

FIRMA DELLO STUDENTE

--

SECONDA PROVA INTERMEDIA DI STATISTICA
CLEA - CLEFIN - CLAPI (cod. 5047/4038) CLELI (cod. 4038) 371-377
14 Gennaio 2004

Cognome

Nome

Numero di matricola

Codice corso

COMPITO C1

**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. (2 punti) Sia X una variabile aleatoria Uniforme continua nell'intervallo $[0, 6k]$, $k > 0$.

a) Calcolare il valore atteso di X . **(1 punto)**

b) Calcolare la probabilità che X assuma valori nell'intervallo $\left[\frac{k}{3}, \frac{k}{2}\right]$. **(1 punto)**

a)

$$E(X) = 3k$$

b)

$$\Pr\left(\frac{k}{3} < X \leq \frac{k}{2}\right) = \int_{k/3}^{k/2} \frac{1}{6k} dx = \frac{1}{36}$$

2. (3 punti) Date le variabili aleatorie indipendenti $X \sim N(3, 16)$ e $Y \sim N(2, 25)$:

a) Calcolare il valore atteso e la varianza della v.a. W ottenuta dalla seguente combinazione lineare $W = 42 + 7X - 3Y$. **(2 punti)**.

b) Come si distribuisce la v.a. W ? **(1 punto)**

a)

$$E(W) = E(42 + 7X - 3Y) = 42 + 7E(X) - 3E(Y) = 42 + 21 - 6 = 57$$

$$\text{Var}(W) = \text{Var}(42 + 7X - 3Y) = 7^2 \text{Var}(X) + 3^2 \text{Var}(Y) = 49 \cdot 16 + 9 \cdot 25 = 1009$$

b)

$$N(57, 1009)$$

3. (3 punti)) La probabilità di riuscire a salire sulla linea gialla della metropolitana nelle ore di punta è pari a $4/5$.

a) Come si distribuisce la v.a. X_i che descrive se la i -esima persona riesce a salire sulla metropolitana oppure no? (1 punto)

b) Se si trovano sulla banchina di attesa 150 persone, che cercano di salire indipendentemente una dall'altra, come si distribuisce *approssimativamente* la v.a. \bar{X} "frequenza relativa delle persone che riescono a salire all'arrivo del prossimo convoglio"? (1 punto)

c) Qual è la probabilità che almeno 114 di queste riescano a salire? (1 punto)

<p>a)</p> $\text{Ber}(4/5) \Rightarrow X_i = \begin{cases} 0 & 1/5 \\ 1 & 4/5 \end{cases}$
<p>b)</p> $N\left(\frac{4}{5}, \frac{4}{3750}\right)$
<p>c)</p> $\Pr(\bar{X} \geq 114/150) = \Pr\left(Z \geq \frac{\frac{114}{150} - \frac{4}{5}}{\sqrt{\frac{4}{3750}}}\right) = 1 - \Phi(-1.2247) = 0.8897$

4. (6 punti) Sia (X_1, \dots, X_6) un campione bernoulliano estratto da una popolazione statistica di media $E(X) = 3q$ e $\text{Var}(X) = 1$.

Siano $T_1 = \left(\frac{1}{5}X_1 + \frac{2}{15}X_2\right)$ e $T_2 = \frac{X_4 + X_6}{6}$ due stimatori per q .

a) Dimostrare che sono entrambi corretti e calcolarne i rispettivi errori quadratici medi. (4 punti)

b) Qual è il più efficiente? E perché? (2 punti)

$E(T_1) = \frac{1}{5}3q + \frac{2}{15}3q = q$
$E(T_2) = \frac{1}{6}(3q + 3q) = q$
<p>a)</p> $EQM(T_1) = \text{Var}(T_1) = \left(\frac{1}{5}\right)^2 + \left(\frac{2}{15}\right)^2 = \frac{1}{25} + \frac{4}{225} = \frac{13}{225}$
$EQM(T_2) = \text{Var}(T_2) = \left(\frac{1}{6}\right)^2 + \left(\frac{1}{6}\right)^2 = \frac{2}{36} = \frac{1}{18}$
<p>b) T_2 è più efficiente perchè ha un errore quadratico medio minore.</p>

5. (6 punti) Sia (X_1, \dots, X_6) un campione bernoulliano di osservazioni estratto da una popolazione Normale (μ, σ^2) di media e varianza entrambe incognite.

a) Si definisca con l'opportuna espressione analitica un intervallo di confidenza al livello $(1-\alpha)$ per il parametro μ . **(2 punti)**.

b) Se il campione osservato risulta $(11, 4, 17, 13, 3, 9)$, qual è l'intervallo di confidenza per μ a

livello $1-\alpha = 0.90$? **(2 punti)** [Sugg. $\sum_{i=1}^n x_i = 57, \sum_{i=1}^n x_i^2 = 685$]

c) Se fosse noto che $\sigma = 7$, quale sarebbe la dimensione campionaria minima necessaria per ottenere, allo stesso livello di confidenza, un intervallo di lunghezza pari al massimo a 4? **(2 punti)**

a)

$$\left(\bar{X} - t_{1-\frac{\alpha}{2}}^{n-1} \frac{S_c}{\sqrt{n}}; \bar{X} + t_{1-\frac{\alpha}{2}}^{n-1} \frac{S_c}{\sqrt{n}} \right) \quad (n=6)$$

b)

essendo $\bar{x} = 9.5, s_c^2 = 28.7, s_c = 5.3572$ e $t_{0.95}^5 = 2.015$, si ha

$$(5.0931; 13.9069)$$

c)

$$l = 2 \cdot z_{0.95} \frac{s}{\sqrt{n}} = 2 \cdot 1.645 \cdot \frac{7}{\sqrt{n}} \leq 4 \Rightarrow n \geq \left(\frac{1.645 \cdot 7}{2} \right)^2 = 33.14 \Rightarrow n = 34$$

6. (6 punti) Sia (X_1, \dots, X_5) un campione da una popolazione $X \sim N(\mu, 144)$. Si vuole testare l'ipotesi nulla $H_0: \mu = 11$ contro l'ipotesi alternativa $H_1: \mu < 11$.

a) Proponete l'espressione analitica dell'opportuna regione di rifiuto. **(2 punti)**

b) Per $\alpha = 0.05$, se $(7, 4, 12, 18, 5)$ è il campione osservato, accetto o rifiuto l'ipotesi nulla? **(1 punto)**

c) Se il P-value osservato è 0.02, accetto o rifiuto l'ipotesi nulla? (Giustificare la risposta) **(1 punto)**

d) Se il test fosse caratterizzato dalla regione di rifiuto $R = \{(x_1, \dots, x_n) : \bar{x}_n < 9.5\}$ quale risulterebbe la probabilità dell'errore di prima specie α ? **(2 punti)**

a)

$$R = \left\{ (x_1, \dots, x_n) : \bar{x}_n < m_0 - z_{1-\alpha} \frac{s}{\sqrt{n}} \right\} \quad m_0 = 11, \quad s = 12, \quad n = 5$$

b)

da $z_{1-\alpha} = z_{0.95} = 1.645$ e $\bar{x} = 9.2$ si ha

$9.2 > 2.17$, quindi accetto l'ipotesi nulla.

c)

Rifiuto l'ipotesi nulla, perchè il valore del P-value è minore del livello di significatività assegnato pari a 0.05.

d)

$$\Pr(\bar{X} < 9.5 | H_0) = \Pr\left(Z < \frac{9.5 - 11}{12/\sqrt{5}}\right) = \Phi(-0.28) = 0.3897$$

7. (4 punti) Dato un campione di osservazioni $(Y_1, x_1), (Y_2, x_2), \dots, (Y_n, x_n)$, assumere che il modello lineare semplice spieghi la dipendenza della variabile aleatoria Y dalla variabile deterministica x significa ipotizzare che $Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$, per $i=1, \dots, n$.

E' noto che come stime puntuali dei parametri incogniti β_0 e β_1 si utilizzano le stime dei minimi quadrati \hat{b}_0 e \hat{b}_1 .

a) Quale ipotesi aggiuntiva sulla distribuzione degli errori ε_i , rende *forti* le ipotesi *deboli* per il modello lineare semplice e consente, ad esempio, di calcolare stime di intervallo per β_0 e β_1 ? **(2 punti)**

b) La formula sotto riportata è nota sotto il nome di **scomposizione della devianza totale**.

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Quale delle quantità a destra del segno di uguale è la **devianza del modello**? **(1 punto)**

c) Quale rapporto tra le quantità coinvolte nella scomposizione fornisce il coefficiente di determinazione, che misura la bontà di adattamento del modello lineare? **(1 punto)**

a)

Si assume che gli errori abbiano una *distribuzione normale*.

b)

$$\sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

c)

$$\frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$