	1
	11




ordinabile \Rightarrow piano cartesiano

- Quantitativo continuo : **istogramma** (o "a canne d'organo")

NB classi di pari ampiezza : plottiamo le h_i
 classi di ampiezza diversa : plottiamo le d_i

- Pari ampiezza

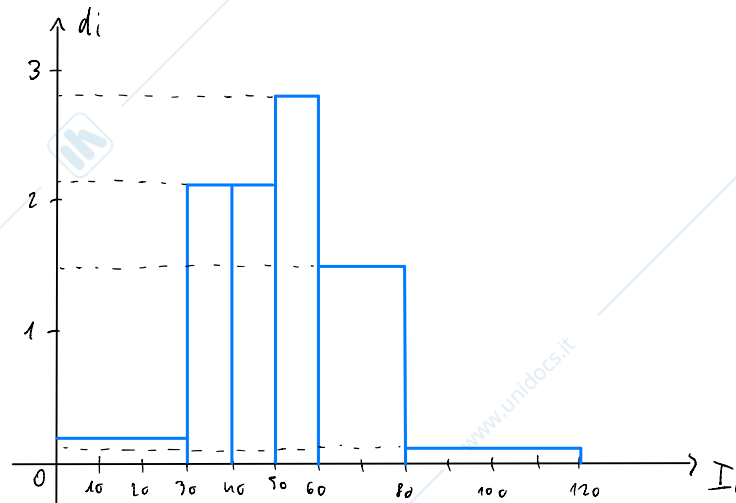
I_i	h_i
0 - 1000	3
1000 - 2000	2
2000 - 3000	5
3000 - 4000	3
4000 - 5000	2
	15



$a_i = 10$ costante

Diversa ampiezza

I_i	h_i	a_i	d_i
0 - 30	6	30	0,2
30 - 40	21	10	2,1
40 - 50	21	10	2,1
50 - 60	27	10	2,7
60 - 80	29	20	1,45
80 - 120	2	40	0,05
	106		



Ampiezza diverse

Notare che se qui avessimo usato le h_i , la classe 60-80 sarebbe stata la più "alta".

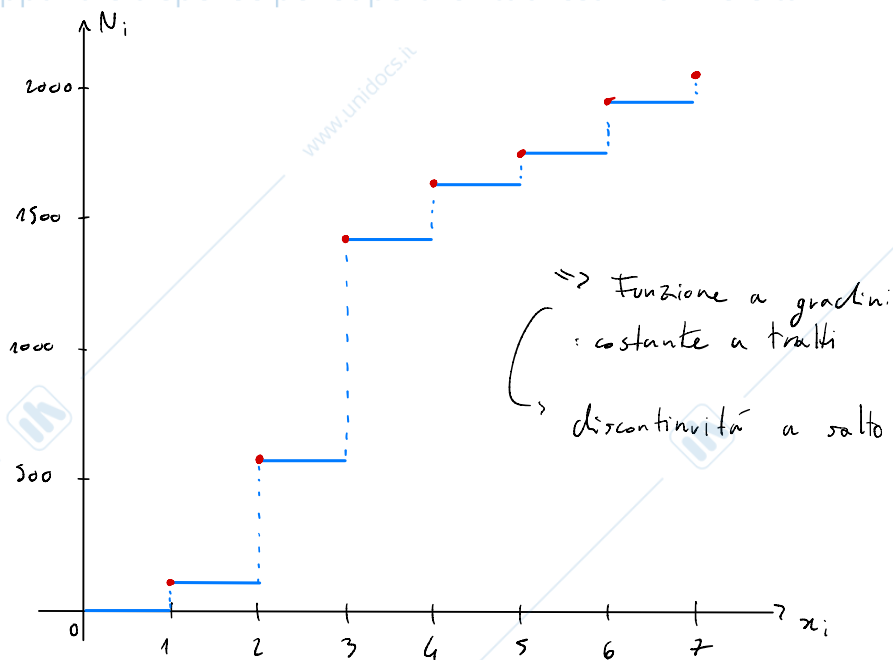
Grafico di frequenze cumulate

: si fa solo per caratteri quantitativi! (per quelli qual. ordinabili ha senso calcolarle, ma non plottarle).

NB Anche qui N_i o F_i cambia solo la scala.

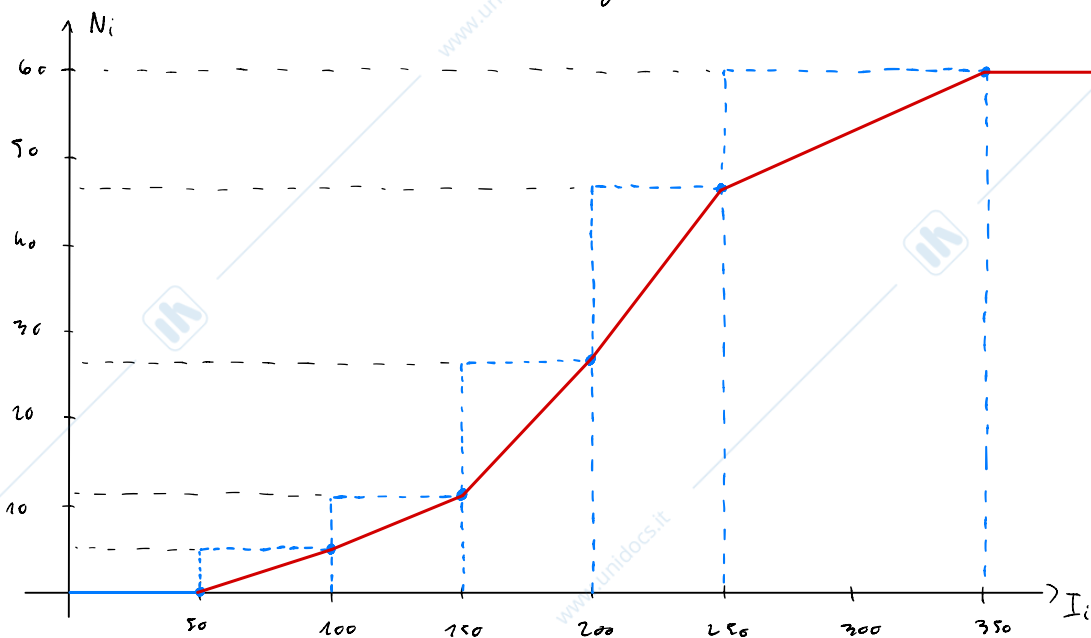
- Quantitativo **discreto**

x_i	h_i	N_i
1	157	157
2	410	567
3	890	1457
4	215	1672
5	120	1792
6	150	1942
7	95	2037
	2037	



- Quantitativo **continuo** (siccome cumulo me ne spezzo delle ampiezze diverse)


I_i	h_i	N_i
50 - 100	5	5
100 - 150	6	11
150 - 200	15	26
200 - 250	20	46
250 - 350	14	60
	60	



Siccome non so come sono distribuite le unità all'interno della classe, ipotizzo siano **equi distribuite** \Rightarrow unisco con la spezzata (che potrei interpolare per ottenere una curva polinomiale).

Altri grafici (cenni)

- Serie storica



\Rightarrow studia l'andamento del fenomeno nel tempo

- Ideogrammi : carini da vedere ma difficili da leggere

- Cartogrammi : usano una cartina geografica, con diversi colori definiti da una legenda

Le Medie

- : sintesi dei dati con la minore perdita d'informazione possibile
- : una media è un indice sintetico "rappresentativo" delle modalità assunte dalla variabile/motabile

Def. sia X una variabile statistica tale che:

$$X = \{x_i; n_i\} \text{ con } i = 1, \dots, r$$

La MEDIA di X è una qualsiasi funzione reale α tale che:

$$\alpha = \alpha(X) = \alpha\{x_1, \dots, x_r; n_1, \dots, n_r\}$$

che soddisfa le seguenti condizioni/proprietà:

① Condizione di Cauchy (o "di internabilità")

$$x_1 \leq \alpha(X) \leq x_r \quad \text{dove } x_1 = x_{\min}, \quad x_r = x_{\max}$$

② Proprietà moltiplicativa ($c = \text{costante}$)

$$\alpha\{cx_1, cx_2, \dots, cx_r; n_1, \dots, n_r\} = \alpha\{cx_i; n_i\} = \alpha(cX) = c \cdot \alpha(X)$$

③ Proprietà di monotonicità

$$\text{se } x_i \geq y_i \quad \forall i \quad \text{allora } \alpha(X) \geq \alpha(Y)$$

[Una media è funzione monotona non decrescente dei valori del carattere.]

Una media "in senso stretto" soddisfa tutte e 3 le proprietà. Se mancano la 2 o la 3 o entrambe si parla di media "in senso lato", mentre la 1 deve sempre essere rispettata.

Moda

- : indice di posizione NON analitico (non ha una formulazione matematica rigorosa \Rightarrow si può usare quasi sempre)
- : è comunque considerata una media, ma non analitica.

Def. Sia X una variabile o motabile statistica qualsiasi

$$\text{allora la MODA di } X \text{ è: } Mo(X) = \tilde{x} = \{x_j; n_j = \max n_i\}$$

Quindi la moda coincide con la (una) modalità a cui è associata la massima frequenza (assoluta/relativa/densità).

Nel caso di variabili quantitative continue, la classe I_j a cui è associata la massima densità di frequenza sarà la **CLASSE MODALE**:

Classe modale I_j : $d_j = \max d_i$

La MODA allora coinciderà con il valore centrale della classe modale I_j :

$$M_o(x) = \frac{x_{\max} - x_{\min}}{2} \quad \text{dove } x_{\max} \text{ e } x_{\min} \text{ sono gli estremi della classe modale.}$$

La Moda può quindi essere calcolata con qualsiasi tipo di carattere.

Lezione 6 -

Proprietà della Moda

- ① Cauchy : la Moda la rispetta sempre : $x_{\min} \leq \tilde{x} \leq x_{\max}$
- ② Moltiplicativa : la Moda la rispetta sempre
(anche se ovviamente non si applica alle mutabili)
- ③ Monotonicità : non sempre rispettata, in quanto la monotonicità riguarda il valore delle modalità, mentre la Moda le loro frequenze associate.

es.

$$X = \{ \underline{1, 1}, \underline{2, 2, 2, 2}, \underline{3, 3, 3}, \overline{3, 3, 3}, \overline{4} \}$$

$$Y = \{ \underline{1, 1}, \underline{2, 2, 2, 2}, \underline{3, 3, 3}, \overline{4, 4, 4} \}$$

$$\Rightarrow y_{10} > x_{10} \quad | \quad y_{11} > x_{11}$$

x_i	n_i	y_i	n_i
1	2	1	2
2	4	2	4
3	5	3	3
4	1	4	3
	12		12

$$\Rightarrow M_o(x) = 3 > M_o(y) = 2$$

\Rightarrow Nonostante $y_i > x_i$, $M_o(x) > M_o(y) \Rightarrow$ Monotonicità violata

Esempio

x_i	n_i
Punti di vendita provinciale	
Varese	141
Como	247 *
Sondrio	78
Milano	249 *
Bergamo	250 *
Brescia	206
Pavia	190
Cremona	115
Mantova	70
Totale	1546

$$Mo(X) = \text{Bergamo}$$

NB caso considerabile come POLIMODALE: più di una Moda.

⇒ formalmente la $Mo(X)$ è Bergamo, ma Como e Milano presentano una differenza di fatto irrilevante considerata la instabilità in questione (qualitativa sconnessa).

NB si nota il carattere incerto che assume il concetto di Moda come "modalità tipica".

Esempio

$X = \text{paghetta}$ (⇒ quantitativo continuo)

I_i	n_i	a_i	d_i
0 - 8	140	8	12,5
8 - 12	136	4	34
12 - 18	180	6	30
18 - 24	150	6	25
24 - 28	90	4	22,5
	696		

$$\text{Classe modale} = 8 - 12$$

$$Mo(X) = \frac{12 + 8}{2} = 10$$

Mediana

indice di posizione non analitico

calcolabile solo con caratteri ordinabili (⇒ NO qualitativi sconnessi)

è una media in senso stretto

Def. La Mediana di X corrisponde al valore assunto da X che BIPARTISCE la distribuzione:

$$Me(X) = \hat{x} = \left\{ \hat{x} : \left[\sum_{x_i \leq \hat{x}} f_i \geq 0,50 \right] \wedge \left[\sum_{x_i \geq \hat{x}} f_i \geq 0,50 \right] \right\}$$

Quindi: la $Me(X)$ è quel valore superato e non superato da almeno il 50% delle modalità.

Calcolo: - n pari: $\frac{n+1}{2}$ = posizione occupata da $Me(X)$

[= $Me(X)$ in caso di frequenze unitarie]

- n pari: $\frac{n}{2} = a$, $\frac{n}{2} + 1 = b$

$\frac{a+b}{2}$ = posizione occupata da $Me(X)$ [oppure]

es.

x_i	n_i	p_i	F_i	R_i
1	4	0,2	0,2	1
2	5	0,25	0,45	0,8
3	3	0,15	0,60	0,55
4	6	0,3	0,90	0,4
5	2	0,1	1	0,1
	20	1		0

$R_i = \text{Retrocumulate}$: si parte da 1 e si sottraggono le p_i

$x_i = 3$ "contiene" il 50% delle modalità sia con le F_i che con le R_i

$\Rightarrow x_i = 3$ supera e non supera il 50% delle modalità

$\Rightarrow Me(X) = 3$


Metodo alternativo (per n pari) = semisomma

$\Rightarrow n = 20 = \text{pari}$ quindi non c'è un unico valore centrale che bipartisce la distribuzione

\Rightarrow semisomma dei 2 valori centrali che bipartiscono

$$\frac{n}{2} = \frac{20}{2} = 10 = a \quad \frac{n}{2} + 1 = 11 = b \quad \frac{a+b}{2} = \frac{10+11}{2} = 10,5$$

$\Rightarrow Me(X)$ sarà la modalità che occupa la posizione 10,5



Esempio

x_i	n_i	p_i	F_i	R_i
INS.	6	0,207	0,207	1
SUFF.	10	0,345	0,552	0,743
Buono	8	0,276	0,828	0,468
OTTIMO	5	0,172	1	0,172
	29	1		0

$Me(X) = \text{SUFF}$

\Rightarrow comprende in entrambi i casi almeno il 50% della distribuzione

Attenzione: nel caso di caratteri quantitativi continui, i valori mediani sono potenzialmente infiniti, ma noi vogliamo un numero.

Si deriva allora geometricamente una formula.

Formula: $Me(x) = L_{inf} + \frac{0,5 - F_{inf}}{f_i} \cdot a_i$

dove: L_{inf} = limite inferiore della classe mediana

F_{inf} = F_i della classe precedente a quella mediana

f_i = f_i della classe mediana

a_i = ampiezza della classe mediana

Esempio

I_i	n_i	a_i	f_i	F_i	R_i
0 - 10	20	10	0,357	0,357	1
10 - 20	14	10	0,25	0,607	0,6427
20 - 30	9	10	0,1607	0,7678	0,3427
30 - 40	6	10	0,107	0,875	0,232
40 - 50	7	10	0,125	1	0,125
	56		1		0

Classe mediana = 10 - 20

$Me(x) = 10 + \frac{0,5 - 0,357}{0,25} \cdot 10 = 15,72$

Quantili e Percentili

generalizzazione della Mediana

Def. Dato p : $0 < p < 1$, il P-PERCENTILE (o p-quantile) x_p

è il valore che delimita il primo $p\%$ delle osservazioni (ordinate in senso crescente e le separa dal restante $(1-p)\%$:

$x_p = \left\{ x_p : \left[\sum_{x_i \leq x_p} f_i \geq p \right] \wedge \left[\sum_{x_i > x_p} f_i \geq (1-p) \right] \right\}$

es. $p = 0,5$ $x_{0,5}$ = Mediana : 5° percentile = 2° quartile

$p = 0,25$ $x_{0,25}$ = 1° quartile = modalità che supera almeno il 25% delle modalità ed è superata da almeno il 75% delle stesse.

$p = 0,1$ $x_{0,1}$ = 10° percentile = 1° decile

$p = 0,75$ $x_{0,75}$ = 3° quartile

⋮

Medie algebriche o "potenziate"

: indici di posizione analitici

: solo per variabili quantitative continue

Formula generica: $M_{(k)} = \left(\frac{1}{n} \sum_{i=1}^n m_i x_i^k \right)^{1/k} = \left(\sum_{i=1}^n f_i x_i^k \right)^{1/k}$

NB: $x_i > 0$

Medie potenziate ricorrenti:

- $k = 1$ Media aritmetica
- $k = 2$ Media quadratica
- $k = -1$ Media armonica
- $\lim_{k \rightarrow 0} \mu_k \rightarrow \mu_0$ Media geometrica

Media aritmetica ($k = 1$)

$$\mu_{(1)} = \frac{\sum_{i=1}^n x_i m_i}{n} = \sum_{i=1}^n f_i x_i \quad \text{NB: } x_i > 0 \text{ è } \underline{\text{inessenziale}}$$

Media armonica ($k = -1$)

$$\mu_{(-1)} = \left(\sum_{i=1}^n f_i x_i^{-1} \right)^{-1} = \frac{1}{\sum_{i=1}^n f_i \cdot \frac{1}{x_i}}$$

NB: $x_i \neq 0$

NB: $x_i > 0$

rischio di compensazione delle x_i con conseguente valore nullo della sommatoria

⇒ non si può calcolare la $\mu_{(-1)}$ per X che assumono valori negativi o nulli (es. temperatura)

Media quadratica ($k = 2$)

$$\mu_{(2)} = \left(\sum_{i=1}^n f_i x_i^2 \right)^{1/2} = \sqrt{\sum_{i=1}^n f_i x_i^2} \quad \text{NB: } x_i > 0 \text{ non necessaria}$$

NB: Date x_i uguali: $\mu_{(-1)} \leq \mu_{(1)} \leq \mu_{(2)}$

Lezione 7 - 18/10/21

Le medie potenziate sono medie in senso stretto: rispettano le 3 proprietà

① Cauchy : $x_{\min} \leq \mu_{(k)} \leq x_{\max}$ \Leftrightarrow conseguenza dell'attribuzione alle x_i di un sistema di pesi (p_i) che somma a 1

② Moltiplicatività : $\mu_{(k)}(c \cdot x) = \left[\sum_{i=1}^m (c \cdot x_i)^k p_i \right]^{1/k} = c \cdot \left(\sum_{i=1}^m x_i^k p_i \right)^{1/k} = c \cdot \mu_{(k)}(x)$

③ Monotonicità rispetto agli x_i

per $k > 0$: $y_i \geq x_i \Rightarrow y_i^k \geq x_i^k$ data la crescita monotona di $f(x) = a^x$

per $k < 0$: $\mu_{(k)}(x) = \frac{1}{\left(\sum_{i=1}^m p_i \cdot \frac{1}{x_i^{|k|}} \right)^{1/|k|}} = \frac{1}{\mu_{(|k|)}\left(\frac{1}{x}\right)}$

allora $y_i \geq x_i \Rightarrow \frac{1}{y_i} \leq \frac{1}{x_i} \Rightarrow \mu_{(|k|)}\left(\frac{1}{y}\right) \leq \mu_{(|k|)}\left(\frac{1}{x}\right)$

$\Rightarrow \mu_{(|k|)}(y) \geq \mu_{(|k|)}(x)$

TEO. fondamentale sulle medie potenziate

Data $\mu_{(k)} = \left(\sum_{i=1}^m x_i^k p_i \right)^{1/k}$ $k \in [\pm 1, \pm 2, \pm 3, \dots]$ e x_i positivi ordinati e distinti

① Monotona in senso stretto (rispetto a k)

$$\mu_{(s)} \geq \mu_{(r)} \quad \text{se } s \geq r$$

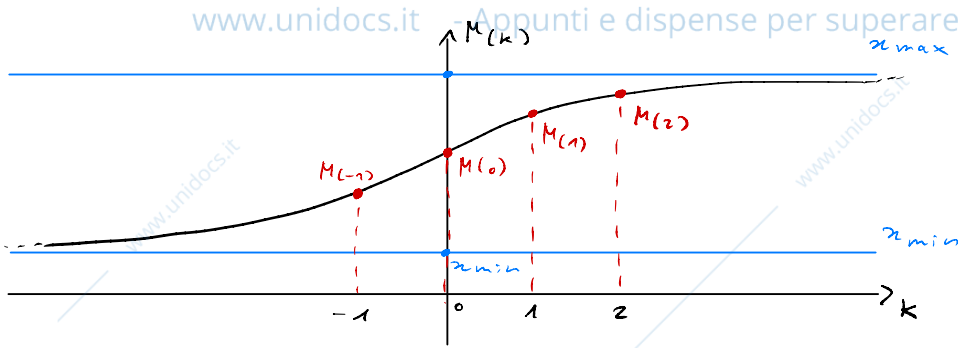
② $\lim_{k \rightarrow +\infty} \mu_{(k)} = x_{\max}$; $\lim_{k \rightarrow -\infty} \mu_{(k)} = x_{\min}$

\Rightarrow funzione Media potenziata ha due asintoti orizzontali in corrispondenza di $y = x_{\min}$ e $y = x_{\max}$

③ Ogni media potenziata di ordine k (con k qualsiasi) è media in senso stretto

④ Media geometrica

$$\lim_{k \rightarrow 0} \mu_{(k)} = \sqrt{x_1^{m_1} \cdot x_2^{m_2} \cdot \dots \cdot x_m^{m_m}} = \sqrt[m]{\prod_{i=1}^m x_i^{m_i}} = \text{Media geometrica}$$



=> è chiaro come a un certo punto gli ordini perdano di interesse

DIM.

① Troppo avanzata

$$\textcircled{2} \lim_{k \rightarrow +\infty} M(k) = \lim_{k \rightarrow +\infty} \left(\frac{\sum_{i=1}^r x_i^k \cdot m_i}{n} \right)^{1/k} = \lim_{k \rightarrow +\infty} \left(\frac{x_r^k \cdot m_r}{n} + \frac{\sum_{i=1}^{r-1} x_i^k \cdot m_i}{n} \right)^{1/k}$$

↖ valore più grande osservato

$$= \lim_{k \rightarrow +\infty} \left[x_r^k \left(\frac{x_r^k}{x_r^k} \cdot \frac{m_r}{n} + \sum_{i=1}^{r-1} \frac{x_i^k}{x_r^k} \cdot \frac{m_i}{n} \right) \right]^{1/k}$$

$$= \lim_{k \rightarrow +\infty} x_r \left[\frac{m_r}{n} + \sum_{i=1}^{r-1} \left(\frac{x_i^k}{x_r^k} \cdot \frac{m_i}{n} \right) \right]^{1/k} = x_r \cdot \lim_{k \rightarrow +\infty} \left[\frac{m_r}{n} + \sum_{i=1}^{r-1} \left(\frac{x_i^k}{x_r^k} \cdot \frac{m_i}{n} \right) \right]^{1/k}$$

i) $x_i < x_r \quad \forall i < r \Rightarrow x_i^k < x_r^k \quad \forall i < r \Rightarrow \frac{x_i^k}{x_r^k} < 1$

$\Rightarrow \lim_{k \rightarrow +\infty} \left(\frac{x_i}{x_r} \right)^k = 0 \Rightarrow (0)^{1/k} = 0$

ii) $x_r \cdot \lim_{k \rightarrow +\infty} \left(\frac{m_r}{n} \right)^{1/k} = 1$

$\hookrightarrow m_r > 0; m_r < n \Rightarrow 0 < \frac{m_r}{n} < 1$

$\Rightarrow x_r \cdot (1 + 0) = x_r$

$\Rightarrow \lim_{k \rightarrow +\infty} M(k)$ tende al valore più grande osservato

NB: per $k \rightarrow -\infty$ la DIM è identica, semplicemente si mette in evidenza $x_1 = x_{\min}$ e si lavora con il $-\infty$

③ Già dimostrata

④ $\lim_{k \rightarrow 0} M(k) = \lim_{k \rightarrow 0} \left(\sum_{i=1}^n x_i^k \cdot f_i \right)^{1/k} = 1^\infty \quad \text{FDI.}$

$$\lim_{k \rightarrow 0} M(k) = M_f(x) \quad \ln M_f(x) = \lim_{k \rightarrow 0} \ln M(k) = \lim_{k \rightarrow 0} \ln M(k) =$$

$$= \lim_{k \rightarrow 0} \ln \left(\sum_{i=1}^n x_i \cdot f_i \right)^{1/k} = \lim_{k \rightarrow 0} \frac{1}{k} \ln \left(\sum_{i=1}^n x_i \cdot f_i \right) = \frac{0}{0} \quad \text{FDI}$$

$\hookrightarrow \text{NB: } \ln a^x = x \ln a$

De L'Hospital : $\frac{dN/dk}{dD/dk}$

i) D: $k \quad \frac{dD}{dk} = \frac{d}{dk} k = 1 \quad \left[\Leftrightarrow \frac{dk}{dk} = 1 \right]$

ii) N: $\ln \left(\sum_{i=1}^r x_i^k \cdot f_i \right) \quad \frac{dN}{dk} = \frac{d}{dk} \ln \sum_{i=1}^r (x_i^k \cdot f_i) \quad \text{NB: } \frac{d}{dx} \ln f(x) = \frac{f'(x)}{f(x)}$

$$= \frac{\sum_{i=1}^r \frac{d}{dk} x_i^k \cdot f_i}{\sum_{i=1}^r x_i^k \cdot f_i} = \text{NB: } \frac{d}{dx} a^x = \ln a \cdot a^x = \frac{\sum_{i=1}^r f_i [(\ln x_i) \cdot x_i^k]}{\sum_{i=1}^r x_i^k \cdot f_i}$$

$$\Rightarrow \lim_{k \rightarrow 0} \ln M_g(x) = \lim_{k \rightarrow 0} \frac{\sum_{i=1}^r f_i [(\ln x_i) \cdot x_i^k]}{\sum_{i=1}^r x_i^k \cdot f_i} = \frac{\lim_{k \rightarrow 0} \sum_{i=1}^r f_i [(\ln x_i) \cdot x_i^k]}{\lim_{k \rightarrow 0} \sum_{i=1}^r f_i \cdot x_i^k} =$$

$$= \frac{\sum_{i=1}^r f_i \cdot \ln(x_i)}{\sum_{i=1}^r f_i} = \sum_{i=1}^r f_i \cdot \ln(x_i) = \sum_{i=1}^r \ln(x_i)^{f_i} \quad \text{NB: } \lim_{k \rightarrow 0} \prod_{i=1}^r x_i^k = \prod_{i=1}^r x_i$$

= $\ln \prod_{i=1}^r (x_i)^{f_i} = \ln M_g(x)$: faccio l'exp per ottenere $M_g(x)$

$$\Rightarrow e^{\ln M_g(x)} = e^{\ln \prod_{i=1}^r (x_i)^{f_i}} \Rightarrow M_g(x) = \prod_{i=1}^r (x_i)^{f_i} = \prod_{i=1}^r (x_i)^{\frac{n_i}{n}} = \sqrt[n]{\prod_{i=1}^r (x_i)^{n_i}}$$

Media aritmetica

- Indice di posizione : espone su quale punto dell'asse reale è concentrata la distribuzione.

- Si indica con μ ($= \mu_{(1)}$)

Proprietà esclusive (soddisfa le 3 delle medie)

$$\textcircled{1} \sum_{i=1}^r (x_i - \mu) \cdot n_i = 0$$

$$\textcircled{2} \sum_{i=1}^r (x_i - \mu)^2 n_i = \min$$

Proprietà dell'operatore Media

- $M(x)$ in IFA, $E(x)$ in EUG

Prendiamo $a \in \mathbb{R}$, $b \in \mathbb{R}$

$$\textcircled{1} \quad M(a) = a$$

$$\textcircled{2} \quad M(ax) = aM(x)$$

$$M(ax) = \frac{\sum_{i=1}^r ax_i n_i}{n} = a \frac{\sum_{i=1}^r n_i \cdot n_i}{n} = aM(x)$$

$$\textcircled{3} \quad M(x+y) = M(x) + M(y)$$

$$M(x+y) = \frac{\sum_{i=1}^r (x_i + y_i) n_i}{n} = \frac{\sum_{i=1}^r x_i n_i}{n} + \frac{\sum_{i=1}^r y_i n_i}{n}$$

$$\textcircled{4} \quad M(a+bx) = a + bM(x)$$

$$\frac{\sum_{i=1}^r (a+bn_i) n_i}{n} = \frac{\sum_{i=1}^r a n_i}{n} + \frac{\sum_{i=1}^r b n_i n_i}{n} = a + b \frac{\sum_{i=1}^r n_i n_i}{n}$$

dalle proprietà esclusive della Media aritmetica

Dim (1)

$$\sum_{i=1}^r (n_i - \mu) n_i = 0 \quad \text{oppure} \quad \frac{\sum_{i=1}^r (n_i - \mu) n_i}{n} = \sum_{i=1}^r (n_i - \mu) f_i =$$

$$= \sum_{i=1}^r n_i f_i - \sum_{i=1}^r \mu f_i = \mu - (\mu \cdot 1) = 0$$

Dim. (2)

$$\sum_{i=1}^r (n_i - \mu)^2 n_i = \min$$

con derivate (ne calcolo la derivata e la pongo = 0)
metodo analitico

metodo analitico: $\min_{\theta} \sum_{i=1}^r (n_i - \theta)^2 = ??$ Quale θ rende minimo questa quantità?

$$\sum_{i=1}^r (n_i - \theta)^2 \quad \text{NB: tolgo } f_i, \text{ tanto sono solo un sistema di pesi} = \sum_{i=1}^r [(n_i - \theta + \mu - \mu)^2] =$$

$$= \sum_{i=1}^r [(n_i - \mu) - (\theta - \mu)]^2 = \sum_{i=1}^r [(n_i - \mu)^2 + (\theta - \mu)^2 - 2(n_i - \mu)(\theta - \mu)]$$

$$= \sum_{i=1}^r (n_i - \mu)^2 + \sum_{i=1}^r (\theta - \mu)^2 - 2 \sum_{i=1}^r (n_i - \mu)(\theta - \mu) =$$

$$\sum_{i=1}^r (n_i - \mu)^2 + n(\theta - \mu)^2 - 2(\theta - \mu) \underbrace{\sum_{i=1}^r (n_i - \mu)}_{=0} =$$

$$= \sum_{i=1}^r (n_i - \mu)^2 + n(\theta - \mu)^2 \stackrel{?}{=} \min$$

Con $\theta = \mu \Rightarrow n(\theta - \mu)^2 = 0$ (CVD)

Alcune zolle medie potenziate:

Abbiamo detto che sono infinite, ma ce ne interessano solo 4 o 5.
Ma come si sceglie quale usare?

Un paio di criteri:

① Metodo del Chisini o Media obiettivo

(non sempre restituisce una media in senso stretto)

Dato X , impongo un vincolo globale (= funzione obiettivo)

$$f(x) = f(n_1, n_2, \dots, n_r; n_1, \dots, n_r)$$

CHISINI: risolvere l'equazione

$$f(n_1, \dots, n_r; n_1, \dots, n_r) = f(\alpha, \dots, \alpha; n_1, \dots, n_r)$$

sostituisco la costante α agli n_i

Se f è monotona continua avrà una soluzione unica.

Tipiche funzioni obiettivo:

- $f(x) = \sum_{i=1}^r n_i n_i$ Funzione additiva (es. costo totale, ...)

$$\Rightarrow \sum_{i=1}^r n_i n_i = \sum_{i=1}^r \alpha n_i \Rightarrow \alpha = \frac{\sum_{i=1}^r n_i n_i}{n}$$

Totale invariato

- $f(x) = \prod_{i=1}^r n_i^{n_i}$ Funzione moltiplicativa

$$\Rightarrow \prod_{i=1}^r n_i^{n_i} = \prod_{i=1}^r \alpha^{n_i} \Rightarrow \prod_{i=1}^r n_i^{n_i} = \alpha^{\sum n_i} \Rightarrow \alpha = \sqrt[n]{\prod_{i=1}^r n_i^{n_i}} = M_g(x)$$

Prodotto globale invariato