

# Esta aula

---

## ▶ Plano

- ▶ R-quadrado ajustado
- ▶ Testes de Hipóteses
- ▶ Heterocedasticidade
- ▶ Variáveis binárias

## ▶ Bibliografia

- ▶ Wooldridge, J. M. *Introductory Econometrics: A modern Approach*, 6th Ed.

# R-quadrado Ajustado

# R-quadrado

---

Vimos que o R-quadrado amostral é definido por:

$$R^2 \equiv 1 - \frac{[SQR]}{[SQT]}$$

Já o R-quadrado populacional é definido por:

$$R^2 \equiv 1 - \frac{\sigma_u^2}{\sigma_y^2}$$

# R-quadrado

---

- ▶ Problema: o R-quadrado sempre aumenta com a inclusão de uma variável adicional
- ▶ Já o R-quadrado ajustado é penalizado com o aumento do número de variáveis explicativas incluídas:

$$\begin{aligned}\bar{R}^2 &\equiv 1 - \frac{[SSR/(n - k - 1)]}{[SST/(n - 1)]} \\ &= 1 - \frac{\hat{\sigma}^2}{[SST/(n - 1)]}\end{aligned}$$

# R-quadrado

---

- ▶ O R-quadrado ajustado pode ser utilizado para comparar o poder explicação de dois modelos diferentes com a mesma variável dependente  $y$ . Porém, apenas a teoria de RI pode prever quais variáveis poderiam ser incluídas.
- ▶ Uma variável nunca deve ser incluída apenas porque aumenta o R-quadrado ajustado se não existe uma justificativa teórica para a sua inclusão.

# Testes de Hipóteses

# Regressão Linear - Inferência

---

- Para realizar testes de hipóteses, assumimos que  $u$  tem distribuição normal com média 0 e variância constante.

- Nesse caso, 
$$\frac{(\hat{\beta}_j - \beta_j)}{se(\hat{\beta}_j)} \sim t_{n-k-1}$$

- **IMPORTANTE:** Mesmo que  $u$  não tenha distribuição normal, se a amostra for relativamente grande as estatísticas  $t$  e  $F$  usuais tem uma distribuição que converge para as distribuições  $t$ -student e  $F$ .

# Regressão Linear - Inferência

---

- Podemos testar hipóteses com relação aos parâmetros populacionais
- Para isso, precisamos calcular o desvio-padrão associado aos estimadores.

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{SST_j(1 - R_j^2)}, \text{ onde}$$



# Regressão Linear Simples - Inferência

---

➤ Estamos prontos para testar hipóteses com relação aos valores dos parâmetros populacionais

➤ Exemplo:

$$H_0: \beta = 0$$

$$H_1: \beta \neq 0$$

# Regressão Linear - Inferência

---

➤ A estatística do teste é:

$$t = \frac{(\hat{\beta}_j)}{se(\hat{\beta}_j)}$$

# Teste de Hipótese


---

- ▶ As etapas do teste são:
  1. Escrever as hipóteses alternativas e nulas
  2. Escolher o nível de significância do teste  $\alpha$
  3. Calcular a estatística  $t$ , conhecida como a **estatística do teste**
  4. Encontrar o **valor crítico** do teste  $t^*$ ,
  5. Decidir: Se o valor absoluto de  $t$  for maior do que o de  $t^*$ , rejeitar  $H_0$  com um nível de confiança de  $1-\alpha$  (**teste bicaudal**)

# Regressão Linear - Inferência

## Valores Críticos


FIGURE 4.4 5% rejection rule for the alternative  $H_1: \beta_j \neq 0$  with 25 *df*.



# Regressão Linear - Inferência

$$\text{P-value: } P(|T| > |t|)$$

FIGURE 4.6 Obtaining the  $p$ -value against a two-sided alternative, when  $t = 1.85$  and  $df = 40$ .



# Regressão Linear - Inferência

---

➤ Podemos também testar hipóteses conjuntas:

➤ Exemplo:

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

$$H_1: H_0 \text{ não é verdadeira}$$

Ou, equivalentemente,

$$H_0: y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_{k-q} x_{k-q} + u$$

$$H_1: y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_{k-q} x_{k-q} + \beta_{k-q+1} x_{k-q+1} + \dots + \beta_k x_k + u$$

# Regressão Linear - Inferência

---

A estatística do teste é dada por:

$$F \equiv \frac{(\text{SSR}_r - \text{SSR}_{ur})/q}{\text{SSR}_{ur}/(n - k - 1)}$$

Onde:

$\text{SSR}_r$  é a soma do quadrado dos resíduos do modelo restrito (sob  $H_0$ );

$\text{SSR}_{ur}$  é a soma do quadrado dos resíduos do modelo irrestrito (sob  $H_1$ );

$Q$  é o número de restrições;

$K+1$  é o número de parâmetros estimados.



# Teste de Hipótese

---


▶ As etapas do teste são:

1. Escrever as hipóteses alternativas e nulas
2. Escolher o nível de significância do teste  $\alpha$
3. Calcular a estatística  $F$ , conhecida como a **estatística do teste**
4. Encontrar o **valor crítico** do teste  $F^*$ ,
5. Decidir: Se o valor de  $F$  for maior do que o de  $F^*$ , rejeitar  $H_0$  com um nível de confiança de  $1-\alpha$



# Regressão Linear - Inferência

FIGURE 4.7 The 5% critical value and rejection region in an  $F_{3,60}$  distribution.



# Regressão Linear Simples - Inferência

---

- Se  $SSR = SST \cdot (1 - R^2)$ , a estatística  $F$  também pode ser reescrita como:

$$F = \frac{(R_{ur}^2 - R_r^2)/q}{(1 - R_{ur}^2)/(n - k - 1)}$$

# Regressão Linear Simples - Inferência

---

➤ E podemos testar o poder de explicação do modelo:

$H_0$  : todos os parâmetros (com exceção do intercepto) são equivalentes a zero

$H_1$  : pelo menos um dos parâmetros (com exceção do intercepto) é diferente de zero.

➤ Nesse caso, a estatística do teste é:

$$F = \frac{R^2 / k}{(1 - R^2) / (n - k - 1)}$$


# Heterocedasticidade

# Revisão: Homocedasticidade

---

- ▶ O pressuposto de homocedasticidade significa que a variância do erro não-observável é constante e independente do valor das variáveis explicativas

# Exemplo de Heterocedasticidade



# Consequências da Heterocedasticidade

---

- ▶ MQO é não-enviesado mesmo na presença de heterocedasticidade.
- ▶ Porém, nesse caso, os erros padrões são viesados.
- ▶ Portanto, as estatísticas  $t$  e  $F$  não são válidas.

# Variância com Homocedasticidade

---

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{s_x^2}$$



# Variância com Homocedasticidade

---

- ▶ Quanto maior a variância do erro, maior a variância do estimador beta
- ▶ Quanto maior a variabilidade de  $x$ , menor essa variância.

# Variância com Homocedasticidade

---

Um estimador não-enviesado de  $\sigma^2$  é:

$$\hat{\sigma}^2 = \frac{1}{(n-2)} \sum \hat{u}_i^2 = \text{SQR} / (n-2)$$

# Variância com Homocedasticidade

---

## Regressão Múltipla

Dados os pressupostos de Gauss-Markov, tem-se:

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{SST_j (1 - R_j^2)}, \text{ onde}$$

$$SST_j = \sum (x_{ij} - \bar{x}_j)^2 \text{ e } R_j^2 \text{ é o } R^2 \text{ da}$$

*regressão de  $x_j$  nos demais  $x$ 's*

# Heterocedasticidade

---

Importante: se o modelo tiver heterocedasticidade e os demais 4 pressupostos de Gauss-Markov continuarem válidos, o estimador MQO continua não-enviesado porém não é mais BLUE!

Além disso, testes de hipóteses baseadas nas variâncias dos parâmetros estimadas por MQO não são mais válidos

# Variância com Heterocedasticidade

---

*Regressão Simples*

$$\text{Var}(\hat{\beta}_1) = \frac{\sum (x_i - \bar{x})^2 \sigma_i^2}{SST_x^2}, \text{ onde } SST_x = \sum (x_i - \bar{x})^2$$

Um estimador convergente ou válido assintoticamente seria:

$$\frac{\sum (x_i - \bar{x})^2 \hat{u}_i^2}{SST_x^2}$$

# Variância com Heterocedasticidade

---

## Regressão Múltipla

$$Var\hat{r}(\hat{\beta}_j) = \frac{\sum \hat{r}_{ij}^2 \hat{u}_i^2}{SSR_j^2}, \text{ onde } \hat{r}_{ij} \text{ é o } i^{\text{th}} \text{ resíduo da}$$

regressão  $x_j$  contra todas as outras variáveis explicativas e  $SSR_j$  é a soma do quadrado dos resíduos dessa regressão.

# Variância com Heterocedasticidade

---

- ▶ A variância e desvio-padrão robusto somente levarão a estatísticas  $t$  e  $F$  válidas se as amostras forem grandes.

# Teste para Heterocedasticidade: Breusch-Pagan

---

- ▶ Queremos testar  $H_0: \text{Var}(u|x_1, x_2, \dots, x_k) = \sigma^2$
- ▶ Se assumirmos uma relação linear entre  $u^2$  e  $x_j$ :  
$$u^2 = \delta_0 + \delta_1 x_1 + \dots + \delta_k x_k + v$$
  
, podemos testar:
- ▶  $H_0: \delta_1 = \delta_2 = \dots = \delta_k = 0$
- ▶ Esse é o teste Breusch-Pagan.



# Teste White

---

- ▶ O Teste White permite que a heterocedasticidade dependa das variáveis explicativas ao quadrado e produtos cruzados.
- ▶ Para simplificar o teste, procedemos da seguinte forma:

# Teste White

---

- ▶ Fazemos a regressão dos resíduos ao quadrado nos valores de  $\hat{y}$  e  $\hat{y}^2$  e fazemos um teste F no R-quadrado

# Mínimos Quadrados Ponderados

---

- ▶ Apesar de conseguirmos obter erros padrões robustos, se soubermos a forma funcional da heterocedasticidade, podemos obter estimativas mais eficientes.
- ▶ O métodos dos mínimos quadrados ponderados (MQP) ou weighted least squares (WLS) permite transformar o modelo tal que ele tenha erros homocedásticos, soubermos a forma exata da heterocedasticidade. Nesse caso WLS is BLUE!
- ▶ Assim como em MQO, os testes  $t$  e  $F$  são assintoticamente válidos ou exatamente válidos se os erros possuírem distribuição Normal.

# Mínimos Quadrados Ponderados

---

- ▶ Suponha que a heterocedasticidade seja da seguinte forma:  $\text{Var}(u|\mathbf{x}) = \sigma^2 h(\mathbf{x})$ ,
- ▶ Dividindo todas as variáveis por  $\sqrt{h}$ , obtemos um modelo com erros homocedásticos:

$$y_i/\sqrt{h_i} = \beta_0/\sqrt{h_i} + \beta_1(x_{i1}/\sqrt{h_i}) + \beta_2(x_{i2}/\sqrt{h_i}) + \dots \\ + \beta_k(x_{ik}/\sqrt{h_i}) + (u_i/\sqrt{h_i})$$

- ▶ Nesse caso,  $\text{Var}(u_i/\sqrt{h_i}|\mathbf{x}) = \sigma^2$ , visto que:

$$E((u_i/\sqrt{h_i})^2) = E(u_i^2)/h_i = (\sigma^2 h_i)/h_i = \sigma^2,$$

# Mínimos Quadrados Ponderados

---

- ▶ Porém, o método dos mínimos quadrados ponderados já está programado no Stata.
- ▶ Apenas declare o peso  $1/h_i$  para efetuar a estimação (no stata declare `[aweight=hi]`).

# FGLS

---

- ▶ Se não soubermos  $h(\mathbf{x}_i)$ , podemos estimar essa função
- ▶ Assume-se:  
$$\text{Var}(u|\mathbf{x}) = \sigma^2 \exp(\delta_0 + \delta_1 x_1 + \dots + \delta_k x_k)$$
- ▶ e estima-se  $\delta$ !

# FGLS

---

► Portanto:

$$u^2 = \sigma^2 \exp(\delta_0 + \delta_1 x_1 + \dots + \delta_k x_k) v$$

onde  $E(v|\mathbf{x}) = 1$

Equivalentemente:

$$\ln(u^2) = \alpha_0 + \delta_1 x_1 + \dots + \delta_k x_k + e$$

# FGLS

---

- ▶ Portanto, devemos adotar o seguinte procedimento:
  1. Estimar o modelo por MQO
  2. Obter os resíduos,  $\hat{u}$
  3. Gerar  $\ln(\hat{u}^2)$
  4. Fazer a regressão de  $\ln(\hat{u}^2)$  nas variáveis independentes e obter os valores previstos  $\hat{g}$ . A variancia estimada é equivalente a  $\exp(\hat{g})$ .
  5. Fazer a regressão pelo método dos mínimos quadrados ponderados com peso  $\exp(\hat{g})$  no Stata. ( $1/\exp(\hat{g})$  sendo o peso para os resíduos ao quadrado).



# FGLS

---

- ▶ FGLS não é não-enviesado, mas ainda consistente e assintoticamente eficiente.

# Variável Binária ou Dummy

# Variável Binária ou “Dummy”

---

- ▶ Uma variável binária é aquela que toma dois valores possíveis, geralmente 0 e 1.
- ▶ No nosso banco de dados trabalhado nas últimas aulas, female é uma variável binária.

# Variável Binária ou “Dummy”

---

▶ Considere o seguinte modelo com uma variável binária:

▶  $y = \beta_0 + \delta_0 d + \beta_1 x + u$

▶ Nesse caso, a variável  $d$  representa uma mudança de intercepto quando se passa de um grupo para o outro do banco de dados.

▶ If  $d = 0$ ,  $y = \beta_0 + \beta_1 x + u$

▶ If  $d = 1$ ,  $y = (\beta_0 + \delta_0) + \beta_1 x + u$

# Variável Binária ou “Dummy”

---

- ▶ Considere agora o seguinte modelo:
- ▶  $y = \beta_0 + \delta_1 d + \beta_1 x + \delta_2 d * x + u$
- ▶ If  $d = 0$ ,  $y = \beta_0 + \beta_1 x + u$
- ▶ If  $d = 1$ ,  $y = (\beta_0 + \delta_1) + (\beta_1 + \delta_2) x + u$
- ▶ Nesse modelo, a variável dummy permite uma mudança de intercepto, bem como uma mudança de inclinação.

# Modelo Linear de Probabilidade

---

- ▶ Se a variável dependente for binária, então  $P(y = 1 | x) = E(y|x)$ . Nesse caso:
- ▶  $P(y = 1 | x) = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k$
- ▶ Nesse caso, cada intercepto beta i mede o impacto de variações marginais em  $x_i$  na probabilidade do evento 1 ocorrer.
- ▶ O valor previsto de  $y$  nesse é a probabilidade estimada do evento 1 ocorrer.

# Modelo Linear de Probabilidade

---

- ▶ Problema: nada impede que o  $y$  previsto não esteja no intervalo  $[0, 1]$ .
- ▶ Geralmente, esse modelo viola também o pressuposto de homocedasticidade.

# Avaliação de Políticas/Programas

---

- ▶ Podemos utilizar variáveis dummy para avaliar o impacto de políticas/programas
- ▶ Por exemplo, qual o impacto da participação no programa Bolsa Família no nível educacional da família?



# Avaliação de Políticas/Programas

---

- ▶ Problema: variáveis que influenciam a participação no Bolsa Família, como a renda dos ascendentes, também podem explicar o nível educacional.
- ▶ Isso levaria a viés nas estimações



Obrigada!

