

# AULA 5 - MQO Simples: Variância Desconhecida e Teorema de Gauss-Markov

Econometria I

Área quantitativa - IE/UFRJ

## Estimando $V[\hat{\beta}|X]$ com $\sigma^2$ desconhecida

- ▶ A derivação na aula passada nos mostrou um estimador para a variância de  $\hat{\beta}$

$$V[\hat{\beta}|X] = \frac{\sigma^2}{\sum (x_i - \bar{x})^2}$$

- ▶ No entanto, lembremos que: da hipótese de que  $V[u_i|X] = \sigma^2$ , onde  $\sigma^2$  é um parâmetro populacional e desconhecido.
- ▶ Portanto, precisamos de uma maneira de encontrar (estimar) o parâmetro  $\sigma^2$ :

- ▶ Caso os erros  $u_i$  fossem observados, o que podemos fazer? sendo  $V[u|X] = E(u^2|X) - \underbrace{[E(u|X)]^2}_0 = E(u^2|X) = \sigma^2$ , o

que significa também que vale para o caso não condicional:  $V[u] = E(u^2) = \sigma^2$ , assim uma estimativa inicial seria

$$\hat{\sigma}^2 = \frac{\sum u_i^2}{n}, \text{ por exemplo?}$$

- ▶ No entanto, não observamos  $\sum u_i^2$

## Estimando $V[\hat{\beta}|X]$ com $\sigma^2$ desconhecida

- ▶ Uma alternativa consiste em utilizar os resíduos  $\hat{u}_i = \hat{y}_i - y_i$  em lugar de  $u_i$ . Teríamos então o seguinte estimador:

$$\hat{\sigma}^2 = \sum \frac{\hat{u}_i^2}{n}$$

o qual é computável.

- ▶ O problema é que este estimador é **viesado**. A nossa estratégia a partir de agora será:
  - ▶ Mostrar que o estimador acima é viesado.
  - ▶ Ao mostrar isso, identificaremos o viés e conseguiremos sugerir um **novo estimador não viesado**.

## Estimando $V[\hat{\beta}|X]$ com $\sigma^2$ desconhecida

- ▶ Primeiro, vamos montar a seguinte equação:

$$(i) \quad y_i = \hat{\alpha} + \hat{\beta}x_i + \hat{u}_i$$

$$(ii) \quad y_i = \alpha + \beta x_i + u_i$$

Fazendo (i)=(ii):

$$\hat{u}_i = u_i - (\hat{\alpha} - \alpha) - (\hat{\beta} - \beta)x_i \quad (1)$$

- ▶ Ou seja, escrevemos  $\hat{u}_i$  em função de  $u_i$  populacional (não observado). Agora, tomemos a média da equação acima:

$$\sum \frac{\hat{u}_i}{n} = \sum \frac{u_i}{n} - (\hat{\alpha} - \alpha) - (\hat{\beta} - \beta) \sum \frac{x_i}{n}$$

- ▶ Temos então:

$$0 = \bar{u} - (\hat{\alpha} - \alpha) - (\hat{\beta} - \beta)\bar{x} \quad (2)$$

## Estimando $V[\hat{\beta}|X]$ com $\sigma^2$ desconhecida

- ▶ Subtraindo (1)-(2), temos:

$$\hat{u}_i = (u_i - \bar{u}) - (\hat{\beta} - \beta)(x_i - \bar{x})$$

E, elevando os dois lados ao quadrado:

$$\hat{u}_i^2 = (u_i - \bar{u})^2 + (\hat{\beta} - \beta)^2(x_i - \bar{x})^2 - 2(u_i - \bar{u})(\hat{\beta} - \beta)(x_i - \bar{x})$$

Tomando o somatório dos dois lados em  $i = 1, \dots, n$ :

$$\begin{aligned} \sum \hat{u}_i^2 &= \underbrace{\sum (u_i - \bar{u})^2}_{(a)} + \underbrace{\sum (\hat{\beta} - \beta)^2(x_i - \bar{x})^2}_{(b)} \\ &\quad - 2 \underbrace{\sum (u_i - \bar{u})(\hat{\beta} - \beta)(x_i - \bar{x})}_{(c) = -2(\hat{\beta} - \beta) \sum (x_i - \bar{x})u_i} \end{aligned}$$

- ▶ Agora, basta tomar o valor esperado dos dois lados da expressão acima:

## Estimando $V[\hat{\beta}|X]$ com $\sigma^2$ desconhecida

- ▶ Vamos tomar o valor esperado de cada termo separadamente, a começar pelo primeiro:

$$(a) : \sum (u_i - \bar{u})^2 = \sum u_i^2 - n\bar{u}^2 \quad \text{ver apêndice A.7 Wooldridge}$$

Fazendo para cada um dos dois termos acima:

$$E[\sum u_i^2] = \sum E[u_i^2] = n\sigma^2$$

$$E[-n\bar{u}^2] = -nE[\bar{u}^2] = -n \underbrace{[E\bar{u}^2 - \underbrace{(E(\bar{u}))^2}_0]}_{\sigma^2/n} = -n \frac{\sigma^2}{n} = -\sigma^2$$

- ▶ Logo, fechamos o primeiro termo:

$$E[(a)] = E[\sum (u_i - \bar{u})^2] = n\sigma^2 - \sigma^2 = (n - 1)\sigma^2$$

## Estimando $V[\hat{\beta}|X]$ com $\sigma^2$ desconhecida

- ▶ Para o segundo termo:

$$(b) : \sum (\hat{\beta} - \beta)^2 (x_i - \bar{x})^2$$

$$E\left[\sum (\hat{\beta} - \beta)^2 (x_i - \bar{x})^2\right] = \sum (x_i - \bar{x})^2 \underbrace{E[(\hat{\beta} - \beta)^2]}_{\frac{\sigma^2}{\sum (x_i - \bar{x})^2}} = \sigma^2$$

- ▶ Assim:  $E[(b)] = \sigma^2$
- ▶ Por fim, com relação ao terceiro termo, é possível mostrar também que:

$$\begin{aligned} E[(c)] &= E\left[-2(\hat{\beta} - \beta) \sum (x_i - \bar{x})u_i\right] \\ &= -2E[(\hat{\beta} - \beta)^2] \sum (x_i - \bar{x})^2 = -2\sigma^2 \end{aligned}$$

## Estimando $V[\hat{\beta}|X]$ com $\sigma^2$ desconhecida

- ▶ Logo, podemos concluir que o valor esperado da expressão abaixo:

$$\begin{aligned}\sum \hat{u}_i^2 &= \underbrace{\sum (u_i - \bar{u})^2}_{(a)} + \underbrace{\sum (\hat{\beta} - \beta)^2 (x_i - \bar{x})^2}_{(b)} \\ &\quad - 2 \underbrace{\sum (u_i - \bar{u})(\hat{\beta} - \beta)(x_i - \bar{x})}_{(c) = -2(\hat{\beta} - \beta) \sum (x_i - \bar{x})u_i}\end{aligned}$$

- ▶ Pode ser escrito como:

$$E\left[\sum \hat{u}_i^2\right] = E[(a)] + E[(b)] + E[(c)] = (n-1)\sigma^2 + \sigma^2 - 2\sigma^2 = (n-2)\sigma^2$$

- ▶ Neste caso, notem que o estimador

$$\hat{\sigma}^2 = \sum \frac{\hat{u}_i^2}{n} = \frac{SQR}{n} \rightarrow \text{viesado, já que } \frac{(n-2)}{n}\sigma^2 \neq \sigma^2$$

- ▶ Qual seria então um estimador não viesado para  $\sigma^2$ ?

## Estimando $V[\hat{\beta}|X]$ com $\sigma^2$ desconhecida

- ▶ Agora ficou fácil ver que o estimador

$$\hat{\sigma}^2 = \sum \frac{\hat{u}_i^2}{n-2} = \frac{SQR}{n-2} \rightarrow \text{n\~{a}o viesado, j\~{a} que } \frac{(n-2)}{n-2} \sigma^2 = \sigma^2$$

- ▶ Agora que j\~{a} encontramos um estimador n\~{a}o viesado e comput\~{a}vel para o par\~{a}metro populacional  $\sigma^2$ , podemos sugerir o seguinte estimador para  $V[\hat{\beta}|X]$ :

$$V[\hat{\beta}|X] = \frac{\hat{\sigma}^2}{\sum (x_i - \bar{x})^2} = \frac{\frac{SQR}{n-2}}{\sum (x_i - \bar{x})^2}$$

- ▶ J\~{a} temos ent\~{a}o todos os elementos para computar  $V[\hat{\beta}|X]$ .

## Re-interpretando o estimador de MQO

- ▶ Antes de enunciar e provar o Teorema de Gauss-Markov, é útil refazer algumas contas de modo diferente de forma a revelar interpretações alternativas sobre o MQO. Defina:

$$\hat{\beta} = \sum k_i y_i, \text{ onde } k_i = \frac{(x_i - \bar{x})}{\sum (x_i - \bar{x})^2}$$

- ▶ Aqui vemos claramente uma implicação da hipótese de linearidade no modelo populacional:  $\hat{\beta}$  é uma função linear de  $y_i$ . Mais precisamente, é uma média ponderada dos  $y_i$ , onde os pesos são dados por  $k_i = \frac{(x_i - \bar{x})}{\sum (x_i - \bar{x})^2}$
- ▶ Vejamos algumas propriedades desses pesos. Vocês podem prova-las como exercício:
  1.  $\sum k_i = 0$ , pois  $\sum x_i - \sum \bar{x} = \sum x_i - n \sum x_i/n = 0$
  2.  $\sum k_i^2 = \frac{1}{\sum (x_i - \bar{x})^2}$
  3.  $\sum k_i (x_i - \bar{x}) = \sum k_i x_i = 1$

## Re-interpretando o estimador de MQO

- ▶ Notem também que:

$$\sum k_i y_i = \sum k_i (\alpha + \beta x_i + u_i) = \underbrace{\alpha \sum k_i}_0 + \beta \underbrace{\sum k_i x_i}_1 + \sum k_i u_i$$

$$\sum k_i y_i = \beta + \sum k_i u_i$$

- ▶ Assim, vocês podem tomar o valor esperado e a variância da expressão acima para encontrar as propriedades estatísticas do MQO novamente. Se valem as hipóteses enunciadas até aqui:

$$E[\hat{\beta}|X] = \beta + \underbrace{\sum k_i E[u_i|X]}_0 = \beta$$

$$V[\hat{\beta}|X] = E[(\hat{\beta} - \underbrace{E(\hat{\beta})}_\beta)^2 | X] = E[(\hat{\beta} - \beta)^2 | X] = E[\sum (k_i u_i)^2 | X]$$

# Re-interpretando o estimador de MQO

Desenvolvendo o somatório

$$E[\sum (k_i u_i)^2 | X] = \\ E[k_1^2 u_1^2 + k_2^2 u_2^2 + \dots + k_n^2 u_n^2 + 2k_1 k_2 u_1 u_2 + \dots + 2k_{n-1} k_n u_{n-1} u_n | X]$$

Onde:

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

$$E[u_i u_j] = 0 \quad \forall i \neq j$$

► Logo:

$$V[\hat{\beta} | X] = \sigma^2 \sum k_i^2 = \frac{\sigma^2}{\sum (x_i - \bar{x})^2}$$

# Teorema de Gauss-Markov

## Theorem (Gauss-Markov)

*Sejam as hipóteses clássicas de um modelo de Regressão Linear*

1. *Linearidade:  $y = \alpha + \beta x + u$*
2. *Amostragem aleatória  $(x_i, y_i)$ ;  $i = 1, \dots, n$ . A amostra é suficientemente grande, com variação em  $x$ .*
3. *Independência entre  $x$  e  $u$ ,  $E[u] = 0$  e  $E[u|X] = 0$ .*
4. *Homocedasticidade:  $Var(u|X) = \sigma^2$*

*Então os estimadores por MQO são BLUE/MELNV (Best Linear Unbiased Estimator/Melhor Estimador Linear Não Viesado). Ou seja, na classe dos estimadores lineares não viesados, são aqueles com variância mínima (mais eficientes).*

## Teorema de Gauss-Markov

*Prova:*

Seja  $\hat{\beta}_{MQO} = \sum k_i y_i$ , onde  $k_i$  é o fator de ponderação do MQO.

Defina um  $\hat{\beta}_{alternativo} = \beta^* = \sum w_i y_i$ , onde  $w_i$  é um fator alternativo a  $k_i$ . Logo:

$$E[\beta^* | X] = \sum w_i (\alpha + \beta x_i + u_i) = \alpha \sum w_i + \beta \sum w_i x_i + \sum w_i u_i$$

Além da independência entre  $x$  e  $u$ , para  $\beta^*$  ser não viesado precisamos  $\sum w_i = 1$  e  $\sum w_i x_i = 1$ .

Já que sob as condições acima ambos os estimadores são não viesados, agora temos que comparar suas variâncias para ver qual é o mais eficiente. Fazendo:

$$V(\beta^*) = Var(\sum w_i y_i) = \sum w_i^2 Var(y_i) = \sigma^2 \sum w_i^2$$

## Teorema de Gauss-Markov

*Continuação da prova:* como visto acima  $V(\beta^*) = \sigma^2 \sum w_i^2$   
Defina uma  $w_i = k_i + d_i$ , sendo  $k_i$  constante e  $d_i$  constante arbitrária.

$$\begin{aligned}V(\beta^*) &= \sigma^2 \sum (k_i + d_i)^2 \\&= \sigma^2 \left( \sum k_i^2 + \sum d_i^2 + 2 \sum k_i d_i \right) \\&= \sigma^2 \sum k_i^2 + \sigma^2 \sum d_i^2 + \sigma^2 2 \sum k_i d_i\end{aligned}$$

onde  $\sigma^2 \sum k_i^2 = V(\hat{\beta})$

$$\sum k_i d_i = \sum k_i (w_i - k_i) = \sum k_i w_i - \sum k_i^2 =$$

$$\sum w_i \frac{(x_i - \bar{x})}{\sum (x_i - \bar{x})^2} - \frac{1}{\sum (x_i - \bar{x})^2} = \frac{\sum w_i x_i - \bar{x} \sum w_i}{\sum (x_i - \bar{x})^2} - \frac{1}{\sum (x_i - \bar{x})^2} = 0$$

Assim

$$V(\beta^*) = V(\hat{\beta}) + \sigma^2 \sum d_i^2$$

para ser mínima a variância o  $d_i = 0$  o que implica que  $w_i = k_i$

# Teorema de Gauss-Markov

*Continuação da prova:*

Concluindo: não existe qualquer outro fator de ponderação melhor que o de MQO (isto é, não existe um estimador que seja simultaneamente não viesado e mais eficiente que o MQO).