

## CONFRONTO TRA DISTRIBUZIONE OSSERVATA E TEORICA O ATTESA

Nella teoria statistica e nella pratica sperimentale, è frequente la necessità di verificare se esiste accordo tra una distribuzione osservata e la corrispondente distribuzione attesa o teorica.

Questa verifica viene eseguita mediante l'impiego di un test che viene definito *test per la bontà dell'adattamento* (in inglese, goodness of fit test).

Il test  $\chi_n^2$  (chi-quadro o chi-quadrato) di Pizzetti-Pearson storicamente è stato costruito proprio a questo scopo.

E' un metodo di inferenza statistica che non richiede ipotesi "a priori" sul tipo e sulle caratteristiche della distribuzione, come invece avviene per la statistica parametrica che fa riferimento alla distribuzione normale. Sono metodi *non parametrici*.

### **Il numero di g.d.l corrisponde al numero di osservazioni indipendenti.**

Infatti *le frequenze attese di ogni gruppo, che sono calcolate dal totale dei casi ed attribuite ad ogni gruppo secondo la legge di distribuzione, sono libere di assumere qualsiasi valore; ma fa eccezione la frequenza attesa dell'ultimo gruppo, la quale è totalmente determinata dalla differenza tra la somma delle frequenze relative a tutti i gruppi precedenti, già definiti, ed il totale.*

*Quando tra n variabili casuali sussistono k vincoli lineari, ossia relazioni che riducono il numero di osservazioni indipendenti, i gradi di libertà del corrispondente  $\chi_{(g.d.l.)}^2$  diminuiscono di un numero pari a k e sono, quindi, pari a (n-k). Si può anche dire che il numero dei gradi di libertà è determinato dai vincoli, di qualsiasi natura, che esistono fra le frequenze dei vari gruppi.*

### **Il test del $\chi_n^2$**

Il test del  $\chi_n^2$  serve per il *confronto tra 2 o più distribuzioni*;

L'interesse consiste nel *trarre conclusioni generali dal singolo esperimento*; in altri termini, nel *conoscere la probabilità con cui le differenze tra una distribuzione osservata e quella attesa possono riprodursi per caso, in una serie di esperimenti analoghi.*

Il test  $\chi_n^2$ , utilizza non le frequenze relative o percentuali, ma le *frequenze assolute*, con la formula

$$\chi_{n-1}^2 = \sum_{i=1}^n \frac{(f_i^{oss} - f_i^{att})^2}{f_i^{att}}$$

dove:

$f_i^{oss}$  = frequenza osservata i-esima

$f_i^{att}$  = frequenza attesa i-esima

Tuttavia, nell'applicazione del test  $\chi^2$  per misurare la bontà dell'adattamento dobbiamo tenere presente che, in generale, i parametri che caratterizzano la distribuzione teorica non sono noti, ma sono sostituiti dalle loro stime ricavate dai dati osservati.

Ciò vuol dire che *il numero dei gradi di libertà deve essere ridotto di una unità ogni volta che un parametro viene sostituito dalla sua stima.*

Per esempio, per una curva normale, il numero dei gradi di libertà per il test  $\chi^2$  è inferiore di 3 unità rispetto al numero delle frequenze, perché l'equazione della curva normale dipende dai parametri N, M e  $\sigma$ . Se si fosse adattata una distribuzione di Poisson, i gradi di libertà sarebbero stati solo di 2 unità inferiori al numero delle frequenze, perché la curva di Poisson dipende solo dai due parametri: N ed M.

Quando, in alcuni problemi, uno o più di questi parametri sono noti in base ad altre considerazioni, nel procedere all'adattamento della curva è necessario usare i loro valori veri invece delle loro stime campionarie. In tali casi, i gradi di libertà saranno uguali al numero delle frequenze diminuito di una unità, perché il valore di  $N$  è sempre preso dai dati osservati.

Per la comprensione del test del  $\chi^2$ , è utile ricordare che *quanto più le differenze tra valori osservati ed attesi sono grandi, tanto più il valore del  $\chi^2$  sarà elevato*; di conseguenza, *la probabilità che tali differenze siano dovute solo al caso sarà bassa e si rifiuterà l'ipotesi nulla*, accettando implicitamente l'ipotesi alternativa  $H_1$ . Al contrario, *quando le differenze tra valori osservati ed attesi sono ridotte, ugualmente basso sarà il valore del  $\chi^2$ ; pertanto, sarà elevata la probabilità che esse siano imputabili esclusivamente al caso e si accetterà l'ipotesi nulla  $H_0$ .*

Frequenze osservate <u>f</u>	Frequenze teoriche <u>f'</u>
4	2,106
20	18,642
28	23,868
12	20,202
8	10,842
6	2,340

### Esempio X.24

Si applichi ora il test  $\chi^2$  per determinare se la curva normale si è adattata bene alla distribuzione ottenuta dall'osservazione:

$$\chi^2 = \left( \frac{4^2}{2,106} + \frac{20^2}{18,642} + \frac{28^2}{23,868} + \frac{12^2}{20,202} + \frac{8^2}{10,84} + \frac{6^2}{2,340} \right) - 78 =$$

$$\chi^2 = \left( \frac{4^2}{2,106} + \frac{20^2}{18,642} + \frac{28^2}{23,868} + \frac{12^2}{20,202} + \frac{8^2}{10,84} + \frac{6^2}{2,340} \right) - 78 =$$

$$= (7,59 + 21,45 + 32,85 + 7,12 + 5,90 + 15,38) - 78 = 90,31 - 78 = 12,31$$

Nell'adattare la curva normale  $N$ ,  $M$  e  $\sigma$  sono stati presi dai dati osservati. Quindi, i gradi di libertà saranno  $v = 6 - 3 = 3$ , cioè uguali al numero delle frequenze diminuito di 3.

Sulla tavola del  $\chi^2$  con  $v = 3$  gradi di libertà si vede che il livello di significatività del 5% corrisponde ad un  $\chi^2 = 7,815$ , il livello di significatività dell'1% corrisponde ad un  $\chi^2 = 11,341$ . Poiché  $\chi^2 = 12,31$  corrisponderà ad una probabilità inferiore all'1%,

Possiamo concludere che la discrepanza tra frequenze osservate e frequenze teoriche è *troppo grande*; quindi, la scelta della curva normale non è stata molto appropriata per rappresentare la distribuzione data.

**Secondo uno schema valido per tutti i test statistici, il procedimento logico che deve essere seguito nell'applicazione del  $\chi^2$  comprende diverse fasi, che possono essere riassunte in 7 passaggi:**

- 1 - stabilire l'ipotesi nulla ( $H_0$ ) e l'eventuale ipotesi alternativa ( $H_1$ );
- 2 - scegliere il test più appropriato per saggiare l'ipotesi nulla  $H_0$ , secondo le finalità della ricerca e le caratteristiche statistiche dei dati (in questo caso, ovviamente, è il test chi quadrato);
- 3 - specificare il livello di significatività, l'ampiezza del campione e i gradi di libertà;
- 4 - trovare la distribuzione di campionamento del test statistico nell'ipotesi nulla  $H_0$ , di norma fornita da tabelle;

5 - stabilire la zona di rifiuto (di norma prefissata al 5%, all'1% o all'1‰);

6 - calcolare il valore del test statistico sulla base dei dati sperimentali, stimando il valore di probabilità ad esso associato;

7 - sulla base della probabilità, trarre le conclusioni: se la probabilità risulta superiore a quella prefissata, concludere che non è possibile rifiutare l'ipotesi nulla  $H_0$ ; se la probabilità risulta inferiore a quella prefissata, rifiutare l'ipotesi nulla e quindi implicitamente accettare l'ipotesi alternativa  $H_1$ .