

Verifica n. 1 - 21 aprile 2006

COMPITO A

COGNOME E NOME _____

Esercizio 1. Da un'indagine demografica condotta dal *Census Bureau* statunitense, risulta che il 9.96 % dei cittadini americani di età superiore a 18 anni è di origine ispanica. Si consideri un campione casuale di $n = 1200$ cittadini americani e determinare

- il numero medio di cittadini ispanici in un campione di tale ampiezza;
- la probabilità che di un campione di tale ampiezza facciano parte meno di 100 cittadini ispanici.

Svolgimento.

X_i = etnia cittadino i -esimo campionario (1=ispanico, 0=non ispanico);

$Y_n = \sum_{i=1}^n X_i$ = numero di cittadini ispanici nel campione;

$\theta = 0.0996$

$X_i|\theta \sim \text{Ber}(\theta)$, $Y_n|\theta \sim \text{Binom}(n, \theta)$.

a) $E_\theta[Y_n] = n\theta = (1200) * (0.096) = 119.52$.

b) Utilizzando l'approssimazione normale della distribuzione binomiale e ricordando che $V_\theta(Y_n) = n\theta(1 - \theta)$ si ottiene

$$\Pr(Y_n < 100) \approx \Pr(Z < (100 - 119.52)/\sqrt{107.64}) = \Phi(-1.88) = 0.03,$$

dove $\Phi(\cdot)$ indica la funzione di ripartizione della v.a. normale standardizzata (Z).

Esercizio 2. Si consideri un campione casuale di n osservazioni da una popolazione X con distribuzione di probabilità

$$f_X(x; \theta) = \frac{\theta}{(1+x)^{1+\theta}} \quad x > 0, \quad \theta > 0.$$

- Scrivere il modello statistico-probabilistico associato al campione casuale.
- Determinare l'espressione della funzione di verosimiglianza del parametro associata a un generico campione osservato, \mathbf{x}_n ; individuare il nucleo della funzione di verosimiglianza e, se esiste, una statistica sufficiente unidimensionale.
- Determinare la stima di massima verosimiglianza di θ e calcolarne il valore per un campione di dimensione $n = 10$ in cui si ha che

$$\sum_{i=1}^{10} \ln(1+x_i) = 5.$$

- Verificare se la famiglia di densità $\mathcal{F} = \{f_X(\cdot; \theta); \theta \in \Theta\}$ è una famiglia esponenziale.

Svolgimento.

- Il modello statistico è:

$$\left((\mathbb{R}^+)^n, \frac{\theta^n}{[\prod_{i=1}^n (1+x_i)]^{(1+\theta)}} \prod_{i=1}^n I_{(0,+\infty)}(x_i), \mathbb{R}^+ \right).$$

-

$$L(\theta; \mathbf{x}_n) = \prod_{i=1}^n f_X(x_i; \theta) = \frac{\theta^n}{[\prod_{i=1}^n (1+x_i)]^{(1+\theta)}} \prod_{i=1}^n I_{(0,+\infty)}(x_i) = \frac{\prod_{i=1}^n I_{(0,+\infty)}(x_i)}{\prod_{i=1}^n (1+x_i)} \frac{\theta^n}{\prod_{i=1}^n (1+x_i)^\theta}.$$

da cui si evince che L si fattorizza nel prodotto $h(\mathbf{x}_n)g(T(\mathbf{x}_n), \theta)$, dove il nucleo della funzione di verosim. è

$$g(T(\mathbf{x}_n), \theta) = \frac{\theta^n}{\prod_{i=1}^n (1+x_i)^\theta}$$

mentre $h(\mathbf{x}_n) = \frac{\prod_{i=1}^n I_{(0,+\infty)}(x_i)}{\prod_{i=1}^n (1+x_i)}$. Pertanto, per il teorema di fattorizzazione si ha che $T(\mathbf{x}_n) = \prod_{i=1}^n (1+x_i)$ è stat. suff. unidimensionale per il modello considerato.

- Consideriamo la f.ne di log-verosimiglianza:

$$\ell(\theta; \mathbf{x}_n) = n \ln \theta - \theta \sum_{i=1}^n \ln(1+x_i).$$

Per trovare la stima di massima verosimiglianza consideriamo l'equazione di log-verosimiglianza:

$$\frac{d}{d\theta} \ell(\theta; \mathbf{x}_n) = 0 \quad \text{ovvero} \quad \frac{n}{\theta} - \sum_{i=1}^n \ln(1+x_i) = 0,$$

la cui unica radice è $\frac{n}{\sum_{i=1}^n \ln(1+x_i)}$. Poichè la derivata seconda di $\ell(\theta; \mathbf{x}_n)$ è $-n/\theta^2$, ovvero sempre negativa, la radice trovata è punto di massimo per ℓ (e per L) e quindi stima di massima verosimiglianza, $\hat{\theta}_{mv}(\mathbf{x}_n)$. Per il campione considerato si ha $\hat{\theta}_{mv}(\mathbf{x}_n) = 10/5 = 2$.

c) Si tratta di famiglia esponenziale. Infatti, osservando che

$$f_X(x; \theta) = \frac{1}{1+x} \exp(-\theta \ln(1+x) + \ln \theta),$$

le funzioni di densità per il modello considerato possono essere scritte nella forma generale

$$f_X(x; \theta) = h(x) \exp(\eta(\theta)T(x) - c(\theta)),$$

con

$$h(x) = \frac{1}{1+x}, \quad \eta(\theta) = -\theta, \quad T(x) = \ln(1+x), \quad c(\theta) = -\ln \theta.$$

Esercizio 3. Si suppone che la durata di funzionamento (X , in decine ore) di una popolazione di macchinari prodotti da una fabbrica sia una v.a. di Weibull con funzione di densità

$$f_X(x; \theta) = 2 \theta x e^{-\theta x^2}, \quad x \geq 0, \quad \theta > 0.$$

In un esperimento si è riscontrato che, per $n = 100$ pezzi esaminati, la somma del quadrato dei tempi di durata è pari a 25.5 (decine di ore). Sulla base del campione osservato,

- a) Determinare la stima di massima verosimiglianza di θ .
- b) Determinare una stima per intervallo per θ , utilizzando l'insieme di verosimiglianza approssimato di livello $q = 0.147$.

Svolgimento.

a)

$$f_n(\mathbf{x}_n; \theta) = 2^n \theta^n \left(\prod_{i=1}^n x_i \right) e^{-\theta \sum_{i=1}^n x_i^2}; \quad \ell(\theta; \mathbf{x}_n) = \ln L(\theta; \mathbf{x}_n) \propto n \ln \theta - \theta \sum_{i=1}^n x_i^2.$$

Pertanto

$$\frac{d}{d\theta} \ell(\theta; \mathbf{x}_n) = 0 \quad \Leftrightarrow \quad \frac{n}{\theta} - \sum_{i=1}^n x_i^2 = 0 \quad \Leftrightarrow \quad \theta = \frac{n}{\sum_{i=1}^n x_i^2}.$$

Poichè la derivata seconda di $\ell(\theta; \mathbf{x}_n)$ è $-n/\theta^2$, ovvero sempre negativa, la radice trovata è punto di massimo per ℓ (e per L) e quindi stima di massima verosimiglianza, $\hat{\theta}_{mv}(\mathbf{x}_n)$. Per il campione osservato si ha: $\hat{\theta}_{mv}(\mathbf{x}_n) = 100/25.5 = 3.92$.

b) Intervallo di verosimiglianza approssimato di livello q è:

$$\hat{\theta}_{mv}(\mathbf{x}_n) \pm K \times \sqrt{1/I_n^{oss}},$$

dove

$$k = \sqrt{-2 \ln q} = 1.96, \quad I_n^{oss} = -\frac{d}{d\theta} \ln L(\theta; \mathbf{x}_n) \Big|_{\theta=\hat{\theta}_{mv}(\mathbf{x}_n)} = \frac{n}{[\hat{\theta}_{mv}(\mathbf{x}_n)]^2} = \frac{(\sum_{i=1}^n x_i^2)^2}{n} = 6.05.$$

Si ha quindi che l'intervallo richiesto è: (3.16, 4.68).