

Lezione 5**La verifica delle ipotesi sulla forma della distribuzione****Argomenti della lezione:**

- ➔ **Caso di un campione**
- ➔ **Caso di due campioni**

Caso di un campione

- ➔ **Non si stima un parametro**
- ➔ **Esame della forma della distribuzione nella popolazione dai dati del campione**

Problema

- ➔ **Gradimento programmi televisivi**
- ➔ **Campione: 42 telespettatori**
- ➔ **Scelta programma preferito**

**Variabile "tipo di programma".
Su scala nominale**

Distribuzione di frequenza

programma	frequenza
A – culturale	5
B – sportivo	15
C – cartoni	22
totale	42

Ipotesi nulla (H_0)

Nella popolazione da cui è estratto il campione, le frequenze nelle k categorie sono uguali (preferenze equidistribuite)

Ipotesi alternativa (H_1)

Nella popolazione da cui è estratto il campione, le frequenze sono diverse

Test del chi quadrato:

Adattamento fra distribuzione teorica (secondo H_0) ed empirica, rilevata sul campione

Confronto fra:

frequenze teoriche (o attese) e osservate (o empiriche)

$$\chi^2 = \sum_1^k \frac{(f_0 - f_t)^2}{f_t}$$

$$\text{gdl} = (k - 1)$$

Ipotesi statistiche dell'esempio

$$H_0: f_A = f_B = f_C$$

(equidistribuzione nella popolazione)

$$H_1: (f_A \neq f_B) \text{ o } (f_A \neq f_C) \text{ o } (f_B \neq f_C)$$

(frequenze diverse nella popolazione)

Calcolo delle frequenze teoriche

Se è vera l'ipotesi nulla:

$$f_t = n/k$$

quindi

$$42/3 = 14$$

Scelta di α e individuazione di χ^2 critico con 2gdl

$$\alpha = 0.05$$

$$\chi^2 \text{ critico} = 5.99$$

Calcolo del chi quadrato:

$$\begin{aligned}\text{Chi}^2 &= \sum_1^3 \frac{(f_0 - f_t)^2}{f_t} = \\ &= \frac{(5 - 14)^2}{14} + \frac{(15 - 14)^2}{14} + \frac{(22 - 14)^2}{14} = \\ &= 81/14 + 1/14 + 64/14 = \\ &= 146/14 = 10.43\end{aligned}$$

Decisione

- $\text{Chi}^2 > \text{chi}^2 \text{ critico}$
- Si respinge H_0

C'è differenza nella preferenza dei programmi televisivi

Celle che danno il maggior contributo alla significatività**Residuo Standardizzato**

$$R = \frac{f_0 - f_t}{\sqrt{f_t}}$$

Deve essere maggiore di |2|

Programma	F_0	F_t	$? F_t$	R
A - culturale	5	14	3.74	-2.491
B - sportivo	15	14	3.74	.27
C - cartoni	22	14	3.74	2.14

Programma più scelto: Cartoni
Programma meno scelto: Culturale

Limiti di applicabilità

- ⇒ indipendenza
- ⇒ $k = 2, f_t \geq 5$
- ⇒ $k > 2, f_t \geq 1,$
 $f_t < 5$ in non più del 20%

Caso di due campioni**Incrocio fra 2 variabili categoriali**

Variabile 1:
Genere: M, F

Variabile 2:
Tipo di facoltà: I, P, L

Esiste una relazione tra le due variabili ?

Campione: 84 soggetti
tabella a doppia entrata

	I	P	L	
M	20	5	3	34($n_{1.}$)
F	3	20	22	50($n_{2.}$)
	23 ($n_{.1}$)	25 ($n_{.2}$)	30 ($n_{.3}$)	84 (N)

→ **Ipotesi nulla**
Equivalenza tra le proporzioni
nelle popolazioni
(assenza di relazione)

→ **Ipotesi alternativa**
Proporzioni diverse nelle
popolazioni
(relazione significativa)

Le f_t si calcolano per ogni casella
tenendo conto dei totali marginali

	B=1	B=2	B=3	
A = 1				($n_{1.}$)
A = 2				($n_{2.}$)
	($n_{.1}$)	($n_{.2}$)	($n_{.3}$)	(N)

frequenza teorica, in ogni cella,
che si avrebbe se H_0 fosse vera

A e B indipendenti ⇒

$$P[(A = 1) \text{ e } (B = 1)] = P(A = 1) * P(B = 1)$$

$$P(A = 1) = n_{1.}/N, P(B = 1) = n_{.1}/N$$

$$P[(A = 1) \text{ e } (B = 1)] = n_{1.}/N * n_{.1}/N$$

Probabilità = Frequenza relativa

Frequenza Assoluta =
Probabilità * N

$$f_{11}[(A = 1) \text{ e } (B = 1)] = N * P[(A = 1) \text{ e } (B = 1)] = N * (n_{1.}/N * n_{.1}/N) = n_{1.} * n_{.1}/N$$

Per ogni cella:

$$f_{11} = n_{1.} * n_{.1}/N$$

$$f_{12} = n_{1.} * n_{.2}/N$$

$$f_{13} = n_{1.} * n_{.3}/N$$

$$f_{21} = n_{2.} * n_{.1}/N$$

$$f_{22} = n_{2.} * n_{.2}/N$$

$$f_{23} = n_{2.} * n_{.3}/N$$

Per ogni casella la frequenza teorica f_t si calcola moltiplicando i corrispondenti totali marginali di riga e di colonna e dividendo il prodotto per il totale generale

$$f_t = \frac{m_r \cdot n_c}{N}$$

Calcolo della frequenza teorica f_{11}

	B=1	B=2	B=3	
A = 1	11.33			34
A = 2				
	28			84

$$f_{11} = (34 * 28) / 84$$

Calcolo della frequenza teorica f_{12}

	B=1	B=2	B=3	
A = 1		10.52		34
A = 2				
		26		84

$$f_{12} = (34 * 26) / 84$$

Calcolo della frequenza teorica f_{13}

	B=1	B=2	B=3	
A = 1			12.14	34
A = 2				
			30	84

$$f_{13} = (34 * 30) / 84$$

Calcolo della frequenza teorica f_{21}

	B=1	B=2	B=3	
A = 1				
A = 2	16.67			50
	28			84

$$f_{21} = (50 * 28) / 84$$

Calcolo della frequenza teorica f_{22}

	B=1	B=2	B=3	
A = 1				
A = 2		15.48		50
		26		84

$$f_{22} = (50 * 26) / 84$$

Calcolo della frequenza teorica f_{23}

	B=1	B=2	B=3	
A = 1				
A = 2			17.86	50
			30	84

$f_{23} = (50 * 30) / 84$

Frequenze teoriche: Tabella finale

	I	P	L	
M	11.33	10.52	12.14	34 ($n_{1.}$)
F	16.67	15.48	17.86	50 ($n_{2.}$)
	28 ($n_{.1}$)	26 ($n_{.2}$)	30 ($n_{.3}$)	84 (N)

$\alpha = 0.05$
 $gdl = (r-1) \times (c-1)$
 $gdl = (2-1) \times (3-1) = 2$

chi² critico = 5.99

Calcolo del chi²

$$Chi^2 = \sum_1^k \frac{(f_o - f_t)^2}{f_t}$$

f_o	f_t	$(f_o - f_t)$	$(f_o - f_t)^2$	$(f_o - f_t)^2 / f_t$
20	11.33	8.67	75.17	6.63
6	10.52	-4.52	20.43	1.94
8	12.14	-4.14	17.14	1.41
8	16.67	-8.67	75.17	4.51
20	15.58	4.52	20.43	1.32
22	17.86	4.14	17.14	.96

chi² = 16.77

Decisione

- Chi² > chi² critico
- Rifiuto l'ipotesi nulla

C'è una relazione significativa tra le due variabili

Residui standardizzati

Cella	f_o	f_t	R
M - I	20	11.33	2.57
M - P	6	10.52	-1.40
M - L	8	12.14	-1.19
F - I	8	16.67	-2.13
F - P	20	15.58	1.15
F - L	22	17.86	.98

Formula abbreviata per tabelle 2 x 2

A	B	A+B
C	D	C+D
A+C	B+D	N

$$\chi^2 = \frac{N(AD-BC)^2}{(A+B)(C+D)(A+C)(E+D)}$$

Esempio

- ⇒ Campione: 216 studenti
 - 90 di Psicologia
 - 126 di Ingegneria
- ⇒ Variabile: favorevoli o contrari al numero chiuso

	FAV	CONT	
PSI	55	35	90
ING	55	71	126
	110	106	216

$$\chi^2 = \frac{216(55 \times 71 - 35 \times 55)^2}{90 \times 126 \times 110 \times 106} =$$

$$\chi^2 = \frac{216(3905 - 1925)^2}{90 \times 126 \times 110 \times 106} = 6.40$$

$$\alpha = .05$$

$$gdl = 1$$

$$\chi^2 \text{ critico} = 3.84$$

χ^2 calcolato > χ^2 critico

C'è relazione significativa tra le due variabili categoriali

CONCLUSIONE

- Ipotesi sulla forma della distribuzione
- Bontà dell'adattamento
- Test su uno e su due campioni