

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 α
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:

SSR_r é a soma do quadrado dos resíduos do modelo restrito (sob H_0);

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 α
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 σ^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

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!

