

LEZIONI DI STATISTICA MEDICA

Indici di posizione



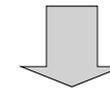
Sezione di Epidemiologia & Statistica Medica
Università degli Studi di Verona

1

“un qualsiasi insieme di dati porta in sé una certa quantità di informazione”

OBIETTIVO:
riassumere tutta l'informazione possibile in modo SINTETICO ed EFFICACE

diversi strumenti e possibilità offerti dalla statistica



STATISTICHE DI BASE



2

Una serie di dati numerici è compiutamente descritta da tre **PROPRIETÀ PRINCIPALI**:

1. La tendenza centrale o posizione
2. La dispersione o variabilità
3. La forma

Queste misure descrittive sintetiche sono chiamate:

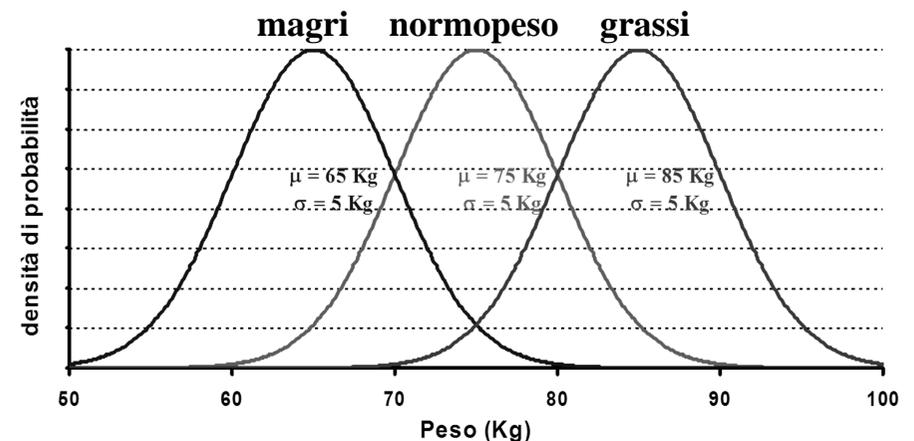
STATISTICHE (\bar{x}, s, p) → quando sono calcolate su un **CAMPIONE** di dati (si esprimono con lettere dell'alfabeto latino)

PARAMETRI (μ, σ, π) → quando descrivono la **POPOLAZIONE** (si esprimono con lettere dell'alfabeto greco)

3



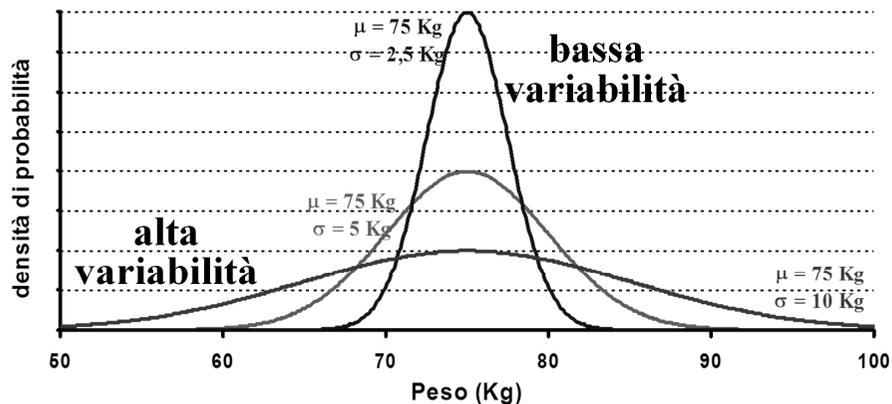
Posizione differente, uguale dispersione



1

4

Dispersione differente, uguale posizione

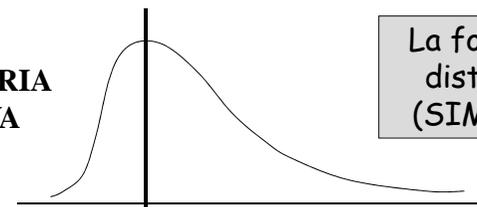


2

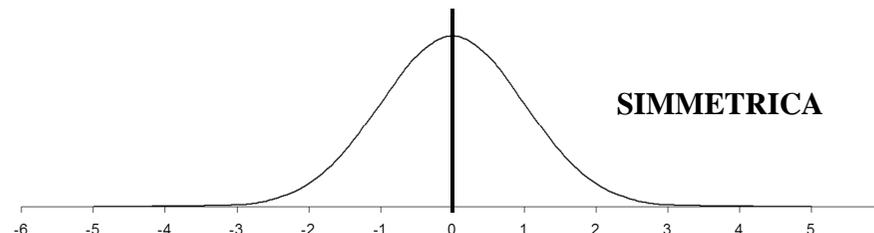
5

ASIMMETRIA
POSITIVA

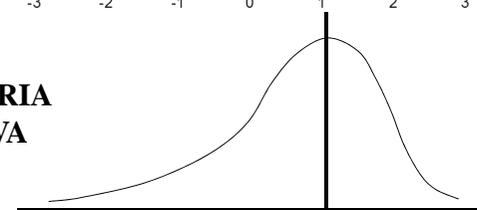
La forma di una
distribuzione
(SIMMETRIA)



SIMMETRICA



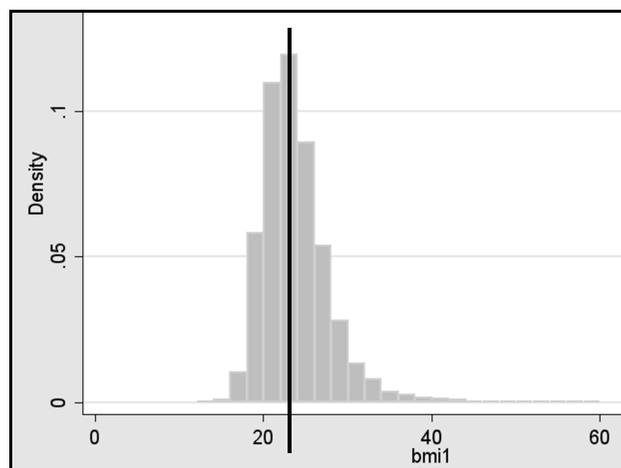
ASIMMETRIA
NEGATIVA



3

6

II BMI in ECRHS (European Community Respiratory Health Survey)



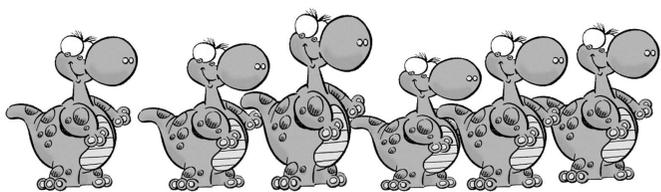
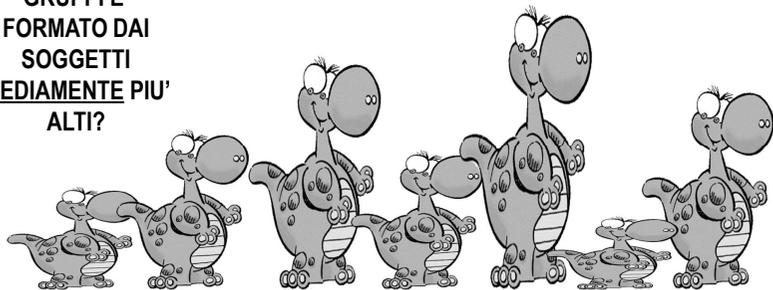
7

INDICI DI POSIZIONE

8

QUALE DEI DUE GRUPPI E' FORMATO DAI SOGGETTI MEDIAMENTE PIU' ALTI?

la variabile d'interesse è l'ALTEZZA



9

INDICI DI POSIZIONE

(measures of location or central tendency)

- 1. MODA
 - 2. MEDIA
 - 3. MEDIANA
-
- aritmetica
 - armonica
 - geometrica



MODA

E' la scelta fatta dalla maggioranza della popolazione, lo stile che "tutti" seguono

in statistica non è diverso

Si definisce moda (*classe modale*) di un insieme di dati o di una distribuzione di frequenza la modalità / il valore (l'intervallo di classe) della variabile cui corrisponde la massima frequenza.

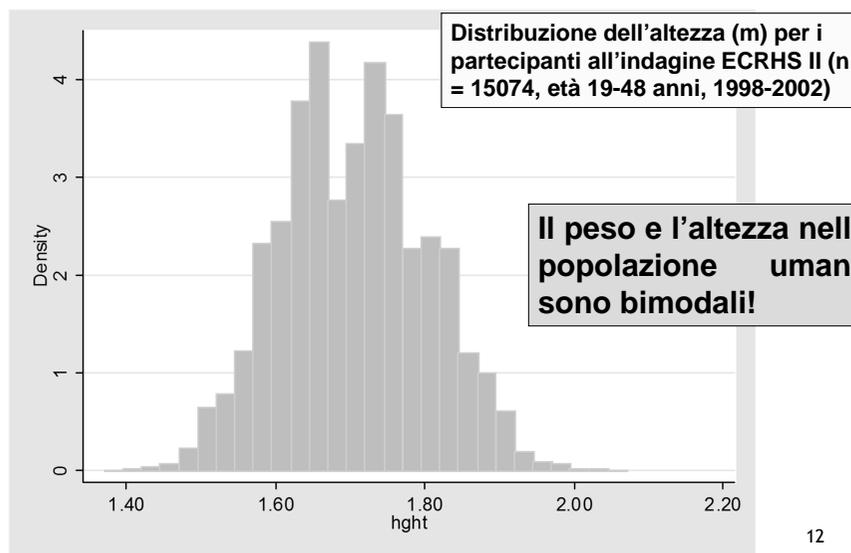
esempio:
X = tipo di parto
(50 neonati)

modalità x_i	frequenza assoluta n_i	frequenza relativa p_i	frequenza relativa percentuale p_i (%)
normale	35	0.70	70%
forcipe	1	0.02	2%
cesareo	14	0.28	28%
TOTALE	50	1.00	100%

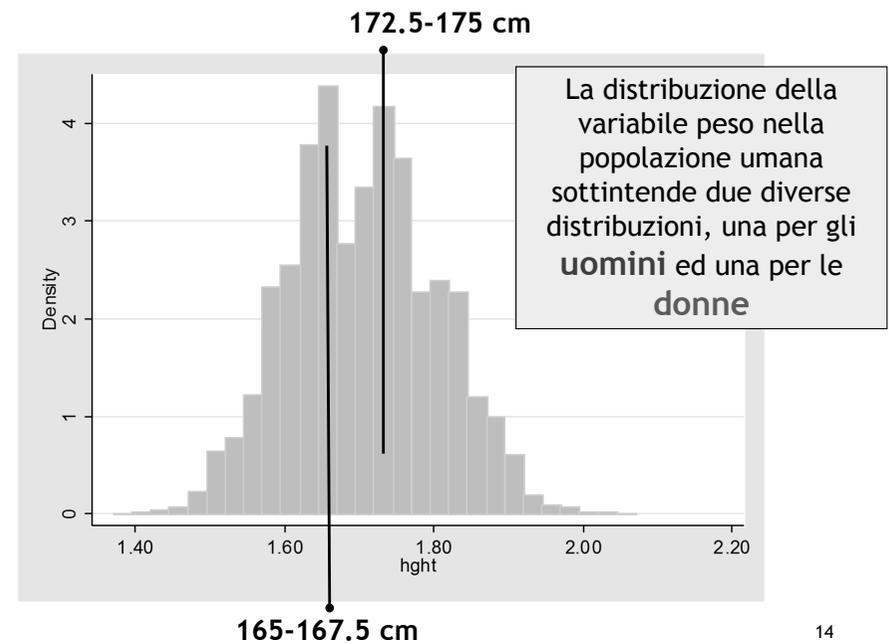
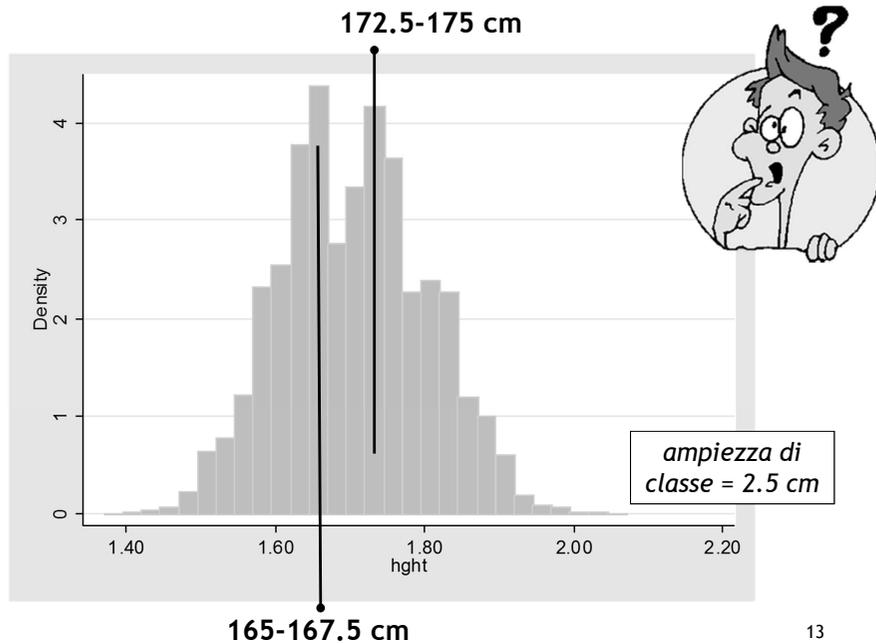
MODA

11

MA LA MODA E' SEMPRE UNA SOLA?



12



MEDIANA

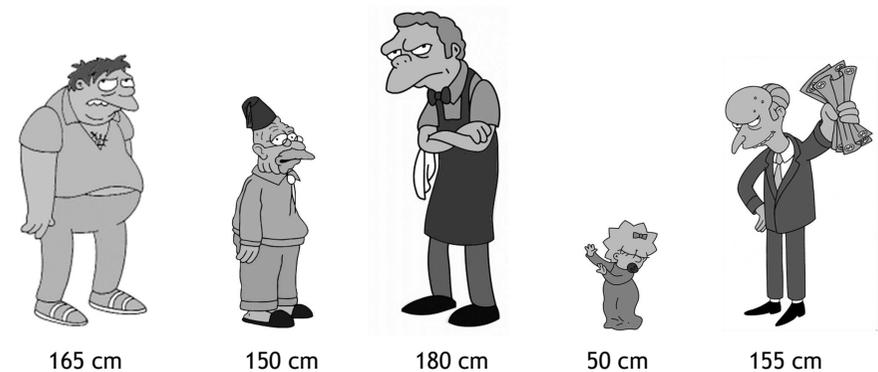
- Il valore centrale di una serie **ORDINATA** di dati
- Le osservazioni vengono separate dal valore mediano in due parti numericamente uguali
- Mediana (Me) è sinonimo di **50-esimo percentile** o di **II quartile**

se n è *dispari* \longrightarrow $Me = x_{[(n+1)/2]}$

se n è *pari* \longrightarrow $Me = [x_{n/2} + x_{(n/2+1)}] / 2$

es. sulla mediana

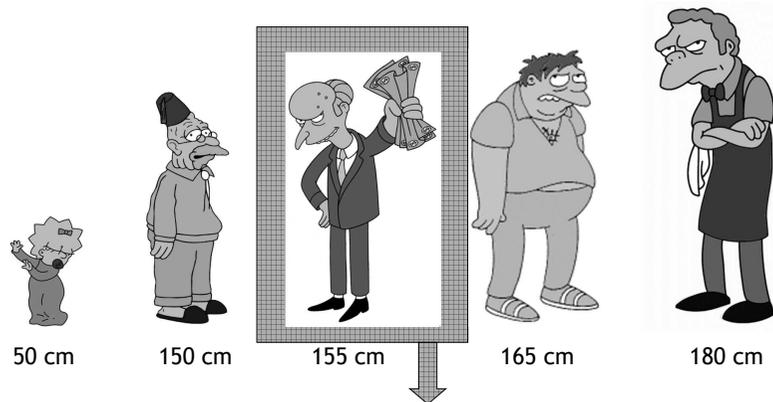
campione di 5 unità
variabile d'interesse = altezza



1. metto le unità in **ORDINE** crescente di altezza

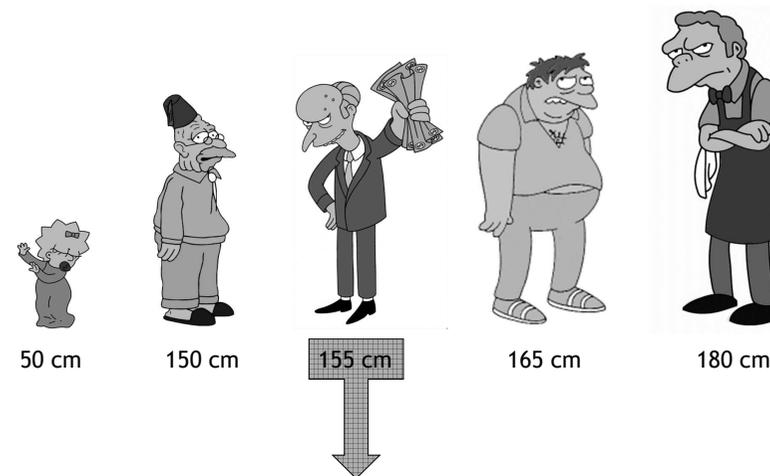
es. sulla mediana

campione di 5 unità
variabile d'interesse = altezza



2. identifico l'unità centrale nella serie ordinata di dati

17



2. la mediana è il **VALORE** che la variabile altezza assume sull'unità che divide il campione in due parti numericamente uguali

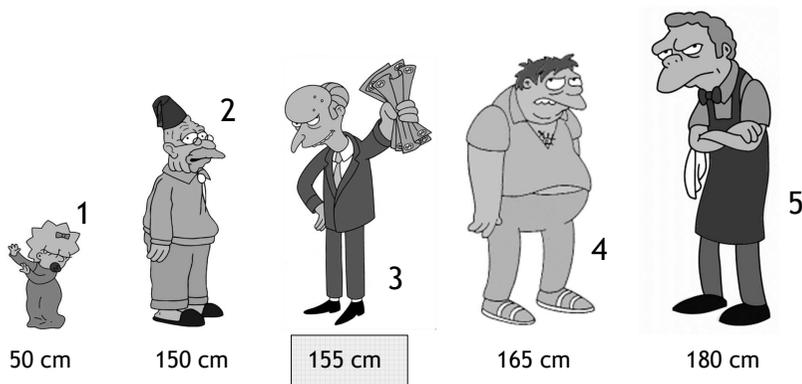
18

formalmente:

n è dispari



$$Me = x_{[(n+1)/2]} = x_{(5+1)/2} = x_3$$



NB: le misure di posizione sono *valori* o *modalità*,
NON *frequenze*!

19

esercizio (moda e mediana)

1. VARIABILE QUALITATIVA
2. VARIABILE QUANTITATIVA

20

ESERCIZIO - I

I dati seguenti si riferiscono all'abitudine al fumo in un campione di 168 soggetti senza bronchite cronica di età 20-44 anni:

X = abitudine al fumo

x_i = non fumatore
ex fumatore
moderato fumatore
forte fumatore



	frequenza assoluta
non fumatore	74
ex fumatore	37
moderato fumatore	34
forte fumatore	23
Totale	168

E' possibile determinare la moda e la mediana di questa distribuzione di frequenza? Se la risposta è affermativa calcolatele.

SOLUZIONE - I

	frequenza assoluta	assoluta cumulata
non fumatore	74	74
ex fumatore	37	111
moderato fumatore	34	145
forte fumatore	23	168
Totale	168	

CALCOLO DELLA MODA

massima frequenza assoluta

MODA:
non fumatore



SOLUZIONE - I



CALCOLO DELLA MEDIANA

	frequenza assoluta	assoluta cumulata
non fumatore	74	74
ex fumatore	37	111
moderato fumatore	34	145
forte fumatore	23	168
Totale	168	

per le osservazioni con rango 84 e 85 la variabile assume questa modalità

MEDIANA:
ex fumatore

le osservazioni centrali hanno rango:

$$- n/2 = 168/2 = 84$$

$$- n/2 + 1 = 84 + 1 = 85$$

ESERCIZIO - II

I dati seguenti si riferiscono al livello di emoglobina (X) in g/100 ml misurato in un campione di 70 donne:



1. Determinate la mediana della distribuzione (dati individuali).

9	11,4	12,9
9,3	11,4	13
9,4	11,4	13,1
9,7	11,5	13,1
10,2	11,6	13,2
10,2	11,6	13,3
10,3	11,7	13,3
10,4	11,7	13,4
10,4	11,8	13,4
10,5	11,8	13,5
10,6	11,9	13,5
10,6	11,9	13,6
10,7	12	13,7
10,8	12	13,7
10,8	12,1	14,1
10,9	12,1	14,6
10,9	12,1	14,6
10,9	12,2	14,7
11	12,3	14,9
11	12,5	15
11,1	12,5	
11,1	12,7	
11,2	12,9	
11,2	12,9	
11,3	12,9	

SOLUZIONE - II

$n = 70 \rightarrow$ pari



le osservazioni centrali hanno rango:

- $n/2 = 70/2 = 35$
- $n/2 + 1 = 70/2 + 1 = 36$

$$\text{MEDIANA} = (11.8 + 11.9) / 2 = 11.85 \text{ g/100mL}$$

osservazione con rango 35

osservazione con rango 36

9	11,4	12,9
9,3	11,4	13
9,4	11,4	13,1
9,7	11,5	13,1
10,2	11,6	13,2
10,2	11,6	13,3
10,3	11,7	13,3
10,4	11,7	13,4
10,4	11,8	13,4
10,5	11,8	13,5
10,6	11,9	13,5
10,6	11,9	13,6
10,7	12	13,7
10,8	12	13,7
10,8	12,1	14,1
10,9	12,1	14,6
10,9	12,1	14,6
10,9	12,2	14,7
11	12,3	14,9
11	12,5	15
11,1	12,5	
11,1	12,7	
11,2	12,9	
11,2	12,9	
11,3	12,9	

25

I PERCENTILI

K-MO PERCENTILE (n_i)

Quel VALORE x_i della variabile tale per cui il k% delle osservazioni del campione assume valori $\leq x_i$.

K è noto anche come RANGO PERCENTILICO

I PERCENTILI PIU' NOTI:

25° \rightarrow 1° QUARTILE

50° \rightarrow 2° QUARTILE o MEDIANA

75° \rightarrow 3° QUARTILE

3° QUARTILE - 1° QUARTILE = DIFFERENZA INTERQUARTILICA

26

ESEMPIO:

Un ragazzo ha la glicemia a 90 mg/dl. Nella sua scuola ci sono **700** ragazzi. Se ordiamo la glicemia in ordine crescente questo ragazzo occupa la posizione **500** (rango assoluto).



PIERINO

Qual è il rango percentilico?

$$\text{RangoPercentilico} = \text{RangoAssoluto} / (n+1) * 100$$

$$500 / (700+1) * 100 = 0,713 * 100 = 71,3 \sim 71$$

Il valore di 90 mg/dl corrisponde al 71-esimo percentile

27

CALCOLO DEL K-ESIMO PERCENTILE - 1

(1. Dati individuali disponibili)

1. Si individua il rango assoluto corrispondente al **k-esimo** percentile

$$\text{Rango Assoluto} = (n + 1) * k / 100$$

2. Si riporta il VALORE dell'osservazione cui corrisponde quel determinato rango

28

Esempio

la mediana (*50-esimo percentile*, $k = 50$) di un campione di 89 individui ha **rango**:

$$(89 + 1) * 50 / 100 = 45$$

il 50-esimo percentile sarà il valore osservato per la variabile di interesse nell'unità statistica con rango 45



29

CALCOLO DEL K-ESIMO PERCENTILE - 2

(2. Dati disponibili in classi sotto forma di tabella di frequenza)

Nel caso **ad esempio** del 50-esimo percentile (mediana):

- Si individua la **CLASSE MEDIANA**, ovvero la classe in cui la frequenza relativa cumulata supera o coincide con il 50%
- esiste una formula per ottenere a questo punto una stima accurata del valore della mediana (si procede per *interpolazione lineare*).

Per gli scopi del corso è sufficiente, partendo dai dati raggruppati in classi, costruire la curva delle frequenze cumulate (ogiva) e identificare graficamente il valore della mediana (si veda diapositiva successiva)

30

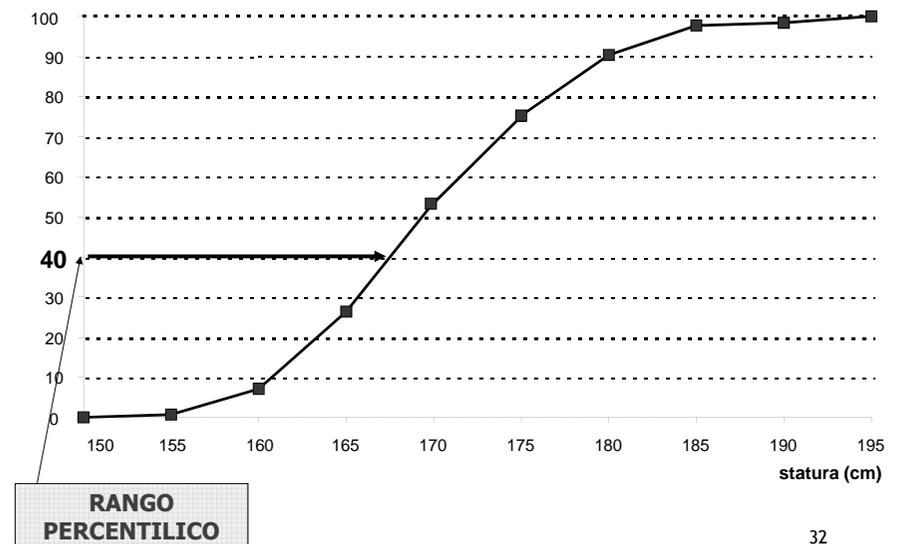
CALCOLO DEL K-ESIMO PERCENTILE - 3

(3. Dati non disponibili, si dispone solamente della **rappresentazione grafica** della frequenza relativa cumulata)

1. Sull'asse delle ordinate (Y), dove è rappresentata la *frequenza relativa cumulata*, si individua il punto corrispondente al **rango percentilico (k)**
2. da qui si traccia una linea orizzontale, che intersechi la linea spezzata (ogiva), che rappresenta l'andamento della frequenza relativa cumulata

31

Esempio: calcolo del **40-esimo percentile**

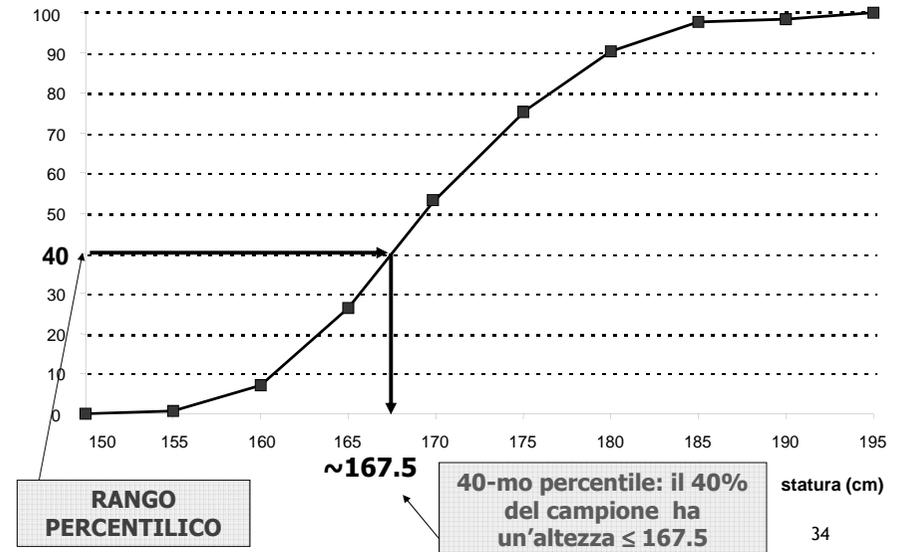


32

3. dal punto d'intersezione così individuato, si traccia una linea verticale fino all'intersezione con l'asse delle ascisse (X), che rappresenta i valori della variabile oggetto dello studio

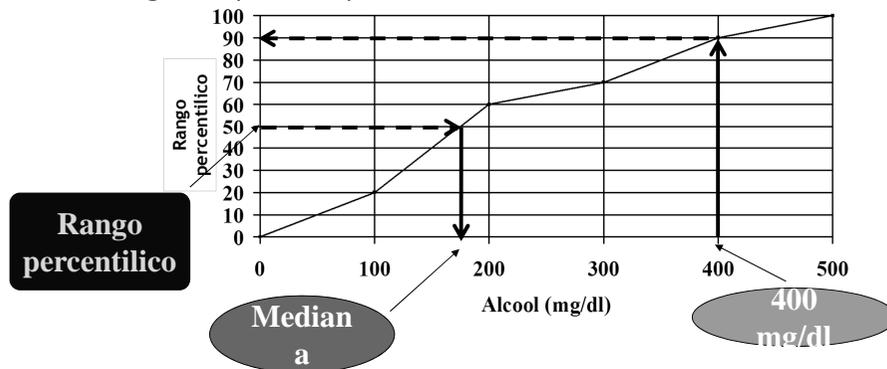
4. il valore della variabile in corrispondenza del punto d'intersezione con le X rappresenta il k-esimo percentile

Esempio: calcolo del **40-esimo percentile**



Un'applicazione pratica:

1. si vuole determinare i livelli ematici di alcool, in un gruppo di 250 soggetti (la cui distribuzione di frequenza cumulata è rappresentata in figura), in corrispondenza del **50-esimo percentile**.
2. si vuole conoscere a che percentile corrisponde un livello ematico di alcol di **400 mg/dl** in questo campione



1. La **mediana** è circa pari a **175 mg/dl**
2. **400 mg/dl** corrisponde circa al **90-esimo percentile**

ESERCIZIO

I dati seguenti si riferiscono al livello di emoglobina (X) in g/100 ml misurato in un campione di 70 donne:



9	11,4	12,9
9,3	11,4	13
9,4	11,4	13,1
9,7	11,5	13,1
10,2	11,6	13,2
10,2	11,6	13,3
10,3	11,7	13,3
10,4	11,7	13,4
10,4	11,8	13,4
10,5	11,8	13,5
10,6	11,9	13,5
10,6	11,9	13,6
10,7	12	13,7
10,8	12	13,7
10,8	12,1	14,1
10,9	12,1	14,6
10,9	12,1	14,6
10,9	12,2	14,7
11	12,3	14,9
11	12,5	15
11,1	12,5	
11,1	12,7	
11,2	12,9	
11,2	12,9	
11,3	12,9	

2. Raggruppate i dati in intervalli di ampiezza 1 g/100 ml.
3. Determinate la moda e la mediana della distribuzione (dati raggruppati in intervalli di classe).

SOLUZIONE

CLASSE	FREQUENZA ASSOLUTA	FREQUENZA CUMULATA ASSOLUTA	FREQUENZA CUMULATA RELATIVA %
[9-10)	4	4	$(4/70) * 100 = 5.7$
[10-11)	14	$4+14 = 18$	$(18/70) * 100 = 25.7$
[11-12)	19	$18+19 = 37$	$(37/70) * 100 = 52.8$
[12-13)	14	$37+14 = 51$	$(51/70) * 100 = 72.8$
[13-14)	13	64	91.4
[14-15]	6	70	100.0
TOTALE	70		

CLASSE MODALE = [11-12) g/100 mL

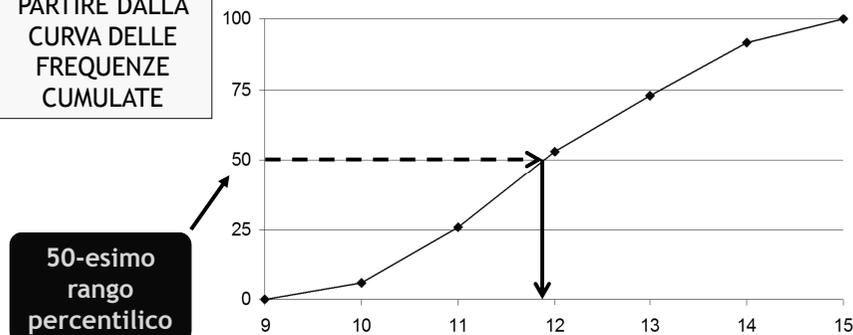
CLASSE MEDIANA:

1. le osservazioni centrali hanno rango: 35 e 36
2. classe mediana: [11-12)

37

SOLUZIONE

VALUTAZIONE DELLA MEDIANA A PARTIRE DALLA CURVA DELLE FREQUENZE CUMULATE



La mediana (50-esimo percentile) è pari a circa 11.9 g/100 mL

38



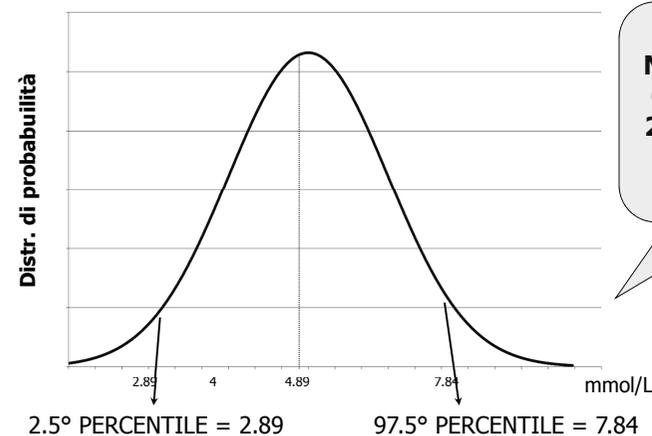
ESEMPI DELL'UTILITA' DEI PERCENTILI NELLA PRATICA CLINICA

1. intervallo di normalità di un parametro biologico
2. curve auxologiche

39

PERCENTILI E VALORI DI NORMALITA'

Esempio: i valori di normalità dell'UREA sono compresi tra **2.89** e **7.84** mmol/L. Rappresentiamo la distribuzione di frequenza dei dati relativi ai valori della concentrazione di urea:



40

MEDIA ARITMETICA

La media aritmetica di un insieme di osservazioni è pari alla somma dei **valori** diviso il numero totale delle osservazioni

Formalmente: siano (x_1, x_2, \dots, x_n) le osservazioni della variabile X su un campione di n unità statistiche, allora

$$\bar{x} = \sum_{i=1}^n x_i / n = (x_1 + x_2 + \dots + x_n) / n$$

esempio:
(8 osservazioni)

	5	16	13	27	11	5	13	13
	↑	↑	↑	↑	↑	↑	↑	↑
	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8

$$\bar{x} = (5+16+13+27+11+5+13+13)/8 = 103/8 = 12.9 \quad 45$$



MEDIA ARITMETICA PONDERATA - I

Se una variabile assume lo stesso valore in più unità statistiche, la media può essere calcolata moltiplicando quel valore per la frequenza con cui compare nella distribuzione

$$\bar{x} = \frac{\sum_{i=1}^k x_i n_i}{n} = \frac{x_1 n_1 + x_2 n_2 + \dots + x_k n_k}{n}$$



k = numero di valori che la variabile può assumere
 x_i = valore assunto dalla variabile nel soggetto i -esimo
 n_i = frequenza corrispondente al valore x_i

46



$$\bar{x} = \frac{\sum_{i=1}^k x_i n_i}{n} = \frac{x_1 n_1 + x_2 n_2 + \dots + x_k n_k}{n}$$

k = numero di valori che la variabile può assumere
 x_i = valore assunto dalla variabile nel sogg. i -esimo
 n_i = frequenza corrispondente al valore x_i

esempio sulla media aritmetica ponderata:

- $x_1 \rightarrow 5$
- $x_2 \rightarrow 16$
- $x_3 \rightarrow 13$
- $x_4 \rightarrow 27$
- $x_5 \rightarrow 11$
- $x_6 \rightarrow 5$
- $x_7 \rightarrow 13$
- $x_8 \rightarrow 13$

la variabile può assumere 5 valori
($k = 5$)

x_i	n_i	$x_i n_i$
5	2	10
11	1	11
13	3	39
16	1	16
27	1	27
Totale	8	103

$$\bar{x} = (10+11+39+16+27)/8 = 103/8 = 12.9$$

47



Nel caso di variabili quantitative continue, i dati sono spesso organizzati in classi per una migliore capacità descrittiva

Distribuzione del FEV₁ (cl/s) in 54 soggetti maschi di età 20-44 anni (indagine European Community Respiratory Health Survey - ECRHS)



	n_i
[223 – 270.25)	0
[270.25 – 317.5)	3
[317.5 – 364.75)	9
[364.75 – 412)	10
[412 – 459.25)	14
[459.25 – 506.5)	8
[506.5 – 553.75)	7
[553.75 – 601]	3
TOTALE	54

48



Per il calcolo della media ponderata le osservazioni di una classe si considerano coincidenti con il suo valore centrale

punto centrale della 1^a classe: $(223+270.25)/2 = 246.625$

	x_i	n_i	$x_i n_i$
[223 – 270.25)	246.625	0	0
[270.25 – 317.5)	293.875	3	881.625
[317.5 – 364.75)	341.125	9	3070.125
[364.75 – 412)	388.375	10	3883.750
[412 – 459.25)	435.625	14	6098.750
[459.25 – 506.5)	482.875	8	3863
[506.5 – 553.75)	530.125	7	3710.875
[553.75 – 601]	577.375	3	1732.125
TOTALE		54	23240.25

$$\bar{x} = (x_1 n_1 + x_2 n_2 + \dots + x_n n_n) / n = 23240.25 / 54 = 430.375 \text{ cl/s}$$

MEDIA ARITMETICA PONDERATA - II

Date più medie e le singole frequenze con cui sono state calcolate, la media generale può essere calcolata come media ponderata delle medie

$$\bar{x} = \frac{\bar{x}_1 n_1 + \bar{x}_2 n_2 + \dots + \bar{x}_k n_k}{n_1 + n_2 + \dots + n_k}$$

k = numero di gruppi

\bar{x}_i = media aritmetica nel gruppo i-esimo

n_i = numerosità del gruppo i-esimo

\bar{x} = media aritmetica complessiva

esempio: *valore medio dell'altezza nei maschi e nelle femmine matricole della Facoltà di Medicina (A.A. 95/96)*

Sesso	n_i	\bar{x}_i
maschi	34	177
femmine	91	166.1
Totale	125	

$$\bar{x} = \frac{177 * 34 + 166.1 * 91}{125} = 169.1 \text{ cm}$$

La media aritmetica gode di diverse proprietà, le due principali dal punto di vista applicativo sono legate al concetto di scarto:

PRIMA PROPRIETA' DELLA MEDIA ARITMETICA

la somma algebrica degli scarti delle osservazioni dalla loro media aritmetica è pari a zero



$$\sum_{i=1}^n (x_i - \bar{x}) = (x_1 - \bar{x}) + (x_2 - \bar{x}) + \dots + (x_n - \bar{x}) = 0$$

scarto (distanza) della prima osservazione dalla media

Verifica empirica della prima proprietà:

FEV ₁	x_i	n_i	$(x_i - \bar{x})n_i$
[223 – 270.25)	246.625	0	0
[270.25 – 317.5)	293.875	3	-409.5
[317.5 – 364.75)	341.125	9	-803.25
[364.75 – 412)	388.375	10	-420
[412 – 459.25)	435.625	14	73.5
[459.25 – 506.5)	482.875	8	420
[506.5 – 553.75)	530.125	7	698.25
[553.75 – 601]	577.375	3	441
TOTALE		54	0

$$-409.5 = (293.875 - 430.375) \times 3$$

scarti negativi

$$\bar{x} = 430.375 \text{ cl/s}$$

media ponderata

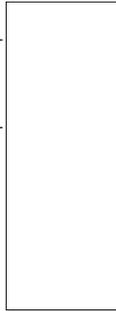
scarti positivi

la somma algebrica degli scarti delle osservazioni dalla loro media aritmetica è pari a zero

ESERCIZIO

I dati seguenti si riferiscono al livello di emoglobina (X) in g/100 ml misurato in un campione di 70 donne:

CLASSE	FREQUENZA ASSOLUTA (n_i)
[9-10)	4
[10-11)	14
[11-12)	19
[12-13)	14
[13-14)	13
[14-15]	6
TOTALE	70



3. Determinate la media della distribuzione.



53

SOLUZIONE-III

CLASSE	FREQUENZA ASSOLUTA (n_i)
[9-10)	4
[10-11)	14
[11-12)	19
[12-13)	14
[13-14)	13
[14-15]	6
TOTALE	70

$$\bar{x} = (x_1n_1 + x_2n_2 + \dots + x_6n_6) / n = 841 / 70 = 12.0 \text{ g/100 mL}$$

54

QUALE MISURA DI POSIZIONE UTILIZZARE?



TIPO DI VARIABILE	OPERAZIONI CONSENTITE	MODA	MEDIANA	MEDIA
nominale	= ≠	Sì	No	No
ordinale	= ≠ < >	Sì	Sì	No
quantitativa	= ≠ < > - + (/ *)	Sì	Sì	Sì

55

CONFRONTO TRA LE MISURE DI POSIZIONE PER UNA VARIABILE QUANTITATIVA

MODA

MEDIANA

MEDIA ARITMETICA

 <p>Buona misura quando un valore ha una frequenza relativa molto elevata</p>	<p>Buona misura con distribuzioni asimmetriche (es. tempo di sopravvivenza) e in presenza di dati estremi</p>	<p>Buona misura con distribuzioni simmetriche (es. molti parametri biologici)</p> <p>Facile da trattare matematicamente</p> <p>Utilizza tutta l'informazione contenuta nei dati</p>
 <p>Dipende dal raggruppamento arbitrario dei dati</p> <p>Varia molto da campione a campione</p>	<p>Difficile da trattare matematicamente</p> <p>Non tiene conto della grandezza delle singole osservazioni</p>	<p>E' inaffidabile in caso di distribuzioni asimmetriche</p>

CONFRONTO TRA LE MISURE DI POSIZIONE PER UNA VARIABILE QUANTITATIVA

esempio:

Supponiamo di avere le Degenze Ospedaliere
di 9 individui (*esprese in giorni*)



CAMPIONE 3 4 4 4 5 6 8 12 95

Moda = 4

Mediana = 5

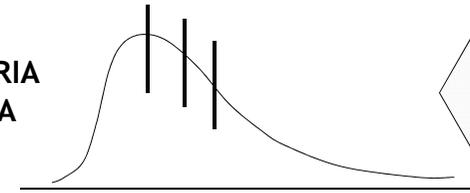
Media \approx 16 (senza *outliers* sarebbe circa 6)

La media aritmetica è poco “robusta” in presenza di
valori anomali (*outliers*)!

57

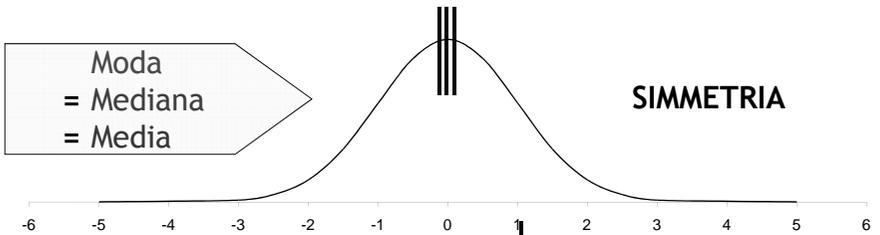
RELAZIONE TRA MODA, MEDIANA E MEDIA ARITMETICA

**ASIMMETRIA
POSITIVA**



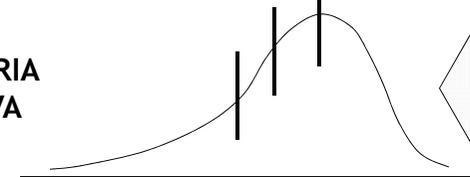
Moda
< Mediana
< Media

Moda
= Mediana
= Media



SIMMETRIA

**ASIMMETRIA
NEGATIVA**



Moda
> Mediana
> Media

58