



LEZIONE 6 | Rapp. grafiche (parte 2)

Rappresentazioni grafiche di distribuzioni per variabili in classi



Funzione di ripartizione empirica



Salta tramite segmenti di retta (incremento del fenomeno) $MAX = 1$
 (useremo molto questo)

• INTRODUZIONE INDICE di POSIZIONE

Primo inx di indici che servono a sintetizzare l'info di una variabile x
 ↳ In particolare indica la posizione della variabile all'interno dell'inx di riferimento

SCOPO • sintetizzare (in un unico valore l'informazione che proviene dalle variabile)

• localizzarla nell'inx dei valori di riferimento

Il valore che "sintetizza" l'informazione dà subito un'idea dell'ordine di grandezza di un fenomeno

distingueremo 2 tipi di medie

Media lasca


una delle modalità privilegiata o perché frequente, o perché in una particolare posizione (la sintetizza meglio)

Media aritmetica

risultato di una manipolazione di dati

può non coincidere con le modalità osservate

NB Ci sono dei minimi requisiti che una media deve soddisfare e essere tale



M è una generica media

deve soddisfare 3 requisiti:

① **Principio di Cauchy**: $x_1 \leq M \leq x_n$ deve essere compreso o eguale tra il valore + piccolo osservato e quello + grande

↓
 x_k è un valore che deve sintetizzare l'informazione della variabile

② **Principio di Chisini (o di invarianza)**: $f(M, M, \dots, M) = f(x_1, x_2, \dots, x_n)$

la funzione applicata sui dati deve essere eguale (coincide) con la funzione quando a ciascun dato osservato sostituiamo la media

③ **Criterio delle minime perdite**: g (funzione generica) sintetizza la perdita di informazione che abbiamo possedendo da tutti i dati ad una singola media

M minimizza la perdita g

$$\sum_{i=1}^n (x_i - M)^2$$

(x_i e M sono nel piano cartesiano)

MEDIE LASCHE 1° gruppo di indici di posizione

Tre tipi

- Moda
- Mediana
- Quartili e quantili

MODA: • modalità che si presenta + spesso ← caratteristica + imp.
 • calcolabile x tutte le variabili
 • può non essere unica ⇒ poco informativa

NB la moda corrisponde alla **modalità** che si presenta con maggior frequenza

- Quando ci sono più mode si ha una **distribuzione bimodale** (meno informativa)

NB Nella distribuzione in classi la moda corrisponde alla **modalità** che si presenta con più densità: $(\frac{h_i}{N}) \cdot \frac{1}{\Delta x_i}$ e si prende il valore di riferimento della classe

MEDIANA : è il valore m associato all'unità statistica che occupa la posizione centrale della distribuzione [primo bisogna ordinare le unità statistiche in ordine crescente rispetto alle modalità]

- le variabili devono essere **ordinabili** (le variabili qualitative su scala sconnessa non sono considerate)
- principio di Cauchy ($x_1 \leq m \leq x_n$)
- la somma dei valori assoluti degli scarti da un valore c è minima se $c = \text{mediana}$

$$\sum_{i=1}^N |x_i - m| = \min_c \sum_{i=1}^N |x_i - c|$$

* Per distribuzioni di frequenza : N DISPARI

- 1 ordinare le modalità in senso crescente
- 2 si cerca l'unità che sta in posizione $(N+1)/2$
 lascia alla sua sx e dx lo stesso numero di unità : $(N-1)/2$
- 3 la mediana è la **modalità** posseduta da quella unità

* Per distribuzioni di frequenza : N PARI

- 1 ordinare le modalità in senso crescente
- 2 cercano le unità in posizione $N/2$ e $N/2+1$ che lasciano la prima alla sua sx e la seconda alla sua dx lo stesso numero di ~~unità~~ unità : $N/2-1$

caso di variabile qualitativa ordinale

caso di variabile quantitativa discreta

- se la **modalità** posseduta dalle unità statistiche è la stessa, quella è la **MEDIANA**
- se la **più** modalità posseduta dalle unità Non è la stessa, la mediana non esiste

- se la **modalità** posseduta dalle unità è la stessa, quella è la **MEDIANA**
- se la **modalità** posseduta dalle unità non è la stessa, ogni valore compreso tra le due modalità è **MEDIANA**, di solito si sceglie il valore centrale

* Per distribuzioni in class : individuazione della classe mediana $[c_{i-1}, c_i)$

poiché : individuazione della mediana all'interno della classe mediana $[c_{i-1}, c_i)$

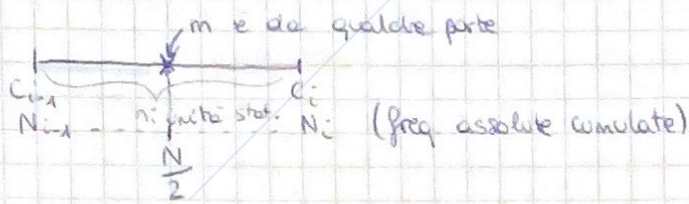
$$(m - c_{i-1}) : (N/2 - N_{i-1}) = (c_i - c_{i-1}) : n_i$$

$$\text{Si ha : } m = c_{i-1} + \frac{0.5 - F_{i-1}}{f_i} \cdot d_i$$

* prendo dove F_i soffo!



Intervallo generico: $[c_{i-1}, c_i)$



relazione: l'ampiezza di questo intervallo $[c_{i-1}, \frac{m}{2})$ ha un'ampiezza di questo tipo: $(m - c_{i-1})$ sta a tutte le unità statistiche che ci sono in quell'intervallo, come l'ampiezza di tutto l'intervallo sta a tutte le U.S. n_i .

$$(m - c_{i-1}) : (\frac{N}{2} - N_{i-1}) = c_i - c_{i-1} : n_i$$

unica quantità non nota

$$m - c_{i-1} = \frac{(\frac{N}{2} - N_{i-1})(c_i - c_{i-1})}{n_i}$$

$$m = \frac{(\frac{N}{2} - N_{i-1})(c_i - c_{i-1})}{\frac{n_i}{N}} + c_{i-1}$$

$\frac{n_i}{N} \rightarrow$ freq. relativa: f_i

$$m = c_{i-1} + \frac{(0.5 - F_{i-1}) \cdot d_i}{f_i}$$

N3e la mediana è un valore interno alla classe mediana

controllare sempre che il p.to sia all'interno della classe mediana

QUANTILE:

- (estensione della mediana)
- indice associato a particolari posizioni nella distribuzione ordinate di X
- si parla di quantile di ordine q ($0 < q < 1$)
 - ↓
 - valore del supporto di X che suddivide la distribuzione in 2 parti
 - ↓
 - Sinistra: $q\%$ delle unità stat.
 - ↓
 - destra: $(1-q)\%$ delle unità stat.

⇒ il quantile prende un nome particolare a seconda del valore di q del suo ordine che si considera

QUARTILI (i famosi) quantili con valori di $q = 1/4, 1/2, 3/4$
 (detti ante primo, secondo, terzo quantile)
 = **MEDIANA** (50%)

- si parla anche di **PERCENTILI** (q multiplo di 100)
- **DECILI** (q multiplo di 10)

13 • Dobbiamo avere delle **VARIABILI** almeno **ORDINABILI** x poter individuare i quantili

*** Quantili x variabili quantitative discrete**

- X con valori crescenti: x_1, \dots, x_n
- $h = \frac{p}{4} \cdot N$, $p = 1, 2, 3$
 ↓
 1, 2, 3
 tot. osservazioni
 ↓
 quantile che identifica l'ordine del quantile ($1/4, 2/4, 3/4$)

$$q_p = \begin{cases} \text{se } h \text{ non intero} & \frac{x_h + x_{h+1}}{2} \text{ per } h \text{ intero} \\ \text{oppure} & x_{[h]+1} \text{ per } h \text{ non intero} \end{cases}$$

[h] = parte intera di h

Generale: • Per trovare un **DECILE**: si suddivide la distribuzione in 10 parti e si cerca h

$$h = \frac{p}{10} \cdot N \quad p = 1, \dots, 9$$

Per i quartili si procede come Y

• Per trovare un **CENTILE**: si suddivide la distribuzione in 100 parti e si cerca h

$$h = \frac{p}{100} \cdot N \quad p = 1, \dots, 99$$

si procede come per i quantili

* Quantili per distribuzioni in classe

• logica = per trovare la MEDIANA

→ questo valore cumulato è i quantili

$$m = c_{i-1} + \left(\frac{0,5 - F_{i-1}}{f_i} \right) \cdot d_i$$

per trovare la mediana

ES. cerchiamo l'ottavo decile (sx 80% dx 20%)
= quantile di ordine 0,8

① Si cerca sulla colonna delle freq. relative cumulative (F_i) dove superiamo l'80% delle U.S., prendiamo la propria CLASSE

② Si trova l'ottavo decile (d_8) valore del quantile che stiamo cercando

$$d_8 = c_{i-1} + \left(\frac{0,8 - F_{i-1} (F_i \text{ della classe prec.})}{f_i \text{ (della classe del nostro decile)}} \right) \cdot d_i$$

ampiezza classe

$$d_n = c_{i-1} + \left(\frac{v_n - F_{i-1}}{f_i} \right) \cdot d_i$$

NB: il risultato deve rientrare nella classe da cui siamo partiti

ES 2 cerchiamo il primo quartile

$$q_n = c_{i-1} + \left(\frac{v_n - F_{i-1}}{f_i} \right) \cdot d_i$$