



Inferência e Decisão I (LMAC)

2003/04

2^o Teste

26 de Novembro de 2003

LMAC

Resolução do teste

Exercício .1 Considere uma amostra aleatória de vectores bidimensionais $X_i = (Y_i, Z_i)$, nas condições enunciadas, com $\{Y_i, i = 1, \dots, n\} \sim_{i.i.d.} Y \sim Bin(m, p)$ e $\{Z_i, i = 1, \dots, n\} \sim_{i.i.d.} Z \sim Geo(p)$.

- (a) Seja $\underline{x} = ((y_1, z_1), \dots, (y_n, z_n))$ uma amostra de $X = (Y, Z)$ de dimensão n , com $(y_i, z_i) \in \{0, \dots, m\} \times \mathbb{N}$, $\forall i = 1, \dots, n$. Considere-se $L(p|\underline{x})$ a função de verosimilhança definida para $p \in (0, 1)$. Então

$$\begin{aligned}
 L(p|\underline{x}) &= \prod_{i=1}^n P(Y_i = y_i, Z_i = z_i|p) \\
 &= \prod_{i=1}^n P(Y_i = y_i|p)P(Z_i = z_i|p) \quad Y_i \text{ e } Z_i \text{ são independentes} \\
 &= \prod_{i=1}^n \left[\binom{m}{y_i} p^{y_i} (1-p)^{m-y_i} (1-p)^{z_i-1} p \right] \\
 &= \left[\prod_{i=1}^n \binom{m}{y_i} \right] p^{\sum_{i=1}^n (y_i+1)} (1-p)^{\sum_{i=1}^n (z_i-y_i+m-1)} \\
 \ln L(p|\underline{x}) &= \ln \left[\prod_{i=1}^n \binom{m}{y_i} \right] + \sum_{i=1}^n (y_i+1) \ln p + \sum_{i=1}^n (z_i-y_i+m-1) \ln(1-p) \\
 \frac{d \ln L(p|\underline{x})}{dp} &= \frac{\sum_{i=1}^n (y_i+1)}{p} - \frac{\sum_{i=1}^n (z_i-y_i+m-1)}{1-p} \\
 \frac{d^2 \ln L(p|\underline{x})}{dp^2} &= -\frac{\sum_{i=1}^n (y_i+1)}{p^2} - \frac{\sum_{i=1}^n (z_i-y_i+m-1)}{(1-p)^2} \\
 &= -n \left[\frac{\bar{y}+1}{p^2} + \frac{(\bar{z}-1) + (m-\bar{y})}{(1-p)^2} \right] < 0
 \end{aligned}$$

$\forall p \in (0, 1), \bar{z} \in [1, \infty), \bar{y} \in [0, m], m \in \mathbb{N}$, pelo que uma estimativa de máxima verosimilhança para esta amostra é o ponto onde a primeira derivada se anula, i.e., $emv(p) = \hat{p}(\underline{x})$ é raiz da equação $\left. \frac{\sum_{i=1}^n (y_i+1)}{p} - \frac{\sum_{i=1}^n (z_i-y_i+m-1)}{1-p} \right|_{p=\hat{p}(\underline{x})} = 0$, i.e.,

$$\hat{p}(\underline{x}) = \frac{1 + \bar{y}}{\bar{z} + m}$$

donde

$$EMV(p) = \hat{p}(\underline{X}) = \frac{1 + \bar{Y}}{m + \bar{Z}}$$

(b) Seja então

$$W_n = \frac{1 + \bar{Y}_n}{m + \bar{Z}_n}$$

onde \bar{Y}_n (\bar{Z}_n) designa a média amostral de \underline{Y} (\underline{Z}) com base numa amostra de dimensão n . Para provar que a sucessão $\{W_n, n \in \mathbb{N}\}$ é uma sucessão de estimadores consistente de p temos de provar que

$$W_n \rightarrow_P p$$

i.e., temos de provar que a v.a. W_n converge em probabilidade para p . Da lei fraca dos grandes números resulta que $\bar{Y}_n \xrightarrow{P} E[\text{Binomial}(m, p)|p] = mp$ e que, pelo mesmo argumento, $\bar{Z}_n \xrightarrow{P} E[\text{Geo}(p)|p] = \frac{1}{p}$. Decorre da convergência em probabilidades que

$$\begin{aligned} (i) \quad & \bar{Y}_n \xrightarrow{P} mp \Rightarrow 1 + \bar{Y}_n \xrightarrow{P} 1 + mp \\ (ii) \quad & \bar{Z}_n \xrightarrow{P} \frac{1}{p} \Rightarrow m + \bar{Z}_n \xrightarrow{P} m + \frac{1}{p} \neq 0 \\ (i) + (ii) \quad & \Rightarrow \frac{1 + \bar{Y}_n}{m + \bar{Z}_n} \xrightarrow{P} \frac{1 + mp}{m + \frac{1}{p}} = p \end{aligned}$$

o que prova o resultado.

(c) Seja $X = (Y, Z)$. Note-se que a f.d.p. conjunta de Y e Z , dado que as v.a. são independentes, é o produto das funções densidade de probabilidade de cada uma delas. Uma vez que o parâmetro m é conhecido (ou assume-se que é) então cada uma destas f.d.p. pertence à família exponencial pelo que a f.d.p. conjunta satisfaz as condições de regularidade necessárias para que $E \left[\left(\frac{\delta}{\delta p} \ln f(X|p)|p \right)^2 \right] = -E \left[\frac{\delta^2}{\delta p^2} \ln f(X|p)|p \right]$. Seja $x = (y, z) \in \{0, \dots, m\} \times \mathbb{N}$. Note-se que

$$\begin{aligned} f(x|p) &= \binom{m}{y} p^y (1-p)^{(m-y)} (1-p)^{z-1} p \\ \ln f(x|p) &= \ln \binom{m}{y} + y \ln p + (m-y) \ln(1-p) + (z-1) \ln(1-p) + \ln p \\ \frac{\delta}{\delta p} \ln f(x|p) &= \frac{y+1}{p} - \frac{z-1+m-y}{1-p} \\ \frac{\delta^2}{\delta p^2} \ln f(x|p) &= -\frac{y+1}{p^2} - \frac{z-1+m-y}{(1-p)^2} \end{aligned}$$

Logo

$$\begin{aligned} -E \left[\frac{\delta^2}{\delta p^2} \ln f(X|p) \middle| p \right] &= E \left[\frac{Y+1}{p^2} + \frac{Z-1+m-Y}{(1-p)^2} \middle| p \right] \\ &= \frac{mp+1}{p^2} + \frac{\frac{1}{p}-1+m-mp}{(1-p)^2} \\ &= \frac{m}{p(1-p)} - \frac{1}{p^2(1-p)} \end{aligned}$$

Logo o limite inferior da desigualdade de Frechet-Cramér-Rao para a variância de um estimador centrado de p , $T_n(\underline{X})$, baseada numa amostra aleatória $\underline{X} = ((Y_1, Z_1), \dots, (Y_n, Z_n))$ de dimensão n é dado por

$$\begin{aligned} \text{Var}(T_n(\underline{X})|p) &\geq \frac{1}{n \left(\frac{m}{p(1-p)} - \frac{1}{p^2(1-p)} \right)} \\ &\geq \frac{p^2(1-p)}{n(mp-1)} \end{aligned}$$

- (d) *Suponhamos* então que $W_n = \frac{1+\bar{Y}_n}{m+\bar{Z}_n}$ é um estimador centrado. Note-se que $f_{Bin(m,p),Geo(p)}(\cdot|p)$ pertence à família exponencial (com m conhecido) uma vez que

$$\begin{aligned} f_{Bin(m,p),Geo(p)}((y, z)|p) &= \binom{m}{y} p^y (1-p)^{m-y} p(1-p)^{z-1} \\ &= \binom{m}{y} p(1-p)^{m-1} e^{y \ln p + (z-y) \ln(1-p)} \end{aligned}$$

pelo que recorrendo à definição de família exponencial vem

$$\begin{aligned} h(y, z) &= \binom{m}{y} > 0, \quad c(p) = p(1-p)^{m-1} \geq 0, \quad k = 2 \\ w_1(p) &= \ln p, \quad t_1(y, z) = y, \quad w_2(p) = \ln(1-p), \quad t_2(y, z) = (z-y) \end{aligned}$$

Do critério da factorização decorre que a estatística

$$T(\underline{X}) = T((Y_1, Z_1), \dots, (Y_n, Z_n)) = (\bar{Y}, \bar{Z})$$

é uma estatística suficiente. Além disso é completa uma vez que para qualquer função g da estatística T tal que $E[g(T)|p] = 0$ tem-se que

$$0 = E[g(T)|p] = \sum_{y=0}^{nm} \sum_{z=n}^{\infty} g\left(T\left(\frac{y}{n}, \frac{z}{n}\right)\right) \binom{nm}{y} p^y (1-p)^{nm-y} \binom{z-1}{z-n} p^n (1-p)^{z-n}$$

uma vez que a soma de n $Bin(m, p)$ independentes é ainda uma $Bin(nm, p)$ e a soma de n $Geo(p)$ independentes é uma $BN(n, p)$. Note-se que a expressão anterior é uma série pelo que para que esta seja nula para todos os valores de p então os seus coeficientes terão de ser nulos, o que implica que $g\left(T\left(\frac{y}{n}, \frac{z}{n}\right)\right) = 0, \forall y \in \{0, \dots, nm\}, z \in \{n, \dots, \infty\}$, i.e., $g(T) = 0$ em todos os pontos com probabilidade diferente de zero, pelo que $g(T) = 0$ com probabilidade 1.

Temos então que W_n é função de uma estatística suficiente completa. Como por hipótese é um estimador centrado de p , então decorre do teorema de Rao-Blackwell que se trata de um estimador de variância mínima.

- (e) Invocando o teorema das probabilidades totais temos:

$$\begin{aligned} P(Y > Z|p) &= \sum_{z=1}^{\infty} P(Y > z|p)P(Z = z|p) \\ &= \sum_{z=1}^m (1 - F_{Bin(m,p)}(z))p(1-p)^{z-1} \end{aligned}$$

Decorre então do princípio da invariância dos estimadores de máxima verosimilhança que $EMV(P(Y > Z|p)) = P(Y > Z|EMV(p))$, i.e.

$$EMV(P(Y > Z|p)) = \sum_{z=1}^m (1 - F_{Bin(m, \frac{1+\bar{Y}_n}{m+\bar{Z}_n})}(z)) \frac{1+\bar{Y}_n}{m+\bar{Z}_n} \left(1 - \frac{1+\bar{Y}_n}{m+\bar{Z}_n}\right)^{z-1}$$

Exercício .2 Seja \underline{X} uma amostra aleatória de dimensão n , proveniente de uma população $N(\theta, \theta^2)$.

1. Seja $\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$ e $S_{n-1} = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}}$ dois estimadores de θ . Vejamos se se trata de dois estimadores centrados de θ , com $\theta > 0$.

$$\begin{aligned} E[\bar{X}|\theta] &= E\left[\frac{\sum_{i=1}^n X_i}{n}|\theta\right] \\ &= \frac{1}{n} \sum_{i=1}^n E[X_i|\theta] \\ &= \frac{1}{n} \sum_{i=1}^n \theta \quad X_i's \text{ são v.a. i.i.d.} \\ &= \theta \end{aligned}$$

pelo que \bar{X} é efectivamente um estimador centrado de θ .

Sabe-se que $V = \frac{(n-1)S_{n-1}^2}{\theta^2} \sim \chi_{n-1}^2$, pelo que

$$f_{\frac{(n-1)S_{n-1}^2}{\theta^2}}(s) = f_V(s) = \frac{s^{\frac{n-1}{2}-1} e^{-s/2}}{2^{(n-1)/2} \Gamma(\frac{n-1}{2})} I_{\mathbb{R}^+}(s)$$

Então

$$\begin{aligned} E\left[\frac{\sqrt{n-1}S_{n-1}}{\theta}|\theta\right] &= \int_0^\infty s^{\frac{1}{2}} f_V(s) ds \\ &= \int_0^\infty s^{\frac{1}{2}} \frac{s^{\frac{n-1}{2}-1} e^{-s/2}}{2^{(n-1)/2} \Gamma(\frac{n-1}{2})} ds \\ &= \int_0^\infty \frac{s^{\frac{n}{2}-1} e^{-s/2}}{2^{(n-1)/2} \Gamma(\frac{n-1}{2})} ds \\ &= \frac{2^{n/2} \Gamma(\frac{n}{2})}{2^{(n-1)/2} \Gamma(\frac{n-1}{2})} \int_0^\infty \frac{s^{\frac{n}{2}-1} e^{-s/2}}{2^{n/2} \Gamma(\frac{n}{2})} ds \\ &= \frac{\sqrt{2} \Gamma(\frac{n}{2})}{\Gamma(\frac{n-1}{2})} \end{aligned}$$

pelo que

$$E[S_{n-1}|\theta] = \frac{\theta}{\sqrt{n-1}} \frac{\sqrt{2} \Gamma(\frac{n}{2})}{\Gamma(\frac{n-1}{2})}$$

donde resulta que cS_{n-1} , com c dado no enunciado, é efectivamente um estimador centrado de θ .

2. Dado que a f.d.p. normal obedece às condições de regularidade de Frechet-Cramér-Rao, e como por hipótese $W(\underline{X}) = W(\bar{X}, S_{n-1})$ é um estimador centrado, então o limite inferior da desigualdade de Frechet-Cramér-Rao é atingido se e só se existir alguma função $\alpha(\theta)$ tal que

$$\alpha(\theta)[W(\underline{x}) - \tau(\theta)] = \frac{\delta}{\delta\theta} \ln L(\theta|\underline{x})$$

para qualquer amostra \underline{x} de X .

Note-se que

$$\begin{aligned} L(\theta|\underline{x}) &= \prod_{i=1}^n \left(\frac{1}{\theta\sqrt{2\pi}} e^{-\frac{(x_i-\theta)^2}{2\theta^2}} \right) \\ &= \left(\frac{1}{\theta\sqrt{2\pi}} \right)^n e^{-\sum_{i=1}^n \frac{(x_i-\theta)^2}{2\theta^2}} \\ &= \left(\frac{1}{\theta\sqrt{2\pi}} \right)^n e^{-\frac{\sum_{i=1}^n x_i^2 + n\theta^2 - 2\theta n\bar{x}}{2\theta^2}} \\ \ln L(\theta|\underline{x}) &= -n \ln \theta\sqrt{2\pi} - \frac{\sum_{i=1}^n x_i^2}{2\theta^2} - \frac{n}{2} + \frac{n\bar{x}}{\theta} \\ \frac{\delta}{\delta\theta} \ln L(\theta|\underline{x}) &= -\frac{n}{\theta} + \frac{\sum_{i=1}^n x_i^2}{2\theta^3} - \frac{n\bar{x}}{\theta^2} \end{aligned}$$

Logo se existir um estimador que atinja o limite inferior de Frechet-Cramér-Rao teremos a seguinte decomposição:

$$\alpha(\theta) [W(\underline{x}) - \theta] = -\frac{n}{\theta} + \frac{\sum_{i=1}^n x_i^2}{2\theta^3} - \frac{n\bar{x}}{\theta^2}$$

Porém como $\frac{\delta}{\delta\theta} \ln L(\theta|\underline{x})$ depende de θ através de θ^2 e θ^3 , não é possível decompor da forma pretendida, pelo que não existe nenhum estimador centrado de θ para o qual o limite de FCR seja atingido.

3. Considere-se então a v.a. $X \sim N(\theta, \theta^2)$. Note-se que

$$\begin{aligned} f_X(x - \theta) &= \frac{1}{\theta\sqrt{2\pi}} e^{-\frac{x^2}{2\theta^2}} = g_1(\theta) \quad \Rightarrow \theta \text{ não é parâmetro de localização} \\ \theta f_X(x\theta) &= \theta \frac{1}{\theta\sqrt{2\pi}} e^{-\frac{(\theta x - \theta)^2}{2\theta^2}} = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-1)^2}{2}} \quad \Rightarrow \theta \text{ é parâmetro de escala} \end{aligned}$$

4. Seja Y_i o valor inteiro mais próximo de X_i , e \underline{Y} uma amostra aleatória de Y , de dimensão n . Sem perda de generalidade assumimos que caso $x_i = *.5$ então $y_i = * + 1$. A função de verosimilhança correspondente a uma amostra \underline{y} de dimensão n , com $y_i \in \mathbb{Z}, \forall i = 1, \dots, n$, é dada por

$$\begin{aligned} L(\theta|\underline{y}) &= \prod_{i=1}^n P(y_i - 0.5 \leq X_i < y_i + 0.5|\theta) \\ &= \prod_{i=1}^n \left[\Phi\left(\frac{y_i + 0.5 - \theta}{\theta}\right) - \Phi\left(\frac{y_i - 0.5 - \theta}{\theta}\right) \right] \\ \ln L(\theta|\underline{y}) &= \sum_{i=1}^n \ln \left(\Phi\left(\frac{y_i + 0.5 - \theta}{\theta}\right) - \Phi\left(\frac{y_i - 0.5 - \theta}{\theta}\right) \right) \end{aligned}$$

Exercício .3 Considere-se a família $\mathcal{F} = (x|\theta) = \left(\frac{\theta}{2}\right)^{|x|} (1-\theta)^{1-|x|} I_{\{-1,0,1\}}(x), \theta \in (0, 1)$ e seja $x \in \{-1, 0, 1\}$ uma observação proveniente deste modelo.

1. Para $\theta \in (0, 1)$ e $x \in \{-1, 0, 1\}$:

$$\begin{aligned}
 L(\theta|x) &= \left(\frac{\theta}{2}\right)^{|x|} (1-\theta)^{1-|x|} \\
 \ln L(\theta|x) &= |x|(\ln \theta - \ln 2) + (1-|x|)\ln(1-\theta) \\
 \frac{d \ln L(\theta|x)}{d\theta} &= \frac{|x|}{\theta} - \frac{1-|x|}{1-\theta} \\
 \frac{d^2 \ln L(\theta|x)}{d\theta^2} &= -\frac{|x|}{\theta^2} - \frac{1-|x|}{(1-\theta)^2} < 0, \quad \forall x \in \{-1, 0, 1\}, \theta \in (0, 1)
 \end{aligned}$$

pele que a estimativa de máxima verosimilhança calculada com base numa observação x é o zero da primeira derivada, i.e.,

$$\begin{aligned}
 \left. \frac{d \ln L(\theta|x)}{d\theta} \right|_{\theta=\hat{\theta}(x)} &= 0 \\
 &\iff \\
 \frac{|x|}{\hat{\theta}(x)} - \frac{1-|x|}{1-\hat{\theta}(x)} &= 0 \\
 &\iff \\
 \hat{\theta}(x) &= |x|
 \end{aligned}$$

pele que o estimador de máxima verosimilhança baseado numa observação (aleatória) X é dado por

$$EMV(\theta) = \hat{\theta}(X) = |X|$$

Quanto aos estimador dos momentos, atendendo a que $E[X|\theta] = 0, \forall \theta \in (0, 1)$ (a f.d.p. é simétrica em torno do ponto zero), decorre que o estimador dos momentos de θ é dado por

$$EM(\theta) = \sqrt{EM(E[X^2|\theta])} = \sqrt{X^2} = |X|$$

pele que nesta situação o EMV e o EM do parâmetro coincidem.

2. Considere-se:

$$T(X) = 2I_{\{1\}}(X)$$

Trata-se efectivamente de uma estatística mas de acordo com a nossa definição não é um estimador, pois toma valores que não pertencem ao espaço paramétrico. Note-se que

$$E[T(X)|\theta] = 2P(X = 1|\theta) = 2\left(\frac{\theta}{2}\right) = \theta, \quad \forall \theta \in (0, 1)$$

3. Na alínea anterior deduzimos que, com base numa observação, $|X|$ é o estimador de máxima verosimilhança. Vejamos se este estimador é centrado.

$$\begin{aligned}
 E[|X||\theta] &= P(X = 1|\theta) + P(X = -1|\theta) \\
 &= \frac{\theta}{2} + \frac{\theta}{2} \\
 &= \theta
 \end{aligned}$$

pele que $|X|$ é efectivamente um estimador centrado. Além disso é função da estatística suficiente completa, pelo que do teorema de Karlin-Rubin decorre que

$|X|$ é o estimador UMVUE pelo que, em particular, é melhor que $T(X)$, uma vez que sendo estimador função de uma estatística suficiente completa ele é único a menos de um conjunto de medida nula (note-se que $T(X) \neq |X|$ com probabilidade $1 - P(X = 0|\theta) \neq 0$).