

# AULA 15 - Heterocedasticidade

## Econometria I

Área quantitativa - IE/UFRJ

# Heterocedasticidade

- ▶ **Questões** que iremos responder:
  - ▶ Como **detectamos** este problema?
  - ▶ Quais são as **consequências** nas propriedades dos estimadores por mínimos quadrados?
  - ▶ Quais são as **soluções** para este problema?
- ▶ A heteroscedasticidade aparece em várias **aplicações**, tanto em *cross-section* quanto em séries temporais.
- ▶ Observação: em séries de tempo existe uma forma de heterocedasticidade em que o distúrbio depende de próprio distúrbio defasado, sendo usado um método específico para a estimativa, chamado Autoregressivo Condicional a heterocedasticidade (ARCH).

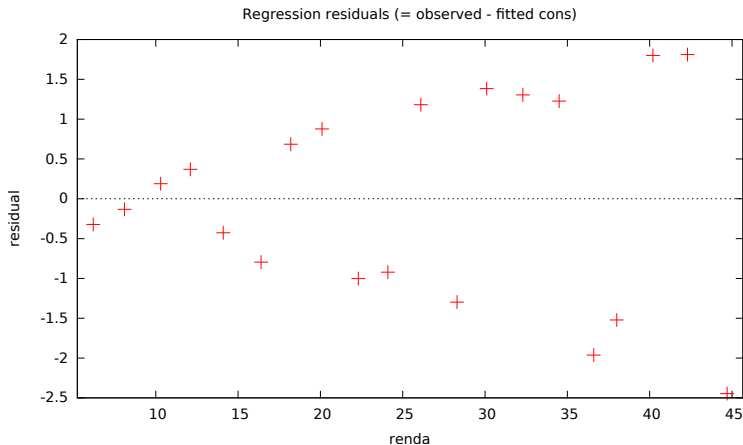
# Heterocedasticidade

## Example (Gastos com consumo e renda para 20 famílias)

Estimando a equação por mínimos quadrados, obtemos:

$$\text{consumo} = 0.847 + 0.899\text{renda} + u$$

(0.703)      (0.025)



# Heterocedasticidade

- ▶ No modelo de regressão **heterocedástico**:

$$\text{Var}[u_i|x_i] = \sigma_i^2, \quad i = 1, \dots, n$$

- ▶ Assumindo que os erros são **não correlacionados**

$$\sigma^2 \Omega = \sigma^2 \begin{bmatrix} \omega_1 & 0 & \cdots & 0 \\ 0 & \omega_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \omega_n \end{bmatrix} = \begin{bmatrix} \sigma_1^2 & 0 & \cdots & 0 \\ 0 & \sigma_2^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_n^2 \end{bmatrix}$$

- ▶ Para facilitar a notação escreveremos  $\sigma_i^2 = \sigma^2 \omega_i$
- ▶ A regressão clássica com erros **homocedásticos** pode ser visto como um **caso especial** em que  $\omega_i = 1, i = 1, \dots, n$

# Teste para heterocedasticidade

O teste geral considera a seguinte hipótese:

$$H_0 : \sigma_i^2 = \sigma^2 \quad \text{para todo } i$$

$$H_1 : \text{Não } H_0.$$

- ▶ É feita a regressão da seguinte forma:  
$$\hat{u}^2 = \delta_0 + \delta_1 x_1 + \delta_2 x_2 + \dots + \delta_k x_k + \epsilon$$
- ▶ A estatística do teste é o  $nR_{\hat{u}^2}^2$  (teste LM multiplicador de Lagrange) em que  $n$  são as observações e  $R_{\hat{u}^2}^2$  é o poder de explicação da regressão acima, distribuída assintoticamente por uma  $\chi^2(k)$ .
- ▶ A versão LM do teste é geralmente chamada teste de BREUSCH-PAGAN da heterocedasticidade.

# Teste para heterocedasticidade

## Example (Gastos com consumo e renda para 20 famílias)

```
model_hetero <- lm((resid(model))^2 ~ renda, data = tutoria2_2019_1)
> summary(model_hetero)
```

Call:

```
lm(formula = (resid(model))^2 ~ renda, data = tutoria2_2019_1)
```

Residuals:

```
      Min       1Q   Median       3Q      Max
-1.1212 -0.2607 -0.1955  0.1335  2.1811
```

Coefficients:

```
              Estimate Std. Error t value Pr(>|t|)
(Intercept) -1.37033    0.38860  -3.526  0.00241 **
renda        0.11580    0.01398   8.282 1.49e-07 ***
```

---

```
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 0.7259 on 18 degrees of freedom

Multiple R-squared: 0.7921, Adjusted R-squared: 0.7806

F-statistic: 68.59 on 1 and 18 DF, p-value: 1.492e-07

0 teste LM=n\*R-squared

```
> 20*0.7921
```

```
[1] 15.842
```

A distribuição  $\chi^2(1)$  para 95% de confiança é 3.84.

O teste foi  $15.842 > 3.84$ , então rejeitamos a hipótese nula de homocedasticidade.

## Outros testes para heterocedasticidade

- ▶ No **teste de White** regredimos  $\hat{u}^2 = \delta_0 + \delta_1 x_1 + \delta_2 x_1^2 + \epsilon$  no caso de regressão simples e incluímos o produto cruzado se for uma regressão múltipla.
- ▶ **Teste Goldfeld-Quandt**
  - ▶ Assume que as observações podem ser divididas em **dois grupos**, tal que a **hipótese nula de homocedasticidade** significa que a **variância dos erros serão as mesmas** nos dois grupos.
  - ▶ A ideia é separar as observações em dois grupos com **alta e baixa variância**.
  - ▶ É estimado separadamente os dois conjuntos de observações.
  - ▶ A **estatística** é

$$F[n_1 - K, n_2 - K] = \frac{u_1' u_1 / (n_1 - K)}{u_2' u_2 / (n_2 - K)}$$

em que assumimos que a variância do erro é maior na primeira amostra. Sob a hipótese nula de homocedasticidade, esta estatística tem distribuição F com  $n_1 - K$  e  $n_2 - K$  graus de liberdade.

# Ineficiência na estimativa por mínimos quadrados

- ▶ Quando **falha a hipótese de homocedasticidade**, temos que o estimador por mínimos quadrados, apesar de ser não viesado ele é **ineficiente**.
- ▶ Em um modelo de regressão simples temos que a inclinação do estimador por mínimos quadrados é escrito como:

$$\hat{\beta} = \beta + \frac{\sum (x_i - \bar{x}) u_i}{\sum (x_i - \bar{x})^2} = \beta + \sum w_i u_i$$

$$E[\hat{\beta}] = E[\beta + \sum w_i u_i] = \beta + \sum w_i E(u_i) = \beta$$

$$V[\hat{\beta}] = V[\sum w_i u_i] = \sum w_i^2 V[u_i] + \sum \sum w_i w_j Cov[u_i, u_j] = \sum w_i^2 \sigma_i^2$$

Se  $\sigma_i^2$  é constante temos a fórmula usual  $\sigma^2 / \sum (x_i - \bar{x})^2$



# Soluções para o problema de heterocedasticidade

- ▶ **Casos simples:** transformar os dados em logaritmo ou fazer o uso de deflatores.
- ▶ Se o tipo de **heterocedasticidade é conhecido** podemos usar o mínimo quadrado generalizado.
- ▶ Se a precisa forma de **heterocedasticidade não é conhecida**, devemos usar técnicas de estimação apropriadas que requerem uma formulação de  $\Omega$ .
- ▶ O **estimador de White** mostra que é possível obter um estimador adequado para a variância usando o resíduo dos mínimos quadrados na estimativa da variância assintótica.

## Equação do Log dos de Preços dos Imóveis

$$\begin{aligned} \text{prêço} = & -21,77 + 0,00207 \text{ tamterr} + 0,123 \text{ arquad} + 13,85 \text{ qtdorm} \\ & (29,48) \quad (0,00064) \quad (0,013) \quad (9,01) \\ & n = 88, R^2 = 0,672. \end{aligned}$$

- ▶ O R-quadrado da regressão  $\hat{u}^2$  sobre tamterr, arquad e qtdorm é 0,1601 e temos  $n=88$  e  $k=3$
- ▶ Fazendo o teste para heterocedasticidade  $LM = 88(0,1601) = 14,09 > 7,815$  temos heterocedasticidade.

$$\begin{aligned} \log(\text{prêço}) = & -1,30 + 0,168 \log(\text{tamterr}) + 0,700 \log(\text{arquad}) + 0,037 \text{ qtdorm} \\ & (0,65) \quad (0,038) \quad (0,093) \quad (0,028) \\ & n = 88, R^2 = 0,643. \end{aligned}$$

- ▶ Fazendo o teste para heterocedasticidade  $LM = 88(0,048) = 4,22 < 7,815$  não temos mais heterocedasticidade.

## Quando o $\Omega$ é conhecido - MQG

- ▶ Sendo o estimador generalizado:  $\hat{\beta} = (\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1} \mathbf{X}'\Omega^{-1}\mathbf{y}$  e considere  $Var[u_i|x_i] = \sigma_i^2 = \sigma^2\omega_i$ .
- ▶ Então  $\Omega^{-1}$  é uma matriz diagonal com o  $i$ th elemento da diagonal  $1/\omega_i$ .
- ▶ Aplicando mínimos quadrados no modelo transformado obtemos o estimador por **mínimos quadrados ponderados**
  - ▶ 
$$\hat{\beta} = \left[ \sum_{i=1}^n \frac{1}{\omega_i} \mathbf{x}_i \mathbf{x}_i' \right]^{-1} \left[ \sum_{i=1}^n \frac{1}{\omega_i} \mathbf{x}_i y_i \right]$$
- ▶ Ideia: observações com menor variância tem um maior peso.

## Exemplo Gastos com consumo usando MQG

### Example (Gastos com consumo e renda para 20 famílias)

Assumindo que  $\sigma_i^2 = \gamma_0 + \gamma_1 x_i + \gamma_2 x_i^2$  podemos fazer o WLS em dois passos

Regredindo o  $u_i^2$  com  $renda_i$  e  $renda_i^2$

$$\omega_i^2 = 0.4875 - 0.0701 \text{renda}_i + 0.0037 \text{renda}_i^2$$

Regredindo  $cons_i/\omega_i$  com  $1/\omega_i$  e  $renda_i/\omega_i$

$$cons_i/\omega_i = \underset{(0.3299)}{0.7287} 1/\omega_i + \underset{(0.0199)}{0.9052} \text{renda}_i/\omega_i + e$$

Temos que o  $\beta$  estimado é maior do que o MQO, a inclinação menor e os erros padrão menores.

## Quando o $\Omega$ não é conhecido - MQGE

- ▶ Podemos obter uma estimativa consistente de  $\Omega$ , digamos  $\hat{\Omega}$ , usando um MQG implementável conhecido como estimador mínimos quadrados generalizados estimado (MQGE).
- ▶ O modelo é feito em dois estágios:
  - ▶ (1) o modelo é estimado por MQO ou outro estimador consistente (mas ineficiente), e os resíduos são usados para construir um estimador consistente da matriz de covariância de erros;
  - ▶ (2) usando o estimador consistente da matriz de covariância dos erros, pode-se implementar a estrutura do MQG.

## Quando o $\Omega$ não é conhecido - MQGE

- ▶ O estimador MQO é calculado de forma usual

$$\hat{\beta}_{MQO} = (X'X)^{-1}X'y$$

and estimates of the residuals  $u_j = (Y - X\mathbf{b})_j$  are constructed.

- ▶ Cada entrada da diagonal deve ser estimada pelo resíduo  $e_j$  tal que

$$\hat{\Omega}_{MQO} = \text{diag}(\hat{\sigma}_1^2, \hat{\sigma}_2^2, \dots, \hat{\sigma}_n^2)$$

- ▶ Estima  $\beta_{MQGE1}$  usando mínimos quadrados ponderados

$$\hat{\beta}_{MQGE1} = (X'\hat{\Omega}_{MQO}^{-1}X)^{-1}X'\hat{\Omega}_{MQO}^{-1}y$$

## Quando o $\Omega$ não é conhecido - MQGE

- ▶ O procedimento pode ser iterado. A primeira iteração é dada por

$$e_{MQGE1} = Y - X\hat{\beta}_{MQGE1}$$
$$\hat{\Omega}_{MQGE1} = \text{diag}(\hat{\sigma}_{MQGE1,1}^2, \hat{\sigma}_{MQGE1,2}^2, \dots, \hat{\sigma}_{MQGE1,n}^2)$$
$$\hat{\beta}_{MQGE2} = (X'\hat{\Omega}_{MQGE1}^{-1}X)^{-1}X'\hat{\Omega}_{MQGE1}^{-1}y$$

- ▶ Esta estimativa de  $\hat{\Omega}$  pode ser iterada para convergência.
- ▶ As propriedades assintóticas do estimador iterado são as mesmas que as do estimador de dois passos.

# Inferência Robusta em relação à heterocedasticidade após a estimação MQO

- ▶ Sabemos que a inferência habitual dos estimadores MQO é viesada na presença de heterocedasticidade.
- ▶ Com esta informação temos que decidir se abandonaremos de vez o método MQO.
- ▶ Felizmente, ele ainda é útil.
- ▶ É possível ajustar erros-padrão, estatísticas t, F e LM de forma a torná-la válidas na presença de heterocedasticidade de forma desconhecida.
- ▶ Esses métodos são conhecidos como **procedimentos robustos em relação à heterocedasticidade**.
- ▶ A ideia aqui é como calculamos a  $Var(\hat{\beta}_j)$ , na presença de heterocedasticidade.



# Inferência Robusta em relação à heterocedasticidade após a estimação MQO

- ▶ Considere um modelo de regressão simples:

$$y_i = \beta_0 + \beta_1 x_i + u_i$$

- ▶ Assumindo que as hipóteses clássicas são satisfeitas, exceto que:  $Var(u_i|x_i) = \sigma_i^2$
- ▶ Vimos que

$$Var(\hat{\beta}_j) = \frac{\sum (x_i - \bar{x})^2 \sigma_i^2}{SQT_x^2}$$

onde  $SQT_x = \sum (x_i - \bar{x})^2$  é a soma dos quadrados totais de  $x_i$ .

- ▶ Quando  $\sigma_i^2 = \sigma^2$  essa fórmula se reduz em  $\sigma^2/SQT_x$ .

# Inferência Robusta em relação à heterocedasticidade após a estimação MQO

- ▶ Na presença de heterocedasticidade temos que achar uma forma de estimar

$$Var(\hat{\beta}_j) = \frac{\sum (x_i - \bar{x})^2 \hat{u}_i^2}{SQT_x^2}$$

- ▶ Uma forma de estimadar a equação acima é:

$$\hat{Var}(\hat{\beta}_j) = \frac{\sum \hat{r}_{ij}^2 \hat{u}_i^2}{SQR_j^2}$$

onde  $\hat{r}_{ij}$  representa o  $i$ -ésimo resíduo da regressão de  $x_j$  sobre todas as outras variáveis independentes e  $SQR_j$  é a soma dos resíduos quadrados dessa regressão.

- ▶ A raiz quadrada da estimativa acima é chamada de **erro-padrão robusto em relação a heterocedasticidade** de  $\hat{\beta}_j$

# Inferência Robusta em relação à heterocedasticidade após a estimação MQO

- ▶ Com os erros-padrão robustos em relação a heterocedasticidade podemos construir a estatística  $t$  como anteriormente.

$$t = \frac{\text{estimativa-valor hipotético}}{\text{erro-padrão}}$$

assim a única diferença é o erro-padrão calculado.

## Equação do Log dos Salários com erros-padrão robustos em relação à heterocedasticidade

$$\begin{aligned} \log(\hat{\text{salário}}) = & 0,321 + 0,213 \text{ hcasados} - 0,198 \text{ mcasadas} - 0,110 \text{ msolteiras} \\ & (0,100) \quad (0,055) \quad (0,058) \quad (0,056) \\ & [0,109] \quad [0,057] \quad [0,058] \quad [0,057] \\ & + 0,0789 \text{ educ} + 0,0268 \text{ exper} - 0,00054 \text{ exper}^2 \\ & (0,0067) \quad (0,0055) \quad (0,00011) \\ & [0,0074] \quad [0,0051] \quad [0,00011] \\ & + 0,0291 \text{ perm} - 0,00053 \text{ perm}^2 \\ & (0,0068) \quad (0,00023) \\ & [0,0069] \quad [0,00024] \\ & n = 526, R^2 = 0,461. \end{aligned}$$

- ▶ Em parênteses ( ) erro-padrão usual do MQO e em colchetes [ ] o erro-padrão robusto em relação à heterocedasticidade
- ▶ Neste caso as variáveis eram significativas e continuarem sendo, pois não houve muita mudança.
- ▶ Erros-padrão robustos podem ser maiores ou menores do que os usuais.

## Equação do Log dos Salários com erros-padrão robustos em relação à heterocedasticidade

- ▶ Não sabemos se este exemplo existe problema de heterocedasticidade.
- ▶ Se a diferença for muito grande a suspeita é que haja problema.
- ▶ Também podemos nos perguntar se dada que é feita a correção por que não utilizamos esses erros-padrão robustos em vez dos usuais?
- ▶ A resposta é que se os erros são homocedásticos e normalmente distribuídos as estatísticas  $t$  usuais têm distribuições  $t$  exatas, independente do tamanho da amostra.
- ▶ O erros robustos são justificados somente quando o tamanho da amostra se torna grande.
- ▶ Com amostras pequenas as estatísticas  $t$  robustas podem ter distorções que não sejam muito próximas da distribuição  $t$ , e isso pode ofuscar nossa inferência.

## Equação do número de prisões no ano atual

- ▶ Exemplo 8.3 do Wooldridge sobre do efeito da média de tempo das penas cumpridas de condenações passadas afeta o número de prisões no anos atual.

$$\begin{aligned} n\hat{p}re86 = & 0,567 - 0,136 pcond + 0,0178 sentmed - 0,00052 sentmed^2 \\ & (0,036) \quad (0,040) \quad (0,0097) \quad (0,00030) \\ & [0,040] \quad [0,034] \quad [0,0101] \quad [0,00021] \\ & - 0,0394 ptemp86 - 0,0505 empr86 - 0,00148 rend86 \\ & (0,0087) \quad (0,0144) \quad (0,00034) \\ & [0,0062] \quad [0,0142] \quad [0,00023] \\ & + 0,325 negro + 0,193 hispan \\ & (0,045) \quad (0,040) \\ & [0,058] \quad [0,040] \\ & n = 2,725, R^2 = 0,0728. \end{aligned}$$

- ▶ A estatística  $t$  habitual de  $sentmed^2$  é aproximadamente  $-1,73$  (não significativa a 5%) e a estatística robusta é  $-2,48$  (significativo).