

Lezione 30

13/12/24

TEST χ^2
 ↗ DI ADATTAMENTO
 ↘ DI INDIPENDENZA

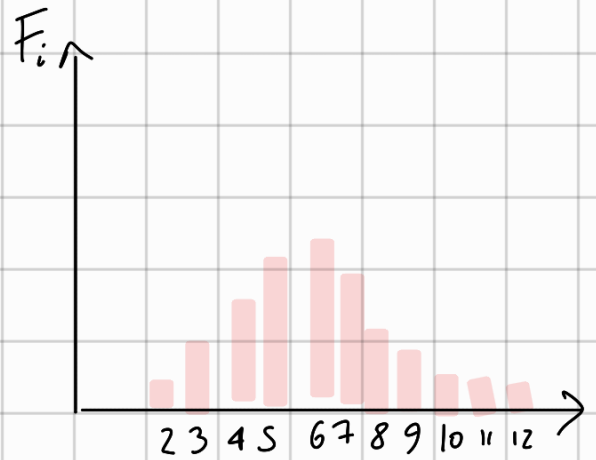

H_0 : LA DISTRIBUZIONE COINCIDE CON QUELLA TEORICA
 H_1 : LA DISTRIBUZIONE NON COINCIDE

Se abbiamo una distribuzione discreta o qualitativa

CONDIZIONE: $F_i \geq 5 \rightarrow$

TESTIAMO SE UNA VARIABILE È VEROSIMILE CHE SIA STATA ESTRATTA SECONDO UNA DISTRIBUZIONE DI PROBABILITÀ NOTA.

ES. LANCIO DI DUE DADI $M=250$ VOLTE



DISTRIBUZIONE DI PROBABILITÀ

DISTRIBUZIONE DI FREQUENZE

SE 10 LANCI 1 DADI

2	3	4	5	6	7	8	9	10	11	12
9	15	22	28	39	43	34	25	17	13	5

$E_i = n e_i$ ← probabilità teorica

F_i

FREQUENZA ASSOLUTA ATTESA

FREQUENZE ASSOLUTE REALI

$F_i \geq 5$

NELL'ESEMPIO

$K = \#$ DI CLASSI

$K = 11$

DEVO RIPETERE L'ESPERIMENTO ABBASTANZA VOLTE DA AVERE CHE OGNI NUMERO È USCITO ALMENO 5 VOLTE.

$$\chi^2_{k-1} = \sum_{i=1}^m \frac{(F_i - E_i)^2}{E_i}$$

$$E_i = \begin{array}{ccccccc} & 2 & 3 & 4 & & & 12 \\ & \frac{250}{36} & \frac{2 \cdot 250}{36} & \cdot & - & - & \frac{1}{36} \cdot 250 \\ & 11 & 11 & 11 & & & 11 \\ & 6.94 & 13.89 & 20.83 & & & 6.94 \end{array}$$

$$\chi^2_{10} = \frac{(9 - 6.94)^2}{6.94} + \frac{(15 - 13.89)^2}{13.89} + \frac{(22 - 20.83)^2}{20.83} + \dots + \frac{(5 - 6.94)^2}{6.94} =$$

$$= 2.93 < 15.987$$

\Rightarrow ACCETTAMO L'IPOTESI NULLA \rightarrow I DADI CHE HO LANCIATO NON SONO TRUCCATI.

(ESERCIZIO 4 DEL 6 SETTEMBRE 2024)

$$e_1 = \frac{5}{10}$$

$$E_1 = \frac{5}{10} \cdot 100 = 50$$

$$10 = 5 + 3 + 2$$

$$e_2 = \frac{3}{10}$$

$$E_2 = \frac{3}{10} \cdot 100 = 30$$

$$e_3 = \frac{2}{10}$$

$$E_3 = \frac{2}{10} \cdot 100 = 20$$

TEST χ^2 DI INDIPENDENZA (E' UN CASO PARTICOLARE)

SUPPONIAMO CHE DI OGNI UNITA' STATISTICA CONOSCIAMO DUE VARIABILI QUALITATIVE.

ESEMPIO Ho UN FARMACO E LO TESTO CON 3 POSSIBILITÀ

$K = 3$ CATEGORIE

- DOSE DOPPIA
- DOSE SINGOLA
- PLACEBO

DI OGNI PERSONA VERIFICO SE È MIGLIORATA OPPURE NO

$L = 2$ CATEGORIE

TABELLA
FREQUENZE

	D_D	D_S	P	
MIGLIORATO	$M_{11}=29$	$M_{12}=5$	$M_{13}=29$	46 = $M_{1\cdot}$
NO	90	80	114	284 = $M_{2\cdot}$
	119	85	126	330 = M
	$M_{\cdot 1}$	$M_{\cdot 2}$	$M_{\cdot 3}$	

FREQUENZE MARGINALI

NUMERO TOTALE M

SE LE DUE VARIABILI FOSSERO SLEGATE AVREMMO LE SEGUENTI FREQUENZE ATTESE: $H_i = 1 \dots k$ $H_j = 1 \dots l$

$$E_{i,j} = \frac{M_{i\cdot} \times M_{\cdot j}}{M}$$

$E_{1,1}$

	D_D	D_S	P	
SI	$\frac{46 \cdot 119}{330} = 16.6$	$\frac{85 \cdot 46}{330} = 11.8$	$\frac{46 \cdot 126}{330} = 17.6$	46 = $M_{1\cdot}$
NO	102.4	73.2	108.4	284 = $M_{2\cdot}$
	119	85	126	330 = M
	$M_{\cdot 1}$	$M_{\cdot 2}$	$M_{\cdot 3}$	

ESEMPIO

$$E_{12} = \frac{M_{1\cdot} \times M_{\cdot 2}}{M} = \frac{46 \cdot 85}{330}$$

$$\chi^2_{(k-1)(l-1)} = \sum_{i,j} \frac{(F_{ij} - E_{ij})^2}{E_{ij}} = \frac{(29 - 16.6)^2}{16.6} + \frac{(5 - 11.8)^2}{11.8} + \dots + \frac{(114 - 108.4)^2}{108.4}$$

RIFIUTO

$$\chi^2_{2.1=2} = 17.4 > 13.816 \Rightarrow \text{L'IPOTESI NULLA CHE LE DUE VARIABILI SIANO INDIPENDENTI}$$

IL FARMACO INFLUISCE SULLA GUARIGIONE AL 99.9 %

DIAMO UN FARMACO CONTIAMO LE GUARIGIONI

FARMACO

TUTTI I NUMERI SONO ≥ 5

F_{ij}	SI	NO	\leftarrow
SI	52	28	80
NO	8	12	20
	60	40	100

ok

$k=2$
 $h=2$

E_{ij}	SI	NO	
SI	48	32	80
NO	12	8	20
	60	40	100

$\nu = (2-1)(2-1) = 1$

$$\chi^2_1 = \frac{(52-48)^2}{48} + \frac{(28-32)^2}{32} + \frac{(8-12)^2}{12} + \frac{(12-8)^2}{8} = 4.17$$

IL FARMACO FUNZIONA CON CONFIDENZA 95 %

STATISTICA BIVARIATA

Di ogni unità statistica misuriamo due variabili numeriche continue:

HO N COPPIE DI DATI

$$\underline{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)}$$

Solitamente UNA DELLE DUE è FACILE DA MISURARE e l'altra no
Se riusciamo a trovare un legame tra le due allora potremo usarlo

ESEMPIO [ALBERI]

$x_i =$ diametro

$y_i =$ età

MEDIA

$$\bar{x}$$

VARIANZA

$$\sigma_x^2$$

$$\bar{y}$$

$$\sigma_y^2$$

Si definisce COVARIANZA tra X e Y la quantità

$$\sigma_{xy} = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})$$

OSSERVA CHE

$$\sigma_{xy} > 0$$

X CRESCE
e VICEVERSA

Y CRESCE

→ VARIABILI CONCORDI

$$\sigma_{xy} < 0$$

X CRESCE
e VICEVERSA

Y DECRESCHE → VARIABILI DISCORDI

PROPOSIZIONE

$$\sigma_{xy} = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y}) = \overline{xy} - \bar{x} \cdot \bar{y}$$

$$\overline{xy} = \frac{1}{N} \sum_{i=1}^N x_i y_i$$

DIM.


$$\begin{aligned}\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y}) &= \frac{1}{N} \sum_{i=1}^N (x_i y_i - \bar{x} y_i - x_i \bar{y} + \bar{x} \bar{y}) = \\ &= \frac{1}{N} \sum_{i=1}^N x_i y_i - \frac{1}{N} \sum_{i=1}^N \bar{x} y_i - \frac{1}{N} \sum_{i=1}^N x_i \bar{y} + \frac{1}{N} \sum_{i=1}^N \bar{x} \bar{y} \\ &= (\bar{x} \bar{y}) - \bar{x} \left[\frac{1}{N} \sum_{i=1}^N y_i \right] - \bar{y} \left[\frac{1}{N} \sum_{i=1}^N x_i \right] + \frac{1}{N} \cancel{N} \bar{x} \bar{y} \\ &= (\bar{x} \bar{y}) - \bar{x} \bar{y} - \bar{x} \bar{y} + \bar{x} \bar{y} \quad \square\end{aligned}$$

DEFINIZIONE : COEFFICIENTE DI CORRELAZIONE LINEARE

$$\rho_{xy} = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \quad \text{e' UN NUMERO ADIMENSIONALE}$$

$$\boxed{-1 \leq \rho_{xy} \leq 1}$$

SCATTERSHOT



LA RETTA CHE APPROSSIMA MEGLIO QUESTI PUNTI SI CHIAMA
RETTA DI REGRESSIONE LINEARE.