

# AULA 10 - MQO em regressão múltipla: Propriedades Estatísticas (Variância)

Econometria I

Área quantitativa - IE/UFRJ

# Variância dos estimadores MQO

- ▶ Vamos incluir mais uma hipótese:

## H1 [Linear nos parâmetros]

$$y = \alpha + \beta_1 x_1 + \dots + \beta_k x_k + u$$

## H2 [Amostragem aleatória]

Temos uma amostra aleatória de  $n$  observações,  
 $\{(x_{i1}, x_{i2}, \dots, x_{ik}; y_i) : i = 1, 2, \dots, n\}$  do modelo populacional

## H3 [Média condicional zero]

$$E(u|x_{i1}, x_{i2}, \dots, x_{ik}) = 0$$

## H4 [Colinearidade não perfeita]

Na amostra (e na população), nenhuma das variáveis independentes é constante, e não há relações lineares exatas entre as variáveis independentes.

## H5 [Homocedasticidade]

$$Var(u|x_{i1}, x_{i2}, \dots, x_{ik}) = \sigma^2$$

# Hipótese H5

- ▶ Adicionar H5 não só simplifica as fórmulas, mas também faz com que o MQO tenha a propriedade de eficiência.
- ▶ A H5 significa que a variância do termo erro  $u$ , condicional as variáveis explicativas, é a mesma para todas as combinações de resultados das variáveis explicativas.
- ▶ Se a variância varia com qualquer uma das três variáveis explicativas, então a heterocedasticidade está presente.
- ▶ As hipóteses H1 a H5 são necessárias para o teorema de Gauss-Markov em regressão múltipla (para dados de corte transversal).

# Variância dos estimadores MQO

- ▶ Usaremos a notação  $\mathbf{x}$  para representar o conjunto de variáveis explicativas  $(x_1, \dots, x_k)$ .
- ▶ De H1 a H3 podemos escrever

$$E(y|\mathbf{x}) = \alpha + \beta_1x_1 + \beta_2x_2 + \dots + \beta_kx_k$$

o que significa que o valor esperado de  $y$ , dado  $\mathbf{x}$ , é linear nos parâmetros e depende de  $(x_1, \dots, x_k)$ .

- ▶ De H5 escrevemos  $Var(y|\mathbf{x}) = \sigma^2$ , o que significa que a variância de  $y$ , dado  $\mathbf{x}$ , não depende dos valores das variáveis independentes.

## Variância dos estimadores MQO

- ▶ Sob H1 a H5, condicionadas aos valores amostrais das variáveis independentes

$$Var(\hat{\beta}_j) = \frac{\sigma^2}{[SQT_j(1 - R_j^2)]}$$

para  $j = 1, 2, \dots, k$ , em que  $SQT_j = \sum_{i=1}^n (x_{ij} - \bar{x}_j)^2$  é a variação amostral total em  $x_j$  e  $R_j^2$  é o R-quadrado da regressão  $x_j$  sobre todas as outras variáveis independentes (incluindo o intercepto).

- ▶ A variância do erro  $\sigma^2$ : quanto maior for  $\sigma^2$  maior será a variância do estimador. Uma forma de reduzir a variância do erro é incluir variáveis explicativas.
- ▶  $SQT_j$ : quanto maior, menor é a  $Var(\hat{\beta}_j)$ . Podemos fazer isso aumentando o tamanho da amostra.
- ▶  $R_j^2$  não é o  $R^2$  da regressão. Um elevado grau de relação linear entre as variáveis explicativas pode levar a variâncias grandes.  $R_j^2 = 1$  está excluído por H4 (multicolinearidade).

## Variância em modelos mal especificados

- ▶ Incluir ou não uma variável particular em um modelo pode ser feita ao analisar o dilema entre viés e variância.
- ▶ Na aula passada vimos o viés produzido pela omissão, vamos agora incluir nesta análise a variância.
- ▶ Suponha o modelo populacional, que satisfaz H1 a H5

$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + u$$

- ▶ Considere dois estimadores de  $\beta_1$ .  
Da regressão múltipla:

$$\hat{y} = \hat{\alpha} + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2$$

Da regressão simples:

$$\tilde{y} = \tilde{\alpha} + \tilde{\beta}_1 x_1$$

## Variância em modelos mal especificados

- ▶ Se  $\beta_2 \neq 0$  vimos na aula anterior que induz ao viés em  $\tilde{\beta}_1$ , assim  $\hat{\beta}_1$  é preferível a  $\tilde{\beta}_1$ , entretanto, se calcularmos a variância

Da regressão múltipla: 
$$Var(\hat{\beta}_1) = \frac{\sigma^2}{[SQT_1(1-R_1^2)]}$$

Da regressão simples: 
$$Var(\tilde{\beta}_1) = \frac{\sigma^2}{SQT_1}$$

Neste caso temos que  $Var(\tilde{\beta}_1)$  é sempre menor que  $Var(\hat{\beta}_1)$

- ▶ Se  $\beta_2 = 0$ , temos que  $\hat{\beta}_1$  e  $\tilde{\beta}_1$  não são viesado, mas  $Var(\tilde{\beta}_1) < Var(\hat{\beta}_1)$ . Neste caso fica claro que a inclusão de uma variável irrelevante causa apenas maior variância.
- ▶ No caso que  $\beta_2 \neq 0$  temos que  $\hat{\beta}_1$  é não viesado e  $\tilde{\beta}_1$  é viesado com  $Var(\tilde{\beta}_1) < Var(\hat{\beta}_1)$

## Estimação de $\sigma^2$

- ▶ Vamos escolher um estimador não viesado de  $\sigma^2$ , que nos permitirá obter estimadores não viesados de  $Var(\beta_j)$ .
- ▶ Como vimos na regressão simples estimar  $\sigma^2$  por  $\hat{u}_i$  leva a um estimador viesado.
- ▶ O estimador não viesado de  $\sigma^2$  no caso geral de regressão múltipla é uma extensão do caso simples

$$\hat{\sigma}^2 = \left( \sum u_i^2 \right) / (n - k - 1)$$

no caso da regressão simples  $k = 1$  por isso descontamos  $(n - 2)$ .

- ▶ O termo  $n - k - 1$  representa os graus de liberdade (gl) do problema geral de MQO com  $n$  observações,  $k$  variáveis independentes e um intercepto.

$$\begin{aligned} gl &= n - (k + 1) \\ &= (\text{número de observações}) - (\text{número de parâmetros estimados}) \end{aligned}$$



# Teorema de Gauss-Markov

- ▶ Sob H1 a H5  $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$ , são os melhores estimadores lineares não viesados e eficientes de  $\beta_1, \beta_2, \dots, \beta_k$
- ▶ É valido apenas para dados de corte transversal