
Sintesi della distribuzione di un carattere: la variabilità

Introduzione alla variabilità

- Nelle lezioni precedenti abbiamo visto come sia possibile riassumere tutte le informazioni disponibili attraverso l'utilizzo di una misura sintetica (come la media aritmetica).
- I fenomeni che vengono studiati tendono a variare. Tale elemento giustifica l'esistenza stessa delle metodologie quantitative; pertanto, sarà necessario comprendere in che modo tale variabilità si manifesta all'interno dell'analisi che stiamo effettuando.

Introduzione alla variabilità

ATTENZIONE!!!!

- Quando sintetizziamo una distribuzione con una sola informazione quantitativa guadagniamo qualcosa in termini di *capacità informativa*, ma perdiamo qualcos'altro rispetto all'informazione disaggregata. Sarà dunque necessario capire se la sintesi effettuata è “buona”, in altri termini se l'informazione ottenuta riassume bene i dati di partenza, altrimenti possono risultare errate le conclusioni alle quali perveniamo (proprio perché la misura utilizzata non rappresenta bene i dati disponibili)

Introduzione alla variabilità

| | | | | |
|----|----|----|-----|--------------|
| A) | 40 | 50 | 60 | $\bar{X}=50$ |
| B) | 50 | 50 | 50 | $\bar{X}=50$ |
| C) | 0 | 0 | 150 | $\bar{X}=50$ |

**Distribuzioni con media aritmetica uguale ma
differente variabilità**

Il Campo di Variazione

$$R = X_n - X_1$$

| | | | |
|----|----|----|-----|
| A) | 40 | 50 | 60 |
| B) | 50 | 50 | 50 |
| C) | 0 | 0 | 150 |

$$A) R_A = X_n - X_1 = 60 - 40 = 20$$

$$B) R_B = X_n - X_1 = 50 - 50 = 0$$

$$C) R_C = X_n - X_1 = 150 - 0 = 150$$

Difetti: Ha un minimo, ma non ha un massimo definito;
è difficilmente interpretabile nel caso di *outliers*

Alcune considerazioni

La misura appena presentata:

- ❑ **Prende in considerazione solo due soggetti**
- ❑ **Non ha estremi definiti**
- ❑ **Sono spesso di difficile interpretazione**
- ❑ **Sono misure assolute rendono difficile il confronto**

La Varianza

La **VARIANZA** è data dalla sommatoria di tutti gli scarti tra le singole modalità e la media aritmetica, elevate al quadrato e rapportata alla numerosità totale:

$$\text{Var} = \sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}$$

| X | X ² |
|---|----------------|
| 1 | 1 |
| 2 | 4 |
| 3 | 9 |
| 5 | 25 |

$$\text{s.q.m.} = \sigma = \sqrt{\sigma^2}$$

Esempio 1 – Varianza e S.Q.M.

Supponiamo di avere a disposizione l'età di cinque individui, che di seguito riportiamo:

25 37 19 21 28

Si calcoli:

- A) L'età media degli individui
- B) la varianza
- C) lo scarto quadratico medio

A) $(25 + 37 + 19 + 21 + 28)/5 = 26$

Esempio 1 – seconda parte

$$\text{B) } \text{Var} = \sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}$$

$$\begin{aligned} & [(25-26)^2 + (37-26)^2 + (19-26)^2 + (21-26)^2 + (28-26)^2] / 5 = \\ & = [(-1)^2 + (+11)^2 + (-7)^2 + (-5)^2 + (+2)^2] / 5 = \\ & = (1 + 121 + 49 + 25 + 4) / 5 = (200 / 5) = 40 \end{aligned}$$

$$\text{C) } \sigma = \sqrt{\sigma^2} = \sqrt{40} = 6,32$$

Esempio 2 – Varianza e S.Q.M.

| x_i | n_i | $x_i \cdot n_i$ | $(x_i - \bar{X})$ | $(x_i - \bar{X})^2$ | $(x_i - \bar{X})^2 \cdot n_i$ |
|-------|-------|-----------------|-------------------|---------------------|-------------------------------|
| 1 | 11 | 11 | -2,33 | 5,43 | 59,73 |
| 2 | 21 | 42 | -1,33 | 1,77 | 37,17 |
| 3 | 32 | 96 | -0,33 | 0,11 | 3,52 |
| 4 | 28 | 112 | 0,67 | 0,45 | 12,60 |
| 5 | 16 | 80 | 1,67 | 2,79 | 44,64 |
| 6 | 7 | 42 | 2,67 | 7,13 | 49,91 |
| | 115 | 383 | | | 207,57 |

$$\bar{X} = 383/115 = 3,33$$

MAI NEGATIVA

$$\text{Var} = \sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{X})^2 \cdot n_i}{n} = \frac{207,57}{115} = 1,80$$

$$\sigma = \sqrt{\sigma^2} = \sqrt{1,80} = 1,34$$

Esempio 3 – Varianza e S.Q.M.

| x_i | n_i | c_i | $c_i \cdot n_i$ |
|-------|-------|-------|-----------------|
| 1-5 | 45 | 3 | 135,0 |
| 6-9 | 35 | 7,5 | 262,5 |
| 10-19 | 26 | 14,5 | 377,0 |
| 20-29 | 20 | 24,5 | 490,0 |
| 30-39 | 15 | 34,5 | 517,5 |
| 40-49 | 10 | 44,5 | 445,0 |
| | 151 | | 2.227,0 |

a) $\bar{X} = 2.227 / 151 = 14,75$

b) $R = X_n - X_1 = 49 - 1 = 48$

Calcolare:

a) La media aritmetica

b) Il campo di variazione

c) La varianza e lo scarto quadratico medio

Esempio 3 – seconda parte

| x_i | n_i | c_i | $c_i \cdot n_i$ | $(c_i - \bar{X})$ | $(c_i - \bar{X})^2$ | $(c_i - \bar{X})^2 \cdot n_i$ |
|-------|-------|-------|-----------------|-------------------|---------------------|-------------------------------|
| 1-5 | 45 | 3 | 135,0 | -11,75 | 138,06 | 6.212,70 |
| 6-9 | 35 | 7,5 | 262,5 | -7,25 | 52,56 | 1.839,60 |
| 10-19 | 26 | 14,5 | 377,0 | -0,25 | 0,06 | 1,56 |
| 20-29 | 20 | 24,5 | 490,0 | 9,75 | 95,06 | 1.901,20 |
| 30-39 | 15 | 34,5 | 517,5 | 19,75 | 390,06 | 5.850,90 |
| 40-49 | 10 | 44,5 | 445,0 | 29,75 | 885,06 | 8.850,60 |
| | 151 | | 2.227,0 | | | 24.656,56 |

c)

$$\text{Var} = \sigma^2 = \frac{\sum_{i=1}^n (c_i - \bar{X})^2 \cdot n_i}{n} = \frac{24.656,56}{151} = 163,29$$

$$\sigma = \sqrt{\sigma^2} = \sqrt{163,29} = 12,78$$

Indici di variabilità relativi

- **Giudicare la rappresentatività della media aritmetica**

Devo capire se la media che ho calcolato sintetizza bene le informazioni

- **Confrontare la variabilità di due distribuzioni**

Varianza e scarto quadratico medio dipendono dall'unità di misura e dal "livello"; non posso fare confronti

Rappresentatività della media

Distribuzione di 20 studenti per numero di esami effettuati nella sessione

| x_i | n_i | $x_i \cdot n_i$ | $(x_i - \bar{X})$ | $(x_i - \bar{X})^2$ | $(x_i - \bar{X})^2 \cdot n_i$ |
|-------|-------|-----------------|-------------------|---------------------|-------------------------------|
| 1 | 8 | 8 | $(1-2) = -1$ | $(-1)^2 = 1$ | $(1 \times 8) = 8$ |
| 2 | 5 | 10 | $(2-2) = 0$ | $(0)^2 = 0$ | $(0 \times 5) = 0$ |
| 3 | 6 | 18 | $(3-2) = 1$ | $(1)^2 = 1$ | $(1 \times 6) = 6$ |
| 4 | 1 | 4 | $(4-2) = 2$ | $(2)^2 = 4$ | $(4 \times 1) = 4$ |
| | 20 | 40 | | | 18 |

$$\bar{X} = \frac{\sum_{i=1}^n x_i \cdot n_i}{n} = \frac{40}{20} = 2$$

$$\sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{X})^2 \cdot n_i}{n}$$

$$\sigma = \sqrt{\sigma^2} = \sqrt{0,9} = 0,95$$

| x_i | n_i | $x_i \cdot n_i$ | $(x_i - \bar{X})^2 \cdot n_i$ |
|-------|-------|-----------------|-------------------------------|
| 2 | 20 | 40 | $(2 - 2)^2 \times 40 = 0$ |
| | 20 | 40 | 0 |

MINIMA VARIABILITA'

$$\sigma = \sqrt{\sigma^2} = \sqrt{0} = 0$$

Rappresentatività della media - 2

| x_i | n_i | $x_i \cdot n_i$ | $(x_i - \bar{x})^2 \cdot n_i$ |
|-------|-------|-----------------|-------------------------------|
| 0 | 19 | 0 | $(0 - 2)^2 \times 19 = 76$ |
| 40 | 1 | 40 | $(40 - 2)^2 \times 1 = 1444$ |
| | 20 | 40 | 1.520 |

$$\sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2 \cdot n_i}{n}$$

$$\sigma = \sqrt{\sigma^2} = \sqrt{76} = 8,72$$

MASSIMA VARIABILITA'

$$\sigma_{\max} = \bar{x} \sqrt{(n-1)} = 2 \cdot \sqrt{(20-1)} = 2 \cdot \sqrt{19} = 2 \cdot 4,36 = 8,72$$

Rappresentatività della media - 3

$$\frac{\sigma}{\sigma_{\max}}$$

+ si avvicina a 0

+ Media rappresentativa

+ si avvicina a 1

+ Media NON rappresentativa

□ Nel nostro caso:

$$\frac{\sigma}{\sigma_{\max}} = \frac{0,95}{8,72} = 0,11$$

La Media rappresenta bene i dati

Confrontare la variabilità

□ Confrontare la variabilità di due distribuzioni

Varianza e scarto quadratico medio dipendono dall'unità di misura e dal "livello"; non posso fare confronti

□ Esempio: confronto tra peso adulti e neonati

78,4 65,8 72,2 85,6 75,2 58,7 69,9

3,875 2,954 3,458 4,512 2,722 3,158

Confrontare la variabilità - 2

Adulti

$$\bar{x} = \frac{(78,4 + 65,8 + 72,2 + 85,6 + 75,2 + 58,7 + 69,9)}{7} = 72,26$$

$$\sigma = \sqrt{\frac{\left[(78,4 - 72,26)^2 + (65,8 - 72,26)^2 + (72,2 - 72,26)^2 + (85,6 - 72,26)^2 + \right.}{7} \left. + (75,2 - 72,26)^2 + (58,7 - 72,26)^2 + (69,9 - 72,26)^2 \right]}{7}} = 8,066$$

Neonati

$$\bar{x} = \frac{(3,875 + 2,954 + 3,458 + 4,512 + 2,722 + 3,158)}{6} = 3,447$$

$$\sigma = \sqrt{\frac{\left[(3,875 - 3,447)^2 + (2,954 - 3,447)^2 + (3,458 - 3,447)^2 + \right.}{6} \left. + (4,512 - 3,447)^2 + (2,722 - 3,447)^2 + (3,158 - 3,447)^2 \right]}{6}} = 0,601$$

Confrontare la variabilità - 3

Coefficiente di Variazione

Più è grande CV, maggiore è la variabilità

$$CV_{\text{adu}} = \frac{\sigma}{x} \cdot 100 = \frac{8,066}{72,26} \cdot 100 = 0,112 \cdot 100 = 11,2$$

$$CV_{\text{neo}} = \frac{\sigma}{x} \cdot 100 = \frac{0,601}{3,447} \cdot 100 = 0,174 \cdot 100 = 17,4$$

$CV_{\text{neo}} > CV_{\text{adu}}$ - La variabilità è maggiore nei neonati

Riferimenti sul testo

di **Whitlock M.C., Schluter D.**
Analisi statistica dei dati biologici,
Zanichelli

Paragrafi da studiare: 3.1 (tranne primo punto), 3.5, 3.6
Esercizi alla fine dei paragrafi.