

# ESTATÍSTICA AVANÇADA: MODELOS NÃO LINEARES

## Modulo 3: Teoria Assintótica

Gilvan Guedes, Cedeplar - UFMG  
Melissa Pinho, Estatística - UFMG

Escola do Legislativo - ALMG  
Belo Horizonte, Minas Gerais


21 de setembro de 2015

# Sumário

<b>1</b>	<b>Propriedades Assintóticas dos Estimadores</b>	<b>2</b>
<b>2</b>	<b>Propriedades Assintóticas</b>	<b>3</b>
2.1	Consistência de um estimador . . . . .	4
2.2	Convergência em quadrado médio ou média quadrática . . . . .	5
2.3	O Teorema de Slutsky . . . . .	7
2.4	Convergência em Distribuição . . . . .	8
<b>3</b>	<b>Consistência de <math>\hat{\beta}</math></b>	<b>8</b>
3.1	Prova de Consistência de $\hat{\beta}$ . . . . .	9
3.2	Normalidade Assintótica de $\hat{\beta}$ de MQO . . . . .	12
3.3	Prova da Normalidade Assintótica de $\hat{\beta}$ . . . . .	13
3.3.1	TCL variante de Lindberg-Feller . . . . .	15
3.4	Consistência de $s^2$ e a variância assintótica de $\hat{\beta}$ . . . . .	17
3.5	Eficiência assintótica de $\hat{\beta}$ . . . . .	19
<b>4</b>	<b>Prática de Teoria Assintótica</b>	<b>19</b>
4.1	Simulação de Monte Carlo Simples e Propriedades Assintóticas . . . . .	19

# 1 Propriedades Assintóticas dos Estimadores

Esse texto é de autoria da Profa. Sueli Moro (Departamento de Economia/UFMG) e está estritamente proibida sua reprodução. A maior parte das fórmulas é baseada no livro do (Greene, 2012). Algumas pequenas alterações no texto original foram feitas para adequar linguagem e notação para o LaTeX.



A econometria tem se tornado “cheia de assintótico” (Leamer, 1988).

A teoria assintótica trata do **que acontece a uma estatística ou estimador quando o tamanho da amostra se torna muito grande**. Essa estatística pode ser a média, variância, os coeficientes do modelo linear e até mesmo os testes estatísticos.

Indexamos sempre em  $n$  ou  $T$  para mostrar o papel do tamanho da amostra:

$$\hat{\beta}_n \text{ ou } \hat{\beta}_t$$

**O quão grande precisa ser uma amostra** para que o estimador mostre as suas propriedades assintóticas?

Goldfeld and Quandt (1972) mostram um exemplo em que uma amostra de tamanho 30 já é suficientemente grande. Mostram também outro exemplo em que é necessária uma amostra de 200 observações. Segundo os autores, **grandes amostras são mais importantes quando existe maior interesse na variância do que nos valores**.

Como quase sempre trabalhamos com pequenas amostras (finitas), defender um estimador com base nas suas propriedades assintóticas faria sentido somente se **estimadores com melhores propriedades assintóticas também tivessem melhores propriedades em amostras finitas**. E parece que é isso que acontece!

## 2 Propriedades Assintóticas

Um **estimador não viesado** é aquele cuja distribuição amostral é centrada no verdadeiro valor do parâmetro; ou seja:

$$E[\hat{\theta}] = \theta$$

Essa propriedade não depende do tamanho da amostra: um estimador não viesado é não viesado em pequenas e grandes amostras!

Mas às vezes não é possível encontrar um estimador que tenha boas propriedades em pequenas amostras. Quando isso acontece, precisamos justificar o uso do estimador com base em suas propriedades assintóticas, ou seja, a sua distribuição em grandes amostras.

**A distribuição de um estimador muda com o tamanho da amostra.** A média da amostra, por exemplo, tem uma distribuição amostral que é centrada na média da população:

$$E[\bar{X}] = \mu$$

Mas a **variância da média torna-se menor à medida que a amostra aumenta**:

$$Var[\bar{X}] = \frac{\sigma^2}{n}$$

Quais são as propriedades assintóticas que precisamos definir para um estimador?

1. **Consistência:** utiliza o conceito de **convergência em probabilidade**. Questão: a distribuição de  $\hat{\beta}$  colapsa para um valor específico quando  $n$  aumenta?
2. **Eficiência assintótica:** utiliza o conceito de **convergência em distribuição** e está relacionada com o conceito de distribuição assintótica. Questão: a distribuição de  $\hat{\beta}$  se aproxima de uma forma conhecida (ex. normal) quando  $n$  aumenta?

Para provar que um estimador é eficiente assintoticamente, é necessário conhecer a distribuição assintótica desse estimador! **Observação:** ela precisa ser normal!

Mas **o que é a distribuição assintótica de um estimador?**

Considerar a distribuição de um estimador  $\hat{\beta}$  para amostras cada vez maiores: **se as distribuições vão se tornando cada vez mais parecidas com alguma distribuição específica, esta é chamada de distribuição assintótica** desse estimador!

Algumas considerações:

1. Se a distribuição assintótica de  $\hat{\beta}$  se concentra em um valor  $k$  quando a amostra tende ao infinito, diz-se que  $k$  é a **probabilidade limite** de  $\hat{\beta}$ . Se  $\lim_{n \rightarrow \infty} \hat{\beta} = \beta$ , dizemos que  $\hat{\beta}$  é um estimador consistente!
2. A variância da distribuição assintótica é chamada de variância assintótica.

Então, se  $\hat{\beta}$  é consistente e a sua variância assintótica é menor que a variância assintótica de qualquer outro estimador consistente,  $\hat{\beta}$  é chamado de **assintoticamente eficiente**!

- A propriedade  $plim \hat{\beta} = \beta$  pode ser vista como o equivalente de ausência de viés em grandes amostras (**atenção**, isso somente no sentido de que se refere ao valor do parâmetro)
- Consistência pode ser pensada como o equivalente da propriedade de *minimum mean square error* (mínimo erro quadrático médio)

que  $MSE$  pode ser definido como:

$$MSE = \text{Var}(\hat{\theta}) + [\text{Viés}(\hat{\theta})]^2$$

A variância de um estimador assintoticamente eficiente tende a zero mais rapidamente que a variância de qualquer outro estimador consistente.

## 2.1 Consistência de um estimador

**Observação:** mesma intuição da esperança, no sentido que se refere a valores.

Para estabelecer consistência, precisamos do conceito de **convergência em probabilidade**. O conceito de convergência em probabilidade é **usado para definir a consistência de estimadores**.

### Convergência em Probabilidade:

A sequência de variáveis aleatórias

$$z_1, z_2, \dots, z_n$$

converge em probabilidade para a variável aleatória  $z$  se:

$$\lim_{T \rightarrow \infty} \text{Prob}[|z_n - z| > \epsilon] = 0 \quad \forall \epsilon > 0$$

Diz-se, então que:

$$z_n \xrightarrow{p} z$$

Ou seja,  $z_n$  converge em probabilidade para  $z$ . E que:

$$plim(z_n) = z$$

Isso quer dizer que a **probabilidade da diferença ser maior que qualquer número positivo**, por menor que ele seja, é **zero**.

Uma **condição suficiente (mas não necessária)** para que ocorra a convergência é a **convergência em quadrado médio ou média quadrática** (*mean square*). É condição suficiente porque pode haver convergência sem que ocorra convergência em média quadrática.

**Exemplo** Uma variável aleatória  $z$  toma dois valores 0 e  $T$  com probabilidades:

$$P(z = 0) = 1 - \frac{1}{T}$$

e

$$P(z = T) = \frac{1}{T}$$

Quando  $T$  aumenta a  $P(z = 0)$  tende a 1 e a  $P(z = T)$  tende a 0. Nesse caso,  $z$  converge em probabilidade a 0 e, portanto:

$$\lim_{T \rightarrow +\infty} z_T = 0$$

e

$$z_T \xrightarrow{P} 0 \text{ ou seja, } plim(z_T) = 0$$

## 2.2 Convergência em quadrado médio ou média quadrática

Se  $z_n$  tem média  $\mu_n$  e variância  $\sigma_n^2$  tais que:

$$\lim_{n \rightarrow +\infty} E[z_n] = c$$

e

$$\lim_{n \rightarrow +\infty} Var[z_n] = 0$$

então  $z_n$  converge em média quadrática para  $c$  e

$$plim(z_n) = c$$

A prova é obtida pelo Teorema de Chebychev. Ou seja, limite da esperança é uma constante e limite da variância é zero.

Para nosso estimador  $\hat{\beta}$ , teríamos:

$$\lim_{n \rightarrow +\infty} E[\hat{\beta}_n] = \beta$$

e

$$\lim_{n \rightarrow +\infty} Var[\hat{\beta}_n] = 0$$

**Convergência em média quadrática implica em convergência em probabilidade, mas a recíproca não é verdadeira!**

**Observação:** Convergência em média quadrática: o limite da esperança tem que ser uma constante e o limite da variância tem que ser zero.

Exemplo de um caso em que a convergência em probabilidade não implica em convergência em quadrado médio: Seja  $x_n = 0, T$ ,  $P(x_n = 0) = 1 - \frac{1}{T}$  e  $P(x_n = T) = \frac{1}{T}$ . Nesse caso:

$$E[x_n] = 0\left(1 - \frac{1}{T}\right) + T\left(\frac{1}{T}\right) = 1$$

e

$$\lim_{n \rightarrow +\infty} E[x_n] = 1$$

mas a probabilidade limite é zero, porque:

$$x_n \xrightarrow{p} 0$$

ou seja,

$$plim(x_n) = 0$$

**Conclusão:** O limite da esperança é 1 e a *plim* é 0.

O limite da variância também não é zero:

$$E(x_n^2) = (0)^2\left(1 - \frac{1}{T}\right) + (T)^2\frac{1}{T} = T$$

$$Var(x_n) = E[x_n - E(x_n)]^2 \tag{1}$$

$$Var(x_n) = E[x_n - 1]^2 = E[x_n^2] - 2E[x_n] + (1)^2$$

$$Var(x_n) = T - 2 + 1 = T - 1$$

**Conclusão:** A variável  $z_n$  converge em probabilidade, mas não converge em quadrado médio, porque **a média converge para uma constante, mas a variância não converge para zero.**

Felizmente, isso é raro de acontecer. Normalmente, convergência em probabilidade implica em convergência em quadrado médio.

O conceito de convergência em probabilidade é usado para definir a consistência de estimadores:

- **Convergência** → Para onde vai? *plim*
- **Consistência** → Vai para onde eu quero que vá e a variância se aproxima de zero?  
 $plim\hat{\beta} = \beta$ ?

**Então, um estimador será consistente se  $plim\hat{\beta} = \beta$  e sua variância se aproxima de zero quando  $n$  aumenta.**

## Consistência da média de uma amostra

A média de uma amostra é um estimador consistente para a média da população. Isto porque:

$$E[\bar{x}] = \mu$$

e

$$Var[\bar{x}] = \frac{\sigma^2}{n}$$

Assim,

$$\lim_{n \rightarrow +\infty} var(\bar{x}) = 0$$

e

$$\lim_{n \rightarrow +\infty} E[\bar{x}] = \mu$$

## 2.3 O Teorema de Slutsky

É uma consequência interessante da consistência. É uma das razões que possibilita usar a teoria assintótica. Isso porque a álgebra associada ao cálculo das esperanças, que é necessária para encontrar as propriedades em amostras finitas, às vezes é muito difícil, pode ser até impossível, e no limite tudo fica mais fácil!

### Teorema de Slutsky:

Para uma função contínua de  $x_n$ ,  $g(x_n)$ ,

$$plim g(x_n) = g[plim(x_n)]$$

**Observação:**  $g(x_n)$  precisa ser uma função contínua. Isto é: a *plim* de uma função contínua é a função avaliada na *plim*.

Isso não é verdade para a esperança matemática, pois o valor esperado de uma função não-linear de uma estatística não é uma função não-linear do valor esperado daquela estatística.

**Exemplo** Seja  $g$  uma função quadrática de um estimador  $g(b) = b^2$ , então:

$$E[b^2] = Var(b) + [E(b)]^2$$

Lembre-se que  $Var(x) = E(x^2) - [E(x)]^2 \rightarrow E(x^2) = Var(x) + [E(x)]^2$

Sabemos que  $E[b^2] \neq [E(b)]^2$ . Mas no limite  $Var(b)$  tende a zero e, portanto:

$$\lim_{n \rightarrow +\infty} E[b^2] = [E(b)]^2$$

e

$$plim[b^2] = plim[E(b)]^2$$

O Teorema de Slutsky é utilizado em várias situações como, por exemplo, em *plim* da multiplicação de funções, *plim* da soma de funções, etc.



## 2.4 Convergência em Distribuição

**Convergência em distribuição** é a forma mais fraca de convergência. O Teorema Central do Limite é um teorema sobre convergência em distribuição.

Convergência em probabilidade não é a mesma coisa que convergência em distribuição. Vejamos a diferença:

- **Convergência em probabilidade:** diz que a variável aleatória converge para um valor conhecido (o parâmetro na população).
- **Convergência em distribuição:** diz que as variáveis se comportam da mesma maneira, ou seja, tem a mesma distribuição, mas não têm necessariamente os mesmos parâmetros.

É importante para a distribuição limite e para a distribuição assintótica.

**Observação:** Convergência em distribuição é a forma de convergência mais fraca (*weak convergence*) e não implica nenhum outro tipo de convergência. Mas todos os outros tipos de convergência implicam em convergência em distribuição, como a convergência em probabilidade.

## 3 Consistência de $\hat{\beta}$

Para que  $\hat{\beta}$  seja um estimador consistente de  $\beta$  é preciso que  $\text{plim}\hat{\beta} = \beta$  (o viés e a variância se aproximem de 0)!

**Observação:** Lembre-se que  $\hat{\beta}$  é uma variável aleatória em amostras repetidas.

Se  $\hat{\beta}$  convergir em probabilidade para uma constante, ou seja, a média na população, e se a sua variância convergir para zero, teremos convergência em *mean square*, e a probabilidade limite de  $\hat{\beta}$  é  $\beta$ . Isso porque convergência em *mean square* implica em convergência em probabilidade.

Então, para onde converge  $\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$ ?

A partir de agora fazemos toda a análise indexada em  $n$ , ou seja, o tamanho da amostra agora é importante, porque desejamos saber as propriedades do estimador quando  $n$  aumenta.

Quando dividimos por  $n$  temos médias e queremos saber se essas médias de amostras convergem para médias na população.

### 3.1 Prova de Consistência de $\hat{\beta}$

O método dos Mínimos Quadrados Ordinários busca minimizar a soma dos quadrados dos erros, utilizando como base as equações normais:

$$\begin{aligned}(\beta) &= \epsilon^T \epsilon = (\mathbf{Y} - \mathbf{X}\beta)^T (\mathbf{Y} - \mathbf{X}\beta) \\ S(\beta) &= \mathbf{Y}^T \mathbf{Y} - \beta^T \mathbf{X}^T \mathbf{Y} - \mathbf{Y}^T \mathbf{X}\beta + \beta^T \mathbf{X}^T \mathbf{X}\beta \\ S(\beta) &= \mathbf{Y}^T \mathbf{Y} - 2\beta^T \mathbf{X}^T \mathbf{Y} + \beta^T \mathbf{X}^T \mathbf{X}\beta \\ \frac{\partial S(\beta)}{\partial \beta} &= -2\mathbf{X}^T \mathbf{Y} + 2\mathbf{X}^T \mathbf{X}\beta\end{aligned}\tag{2}$$

As equações normais são obtidas como:

$$\begin{aligned}S(\beta)/\beta &= 0 \\ \frac{\partial S(\beta)}{\partial \beta} &= -2\mathbf{X}^T \mathbf{Y} + 2\mathbf{X}^T \mathbf{X}\beta = 0 \\ \mathbf{X}^T \mathbf{X}\beta &= \mathbf{X}^T \mathbf{Y}\end{aligned}\tag{3}$$

Como:

$$\begin{aligned}\partial S(\beta)\partial \beta &= -2\mathbf{X}^T \mathbf{Y} + 2\mathbf{X}^T \mathbf{X}\beta = 0 \\ \beta &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} \\ \frac{\partial^2 S(\beta)}{\partial \beta \partial \beta} &= 2\mathbf{X}^T \mathbf{X}\end{aligned}\tag{4}$$

Assim,  $\mathbf{X}^T \mathbf{X}$  é uma matriz positiva e definida.

O estimador MQO de  $\beta$  é:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

Substituindo  $\mathbf{y} = \mathbf{X}\beta + \epsilon$ , temos:

$$\begin{aligned}\beta &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T (\mathbf{X}\beta + \epsilon) \\ \hat{\beta} &= (\mathbf{X}^T \mathbf{X})^{-1} (\mathbf{X}^T \mathbf{X})\beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \epsilon \\ \hat{\beta} &= \beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \epsilon\end{aligned}\tag{5}$$

Multiplicando e dividindo a parte destacada de  $\hat{\beta}$  por  $n$  teremos:

$$plim(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \epsilon = plim \left[ \frac{(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \epsilon}{n} \right]$$

Utilizando o Teorema de Slutsky:

$$plim(g(x)) = g(plim(x))$$

temos:

$$plim \left[ \frac{(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \epsilon}{n} \right] = plim \frac{(\mathbf{X}^T \mathbf{X})^{-1}}{n} plim \frac{\mathbf{X}^T \epsilon}{n}$$

Dividir a equação acima por  $n$  faz sentido porque agora  $n \rightarrow +\infty$  e também porque  $\mathbf{X}^T \mathbf{X}$  é uma matriz de somas de produtos e os elementos de sua diagonal são somas de quadrados.

Se existe um intercepto, o elemento superior à direita da matriz  $\mathbf{X}^T \mathbf{X}$  será igual a  $n$ . Então, quando  $n \rightarrow +\infty$ , algumas dessas somas tendem a ficar muito grandes. Por isso, não faz sentido achar  $plim(\mathbf{X}^T \mathbf{X})$ . Quando olhamos a  $plim(\frac{\mathbf{X}^T \mathbf{X}}{n})$  estamos olhando para os valores médios de  $\mathbf{X}^T \mathbf{X}$ , e esses são finitos quando  $n$  aumenta.

**Pressuposto:**

$$\lim_{n \rightarrow +\infty} \frac{\mathbf{X}^T \mathbf{X}}{n} = \mathbf{Q}$$

em que  $\mathbf{Q}$  é uma matriz finita, positiva definida e não-singular. É uma média do somatório de produtos e dos somatórios de quadrados de variáveis.

Isso implica que quando  $n$  aumenta os elementos de  $\mathbf{X}^T \mathbf{X}$  não aumentam a uma taxa maior do que  $n$ . Mas quando essa expressão se torna infinita (no caso da equação de tendência) a sua inversa se torna 0.

Vamos mostrar que:

$$\sigma^2(\mathbf{X}^T \mathbf{X})^{-1} = var(\beta)$$

vai se aproximando de zero quando  $n$  aumenta, ou seja:

$$\lim_{n \rightarrow \infty} \sigma^2(\mathbf{X}^T \mathbf{X})^{-1} = var(\beta) = 0$$

A expressão  $\lim_{n \rightarrow +\infty} \frac{\mathbf{X}^T \mathbf{X}}{n} = \mathbf{Q}$  também implica que quando  $n$  aumenta, os elementos de  $\mathbf{X}^T \mathbf{X}$  são linearmente independentes no limite, uma vez que ela é não-singular, admitindo inversa. Vejamos um exemplo de violação dessa hipótese.

Equação de tendência:

$$y = \beta_1 + \beta_2 + \epsilon$$

$$\mathbf{X}^T \mathbf{X} = \begin{bmatrix} T & \frac{T(T+1)}{2} \\ T(T+1) & \frac{T(T+1)(2T+1)}{6} \end{bmatrix}$$

Veja que a equação viola o pressuposto, pois

$$\lim_{T \rightarrow +\infty} \left( \frac{\mathbf{X}^T \mathbf{X}}{T} \right) = \begin{bmatrix} 1 & +\infty \\ +\infty & +\infty \end{bmatrix}$$

esta matriz não é finita, ou seja, “explode” no infinito.

Outra equação que viola o pressuposto é:

$$y_t = \beta_1 + \beta_2 \lambda^t + \epsilon_t$$

em que:  $|\lambda| < 1$

Nesse caso,

$$\lim_{T \rightarrow +\infty} \begin{pmatrix} \mathbf{X}^T \mathbf{X} \\ \mathbf{T} \end{pmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}$$

que é uma matriz singular.

Felizmente, a matriz  $\mathbf{X}^T \mathbf{X}$  satisfaz as **condições de Grenander**, que são mais fracas e suficientes para a consistência dos  $\hat{\beta}$ .

Condições de Grenander (Greene, 2012):

G1 - Para cada coluna de  $\mathbf{X}$ ,  $\mathbf{x}_k$ , se  $d_{nk}^2 = \mathbf{x}_k^T \mathbf{x}_k$ , então  $\lim_{n \rightarrow +\infty} d_{nk}^2 = +\infty$ . Portanto,  $\mathbf{x}_k$  não degenera a uma sequência de zeros. As somas dos quadrados continuarão a crescer na medida em que o tamanho da amostra aumenta. Nenhuma variável degenerará para uma sequência de zeros.

G2 -  $\lim_{n \rightarrow +\infty} x_{ik}^2 / d_{nk}^2 = 0$  para todo  $i = 1, \dots, n$ . Essa condição implica que nenhuma observação individual dominará  $\mathbf{x}_k^T \mathbf{x}_k$ , e na medida em que  $n \rightarrow +\infty$ , observações individuais se tornarão menos importantes.

G3 - Seja  $\mathbf{R}_n$  a matriz de correlação amostral das colunas da matriz  $\mathbf{X}$ , excluindo o termo constante caso haja um. Então,  $\lim_{n \rightarrow +\infty} \mathbf{R}_n = \mathbf{C}$ , uma matriz positiva definida. Essa condição implica que a condição de posto completo sempre será atingida. Já assumimos que  $\mathbf{X}$  tem posto completo em uma amostra finita, então esse pressuposto assegura que a condição nunca será violada.

Até agora provamos que

$$\lim_{n \rightarrow +\infty} \frac{\mathbf{X}^T \mathbf{X}}{n} = \mathbf{Q}$$

ou que pelo menos  $\mathbf{X}^T \mathbf{X}$  satisfaz as condições de Grenander. Portanto, temos agora que:

$$\begin{aligned} \text{plim} \hat{\beta} &= \beta + \text{plim} \left( \frac{\mathbf{X}^T \mathbf{X}}{n} \right)^{-1} \text{plim} \left( \frac{\mathbf{X}^T \epsilon}{n} \right) \\ \text{plim} \hat{\beta} &= \beta + \mathbf{Q}^{-1} \text{plim} \left( \frac{\mathbf{X}^T \epsilon}{n} \right) \end{aligned} \tag{6}$$

Agora precisamos fazer a prova assintótica de  $\text{plim} \left( \frac{\mathbf{X}^T \epsilon}{n} \right)$ . Fazendo:

$$\frac{\mathbf{X}^T \epsilon}{n} = \frac{1}{n} \sum_{i=1}^n x_i \epsilon_i = \frac{1}{n} \sum_{i=1}^n w_i = \bar{w}$$

Assim, teremos:

$$\text{plim} \hat{\beta} = \beta + \mathbf{Q}^{-1} \text{plim} \bar{w}$$

Supondo que  $\mathbf{X}$  seja não-estocástico (e portanto, não-correlacionado com o erro), temos:

**Média de  $\bar{w}$**

$$E[\bar{w}] = \frac{1}{n} \sum_{i=1}^n E[w_i] = \frac{1}{n} \sum_{i=1}^n E[x_i, \epsilon_i] = \frac{1}{n} \sum_{i=1}^n x_i E[\epsilon_i] = \frac{1}{n} \mathbf{X}^T E[\epsilon] = 0$$

**Variância de  $\bar{w}$**

$$Var(\bar{w}) = E[\bar{w}\bar{w}^T] = E\left[\frac{\mathbf{X}^T \epsilon}{n} \frac{\epsilon^T \mathbf{X}}{n}\right] \quad (7)$$

$$Var(\bar{w}) = \frac{1}{n} \mathbf{X}^T \mathbf{E}(\epsilon \epsilon^T | \mathbf{X}) \frac{\mathbf{X}}{n} = \frac{1}{n} \sigma^2 \frac{\mathbf{X}^T \mathbf{X}}{n} = \frac{\sigma^2}{n} \frac{\mathbf{X}^T \mathbf{X}}{n}$$

Tomando o limite:

$$\lim_{n \rightarrow +\infty} var(\bar{w}) = \lim_{n \rightarrow +\infty} \left( \frac{\sigma^2}{n} \frac{\mathbf{X}^T \mathbf{X}}{n} \right) = 0 \mathbf{Q} = 0$$

Então, uma vez que a média de  $\bar{w}$  é zero (uma constante) e sua variância converge para zero,  $\bar{w}$  converge em média quadrática para zero.

Assim:

$$plim(\bar{w}) = 0$$

e

$$plim\left(\frac{1}{n} \mathbf{X}^T \epsilon\right) = 0$$

**Observação:** Lembre-se que isso é a prova da consistência de  $\hat{\beta}$  e que estamos usando convergência em probabilidade.

Então:

$$\hat{\beta} = \beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \epsilon$$

$$plim \hat{\beta} = \beta + \mathbf{Q}^{-1} plim \frac{\mathbf{X}^T \epsilon}{n} \quad (8)$$

$$plim \hat{\beta} = \beta + \mathbf{Q}^{-1} 0$$

$$plim \hat{\beta} = \beta$$

**Conclusão:**  $\hat{\beta}$  é um estimador consistente no modelo de Regressão Clássico.

### 3.2 Normalidade Assintótica de $\hat{\beta}$ de MQO

Nessa sessão perguntamos qual é a distribuição assintótica de  $\hat{\beta}$ .

Vimos que em uma amostra finita não precisamos de normalidade dos erros nem dos  $\hat{\beta}$  para provar a eficiência dos  $\hat{\beta}$  de MQO (a prova é obtida utilizando Gauss-Markov).

Mas vimos também que só podemos afirmar que  $\hat{\beta}$  tem uma distribuição normal quando  $\epsilon$  tem uma distribuição normal. Ou seja, somente podemos inferir sobre a distribuição de  $\hat{\beta}$  quando os erros são normais.

Agora, para derivar a distribuição assintótica de  $\hat{\beta}$  precisamos assumir a matriz  $\mathbf{X}$  independente dos erros (ou seja, exogeneidade). Usamos o Teorema Central do Limite e não precisamos de normalidade em amostra finita.

**Distribuições assintóticas:** são também caracterizadas por suas médias e variâncias como nas distribuições finitas.

Temos então a **média assintótica** e a **variância assintótica**:

$$\hat{\beta} = E[\hat{\beta}] = \beta$$

A **média assintótica é igual à esperança assintótica** que é dada por  $plim \hat{\beta} = \beta$ . No caso dos estimadores, como no limite temos uma constante  $\beta$ , a variância é zero! Então a distribuição assintótica **não** é a distribuição no limite, porque no limite é uma distribuição **degenerada!**

**Observação:** No limite não há distribuição, é um pico! Então a distribuição assintótica é a distribuição da jornada final, antes de colapsar para um ponto.

A distribuição de um determinado estimador é diferente (ou pode ser), à medida que o tamanho da amostra aumenta. Pode diferir não somente na média e variância, mas também na forma matemática (lembrar que a binomial é assintoticamente uma normal).

A essência do **Teorema Central do Limite** pode ser resumida como:

**Quando o tamanho da amostra aumenta a distribuição da média amostral aproxima-se da normal. Diz-se então que a normal é a distribuição assintótica da média amostral.**

Quando estamos interessados em saber se os momentos da amostra convergem para os momentos da população, a **Lei dos Grandes Números (LGN)** nos dá essa resposta. Veja que há uma diferença entre a LGN e o TCL:

- LGN: momentos  $\rightarrow$  média, variância, etc.
- TCL: distribuição

### 3.3 Prova da Normalidade Assintótica de $\hat{\beta}$

Para derivar a distribuição de  $\hat{\beta}$ , não precisamos que os erros sejam normais. No entanto, precisaremos de duas condições:

- Teorema Central do Limite (TCL)
- assumir que  $\mathbf{X}$  é uma matriz de variáveis independentes dos erros

**Observação:** Fazemos a prova utilizando uma função de  $\hat{\beta}$ , ao invés de  $\hat{\beta}$  diretamente, porque se  $\hat{\beta}$  converge para  $\beta$  - que é uma constante - no limite não há distribuição, apenas um pico.

Lembre-se que:

$$\begin{aligned}\hat{\beta} &= \beta + \frac{\mathbf{X}^T \mathbf{X}}{n}^{-1} \frac{\mathbf{X}^T \epsilon}{n} \\ \hat{\beta} - \beta &= \frac{\mathbf{X}^T \mathbf{X}}{n}^{-1} \frac{\mathbf{X}^T \epsilon}{n}\end{aligned}\tag{9}$$

Multiplicando ambos os lados por  $\sqrt{n}$ , obtemos:

$$\begin{aligned}\sqrt{n}(\hat{\beta} - \beta) &= \left[ \frac{\mathbf{X}^T \mathbf{X}}{n}^{-1} \frac{\mathbf{X}^T \epsilon}{\sqrt{n}\sqrt{n}} \right] \sqrt{n} \\ \sqrt{n}(\hat{\beta} - \beta) &= \frac{\mathbf{X}^T \mathbf{X}}{n}^{-1} \frac{\mathbf{X}^T \epsilon}{\sqrt{n}}\end{aligned}\tag{10}$$

Temos que a distribuição limite de  $\sqrt{n}(\hat{\beta} - \beta)$  é igual à distribuição limite do lado direito, ou seja:

$$plim \left[ \left( \frac{\mathbf{X}^T \mathbf{X}}{n} \right)^{-1} \left( \frac{\mathbf{X}^T \epsilon}{\sqrt{n}} \right) \right]$$

Já obtivemos a  $plim \left( \frac{\mathbf{X}^T \mathbf{X}}{n} \right)^{-1}$ , que é  $\mathbf{Q}^{-1}$ . Mas não temos a  $plim \left( \frac{\mathbf{X}^T \epsilon}{\sqrt{n}} \right)$ , embora tenhamos a  $plim \left( \frac{\mathbf{X}^T \epsilon}{n} \right) = 0$ .

Então, qual seria a distribuição limite de  $\left( \frac{\mathbf{X}^T \epsilon}{\sqrt{n}} \right)$ ? Veja que essa é uma distribuição que será mais lenta para convergir, pois é indexada em  $\sqrt{n}$  ao invés de  $n$ :

$$\left( \frac{1}{\sqrt{n}} \right) \mathbf{X}^T \epsilon = \sqrt{n} \bar{\mathbf{w}}$$

$$\text{Lembre-se que } \bar{\mathbf{w}} = \frac{\mathbf{X}^T \epsilon}{n} = \frac{\mathbf{X}^T \epsilon}{\sqrt{n}\sqrt{n}}$$

$$\sqrt{n} \bar{\mathbf{w}} = \sqrt{n} \frac{\mathbf{X}^T \epsilon}{\sqrt{n}\sqrt{n}} = \frac{\mathbf{X}^T \epsilon}{\sqrt{n}} = \frac{1}{\sqrt{n}} \mathbf{X}^T \epsilon \tag{11}$$

Calculando a esperança e a variância de  $\sqrt{n}\bar{\mathbf{w}}$ , temos:

$$\begin{aligned}
 &\text{Média:} \\
 E[\sqrt{n}\bar{\mathbf{w}}] &= \sqrt{n}E[\bar{\mathbf{w}}] = 0 \\
 &\text{Variância:} \\
 Var[\sqrt{n}\bar{\mathbf{w}}] &= nVar(\bar{\mathbf{w}}) \\
 Var[\sqrt{n}\bar{\mathbf{w}}] &= n \left[ \frac{\sigma^2}{n} \frac{\mathbf{X}^T \mathbf{X}}{n} \right] \\
 Var[\sqrt{n}\bar{\mathbf{w}}] &= \sigma^2 \frac{\mathbf{X}^T \mathbf{X}}{n}
 \end{aligned} \tag{12}$$

Se tomarmos o limite da variância de  $\sqrt{n}\bar{\mathbf{w}}$ , teremos:

$$\lim_{n \rightarrow +\infty} Var[\sqrt{n}\bar{\mathbf{w}}] = \lim_{n \rightarrow +\infty} \sigma^2 \frac{\mathbf{X}^T \mathbf{X}}{n} = \sigma^2 \mathbf{Q}$$

Resta agora aplicar uma variante do Teorema Central do Limite (variante de Lindberg-Feller) ao vetor  $\sqrt{n}\bar{\mathbf{w}}$ . Vejamos o TCL de Lindberg-Feller.

### 3.3.1 TCL variante de Lindberg-Feller

#### Caso Univariado

Se  $x_1, \dots, x_n$  é uma amostra aleatória de uma distribuição de probabilidade com média  $\mu$  e variância  $\sigma^2$  na população:

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n x_i$$

Então,

$$\sqrt{n}(\bar{X}_n - \mu) \stackrel{d}{\sim} N[0, \sigma^2]$$

em que  $(\bar{X}_n - \mu)$  são desvios da média da amostra em relação à média da população.

A média de  $\sqrt{n}(\bar{X}_n - \mu)$  é obtida por:

$$\begin{aligned}
 E[\sqrt{n}(\bar{X}_n - \mu)] &= E[\sqrt{n}\bar{X}] - E[\sqrt{n}\mu] = \sqrt{n}E[\bar{X}] - \sqrt{n}E[\mu] \\
 E[\sqrt{n}(\bar{X}_n - \mu)] &= \sqrt{n}\mu - \sqrt{n}\mu = 0
 \end{aligned} \tag{13}$$

#### Caso Multivariado

Agora temos  $\mathbf{x}_1, \dots, \mathbf{x}_n$  representando amostras de uma distribuição multivariada. Assim:

$$\sqrt{n}(\bar{\mathbf{X}} - \mu) \stackrel{d}{\sim} N[\mathbf{0}, \mathbf{Q}]$$

No nosso caso, temos que

$$\frac{1}{\sqrt{n}} \mathbf{X}^T \epsilon = \sqrt{n}[\bar{\mathbf{w}} - E(\bar{\mathbf{w}})]$$



em que:

$$\sqrt{n}[\bar{\mathbf{w}} - E(\bar{\mathbf{w}})] \stackrel{d}{\sim} N[\mathbf{0}, \mathbf{Q}]$$

Então:

$$\frac{1}{\sqrt{n}}\mathbf{X}^T\epsilon \stackrel{d}{\sim} N[\mathbf{0}, \sigma^2\mathbf{Q}]$$

Segue-se que:

$$\sqrt{n}(\hat{\beta} - \beta) = \left( \frac{\mathbf{X}^T\mathbf{X}^{-1}}{n} \right) \frac{\mathbf{X}^T\epsilon}{\sqrt{n}}$$

$$\lim_{n \rightarrow +\infty} [\sqrt{n}(\hat{\beta} - \beta)] = \lim_{n \rightarrow +\infty} \left[ \left( \frac{\mathbf{X}^T\mathbf{X}^{-1}}{n} \right) \frac{\mathbf{X}^T\epsilon}{\sqrt{n}} \right]$$

$$\lim_{n \rightarrow +\infty} [\sqrt{n}(\hat{\beta} - \beta)] = \mathbf{Q}^{-1} \frac{1}{\sqrt{n}} \mathbf{X}^T \epsilon \quad (14)$$

$$\mathbf{Q}^{-1} \frac{1}{\sqrt{n}} \mathbf{X}^T \epsilon \stackrel{d}{\sim} N[\mathbf{Q}^{-1}\mathbf{0}, \mathbf{Q}^{-1}(\sigma^2\mathbf{Q})\mathbf{Q}^{-1}]$$

$$\mathbf{Q}^{-1} \frac{1}{\sqrt{n}} \mathbf{X}^T \epsilon \stackrel{d}{\sim} N[\mathbf{Q}^{-1}\mathbf{0}, \sigma^2\mathbf{Q}^{-1}]$$

**Observação:** Lembre-se que o primeiro termo é a média de  $\mathbf{Q}^{-1} \frac{1}{\sqrt{n}} \mathbf{X}^T \epsilon$ :

$$E \left[ \mathbf{Q}^{-1} \frac{1}{\sqrt{n}} \mathbf{X}^T \epsilon \right] = \mathbf{Q}^{-1}\mathbf{0}$$

e o segundo termo é a variância de  $\mathbf{Q}^{-1} \frac{1}{\sqrt{n}} \mathbf{X}^T \epsilon$ :

$$Var \left( \mathbf{Q}^{-1} \frac{1}{\sqrt{n}} \mathbf{X}^T \epsilon \right) = \mathbf{Q}^{-1}(\sigma^2\mathbf{Q})\mathbf{Q}^{-1}$$

Então:

$$\sqrt{n}(\hat{\beta} - \beta) \stackrel{d}{\sim} N[\mathbf{0}, \sigma^2\mathbf{Q}^{-1}]$$

Vamos agora utilizar um resultado do Greene (2012):

**Teorema:** Se  $\sqrt{n}(\hat{\theta}_n - \theta) \stackrel{d}{\sim} N[0, V]$ , então  $\hat{\theta} \sim N \left[ \theta, \frac{1}{n}V \right]$ , em que a primeira expressão diz que  $\sqrt{n}(\hat{\theta}_n - \theta)$  converge em distribuição para uma normal com média zero e variância  $V$  e a segunda expressão diz que  $\hat{\theta}$  é **assintoticamente normalmente distribuído** com média  $\theta$  e variância  $\frac{1}{n}V$ .

No caso do estimador MQO, se:

$$\sqrt{n}(\hat{\beta} - \beta) \stackrel{d}{\sim} N[\mathbf{0}, \sigma^2\mathbf{Q}^{-1}]$$

então:

$$\hat{\beta} \sim N \left[ \beta, \frac{\sigma^2\mathbf{Q}^{-1}}{n} \right]$$

ou

$$\hat{\beta} \sim N[\beta, \sigma^2(\mathbf{X}^T\mathbf{X})^{-1}]$$

Logo, a normalidade assintótica de  $\hat{\beta}$  não necessita da normalidade dos erros! É uma consequência do Teorema Central do Limite!

### 3.4 Consistência de $s^2$ e a variância assintótica de $\hat{\beta}$

Para computar as propriedades assintóticas de  $\hat{\beta}$  precisamos saber se o estimador da variância,  $\hat{\sigma}^2$  é consistente. Aqui só precisamos de consistência!

O problema é a consistência do estimador de  $\sigma^2$ ,  $\hat{\sigma}^2 = \mathbf{s}^2$ , uma vez que  $\mathbf{Q}^{-1}$  não é problema. Será que  $\mathbf{s}^2$  é consistente?

$$\begin{aligned}\mathbf{s}^2 &= \frac{\hat{\epsilon}^T \hat{\epsilon}}{n-k} \\ \mathbf{s}^2 &= \frac{1}{n-k} \epsilon^T \mathbf{M} \epsilon\end{aligned}\tag{15}$$

Lembre-se que  $M$  é a matriz geradora de resíduos, obtida como se segue:

$$\begin{aligned}\hat{\epsilon} &= \mathbf{y} - \mathbf{X}\hat{\beta} \\ \hat{\epsilon} &= \mathbf{y} - \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} \\ \hat{\epsilon} &= \mathbf{I} - \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} \\ \hat{\epsilon} &= \mathbf{M} \mathbf{y} \\ \hat{\epsilon} &= \mathbf{M}(\mathbf{X}\beta + \epsilon) \\ \hat{\epsilon} &= \mathbf{M}\mathbf{X}\beta + \mathbf{M}\epsilon = \mathbf{M}\epsilon \\ \hat{\epsilon}^T \hat{\epsilon} &= \epsilon^T \mathbf{M}^T \mathbf{M} \epsilon \\ \hat{\epsilon}^T \hat{\epsilon} &= \epsilon^T \mathbf{M} \epsilon\end{aligned}\tag{16}$$

Abrindo a expressão  $\mathbf{s}^2$  e multiplicando, temos:

$$\begin{aligned}\mathbf{s}^2 &= \frac{1}{n-k} \epsilon^T [\mathbf{I} - \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T] \epsilon \\ \mathbf{s}^2 &= \frac{1}{n-k} [\epsilon^T \epsilon - \epsilon^T \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \epsilon]\end{aligned}\tag{17}$$

Multiplicando por  $\frac{n}{n}$ , temos:

$$\begin{aligned}\mathbf{s}^2 &= \frac{n}{n-k} \left[ \frac{\epsilon^T \epsilon}{n} - \frac{\epsilon^T \mathbf{X}}{n} \left( \frac{\mathbf{X}^T \mathbf{X}^{-1}}{n} \right) \frac{\mathbf{X}^T \epsilon}{n} \right] \\ \lim_{n \rightarrow +\infty} \mathbf{s}^2 &= \lim_{n \rightarrow +\infty} \frac{n}{n-k} \left[ \frac{\epsilon^T \epsilon}{n} - \frac{\epsilon^T \mathbf{X}}{n} \left( \frac{\mathbf{X}^T \mathbf{X}^{-1}}{n} \right) \frac{\mathbf{X}^T \epsilon}{n} \right]\end{aligned}\tag{18}$$

Sabe-se que  $\frac{n}{n-k}$  converge para 1,  $\frac{\epsilon^T \mathbf{X}}{n}$  e  $\frac{\mathbf{X}^T \epsilon}{n}$  convergem para zero e  $\frac{\mathbf{X}^T \mathbf{X}}{n}$  converge para  $\mathbf{Q}^{-1}$ . Portanto, resta saber qual o limite de  $\frac{\epsilon^T \epsilon}{n}$ , ou seja:

$$\lim_{n \rightarrow +\infty} s^2 = \lim_{n \rightarrow +\infty} \frac{\epsilon^T \epsilon}{n}$$

Para chegar a este resultado, utilizamos o seguinte teorema:

**Teorema de Kinshine:** A média de uma amostra aleatória de observações independentes e identicamente distribuídas (*i.i.d.*) é um estimador consistente da média da população.

Então, precisamos apenas assumir que os erros são *i.i.d.*, não precisamos assumir que eles são normais.

Neste caso, basta olharmos  $\epsilon_1^2, \epsilon_2^2, \dots, \epsilon_n^2$  como uma amostra aleatória *i.i.d.* com média na população igual  $\sigma^2$ .

**Observação:** Isso é válido porque:

$$E[\epsilon_i^2] = \sigma^2$$

A média de  $\epsilon_i^2$  nossa amostra é dada por:

$$\bar{\epsilon}^2 = \frac{\sum_{i=1}^n \epsilon_i^2}{n} = \frac{\epsilon^T \epsilon}{n}$$

Temos então que  $\frac{\epsilon^T \epsilon}{n}$  é um **estimador consistente** da média da população  $\sigma^2$  (pelo Teorema de Kinshine).

Logo:

$$plim\left(\frac{\epsilon^T \epsilon}{n}\right) = \sigma^2$$

Então:

$$plim(s^2) = \sigma^2$$

**Observação:**

$$\hat{\beta} \sim N\left[\beta, \sigma^2 \frac{\mathbf{Q}^{-1}}{n}\right]$$

ou

$$\hat{\beta} \sim N[\beta, \sigma^2 \mathbf{X}^T \mathbf{X}^{-1}]$$

A variância assintótica de  $\hat{\beta}$  é:

$$AsyVar[\hat{\beta}] = s^2 (\mathbf{X}^T \mathbf{X})^{-1}$$

exatamente igual à da amostra finita.

### 3.5 Eficiência assintótica de $\hat{\beta}$

**Definição:** “um estimador é assintoticamente eficiente quando ele é **consistente**, **assintoticamente normalmente distribuído** e tem uma **matriz de variância-covariância assintótica que não é maior que nenhuma outra matriz de variância-covariância assintótica de um outro estimador** nas mesmas condições, isto é, **consistente e normalmente assintoticamente distribuído**”.

Já vimos que o vetor  $\hat{\beta}$  dos MQO é consistente, normalmente distribuído. Além dessas propriedades assintóticas, é provado que **a matriz da variância-covariância assintótica é mínima**.

## 4 Prática de Teoria Assintótica

### 4.1 Simulação de Monte Carlo Simples e Propriedades Assintóticas

Nesse exercício trabalharemos com duas variáveis aleatórias,  $x$  e  $z$ , com mesma média e variâncias diferentes.

1. Crie erros aleatórios com distribuição normal, com média zero e variância unitária. Peça as médias para as variáveis  $x$  e  $z$  e para os erros criados para diferentes números de observações (por exemplo, 10, 100, 1000) e verifique que as variâncias das variáveis diminuem à medida que aumenta o número de observações.
2. Crie novas variáveis (variáveis dependentes)  $y$  como função de  $x$  e  $z$ , de cada vez, da seguinte forma:  $y = 20 + 0,6x + \epsilon$  e  $y = 20 + 0,6z + \epsilon$ .
3. Estime os modelos de regressão linear para números diferentes de observações (10, 10, 1000), tanto para  $y = f(x, \epsilon)$  quanto para  $y = f(z, \epsilon)$
4. Crie uma variável  $w$  correlacionada com os erros aleatórios, da seguinte maneira:  $w = 150 + \epsilon$
5. Transforme as variáveis  $x$  e  $z$  de modo a serem correlacionadas com os erros, da seguinte maneira:  $wx = x + 500\epsilon$  e  $wz = z + 5\epsilon$
6. Calcule as médias e teste as correlações entre todas as variáveis e os erros. O que se observa?
7. Estime modelos de regressão linear com os  $y$  criados e as variáveis  $x$ ,  $z$ ,  $w$ ,  $wx$  e  $wz$  para diferentes tamanhos de amostras (10, 100, 1000). Observe a convergência dos parâmetros para cada modelo e discuta com detalhes, segundo o que você conhece sobre a propriedade de consistência do estimador dos MQO.

**Observações Gerais:**

A convergência do estimador dos MQO pode ser compreendida da seguinte forma:

$$\begin{aligned}\hat{\beta} &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} \\ \hat{\beta} &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T (\mathbf{X} \beta + \epsilon) \\ \hat{\beta} &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X} \beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \epsilon \\ \hat{\beta} &= \beta + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \epsilon \\ plim \hat{\beta} &= \beta + plim \left( \frac{\mathbf{X}^T \mathbf{X}}{n} \right)^{-1} \frac{\mathbf{X}^T \epsilon}{n}\end{aligned}\tag{19}$$

**Atenção:** quanto maior a variabilidade na matrix  $\mathbf{X}$ , mais rápida é a convergência.

**Para casa:** crie uma variável  $xk$  muito correlacionada com os erros e repita o procedimento. Conclua.

## Referências

Goldfeld, S. M. and R. E. Quandt (1972). *Nonlinear methods in econometrics*.

Greene, W. H. (2012). *Econometric Analysis* (7th ed.). Pearson Education India.

Leamer, E. E. (1988). 3 things that bother me. *Economic Record* 64(4), 331–335.