

# AULA 12 - Normalidade e Inferência em Regressão Múltipla - Parte 2

Econometria I

Área quantitativa - IE/UFRJ

# Testes de hipóteses sobre combinação linear dos parâmetros

- ▶ Na aula passada testamos hipóteses sobre um único  $\beta_j$  de cada vez.
- ▶ Em algumas aplicações queremos testar mais de um dos parâmetros da população.
- ▶ Vamos começar a análise com um exemplo para comparar os retornos da educação de cursos superiores profissionalizantes de dois anos (cp) e de cursos superiores de quatro anos (univ).

$$\log(\text{salário}) = \alpha + \beta_1 \text{cp} + \beta_2 \text{univ} + \beta_3 \text{exper} + u \quad (1)$$

- ▶ A hipótese de interesse é se um ano no curso profissionalizante é equivalente a um ano na universidade

$$H_0 : \beta_1 = \beta_2$$

sob  $H_0$  um ano a mais no curso profissionalizante e um ano a mais na universidade levam ao mesmo aumento percentual em salário.

# Testes de hipóteses sobre combinação linear dos parâmetros

- ▶ A hipótese alternativa de interesse é unilateral: um ano no curso profissionalizante é menos valioso do que um ano na universidade

$$H_1 : \beta_1 < \beta_2$$

- ▶ Não podemos usar simplesmente as estatísticas  $t$  individuais de  $\beta_1$  e  $\beta_2$  para testar  $H_0$
- ▶ Para fazer o teste reescrevemos

$$H_0 : \beta_1 - \beta_2 = 0$$

$$H_1 : \beta_1 - \beta_2 < 0$$

- ▶ A estatística  $t$  é baseada em se a diferença estimada  $\hat{\beta}_1 - \hat{\beta}_2$  é estatisticamente zero.

## Testes de hipóteses sobre combinação linear dos parâmetros

- ▶ Para considerar o erro de nossos estimadores, padronizamos essa diferença ao dividi-la pelo erro-padrão:

$$t = \frac{\hat{\beta}_1 - \hat{\beta}_2}{ep(\hat{\beta}_1 - \hat{\beta}_2)}$$

Assim o teste segue o procedimento anterior, escolhendo um nível de significância.

- ▶ Nossa única dificuldade neste teste é calcular  $ep(\hat{\beta}_1 - \hat{\beta}_2)$ , que não é fornecido automaticamente nos programas econmétricos. Temos duas formas de calcular:
  - ▶  $ep(\hat{\beta}_1 - \hat{\beta}_2) = \{[ep(\hat{\beta}_1)]^2 + [ep(\hat{\beta}_2)]^2 - 2Cov(\hat{\beta}_1, \hat{\beta}_2)\}^{1/2}$
  - ▶ Estimar um modelo diferente que produz diretamente o erro-padrão de interesse.

## Teste F

- ▶ Agora queremos testar se um grupo de variáveis não tem efeito sobre a variável dependente.
- ▶ Suponha que queremos testar  $q < k + 1$  variáveis, assuma que sejam as  $q$  últimas variáveis:  $x_{k-q+1}, \dots, x_k$ .
- ▶ A hipótese nula testada, será

$$H_0 : \beta_{k-q+1} = 0, \dots, \beta_k = 0$$

- ▶ A hipótese alternativa é

$$H_1 : H_0 \text{ não é verdadeira}$$

- ▶ Em princípio poderíamos fazer um teste  $t$  para cada restrição individualmente, mas isso, pode ser enganoso.
- ▶ Podemos ter resultados em que as estatísticas  $t$  não podem rejeitar  $H_0$  para as  $q$  variáveis, mas quando testamos em conjunto não necessariamente isso pode ser verdade.

## Teste F

- ▶ O que devemos observar para o grupo de variáveis que serão ou não retiradas do modelo será a relação custo-benefício da soma dos resíduos ao quadrado (SQR).
- ▶ Sabemos que o SQR sempre aumenta quando variáveis são retiradas do modelo.
- ▶ A questão é saber se esse aumento é suficientemente grande, relativamente ao SQR do modelo com todas as variáveis.
- ▶ Para fazer o teste F considere dois modelos:
  - ▶ Modelo irrestrito com  $k$  variáveis:

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

- ▶ Modelo restrito com  $q < k$  variáveis:

$$y = \alpha + \beta_1 x_1 + \dots + \beta_{k-q} x_{k-q} + u$$

## Teste F

- ▶ Como dizemos anteriormente olharemos para o aumento relativo em SQR quando nos movemos do modelo irrestrito para o restrito.
- ▶ Neste sentido a estatística F é definida como:

$$F = \frac{(SQR_r - SQR_{ir})/q}{SQR_{ir}/(n - k - 1)}$$

em que  $SQR_r$  é a soma dos resíduos quadrados do modelo restrito e  $SQR_{ir}$  é do modelo irrestrito.

- ▶ Como  $SQR_r$  não pode ser menor que o  $SQR_{ir}$  a estatística  $F$  é sempre não negativa.
- ▶ No numerador de  $F$  temos a divisão por  $q$ , que o número de restrições impostas:

$$q = \text{graus de liberdade do numerador} = gl_r - gl_{ir}$$

- ▶ No denominador do  $F$  temos a divisão pelos graus de liberdade do modelo irrestrito

$$n - k - 1 = \text{graus de liberdade do denominador} = gl_{ir}$$

## Teste F

- ▶ Para usar a estatística  $F$ , devemos conhecer sua distribuição amostral sob a hipótese nula para escolher os valores críticos e as regras de rejeição.
- ▶ Temos que sob  $H_0$  (e assumindo que as hipóteses se mantêm),  $F$  é distribuído como uma variável aleatória  $F$  com  $(q, n - k - 1)$  graus de liberdade.

$$F \sim F_{q, n-k-1}$$

- ▶ A distribuição  $F_{q, n-k-1}$  está tabelada.
- ▶ Da definição de  $F$ , é claro que rejeitaremos  $H_0$  em favor de  $H_1$  quando  $F$  for suficientemente “grande”  $F > c$
- ▶ Se  $H_0$  é rejeitada, dizemos que  $x_{k-q+1}, \dots, x_k$  são estatisticamente significantes conjuntamente.

**EXERCÍCIO:** Usando os dados Wooldridge MLB1.RAW do exemplo do capítulo 4.5 estimar o modelo irrestrito e restrito e fazer o teste  $F$  para as três últimas variáveis do modelo irrestrito.