

## ML E TESTES WALD, LM E RAZÃO DE ML

Prof. Denisard Alves

### 1. Princípio da Maximaverossimilhança (MV)

Já discutimos em aulas anteriores o princípio da maximaverossimilhança-MV. Agora vamos dar um tratamento mais completo.

Nos anos recentes tem sido comum o uso de testes com base nos enfoques de Wald e do multiplicador de Lagrange. São testes baseados no enfoque de MV.

Suponha um vetor de observações:

$y' = [y_1, y_2, \dots, y_n]$  de  $n$  observações amostrais dependentes de  $k+1$  parâmetros desconhecido  $\theta' = [\theta_0, \theta_1, \dots, \theta_k]$ . Vamos definir a função de densidade conjunta das observações da amostra como  $f(y; \theta)$ , que indica a dependência de  $\theta$ . Essa densidade pode ser interpretada de duas formas diferentes. Para um dado  $\theta$ , ela representa a probabilidade do conjunto de valores amostrais de  $y$  ser obtido. Alternativamente ela pode ser interpretada como dado o conjunto de valores da amostra qual a probabilidade da amostra ter sido gerada para valores diferentes de  $\theta$ . Nesta última interpretação ela é chamada de função de verossimilhança, ou seja,

$$\text{Função de verossimilhança} = L(\theta; y) = f(y; \theta)$$

É usual reverter símbolos da função de verossimilhança para enfatizar que o que está variando, está definindo a probabilidade dos valores da amostra, agora é o vetor de parâmetros  $\theta$ . Maximizar a função de verossimilhança com respeito a  $\theta$ , significa encontrar o conjunto de valores para  $\theta$  que maximiza a probabilidade de se obter os valores observados da amostra. Então  $\hat{\theta}$ , o vetor de parâmetros estimados que maximiza essa probabilidade ou a verossimilhança é chamado de Estimador de Maximaverossimilhança (MLE)<sup>1</sup>. Em geral, é mais simples maximizar logaritmo da função de verossimilhança, ou seja:

$$l = \ln L(\theta; y)$$

Logo,

$$\frac{\partial l}{\partial \theta} = \frac{1}{L} \frac{\partial L}{\partial \theta} \text{ e o } \hat{\theta}, \text{ que maximiza } l \text{ também maximiza } L.$$

As condições de primeira ordem de máximo, derivadas de  $l$  com relação a  $\theta$ , que chama-se por  $s(\theta; y)$ , também é chamada de *score function*, quando igualadas a zero fornecem as  $k+1$  equações necessárias para se encontrar o vetor dos  $k+1$  parâmetros estimados  $\hat{\theta}$ , que maximizam a verossimilhança, ou seja  $\hat{\theta}$  é obtido pela solução das CPO:

---

<sup>1</sup> MLE do inglês Maximum Likelihood Estimator

$$s(\theta; y) = \frac{\partial l}{\partial \theta}$$

O uso do MLE é devido a suas propriedades desejáveis, que a seguir são sumarizadas.

## 2. Propriedades do MV

A atratividade do MLE decorre de suas propriedades desejáveis, em especial suas propriedades de grandes amostras ou assintóticas. Elas são obtidas sob condições bem gerais.

### 2.1 Consistência

Para um melhor entendimento do conceito de consistência que envolve o conceito de convergência em probabilidade, Farei uma breve revisão, resumindo, os aspectos essenciais apresentadas no livro do Amemiya<sup>2</sup>, para isso começaremos com convergência de números reais.

**Definição 2.1.1 Convergência de sequência de números reais)** A sequência de números reais,  $(\alpha_n), n = 1, 2, \dots$ , converge para um número real  $\alpha$  se para qualquer  $\epsilon > 0$ , existe um número inteiro  $N$  tal que para todo  $n > N$  temos

$$|\alpha_n - \alpha| < \epsilon.$$

Então, escrevemos  $\alpha_n \rightarrow \alpha$ , quando  $n \rightarrow \infty$  ou  $\lim_{n \rightarrow \infty} \alpha_n = \alpha$ .

Para levar este conceito para sequências de variáveis aleatórias ocorrem algumas diferenças. No caso de variáveis aleatórias 2.1 as vezes é verdadeira as vezes não, pois estamos tratando de variáveis aleatórias, bem diferente de convergência de números reais. Agora só podemos falar da probabilidade de 2.1 ser verdadeira e não afirmar que ela é verdadeira. Tal constatação nos sugere que 2.1 deve ser definida em outros termos, ou seja, pode-se afirmar que 2.1 ocorre com probabilidade se aproximando de 1 quando  $n \rightarrow \infty$ . Então nós temos:

#### Convergência em Probabilidade:

Uma sequência de variáveis aleatórias  $\{y_n\}, n=1,2,\dots$  se diz que converge *em probabilidade* para uma variável aleatória  $y$  se para qualquer  $\epsilon > 0$  e  $\delta > 0$  existe um número inteiro  $N$  para todo  $n >$

$N$ , onde a  $P(|y_n - y| < \epsilon) > 1 - \delta$ . Escreve-se  $y_n \xrightarrow{p} y$  quando  $n \rightarrow \infty$  ou  $\text{plim}_{n \rightarrow \infty} y_n = y$ , ou, alternativamente e mais usual,  $P(|y_n - y| < \epsilon) = 1$  para qualquer  $\epsilon > 0$

Diferentemente do caso de sequência de constantes onde apenas um tipo de convergência, como estabelecido em 2.1 é suficiente, no caso de sequências de variáveis aleatórias precisamos de dois tipos de convergência: *convergência em média quadrática* e *convergência em distribuição*.<sup>3</sup>

#### Definição 2.1.2 (Convergência em Média Quadrática)

Diremos que uma variável aleatória  $y_n$  converge em média quadrática para  $y$  se  $\lim_{n \rightarrow \infty} E(y_n - y)^2 = 0$  e dizemos que

$$y_n \xrightarrow{M} y.$$

<sup>2</sup> Veja AMEMIYA, T., *Introcyion to Statistics and Econometrics*, Harvard University Press, Cambridge, MA, 1994, pp.100 -110.

<sup>3</sup> Existe um outro modo de convergência que é a *almost sure convergence*. Que não será discutida aqui, pois os dois tipos de convergência mencionados acima serão suficientes para a discussão sobre propriedades de grandes amostras desta nota.

### Definição 2.1.3 (Convergência em Distribuição)

Uma sequência de variáveis aleatórias  $\{y_n\}$  converge para  $y$ , em distribuição se a função distribuição de probabilidade dessa sequência, definida por  $F_n$ , for igual a cada ponto de  $F$ , função de distribuição de probabilidades de  $y$ , e escrevemos  $y_n \xrightarrow{d} y$ , e chamamos  $F$  a distribuição limite da sequência  $\{y_n\}$ .

### Definição 2.1.4 Leis dos Grandes Números (LLN)

As LLN são teoremas sobre *convergência em probabilidade* (ou “*almost sure convergence*”) no caso especial onde  $\{y_n\}$  é uma média amostral ou quando  $y_n = \bar{y}_n$ , onde:

$$\bar{y}_n = \frac{1}{n} \sum_{i=1}^n y_i.$$

Note que  $y_i$  aqui é uma notação geral para uma variável aleatória. Observe que, no contexto do modelo de regressão linear ela não representa a variável explicativa. No caso de regressão,  $y_i = \mathbf{x}_i \boldsymbol{\beta}$ .

A LLN é uma forma mais fácil de se chegar ao plim do que as definições de convergência em probabilidade e convergência em média quadrática discutidas em 2.1.1 e 2.1.2 acima. As LLN são de grande uso em econometria, pois elas tratam de convergência de médias amostrais e os estimadores envolvem médias.

#### 2.1.4 LLN ( Lei dos Grandes Números Fraca)

Uma LLN fraca especifica condições sobre os termos individuais  $y_i$  em  $\bar{y}_n$ , sob as quais

$$\bar{y}_n - E(\bar{y}_n) \xrightarrow{p} 0^4$$

Aplicando-se a convergência em probabilidade ou a a convergência em média quadrática, ou mesmo a LLN fraca, dada as hipóteses do modelo de MV, com o estimador sendo função de variáveis iid e que formam médias, temos garantido q

$$\text{plim}(\hat{\boldsymbol{\theta}}) = \boldsymbol{\theta}$$

## 2.2 Normalidade Assintótica

No caso do plim, a LLN fraca dá respaldo a convergência de  $\hat{\boldsymbol{\theta}}$  para a média populacional  $\boldsymbol{\theta}$ . No caso da convergência em distribuição além de se supor que a média existe também é necessário a existência da variância, no caso em que a convergência em distribuição é para uma distribuição assintótica requer também a existência da variância-covariância assintótica.

Importante observar que consistência requer uma distribuição degenerada, ou seja a variância vai para zero quando aumenta o tamanho da amostra e o estimador converge para o verdadeiro valor do parâmetro. Neste caso não há como fazer inferência, a variância é zero, a distribuição se degenera em cima do verdadeiro valor do parâmetro, quando  $n \rightarrow \infty$ . É necessário fazer com que

---

<sup>4</sup> Uma LLN forte estas condições sobre os elementos  $y_i$  que compõem  $\bar{y}_n$  levam a *almost sure convergence*.

a distribuição não se degenera para permitir a inferência estatística. Para isso será necessário magnificar ou fazer um reescalonamento na variável aleatória ou o estimador para que a convergência em distribuição possa ocorrer evitando que a distribuição se degenera quando  $n \rightarrow \infty$ .

É usualmente usado  $\sqrt{n}$  como fator para reescalonar a variável aleatória para se evitar que a distribuição se degenera. Então, considere  $y_n = (\hat{\theta} - \theta)$ .  $y_n$  pode ter uma função de distribuição acumulada  $F_n$  complicada. Mas, Como qualquer outra função,  $F_n$  converge para uma função limite, como vimos na definição 2.1, onde convergência é não estocástica, no sentido matemático. Aplicando-se a definição 2.1.3, vista acima, temos se  $F_n$  for definida agora como a função de **distribuição de probabilidade**  $y_n$ ,  $F_n$ , for igual a cada ponto de continuidade de  $F$ , função de distribuição de probabilidades de  $y$ , e escrevemos  $y_n \xrightarrow{d} y$ , e chamamos  $F$  a distribuição limite da sequência  $\{y_n\}$ .

Em geral  $y_n \xrightarrow{d} y$  implica em  $y_n \xrightarrow{p} y$ , mas o reverso não é verdadeiro.

Pela LLN ou pela convergência em probabilidade  $y_n$  converge para uma constante: a distribuição se degenera e  $\lim_{n \rightarrow \infty} \bar{y}_n = \lim_{n \rightarrow \infty} E(\bar{y}_n) < \infty$ <sup>5</sup>.

Para eliminarmos o problema em que  $\lim_{n \rightarrow \infty} [\bar{y}_n - E(\bar{y}_n)]$  ser zero, rescalonamos  $[y_n - E(y_n)]$  pelo desvio padrão, o que garante à variável aleatória reescalada a existência de variância igual a 1.

### **Teorema do Limite Central**

Dado

$$z_n = \frac{\bar{y}_n - E(\bar{y}_n)}{\sqrt{Var(\bar{y}_n)}}$$

O  $\bar{y}_n$  é a média amostral. O Teorema do Limite Central especifica as condições sobre  $y_i$  para que  $z_n$  convirja assintoticamente para a  $N(0,1)$  ou  $z_n \xrightarrow{d} N(0,1)$ .

No caso de MV e MQO como veremos, para  $n \rightarrow \infty$  MQO, independente da distribuição dos erros, converge para a distribuição assintótica de MV.

No caso da MV a distribuição de  $\hat{\theta}$  é normal e a distribuição assintótica é dada por:

$$\hat{\theta} \stackrel{a}{\sim} N(\theta, I^{-1}(\theta))$$

Com essa definição fica estabelecido que a distribuição assintótica de  $\hat{\theta}$  tem média  $\theta$  e variância  $I^{-1}(\theta)$ , que é a inversa da **Matriz de Informação**. A matriz de informação é definida de duas formas equivalentes:

$$I(\theta) = E \left[ \left( \frac{\partial l}{\partial \theta} \right) \left( \frac{\partial l}{\partial \theta} \right)' \right] = -E \left[ \frac{\partial^2 l}{\partial \theta \partial \theta'} \right]$$

---

<sup>5</sup> Supondo que a média exista e seja finita, a LLN adequada, no caso a de Kolmogorov. Veja Cameron, C em Cameron: Assintotic Theory for OLS, Notas de Aula E240, Theorem 18 e Definição 13.

Usualmente é mais *simples* fazer os cálculos dos elementos da matriz de informação usando a segunda alternativa.  $\theta$  é  $k \times 1$ , portanto,

$$\frac{\partial l}{\partial \theta} = \begin{bmatrix} \frac{\partial l}{\partial \theta_1} \\ \frac{\partial l}{\partial \theta_2} \\ \vdots \\ \frac{\partial l}{\partial \theta_k} \end{bmatrix}$$

Cada um dos elementos desse vetor gradiente ou score, é em si mesmo uma função de  $\theta$ , o que nos permite diferenciar cada elemento desse vetor com relação a cada elemento de  $\theta$ , por exemplo, com relação ao primeiro elemento de  $\theta$  temos:

$$\frac{\partial[\frac{\partial l}{\partial \theta}]}{\partial \theta_1} = \begin{bmatrix} \frac{\partial^2 l}{\partial \theta_1^2} & \frac{\partial^2 l}{\partial \theta_1 \partial \theta_2} & \cdots & \frac{\partial^2 l}{\partial \theta_1 \partial \theta_k} \end{bmatrix}$$

Se a derivada for feita para cada elemento do vetor teremos a matriz  $k \times k$  de derivadas segundas de  $l$ , conhecida por matriz

Hessiana,

$$\frac{\partial^2 l}{\partial \theta \partial \theta'} = \begin{bmatrix} \frac{\partial^2 l}{\partial \theta_1^2} & \frac{\partial^2 l}{\partial \theta_1 \partial \theta_2} & \cdots & \frac{\partial^2 l}{\partial \theta_1 \partial \theta_k} \\ \frac{\partial^2 l}{\partial \theta_2 \partial \theta_1} & \frac{\partial^2 l}{\partial \theta_2^2} & \cdots & \frac{\partial^2 l}{\partial \theta_2 \partial \theta_k} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 l}{\partial \theta_k \partial \theta_1} & \frac{\partial^2 l}{\partial \theta_k \partial \theta_2} & \cdots & \frac{\partial^2 l}{\partial \theta_k^2} \end{bmatrix}$$

#### a. Eficiência Assintótica

$\hat{\theta}$  é o MLE do vetor  $\theta$  com  $k + 1$  parâmetros desconhecidos,

$$\sqrt{n}(\hat{\theta} - \theta) \xrightarrow{d} N(\mathbf{0}, \mathbf{V})$$

onde  $\mathbf{V}$  é a matriz positiva definida – PD de variância-covariância. Qualquer outro estimador também consistente, assintoticamente normal, com matriz de variância-covariância  $\tilde{\mathbf{V}}$  também PD. Então  $\tilde{\mathbf{V}} - \mathbf{V}$  é positiva semidefinida, o que garante a eficiência assintótica para o  $\hat{\theta}$  MLE. Como exemplificaremos com o modelo de regressão linear clássico nesta nota,

$\mathbf{V} = \mathbf{I}^{-1}(\theta)$ , que estabelece o “Cramer-Rao Lower Bound”, ou limite mínimo de Cramer-Rao, já apresentado em nota de aula anterior sobre propriedades dos estimadores.

### c.1 Derivação da Matriz de Informação

Se tomarmos  $\mathbf{s}(\boldsymbol{\theta}; \mathbf{y}) = \frac{\partial l}{\partial \boldsymbol{\theta}}$ , que é constituído de observações de uma amostra aleatória, que são funções de  $\boldsymbol{\theta}$  tendo, pois uma distribuição de densidade de probabilidade, nos permite, então calcular encontrar o vetor de  $k$  médias zero e a matriz de variância,  $I(\boldsymbol{\theta})$ ,  $k \times k$ , destes  $k$  vetores<sup>6</sup>. Para demonstrar a média zero, tomemos a função de distribuição de probabilidades conjuntas das  $n$  observações da amostra, que será igual a 1:

$$\int \cdots \int f(y_1, y_2, \dots, y_n; \boldsymbol{\theta}) dy_1 \cdots dy_n = \int \cdots \int L d\mathbf{y} = 1$$

Derivando ambos os lados da igualdade com relação a  $\boldsymbol{\theta}$  obtemos:

$$\int \cdots \int \frac{\partial L}{\partial \boldsymbol{\theta}} d\mathbf{y} = 0$$

Mas,

$$E(\mathbf{s}) = \int \cdots \int \frac{\partial l}{\partial \boldsymbol{\theta}} L d\mathbf{y}$$

E,

$$\text{Var}(\mathbf{s}) = E(\mathbf{s}\mathbf{s}') = E \left[ \left( \frac{\partial l}{\partial \boldsymbol{\theta}} \right) \left( \frac{\partial l}{\partial \boldsymbol{\theta}} \right)' \right] = I(\boldsymbol{\theta})$$

Ou seja, temos então a média e variância do gradiente ou *score function*.

### 3. Estimador de MV do modelo de regressão clássico

Como vimos, em aulas anteriores, o modelo linear de regressão é dado por:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u},$$

onde  $\mathbf{y}$  é  $n \times 1$ ,  $\mathbf{X}$  é  $n \times (k + 1)$ ,  $\boldsymbol{\beta}$  é  $(k + 1) \times 1$  e  $\mathbf{u}$  é  $n \times 1$ .

Adicionando-se ao modelo linear as 5 hipóteses de Gauss-Markov teremos as condições para o modelo ser BLUE e se, além delas adicionarmos a hipótese 6 de normalidade para o termo erro:

$$\mathbf{H6} \quad \mathbf{u} \sim \mathbf{N}(\mathbf{0}, \sigma^2 \mathbf{I}_n).$$

A função densidade multivariada normal de  $\mathbf{u}$  é:

$$f(\mathbf{u}) = \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-(1/2\sigma^2)(\mathbf{u}'\mathbf{u})}$$

A função multivariada de

$$f(\mathbf{y} | \mathbf{X}) = f(\mathbf{u}) \left| \frac{\partial \mathbf{u}}{\partial \mathbf{y}} \right|$$

---

<sup>6</sup> Farei aqui uma adaptação da apresentação do Maximum Likelihood Estimation with Stata, Gold, W., j. Pitblado, B. Poi, 4TH Edition, Stata Press, 2004, cap 1.

onde  $\left| \frac{\partial \mathbf{u}}{\partial \mathbf{y}} \right|$  é o *Jacobiano* da transformação de  $\mathbf{u}$  em  $\mathbf{y}$  e é dado pelo determinante da seguinte matriz  $n \times n$ :

$$\begin{bmatrix} \frac{\partial u_1}{\partial y_1} & \frac{\partial u_1}{\partial y_2} & \dots & \frac{\partial u_1}{\partial y_n} \\ \frac{\partial u_2}{\partial y_1} & \frac{\partial u_2}{\partial y_2} & \dots & \frac{\partial u_2}{\partial y_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial u_n}{\partial y_1} & \frac{\partial u_n}{\partial y_2} & \dots & \frac{\partial u_n}{\partial y_n} \end{bmatrix}$$

No caso do modelo de regressão linear clássico essa matriz é a identidade, pois  $\frac{\partial u_i}{\partial y_j} = 1$ , se  $i = j$ ; e  $0$  para  $i \neq j$ . A razão é simples; cada observação da amostra é independente da outra, logo não existe correlação entre o erro de uma observação e a variável dependente de outra.

A  $\log$  da verossimilhança é:

$$\begin{aligned} l = \ln f(\mathbf{y} | \mathbf{X}) &= \ln f(\mathbf{u}) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \mathbf{u}'\mathbf{u} \\ &= -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \end{aligned}$$

O vetor de parâmetros desconhecidos,  $\boldsymbol{\theta}'$  neste caso terá  $k + 2$  parâmetros desconhecidos,  $k+1$ ,  $\boldsymbol{\beta}$  e  $\sigma^2$ .

$$\boldsymbol{\theta}' = [\boldsymbol{\beta}', \sigma^2]$$

Tomando derivadas parciais com relação aos parâmetros encontramos as equações do gradiente que quando igualadas a zero para se obter os estimadores dos parâmetros se tornam em condições de 1ª ordem-CPO, necessárias para o máximo da função  $\log$  da verossimilhança:

$$\begin{aligned} \frac{\partial l}{\partial \boldsymbol{\beta}} &= -\frac{1}{\sigma^2} (-\mathbf{X}'\mathbf{y} + \mathbf{X}'\mathbf{X}\boldsymbol{\beta}) \\ \frac{\partial l}{\partial \sigma^2} &= -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \end{aligned}$$

As soluções dessas CPO nos rendem:

$$\begin{aligned} \hat{\boldsymbol{\beta}} &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} \\ \hat{\sigma}^2 &= (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})'(\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})/n \end{aligned}$$

Como os elementos de fora da diagonal principal de

Como vemos o estimador obtido para o vetor  $\hat{\boldsymbol{\beta}}$  é exatamente igual a solução de MQO para o modelo de regressão linear clássico. Logo este  $\hat{\boldsymbol{\beta}}$  de ML apresenta todas as propriedades desejáveis vistas para o estimador MQO. Mas, o mesmo não ocorre para o estimador  $\hat{\sigma}^2$ , que, como se observa é

viesado, pois sua  $E(\hat{\sigma}^2) = \sigma^2 \frac{n-k-1}{n}$ , tomando as derivadas segundas do gradiente com relação a  $\beta$  e  $\sigma^2$ , temos

$$\frac{\partial^2 l}{\partial \beta \partial \beta'} = -\frac{X'X}{\sigma^2}$$

$$\frac{\partial^2 l}{\partial \beta \partial \sigma^2} = -\frac{X'u}{\sigma^4}$$

$$\frac{\partial^2 l}{\partial (\sigma^2)^2} = \frac{n}{2\sigma^4} - \frac{u'u}{\sigma^6}$$

Tomando o negativo da esperança matemática, obtêm-se os elementos da matriz de informação:

$$-E\left(\frac{\partial^2 l}{\partial \beta \partial \beta'}\right) = \frac{X'X}{\sigma^2}$$

$$-E\left(\frac{\partial^2 l}{\partial \beta \partial \sigma^2}\right) = \mathbf{0}$$

$$-E\left(\frac{\partial^2 l}{\partial (\sigma^2)^2}\right) = \frac{n}{2\sigma^4}$$

Para se obter o último resultado lembre-se que  $E(u'u) = E(\sum u_i^2) = n\sigma^2$ .

E a matriz de informação é:

$$I(\theta) = I\left(\begin{matrix} \beta \\ \sigma^2 \end{matrix}\right) = \begin{bmatrix} \frac{1}{\sigma^2}(X'X) & \mathbf{0} \\ \mathbf{0} & \frac{n}{2\sigma^4} \end{bmatrix}$$

A sua inversa nos fornecerá a matriz de variância-covariância do estimador ML que coincide com o *Cramer-Rao Lower Bound*:

$$I^{-1}\left(\begin{matrix} \beta \\ \sigma^2 \end{matrix}\right) = \begin{bmatrix} \sigma^2(X'X)^{-1} & \mathbf{0} \\ \mathbf{0} & \frac{2\sigma^4}{n} \end{bmatrix}$$

Como é possível observar em  $I^{-1}\left(\begin{matrix} \beta \\ \sigma^2 \end{matrix}\right)$  os elementos fora da diagonal principal são zeros, indicando que  $\beta$  e  $\sigma^2$  são independentemente distribuídos. [Type equation here.](#)

Substituindo os estimadores de MV na função de verossimilhança, obtemos;

$$L(\hat{\beta} \hat{\sigma}^2).$$

Substituindo os valores de  $\hat{\beta}$  e de  $\hat{\sigma}^2$  na função de verossimilhança e tomando-a em termos exponenciais obtemos:

$$\begin{aligned} L(\hat{\beta} \hat{\sigma}^2) &= (2\pi e)^{-\frac{n}{2}} (\hat{\sigma}^2)^{-\frac{n}{2}} \\ &= \left(\frac{2\pi e}{n}\right)^{-\frac{n}{2}} (\hat{u}'\hat{u})^{-\frac{n}{2}} \\ &= \text{Constante} \cdot (\hat{u}'\hat{u})^{-\frac{n}{2}} \end{aligned}$$

No caso a Constante não depende de nenhum parâmetro do modelo.

O elemento (1,1) que é a matriz de variância-covariância de  $\hat{\beta}$  de ML, que coincide com a de MQO é o limite ímimo de Cramer-Rao, o que implicitamente demonstra que MQO é assintoticamente eficiente.

#### 4. Testes de LR, WALD e LM

Vamos ilustrar estes testes no âmbito de hipóteses lineares sobre os  $\beta$ s. Elas terão o seguinte formato:

$$H_0: R\beta = r$$

Onde  $R$  é uma matriz conhecida  $q \times k+1$ ,  $\beta$  é um vetor  $(k+1) \times 1$  e  $r$  é um vetor também de elementos conhecidos  $q \times 1$ . E  $q < k+1$ .

Os testes serão os testes LR, W e LM.

##### 4.1 Teste de LR

Os estimadores de MV desenvolvidos acima definem o máximo da função de verossimilhança sem impor nenhuma restrição sobre os parâmetros. Vamos representar o máximo da função de verossimilhança como:

$L(\hat{\beta}; \hat{\sigma}^2)$ . É importante que seja observado que  $\hat{\sigma}^2$  é expresso como função da soma dos resíduos sem restrições ao quadrado,  $\hat{u}'\hat{u}$ . O estimador de MV a semelhança do estimador de MQO, também pode ser obtido através da maximização do log da verossimilhança impondo  $H_0: R\beta = r$ . Ou seja  $\max_{\beta}(\tilde{l}) = l - \gamma'(R\beta - r)$ , onde  $\gamma$  é um vetor  $q \times 1$  de multiplicadores de Lagrange,

Assim obtém-se  $L(\tilde{\beta}; \tilde{\sigma}^2)$ , que corresponde a soma de quadrados dos resíduos do estimador ML com restrições,  $\tilde{u}'\tilde{u}$ .

É fácil entender que  $L(\tilde{\beta}; \tilde{\sigma}^2) \leq L(\hat{\beta}; \hat{\sigma}^2)$ . Quando se restringe os parâmetros a função de verossimilhança jamais terá um valor máximo superior ao da função sem restrições.

A estatística de LR é obtida pela razão entre a função sem restrição sobre o valor da que é obtido pela função quando se restringe o valor dos parâmetros especificados na hipótese nula. A estatística então é:

$$\lambda = \frac{L(\tilde{\beta}; \tilde{\sigma}^2)}{L(\hat{\beta}; \hat{\sigma}^2)}$$

Esta estatística necessita de transformações especiais no caso de amostras finitas ficam bem complexas e tem que ser encontrada a distribuição amostral de  $\lambda$  caso a caso. Mas, para grandes amostras a estatística de teste tem distribuição amostral definida e é dada por:

$$LR = -2 \ln \lambda = 2[\ln L(\hat{\beta}, \hat{\sigma}^2) - \ln L(\tilde{\beta}, \tilde{\sigma}^2)] \stackrel{a}{\sim} \chi^2(q)$$

O estimador de MV restrito é obtido pelo  $\max_{\beta}(\tilde{l})$  e substituindo

$$L(\hat{\beta}; \hat{\sigma}^2) = \text{Constante} \cdot (\hat{u}'\hat{u})^{-\frac{n}{2}}$$

Fazendo o mesmo para o máximo da função de verossimilhança restrita;

$$L(\tilde{\beta}; \tilde{\sigma}^2) = \text{Constante} \cdot (\tilde{u}'\tilde{u})^{-\frac{n}{2}}$$

Substituindo esses valores em:

$$LR = n[\ln L(\hat{\beta} \hat{\sigma}^2) - \ln L(\tilde{\beta} \tilde{\sigma}^2)]$$

Obtemos;

$$LR = n[\ln(\tilde{u}'\tilde{u}) - \ln(\hat{u}'\hat{u})],$$

Colocado o LR de uma forma mais adequada para mostrarmos. Posteriormente, que  $WALD \geq LR \geq LM$ , temos:

$$\begin{aligned} LR &= n \left[ \ln \frac{\tilde{u}'\tilde{u}}{\hat{u}'\hat{u}} \right] = n \left[ \ln \left( \frac{\hat{u}'\hat{u}}{\hat{u}'\hat{u}} + \frac{\tilde{u}'\tilde{u}}{\hat{u}'\hat{u}} - \frac{\hat{u}'\hat{u}}{\hat{u}'\hat{u}} \right) \right] \\ &= n \left[ \ln \left( 1 + \frac{\tilde{u}'\tilde{u} - \hat{u}'\hat{u}}{\hat{u}'\hat{u}} \right) \right] \\ &= n \left[ \ln \left( 1 + \frac{\tilde{u}'\tilde{u} - \hat{u}'\hat{u}}{\hat{u}'\hat{u}} \right) \right], \text{ ou} \end{aligned}$$

$$\begin{aligned} LR &= n \left[ \ln \left( \frac{\hat{u}'\hat{u}}{\tilde{u}'\tilde{u}} \right)^{-1} \right] = n \left[ \ln \left( \frac{1}{\frac{\tilde{u}'\tilde{u}}{\hat{u}'\hat{u}} + \frac{\hat{u}'\hat{u}}{\hat{u}'\hat{u}} - \frac{\tilde{u}'\tilde{u}}{\hat{u}'\hat{u}}} \right) \right] \\ &= n \left[ \ln \left( \frac{1}{1 - \frac{\tilde{u}'\tilde{u} - \hat{u}'\hat{u}}{\hat{u}'\hat{u}}} \right) \right] \end{aligned}$$

Como vemos o cálculo da estatística LR requer a estimação dos modelos sem e com restrições para se obter a soma dos quadrados dos resíduos dos dois modelos.

## 4.2 Teste de Wald (W)<sup>7</sup>

No teste de Wald apenas o vetor  $\hat{\beta}$  de MV da regressão sem restrições é estimado. A partir dos coeficientes estimados aplica-se as restrições, dadas por  $H_0: R\beta = r$ , e verifica se a redução da função de verossimilhança é “pequena” ou “grande”, sendo que pequena ou grande terá métrica definida pela distribuição da estatística de teste, W.

Como:

$\hat{\beta} \sim N[\hat{\beta}, I^{-1}(\hat{\beta})]$ , sob  $H_0$ ,  $(R\hat{\beta} - r) \sim N[0, RI^{-1}(\hat{\beta})R']$ , onde  $I^{-1}(\hat{\beta}) = \sigma^2(X'X)^{-1}$ . Como vimos acima a matriz de informação é bloco diagonal logo podemos centrar a atenção na sub-matriz relativa a  $\beta$ . Segue então que:

$$(R\hat{\beta} - r)' [RI^{-1}(\hat{\beta})R']^{-1} (R\hat{\beta} - r) \underset{a}{\sim} \chi^2_{(q)},$$

se distribui assintoticamente como uma Chi<sup>2</sup>, com  $q$  graus de liberdade.

<sup>7</sup> Veja, Wooldridge, J., Introductory Econometrics: A modern Approach, 6<sup>th</sup>, Edition, Cengage, Appendix e, pp. 737-31 para uma discussão excelente dos testes assintóticos

onde  $q$  é o número de linhas da matriz  $R$  ou o número de restrições impostas sobre o vetor  $\beta$ . A distribuição assintótica ainda se mantém quando substituimos  $I^{-1}(\beta)$  por  $\hat{\sigma}^2(X'X)^{-1}$ .

$$W = \frac{(R\hat{\beta} - r)'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r)}{\hat{\sigma}^2} \underset{a}{\sim} \chi^2(q)$$

Com as hipóteses H1 a H6<sup>8</sup> é fácil de ver que o Wald se reduz ao teste de F, quando dividida por  $q$ :

$$W/q = \frac{(R\hat{\beta} - r)'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r)'}{\frac{\hat{u}'\hat{u}}{n}} \sim F(q, n - k - 1)$$

Nós já vimos acima que o numerador da estatística Wald pode ser expresso como  $(\tilde{u}'\tilde{u} - \hat{u}'\hat{u})$ , que é a diferença da soma dos quadrados da regressão com restrição menos a soma de quadrados da regressão sem restrições. Portanto,  $W$

$$W = \frac{(R\hat{\beta} - r)'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r)}{\frac{\hat{u}'\hat{u}}{n}} \underset{a}{\sim} \chi^2(q)$$

$$W = \frac{(\tilde{u}'\tilde{u} - \hat{u}'\hat{u})}{\frac{\hat{u}'\hat{u}}{n}} = \frac{n(\tilde{u}'\tilde{u} - \hat{u}'\hat{u})}{\hat{u}'\hat{u}} \underset{a}{\sim} \chi^2(q)$$

### 4.3 Teste de LM<sup>9</sup>

O teste de LM é conhecido como o teste do *score*, pois ele se baseia nas condições de primeira ordem para maximização da MV:

$$s(\theta) = \frac{\partial \ln L}{\partial \theta} = \frac{\partial l}{\partial \theta}$$

<sup>8</sup> Sob H6 a estatística Wald tem distribuição Chi<sup>2</sup> exata, logo quando dividida pelo número de restrições terá a distribuição F exata obtida para amostras finitas.

<sup>9</sup> Veja, Wooldridge, J., *op. cit.*, Chap. 5, onde só o resultado  $LM = nR^2 \sim \chi^2(q)$  é apresentado.

O estimador sem restrições,  $\hat{\theta}$ , que é obtido através da solução as CPO:  $\mathbf{s}(\theta) = \mathbf{0}$ , que fornece o *score vector* avaliado em  $\hat{\theta}$ . Quando se impõem restrições sobre os parâmetros, para se obter o estimador com restrições, o  $\mathbf{s}(\theta)$ , quando avaliado em  $\tilde{\theta}$  não será zero. Mas, se as restrições forem válidas, o valor do máximo restrito  $l(\tilde{\theta}) \approx l(\hat{\theta})$ , e  $\mathbf{s}(\tilde{\theta}) \approx \mathbf{0}$ . Como vimos anteriormente, o  $\mathbf{s}(\theta)$  tem média zero e variância  $\mathbf{I}(\theta)$ . A forma quadrática  $\mathbf{s}'(\theta)\mathbf{I}^{-1}(\theta)\mathbf{s}(\theta)$  que está [ponderada pela matriz de variância-covariância,  $\mathbf{I}^{-1}(\theta)$ ], tem uma distribuição  $\chi^2$ . Avaliando esta forma quadrática em  $\theta = \tilde{\theta}$  fornece um teste para se testar a hipótese nula. O resultado importante é que sob a hipótese nula com  $q$  restrições nos coeficientes, resulta que:

$$LM = \mathbf{s}'(\tilde{\theta})\mathbf{I}^{-1}(\tilde{\theta})\mathbf{s}(\tilde{\theta}) \stackrel{a}{\sim} \chi^2_{(q)}$$

Em contraste com o teste de Wald onde se estimava a regressão sem restrições agora basta estimar a regressão com restrições para se construir a estatística LM. É uma das razões para a popularidade do LM, mas a principal está na facilidade em aplica-lo, pois em muitas situações é bem mais simples estimar a regressão com restrições e aplicar o teste. Vimos acima que o vetor *score* ou as CPO é dado por:

$$\mathbf{s}(\theta) = \begin{bmatrix} \frac{\partial l}{\partial \boldsymbol{\beta}} \\ \frac{\partial l}{\partial \sigma^2} \end{bmatrix} = \begin{bmatrix} \frac{1}{\sigma^2} \mathbf{X}'\mathbf{u} \\ -\frac{n}{2\sigma^2} + \frac{\mathbf{u}'\mathbf{u}}{2\sigma^4} \end{bmatrix}$$

Para se avaliar o vetor *score* nos valores do estimador com restrições basta substituímos  $\theta$  por  $\tilde{\theta}$  em  $\mathbf{s}(\theta)$  e substituímos  $\mathbf{u}$  por  $\tilde{\mathbf{u}} = \mathbf{y} - \mathbf{X}\tilde{\boldsymbol{\beta}}$  e  $\sigma^2$  por  $\tilde{\sigma}^2$ , ou seja,

$$\mathbf{s}(\tilde{\theta}) = \begin{bmatrix} \frac{1}{\tilde{\sigma}^2} \mathbf{X}'\tilde{\mathbf{u}} \\ \mathbf{0} \end{bmatrix}.$$

O inverso da matriz de informação, como vimos. Avaliando-a em  $\tilde{\theta}$  temos:

$$\mathbf{I}^{-1}(\tilde{\theta}) = \begin{bmatrix} \tilde{\sigma}^2(\mathbf{X}'\mathbf{X})^{-1} & \mathbf{0} \\ \mathbf{0} & \frac{2\tilde{\sigma}^4}{n} \end{bmatrix}$$

Substituindo  $\mathbf{s}$  e  $\mathbf{I}^{-1}$  na estatística LM, temos:

$$LM = \begin{bmatrix} \frac{1}{\tilde{\sigma}^2} \mathbf{X}'\tilde{\mathbf{u}} & \mathbf{0} \end{bmatrix}' \begin{bmatrix} \tilde{\sigma}^2(\mathbf{X}'\mathbf{X})^{-1} & 0 \\ 0 & \frac{\sigma^4}{n} \end{bmatrix} \begin{bmatrix} \frac{1}{\tilde{\sigma}^2} \mathbf{X}'\tilde{\mathbf{u}} \\ 0 \end{bmatrix}, \text{ fazendo o produto dos vetores e matriz, obtemos:}$$

$$LM = \frac{n[\tilde{\mathbf{u}}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\tilde{\mathbf{u}}]}{\tilde{\mathbf{u}}'\tilde{\mathbf{u}}}$$

Mas,  $\tilde{\mathbf{u}}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\tilde{\mathbf{u}} = \tilde{\mathbf{u}}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\tilde{\mathbf{u}}$ , pois  $\mathbf{X}\tilde{\mathbf{u}}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\tilde{\mathbf{u}}$  é uma matriz simétrica e idempotente. Então

$\tilde{\mathbf{u}}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\tilde{\mathbf{u}} = \hat{\boldsymbol{\alpha}}'\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\alpha}}$ , que nada mais é do que a soma dos quadrados explicada da regressão de  $\tilde{\mathbf{u}}$  na matriz com  $k+1$  variáveis  $\mathbf{X}$ . Observe que neste caso,  $\tilde{\mathbf{u}}'\tilde{\mathbf{u}}$  nada mais é do

que a soma dos quadrados a ser explicada, no caso, a soma dos quadrados da variável dependente  $\tilde{u}$ . Desta forma a estatística LM é simplesmente dada por:

$$LM = n \left[ \frac{\text{Soma dos Quadrados Explicada}(SQE)}{\text{Soma dos Quadrados Total}(SQT)} \right]$$

$$LM = nR^2 \sim \chi^2_{(q)}$$

**PASSOS** (para se testar  $H_0 = \beta_1 = 0, \dots, \beta_q = 0$ )

1º) Faz-se a regressão;

$y_i = \beta'_0 + \beta_{q+1}x_{q+1,i} + \dots + \beta_k x_{k,i} + u_i$ , que é a regressão sob  $H_0$ , donde se obtém:

$$\tilde{u}_i = y_i - \tilde{\beta}'_0 - \tilde{\beta}_{q+1}x_{q+1,i} - \dots - \tilde{\beta}_k x_{k,i}$$

2º) Faz-se a regressão de  $\tilde{u}_i$  em  $x_1, x_2, \dots, x_k$ , com as K variáveis explicativas;

3º) Calcula-se

$LM = nR^2$  que tem distribuição  $\chi^2_{(q)}$  e testa-se para se rejeitar ou não  $H_0$ .

Também é simples mostrar que

$$LM = \frac{n[\tilde{u}'X(X'X)^{-1}X'\tilde{u}]}{\tilde{u}'\tilde{u}} = n \frac{(\tilde{u}'\tilde{u} - \hat{u}'\hat{u})}{\tilde{u}'\tilde{u}}.$$

Para mostrar como se chega a este resultado temos que mostrar que:

$$[\tilde{u}'X(X'X)^{-1}X'\tilde{u}] = (\tilde{u}'\tilde{u} - \hat{u}'\hat{u}).$$

Considere:

$$\tilde{u}'\tilde{u} - \tilde{u}'X(X'X)^{-1}X'\tilde{u} = \tilde{u}'[I_n - X(X'X)^{-1}X']\tilde{u} = \tilde{u}'M\tilde{u}$$

, onde

$M = [I_n - X(X'X)^{-1}X']$  é uma matriz simétrica e idempotente, tal que  $MM' = MM = M$ .

Então temos que mostrar que  $\tilde{u}'M\tilde{u} = \hat{u}'\hat{u}$ , o que ocorrerá se  $M\tilde{u} = \hat{u}$ . Por definição

$\tilde{u} = y - X\tilde{\beta}$ , onde  $\tilde{\beta}$  é o estimador com restrições satisfazendo

$$R\tilde{\beta} = r.$$

Portanto,  $M\tilde{u} = M(y - X\tilde{\beta}) = My - MX\tilde{\beta}$ , mas, é fácil verificar que  $MX = 0$ , logo  $M\tilde{u} = My =$

$$M(X\hat{\beta} + \hat{u}) = M\hat{u} = \hat{u}, \text{ pois}$$

$$[I_n - X(X'X)^{-1}X']\hat{u} = [\hat{u} - X(X'X)^{-1}X'\hat{u}] = \hat{u}, \text{ pelas condições de primeira ordem } X'\hat{u} = 0.$$

Portanto  $[\tilde{u}'X(X'X)^{-1}X'\tilde{u}] = (\tilde{u}'\tilde{u} - \hat{u}'\hat{u})$  e

$$LM = \frac{n(\tilde{u}'\tilde{u} - \hat{u}'\hat{u})}{\tilde{u}'\tilde{u}}$$

## 5. Relação entre W, LR e LM

Podemos agora demonstrar a famosa desigualdade entre os 3 testes:

$$W \geq LR \geq LM$$

Sabemos que:

$$\ln(1+x) \cong x - \frac{x^2}{2!} + \dots^{10}$$

<sup>10</sup> Expansão por Série de Taylor no ponto  $x = 0$ , para aproximar

$$f(x) = f(0) + \frac{x}{1!} \frac{\partial f}{\partial x} \Big|_{x=0} + \frac{x^2}{2!} \frac{\partial^2 f}{\partial x^2} \Big|_{x=0} + \dots$$

A 2ª fórmula para LR derivada acima, nos fornece:

$LR = c$ , logo aplicando a expansão acima até o 2º termo temos:

$$LR = n \left( \frac{\tilde{u}'\tilde{u} - \hat{u}'\hat{u}}{\hat{u}'\hat{u}} \right) - \frac{n}{2} \left( \frac{\tilde{u}'\tilde{u} - \hat{u}'\hat{u}}{\hat{u}'\hat{u}} \right)^2.$$

Mas, como visto acima  $n \left( \frac{\tilde{u}'\tilde{u} - \hat{u}'\hat{u}}{\hat{u}'\hat{u}} \right) = W$ , conclui-se pois que

$$W \geq LR$$

De forma similar, mas agora usando a 3ª expressão para LR, temos

$$LR = -n \ln \left( 1 - \frac{(\tilde{u}'\tilde{u} - \hat{u}'\hat{u})}{\tilde{u}'\tilde{u}} \right)$$

$$LR = -n \left( -\frac{(\tilde{u}'\tilde{u} - \hat{u}'\hat{u})}{\tilde{u}'\tilde{u}} \right) - \left( -\frac{n}{2} \right) \left( -\frac{(\tilde{u}'\tilde{u} - \hat{u}'\hat{u})}{\tilde{u}'\tilde{u}} \right)^2$$

$$LR = n \left( \frac{(\tilde{u}'\tilde{u} - \hat{u}'\hat{u})}{\tilde{u}'\tilde{u}} \right) + \frac{n}{2} \left( \frac{(\tilde{u}'\tilde{u} - \hat{u}'\hat{u})}{\tilde{u}'\tilde{u}} \right)^2 \text{ ou}$$

$$LR = LM + \frac{n}{2} \left( \frac{(\tilde{u}'\tilde{u} - \hat{u}'\hat{u})}{\tilde{u}'\tilde{u}} \right)^2, \text{ concluímos então que}$$

$LR \geq LM$ , ou seja, comparando os três testes temos:

$$W \geq LR \geq LM.$$

Os testes são assintoticamente equivalentes, mas para amostras finitas, podem ser diferentes, mas mantendo a ordem de grandeza acima demonstrada.

## 6. Exemplo

Usarei o exemplo do Wooldridge, onde ele especifica uma relação para explicar o número de vezes que jovens nascidos em 1960, dão detidos pela polícia em 1986. Vou copiar aqui o Cap5.do, colocado no STOA.

\* Stata Do-file

```
* setup
version 14.2
capture log close
set more off
```

```
* open log
log using Chap5Asyntotics, replace text
```

---


$$f(x) = \ln(1+x) = \ln(1+0) + \frac{x}{1!}(1+0) + \frac{x^2}{2!}[-1(1+0)^{-2}] + \dots$$

$$\ln(1+x) = x - \frac{x^2}{2} + \dots$$

```
* open data
use "/Users/denisardalves/Desktop/EAE-324/DATA SET/CRIME1.DTA", clear
/*Para voces verem que narr86, mesmo com n=2724 está muito longe da dist. normal, vou usar o
comando kdensity em narr86*/
```

```
kdensity narr86, bwidth(0.2) normal
```

```
* Vou selecionar uma amostra, com reposição, das 2725 obs dos dados de CRIME1.DTA. Para
isso uso o comando bsample com n = 500. Quero mostrar que as diferenças entre os testes de
WALD, LR e LM, diminuem a medida que o n aumenta.*/
```

```
bsample 500
```

```
* estimar regressão sem restrições
```

```
reg narr86 avgsen tottime qemp86 black hispan inc86
```

```
estimates store regsr
```

```
ereturn list
```

```
scalar sqrsr = e(rss)
```

```
*estimar regressão com restrições, supondo que raça não afeta criminalidade
```

```
reg narr86 avgsen tottime qemp86 black hispan inc86
```

```
estimates store regcr
```

```
ereturn list
```

```
scalar sqrcr = e(rss)
```

```
* compute LR
```

```
scalar LR=e(N)*(log(sqrcr) - log(sqrsr))
```

```
* se usarmos LR2=nln(1+(sqrcr-sqrsr)/sqrsr). temos
```

```
scalar LR2=e(N)*(log(1+(sqrcr-sqrsr)/sqrsr))
```

```
di LR2
```

```
^* computo da estatística WALD
```

```
scalar WALD=e(N)*(sqrcr-sqrsr)/sqrsr
```

```
di wALD
```

```
* computo do LM
```

```
*1o Passo:
```

```
quietly reg narr86 avgsen tottime qemp86 inc86
```

```
predict rescr, residuals
```

```
*2o Passo:
```

```
reg rescr avgsen tottime qemp86 black hispan inc86
```

```
*3o Passo:
```

```
scalar LM=e(N)*e(r2)
```

```
di LM
```

```
di LR
```

```
di WALD
```

```
scalar chic = invchi2tail(2,.05)
di "Chi-square(2) 95th percentile = " chic
scalar pvalue = chi2tail(2,WALD)
di pvalue
log close
```

```
log close
```

OBS: Para vocês observarem como os testes se aproximam cada vez mais, é só apagar o comando bsample e rodar o do file(mude o nome do do file) que você estará usando as 2725 e não 500 com0 selecionadas pelo bsample, n=500.