



# ***AUTOCORRELAÇÃO***

PROF. DR. VASCONCELOS REIS  
WAKIM

# *Autocorrelação*

- A autocorrelação serial dos resíduos é outro problema importante que recai sobre o Modelo Clássico de Regressão Linear (MCRL) e que pode tornar os betas estimados inconsistentes e não eficientes.
- As hipóteses do MCRL não podem ser violadas
- 3 tipos dados: Cross-Section, Painel e Séries Temporais



# *Autocorrelação*

- Para cada tipo de dados → pode haver problemas diferentes
- No que tange ao problema de autocorrelação serial dos resíduos este irá recair basicamente sobre os dados de séries temporais



# *Autocorrelação*

- No caso de cross-section → a base de dados é aleatório (unidades de análises diferentes) → o erro de uma ud pode estar relacionado com o de outra ud de análise;
- Neste caso, Gujarati e Porter (2011) mencionam que se chama de **correlação espacial**;
- Pois refere-se a correlação espacial e não de tempo



# *Autocorrelação*

- Veremos então como assuntos em autocorrelação:
  - 1) Natureza da autocorrelação;
  - 2) Consequências;
  - 3) Detecção; e
  - 4) Correção



# *Natureza da Autocorrelação*

- Como acontece com os estimadores na presença de heterocedasticidade, quando existe o problema da autocorrelação, os betas estimados serão lineares, não tendenciosos e o termo de erro será iid (independente e identicamente distribuídos), no entanto, não apresentará variância constante e/ou mínima ( $Var(u_i) = \sigma_i^2$ ), logo os estimadores serão ineficientes.

$$Cov(u_i, u_j | X_i X_j) = 0 \quad \forall i \neq j$$

$$Cov(u_i, u_j | X_i X_j) \neq 0 \quad \forall i \neq j$$



# *Demonstrando que $E(u)$ é não autocorrelacionado*

$$E(uu') = \begin{matrix} | & u_1 & | \\ & u_2 & \\ & u_3 & \\ & \vdots & \\ & u_n & | \end{matrix} \begin{matrix} x | u_1 & u_2 & u_3 & \dots & u_n | \end{matrix}$$

$$E(uu') = \begin{matrix} | & u_1^2 & u_1u_2 & u_1u_3 & \dots & u_1u_n & | \\ u_2u_1 & u_2^2 & u_2u_3 & \dots & u_2u_n & \\ u_3u_1 & u_3u_2 & u_3^2 & \dots & u_3u_n & \\ \vdots & \vdots & \vdots & \ddots & \vdots & \\ u_nu_1 & u_nu_2 & \dots & \dots & u_n^2 & \end{matrix} |$$



# ***Demonstrando que $E(u)$ é não autocorrelacionado***

$$E(uu') = \begin{vmatrix} E(u_1^2) & E(u_1u_2) & E(u_1u_3) & \dots & E(u_1u_n) \\ E(u_2u_1) & E(u_2^2) & E(u_2u_3) & \dots & E(u_2u_n) \\ E(u_3u_1) & E(u_3u_2) & E(u_3^2) & \dots & E(u_3u_n) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ E(u_nu_1) & E(u_nu_2) & \dots & \dots & E(u_n^2) \end{vmatrix}$$

Matriz de Variância e  
Covariância do  
Termo de Erro



$$E(uu') = \begin{vmatrix} \sigma^2 & Cov(u_1u_2) & Cov(u_1u_3) & \dots & Cov(u_1u_n) \\ Cov(u_2u_1) & \sigma^2 & Cov(u_2u_3) & \dots & Cov(u_2u_n) \\ Cov(u_3u_1) & Cov(u_3u_2) & \sigma^2 & \dots & Cov(u_3u_n) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ Cov(u_nu_1) & Cov(u_nu_2) & \dots & \dots & \sigma^2 \end{vmatrix}$$



# *Demonstrando que $E(u)$ é não autocorrelacionado*

$$E(uu') = \begin{vmatrix} \frac{\sigma^2}{\sigma^2} & \frac{Cov(u_1u_2)}{\sigma^2} & \frac{Cov(u_1u_3)}{\sigma^2} & \dots & \frac{Cov(u_1u_n)}{\sigma^2} \\ \frac{Cov(u_2u_1)}{\sigma^2} & \frac{\sigma^2}{\sigma^2} & \frac{Cov(u_2u_3)}{\sigma^2} & \dots & \frac{Cov(u_2u_n)}{\sigma^2} \\ \frac{Cov(u_3u_1)}{\sigma^2} & \frac{Cov(u_3u_2)}{\sigma^2} & \frac{\sigma^2}{\sigma^2} & \dots & \frac{Cov(u_3u_n)}{\sigma^2} \\ \frac{\sigma^2}{\sigma^2} & \frac{\sigma^2}{\sigma^2} & \frac{\sigma^2}{\sigma^2} & \dots & \frac{\sigma^2}{\sigma^2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \frac{Cov(u_nu_1)}{\sigma^2} & \frac{Cov(u_nu_2)}{\sigma^2} & \dots & \dots & \frac{\sigma^2}{\sigma^2} \end{vmatrix}$$

# *Demonstrando que $E(u)$ é não autocorrelacionado*

$$\Omega = \begin{vmatrix} 1 & \rho_1 & \cdots & \rho_{n-1} \\ \rho_1 & 1 & \cdots & \rho_{n-2} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{n-1} & \rho_{n-2} & \cdots & 1 \end{vmatrix}$$

$$E(uu') = \sigma^2 \Omega,$$

COM ESTA DEMONSTRAÇÃO, É POSSÍVEL PERCEBER QUE O TERMO DE ERRO NÃO É AUTOCORRELACIONADO



***Origem da  
Autocorrelação***



# *Origem da Autocorrelação*

- Qual é a origem da autocorrelação? → resposta básica  
→ nos próprios dados
- Mas existem algumas situações mais específicas que podem ajudar a entender a origem da autocorrelação:

# Origem da Autocorrelação

- Inércia da série temporal (lentidão)
- Viés de especificação de modelo (exclusão ou omissão de variável importante no modelo);

$$Y_i = \gamma_0 + \gamma_1 X_1 + \gamma_2 X_2 + \gamma_3 X_3 + \gamma_4 X_4 + \gamma_5 X_5 + \vartheta_i \quad \longrightarrow \quad \text{Modelo original}$$

$$Y_i = \gamma_0 + \gamma_1 X_1 + \gamma_2 X_2 + \gamma_4 X_4 + u_i \quad \longrightarrow \quad \text{Modelo estimado}$$

$$u_i = \gamma_3 X_3 + \gamma_5 X_5 + u_t \quad \longrightarrow \quad \text{Cov}(u_i, u_j | X_i X_j) \neq 0$$



# *Origem da Autocorrelação*

- Forma funcional incorreta;
- Modelos em Diferenças

$$\begin{cases} Y_t = \beta_1 + \beta_2 X_t + u_t & (1) \\ Y_{t-1} = \beta_1 + \beta_2 X_{t-1} + u_{t-1} & (2) \end{cases}$$

$$\Delta Y_t = 0 + \beta_2 X_t + X_{t-1} + u_t - u_{t-1}$$

$$\Delta Y_t = \beta_2 \Delta X_t + \Delta u_t$$

$$\Delta u_t = u_t - u_{t-1}$$



# *Origem da autocorrelação*

- É importante frisar que na presença da autocorrelação os betas estimados serão lineares, não tendenciosos, com distribuição normal, no entanto, apresentaram a característica de ineficiência, pois não possuirão variância mínima.

The background features a series of overlapping, curved lines in various colors including red, blue, yellow, and orange, set against a solid black background. These lines create a sense of motion and depth, resembling a stylized globe or a complex network.

# *Detecção da Autocorrelação*



# *Detecção da autocorrelação*

- A autocorrelação prova → betas estimados ineficientes
- Métodos Informais e Formais
- Informais → forma gráfica
- Formais → testes de detecção



# ***Detecção da autocorrelação***

- **Durbin-Watson (DW)** - foi o primeiro teste formal desenvolvido para testar a existência da autocorrelação utilizando os resíduos do MQO. Tsay (2005) comenta que o Teste de DW é muito utilizado, pois este considera uma defasagem da correlação serial.
- Mils (2019) comenta que a autocorrelação ocorre entre os valores atuais ( $X_t$ ), com os valores futuros ( $X_{t+1}$ ), ou mesmo com os valores defasados ( $X_{t-k}$ ), sendo que  $k$  varia de 1 a  $n$ .



# ***Detecção da autocorrelação***

- Matematicamente:

$$d = \frac{\sum_{t=2}^T (u_t - u_{t-1})^2}{\sum_{t=1}^T u_t^2}$$

- Pressupostos do teste:
  - A regressão tem que ter intercepto;
  - Os X's tem que ser fixo;
  - $u_i$  tem que ter distribuição normal;
  - O termo de erro é gerado por um processo AR(1)
  - A regressão não pode incluir o Y como variável explicativa defasada  $Y_{t-1}$
  - Não pode faltar observações

Como apresenta limitações, não é muito utilizado!



# *Detecção da autocorrelação*

- **Breusch-Godfrey (BG)**: é considerado um teste mais geral e mais indicado para a detecção da autocorrelação.
- Este teste parte de um modelo geral  $\rightarrow Y_t = \beta_1 + \beta_2 X_t + u_i$
- Sendo que  $u_i \rightarrow$  um vetor gerado por um processo AR(p)

$$u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + \dots + \rho_p u_{t-p} + \delta_t$$

$\delta_t$   $\rightarrow$  É considerado um ruído branco  $\rightarrow$  **estacionário**



# *Detecção da autocorrelação*

- **Rotina para estimação do teste BG manualmente:**

- Estimar a regressão principal;
- Obter os resíduos e estimar uma regressão auxiliar tendo o erro estimado como Y
- $\hat{u}_t = \alpha_1 + \alpha_2 X_t + \rho_1 u_{t-1} + \rho_2 u_{t-2} + \dots + \rho_p u_{t-p} + \gamma_t$
- Deve-se inserir todas as variáveis do modelo básico acrescentando o termo de erro defasado e obtenha o  $R^2$  da regressão auxiliar;

- A hipótese nula ( $H_0$ ) do teste =  $\rho_1 = \rho_2 = \dots = \rho_p = 0$
- Se a amostra é considerada grande  $\rightarrow$  quando tende ao infinito

$(n - p)R^2 \approx \chi_p^2$     Se  $\chi_p^2$  calculado  $>$   $\chi_p^2$  tabelado rejeita-se  $H_0$

$H_0 \rightarrow$  ausência de autocorrelação  
 $H_1 \rightarrow$  presença de autocorrelação



# *Detecção da autocorrelação*

- Rotina para estimação do teste BG no Stata
- Estimar modelo básico  $\rightarrow$  `reg Y X1 X2 X3 X4`
- Obter o resíduo ( $\hat{u}_t$ )  $\rightarrow$  `predict u, r`
- Defasar o  $\hat{u}_t$  em t-1 períodos
  - `gen lagUt-1 = u[_n-1]`
  - `gen lagUt-2 = u[_n-2]`
  - `gen lagUt-3 = u[_n-3]`
  - `gen lagUt-4 = u[_n-4]`



# ***Detecção da autocorrelação***

- **Rotina para estimação do teste BG no Stata**

- Estimar regressão auxiliar

- **reg u X<sub>1</sub> X<sub>2</sub> X<sub>3</sub> X<sub>4</sub> lagU<sub>t-1</sub> lagU<sub>t-2</sub> lagU<sub>t-3</sub> lagU<sub>t-4</sub>**

- Obter o R<sup>2</sup> da regressão auxiliar

- $BG = (n - p)R^2$

- H<sub>0</sub> – ausência

$$BG > \chi_{tab}^2 \text{ – rejeita } H_0$$

- H<sub>1</sub> - presença

$$BG < \chi_{tab}^2 \text{ – aceita } H_0$$

Se p-value → significativo → rejeita H<sub>0</sub>

Comando no Stata → estat bgodfrey, lag(n) small  
N = n° de defasagens





*Correção da  
Autocorrelação*



# *Correção da Autocorrelação*

- Relembrando → na presença de autocorrelação os betas são ineficientes
- Tem-se 2 situações para correção da autocorrelação:  $\rho$  conhecido ou  $\rho$  desconhecido
- Modelo Geral:  $Y_t = \beta_1 + \beta_2 X_t + u_t$



# *Correção da Autocorrelação*

- $\rho$  conhecido  $\rightarrow Y_t = \beta_1 + \beta_2 X_t + u_t$ , considerando que  $u_t$  segue um processo de geração AR(1)
- Se a equação  $Y_t = \beta_1 + \beta_2 X_t + u_t$  for verdadeira no tempo  $t$ , ela também será verdadeira no  $t-1$
- $Y_{t-1} = \beta_1 + \beta_2 X_{t-1} + u_{t-1}$



# *Correção da Autocorrelação*

- $Y_{t-1} = \beta_1 + \beta_2 X_{t-1} + u_{t-1} \rightarrow$  multiplicando ambos os lados por  $\rho \rightarrow$  obtêm-se
- $\rho Y_{t-1} = \rho\beta_1 + \rho\beta_2 X_{t-1} + \rho u_{t-1} \rightarrow$  subtraindo esta expressão de  $Y_t = \beta_1 + \beta_2 X_t + u_t$

# *Correção da Autocorrelação*

- $$\begin{cases} \rho Y_{t-1} = \rho\beta_1 + \rho\beta_2 X_{t-1} + \rho u_{t-1} \\ Y_t = \beta_1 + \beta_2 X_t + u_t \end{cases}$$

- $$\rho Y_{t-1} - Y_t = \beta_1(1 - \rho) + \beta_2(1 + \rho X_{t-1}) + \xi_t$$

- Sendo que: 
$$\xi_t = u_t - \rho u_{t-1}$$



# Correção da Autocorrelação

• Logo:  $\rho Y_{t-1} - Y_t = \beta_1(1 - \rho) + \beta_2(X_t - \rho X_{t-1}) + \xi_t$  pode ser  
rescrita como:

• A 1ª diferença pode ser escrita como:

$$Y_t^* = \beta_1^* + \beta_2^* X_t^* + \theta_t^*$$

← Desta forma, estima-se o MQO normalmente e os betas estimados serão **BLUE**.

$$Y_t^* = \rho Y_{t-1} - Y_t$$

$$\beta_1^* = \beta_1(1 - \rho)$$

$$\beta_2^* = \beta_2$$

$$X_t^* = X_t - \rho X_{t-1}$$

No entanto, a 1ª diferença pode levar a perda de 1 observação de Y e X, para contornar, usa-se a correção de Prais-Winsten

$$Y_1 \sqrt{1 - \rho^2}$$

$$X_1 \sqrt{1 - \rho^2}$$



# *Correção da Autocorrelação*

- $\rho$  desconhecido  $\rightarrow \rho$  raramente é conhecido

- Método da 1ª diferença

- $$\begin{cases} Y_t = \beta_1 + \beta_2 X_t + u_t \\ Y_{t-1} = \beta_1 + \beta_2 X_{t-1} + u_{t-1} \end{cases}$$

- $\Delta Y_t = \beta_2 \Delta X_t + \Delta u_t \rightarrow$  a 1ª  $\neq$  não tem intercepto  $\rightarrow$  passa pela origem a reta



# *Correção da Autocorrelação*

- Método de **Newey-West** → corrige os erros padrões → contorna heterocedasticidade e autocorrelação simultaneamente.
- **No stata:** `newey Y X1 X2 X3 X4, lag(0)` → é equivalente ao uso do **vce(robust)**
- **Newey-West** propõe uma matriz de correção para a  $Var-cov(\hat{\beta})$  que corrige heterocedasticidade e autocorrelação simultaneamente.

$$Var(\hat{\beta}) = (X'X)^{-1}X'\sigma^2\Omega(X'X)^{-1}$$