

Le misure di sintesi

1

Le misure di sintesi

- Le misure di sintesi descrivono un insieme di dati attraverso un valore (o modalità) rappresentativo del carattere.
- Alcune sono definiti solo per caratteri quantitativi (medie analitiche), altre per caratteri quantitativi e qualitativi (medie di posizione).

2

La media aritmetica

- La media aritmetica è la più diffusa misura di sintesi per caratteri quantitativi.
- Date n osservazioni, x_1, x_2, \dots, x_n , la media aritmetica è data da

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n}$$

- In forma compatta

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$$

3

- La media aritmetica è calcolata considerando tutti i dati!
- Se il dato più piccolo oppure il dato più grande sono anomali (estremi), tale misura di sintesi potrebbe rivelarsi poco opportuna.
- La media aritmetica è influenzata da valori anomali (misura di sintesi non robusta).
- Dato anomalo: *outlier*

4

- Es. 1: si calcoli la media aritmetica

12 12 14 15 16 16 18 19 21 29

n = 10

$$\bar{x} = \frac{12 + 12 + \dots + 21 + 29}{10} = \frac{172}{10} = 17,2$$

5

- Es. 2: si calcoli la media aritmetica

12 12 14 15 16 16 18 19 21 **290**

n = 10

$$\bar{x} = \frac{12 + 12 + \dots + 21 + 290}{10} = \frac{433}{10} = 43,3$$

6

La media aritmetica per una distribuzione di frequenze

- Per una distribuzione di frequenze con modalità x_1, x_2, \dots, x_k e frequenze n_1, n_2, \dots, n_k , la media aritmetica è calcolata come

$$\bar{x} = \frac{x_1 n_1 + x_2 n_2 + \dots + x_k n_k}{n}$$

- Perché?

$$\underbrace{x_1, \dots, x_1}_{n_1 \text{ volte}} \quad \underbrace{x_2, \dots, x_2}_{n_2 \text{ volte}} \quad \dots \quad \underbrace{x_k, \dots, x_k}_{n_k \text{ volte}}$$

7

La media aritmetica per una distribuzione di frequenze

- In forma compatta

$$\bar{x} = \frac{\sum_{i=1}^k x_i n_i}{n}$$

8

- Esempio: numero dipendenti (Tabella 1, col. 2).
Si calcoli la media aritmetica

x_i	n_i	$x_i n_i$
1	2	2
2	6	12
3	9	27
4	3	12
<i>Totale</i>	20	53

$$\bar{x} = \frac{53}{20} = 2,65$$

9

La media aritmetica per una distribuzione di frequenze in classi

- Per una distribuzione di frequenze in classi si considerano i valori centrali di ogni classe c_1, c_2, \dots, c_k .
- La media aritmetica (approssimata) è

$$\bar{x} \approx \frac{c_1 n_1 + c_2 n_2 + \dots + c_k n_k}{n}$$

- In sintesi

$$\bar{x} \approx \frac{\sum_{i=1}^k c_i n_i}{n}$$

10

- Esempio: fatturato 2012 (Tabella 1, col. 4)

Si calcoli la media aritmetica

<i>Classe</i>	n_i	c_i	$c_i n_i$
2 – 3	3	2,5	7,5
3 – 4	5	3,5	17,5
4 – 5	8	4,5	36
5 – 6	4	5,5	22
<i>Totale</i>	<i>20</i>		<i>83</i>

11

- In formula

$$\bar{x} \approx \frac{83}{20} = 4,15$$

- La media aritmetica così calcolata coinciderebbe con la media aritmetica esatta se ogni valore centrale fosse uguale alla media aritmetica dei valori della classe.

12

La media aritmetica ponderata

- n osservazioni, x_1, x_2, \dots, x_n
- n corrispondenti pesi, p_1, p_2, \dots, p_n
- La media aritmetica ponderata (o pesata) è

$$\bar{x} = \frac{x_1 p_1 + x_2 p_2 + \dots + x_n p_n}{p_1 + p_2 + \dots + p_n}$$

- In forma compatta

$$\bar{x} = \frac{\sum_{i=1}^n x_i p_i}{\sum_{i=1}^n p_i}$$

13

- Viene utilizzata quando si vuole attribuire una diversa importanza (peso) ai dati.
- La media dei voti universitari è una media ponderata con pesi pari ai CFU.
- Esempio: lo studente De Luca ha i seguenti voti (crediti):

26 (9) 28 (12) 30 (12)

$$\bar{x} = \frac{x_1 p_1 + x_2 p_2 + x_3 p_3}{p_1 + p_2 + p_3}$$

$$\bar{x} = \frac{26 \cdot 9 + 28 \cdot 12 + 30 \cdot 12}{9 + 12 + 12} = \frac{930}{33} = 28,18$$

14

- La media calcolata per distribuzioni di frequenze è un esempio di media aritmetica ponderata con $p_i = n_i$.
- Infatti

$$\bar{x} = \frac{x_1 n_1 + x_2 n_2 + \cdots + x_k n_k}{n}$$

e poiché

$$n = n_1 + n_2 + \cdots + n_k$$

$$\bar{x} = \frac{x_1 n_1 + x_2 n_2 + \cdots + x_k n_k}{n_1 + n_2 + \cdots + n_k}$$

15

Alcune proprietà della media aritmetica

- Si definiscono 4 proprietà:
1. La somma dei valori x_1, x_2, \dots, x_n è pari a n volte la media aritmetica

$$\sum_{i=1}^n x_i = n \cdot \bar{x}$$

16

2. La somma delle differenze (scarti) dei valori dalla media è pari a 0

$$\sum_{i=1}^n (x_i - \bar{x}) = 0$$

17

3. Se un insieme di n dati x_1, x_2, \dots, x_n è suddiviso in L sottoinsiemi di numerosità n_1, n_2, \dots, n_L tali che

$$n_1 + n_2 + \dots + n_L = n$$

e con medie $\bar{x}_{(1)}, \bar{x}_{(2)}, \dots, \bar{x}_{(L)}$ allora la media complessiva è

$$\bar{x} = \frac{\bar{x}_{(1)}n_1 + \bar{x}_{(2)}n_2 + \dots + \bar{x}_{(L)}n_L}{n_1 + n_2 + \dots + n_L}$$

(la media complessiva è la media ponderata delle medie dei sottoinsiemi con pesi pari alle numerosità degli stessi)

18

- Lo stipendio medio mensile nell'Italia del Nord, calcolato su 22,8 milioni di persone, è pari a 1784, mentre nell'Italia centrale, calcolato su 5,1 milioni di persone, è 1004.
- Calcolare lo stipendio medio dell'Italia Centro-Nord.

$$\bar{x}_{(1)} = 1784, n_1 = 22,8$$

$$\bar{x}_{(2)} = 1004, n_2 = 5,1$$

$$\bar{x} = \frac{1784 \cdot 22,8 + 1004 \cdot 5,1}{22,8 + 5,1} = \frac{45795,6}{27,9} = 1641,42$$

19

4. Data una variabile X e considerata una trasformazione lineare

$$Y = a + bX$$

allora la media della variabile Y è pari a

$$\bar{Y} = a + b\bar{X}$$

20

- Lo stipendio annuale del sig. Smith è pari a 6000 euro più il 10% del fatturato aziendale X . Se il fatturato medio è pari a 300000, qual è lo stipendio medio del sig. Smith?

- Lo stipendio del sig. Smith è

$$Y = 6000 + 0,10 \cdot X$$

- Quindi

$$\bar{Y} = 6000 + 0,10 \cdot \bar{X}$$

$$\bar{Y} = 6000 + 0.10 \cdot 300000 = 36000$$

21

La trimmed mean

- Consiste in una media aritmetica calcolata su una percentuale dei valori centrali.
- La trimmed mean all' $\alpha\%$ è calcolata sull' $\alpha\%$ dei valori centrali.
- È indicata con $\bar{x}_{TR}(\alpha\%)$
- È una media non influenzata da valori anomali (misura di sintesi robusta).

22

- Es. 1: si calcoli la trimmed mean all'80%

• ~~12~~ 12 14 15 16 16 18 19 21 ~~29~~

- $n = 10$

- Si considera l'80% dei valori centrali ($0,80 \cdot 10 = 8$).

- Si escludono i 2 valori più estremi (il minore e il maggiore).

- Quindi

$$\bar{x}_{TR}(80\%) = \frac{12 + 14 + \dots + 19 + 21}{8} = \frac{131}{8} = 16,375$$

23

- Es. 2: si calcoli la trimmed mean all'80%

• ~~12~~ 12 14 15 16 16 18 19 21 ~~290~~

- $n = 10$

- Si considera l'80% dei valori centrali ($0,80 \cdot 10 = 8$).

- Si escludono i 2 valori più estremi (il minore e il maggiore).

- Quindi

$$\bar{x}_{TR}(80\%) = \frac{12 + 14 + \dots + 19 + 21}{8} = \frac{131}{8} = 16,375$$

24

- Es. 3: si calcoli la trimmed mean al 90%

<i>Numero dipendenti</i>	<i>Frequenze (assolute)</i>
1	2
2	6
3	9
4	3
<i>Totale</i>	20

25

- $n = 20$
- Si considera il 90% dei valori centrali ($0,90 \cdot 20 = 18$).
- Si escludono i 2 valori più estremi.
- Il minore è 1, il maggiore è 4.

26

- La distribuzione di frequenze da considerare diviene

Numero dipendenti	Frequenze (assolute)
1	2 1
2	6
3	9
4	3 2
<i>Totale</i>	20 18

$$\begin{aligned}\bar{x}_{TR}(90\%) &= \frac{1 \cdot 1 + 2 \cdot 6 + 3 \cdot 9 + 4 \cdot 2}{18} \\ &= \frac{48}{18} = 2,67\end{aligned}$$

27

La media geometrica

- Dati n valori positivi, x_1, x_2, \dots, x_n , la media geometrica è data da

$$\bar{x}_g = \sqrt[n]{x_1 \cdot x_2 \cdot \dots \cdot x_n}$$

28

- Il suo principale utilizzo riguarda tassi di variazione percentuali (TVP), osservati nel tempo.
- Obiettivo: calcolare il tasso medio di variazione percentuale (TMVP) attraverso la media geometrica dei coefficienti di incremento (CI).
- Il coefficiente di incremento è dato da

$$CI = 1 + \frac{TVP}{100}$$

29

<i>Anno</i>	<i>Tassi di variazione (%)</i>	<i>Coefficienti di incremento</i>
1	8%	1,08
2	10%	1,10
3	12%	1,12
4	14%	1,14

30

Si ottiene

$$\bar{x}_g = \sqrt[4]{1,08 \cdot 1,10 \cdot 1,12 \cdot 1,14}$$

$$\bar{x}_g = \sqrt[4]{1,5168}$$

$$\bar{x}_g = 1,1098$$

(media geometrica dei tassi di incremento)

31

E il tasso medio di variazione?

Poiché

$$CI = 1 + \frac{TVP}{100}$$

allora

$$\bar{x}_g = 1 + \frac{TMVP}{100}$$

$$TMVP = 100(\bar{x}_g - 1)$$

32

Nell'esempio

$$TMVP = 100(1,1098 - 1)$$

Il tasso medio di variazione (%) è

$$TMVP = 10,98$$

33

Proprietà della media geometrica

- Il logaritmo naturale della media geometrica è pari alla media aritmetica semplice dei logaritmi dei valori.
- Infatti, applicando il logaritmo naturale si ottiene

$$\log \bar{x}_g = \log \sqrt[n]{x_1 \cdot x_2 \cdot \dots \cdot x_n}$$

$$\log \bar{x}_g = \log(x_1 \cdot x_2 \cdot \dots \cdot x_n)^{1/n}$$

$$\log \bar{x}_g = \frac{1}{n} \log(x_1 \cdot x_2 \cdot \dots \cdot x_n)$$

$$\log \bar{x}_g = \frac{1}{n} (\log(x_1) + \log(x_2) + \dots + \log(x_n))$$

34

La mediana

- La mediana è il valore (o modalità) centrale di un insieme di dati ordinati in senso crescente. Può essere individuata per caratteri quantitativi e caratteri qualitativi ordinabili.
- La mediana, indicata con Me , è preceduta dal 50% dei dati più piccoli ed è seguita dal 50% dei dati più grandi.
- Non è influenzata da valori anomali (misura di sintesi robusta).
- Distinzione tra
 1. numero di osservazioni n dispari
 2. numero di osservazioni n pari

35

1. n dispari: ordinati i dati in senso crescente, la mediana è il valore in posizione $(n+1)/2$.

Es. 1 ($n=5$)

23 25 27 42 22

Ordinati in senso crescente

22 23 25 27 42

Il valore centrale è 25, in posizione $(5+1)/2 = 3$

Dunque $Me = 25$

36

2. n pari: ordinati i dati in senso crescente, è la media aritmetica dei valori in posizione $n/2$ e $n/2+1$.

Es. 2 ($n=6$)

23 25 27 42 22 18

Ordinati in senso crescente

18 22 23 25 27 42

I valori centrali sono 23 e 25, in posizione $6/2=3$ e $6/2+1=4$

Dunque

$$Me = \frac{23 + 25}{2} = 24$$

37

Mediana per distribuzione di frequenze

<i>Numero dipendenti</i>	<i>Frequenze (assolute)</i>
1	2
2	6
3	9
4	3
<i>Totale</i>	20

- $n = 20$ (pari)
- Mediana = media aritmetica dei valori in posizione $n/2$ e $n/2+1$.

38

- Valore in posizione $20/2 = 10$? E' il valore 3
- Valore in posizione $20/2 + 1 = 11$? E' il valore 3

<i>Numero dipendenti</i>	<i>Frequenze (assolute)</i>	<i>Frequenze cumulate</i>
1	2	2
2	6	8
3	9	17
4	3	20
<i>Totale</i>	20	

$$Me = \frac{3 + 3}{2} = 3$$

39

Mediana per distribuzione di frequenze in classi

<i>Classi</i>	<i>Frequenze (assolute)</i>
2 – 3	3
3 – 4	5
4 – 5	8
5 – 6	4
<i>Totale</i>	20

1. Individuazione della classe mediana
2. Individuazione della mediana all'interno della classe mediana (metodo analitico e grafico).

40

1. Individuazione della classe mediana

- Si considerano le frequenze relative cumulate


<i>Classi</i>	<i>Frequenze (assolute)</i>	<i>Frequenze relative</i>	<i>Frequenze relative cumulate</i>
2 – 3	3	0,15	0,15
3 – 4	5	0,25	0,40
4 – 5	8	0,40	0,80
5 – 6	4	0,20	1
<i>Totale</i>	<i>20</i>		

- La classe mediana è la classe 4-5, poiché $0,40 < \mathbf{0,50} < 0,80$.

41

2. Individuazione della mediana (metodo analitico)

- Il metodo analitico si basa su una proporzione.



$$(5 - 4) : (0,80 - 0,40) = (Me - 4) : (0,50 - 0,40)$$

42

2. Individuazione della mediana (metodo analitico)

$$(5 - 4) : (0,80 - 0,40) = (Me - 4) : (0,50 - 0,40)$$

$$(Me - 4) = \frac{(5 - 4)(0,50 - 0,40)}{(0,80 - 0,40)}$$

$$Me = 4 + \frac{0,10}{0,40}$$

$$Me = 4,25$$


43

2. Individuazione della mediana (metodo grafico)

- Il metodo grafico si basa sul poligono cumulativo (con frequenze relative cumulate).

44

Poligono cumulativo con frequenze relative cumulate



45

Mediana per caratteri qualitativi ordinabili Giudizi sulla politica sanitaria di 203 individui

<i>Giudizio</i>	n_i	N_i
Scarso	13	13
Sufficiente	48	61
Buono	77	138
Ottimo	65	203
<i>Totale</i>	203	

46

- Poiché $n = 203$ è dispari, la mediana è la modalità centrale, ovvero la modalità in posizione $(n+1)/2 = 102$
- Il giudizio mediano è «Buono».

47

Robustezza della mediana

- Es. 1 ($n=10$):
- 12 12 14 15 16 16 18 19 21 29
- La mediana è $(16+16)/2 = 16$
- $Me = 16$
- Es. 2 ($n=10$):
- 12 12 14 15 16 16 18 19 21 **290**
- $Me = 16$
- La mediana non è influenzata da 290 (valore anomalo).

48

I quartili

- Si definiscono 3 quartili.
- Il primo quartile (Q_1) è quel valore preceduto dal 25% ($1/4$) dei dati e seguito dal 75% ($3/4$).
- Il secondo quartile è quel valore preceduto dal 50% dei dati e seguito dal 50% (è proprio la mediana).
- Il terzo quartile (Q_3) è quel valore preceduto dal 75% dei dati e seguito dal 25%.

49

Individuazione di Q_1

- Per l'individuazione di Q_1 si guarda alla frequenza relativa cumulata immediatamente maggiore di 0,25.

50

Individuazione di Q_1

x_i	n_i	N_i	F_i
1	2	0,10	0,10
2	6	0,30	0,40
3	9	0,45	0,85
4	3	0,15	1
<i>Totale</i>	20	1	

- La F_i di riferimento è 0,40
- $Q_1 = 2$

51

Individuazione di Q_1

- Se risulta una frequenza relativa cumulata uguale a 0,25 allora Q_1 è la media aritmetica del valore corrispondente e del successivo valore.

52

Individuazione di Q_1

x_i	n_i	f_i	F_i
10	2	0,10	0,10
20	3	0,15	0,25
30	10	0,50	0,75
40	5	0,25	1
<i>Totale</i>	20	1	

- $Q_1 = (20 + 30) / 2 = 25$

53

Individuazione di Q_3

- Per l'individuazione di Q_3 si guarda alla frequenza relativa cumulata immediatamente maggiore di 0,75.

54

Individuazione di Q_3

x_i	n_i	f_i	F_i
1	2	0,10	0,10
2	6	0,30	0,40
3	9	0,45	0,85
4	3	0,15	1
<i>Totale</i>	20	1	

- La F_i di riferimento è 0,85
- $Q_3 = 3$

55

Individuazione di Q_3

- Se risulta una frequenza relativa cumulata uguale a 0,75 allora Q_3 è la media aritmetica del valore corrispondente e del successivo valore.

56

Individuazione di Q_3

x_i	n_i	f_i	F_i
10	2	0,10	0,10
20	3	0,15	0,25
30	10	0,50	0,75
40	5	0,25	1
<i>Totale</i>	20	1	

- $Q_3 = (30 + 40) / 2 = 35$

57

Quartili per distribuzioni di frequenze in classi

1. Individuazione della classe che contiene Q_1 (Q_3).
2. Individuazione di Q_1 (Q_3) nell'ambito della classe di cui al punto 1.

58

<i>Classi</i>	<i>Frequenze (assolute)</i>	<i>Frequenze relative</i>	<i>Frequenze relative cumulate</i>
2 – 3	3	0,15	0,15
3 – 4	5	0,25	0,40
4 – 5	8	0,40	0,80
5 – 6	4	0,20	1
<i>Totale</i>	<i>20</i>		

- La classe che contiene Q_1 è la classe 3-4, poiché $0,40 > 0,25$.

59

Metodo analitico

Proporzione



$$(4 - 3) : (0,40 - 0,15) = (Q_1 - 3) : (0,25 - 0,15)$$

60

$$(4 - 3):(0,40 - 0,15) = (Q_1 - 3):(0,25 - 0,15)$$


$$(Q_1 - 3) = \frac{(4 - 3)(0,25 - 0,15)}{(0,40 - 0,15)}$$

$$Q_1 = 3 + \frac{0,10}{0,25}$$

$$Q_1 = 3,4$$

61

Metodo grafico



62

I percentili

- I percentili fanno riferimento ad una suddivisione dei dati in cento parti.
- Es. 1: il 34° percentile (P_{34}) è quel valore che è preceduto dal 34% dei dati ed è seguito dal 66%.
- Es. 2: il 90° percentile (P_{90}) è quel valore che è preceduto dal 90% dei dati ed è seguito dal 10%.
- Da notare che
- $P_{25} = Q_1$
- $P_{50} = Me$
- $P_{75} = Q_3$

63

Calcolo del 90° percentile (P_{90})


Classi	n_i	f_i	F_i
2 – 3	3	0,15	0,15
3 – 4	5	0,25	0,40
4 – 5	8	0,40	0,80
5 – 6	4	0,20	1
Totale	20	1	

- La classe che contiene P_{90} è la classe 5-6, poiché $1 < 0,90$.

64

Metodo analitico

Proporzione



$$(6 - 5) : (1 - 0,80) = (P_{90} - 5) : (0,90 - 0,80)$$

65

$$(6 - 5) : (1 - 0,80) = (P_{90} - 5) : (0,90 - 0,80)$$


$$(P_{90} - 5) = \frac{(6 - 5)(0,90 - 0,80)}{(1 - 0,80)}$$

$$P_{90} = 5 + \frac{0,10}{0,20}$$

$$P_{90} = 5,5$$

66

Metodo grafico



67

La moda

- La moda è la modalità che si presenta con la massima frequenza (il maggior numero di volte).
- Può essere individuata per variabili e mutabili.

68

x_i	n_i
1	2
2	6
3	9
4	3
<i>Totale</i>	20

- La moda è 3, poiché il valore 3 viene osservato 9 volte
- $Mo = 3$

69

Moda per distribuzioni di frequenze in classi

<i>Classi</i>	n_i	h_i
2 – 3	4	4
3 – 5	13	6,5
5 – 10	1	0,2
10 – 20	2	0,2
<i>Totale</i>	20	

- La classe modale è la classe 3-5, poiché ad essa è associata la maggiore densità di frequenza.


70

- Distribuzione
 - zeromodale: nessuna moda
 - unimodale: una sola moda
 - bimodale: due mode
 - plurimodale: più mode

71

Esempio di distribuzione zeromodale


x_i	n_i
1	5
2	5
3	5
4	5
5	5
6	5
<i>Totale</i>	<i>30</i>



72

Esempio di distribuzione unimodale

x_i	n_i
1	15
2	25
3	34
4	28
5	26
6	12
<i>Totale</i>	<i>140</i>




$Mo = 3$

73

Esempio di distribuzione bimodale

x_i	n_i
1	15
2	25
3	34
4	34
5	26
6	12
<i>Totale</i>	<i>146</i>



$Mo = 3$

$Mo = 4$

74

- Da notare che per distribuzioni di frequenze con classi di uguale ampiezza la classe con maggiore densità di frequenza è la classe con maggiore frequenza assoluta.