

§ 4. STATISTICA.

CHE COS'É LA STATISTICA? ELABORAZIONE E STUDIO DEI DATI RACCOLTI E COMPrensIONE DI COME UN FENOMENO SI EVOLVERÁ (PREVISIONI).

CON L'INTRODUZIONE DEL CALCOLO DELLE PROBABILITA', SI É POTUTI PASSARE DALLA SOLA DESCRIZIONE DI DATI ALLA LORO GENERALIZZAZIONE.

LA STATISTICA CHE VEDREMO IN QUESTO CORSO SARÁ DI 2 TIPI:

- 1) DESCRITTIVA : STUDIO DI UN INSIEME DI DATI TRAMITE INDICI
- 2) INFERENZIALE : GENERALIZZAZIONE E APPROSSIMAZIONE PER FARE PREVISIONI.

OBIETTIVI DEL CORSO :

- 1) STUDIARE I PRINCIPALI INDICATORI USATI IN STATISTICA DESCRITTIVA

2) FARE MODELLI (LINEARI), QUANDO LE VARIABILI LO PERMETTONO, CHE LEGHINO 2 CARATTERI (STATISTICA BI-VARIATA)

ESEMPIO "TARGET": CONSIDERIAMO UN CAMPIONE (= INSIEME DI DATI) DI 7 ALBERI DI CUI RIPORTIAMO ETÀ E DIAMETRO;

ETÀ (ANNI)	1	5	4	11	3	7	7
DIAM. (cm)	4	20	17	44	11	28	27

- CALCOLARE MEIA E VARIANZA DELLA VARIABILE ETÀ
- CALCOLARE IL COEFFICIENTE DI CORRELAZIONE DEL DIAMETRO RISPETTO ALL'ETÀ E SCRIVERE LA RETTA DI REGRESSIONE LINEARE.

STATISTICA DESCRITTIVA.

CI PONIAMO L'OBIETTIVO DI EVIDENZIARE LE CARATTERISTICHE DI UN INSIEME DI DATI SENZA GENERALIZZARNE LE PROPRIETÀ.

IL SINGOLO INDIVIDUO ALL'INTERNO DI UNA POPOLAZIONE È CHIAMATO UNITÀ STATISTICA.

ESSERE ORDINATE E HA SENSO PARLARE DI OPERAZIONI ARITMETICHE, PER LE VARIABILI QUALITATIVE CIO' NON E' POSSIBILE. AD ESEMPIO SE $X = \text{"COLORE DEGLI OCCHI"}$ NON SI POSSONO ORDINARE I RISULTATI IN SENSO CRESCENTE.

IL NUMERO DI VALORI DIVERSI CHE PUO' ASSUMERE UNA VARIABILE E' DETTO MODALITA' (AD ESEMPIO IL GRUPPO SANGUIGNO HA 4 MODALITA': O, A, B, AB). LA PRIMA COSA CHE POSSIAMO CALCOLARE SU UNA POPOLAZIONE DI n UNITA' CON VARIABILE X QUALITATIVA E' LA FREQUENZA CON CUI CIASCUNA MODALITA' SI VERIFICA: AVENDO $\{1, \dots, k\}$ MODALITA', CHIAMIAMO:

- FREQ. ASSOLUTA: $N_J = n^o$ DI INDIVIDUI CON MODALITA' J .
- FREQ. RELATIVA: $f_J = \frac{N_J}{n}$, DOVE $n = \# \text{ POPOLAZ.}$
- FREQ. PERCENTUALE: $p_J = (f_J \cdot 100) \%$

NOTA: IL CALCOLO DELLE FREQUENZE E LA DEFINIZIONE DI MODALITA' VISTE SOPRA SI APPLICANO ANCHE A VARIABILI QUANTITATIVE. IN PARTICOLARE SE LE VARIABILI QUANTITATIVE SONO...

ANCHE A VARIABILI QUANTITATIVE. IN PARTICOLARE, SE LE VARIABILI SONO CONTINUE POSSIAMO DIVIDERE IL CAMPO DEI VALORI IN INTERVALLI I_k E CONSIDERARE OGNI INTERVALLO COME UNA MODALITA'.

ESEMPIO:

	MASCHI	FEMMINE
CAMPIONE DI ZANZARE (SS)	12	188

LA VARIABILE $X =$ GENERE HA 2 MODALITA', M ED F. LA MODALITA' M HA:

- FREQ. ASSOLUTA : 12
- FREQ. RELATIVA : $\frac{12}{200} = 0,06$
- FREQ. PERCENTUALE : $(0,06 \cdot 100) \% = 6 \%$

ESERCIZIO ; VIENE ESTRATTO IL DATO SUL COLORE DEGLI OCCHI DA UNA POPOLAZIONE DI $n = 500$ PERSONE ;

	AZZURRO	CASTANO	VERDE	ALTRI
COLORE	89	342	65	4

CALCOLARE LA FREQ. ASSOLUTA, RELATIVA E PERCENTUALE PER CIASCUNA MODALITA'.

DEF: GLI INDICI DESCRITTIVI DANNO INDICAZIONI SULLA DISTRIBUZIONE DEI DATI. ESSI POSSONO ESSERE:

1. INDICI DI CENTRALITA' (DANNO INFO. SULLA POSIZIONE CENTRALE ATTORNO ALLA QUALE SI DISTRIBUISCONO I DATI)
2. INDICI DI VARIABILITA' (QUANTO I DATI SI ALLONTANANO DALLA POSIZ. CENTRALE)
3. INDICI DI FORMA / SIMMETRIA.

TRA GLI INDICI DI CENTRALITA' ABBIANO:

MODA: E' LA MODALITA' PIU' FREQUENTE.

ESSA VIENE CHIAMATA ANCHE "CLASSE MODALE". NON E' ESCLUSO CHE CI SIANO PIU' CLASSI MODALI.

MEDIA ARITMETICA:
$$\bar{x} = \frac{x_1 + \dots + x_n}{n} = \frac{\sum_{i=1}^n x_i}{n}$$

CHIARAMENTE SE UN VALORE SI RIPETE, ESSO VA CONTATO TANTE VOLTE QUANTO LA SUA FREQUENZA

ES: $\{176, 184, 168, 176, 172\}$

$$\bar{x} = \frac{176 + 184 + 168 + 176 + 172}{5} = 174.6$$

$$\bar{x} = \frac{176 + 181 + 168 + 176 + 172}{5} = 174.6$$

MEDIANA: DATI M VALORI x_1, \dots, x_m , LI
ORDINO IN SENSO CRESCENTE

$x(1), x(2), \dots, x(m)$

SI CHIAMA MEDIANA IL VALORE $x_{0.5}$ (o
 $x_{50\%}$) CHE IN QUESTA SUCCESSIONE OCCUPA
LA POSIZIONE CENTRALE, QUINDI SE M É
DISPARI SI TRATTA DI $x\left(\frac{m+1}{2}\right)$, MENTRE
SE M É PARI SI PRENDE LA MEDIA TRA
 $x\left(\frac{m}{2}\right), x\left(\frac{m}{2} + 1\right)$, QUINDI RICAPITOLANDO

$$x_{0.5} = \begin{cases} x\left(\frac{m+1}{2}\right) & \text{SE } m \text{ DISPARI} \\ \frac{1}{2}\left(x\left(\frac{m}{2}\right) + x\left(\frac{m}{2} + 1\right)\right) & \text{SE } m \text{ PARI} \end{cases}$$

ESEMPI: (CALCOLARE MODA, MEDIA E MEDIANA)

1) $\{176, 181, 168, 176, 172\}$

MODA: 176

MEDIA: $\bar{x} = 174.6$

MEDIANA: PRIMA RIORDINIAMOLI...

$\{168, 172, 176, 176, 181\}$

$\rightarrow x_{0.5} = 176$

2) ALTEZZA (cm)	166	168	169	170	171	172	173	174
FREQ. ASSOLUTA	1	3	6	11	8	6	4	3

MODA : ESERCIZIO

MEDIANA : ESERCIZIO

MEDIA :

$$\bar{x} = \frac{166 \cdot 1 + 168 \cdot 3 + 169 \cdot 6 + 170 \cdot 11 + 171 \cdot 8 + 172 \cdot 6 + 173 \cdot 4 + 174 \cdot 3}{1 + 3 + 6 + 11 + 8 + 6 + 4 + 3}$$

$$= \frac{166 + 504 + 1014 + 1870 + 1368 + 1032 + 692 + 522}{42}$$

CHECK!


$$= 170,7$$

3) N° DI FIGLI PER FAMIGLIA	0	1	2	3	4	5	6
F. ASSOLUTA	6	12	16	9	4	1	2

ESERCIZIO : CALCOLARE IL N° MEDIO DI FIGLI PER FAMIGLIA .

IL PRINCIPALE INDICE DI VARIABILITA' É LA

VARIANZA : DATA X QUANTITATIVA, x_1, \dots, x_n
 I VALORI ASSUMTI, \bar{x} = MEDIA, ESSA È
 IL VALORE

$$\sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n} = \frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n}$$

TALVOLTA DENOTATA CON σ_x^2 O CON $\text{Var}(X)$
 ESSA MISURA QUANTO I VALORI SI DISPONDONO
 (= SONO LONTANI) RISPETTO ALLA MEDIA.

DOMANDA: PERCHÉ INVECE DELLE DIFFERENZE
 AL QUADRATO $(x_i - \bar{x})^2$ NON
 ABBIAMO USATO LE DIFFERENZE
 "SEMPLICI" $(x_i - \bar{x})$?

$$\begin{aligned} \frac{\sum_{i=1}^n (x_i - \bar{x})}{n} &= \frac{(x_1 - \bar{x}) + (x_2 - \bar{x}) + \dots + (x_n - \bar{x})}{n} \\ &= \frac{x_1 + x_2 + \dots + x_n - n(\bar{x})}{n} = \frac{\sum x_i}{n} \\ &= \frac{\sum_i x_i - n \cdot \frac{\sum x_i}{n}}{n} = \frac{\sum x_i - \sum x_i}{n} = 0 \end{aligned}$$

GENERALIZZANDO LA FORMULA PER LA VARIANZA

SI DA' LA SEGUENTE :

DEF: SI DEFINISCE MOMENTO CENTRATO DI

ORDINE k IL VALORE

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


SI VEDE SUBITO CHE $\mu_2 = \sigma^2$

DA QUEST'ULTIMA OTTIENIAMO ANCHE UN'INDICE DI
FORNA/SIMMETRIA, L'INDICE DI SKEWNESS:


$$\gamma_1 = \frac{\mu_3}{\mu_2^{3/2}} \quad (\text{SE } \mu_2 = 0 \text{ SI PONE } \gamma_1 = 0)$$

SE $\gamma_1 > 0$ LA DISTRIBUZIONE DEI DATI É
ASIMMETRICA CON CODA VERSO DX, PER

$\gamma_1 < 0$ IL CONTRARIO



CASO $\gamma_1 > 0$



CASO $\gamma_1 < 0$

ESEMPIO: $\{168, 172, 176, 176, 181\}$

AVERANO $\bar{x} = 174.6$

5 ?

AVVERMO $\bar{x} = 174.6$

$$\sigma^2 = \frac{\sum_{i=1}^5 (x_i - \bar{x})^2}{5} =$$

$$= \frac{(168 - 174.6)^2 + (172 - 174.6)^2 + (176 - 174.6)^2 + (176 - 174.6)^2 + (181 - 174.6)^2}{5}$$


$$= \frac{(-6.6)^2 + (-2.6)^2 + (1.4)^2 + (1.4)^2 + (6.4)^2}{5} = \frac{95.2}{5} = 19.04$$

SKEWNESS : $\mu_3 = \frac{\sum_{i=1}^5 (x_i - \bar{x})^3}{5} =$

$$= \frac{(-6.6)^3 + (-2.6)^3 + (1.4)^3 + (1.4)^3 + (6.4)^3}{5} = -7.488$$

$$\Rightarrow \gamma_1 = \frac{\mu_3}{\mu_2^{3/2}} = \frac{-7.488}{(19.04)^{3/2}} = \frac{-7.488}{83.08} = -0.09$$

$\gamma_1 < 0 \Rightarrow$ DISTRIBUZIONE ASIMMETRICA CON CODA VERSO SX .



ESERCIZIO: INVENTARE UN CAMPIONE CON $n \geq 5$,
 $\gamma_1 = 0$ E $\mu_2 \neq 0$.