



# IND 1115

## Inferência Estatística

### Aula 11

Novembro 2004

Mônica Barros

monica@mbarros.com

1



## Conteúdo

- ❑ Método dos Momentos
- ❑ Medidas da Qualidade dos Estimadores
- ❑ Informação de Fisher
- ❑ Limite Inferior de Cramér e Rao

monica@mbarros.com

2

## Método dos Momentos



- ❑ É uma alternativa ao método de máxima verossimilhança para encontrar estimadores de maneira simples.
- ❑ **Idéia Geral**
- ❑ Igualar os momentos da distribuição aos momentos da amostra. Isso é razoável pois a distribuição empírica converge estocasticamente para a função de distribuição  $F(X)$ .

monica@mbarros.com

3

## Método dos Momentos



- ❑ Considere uma amostra aleatória da distribuição com densidade  $f(x, \theta_1, \theta_2, \dots, \theta_p)$  onde  $(\theta_1, \theta_2, \dots, \theta_p) \in \Omega$ .
- ❑ Seja  $E(X^k)$  o  $k$ -ésimo momento da distribuição ( $k = 1, 2, \dots$ ).
- ❑ Seja  $M_k = \frac{1}{n} \sum_{i=1}^n X_i^k$  o  $k$ -ésimo momento amostral
- ❑ Faça  $E(X^k) = M_k$  para  $k = 1, 2, \dots$
- ❑ Faça isto para quantos  $k$ 's forem necessários até obter soluções únicas para os parâmetros desconhecidos

monica@mbarros.com

4

## Método dos Momentos



- Nota
- Uma formulação equivalente do método dos momentos usa os momentos centrais, igualando os momentos centrais da distribuição e da amostra até obter soluções únicas para todos os parâmetros desconhecidos.
- Ou seja, a outra formulação do método dos momentos é igualar:

$$E(X - \mu)^k = m_k = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^k \text{ para } k = 1, 2, \dots$$

- Até encontrar uma solução única. Muitas vezes a resposta pelas duas formulações será igual.

## Método dos Momentos



- Na maneira dos casos práticos, os estimadores pelo método dos momentos são consistentes.
- O grande problema com este método é que ele não fornece estimadores únicos para um certo parâmetro.
- Por exemplo, se procuramos estimar a média e variância de uma distribuição é possível encontrar estimadores diferentes pelo método de momentos dependendo de quais momentos amostrais são igualados aos momentos da distribuição.

## Medidas da Qualidade dos Estimadores



- Já estudamos dois métodos para encontrar estimadores de um parâmetro desconhecido, o método da máxima verossimilhança e o método dos momentos.
- Estes são os métodos mais comuns para encontrar estimadores.
- Nosso objetivo agora é desenvolver alguns critérios para saber se um dado estimador é "bom" ou "ruim" segundo estes critérios.

## Medidas da Qualidade dos Estimadores



- Na seção anterior definimos estimadores não tendenciosos e consistentes, e comentamos que muitas vezes o MLE é um estimador consistente.
- Também definimos o erro quadrático médio, e veremos que esta quantidade pode ser usada como critério para dizer se um estimador qualquer é "bom" ou "ruim".
- Seja  $T = T(X_1, X_2, \dots, X_n)$  um estimador de  $\tau(\theta)$  onde  $\tau(\theta)$  é uma função qualquer de um parâmetro de interesse  $\theta$ .

## Medidas da Qualidade dos Estimadores



- ❑ **Como comparar um número potencialmente infinito de estimadores tendenciosos e não tendenciosos?**
- ❑ **A comparação entre estimadores será geralmente feita dentro de uma mesma "classe", por exemplo, tentaremos comparar estimadores não tendenciosos, já que o fato de um estimador ser não tendencioso é uma propriedade desejável.**

## Medidas da Qualidade dos Estimadores



- ❑ **A seguir definimos o nosso estimador "ideal". A definição, no entanto, não garante a existência deste estimador.**
- ❑ **Este estimador será chamado de UMVUE (Uniformly Minimum Variance Unbiased Estimator, ou Estimador não tendencioso de variância mínima ou melhor estimador não tendencioso).**

## Medidas da Qualidade dos Estimadores



- ❑ **Um estimador  $T^*$  é o UMVUE, ou *melhor estimador não tendencioso* para  $\tau(\theta)$  se:**
  - ❑ i)  $T^*$  é não tendencioso para  $\tau(\theta)$ .
  - ❑ ii)  $\text{VAR}(T^*) \leq \text{VAR}(T)$  para qualquer outro estimador não tendencioso  $T$  de  $\tau(\theta)$ .
- ❑ **Ou seja, o melhor estimador não tendencioso é o "melhor" no sentido de possuir a menor variância dentre os estimadores não tendenciosos.**

## Medidas da Qualidade dos Estimadores



- ❑ **Note que o critério apresentado é equivalente à minimização do erro quadrático médio para estimadores não tendenciosos, pois o erro quadrático médio de um estimador não tendencioso é a variância deste estimador.**

## Medidas da Qualidade dos Estimadores



### Exemplo 1

- Seja  $T$  a duração de um componente eletrônico até sua primeira falha. Suponha que  $T$  tem distribuição exponencial com média  $1/\beta$ , ou seja, sua densidade é:

$$f(t) = \beta \cdot e^{-\beta \cdot t} \text{ para } t > 0 \text{ e } \beta > 0.$$

- Encontre um estimador não tendencioso da média de  $T$  a partir de uma amostra aleatória de tamanho  $n$ .

## Exemplo 1



- Mostre que os estimadores  $\bar{T} = \frac{1}{n} \sum_{i=1}^n T_i$  e  $T^* = nZ$  onde  $Z = \min(T_1, T_2, \dots, T_n)$  são não tendenciosos para a média de  $T$ ,  $1/\beta$ , e compare as variâncias destes estimadores.

### Solução

- $\bar{T}$  é claramente não tendencioso, pois:

$$E(\bar{T}) = \frac{1}{n} \sum_{i=1}^n E(T_i) = \frac{1}{n} \sum_{i=1}^n (1/\beta) = 1/\beta$$

- Precisamos descobrir qual a distribuição de  $Z$  para podermos calcular sua média e variância.

## Exemplo 1



$$\Pr[Z \leq z] = 1 - \Pr[Z > z] = 1 - \Pr[\min(T_1, T_2, \dots, T_n) \geq z] = 1 - \{\Pr[T_1 \geq z]\}^n$$

- pois os  $T_i$ 's são independentes e identicamente distribuídos com densidade Exponencial de média  $1/\beta$ . Mas,

$$\Pr[T > z] = \int_z^{\infty} \beta e^{-\beta t} dt = \beta \frac{e^{-\beta t}}{-\beta} \Big|_z^{\infty} = e^{-\beta \cdot z}$$

- Assim:

$$\Pr[Z \leq z] = 1 - \{\Pr[T_1 \geq z]\}^n = 1 - e^{-\beta \cdot z \cdot n}$$

- Mas, esta é a função de distribuição de uma variável aleatória Exponencial com média  $1/n\beta$ . Ou seja, a densidade de  $Z = \min(T_1, T_2, \dots, T_n)$  é:

## Exemplo 1



$$g(z) = \frac{1}{\beta n} e^{-n/\beta z}, \beta > 0, z > 0$$

- E portanto a média e variância de  $Z$  são, respectivamente,  $1/n\beta$  e  $1/(n\beta)^2$ .

- Daí:  $E(T^*) = E(nZ) = nE(Z) = \frac{1}{\beta} = E(T)$

e  $T^*$  também é não tendencioso para  $E(T)$ .

- A comparação das variâncias dos estimadores nos dá:

## Exemplo 1



$$\square \text{VAR}(\bar{T}) = \text{VAR}(T_i) / n = 1 / n\beta^2 \text{ e}$$

$$\text{VAR}(T^*) = n^2 \text{VAR}(Z) = 1 / \beta^2 > \text{VAR}(\bar{T})$$

- para todo  $n > 1$ . Assim, é preferível usar a média amostral como estimador, pois sua variância é menor que a de  $T^*$  sempre que a amostra tem tamanho maior que 1.

## Medidas da Qualidade dos Estimadores



### □ Nota

- O fato de  $T$  ser não tendencioso para  $\tau(\theta)$  *não implica* em  $g(T)$  não tendencioso para  $g(\tau(\theta))$  quando  $g(\cdot)$  é uma função *não linear*.
- Às vezes quando procuramos um estimador para  $\tau(\theta)$  encontramos  $T$  tal que  $E(T) = c \cdot \tau(\theta)$  onde  $c$  é uma constante.
- Obviamente então:  $E(T/c) = \tau(\theta)$  e  $T/c$  é um estimador não tendencioso para  $\tau(\theta)$ .
- No entanto, se  $T$  é "quase" não tendencioso para  $\tau(\theta)$ , dividir por  $c$  pode "deteriorar" o erro quadrático médio.

## Medidas da Qualidade dos Estimadores



### □ Exemplo 2

- Sejam  $X_1, X_2, \dots, X_n$  uma amostra da densidade Normal( $\mu, \sigma^2$ ). Considere o MLE para a variância:

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = S^2 = \text{variância amostral}$$

- Já mostramos antes que  $E(S^2) = ((n-1)/n) \sigma^2$  e assim  $S^2$  é tendencioso.

- A tendência ("BIAS") de  $S^2$  é:

$$E(S^2 - \sigma^2) = -\frac{1}{n} \sigma^2$$

## Exemplo 2



- O erro quadrático médio de  $S^2$  é:

$$\begin{aligned} \text{MSE}(S^2) &= \text{VAR}(S^2) + [\text{BIAS}(S^2)]^2 = \\ &= \frac{2(n-1)\sigma^2}{n^2} + \left(-\frac{\sigma^2}{n}\right)^2 = \frac{(2n-1)\sigma^4}{n^2} \end{aligned}$$

- Agora considere o estimador:

$$S^{*2} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{nS^2}{n-1}$$

- Note que  $S^{*2}$  é um estimador **não tendencioso** para a variância da Normal.

## Exemplo 2



- Mas:

$$MSE(S^{*2}) = \text{VAR}(S^{*2}) = \frac{n^2}{(n-1)^2} \text{VAR}(S^2) = \frac{2}{n-1} \sigma^4$$

- que é maior que o MSE de  $S^2$  (estimador tendencioso) para qualquer inteiro positivo  $n$ .
- Assim, embora  $S^{*2}$  seja não tendencioso, se a população é Normal,  $S^{*2}$  é pior que  $S^2$  no sentido de ter maior MSE.

## Informação de Fisher



- Sejam  $X_1, X_2, \dots, X_n$  variáveis aleatórias com verossimilhança  $L(\theta)$  e log-verossimilhança  $\ell(\theta)$ .

- Definição (Função Score)

$$S(X, \theta) = \frac{\partial}{\partial \theta} [\log L(\theta)] = \frac{\partial \ell(\theta)}{\partial \theta}$$

- Por esta definição, vemos que o estimador de máxima verossimilhança é geralmente obtido fazendo-se o score igual a zero.

## Informação de Fisher



- Definição (Informação de Fisher)

A informação de Fisher é definida como:

$$I(\theta) = \text{VAR}[S(X, \theta)]$$

- isto é, a Informação é a variância da função score.
- Veremos depois que a idéia de informação de Fisher corresponde intuitivamente à nossa idéia de “informação” contida numa amostra.

## Exemplo 3



- Sejam  $X_1, X_2, \dots, X_n$  uma amostra aleatória da distribuição Poisson( $\theta$ ).
- Calcule a função score e a informação.
- Solução
- A verossimilhança é:

$$L(\theta) = \prod_{i=1}^n \frac{\theta^{x_i} e^{-\theta}}{x_i!} = \frac{\theta^{\sum x_i} e^{-n\theta}}{\prod_{i=1}^n x_i!}$$

- A log verossimilhança é:

$$\ell(\theta) = \log L(\theta) = \left( \sum_{i=1}^n x_i \right) \log \theta - n\theta - \log \left[ \prod_{i=1}^n x_i! \right]$$

### Exemplo 3



- A função score é:

$$S(\underline{X}, \theta) = \frac{d\ell(\theta)}{d\theta} = \frac{n\bar{X}}{\theta} - n$$

- Note que  $\text{VAR}(X_i) = \theta$  ( $i = 1, 2, \dots, n$ ), e assim  $\text{VAR}(\bar{X}) = \theta/n$ . Logo, a informação de Fisher é:

$$\begin{aligned} I(\theta) &= \text{VAR}(S(\underline{X}, \theta)) = \text{VAR}\left[\frac{n\bar{X}}{\theta} - n\right] = \\ &= \text{VAR}\left(\frac{n\bar{X}}{\theta}\right) = \frac{n^2}{\theta^2} \text{VAR}(\bar{X}) = \frac{n^2}{\theta^2} \left(\frac{\theta}{n}\right) = \frac{n}{\theta} \end{aligned}$$

- Note que a informação é o inverso da variância de  $\bar{X}$

### Informação de Fisher



- De alguma maneira, a informação de Fisher mede a "precisão" da amostra. Quanto maior a variância de  $\bar{X}$ , menor a "precisão" (e menor a informação), e vice-versa.

- A informação de Fisher é um dos elementos fundamentais da Estatística Clássica e Bayesiana.

### Informação de Fisher



- A idéia de que a informação mede a "precisão" de uma amostra é empregada em problemas bem mais complicados que os já vistos aqui.
- É importante notar que a **informação de Fisher depende apenas da distribuição dos dados**, e não de qualquer valor dos X's da amostra. Isto pode ser comprovado algebricamente se notarmos que a informação é a variância do Score, que, por sua vez, é função dos X's e de  $\theta$ . Ao calcularmos esta variância encontramos uma constante que **só depende dos parâmetros da distribuição**.

### Informação de Fisher



- Propriedades do Score e da Informação de Fisher

$$E[S(\underline{X}, \theta)] = 0$$

$$I(\theta) = E\{[S(\underline{X}, \theta)]^2\} = E[-\partial S(\underline{X}, \theta) / \partial \theta] = E[-\partial^2 \ell(\theta) / \partial \theta^2]$$

- Se  $X_1, X_2, \dots, X_n$  é um conjunto de observações independentes (mas não necessariamente identicamente distribuídas) e  $I_i(\theta)$  é a informação em  $X_i$  então:

$$I(\theta) = \sum_{i=1}^n I_i(\theta).$$

## Informação de Fisher



- Ou seja, a informação total contida nos dados é a soma das informações trazidas por cada uma das observações.
- Se, além de independentes, os  $X_i$ 's são identicamente distribuídos, então:  $I(\theta) = n \cdot I_1(\theta)$
- Se os  $X_i$ 's são identicamente distribuídos, todos os  $I_i$ 's são iguais e então a informação contida nas  $n$  observações é  $I(\theta) = n \cdot I_1(\theta)$  onde  $I_1(\theta)$  é a contribuição de  $X_1$  na verossimilhança. Isto é, a informação numa amostra aleatória é a soma das informações de cada elemento da amostra.

## Informação de Fisher



- Este item é de fundamental importância na prática, pois nos fornece duas maneiras de calcular a informação de Fisher.
- A primeira maneira decorre da definição de informação, ou seja, como a variância do Score. A outra maneira envolve o cálculo da segunda derivada da log-verossimilhança, e do valor esperado desta quantidade. É claro que o resultado fornecido deve ser o mesmo, independente da fórmula usada para obter a informação.

## O Limite Inferior de Cramér e Rao



- O próximo teorema (Cramér e Rao) fornece um limite inferior para a variância de qualquer estimador não tendencioso de  $\tau(\theta)$ .
- Este limite é importante, pois nos permite dizer que a variância de qualquer estimador não tendencioso é igual ou superior a este limite.
- Em particular, se  $T$  é um estimador não tendencioso de  $\tau(\theta)$  cuja variância coincide com este limite,  $T$  é o *melhor* estimador não tendencioso possível para  $\tau(\theta)$  pois nenhum outro estimador não tendencioso de  $\tau(\theta)$  poderá ter variância menor que a de  $T$ .

## O Limite Inferior de Cramér e Rao



- O teorema de Cramér e Rao nos fornece o valor mínimo para a variância de um estimador não tendencioso de  $\tau(\theta)$ .
- Logo, se for possível encontrar um estimador não tendencioso de  $\tau(\theta)$  e este tiver a variância indicada no próximo teorema, o estimador encontrado é o UMVUE (melhor estimador não tendencioso) para  $\tau(\theta)$ .

## O Limite Inferior de Cramér e Rao



- Teorema (Desigualdade da informação ou desigualdade de Cramer e Rao)
- Seja T um estimador *não tendencioso* de  $\tau(\theta)$ . Então, sob certas condições de regularidade:

$$VAR(T) \geq \frac{[\tau'(\theta)]^2}{I(\theta)} = \frac{[\tau'(\theta)]^2}{n.E\left\{\left(\frac{\partial \log f(x, \theta)}{\partial \theta}\right)^2\right\}}$$

- e a igualdade ocorre se, e somente se, a verossimilhança tem a forma:

$$L(\theta) = \exp[A(\theta)T(X) + K(\theta) + u(X)]$$

monica@mbarros.com

33

## O Limite Inferior de Cramér e Rao



- Esta desigualdade é conhecida como *Desigualdade de Cramér e Rao*, e o limite inferior para a variância de T é chamado de **limite inferior de Cramér e Rao** (CRLB = Cramér Rao Lower Bound).
- O termo  $(\tau'(\theta))^2 / I(\theta)$  é chamado de *Limite Inferior de Cramer e Rao*. O grande problema com este limite é que, em muitos casos, ele é muito pequeno.
- Exceto em casos "triviais", não é possível encontrar estimadores não tendenciosos cuja variância seja igual ao limite inferior de Cramer e Rao.

monica@mbarros.com

34

## O Limite Inferior de Cramér e Rao



- Definição (Estimador Eficiente)
- T é chamado um *estimador eficiente* de  $\tau(\theta)$  se:
- I) T é não tendencioso para  $\tau(\theta)$ .
- II)  $VAR[T(x)] = [\tau'(\theta)]^2 / I(\theta)$   
isto é, o estimador T atinge o limite inferior de Cramér e Rao.
- Corolário
- Se é um estimador eficiente de  $\tau(\theta)$  então é o melhor estimador não tendencioso de  $\tau(\theta)$ .

monica@mbarros.com

35

## O Limite Inferior de Cramér e Rao



- Exemplo 4
- Sejam  $X_1, X_2, \dots, X_n \stackrel{iid}{\sim} N(0, \theta)$
- Encontre o MLE de  $\theta$ . Calcule o score e a informação de Fisher e mostre que o MLE é um estimador eficiente de  $\theta$ .
- Solução
- Note que  $\theta$ , a variância de distribuição, é o único parâmetro desconhecido aqui.
- A verossimilhança é:

$$L(\theta) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\theta}} \exp\left\{-\frac{1}{2\theta} (x_i^2)\right\} = (2\pi\theta)^{-n/2} \exp\left\{-\frac{1}{2\theta} \sum_{i=1}^n x_i^2\right\}$$

monica@mbarros.com

36

## Exemplo 4



□ A log-verossimilhança é:  $\ell(\theta) = -\frac{n}{2} \log(2\pi\theta) - \frac{\sum x_i^2}{2\theta}$

□ O Score é:

$$S(x, \theta) = \frac{d\ell(\theta)}{d\theta} = -\frac{n}{2} \frac{(2\pi)}{2\pi\theta} - \frac{\sum x_i^2}{2} \left(-\frac{1}{\theta^2}\right)$$

□ O estimador de máxima verossimilhança de  $\theta$  é encontrado fazendo-se o Score igual a zero. Daí:

$$\frac{d\ell}{d\theta} = 0 \Leftrightarrow \frac{\sum x_i^2}{\theta} = n \Leftrightarrow \hat{\theta} = \frac{1}{n} \sum_{i=1}^n x_i^2 = MLE \text{ para } \theta$$

□ A informação de Fisher é:

## Exemplo 4



$$I(\theta) = E\left[-\frac{d^2\ell(\theta)}{d\theta^2}\right] = -E\left[\frac{d}{d\theta}\left\{\frac{\sum x_i^2}{2\theta^2} - \frac{n}{2\theta}\right\}\right]$$

$$= -E\left[\frac{\sum x_i^2}{2}\left(-\frac{2}{\theta^2}\right) - \frac{n}{2}\left(-\frac{1}{\theta^2}\right)\right] = E\left\{\frac{\sum x_i^2}{\theta^2} - \frac{n}{2\theta^2}\right\}$$

$$= \frac{1}{\theta^2} \sum_{i=1}^n E(x_i^2) - \frac{n}{2\theta^2} = \frac{1}{\theta^3} \sum_{i=1}^n \theta - \frac{n}{2\theta^2} = \frac{n}{\theta^2} - \frac{n}{2\theta^2}$$

$$\frac{2n}{2\theta^2} - \frac{n}{2\theta^2} \Rightarrow I(\theta) = \frac{n}{2\theta^2}$$

## Exemplo 4



□ O limite inferior de Cramér e Rao para um estimador de  $\theta$  é:  $1/I(\theta) = 2\theta^2/n$ .

□ Logo, se um estimador não tendencioso de  $\theta$  tem como variância este valor, este estimador é eficiente e é o melhor estimador não tendencioso de  $\theta$ .

□ Considere o estimador de máxima verossimilhança. Para provar que ele é eficiente, precisamos verificar se ele é não tendencioso e que sua variância é  $1/I(\theta) = 2\theta^2/n$ .

## Exemplo 4



□ Mas, o MLE de  $\theta$  é:  $\hat{\theta} = \sum x_i^2 / n$

$$E(\hat{\theta}) = E\left(\frac{1}{n} \sum x_i^2\right) = \frac{1}{n} \sum_{i=1}^n E(x_i^2) = \frac{1}{n} \sum_{i=1}^n \theta = \frac{n\theta}{n} = \theta$$

□ e então o MLE é não tendencioso para  $\theta$ .

$$VAR(\hat{\theta}) = VAR\left[\frac{1}{n} \sum x_i^2\right] = \frac{1}{n^2} \sum_{i=1}^n VAR(x_i^2) = \frac{1}{n^2} \sum_{i=1}^n 2\theta^2$$

$$= \frac{2n\theta^2}{n^2} = \frac{2\theta^2}{n} = \frac{1}{I(\theta)}, \text{ ou seja, } \hat{\theta} \text{ é eficiente.}$$