

Esercitazioni di Statistica Matematica A
Esercitori: Dott. Fabio Zucca - Dott. Maurizio U. Dini
Lezione del 21/1/2003

1. Test χ^2 di adattamento

Esercizio # 1.1

L'azienda di materiale elettronico *Cortocircuito* produce circuiti stampati. Viene avanzata l'ipotesi che la v.a. X che descrive il numero di difetti presentati dai circuiti segua una distribuzione di Poisson. Per verificare tale ipotesi si estrae un campione di 60 circuiti e, per ciascuno di essi, si osserva il numero di difetti che presenta. Il risultato è riassunto nella seguente tabella:

Numero difetti	Frequenza osservata
0	32
1	15
2	9
≥ 3	4

In base a questi dati, si può ritenere al 5% che X segua una legge di Poisson? Com'è definito il p-value del test? Cosa possiamo dire circa il suo valore?

Esercizio # 1.2

Nella sessione di esami 1999-2000 gli studenti hanno ottenuto punteggi finali che sono stati raccolti in quattro categorie **D**, **C**, **B** e **A** rispettivamente con frequenza 40%, 30%, 20% e 10%. In un campione di 2500 studenti che hanno sostenuto lo stesso esame nella sessione 2001-2002 si sono osservate le seguenti frequenze:

Punteggio	Frequenza osservata
D	1170
C	585
B	405
A	340

Al livello di significatività dell'1% si può concludere che questo gruppo sia omogeneo all'insieme degli studenti dell'anno precedente?

Esercizio # 1.3

Si suppone che la v.a. X che misura il tempo medio di vita (in mesi) delle lampadine della ditta *Bulbo Incandescente* segua una legge esponenziale. Su un campione di 100 lampadine si sono osservate le seguenti durate

	Frequenza osservata
$X \leq 1$	0.39
$1 < X \leq 2$	0.24
$2 < X \leq 3$	0.12
$3 < X \leq 5$	0.16
$5 < X \leq 10$	0.09

Si stimi il parametro λ della legge e si apronti un test adatto a valutare l'adattamento della legge trovata.

Esercizio # 1.4

Nel 1856 il biologo Gregor Mendel condusse un esperimento di ibridazione sui piselli. Secondo la teoria sulla trasmissione dei caratteri ereditari da lui stesso proposta, l'esperimento avrebbe dovuto produrre piselli del tipo **RY**, **RG**, **WY** e **WG** rispettivamente con frequenze relative $9/16$, $3/16$, $3/16$ e $1/16$. I risultati dell'esperimento furono:

Piselli	RY	RG	WY	WG
Frequenze	315	108	101	32

Questi risultati confermano la teoria di Mendel?

Esercizio # 1.5

Nel paese di *Crazyland* vigono leggi molto peculiari. La premiata ditta di fuochi di artificio *Miccia Corta* afferma che il numero di settimane che trascorrono tra un incidente in fabbrica ed il successivo è a norma di legge (cioè segue una legge esponenziale con media 2). Un ispettore per la sicurezza sul lavoro raccoglie i dati relativi a 100 incidenti e li riassume nella seguente tabella:

Tempo interincidente X	$X < 1$	$1 \leq X < 2$	$2 \leq X < 3$	$3 \leq X < 4$	$4 \leq X$
Frequenze	35	19	18	11	17

Può l'ispettore confermare, con un livello di significatività del 5%, l'affermazione di regolarità avanzata dal titolare dell'azienda.

Esercizio # 1.6

Nel bacino del fiume *Fast-and-Furious creek* l'irrigazione comincia il 15 Aprile; un tecnico è interessato alla probabilità di pioggia durante la prima settimana di tale periodo. Dai dati ricavati negli ultimi 100 anni nell'area di interesse, si è ricavata la seguente distribuzione di giorni piovosi per la settimana in questione:

Giorni piovosi	0	1	2	3, 4, 5, 6, 7	Totale
Frequenza assoluta	57	30	9	4	100

Sulla base dei dati raccolti è plausibile, ad un livello di significatività del 3%, che il numero dei giorni piovosi segua una legge binomiale $\mathcal{B}(7, 0.1)$.

Esercizio # 1.7

Arturo Cecato, altresì noto agli amici come *Killer*, è un giocatore di freccette accanito, ma piuttosto incapace e pericoloso. In una serata tipica (10 partite) il numero di persone colpite dai suoi tiri fuori bersaglio è notevole. La seguente tabella riassume le sue "imprese" relative a 75 serate

Personne colpite	1	2	3	4	5	6	7	8
Frequenza assoluta	1	11	8	13	11	12	10	9

È plausibile assumere che il numero di persone colpite segua una legge di Poisson di parametro 6? In caso negativo, possiamo concludere che la legge non sia una Poisson?

Esercizio # 1.8

Il signor **Ercole Maciste**, titolare della omonima ditta di martinetti idraulici, vuole analizzare la durata del modello "Ercolissimo" in commercio da ben 5 anni. Si analizza un campione di 100 martinetti di cui si è appena rotto l'ultimo ottenendo la seguente tabella che riporta i tempi intercorsi dalla consegna al guasto (calcolati in settimane).

Tempo intercorso X	Frequenza assoluta
$0 \leq X < 300$	55
$300 \leq X < 600$	25
$600 \leq X < 900$	10
$900 \leq X < 1200$	4
$1200 \leq X < 1500$	3
$1500 \leq X < 1800$	2
$1800 \leq X \leq 1825$	1

È possibile affermare che il tempo di vita dell'apparecchio in questione segua una legge esponenziale? Qual è il tempo di vita medio?

Esercizio # 1.9

Un certo protocollo per il controllo qualità classifica i termometri in quattro classi **A**, **B**, **C** e **D**. Sulla base dell'esperienza passata, i termometri della ditta "Fevertime" si distribuiscono tra le categorie secondo la seguente tabella:

Categoria	A	B	C	D
Proporzione	0.87	0.09	0.03	0.01

L'azienda produttrice sottopone un nuovo lotto di 1336 termometri ad un controllo che dà il seguente risultato:

Categoria	A	B	C	D
Frequenza assoluta	1188	91	47	10

Si può affermare che il nuovo lotto è conforme agli standard passati?

Esercizio # 1.10

La ditta farmaceutica *Pasticche&Vaccini* sta conducendo uno studio su un ceppo batterico mutante in grado di essere utilizzato per la produzione di nuovi medicinali. La particolarità di questo batterio è che la colonia muta (con il ritmo di una volta ogni 24 ore) le sue caratteristiche. In particolare si suppone che possa assumere 3 "forme" differenti A, B e C con probabilità

Categoria	A	B	C
Probabilità	λ	λ	$1 - 2\lambda$

dove $\lambda \in (0, 1/2)$. Per verificare tale ipotesi e cercare un valore opportuno per λ si testa la colonia nei primi 24 giorni di vita e si ottiene la seguente tabella

Categoria	A	B	C
Frequenza assoluta	6	8	10

Ci si chiede se esiste un valore di λ per cui si possa accettare la legge teorica ad un livello di significatività del 5%. Quale valore di λ rende migliore l'adattamento? Cosa si potrebbe concludere nel caso in cui l'ampiezza del campione fosse 2400 così suddivisa

Categoria	A	B	C
Frequenza assoluta	600	800	1000

ad un livello di significatività del 5%?

2. Test χ^2 di indipendenza

Esercizio # 2.1

Ad un campione di 150 persone sono stati chiesti il colore e l'animale preferiti. La seguente tabella mostra i risultati:

	Rosso	Blu	Verde	giallo	Totale
Gatto	7	17	16	13	53
Cane	8	28	22	9	67
Cavallo	5	10	9	6	30
Totale	20	55	47	28	150

Ci chiediamo se il colore preferito si possa ritenere indipendente dall'animale preferito ad un livello di significatività del 12%.

Esercizio # 2.2

Da uno studio condotto su un campione di 1423 individui di 32 anni, di cui 849 primogeniti, si è appurato che ben 115 sono in possesso di una laurea e 543 si sono fermati al diploma di scuola superiore. Dei rimanenti, 84 possiedono una laurea, mentre il numero di coloro che si sono fermati al diploma di scuola superiore è 403. Da questi dati si può desumere l'indipendenza tra primogenitura e grado di istruzione?

Esercizio # 2.3

Per controllare l'efficacia del vaccino Salk (contro la poliomielite) vennero scelti a caso due gruppi di persone, rispettivamente vaccinate e non. Per ogni gruppo si calcolò quante persone non erano state colpite dalla malattia (gruppo 1), quante si erano ammalate di poliomielite ma senza conseguenze di tipo paralitico (gruppo 2) e quante avevano avuto anche conseguenze di tipo paralitico (gruppo 3). I dati osservati sono riassunti nella seguente tabella:

	Gruppo 1	Gruppo 2	Gruppo 3
Vaccinati	200688	24	33
Non vaccinati	201087	27	115

È ovvio che l'indipendenza tra le due variabili X ("vaccinato" e "non vaccinato") e Y ("gruppo 1", "gruppo 2" e "gruppo 3") comporterebbe una sostanziale inefficacia del vaccino; cosa concludiamo a questo proposito?

3. Test di confronto tra due medie

Esercizio # 3.1

L'osservazione del tempo X speso dai clienti agli sportelli della banca *Credito Popolare Usuraio* ha dato il seguente risultato: per lo sportello **A** il tempo medio è risultato pari a 85 secondi con una deviazione standard campionaria di 15 secondi (su un campione di 150 persone), mentre per lo sportello **B** si è osservato un tempo medio di 81 con deviazione standard campionaria di 20 secondi (su un campione di 200 persone). Ci si chiede se sia plausibile pensare, ad un livello di significatività del 5%, che i clienti passino lo stesso tempo ai due sportelli.

Soluzioni

Soluzione es 1.1:

Stimiamo il parametro λ della legge di Poisson utilizzando la media campionaria che, come è noto è uno stimatore non distorto e consistente; pertanto, essendo l'ampiezza del campione $n = 60$, si ha

$$\lambda = \frac{32 \cdot 0 + 15 \cdot 1 + 9 \cdot 2 + 4 \cdot 3}{60} = 0.75.$$

Per effettuare il test di adattamento si costruiscono i valori teorici di frequenza assoluta della variabile X utilizzando la distribuzione di Poisson $\mathcal{P}(0.75)$ come in tabella (si ricordi che $\mathbb{P}(X = i) = \exp(-\lambda) \frac{\lambda^i}{i!}$):

Numero difetti	Frequenza assoluta osservata	Frequenza assoluta teorica
0	32	28.34
1	15	21.26
≥ 2	13	10.40

Utilizzando la statistica

$$Q = \sum_{i=1}^{N_c} \frac{(n \cdot p_i - F_i)^2}{n \cdot p_i} \approx Y \sim \chi^2(N_c - 1 - r)$$

dove $N_c = 3$ è il numero delle classi, $n \cdot p_i$ sono le frequenze assolute teoriche riassunte nella precedente tabella, F_i sono le frequenze assolute osservate e $r = 1$ è il numero di parametri della distribuzione stimati dai dati e considerando come ipotesi nulla

H_0 : le osservazioni provengono dalla distribuzione teorizzata

si ottiene $Q = 2.9659$. Ricordiamo che l'ipotesi nulla viene accettata ad un livello di significatività α se e solo se $Q < \chi_{1-\alpha}^2(N_c - 1 - r) = \chi_{0.95}^2(1) = 3.841$. Quindi l'ipotesi nulla viene accettata al 5%. Alternativamente, il p-value del test è $\bar{\alpha} = 1 - F_{\chi^2(1)}(2.9659) = 0.0850$, un valore non molto alto che comporta la forte dipendenza dell'esito del test dalla scelta di α .

Soluzione es 1.2:

Calcoliamo la frequenza attesa per un campione di ampiezza $n = 2500$

Punteggio	Frequenza osservata	Frequenza attesa
D	1170	1000
C	585	750
B	405	500
A	340	250

Utilizzando la statistica

$$Q = \sum_{i=1}^{N_c} \frac{(n \cdot p_i - F_i)^2}{n \cdot p_i} \approx Y \sim \chi^2(N_c - 1)$$

dove $N_c = 4$ è il numero delle classi, $n \cdot p_i$ sono le frequenze assolute attese, F_i sono le frequenze assolute osservate. e considerando come ipotesi nulla

H_0 : le osservazioni provengono dalla distribuzione teorizzata

si ottiene $Q = 28.9 + 36.3 + 18.05 + 32.4 = 115.65$. Ricordiamo che l'ipotesi nulla viene accettata ad un livello di significatività α se e solo se $Q < \chi_{1-\alpha}^2(N_c - 1) = \chi_{0.99}^2(3) = 11.3449$. Quindi l'ipotesi nulla viene rifiutata al livello 1%. Alternativamente, il p-value del test è $\bar{\alpha} = 1 - F_{\chi^2(3)}(115.65) \approx 0$ per cui l'ipotesi nulla è ragionevolmente rifiutabile.

Soluzione es 1.3:

Incominciamo con lo stimare il parametro λ dell'esponenziale. Uno stimatore non distorto e consistente per il parametro λ è $(n - 1) / \sum_{i=1}^n x_i$ (per $n > 1$). Utilizzando tale stimatore e approssimando $\sum_{i=1}^n x_i$ con $n \sum_{i=1}^{N_c} \bar{c}_j f_j$ dove f_j è la frequenza relativa della classe j -esima e \bar{c}_j è la media uniforme della classe j -esima si ha

$$\lambda = \frac{0.99}{0.39 \cdot 0.5 + 0.24 \cdot 1.5 + 0.12 \cdot 2.5 + 0.16 \cdot 4 + 0.09 \cdot 7.5} \approx 0.461.$$

Per effettuare il test di adattamento si costruiscono i valori teorici di frequenza utilizzando la distribuzione esponenziale $\exp(0.461)$ come in tabella:

	Frequenza teorica
$X \leq 1$	$1 - \exp(-0.461) \approx 0.3693$
$1 < X \leq 2$	$\exp(-0.461) - \exp(-0.461 \cdot 2) \approx 0.2329$
$2 < X \leq 3$	$\exp(-0.461 \cdot 2) - \exp(-0.461 \cdot 3) \approx 0.1469$
$3 < X \leq 5$	$\exp(-0.461 \cdot 3) - \exp(-0.461 \cdot 5) \approx 0.1511$
$5 < X \leq 10$	$\exp(-0.461 \cdot 5) - \exp(-0.461 \cdot 10) \approx 0.0898$

e si utilizza la seguente statistica

$$Q = n \sum_{i=1}^{N_c} \frac{(p_i - f_i)^2}{p_i} \approx Y \sim \chi^2(N_c - 1 - r)$$

dove $N_c = 5$ è il numero delle classi, p_i sono le frequenze relative teoriche riassunte nella precedente tabella, f_i sono le frequenze relative osservate, r è il numero di parametri della distribuzione stimati dai dati (in questo caso $r = 1$) ed infine $n = 100$ è l'ampiezza del campione. L'ipotesi nulla

H_0 : le osservazioni provengono dalla distribuzione teorizzata

viene accettata ad un livello di significatività α se e solo se $Q < \chi_{1-\alpha}^2(N_c - 1 - r)$ (dove $\chi_{1-\alpha}^2(k)$ è la funzione quantile della distribuzione χ^2 con k gradi di libertà in calcolata in corrispondenza del valore $1-\alpha$). Alternativamente, il p-value del test è $\bar{\alpha} = 1 - F_{\chi^2(N_c-1-r)}(Q)$. Utilizzando i dati del problema $Q = 0.6732$ e $\bar{\alpha} = 0.8795$. Il test è quindi accettato al livello di significatività del 10%.

Soluzione es 1.4:

Allo scopo di verificare l’adattamento dei dati reali a quelli teorici calcoliamo le frequenze relative osservate e testiamo l’ipotesi nulla

H_0 : i dati provengono dalla legge teorizzata da Mendel.

L’ampiezza del campione è $n = 315 + 108 + 101 + 32 = 556$ quindi

Piselli	RY	RG	WY	WG
Frequenze assolute osservate	315	108	101	32
Frequenze relative osservate	315/556	108/556	101/556	32/556
Frequenze relative teoriche	9/16	3/16	3/16	1/16

da cui

$$Q = n \sum_{i=1}^{N_c} \frac{(p_i - f_i)^2}{p_i} = 0.47.$$

Il p-value del test è pertanto $\bar{\alpha} = 1 - F_{\chi^2(3)}(0.47) \approx 0.9254$, quindi la teoria di Mendel è molto plausibile.

Soluzione es 1.5:

Il lavoro dell’ispettore è quello di svolgere un test di adattamento sugli $n = 100$ dati provenienti dalla variabile X (tempo che intercorre tra un’incidente ed il successivo); l’ipotesi nulla è

H_0 : per la legge di X vale $\mathcal{L}(X) = \exp(0.5)$.

Ricordando che la funzione di ripartizione della legge $\exp(\lambda)$ è $F(x) = (1 - \exp(-x\lambda))\mathbb{I}_{(0,+\infty)}(x)$ calcoliamo i valori di frequenza assoluta teorici

Tempo interincidente X	$X < 1$	$1 \leq X < 2$	$2 \leq X < 3$	$3 \leq X < 4$	$4 \leq X$
Frequenze assolute osservate	35	19	18	11	17
Frequenze assolute teoriche	39.35	23.87	14.47	8.78	13.53

Utilizziamo la statistica

$$Q = \sum_{i=1}^{N_c} \frac{(n \cdot p_i - F_i)^2}{n \cdot p_i} = 3.7869$$

ed otteniamo il p-value del test è $\bar{\alpha} = 1 - F_{\chi^2(4)}(3.7869) = 0.4356$, pertanto l'ipotesi nulla è accettata ad un livello di significatività del 5% ed la ditta *Miccia Corta* viene considerata in regola.

Alternativamente si confronta $\chi_{0.95}^2(4) = 9.4877$ con Q ; essendo $Q < \chi_{0.95}^2(4)$ non possiamo rifiutare l'ipotesi nulla.

Soluzione es 1.6:

Si tratta di testare l'adattamento dei dati ad una legge Binomiale di parametri noti. Osserviamo immediatamente che, se chiamiamo X la variabile aleatoria, allora $\mathbb{P}(X = 0) = 0.4783$, $\mathbb{P}(X = 1) = 0.372$, $\mathbb{P}(X = 2) = 0.124$ e $\mathbb{P}(X \geq 3) = 0.0257$, pertanto

Giorni piovosi	0	1	2	3, 4, 5, 6, 7
Frequenza assoluta osservata	57	30	9	4
Frequenza assoluta teorica	47.83	37.2	12.4	2.57

Utilizziamo la statistica

$$Q = \sum_{i=1}^{N_c} \frac{(n \cdot p_i - F_i)^2}{n \cdot p_i} \approx Y \sim \chi^2(N_c - 1 - r)$$

dove $N_c = 4$ è il numero delle classi, $n \cdot p_i$ sono le frequenze assolute teoriche, F_i sono le frequenze assolute osservate, $r = 0$ è il numero di parametri della distribuzione stimati dai dati ed infine $n = 100$ è l'ampiezza del campione considerato. Formuliamo l'ipotesi nulla

H_0 : le osservazioni provengono dalla distribuzione teorizzata

ottenendo $Q = 4.8796$ da cui il p-value del test è $\bar{\alpha} = 1 - F_{\chi^2(3)}(4.8796) = 0.1808$; l'ipotesi nulla è accettata ad un livello di significatività del 5%.

Soluzione es 1.7:

Dovendo testare l'adattamento dei dati ad una legge di Poisson di parametro noto procediamo immediatamente con il calcolo dei valori teorici di frequenza assoluta della variabile X utilizzando la distribuzione di Poisson $\mathcal{P}(6)$ (si ricordi che $\mathbb{P}(X = i) = \exp(-\lambda) \frac{\lambda^i}{i!}$); per ottenere una buona stima è necessario accorpate i dati in maniera tale che la frequenza di ogni classe non sia inferiore a 5:

Persone colpite	Frequenza assoluta osservata	Frequenza assoluta teorica
≤ 2	12	4.6477
3	8	6.6926
4	13	10.0389
5	11	12.0467
6	12	12.0467
7	10	10.3258
≥ 8	9	19.2015

Utilizzando la statistica

$$Q = \sum_{i=1}^{N_c} \frac{(n \cdot p_i - F_i)^2}{n \cdot p_i} \approx Y \sim \chi^2(N_c - 1 - r)$$

dove $N_c = 7$ è il numero delle classi, $n \cdot p_i$ sono le frequenze assolute teoriche, F_i sono le frequenze assolute osservate e $r = 0$ è il numero di parametri della distribuzione stimati dai dati ed infine $n = 75$ è l'ampiezza del campione statistico. Formuliamo al solito l'ipotesi nulla

H_0 : le osservazioni provengono dalla distribuzione teorizzata.

Con semplici calcoli si ottiene $Q = 18.2809$ pertanto p-value del test è $\bar{\alpha} = 1 - F_{\chi^2(6)}(18.2809) = 0.0026$; l'ipotesi nulla può essere ragionevolmente rifiutata.

Naturalmente non possiamo concludere che la legge non sia una Poisson; proviamo a stimare il parametro λ utilizzando la media campionaria

$$\lambda = \frac{1 + 2 \cdot 11 + 3 \cdot 8 + 4 \cdot 13 + 5 \cdot 11 + 6 \cdot 12 + 7 \cdot 10 + 8 \cdot 9}{75} = 4.9067$$

Ripetiamo quindi calcoli analoghi ottenendo

Persone colpite	Frequenza assoluta osservata	Frequenza assoluta teorica
≤ 2	12	9.9550
3	8	10.9226
4	13	13.3985
5	11	13.1485
6	12	10.7526
7	10	7.5371
≥ 8	9	9.2858

da cui $Q = 2.5233$ e $\bar{\alpha} = 1 - F_{\chi^2(5)}(2.5233) \approx 0.773$. Per cui l'adattamento alla legge è buono.

Soluzione es 1.8:

Stimiamo il parametro λ dell'esponenziale utilizzando il campione di $n = 100$ dati a nostra disposizione. Uno stimatore non distorto e consistente per il parametro λ è $(n - 1) / \sum_{i=1}^n x_i$ (per $n > 1$). Approssimando $\sum_{i=1}^n x_i$ con $\sum_{i=1}^{N_c} \bar{c}_j F_j$ dove F_j è la frequenza assoluta della classe j -esima e \bar{c}_j è la media uniforme della classe j -esima si ha

$$\lambda = \frac{99}{55 \cdot 150 + 25 \cdot 450 + 10 \cdot 750 + 4 \cdot 1050 + 3 \cdot 1350 + 2 \cdot 1650 + 1813} \approx \frac{99}{40363} = 2.453 \cdot 10^{-3}$$

Per effettuare il test di adattamento si costruiscono i valori teorici di frequenza assoluta utilizzando la distribuzione esponenziale $\exp(2.453 \cdot 10^{-3})$ come in tabella (accorpono opportunamente i dati in modo da avere $n_i \geq 5$):

Tempo intercorso X	Frequenza assoluta dei dati	Frequenza assoluta teorica
$0 \leq X < 300$	55	52.09
$300 \leq X < 600$	25	25
$600 \leq X < 900$	10	11.96
$900 \leq X$	10	11

Utilizziamo ora la seguente statistica

$$Q = \sum_{i=1}^{N_c} \frac{(n \cdot p_i - F_i)^2}{n \cdot p_i} \approx Y \sim \chi^2(N_c - 1 - r)$$

dove $N_c = 4$ è il numero delle classi, $n \cdot p_i$ sono le frequenze assolute teoriche riassunte nella precedente tabella, F_i sono le frequenze assolute osservate e $r = 1$ è il numero di parametri della distribuzione stimati dai dati. L'ipotesi nulla

H_0 : le osservazioni provengono dalla distribuzione teorizzata

viene accettata ad un livello di significatività α se e solo se $Q < \chi_{1-\alpha}^2(N_c - 1 - r)$. Alternativamente, il p-value del test è $\bar{\alpha} = 1 - F_{\chi^2(N_c - 1 - r)}(Q)$. Utilizzando i dati del problema $Q = 0.5747$ e $\bar{\alpha} = 0.7502$. Il test è quindi ragionevolmente accettato.

Soluzione es 1.9:

Si consideri la seguente tabella

Categoria	A	B	C	D
Frequenza assoluta na	1188	91	47	10
Frequenza relativa teorica	0.87	0.09	0.03	0.01
Frequenza assoluta teorica nt	1162.32	120.24	40.08	13.36
$(na - nt)^2/nt$	0.5674	7.1106	1.1948	0.845

da cui $Q = 9.718$. Poichè asintoticamente la distribuzione di Q è $\chi^2(3)$ si calcola il p-value $\bar{\alpha} = 1 - F_{\chi^2(3)}(9.718) = 0.0211$, pertanto concludiamo che ragionevolmente il nuovo lotto è difforme dai precedenti.

Soluzione es 1.10:

Per verificare l'adattamento calcoliamo

$$Q = n \sum_{i \in J} \frac{(p_i - f_i)^2}{p_i}$$

e quindi il p-value $\bar{\alpha} = 1 - F_{\chi^2(|J|-1-r)}(Q)$. Per le note proprietà di monotonia delle funzioni di ripartizione, massimizzare il p-value equivale a minimizzare Q . Supponendo che $p_i = p_i(\underline{\lambda})$ (dove $\underline{\lambda} \in \Omega \subset \mathbb{R}^n$ è un vettore di parametri) siano funzioni derivabili e strattamente positive, allora il minimo di Q nell'aperto Ω se esiste deve essere soluzione di $JQ = 0$ dove, dal teorema di derivazione della funzione composta,

$$Jq(\underline{\lambda}) = n \sum_{i \in J} \left(1 - \frac{f_i^2}{p_i^2(\underline{\lambda})} \right) Jp_i(\underline{\lambda}).$$

Nel nostro caso, posto $f_1 = 6/24 = 0.25$, $f_2 = 8/24 = 1/3$ e $f_3 = 10/24 = 5/12$, si tratta di risolvere l'equazione

$$1 - \frac{f_1^2}{\lambda^2} + 1 - \frac{f_2^2}{\lambda^2} - 2\left(1 - \frac{f_3^2}{(1-2\lambda)^2}\right) = 0$$

con $\lambda \in (0, 1/2)$, la cui soluzione è $\lambda = 1/(2 + \sqrt{2f_3^2/(f_1^2 + f_2^2)}) \approx 0.2929$ (si vede facilmente che questa corrisponde ad un punto di minimo). Pertanto $Q = 0.2851$ e $\bar{\alpha} = 1 - F_{\chi^2(1)}(Q) = 0.5934$ e l'ipotesi di adattamento è accettata al 5%.

Se ora l'ampiezza del campione fosse $n = 2400$ con le stesse frequenze relative si vedrebbe immediatamente, con calcoli analoghi che $Q = 28.51$ e $\bar{\alpha} = 9.3153 \cdot 10^{-8}$ per cui l'ipotesi sarebbe rifiutata (per ogni $\lambda \in (0, 1/2)$).

Soluzione es 2.1:

Per testare l'indipendenza delle variabili si utilizza la seguente statistica

$$Q = \sum_{i=1}^{N_1} \sum_{j=1}^{N_2} \frac{(F_{i,j} - F_i^1 F_j^2/n)^2}{F_i^1 F_j^2/n} = n \sum_{i=1}^{N_1} \sum_{j=1}^{N_2} \frac{(f_{i,j} - f_i^1 f_j^2)^2}{f_i^1 f_j^2} \approx Y \sim \chi^2((N_1 - 1)(N_2 - 1))$$

dove $N_1 = 3$ ed $N_2 = 4$ sono il numero di classi in cui abbiamo suddiviso i dati derivanti rispettivamente dalla prima (X) e dalla seconda (Y) variabile, $f_{i,j}$ (risp. $F_{i,j}$) è la frequenza relativa (risp. assoluta) congiunta (X, Y) mentre f_i^1 ed f_j^2 (risp. F_i^1 e F_j^2) sono le frequenze relative (risp. assolute) di X ed Y rispettivamente ed infine $n = 150$ è l'ampiezza del campione. L'ipotesi nulla

H_0 : le variabili X ed Y sono indipendenti

viene accettata ad un livello di significatività α se e solo se $Q < \chi_{1-\alpha}^2((N_1 - 1)(N_2 - 1))$. Alternativamente, il p-value del test è $\bar{\alpha} = 1 - F_{\chi^2((N_1-1)(N_2-1))}(Q)$. Utilizzando i dati del problema si calcolano $Q = 3.2983$ e $\bar{\alpha} = 0.7706$. Il test è quindi accettato al livello di significatività del 12%.

Soluzione es 2.2:

Implementiamo un test χ^2 di indipendenza utilizzando i dati forniti dal campione di ampiezza $n = 1423$

	Primogenito	Non primogenito	Totale
Né laurea né diploma superiore	191	87	278
Diploma superiore, non laurea	543	403	946
Laurea	115	84	199
Totale	849	574	1423

Utilizzando la seguente statistica

$$Q = n \sum_{i=1}^{N_1} \sum_{j=1}^{N_2} \frac{(f_{i,j} - f_i f_j)^2}{f_i f_j}$$

con $N_1 = 3$, $N_2 = 2$ si ha $Q = 11.75$ ed il p-value $\bar{\alpha} = 1 - F_{\chi^2(2)}(11.75) \approx 0.028$, pertanto propendiamo per rifiutare l'ipotesi nulla e quindi per una dipendenza dai dati.

Soluzione es 2.3:

Costruiamo inizialmente la tabella delle frequenze relative (tenendo presente che il campione ha ampiezza $n = 401974$)

	Gruppo 1	Gruppo 2	Gruppo 3	Totale
Vaccinati	0.49926	$5.97 \cdot 10^{-5}$	$8.21 \cdot 10^{-5}$	0.49940
Non vaccinati	0.50025	$6.72 \cdot 10^{-5}$	$28.61 \cdot 10^{-5}$	0.50060
Totale	0.99951	$12.69 \cdot 10^{-5}$	$36.82 \cdot 10^{-5}$	1

Utilizzando i dati del problema si ottiene

$$Q = n \sum_{i=1}^{N_1} \sum_{j=1}^{N_2} \frac{(f_{i,j} - f_i f_j)^2}{f_i f_j} = 45.41$$

ed il p-value $\bar{\alpha} = 1 - F_{\chi^2(2)}(45.41) \approx 1.38 \cdot 10^{-10}$, pertanto l'ipotesi nulla è ragionevolmente rifiutata.

Soluzione es 3.1:

Consideriamo l'ipotesi nulla

$$H_0: \text{le variabili } \mu_A \leq \mu_B$$

Siamo nel caso in cui le varianze sono incognite e non necessariamente uguali; le approssimiamo con le varianze campionarie $\sigma_A^2 = 225$ e $\sigma_B^2 = 400$ da cui si calcola

$$z = \frac{\bar{x}_A - \bar{x}_B}{\sqrt{\frac{\sigma_A^2}{n_A} + \frac{\sigma_B^2}{n_B}}} = \frac{85 - 81}{\sqrt{\frac{225}{50} + \frac{400}{200}}} \approx 2.1381.$$

la regione di rifiuto di H_0 è $\{z > q_{1-\alpha}\} = q_{0.95} = 1.6449$ ed il p-value è $\bar{\alpha} = 1 - \phi(z) \equiv \phi(-z) = 0.0163$, pertanto il test viene rifiutato.