

Statistica Descrittiva II

Serie statistiche monovariate

- Indici di posizione
- Indici di variabilità
- Indici di asimmetria
- Indici di normalità
- Outlier
- Box-plot



1

Organizzazione dei dati

Carattere: Cellulari posseduti

Popolazione: 75 studenti di Biotechnologie

| i | m_i | n_i |
|-----|--------|-------|
| 1 | 0 | 8 |
| 2 | 1 | 30 |
| 3 | 2 | 26 |
| 4 | 3 | 5 |
| 5 | 4 | 6 |
| | | |
| | | |
| | Totale | 75 |



- Rappresentazioni complete ma “ingombranti”
- Utile un indice più “maneggevole” → indice sintetico

2

Indici di posizione: Media

Indicano in maniera sintetica il “centro” della statistica

- Media: calcolo il valore medio delle osservazioni

– Calcolo standard $\bar{m} = \frac{1}{N} \sum_{i=1}^N o_i$

$$\bar{m} = \frac{1}{75} (0+0+0+0+0+0+0+0+0+1+1+1+1+\dots) = 1,61$$

– Calcolo in tabella (I)
sfrutto le frequenze assolute

$$\bar{m} = \frac{1}{N} \sum_{i=1}^N o_i = \frac{1}{N} \sum_{i=1}^M n_i * m_i$$

$$\bar{m} = \frac{121}{75} = 1,61$$

| m_i | n_i | $n_i * m_i$ |
|--------|-------|-------------|
| 0 | 8 | 0 |
| 1 | 30 | 30 |
| 2 | 26 | 52 |
| 3 | 5 | 15 |
| 4 | 6 | 24 |
| | | |
| | | |
| Totale | 75 | 121 |

3

Indici di posizione: Media

- Calcolo in Tabella (II)

– Sfrutto le frequenze relative

$$\bar{m} = \frac{1}{N} \sum_{i=1}^5 m_i * n_i$$

$$\bar{m} = \frac{m_1 n_1 + m_2 n_2 + m_3 n_3 + m_4 n_4 + m_5 n_5}{N}$$

$$\bar{m} = \frac{m_1 n_1}{N} + \frac{m_2 n_2}{N} + \frac{m_3 n_3}{N} + \frac{m_4 n_4}{N} + \frac{m_5 n_5}{N}$$

$$\bar{m} = m_1 f_1 + m_2 f_2 + m_3 f_3 + m_4 f_4 + m_5 f_5$$

– In generale

$$\bar{m} = \sum_{i=1}^M m_i * f_i$$

| m_i | n_i | f_i | $m_i * f_i$ |
|--------|-------|-------|-------------|
| 0 | 8 | 0,107 | 0 |
| 1 | 30 | 0,400 | 0,4 |
| 2 | 26 | 0,347 | 0,69 |
| 3 | 5 | 0,067 | 0,2 |
| 4 | 6 | 0,080 | 0,32 |
| | | | |
| | | | |
| Totale | 75 | 1 | 1,61 |

4

Media: principali proprietà

Dati $O = \{o_i\}$ osservazioni

- La media è compresa fra le osservazioni minima e massima

$$\min(o_i) \leq \bar{o} \leq \max(o_i)$$

- La somma degli scarti dalla media è nulla

$$\sum_{i=1}^N (o_i - \bar{o}) = 0$$

- La somma del quadrato degli scarti dalla media è minima

$$\sum_{i=1}^N (o_i - \bar{o})^2 \leq \sum_{i=1}^N (o_i - p)^2 \quad \forall p$$

5

Media: altri tipi di dati

- La media si basa sulla somma delle osservazioni
Non può essere calcolata per dati qualitativi
- Caratteri continui.
 - Osservazioni
Nessun problema
 - Dati elaborati (raccolta fatta da terzi)
 - Istogramma
 - Tabella organizzata per classi
Manca la modalità!

6

Media: Raccolta dati per classi

Idea: uso come modalità il valore centrale (medio) della classe

- Tabella ad entrata semplice

1. Ad ogni c_i associare il valore centrale \bar{c}_i

2. Calcolo usuale con \bar{c}_i al posto di m_i

- Istogramma:

1. Da ogni classe ricavo \bar{c}_i

2. Convento densità in frequenza

$$f_i = (sup_i - inf_i) d_i$$

3. Calcolo usuale $\bar{o} = \sum_{i=1}^M \bar{c}_i \cdot f_i$

| inf_i | sup_i | \bar{c}_i | f_i | $\bar{c}_i \cdot f_i$ |
|---------|---------|-------------|-------|-----------------------|
| 1,40 | 1,50 | 1,450 | 0,10 | 0,1450 |
| 1,50 | 1,55 | 1,525 | 0,08 | 0,1220 |
| 1,55 | 1,60 | 1,575 | 0,18 | 0,2835 |
| 1,60 | 1,65 | 1,625 | 0,24 | 0,3900 |
| 1,65 | 1,70 | 1,675 | 0,16 | 0,2680 |
| 1,70 | 1,75 | 1,725 | 0,12 | 0,2070 |
| 1,75 | 1,85 | 1,800 | 0,12 | 0,2160 |
| totale | | | 1 | 1,6315 |



7

Media: Outlier

- Outlier: valore poco plausibile o errato
 - Errori di misura
 - Dato volutamente poco plausibile
- Come si modifica la media ?
 - 1 outlier (u) $N-1$ osservazioni "valide" (o)

$$\bar{m} = \frac{1}{N} \sum_{i=1}^{N-1} o_i + \frac{u}{N}$$

- U outliers (u_j) $N-U$ osservazioni "valide" (o)
(Ovviamente $N \gg U$)

$$\bar{m} = \frac{1}{N} \sum_{i=1}^{N-U} o_i + \frac{1}{N} \sum_{j=1}^U u_j$$

8

Media: considerazioni

- Può essere calcolata solo per caratteri numerici.
- Possibile calcolarla anche per rilevazioni a classi
- Sensibile agli outliers
 - Peggiora al crescere del # di outlier (U)
 - Migliora al crescere di N
- La media non è un'osservazione
 - (solo in rarissimi casi lo è)


9

Indici di posizione: Moda

Indicano in maniera sintetica il “centro” della statistica

- Moda: scelgo il valore più presente fra le osservazioni
 - Frequenza (relativa o assoluta) maggiore
 - Barra “più alta” in un diagramma a barre

| i | m_i | n_i |
|---------------|-------|-------|
| 1 | 0 | 8 |
| 2 | 1 | 30 |
| 3 | 2 | 26 |
| 4 | 3 | 5 |
| 5 | 4 | 6 |
| Totali | | 75 |



10

Moda: altri tipi di dati

- La moda si basa sulle frequenze assolute
 - Può essere calcolata anche per i valori qualitativi
- Caratteri continui.

- Osservazioni
osservazioni uguali sono rare → raggruppamento in classi
- Dati elaborati (raccolta fatta da terzi)
 - Istogramma
 - Tabella organizzata per classi

Classe modale = classe con la frequenza maggiore

11

Moda - Considerazioni


- Può essere calcolata per tutti i dati
- La moda è un'osservazione
- Poco sensibile agli outliers
 - Difficilmente gli outliers hanno alte frequenze

- Non è unica (esempio a lato):
 - Due massimi → serie bimodale
 - Tre massimi → serie trimodale
 -

| i | m_i | n_i |
|---------------|-------|-----------------|
| 1 | A | 8 |
| 2 | B | 30 |
| 3 | C | 26 |
| 4 | D | 30 |
| 5 | E | 12 ⁶ |
| Totali | | 100 |

Box-plot (prima versione)

- Rappresentazione grafica legata ai quartili
- Diverse versioni
- Versione base
 - Rettangolo fra q_1 e q_3
 - Mediana (q_2) evidenziata (rosso)
 - Due “baffi” (segmento)
 - da centro del lato dx e q_4
 - da centro del lato sx e q_0
- Alcuni quartili possono essere sovrapposti (Cell)



21


Indici di variabilità.

- Esempi di popolazioni in cui moda = media = mediana = 5
-
- Statistiche molto diverse fra loro.
 - Si introduce il concetto di variabilità.
“Propensione” delle osservazioni ad allontanarsi dal loro centro.
 - Osservazione: Serve una “distanza” per poter valutare la variabilità. → No caratteri non ordinabili.

22

Campo di variazione o range

- range: differenza fra la massima e la minima osservazione



- Considerazioni:
 - Facilissimo da calcolare
 - Istogrammi: I valori estremi del grafico
 - Molto sensibile alla presenza di outliers.
 (gli outliers per definizione son valori estremi!)

23

Varianza della popolazione σ^2

Media degli scarti dalla media al quadrato.

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (o_i - \bar{m})^2$$

- Esempio: osservazioni
 - $O = \{2 \ 5 \ 6 \ 7\}$
 - Media = $(2 + 5 + 6 + 7)/4 = 5$
 - Scarti dalla media = $\{-3 \ 0 \ 1 \ 2\}$
 - Scarti dalla media al quadrato = $\{9 \ 0 \ 1 \ 4\}$
 - Media degli scarti dalla media al quadrato
 Varianza = $(9 + 0 + 1 + 4)/4 = 3,5$

24

Varianza: formule di calcolo

- Definizione

$$\sigma^2 = \frac{\sum_{i=1}^M n_i (m_i - \bar{m})^2}{N}$$

$$\sigma^2 = \sum_{i=1}^M f_i (m_i - \bar{m})^2$$

| m_i | n_i | f_i | $m_i f_i$ | $m_i - \bar{m}$ | $(m_i - \bar{m})^2$ | $f_i (m_i - \bar{m})^2$ |
|---------------|------------|-------|---------------|-----------------|---------------------|-------------------------|
| 0 | 10 | 0,1 | 0 | -5 | 25 | 2,5 |
| 3 | 20 | 0,2 | 0,6 | -2 | 4 | 0,8 |
| 5 | 40 | 0,4 | 2 | 0 | 0 | 0 |
| 7 | 20 | 0,2 | 1,4 | 2 | 4 | 0,8 |
| 10 | 10 | 0,1 | 1 | 5 | 25 | 2,5 |
| totali | 100 | | $\bar{m} = 5$ | | | 6,6 |

- Formula "breve"

$$\sigma^2 = \sum_{i=1}^M f_i (m_i - \bar{m})^2 = \sum_{i=1}^M f_i (m_i^2 - 2 m_i \bar{m} + \bar{m}^2)$$

$$\sigma^2 = \sum_{i=1}^M f_i m_i^2 - 2 \sum_{i=1}^M f_i m_i \bar{m} + \sum_{i=1}^M f_i \bar{m}^2$$

$$\sigma^2 = \sum_{i=1}^M f_i m_i^2 - 2 \bar{m} \sum_{i=1}^M f_i m_i + \bar{m}^2 \sum_{i=1}^M f_i$$

$$\sigma^2 = \sum_{i=1}^M (f_i m_i^2) - 2 \bar{m} \bar{m} + \bar{m}^2 1 = \sum_{i=1}^M (f_i m_i^2) - \bar{m}^2 \quad 25$$

Varianza: formule di calcolo

- Definizione

$$\sigma^2 = \frac{\sum_{i=1}^M n_i (m_i - \bar{m})^2}{N}$$

$$\sigma^2 = \sum_{i=1}^M f_i (m_i - \bar{m})^2$$

| m_i | n_i | f_i | $m_i f_i$ | $m_i - \bar{m}$ | $(m_i - \bar{m})^2$ | $f_i (m_i - \bar{m})^2$ |
|---------------|------------|-------|---------------|-----------------|---------------------|-------------------------|
| 0 | 10 | 0,1 | 0 | -5 | 25 | 2,5 |
| 3 | 20 | 0,2 | 0,6 | -2 | 4 | 0,8 |
| 5 | 40 | 0,4 | 2 | 0 | 0 | 0 |
| 7 | 20 | 0,2 | 1,4 | 2 | 4 | 0,8 |
| 10 | 10 | 0,1 | 1 | 5 | 25 | 2,5 |
| totali | 100 | | $\bar{m} = 5$ | | | 6,6 |

- Formula "breve"

| m_i | n_i | f_i | $m_i f_i$ | m_i^2 | $f_i (m_i^2)$ |
|---------------|------------|-------|---------------|---------|---------------|
| 0 | 10 | 0,1 | 0 | 0 | 0 |
| 3 | 20 | 0,2 | 0,6 | 9 | 1,8 |
| 5 | 40 | 0,4 | 2 | 25 | 10 |
| 7 | 20 | 0,2 | 1,4 | 49 | 9,8 |
| 10 | 10 | 0,1 | 1 | 100 | 10 |
| totali | 100 | | $\bar{m} = 5$ | | 31,6 |

$$\sigma^2 = (\sum_{i=1}^M f_i m_i^2) - \bar{m}^2$$

$$\sigma^2 = 31,6 - 5^2 = 6,6$$

26

Varianza e scarto quadratico medio

- Calcolo di σ^2 nel caso di

- Istogrammi
- Rilevazione per classi di modalità

Stessa soluzione della media: si utilizza il valore di centro classe come modalità e si procede normalmente

| inf _i | sup _i | \bar{c}_i | f_i | $\bar{c}_i f_i$ | $\bar{c}_i - \bar{m}$ | $(\bar{c}_i - \bar{m})^2$ | $f_i (\bar{c}_i - \bar{m})^2$ |
|------------------|------------------|-------------|------------|-----------------|-----------------------|---------------------------|-------------------------------|
| 0 | 4 | 2 | 0,1 | 0,2 | -4 | 16 | 1,6 |
| 4 | 6 | 5 | 0,4 | 2,0 | -1 | 1 | 0,4 |
| 6 | 8 | 7 | 0,4 | 2,8 | 1 | 1 | 0,4 |
| 8 | 12 | 10 | 0,1 | 1,0 | 4 | 16 | 1,6 |
| | | | 6,0 | | | | 4,0 |

- Spesso si indica lo **scarto quadratico medio** σ

$$\sigma = \sqrt{\sigma^2} = \sqrt{(\sum_{i=1}^M f_i m_i^2) - \bar{m}^2}$$

27

Coefficiente di variazione (cv)


La varianza è sensibile alla media

- Esempio 1: osservazioni $O = \{2 \ 5 \ 6 \ 7\}$
 - Media = $\bar{O} = (2 + 5 + 6 + 7)/4 = 5$
 - Varianza = $\sigma_o^2 = (9 + 0 + 1 + 4)/4 = 3,5$
- Esempio 2: cambio unità di misura $P = \{20 \ 50 \ 60 \ 70\}$
 - Media = $\bar{P} = (20 + 50 + 60 + 70)/4 = 50$
 - Varianza = $\sigma_p^2 = (900 + 0 + 100 + 400)/4 = 350$
- Introduco il coefficiente di variazione $cv = \frac{\sigma}{|\bar{m}|}$

$$cv(P) = \frac{\sqrt{350}}{|50|} = \frac{\sqrt{3,5 \cdot 100}}{|5 \cdot 10|} = \frac{10 \sqrt{3,5}}{10|5|} = cv(O)$$

28

Varianza: considerazioni




- Considerazioni:
 - Migliore del range.
 - Istogrammi: uso il valore di centro classe
 - Sensibile alla presenza di outliers (come la media).
 - Sensibile alla media (indice assoluto)

29

Distanza Interquartile

Rappresenta la distanza fra il terzo ed il primo quartile

$$D = q_3 - q_1$$




- Risulta meno sensibile al valore degli outlier
 - Il valore numerico del outlier non conta
 - Spesso viene usata per indicare gli outlier (boxplot v2.0)


30

Box-plot (seconda versione)

- Considerazione: 50% dati è fra q_1 e q_3
- Il 100% dei dati dovrebbe stare fra
 - Valore Adiacente Superiore = $q_3 + k \cdot D$
 - Valore Adiacente Inferiore = $q_1 - k \cdot D$
- Versione 2 ($k=1$)
 - Rettangolo fra q_1 e q_3
 - Mediana (q_2) evidenziata
 - Due "baffi" (segmento)
 - da lato a min (q_4 e vas)
 - da lato max (q_0 e vai)
 - uso simboli discreti per i valori restanti



BoxPlot: strumento grafico di confronto



32

Indici di forma

Indici sintetici principali:

- **Posizione:** indica il “centro” delle osservazioni
- **Variabilità:** indica quanto le osservazioni si discostano dal “centro”

Spesso insufficienti, si usano anche


- **Indici Sintetici di Forma:** descrivono la “forma” della distribuzione delle osservazioni.
 - **Simmetria:** indica quanto la distribuzione sia asimmetrica rispetto al valore “centrale”
 - **Normalità:** quanto distribuzione è simile alla distribuzione di riferimento normale.

33

Indici di asimmetria

Asimmetria: distribuzione delle osservazioni rispetto al valore centrale (ovvero se sono in maggioranza maggiori o minori).

Esempio di 3 popolazioni (N= 1000) con $\bar{o} \approx 3$ e $\sigma^2 \approx 6$.



- **Asimmetria Positiva:** la distribuzione mostra una “coda” più accentuata verso destra (primo istogramma)
- **Asimmetria Negativa:** la distribuzione mostra una “coda” più accentuata verso sinistra (terzo istogramma)


34

Momento centrale terzo

Idea: medio gli scarti dalla media al cubo.

- Perché al cubo?
 - serve il segno, quindi potenza dispari.
 - con lo scarto semplice la somma è sempre nulla!

- Esempio



| m_i | n_i | f_i | $m_i f_i$ | $m_i - \bar{m}$ | $(m_i - \bar{m})^3$ |
|-------|-------|-------|-----------|-----------------|---------------------|
| 0 | 11 | 0,28 | 0 | -1,7 | -4,91 |
| 1 | 10 | 0,25 | 0,25 | -0,7 | -0,34 |
| 2 | 8 | 0,2 | 0,4 | 0,3 | 0,03 |
| 3 | 6 | 0,15 | 0,45 | 1,3 | 2,2 |
| 4 | 2 | 0,05 | 0,2 | 2,3 | 12,17 |
| 5 | 2 | 0,05 | 0,25 | 3,3 | 35,94 |
| 6 | 1 | 0,03 | 0,15 | 4,3 | 79,51 |
| | 40 | | 1,7 | | |

35

Momento centrale terzo standardizzato

- Momento centrale terzo:

$$\mu_3 = \sum_{i=1}^M f_i (m_i - \bar{m})^3$$

- Calcolo in tabella
- Valore legato a σ

| m_i | n_i | f_i | $m_i f_i$ | $m_i - \bar{m}$ | $(m_i - \bar{m})^3$ | $f_i (m_i - \bar{m})^3$ |
|-------|-------|-------|-----------|-----------------|---------------------|-------------------------|
| 0 | 11 | 0,28 | 0 | -1,7 | -4,91 | -1,35 |
| 1 | 10 | 0,25 | 0,25 | -0,7 | -0,34 | -0,09 |
| 2 | 8 | 0,2 | 0,4 | 0,3 | 0,03 | 0,01 |
| 3 | 6 | 0,15 | 0,45 | 1,3 | 2,2 | 0,33 |
| 4 | 2 | 0,05 | 0,2 | 2,3 | 12,17 | 0,61 |
| 5 | 2 | 0,05 | 0,25 | 3,3 | 35,94 | 1,8 |
| 6 | 1 | 0,03 | 0,15 | 4,3 | 79,51 | 1,99 |
| | 40 | | 1,7 | | | 3,06 |

- Momento terzo standardizzato

- Stesso significato momento terzo
- Meno sensibile alla variabilità $\gamma_1 = \frac{\mu_3}{\sigma^3} = \frac{3,06}{(1,55)^3} = 0,83$

36


(primo) Indice di skewness di Pearson

Idea: se la moda “dista” molto dalla media le osservazioni non sono simmetriche

$$\frac{\bar{m} - moda}{\sigma}$$

Esempio

$$\frac{1,7 - 0}{1,57} = 1,08$$




| m_i | n_i | f_i | $m_i f_i$ |
|-----------|-------|-------|------------|
| 0 | 11 | 0,28 | 0 |
| 1 | 10 | 0,25 | 0,25 |
| 2 | 8 | 0,2 | 0,4 |
| 3 | 6 | 0,15 | 0,45 |
| 4 | 2 | 0,05 | 0,2 |
| 5 | 2 | 0,05 | 0,25 |
| 6 | 1 | 0,03 | 0,15 |
| 40 | | | 1,7 |

Indici di Curtosi (Kurtosi)

Curtosi: distribuzione delle osservazioni “vicine” a quelle della distribuzione normale

Esempio: 3 popolazioni (N= 1000) con $\bar{o} \approx 0$ e $\sigma^2 \approx 1$ e $\gamma_2 \approx 0$.



- **Iper-normalità:** l'istogramma delle osservazioni tendono a mostrare un picco vicino al valore centrale (primo istogramma)
- **Ipo-normalità:** le osservazioni tendono a distribuirsi in maniera piatta (terzo istogramma)

38

Momento centrale quarto

- Momento centrale quarto

$$\mu_4 = \sum_{i=1}^M f_i (m_i - \bar{m})^4$$

- Momento centrale quarto normato

$$\beta_2 = \frac{\mu_4}{\sigma^4}$$

- β_2 sempre positivo.
- Una gaussiana ha $\beta_2 = 3$.
- $\beta_2 > 3 \Rightarrow$ iper-normale
- $\beta_2 < 3 \Rightarrow$ ipo-normale


39

Eccesso Curtosi

- Eccesso curtosi

$$\gamma_2 = \frac{\mu_4}{\sigma^4} - 3$$

- Una gaussiana ha $\beta_2 = 3$ quindi $\gamma_2 = 0$.
- $\gamma_2 > 0 \Rightarrow$ iper-normale
- $\gamma_2 < 0 \Rightarrow$ ipo-normale



40