

ACH3657

# Métodos Quantitativos para Avaliação de Políticas Públicas

Aula Teórica 10  
Regressão Múltipla: Inferência

Alexandre Ribeiro Leichsenring  
[alexandre.leichsenring@usp.br](mailto:alexandre.leichsenring@usp.br)



## 1 Regressão Múltipla: Inferência

- Distribuição amostral dos estimadores MQO
- Testando hipóteses sobre um parâmetro populacional

- Problema: testar hipóteses sobre parâmetros do modelo de regressão populacional
- Vamos descobrir a distribuição amostral dos estimadores MQO
- Adicionar hipótese: normalidade dos termos de erro

## Distribuição amostral dos estimadores MQO

- Conhecer o valor esperado e a variância dos estimadores MQO é útil para descrever a precisão dos estimadores MQO
- Entretanto, para realizar inferência estatística, precisamos conhecer mais sobre a sua distribuição
- Precisamos conhecer a distribuição amostral inteira de  $\hat{\beta}_j$ .
- Sob as hipóteses de Gauss-Markov (RLM.1 a RLM.5), pode ter qualquer forma

## Hipótese RLM.6 (Normalidade)

O termo de erro populacional  $u$  é independente das variáveis explicativas  $x_1, x_2, \dots, x_k$  e tem distribuição Normal com média 0 e variância  $\sigma^2$ :

$$u \sim N(0, \sigma^2)$$

- Suposição RLM.6 é bem mais forte do que qualquer outra das suposições anteriores
- De fato, sob RLM.6  $u$  é independente, e portanto:

$$\begin{aligned} \mathbf{E}(u|x_1, x_2, \dots, x_k) &= \mathbf{E}(u) = 0 \\ \mathbf{Var}(u|x_1, x_2, \dots, x_k) &= \mathbf{Var}(u) = \sigma^2 \end{aligned}$$

- Logo, se assumimos RLM.6, estamos necessariamente assumindo RLM.3 e RLM.5.
- As 6 hipóteses RLM.1 a RLM.6 são chamadas de suposições do **modelo linear clássico (MLC)**

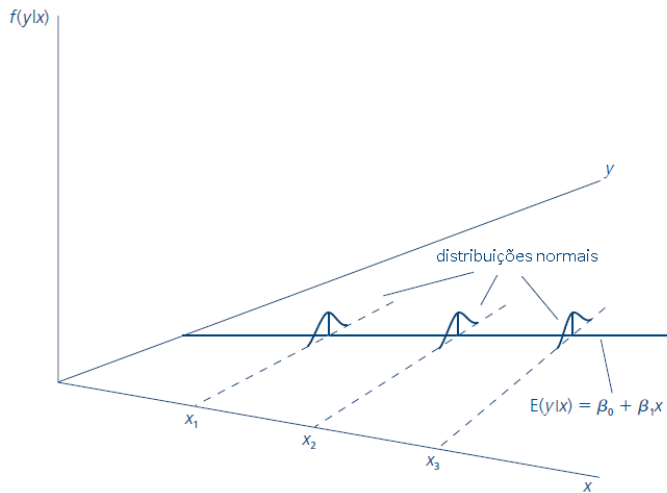
- Sob as suposições CLM, os estimadores MQO  $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$  têm propriedades de eficiência mais fortes do que sob as hipóteses de Gauss-Markov
- Pode-se mostrar que os estimadores MQO são os estimadores de variância mínima (MQO têm a menor variância entre todos os estimadores não viesados)
- Uma maneira sucinta de resumir as suposições MLC:

$$y|\mathbf{x} \sim N(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k, \sigma^2)$$

onde  $\mathbf{x} = (x_1, x_2, \dots, x_k)$

⇒ Condicional em  $\mathbf{x}$ ,  $y$  tem distribuição normal com média linear em  $x_1, x_2, \dots, x_k$  e variância constante

## A distribuição normal homoscedástica com uma variável explicativa



- Argumentos justificando normalidade vão na seguinte linha:
  - ▶ Sendo  $u$  a soma de vários fatores não observados diferentes afetando  $y$ , podemos invocar o teorema central do limite para concluir que  $u$  tem distribuição normal
- Tem seu mérito, mas também fragilidades:
  - ▶ Os fatores  $u$  podem ter distribuições muito diferentes na população (e.g: habilidade e qualidade da educação no termo de erro numa equação de salário)
  - ▶ Embora o teorema central do limite possa valer nesses casos, a aproximação normal pode ser pobre dependendo de quantos fatores aparecem em  $u$  e suas distribuições
  - ▶ Um problema mais sério com esse argumento é que ele assume que todos os fatores afetam  $y$  de uma maneira separada, aditiva (nada garante isso)
  - ▶ Se  $u$  é uma função complicada dos fatores não observados, o teorema central do limite não se aplica



- Em qualquer aplicação, a validade da suposição da normalidade é realmente um problema empírico. Não há, por exemplo, nenhum teorema que afirme que

$$\text{salario} | \text{educ}, \text{exper}, \text{perm} \sim \text{Normal}$$

- O simples raciocínio sugere que o oposto é verdade:
  - ▶ Como o salário não pode ser menor do que zero, não pode, estritamente falando, ter distribuição normal
  - ▶ Além disso, como há lei que rege salário mínimo, uma fração da população recebe salário mínimo, o que viola suposição de normalidade
- Para propósitos práticos, podemos perguntar se o salário condicional tem distribuição “aproximadamente” normal
- Evidências passadas sugerem que normalidade não é uma boa suposição para salário
- Frequentemente, tomar uma transformação (log, especialmente) resulta numa distribuição que é próxima da normal

- Há exemplos em que RLM.6 é claramente falsa
- Quando  $y$  assume apenas alguns poucos valores, não pode ter distribuição normal
- A variável *narr86* (número de vezes que um jovem é preso) é um bom exemplo:
  - ▶ número inteiro
  - ▶ pequena amplitude
  - ▶ zero para a maior parte dos indivíduos

⇒ Longe de ter distribuição normal!

- O que pode ser feito nesses casos?
- Para *amostras grandes*, esse desvio não é um grande problema (veremos adiante)

- Normalidade do termo de erro se traduz em distribuição amostral normal dos estimadores de MQO

### Teorema 1 (Distribuição Amostral Normal)

Sob as suposições RLM.1 a RLM.6, condicional aos valores amostrais das variáveis independentes:

$$\hat{\beta}_j \sim N(\beta_j, \text{Var}(\hat{\beta}_j))$$

Portanto:

$$\frac{(\hat{\beta}_j - \beta_j)}{\text{dp}(\hat{\beta}_j)} \sim N(0, 1)$$

*Obs.* Desvio padrão de  $\hat{\beta}_j$ :

$$\text{dp}(\hat{\beta}_j) = \frac{\sigma}{[\text{SQT}_j(1 - R_j^2)]^{1/2}}$$

Sendo  $\sigma$  desconhecido, o substituímos pelo seu estimador  $\hat{\sigma}$ . Isso nos dá o erro-padrão de  $\hat{\beta}_j$ :

$$\text{ep}(\hat{\beta}_j) = \frac{\hat{\sigma}}{[\text{SQT}_j(1 - R_j^2)]^{1/2}}$$

## Teorema 2 (Distribuição dos estimadores padronizados)

Sob as suposições RLM.1 a RLM.6:

$$\frac{(\hat{\beta}_j - \beta_j)}{\text{ep}(\hat{\beta}_j)} \sim t_{n-k-1}$$

- $k + 1$  é o número de parâmetros do modelo populacional

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$$

- $t_{n-k-1}$  é a distribuição  $t$ -student com  $n - k - 1$  graus de liberdade.

- ▶ A distribuição  $t$  no Teorema 2 vem do fato que a constante  $\sigma$  foi substituída pelo seu estimador  $\hat{\sigma}$ .

- O modelo populacional pode ser escrito como:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$$

- Vamos assumir que o modelo satisfaz as suposições MLC
- Sabemos que os estimadores MQO produzem estimativas não viesadas dos  $\beta_j$
- Vamos ver como testar hipóteses sobre um  $\beta_j$  particular
- Lembremos:  $\beta_j$  são desconhecidos e nunca conheceremos com exatidão
- Entretanto, podemos criar hipóteses sobre seu valor e usar a inferência estatística para testar essas hipóteses

## Testando hipóteses sobre um parâmetro populacional

- Na maioria das aplicações, nosso interesse se concentra em testar a hipótese nula:

$$H_0 : \beta_j = 0$$

- Como  $\beta_j$  mede o efeito parcial de  $x_j$  em  $y$  (controladas todas as outras variáveis independentes),  $H_0$  significa que, controlados os efeitos de

$$x_1, x_2, \dots, x_{j-1}, x_{j+1}, \dots, x_k$$

$x_j$  não tem efeito nenhum no valor esperado de  $y$

## Exemplo

Considere a equação de salário:

$$\log(\text{salario}) = \beta_0 + \beta_1 \text{educ} + \beta_2 \text{exper} + \beta_3 \text{perm} + u$$

- A hipótese nula  $H_0 : \beta_2 = 0$  significa que, uma vez controlados educação e permanência no emprego, o número de anos de experiência não tem efeito no salário hora.
- É uma hipótese socialmente interessante: se for verdade, ela implica que o histórico da pessoa anterior ao atual trabalho não afeta o salário
- Se  $\beta_2 > 0$ , isso significa que a experiência de trabalho prévia contribui para a produtividade e portanto para o salário

- O teorema 2 enuncia que, sob  $H_0$  ( $\beta_j = 0$ ):

$$\frac{(\hat{\beta}_j - \beta_j)}{\text{ep}(\hat{\beta}_j)} = \frac{\hat{\beta}_j}{\text{ep}(\hat{\beta}_j)} \sim t_{n-k-1}$$

- Assim, se  $H_0$  for verdadeira a distribuição da estatística

$$t_{\hat{\beta}_j} = \frac{\hat{\beta}_j}{\text{ep}(\hat{\beta}_j)}$$

é  $t$ -student com  $n - k - 1$  graus de liberdade

- $t_{\hat{\beta}_j}$  é simples de calcular dados  $\hat{\beta}_j$  e o erro padrão  $\text{ep}(\hat{\beta}_j)$  (computados pelos pacotes estatísticos)
- Em qualquer aplicação interessante, a estimativa pontual  $\hat{\beta}_j$  nunca vai ser exatamente zero (independentemente da validade de  $H_0$ )
- A questão é: quão distante de zero?



- Um valor amostral de  $\hat{\beta}_j$  distante de zero fornece evidência contra  $H_0$
- Como reconhecemos que há erro amostral na nossa estimativa de  $\hat{\beta}_j$ , então é preciso confrontar seu erro amostral
- O erro padrão de  $\hat{\beta}_j$  é uma estimativa do desvio padrão de  $\hat{\beta}_j$ , logo  $t_{\hat{\beta}_j}$  mede quantos desvios padrão (estimados)  $\hat{\beta}_j$  está de zero.
- Valores de  $t_{\hat{\beta}_j}$  *suficientemente distantes* de zero resultam em rejeição de  $H_0$
- A regra de decisão depende da definição da hipótese alternativa e do nível de significância adotado para o teste
- Determinar a regra de decisão para um determinado nível de significância – isto é, a probabilidade de rejeitar  $H_0$  quando  $H_0$  é verdadeira – requer conhecer a distribuição amostral de  $t_{\hat{\beta}_j}$ . Do Teorema 2:

$$t_{\hat{\beta}_j} \sim t_{n-k-1}$$

- Importante lembrar que estamos testando hipóteses sobre os parâmetros populacionais
- Não estamos interessados em testar estimativas de uma amostra particular