

SECONDA PROVA INTERMEDIA DI STATISTICA**CLEA, CLEFIN, CLAPI (COD. 5047/4038)****CLELI 4038****371/377****14 Gennaio 2004***Cognome**Nome**Numero di matricola**Codice corso***COMPITO B1**

Ai fini della valutazione si terrà conto solo ed esclusivamente di quanto riportato negli appositi spazi. Al termine della prova, è OBBLIGATORIO consegnare il presente foglio ed il foglio di brutta (DI CUI NON SI TERRÀ CONTO AI FINI DELLA VALUTAZIONE).

APPROSSIMARE TUTTI I CALCOLI ALLA QUARTA CIFRA DECIMALE

- 1) La quantità di acqua contenuta nelle bottiglie da un litro e mezzo di una certa marca si distribuisce secondo una normale con valore atteso pari a 1.5 (litri) e varianza pari a 0.04 (litri²).

- a) Calcolare la probabilità che, scelta a caso una bottiglia, essa contenga una quantità di acqua compresa fra 1.4 e 1.6 litri. **(1 punto)**

$$\begin{aligned}
 X &= \text{quantità d'acqua in una bottiglia} & X &\sim N(1.5, 0.04) \\
 \Pr(1.4 < X < 1.6) &= \Pr(X < 1.6) - \Pr(X \leq 1.4) = \Pr\left(Z < \frac{0.1}{0.2}\right) - \Pr(Z \leq -0.5) = \\
 &= 0.6915 - (1 - 0.6915) = \mathbf{0.383}
 \end{aligned}$$

- b) Scelte a caso 150 bottiglie, si calcoli la probabilità che la quantità totale di acqua contenuta nelle 150 bottiglie sia maggiore di 222 litri? **(2 punti)**

$$\begin{aligned}
 X_1 + \dots + X_{150} &\sim N(150 \cdot 1.5; 150 \cdot 0.04) \sim N(225; 6) \\
 \Pr(X_1 + \dots + X_{150} > 222) &= \Pr\left(Z > \frac{222 - 225}{\sqrt{6}}\right) = \Pr(Z > -1.22) = \Pr(Z = 1.22) = \mathbf{0.8888}
 \end{aligned}$$

- 2) Siano X_1 e X_2 due variabili aleatorie *iid*, con $X_i \sim \text{Be}(0.2)$ ($i = 1, 2$).

- a) Determinare la distribuzione del vettore aleatorio (X_1, X_2) **(1 punto)**

$$\Pr(X_i = x) = \begin{cases} 0.2 & \text{per } x = 1 \\ 0.8 & \text{per } x = 0 \end{cases}. \text{ Quindi avremo}$$

$X_1 \backslash X_2$	0	1
0	0.64	0.16
1	0.16	0.04

- b) Fornire la funzione di probabilità di $Y = |X_1 - X_2|$ **(1 punto)**

$$\Pr(Y_i = y) = \begin{cases} 0.68 & \text{per } y = 0 \\ 0.32 & \text{per } y = 1 \end{cases}$$

- 3) Una società che si occupa di sondaggi vuole stimare la proporzione di italiani che intende votare SI ad un referendum. A tal fine vengono intervistati 300 italiani con diritto di voto, 200 dei quali dichiarano di essere intenzionati a votare SI.

a) Fornire una stima della proporzione incognita oggetto di indagine (**1 punto**)

Stimatore: \bar{X}

$$\text{Stima: } \bar{x} = \frac{200}{300} = 0.6667$$

b) Fornire uno stimatore e la corrispondente stima della varianza dello stimatore utilizzato al punto precedente (**2 punti**)

Stimatore: \bar{X}

$$\text{Varianza di stima} = \text{Var}(\bar{X}) = \frac{\text{Var}(X)}{n} = \frac{p(1-p)}{n}$$

$$\text{Stima della varianza di stima: } \hat{\text{Var}}(\bar{X}) = \frac{\hat{p}(1-\hat{p})}{n} = \frac{0.6667 \cdot 0.3333}{300} = 0.0007$$

- 4) Da una popolazione $X \sim \text{Uniforme}(\theta, \theta+2)$ viene estratto un campione casuale semplice di ampiezza n . Al fine di stimare il parametro θ , vengono proposti i due stimatori:

$$T_1 = \bar{X}$$

$$T_2 = \frac{X_1 + X_n - 2}{2}$$

a) Dimostrare che T_1 è uno stimatore distorto rispetto a θ e proporre, a partire da T_1 , uno stimatore non distorto per θ (si chiami questo nuovo stimatore T_1^*) (**2 punti**)

$$E(T_1) = E(X) = \frac{J+(J+2)}{2} = J+1. \text{ Quindi uno stimatore non distorto può essere } T_1^* = T_1 - 1, \text{ poiché } E(T_1^*) = E(T_1 - 1) = J+1 - 1 = J$$

b) Dimostrare che T_2 è uno stimatore non distorto per θ e calcolarne la varianza (**2 punti**)

$$E\left(\frac{X_1 + X_n - 2}{2}\right) = \frac{E(X_1) + E(X_n) - 2}{2} = \frac{J+1 + J+1 - 2}{2} = J$$

$$\text{Var}\left(\frac{X_1 + X_n - 2}{2}\right) = \frac{\text{Var}(X_1) + \text{Var}(X_n)}{4} = \frac{(J-J-2)^2}{12} \cdot \frac{2}{4} = 0,1667$$

c) Tra T_1 e T_2 quale scegliereste per stimare θ ? Giustificare la risposta (**2 punti**)

Per scegliere tra T_1 e T_2 devo confrontare i loro errori quadratici medi, valutati rispetto a J , che troviamo come somma di varianza e distorsione al quadrato.

$EQM_{T_1}(J) = \frac{1}{3n} + (1)^2 = 1 + \frac{1}{3n}$, mentre $EQM_{T_2}(J) = \frac{1}{6} + (0)^2 = \frac{1}{6}$. Quindi, per qualsiasi n **preferiremo T_2** , perché il suo errore quadratico medio è più basso (qualsiasi sia n).

[Nota. $\text{Var}(T_1) = \text{Var}(\bar{X}) = \frac{\text{Var}(X)}{n} = \frac{(J-J-2)^2}{12} \cdot \frac{1}{n} = \frac{1}{3n}$]

- 5) Si vuole studiare la velocità media (in chilometri orari) μ delle automobili che percorrono una certa autostrada. A tal fine vengono controllate casualmente 200 automobili, ottenendo:

$$\sum_{i=1}^{200} x_i = 24000 \quad \sum_{i=1}^{200} x_i^2 = 3000000$$

dove x_i rappresenta la velocità della i -esima automobile del campione.

- a) Si fornisca uno stimatore non distorto rispetto a μ e se ne calcoli la stima corrispondente in relazione alla realizzazione campionaria osservata (**2 punti**)

Stimatore: \bar{X} , media campionaria

$$\text{Stima: } \bar{x} = \frac{24000}{200} = 120$$

- b) Si dia l'espressione dell'intervallo di confidenza asintotico di livello 0.9 per μ (**2 punti**)

$$\text{I.C.}_{0.90}(\mu) = \left(\bar{X} - z_{0.95} \frac{S_c}{\sqrt{n}}, \bar{X} + z_{0.95} \frac{S_c}{\sqrt{n}} \right) \text{ Intervallo di confidenza aleatorio di livello 0.9 per } \mu.$$

$$\text{i.c.}_{0.90}(\mu) = \left(\bar{x} - z_{0.95} \frac{s_c}{\sqrt{n}}, \bar{x} + z_{0.95} \frac{s_c}{\sqrt{n}} \right) \text{ Intervallo di confidenza di livello 0.9 per } \mu.$$

- c) Si determinino, specificando il valore assunto da tutte le quantità coinvolte, gli estremi dell'intervallo sopra proposto in corrispondenza della realizzazione campionaria osservata (**2 punti**)

$$s_c^2 = \frac{200}{199} \left(\frac{3000000}{200} - (120)^2 \right) = \frac{200}{199} (15000 - 14400) = 603.0151 \quad s_c = 24.5564$$

$$\bar{x} = 120 \quad n = 200 \quad z_{0.95} = 1.645$$

$$\text{i.c.}_{0.9}(\mu) = \left(120 - 1.645 \frac{24.5564}{\sqrt{200}}, 120 + 2.8564 \right) = (117.1436, 122.8564)$$

- 6) Si suppone che la distribuzione del prezzo di un certo prodotto nei supermercati di Milano segua una legge normale, con varianza pari a 1 euro². A partire da un campione casuale di 9 supermercati, si vuole verificare il seguente sistema di ipotesi:

$$H_0: \mu = 4 \text{ (euro)}$$

$$H_1: \mu = 3 \text{ (euro)}$$

dove μ rappresenta il prezzo medio incognito del prodotto in tutti i supermercati milanesi.

- a) Si scriva la regione di rifiuto del test più potente al livello $\alpha = 0.1$ per verificare H_0 contro H_1 (**2 punti**)

$$R := \left\{ (x_1, \dots, x_9) : \frac{\bar{x} - 4}{\sqrt{\frac{1}{9}}} < -z_{0.9} \right\} = \left\{ (x_1, \dots, x_9) : \bar{x} < 4 - \frac{1}{3} \cdot 1.282 \right\} = \left\{ (x_1, \dots, x_9) : \bar{x} < 3.5727 \right\}$$

- b) Si prenda una decisione sulla base del test proposto, supponendo che la somma dei prezzi del prodotto registrati nei 9 supermercati del campione sia pari a 32.4 euro (**2 punti**)

$\bar{x} = 3.6$. Questo significa che $\bar{x} \notin R$ e quindi **accetto** l'ipotesi nulla.

c) Si calcoli la potenza del test utilizzato, specificando il procedimento adottato (2 punti)

Per valutare la potenza del test, valuteremo $1 - b$.

$$b = \Pr\{\bar{X} > 3.5727 | m = 3\} = \Pr\left\{Z > \frac{3.5727 - 3}{\frac{1}{3}}\right\} = \Pr\{Z > 1.7181\} = 1 - 0.9573 = 0.0427$$

Quindi la potenza del test, sarà pari a **0.9573**.

7) Esiste una relazione tra la temperatura e la profondità dell'acqua in un lago? Nella seguente tabella è riportato l'output della regressione lineare della variabile Y = "temperatura dell'acqua" (in gradi centigradi) sulla variabile X = "profondità" (in metri) (la regressione è effettuata in base ad una serie di dati sulle due variabili raccolti in diversi punti di uno stesso lago):

R	R al quadrato
0.922	0.850

	Coefficienti	Errore standard	t	p-value
intercetta	23.384	1.592	14.691	.000
PROFONDITA'	-1.435	.213	-6.726	.000

a) Si scriva l'equazione della retta di regressione lineare di Y rispetto a X (1 punto)

$$\hat{y} = 23.384 - 1.435x$$

b) Sulla base delle informazioni contenute nelle tabelle, è possibile rifiutare l'ipotesi secondo cui il coefficiente angolare della retta sarebbe uguale a zero? Perché? (2 punti)

Secondo i valori presentati nella tabella, l'ipotesi nulla $H_0: b_1 = 0$ deve essere rifiutata, poiché il *p-value* è pari a 0.000, che è sicuramente più piccolo di un qualsiasi α prefissato.

c) Si valuti, giustificando la risposta, la bontà del modello di regressione lineare proposto per spiegare la variabile Y e si utilizzi il modello per prevedere la temperatura dell'acqua del lago in un punto di profondità pari a 15 metri (1 punto)

Un $R^2 = 0.85$ (ovvero un valore vicino a 1) indica un'alta capacità della variabile esplicativa X di spiegare il comportamento della variabile dipendente Y.
Per prevedere la temperatura del lago a una profondità di 15 metri basta sostituire a x il valore 15, ottenendo $\hat{y} = 23.384 - 1.435 \cdot 15 = 1.859$.