

Corso integrato di informatica, statistica e analisi dei dati sperimentali
Esercitazione VI

Test del χ^2 (il file Excel **test_chi.xls** mostra possibili sviluppi degli esercizi proposti)

Esercizio 1a)

un costruttore di lampadine afferma che la probabilità che una delle sue lampadina si fulmini prima di 100 ore di funzionamento è il 12% ($p = 0.12$). Per verificare questa affermazione prendiamo un gruppo di $N=90$ lampadine e le lasciamo accese per 100 ore. Scaduto il tempo verifichiamo che $O_f = 18$ lampadine sono fulminate e $O_a = 72$ sono ancora accese. Verificare l'ipotesi che il costruttore dica il vero.

Prepare un foglio elettronico per il calcolo del test χ^2 .

1	exp.:	fulminate	accese	totale	2
3	th.	18	72	90	p 0.12
	ΔN	10.8	79.2	90	
	$\Delta N^2/N^2 \text{ th}$	7.20	-7.20		$\chi^2 \text{ oss.}$
		4.80	0.65	5.45	v
				1	$P(\chi^2 \text{ oss.})$ 0.019517
	$\frac{(O_i - A_i)^2}{A_i}$				$\chi^2 \text{ Lim.}$
				3.84	α
				0.05	

Inserire i dati (1), inserire la probabilità (2) e calcolare le frequenze teoriche (3).

Calcolare i termini $\frac{(O_i - A_i)^2}{A_i}$ e quindi il χ^2 (4). Definire i gradi di libertà (5) e calcolare la

probabilità associata al valore osservato di χ^2 per una distribuzione con v gradi di libertà usando la funzione Excel DISTIB.CHI(χ^2, v) (6). In base alla probabilità ottenuta si può affermare che?

Confrontare il valore limite sulle tabelle o calcolare il valore limite per $\alpha = 0.05$ utilizzando la funzione Excel INV.CHI(α, v) (7). Trarre le conclusioni del caso.

Cambiando il valore della probabilità determinare i limiti di confidenza entro i quali la probabilità associata al χ^2 osservato è $>$ di 0.05%. In mancanza di un programma di adeguato si cambiano a mano i valori di p e si osserva che per valori di p compresi tra [0.135 ; 0.29] non posso rigettare l'ipotesi con un livello di confidenza migliore del 95%. In base ai dati il valore di p è compreso tra 0.135 e 0.29

exp.: fulminate	18	accese	72	totale	90	p	0.29
th.	26.1		63.9		90		
ΔN	-8.10		8.10			$\chi^2 \text{ oss.}$	v
$\Delta N^2/N^2 \text{ th}$	2.51		1.03			3.54	1
							$P(\chi^2 \text{ oss.})$ 0.059885
						$\chi^2 \text{ Lim.}$	α
						3.84	0.05

exp.: fulminate	18	accese	72	totale	90	p	0.135
th.	12.15		77.85		90		
ΔN	5.85		-5.85			$\chi^2 \text{ oss.}$	v
$\Delta N^2/N^2 \text{ th}$	2.82		0.44			3.26	1
							$P(\chi^2 \text{ oss.})$ 0.071151
						$\chi^2 \text{ Lim.}$	α
						3.84	0.05

Esercizio 1b) Lanciando un dado 38 volte osservo 10 volte testa. Posso affermare con un limite di confidenza del 5% che il dado è truccato?

Dado				p
exp.:	6	<6	totale	0.17
th.	10	28	38	
ΔN	6.33	31.67	38	
$\Delta N^2/N^2\text{th}$	3.67	-3.67	$\chi^2 \text{ oss.}$	$P(\chi^2 \text{ oss.})$
	2.12	0.42		
			$\chi^2 \text{ Lim.}$	α
			3.84	0.05

Esercizio 2)

Per verificare la sensibilità di una specie di piante ad un virus di espongono al contagio M gruppi ($M=90$) di $n = 20$ individui ciascuno. Dopo un tempo certo tempo si contano il numero di contagi k per ogni gruppo e si riportano in tabella le frequenze N_k con cui sono osservati k contagi per gruppo. Si vuole verificare l'ipotesi che la probabilità di contagio sia $p = 0.3$ e che quindi il numero di contagi per gruppo (k) seguia una distribuzione binomiale $f(n, p)$.

I dati mostrati in tabella sono riportati nel file **Contagio.dat**

Importare i dati in Excel e costruire la tabella mostrata in figura.

La distribuzione binomiale calcola la probabilità di ottenere k di successi (nel nostro caso contagi) su n prove indipendenti (nel nostro caso $n=20$):

$$f(k, n) = \binom{n}{k} p^k (1-p)^{n-k} = \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k}$$

In base al modello Binomiale le frequenze teoriche sono: $N_k^{th} = M f(k, n)$ dove

M è il numero delle osservazioni ($M=90$) e sono riportate in tabella.

Classi k	frequenze N_k
2	5
3	2
4	11
5	14
6	18
7	12
8	14
9	6
10	4
11	3
12	1
out	0
totali	11 90

Parametri esperimento		calcolo del termine fattoriale: $n! / k!(n-k)!$	calcolo della distribuzione binomiale	calcolo $N_{k(th)} * f$	calcolo $(N - N_{k(th)})^2 / N_{k(th)}$
Classi k	frequenze N_k				
2	5	190	0.027845873	2.506	2.482
3	2	1140	0.071603672	6.444	3.065
4	11	4845	0.130420974	11.738	
5	14	15504	0.178863051	16.098	
6	18	38760	0.191638983	17.248	
7	12	77520	0.164261985	14.784	
8	14	125970	0.11439674	10.296	1.333
9	6	167960	0.065369566	5.883	0.002
10	4	184756	0.030817081	2.774	0.542
11	3	167960	0.012006655	1.081	3.409
12	1	125970	0.003859282	0.347	1.226
N. di classi osservate	out	0	out	0.802	0.802
totali	11 90	normalizz.	0.991083861	89.198	regione lontana

Riportare in una cella opportuna il numero di prove per esperimento ($n=20$) e la probabilità p che si vuole sottoporre a test. Inserire lunghe formule in Excel può essere complicato: i calcoli si possono dividere ad esempio calcolando prima il termine fattoriale: $n!/k!(n-k)!$ (FATTORIALE(N) è la funzione Excel per il calcolo di $N!$) e quindi la distribuzione $f(k, 20)$.

Si possono calcolare le frequenze attese $M*f$ e i $\frac{(O_i - A_i)^2}{A_i}$ termini

$$\text{e quindi il } \chi^2_o = \sum_{i=1}^N \frac{(O_i - A_i)^2}{A_i}$$

χ^2	
12.94	Senza regione esterna
13.74	Inclusa la regione esterna

facendo attenzione a includere il termine che tiene conto della regione “lontana” dove non abbiamo avuto osservazioni.

Per sottoporre a test l’ipotesi che i dati seguono l’andamento teorico calcolato in base all’ipotesi di una distribuzione binomiale si può:

a) verificare utilizzando le tabelle che il valore osservato del χ^2 è minore del valore limite ($\alpha=0.05$) per un χ^2 con 10 (o 11 se si considera la regione esterna) gradi di libertà.

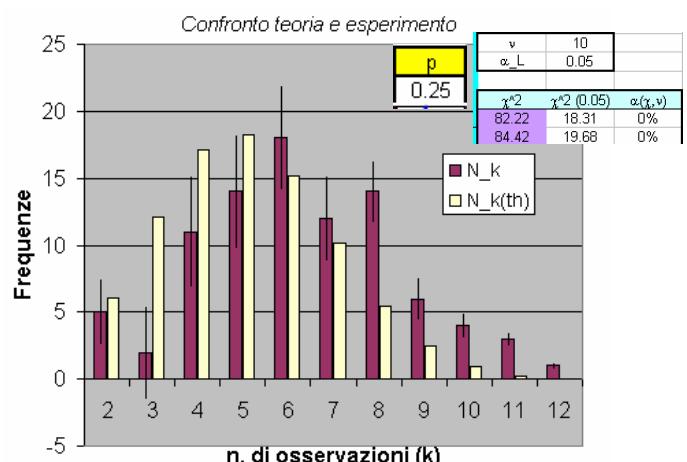
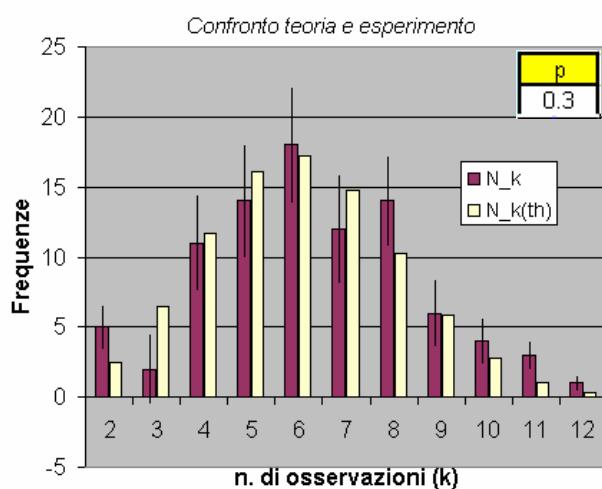
v	10	
α_L	0.05	
χ^2	$\chi^2(0.05)$	$\alpha(\chi, v)$
12.94	18.31	23%
13.74	19.68	25%

b) calcolare i valori limite del χ^2 con 10 (o 11) gradi di libertà e $\alpha=0.05$ usando la funzione Excel= INV.CHI(α, v)

c) calcolare la probabilità associata ad un χ^2 con 10 (o 11) gradi di libertà eguale al valore osservato

Il test dice che....

Un istogramma che mette a confronto i dati sperimentali con le frequenze teoriche fa vedere che c’è un buon accordo tra teoria ed esperimento. Se di cambia il valore della probabilità utilizzato per il test si vede che per $p < 0.28$ o $p > 0.36$ l’accordo peggiora e il test del χ^2 permette di rigettare le ipotesi (le differenze tra dato e teoria sono significative)



Esercizio 3a) Distribuzione di Poisson

Per studiare la distribuzione di piante in una regione si eseguono $M=33$ campionamenti in zone diverse di eguale superficie S . L'istogramma in tabella mostra le frequenze con cui sono state osservate k piante per campionamento. (frequenze di osservazione). I dati sono riportati nel file **Piante.dat**.

In base ai dati sperimentali si può assumere che la distribuzione delle piante sia uniforme con densità $d = \langle k \rangle / S$ ($\langle k \rangle$ numero medio di piante in un'area S) con una confidenza del 95%? Ovvero: le osservazioni seguono una distribuzione di Poisson con valore atteso $\langle k \rangle$ e la probabilità associata al χ^2 è maggiore di 0.05%?

In base ai dati calcoliamo prima il numero medio di piante per area di campionamento:

$$\bar{k} = \frac{\sum_i N_k}{\sum_i N_k} = 28.0$$

e la varianza:

$$\sigma_k^2 = \frac{\sum_i N_k (k - \bar{k})^2}{\sum_i N_k} = 33.8$$

(attenzione al calcolo delle medie pesate!)

La funzione densità di probabilità nel modello di Poisson è:

$$f(k, \lambda) = \frac{\lambda^k e^{-\lambda}}{k!}$$

classi	N_k	somma	scarti^2
20	4	80	1600
21	2	42	882
22	1	22	484
23	2	46	1058
24	0	0	0
25	4	100	2500
26	1	26	676
27	3	81	2187
28	2	56	1568
29	2	58	1682
30	2	60	1800
31	1	31	961
32	0	0	0
33	1	33	1089
34	3	102	3468
35	1	35	1225
36	1	36	1296
37	1	37	1369
38	0	0	0
39	0	0	0
40	2	80	3200
N_oss		21	
totale		33	
media		28.0303	
varianza		819.55	

Le frequenze teoriche sono quindi:

$$N_k^{th} = M f(k, \bar{k})$$

Attenzione a considerare il contributo della regione "lontana" (out): in base al modello teorico avrei dovuto osservare 1.98 eventi per $k < 20$ o $k > 40$, regioni in cui non ho avuto osservazioni.

Si calcolano i temini:

$$\frac{(O_i - A_i)^2}{A_i}$$

E quindi:

$$\chi_o^2 = \sum_{i=1}^N \frac{(O_i - A_i)^2}{A_i}$$

chi^2	38.486
nlib=	20
prob. chi	0.0077194

	f_th	Nth	z
	2.47E-02	0.82	12.430
	3.30E-02	1.09	0.763
	4.20E-02	1.39	0.108
	5.12E-02	1.69	0.057
	5.98E-02	1.97	1.975
	6.71E-02	2.21	1.441
	7.23E-02	2.39	0.806
	7.51E-02	2.48	0.110
	7.52E-02	2.48	0.093
	7.27E-02	2.40	0.066
	6.79E-02	2.24	0.026
	6.14E-02	2.03	0.519
	5.38E-02	1.77	1.774
	4.57E-02	1.51	0.171
	3.77E-02	1.24	2.486
	3.02E-02	1.00	0.000
	2.35E-02	0.77	0.065
	1.78E-02	0.59	0.291
	1.31E-02	0.43	0.433
	9.43E-03	0.31	0.311
	6.61E-03	0.22	14.562
tot. in	9.40E-01	31.02	
resto (out)	5.99E-02	1.98	1.98
controllo	1.0	33.0	

Attenzione al calcolo dei gradi di libertà: ho usato un grado di libertà per il calcolo di M e un grado di libertà per stimare la media, quindi i gradi di libertà sono:

$$M + 1(\text{regione esterna}) - 2 = 20$$

La probabilità associata al valore del χ^2 osservato con 20 gradi di libertà è: 0.77 %, ben inferiore a 0.05% quindi possiamo rigettare l'ipotesi che le piante siano distribuite in modo uniforme.

Esercizio 3b) Distribuzione uniforme:

Utilizzando i dati dell'esercizio precedente dire se i dati sono compatibili con una distribuzione uniforme del numero di piante osservate nell'area di misura.

Il numero minimo di piante osservato è 20, il numero massimo è 40. In tutto abbiamo 21 classi di osservazione. Per una distribuzione uniforme la probabilità di osservare k piante è costante: $f_u = 1/21 = 0.0476$. Il numero di piante per intervallo è $N^{\text{th}} = Mf_i = 1.57$. Quindi calcolo la tabella mostrata, il χ^2 associato e la probabilità associata al χ^2 osservato con $v = 21 - 3$ (ho utilizzato i dati per calcolare M e i limiti k_{\min} e k_{\max} , quindi ho utilizzato tre gradi di libertà).

Ottengo la tabella mostrata da cui risulta un $\chi^2 = 18.5$.

La probabilità ad esso associata per $n=18$ gradi di libertà è alta (> 0.05) quindi non posso rifiutare l'ipotesi che il numero di piantine nelle superfici di campionamento seguano una distribuzione uniforme tra $k_{\min} = 20$ e $k_{\max} = 40$.

		Uniforme
f_{th}	N^{th}	z
4.76E-02	1.57E+00	3.75E+00
4.76E-02	1.57E+00	1.17E-01
4.76E-02	1.57E+00	2.08E-01
4.76E-02	1.57E+00	1.17E-01
4.76E-02	1.57E+00	1.57E+00
4.76E-02	1.57E+00	3.75E+00
4.76E-02	1.57E+00	2.08E-01
4.76E-02	1.57E+00	1.30E+00
4.76E-02	1.57E+00	1.17E-01
4.76E-02	1.57E+00	1.17E-01
4.76E-02	1.57E+00	1.17E-01
4.76E-02	1.57E+00	2.08E-01
4.76E-02	1.57E+00	1.57E+00
4.76E-02	1.57E+00	2.08E-01
4.76E-02	1.57E+00	2.08E-01
4.76E-02	1.57E+00	2.08E-01
4.76E-02	1.57E+00	1.30E+00
4.76E-02	1.57E+00	1.17E-01
4.76E-02	1.57E+00	2.08E-01
4.76E-02	1.57E+00	1.30E+00
4.76E-02	1.57E+00	2.08E-01
4.76E-02	1.57E+00	2.08E-01
4.76E-02	1.57E+00	1.57E+00
4.76E-02	1.57E+00	1.17E-01
tot. in	1.00E+00	33.00
resto (out)	0.00E+00	0.00
controllo	1.0	33.0
	chi^2	18.545
	nlib=	18
	prob. chi	0.420301

