


ECONOMETRIA II

Modelos para dados em Painel ou Pooling
cross-section time series

$$Y_{it} = \beta_{1i} + \sum_{k=2}^K \beta_{ki} X_{kit} + \varepsilon_{it}$$



1. Modelos para dados que usam *cross-section* e séries temporais

Considere o conjunto de equações:

$$Y_1 = X_1 \beta_1 + \varepsilon_1$$

$$Y_2 = X_2 \beta_2 + \varepsilon_2$$

...

$$Y_n = X_n \beta_n + \varepsilon_n$$

Os modelos a serem examinados possuem n unidades *cross-section*, denotados $i = 1, \dots, n$, observados a cada T períodos de tempo, $t = 1, \dots, T$.

Exemplo:

$$I_{it} = \beta_1 + \beta_2 F_{it} + \beta_3 C_{it} + \varepsilon_{it}$$

Dados:

5 firmas ($i=5$):

General Motors (produz automóveis)

Chrysler (produz automóveis)

General Eletric (produz material elétrico)

Westinghouse (produz material elétrico)

US Steel (produz aço)

20 anos ($t=20$):

1935 a 1954

Variáveis:

I_t = investimento bruto

F_t = valor de mercado da firma no final do ano anterior à análise (lucros antecipados)

C_t = valor do estoque de equipamentos no final do ano anterior à análise (investimento necessário para reposição de equipamentos)

Considere o modelo:

$$Y_{it} = \boldsymbol{\beta}' \mathbf{X}_{it} + \varepsilon_{it} \quad i = 1, \dots, n \quad t = 1, \dots, T$$

pressupõe-se que $\beta_1 = \beta_2 = \dots = \beta_n$

Agrupando os t 's em vetores obtém-se :

$$\mathbf{Y}_i = \mathbf{X}_i \boldsymbol{\beta} + \boldsymbol{\varepsilon}_i \quad i = 1, \dots, n$$

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}_{(nT \times 1)} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix}_{(nT \times K)} \boldsymbol{\beta} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}_{(nT \times 1)}$$

cada sub-matriz ou sub-vetor tem T observações.

Considere a matriz de variância e covariância:

$$\Omega = E(\varepsilon\varepsilon') = \begin{bmatrix} \sigma_{11}V_{11} & \sigma_{12}V_{12} & \cdots & \sigma_{1n}V_{1n} \\ \sigma_{21}V_{21} & \sigma_{22}V_{22} & \cdots & \sigma_{2n}V_{2n} \\ \vdots & & & \\ \sigma_{n1}V_{n1} & \sigma_{n2}V_{n2} & \cdots & \sigma_{nn}V_{nn} \end{bmatrix}_{nT \times nT}$$

O modelo de regressão clássica especifica que:

$$E(\varepsilon_{it}) = 0$$

$$Var(\varepsilon_{it}) = \sigma^2$$

$$cov(\varepsilon_{it}, \varepsilon_{js}) = 0 \quad \text{se } t \neq s \text{ ou } i \neq j$$

Então

$$\Omega = \begin{bmatrix} \sigma^2 I & 0 & \dots & 0 \\ 0 & \sigma^2 I & & 0 \\ \vdots & & & \\ 0 & 0 & \dots & \sigma^2 I \end{bmatrix}$$

Modelo $Y = X\beta + \varepsilon$

Neste caso, aplica-se MQO aos dados agrupados (nT observações).

2. Heteroscedasticia

É provável que existam diferenças entre variâncias nas unidades cross-section.

Podemos então permitir que σ^2 varie com i , isto é,

$$\Omega = \begin{bmatrix} \sigma_1^2 I & 0 & \dots & 0 \\ 0 & \sigma_2^2 I & & 0 \\ \vdots & & & \\ 0 & 0 & \dots & \sigma_n^2 I \end{bmatrix}$$

o estimador será:

$$\hat{\beta} = (X' \Omega^{-1} X)^{-1} (X' \Omega^{-1} Y) = \left(\sum \frac{1}{\sigma_i^2} X_i' X_i \right)^{-1} \sum \frac{1}{\sigma_i^2} X_i' Y_i$$

$$X'\Omega^{-1} = \begin{bmatrix} X'_1 & X'_2 & \cdots & X'_n \end{bmatrix}_{(K \times nT)} \begin{bmatrix} \frac{1}{\sigma_1^2} I & 0 & \cdots & 0 \\ 0 & \frac{1}{\sigma_2^2} I & & 0 \\ \vdots & & \ddots & \\ 0 & & \cdots & \frac{1}{\sigma_n^2} I \end{bmatrix}_{(nT \times nT)} = \begin{bmatrix} \frac{X'_1}{\sigma_1^2} & \frac{X'_2}{\sigma_2^2} & \cdots & \frac{X'_n}{\sigma_n^2} \end{bmatrix}_{(K \times nT)}$$

$$X'\Omega^{-1}X = \begin{bmatrix} \frac{X'_1}{\sigma_1^2} & \frac{X'_2}{\sigma_2^2} & \cdots & \frac{X'_n}{\sigma_n^2} \end{bmatrix}_{(K \times nT)} \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix}_{(nT \times K)} = \begin{bmatrix} \frac{X'_1 X_1}{\sigma_1^2} + \frac{X'_2 X_2}{\sigma_2^2} + \cdots + \frac{X'_n X_n}{\sigma_n^2} \end{bmatrix}_{(K \times K)}$$

$$X'\Omega^{-1}Y = \begin{bmatrix} \frac{X'_1}{\sigma_1^2} & \frac{X'_2}{\sigma_2^2} & \dots & \frac{X'_n}{\sigma_n^2} \end{bmatrix}_{(K \times nT)} \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}_{(nT \times 1)} = \begin{bmatrix} \frac{X'_1 Y_1}{\sigma_1^2} + \frac{X'_2 Y_2}{\sigma_2^2} + \dots + \frac{X'_n Y_n}{\sigma_n^2} \end{bmatrix}_{(K \times 1)}$$

$$\left(X' \Omega^{-1} X \right)^{-1} \left(X' \Omega^{-1} Y \right)_{(K \times 1)} = \left[\sum \frac{1}{\sigma_i^2} X'_i X_i \right]^{-1} \left[\sum \frac{X'_i Y_i}{\sigma_i^2} \right]$$

Para estimar σ_i^2 utiliza-se:

$$s_i^2 = \frac{e_i' e_i}{T}$$

para cada unidade *cross-section* i com base em b (MQO) obtido para as nT observações, onde,

$$e_i = Y_i - bX_i$$

3. Teste para detectar heterocedasticidade

Teste do multiplicador de Lagrange:

Este teste é derivado da maximização da função de verossimilhança restrita.

Modelo:

$$Y_{it} = \boldsymbol{\beta}'\mathbf{X}_{it} + \varepsilon_{it}$$

Considere a função de densidade da distribuição normal:

$$f = \frac{1}{\sqrt{2\pi}\sigma_i} e^{-\frac{1}{2}\frac{\varepsilon_i'\varepsilon_i}{\sigma_i^2}}$$

então, a função de verossimilhança é:

$$L = \prod_{i=1}^{nT} f = (2\pi)^{-nT/2} \left(\prod_i \sigma_i^2 \right)^{-T/2} e^{-\frac{1}{2} \sum_i \frac{\varepsilon_i' \varepsilon_i}{\sigma_i^2}}$$

aplicando logaritmo,

$$\ln L = -\frac{nT}{2} \ln(2\pi) - \frac{T}{2} \sum_{i=1}^n \ln \sigma_i^2 - \frac{1}{2} \sum_{i=1}^n \frac{\varepsilon_i' \varepsilon_i}{\sigma_i^2}$$

$$\frac{\partial \ln L}{\partial \beta} = \sum_i \frac{1}{\sigma_i^2} X_i' (Y_i - X_i \beta) = \sum_i \frac{1}{\sigma_i^2} X_i' \varepsilon_i$$

Observe que:

$$\varepsilon_i' \varepsilon_i = (Y_i - X_i \beta)' (Y_i - X_i \beta) = (Y_i' - \beta' X_i') (Y_i - X_i \beta)$$

$$= Y_i' Y_i - Y_{i(1 \times T)}' X_{i(T \times K)} \beta_{(K \times 1)} - \beta' X_i' Y_i + \beta' X_i' X_i \beta$$

$$= Y_i' Y_i - 2 \beta' X_i' Y_i + \beta' X_i' X_i \beta$$

$$\frac{\partial \varepsilon_i' \varepsilon_i}{\partial \beta} = -2 X_i' Y_i + 2 X_i' X_i \beta = -2 X_i' (Y_i - X_i \beta)$$

Continuando,

$$\frac{\partial \ln L}{\partial \sigma_i^2} = -\frac{T}{2\sigma_i^2} + \frac{1}{2\sigma_i^4} \varepsilon_i' \varepsilon_i$$

$$\frac{\partial^2 \ln L}{\partial \beta \partial \beta'} = -\sum_i \frac{1}{\sigma_i^2} X_i' X_i$$

$$\frac{\partial^2 \ln L}{\partial (\sigma_i^2)^2} = \frac{T}{2\sigma_i^4} - \frac{\varepsilon_i' \varepsilon_i}{\sigma_i^6}$$

$$\frac{\partial^2 \ln L}{\partial \beta \partial \sigma_i^2} = - \sum_i \frac{1}{\sigma_i^4} X_i' \varepsilon_i$$

A matriz de derivadas de primeira ordem é:

$$g = \begin{bmatrix} \partial \ln L / \partial \beta \\ \partial \ln L / \partial \sigma_i^2 \end{bmatrix} = \begin{bmatrix} \sum \left(\frac{1}{\sigma_i^2} \right) X_i' \varepsilon_i \\ -\frac{T}{2\sigma_i^2} + \frac{\varepsilon_i' \varepsilon_i}{2\sigma_i^4} \quad \text{para } i = 1, \dots, n \end{bmatrix}$$

A matriz de derivadas de segunda ordem é:

$$S = \begin{bmatrix} -\sum_i \frac{1}{\sigma_i^2} X_i' X_i & -\sum_i \frac{1}{\sigma_i^4} X_i' \varepsilon_i \\ -\sum_i \frac{1}{\sigma_i^4} X_i' \varepsilon_i & \frac{T}{2\sigma_i^4} - \frac{\varepsilon_i' \varepsilon_i}{\sigma_i^6} \end{bmatrix}$$

A matriz de informação ($H = -E(S)$) é:

$$H(\beta, \sigma^2) = \begin{bmatrix} \sum_i \frac{1}{\sigma_i^2} X_i' X_i & 0 \\ 0 & -\frac{T}{2\sigma_i^4} + \frac{T\sigma_i^2}{\sigma_i^6} \end{bmatrix} = \begin{bmatrix} \sum_i \frac{1}{\sigma_i^2} X_i' X_i & 0 \\ 0 & \left(\frac{T}{2\sigma_i^4} \right) I \end{bmatrix}$$

e a inversa da matriz de informação (H^{-1}) é a matriz de variâncias.

Sob a hipótese de que as variâncias são iguais tem-se:

$$\frac{\partial \ln L}{\partial \sigma_i^2} = \frac{T}{2\sigma^2} \left[\frac{s_i^2}{\sigma^2} - 1 \right]$$

onde

$$s_i^2 = \frac{e_i' e_i}{T}$$

Se β é o estimador de máxima verossimilhança, da condição de 1ª. ordem:

$$\frac{\partial \ln L}{\partial \beta} = 0 \Rightarrow g = \begin{bmatrix} 0 \\ -\frac{T}{2s^2} + \frac{T s_i^2}{2s^4} \end{bmatrix}$$

$$s^2 = \frac{e'e}{nT} = \frac{\sum e_i' e_i}{nT} = \frac{1}{n} \sum_i s_i^2$$

O multiplicador de Lagrange $g'H^{-1}g$ é:

$$LM = \sum_i \left[\frac{T}{2s^2} \left(\frac{s_i^2}{s^2} - 1 \right) \right]^2 \left(\frac{2s^4}{T} \right) = \frac{T}{2} \sum_i \left(\frac{s_i^2}{s^2} - 1 \right)^2$$

Esta estatística testa a hipótese $H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_n^2$ e tem distribuição de qui-quadrado com $n-1$ graus de liberdade.

Correlação contemporânea

Há correlação entre as unidades cross-section, i.e.,

$$\begin{aligned}\text{cov}(\varepsilon_{it} \varepsilon_{js}) &= \sigma_{ij} && \text{se } t = s \\ &= 0 && \text{se } t \neq s\end{aligned}$$

$$\text{cov}(\varepsilon_i \varepsilon_j') = \sigma_{ij} I$$

A matriz de variância e covariância neste caso é:

$$\Omega = \begin{bmatrix} \sigma_{11}I & \sigma_{12}I & \cdots & \sigma_{1n}I \\ \sigma_{21}I & \sigma_{22}I & & \sigma_{2n}I \\ \vdots & & & \\ \sigma_{n1}I & \sigma_{n2}I & \cdots & \sigma_{nn}I \end{bmatrix}$$

Se $n = 3$, a matriz de covariância será:

$$\Omega = E(\varepsilon \varepsilon') = E \left[\begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \end{pmatrix} (\varepsilon'_1 \quad \varepsilon'_2 \quad \varepsilon'_3) \right] = \begin{bmatrix} E(\varepsilon_1 \varepsilon'_1) & E(\varepsilon_1 \varepsilon'_2) & E(\varepsilon_1 \varepsilon'_3) \\ E(\varepsilon_2 \varepsilon'_1) & E(\varepsilon_2 \varepsilon'_2) & E(\varepsilon_2 \varepsilon'_3) \\ E(\varepsilon_3 \varepsilon'_1) & E(\varepsilon_3 \varepsilon'_2) & E(\varepsilon_3 \varepsilon'_3) \end{bmatrix} = \begin{bmatrix} \sigma_{11} I & \sigma_{12} I & \sigma_{13} I \\ \sigma_{12} I & \sigma_{22} I & \sigma_{23} I \\ \sigma_{13} I & \sigma_{23} I & \sigma_{33} I \end{bmatrix}$$

$$E(\varepsilon_1 \varepsilon'_2) = E \left[\begin{pmatrix} \varepsilon_{11} \\ \varepsilon_{12} \\ \vdots \\ \varepsilon_{1T} \end{pmatrix} (\varepsilon_{21} \quad \varepsilon_{22} \quad \cdots \quad \varepsilon_{2T}) \right] = E \begin{bmatrix} \varepsilon_{11} \varepsilon_{21} & \varepsilon_{11} \varepsilon_{22} & \cdots & \varepsilon_{11} \varepsilon_{2T} \\ \varepsilon_{12} \varepsilon_{21} & \varepsilon_{12} \varepsilon_{22} & \cdots & \varepsilon_{12} \varepsilon_{2T} \\ \vdots & & & \\ \varepsilon_{1T} \varepsilon_{21} & \varepsilon_{1T} \varepsilon_{22} & \cdots & \varepsilon_{1T} \varepsilon_{2T} \end{bmatrix}$$

$$\text{cov}(\varepsilon_{1t}, \varepsilon_{2t}) = E(\varepsilon_{1t} \varepsilon_{2t}) = \sigma_{12} \quad t = 1, 2, \dots, T$$

$$\text{cov}(\varepsilon_{1t}, \varepsilon_{2s}) = E(\varepsilon_{1t} \varepsilon_{2s}) = 0 \quad t \neq s$$

$$E(\varepsilon_1 \varepsilon_2') = \begin{bmatrix} \sigma_{12} & 0 & \dots & 0 \\ 0 & \sigma_{12} & \dots & 0 \\ \vdots & & & \\ 0 & 0 & \dots & \sigma_{12} \end{bmatrix} = \sigma_{12} I_T$$

Para estimar o modelo, utiliza-se MQO usando as nT observações para obter b e os resíduos (e_i), onde

$$e_i = Y_i - bX_i$$

$$e \quad s_{ij} = \frac{e_i' e_j}{T}$$

é um estimador consistente de σ_{ij}

Estimando-se Ω utiliza-se o estimador:

$$\hat{\beta} = \left(X' \hat{\Omega}^{-1} X \right)^{-1} \left(X' \hat{\Omega}^{-1} Y \right)$$

para as nT observações.

Observe que:

$$\Omega = \Sigma_{n \times n} \otimes I$$

e

$$\Omega^{-1} = \Sigma^{-1} \otimes I$$

Produto de Kronecker

$$A = \begin{bmatrix} 1 & 3 \\ 2 & 0 \end{bmatrix}$$

$$B = \begin{bmatrix} 2 & 2 & 0 \\ 1 & 0 & 3 \end{bmatrix}$$

$$A \otimes B = \begin{bmatrix} 1 \begin{bmatrix} 2 & 2 & 0 \\ 1 & 0 & 3 \end{bmatrix} \\ 2 \begin{bmatrix} 2 & 2 & 0 \\ 1 & 0 & 3 \end{bmatrix} \end{bmatrix} = \begin{bmatrix} 2 & 2 & 0 & 6 & 6 & 0 \\ 1 & 0 & 3 & 3 & 0 & 9 \\ 4 & 4 & 0 & 0 & 0 & 0 \\ 2 & 0 & 6 & 0 & 0 & 0 \end{bmatrix}$$

Seja σ^{ij} o ij ésimo elemento de Σ^{-1} , então,

$$\Omega^{-1} = \begin{bmatrix} \sigma^{11}I & \sigma^{12}I & \cdots & \sigma^{1n}I \\ \sigma^{21}I & \sigma^{22}I & & \sigma^{2n}I \\ \vdots & & & \\ \sigma^{n1}I & \sigma^{n2}I & \cdots & \sigma^{nn}I \end{bmatrix}$$

A utilidade disto é que

$$X' \Omega^{-1} X = \sum_i \sum_j \sigma^{ij} X'_i X_j$$

e

$$X' \Omega^{-1} Y = \sum_i \sum_j \sigma^{ij} X'_i Y_j$$

e o estimador fica:

$$\hat{\beta} = \left[\sum_i \sum_j \sigma^{ij} X_i' X_j \right]^{-1} \left[\sum_i \sum_j \sigma^{ij} X_i' Y_j \right]$$

Exemplo:

$$\begin{aligned} \begin{bmatrix} X_1' & X_2' \end{bmatrix} \begin{bmatrix} \sigma^{11} & \sigma^{12} \\ \sigma^{21} & \sigma^{22} \end{bmatrix} \begin{bmatrix} X_1 \\ X_2 \end{bmatrix} &= \begin{bmatrix} X_1' \sigma^{11} + X_2' \sigma^{21} & X_1' \sigma^{12} + X_2' \sigma^{22} \end{bmatrix} \begin{bmatrix} X_1 \\ X_2 \end{bmatrix} \\ &= X_1' X_1 \sigma^{11} + X_2' X_1 \sigma^{21} + X_1' X_2 \sigma^{12} + X_2' X_2 \sigma^{22} \end{aligned}$$

Testando correlação contemporânea:

Teste do multiplicador de Lagrange desenvolvido por Breusch e Pagan.

$$\lambda_{LM} = T \sum_{i=2}^n \sum_{j=1}^{i-1} r_{ij}^2$$

onde

$$r_{ij}^2 = \frac{s_{ij}^2}{s_{ii}s_{jj}} \quad s_{ij} = \frac{e_i' e_j}{T}$$

Esta estatística tem distribuição de qui-quadrado com $\frac{n(n-1)}{2}$ graus de liberdade e H_0 = não há corr. contemporânea, i.e., fora da diagonal principal os valores são zero.

Autocorrelação

Vamos pressupor que não há correlação nos erros entre as unidades cross-section.

$$\text{cov}(\varepsilon_{it}, \varepsilon_{js}) = 0 \quad \text{se} \quad i \neq j$$

e vamos permitir autocorrelação dentro das unidades cross-section.

$$E(\varepsilon_i \varepsilon_j) = 0$$

$$E(\varepsilon_i \varepsilon_i) = \sigma_i^2 V_i$$

Então, a matriz de variância e covariância fica:

$$\Omega = \begin{bmatrix} \sigma_1^2 V_1 & 0 & \cdots & 0 \\ 0 & \sigma_2^2 V_2 & & 0 \\ \vdots & & & \\ 0 & 0 & \cdots & \sigma_n^2 V_n \end{bmatrix}$$

Considere um AR(1)

$$\varepsilon_{it} = \rho_i \varepsilon_{it-1} + u_{it}$$

$$0 < |\rho_i| < 1$$

Revisão de Autocorrelação do Mestrado.

$$Y_t = X_t \beta + \varepsilon_t$$

$$\varepsilon_t = \rho \varepsilon_{t-1} + u_t$$

$$0 \leq |\rho| < 1$$

$$\varepsilon_{t-1} = \rho \varepsilon_{t-2} + u_{t-1}$$

$u_t \sim N(0, \sigma_u^2)$ são independentes entre si e com os ε .

$$\varepsilon_t = \rho(\rho \varepsilon_{t-2} + u_{t-1}) + u_t \longrightarrow \varepsilon_t = \rho^2 \varepsilon_{t-2} + \rho u_{t-1} + u_t$$

$$\varepsilon_{t-2} = \rho \varepsilon_{t-3} + u_{t-2}$$

$$\varepsilon_t = \rho^2 (\rho \varepsilon_{t-3} + u_{t-2}) + \rho u_{t-1} + u_t$$

$$\varepsilon_t = \rho^3 \varepsilon_{t-3} + \rho^2 u_{t-2} + \rho u_{t-1} + u_t$$

Generalizando,

$$\varepsilon_t = u_t + \rho u_{t-1} + \rho^2 u_{t-2} + \dots = \sum_{i=0}^{\infty} \rho^i u_{t-i}$$

$$\text{Var}(\varepsilon) = E\left[(u_t + \rho u_{t-1} + \rho^2 u_{t-2} + \dots)(u_t + \rho u_{t-1} + \rho^2 u_{t-2} + \dots)\right]$$

$$\sigma_{\varepsilon}^2 = \sigma_u^2 + \rho^2 \sigma_u^2 + \rho^4 \sigma_u^2 + \rho^6 \sigma_u^2 + \dots$$

$$= \sigma_u^2 (1 + \rho^2 + \rho^4 + \rho^6 + \dots) = \frac{\sigma_u^2}{1 - \rho^2}$$

$$\text{cov}(\varepsilon_t, \varepsilon_{t-s}) = E(\varepsilon_t, \varepsilon_{t-s}) = E\left[(u_t + \rho u_{t-1} + \rho^2 u_{t-2} + \dots)(u_{t-s} + \rho u_{t-s-1} + \rho^2 u_{t-s-2} + \dots)\right]$$

Para $s = 1$

$$\begin{aligned}\text{cov}(\varepsilon_t, \varepsilon_{t-1}) &= E\left[(u_t + \rho u_{t-1} + \rho^2 u_{t-2} + \dots)(u_{t-1} + \rho u_{t-2} + \rho^2 u_{t-3} + \dots)\right] \\ &= \rho \sigma_u^2 + \rho^3 \sigma_u^2 + \dots\end{aligned}$$

Para $s = 2$

$$\begin{aligned}\text{cov}(\varepsilon_t, \varepsilon_{t-2}) &= E\left[(u_t + \rho u_{t-1} + \rho^2 u_{t-2} + \rho^3 u_{t-3} + \dots)(u_{t-2} + \rho u_{t-3} + \rho^2 u_{t-4} + \dots)\right] \\ &= \rho^2 \sigma_u^2 + \rho^4 \sigma_u^2 + \dots\end{aligned}$$

Generalizando,

$$\text{cov}(\varepsilon_t, \varepsilon_{t-s}) = \rho^s \sigma_u^2 + \rho^{s+2} \sigma_u^2 + \dots$$

$$\rho^s \sigma_u^2 (1 + \rho^2 + \rho^4 + \dots) = \frac{\rho^s \sigma_u^2}{1 - \rho^2}$$

$$\Omega = \frac{\sigma_u^2}{1 - \rho^2} \begin{bmatrix} 1 & \rho & \rho^2 & \rho^3 & \dots & \rho^{T-1} \\ \rho & 1 & \rho & \rho^2 & & \rho^{T-2} \\ \rho^2 & \rho & 1 & \rho & & \rho^{T-3} \\ \vdots & & & & & \\ \rho^{T-1} & \rho^{T-2} & & & \dots & 1 \end{bmatrix}$$

$$Y_t = \alpha + \beta X_t + \varepsilon_t$$

$$\varepsilon_t = \rho \varepsilon_{t-1} + u_t$$

$$Y_{t-1} = \alpha + \beta X_{t-1} + \varepsilon_{t-1}$$

$$\underbrace{Y_t - \rho Y_{t-1}}_{Y^*} = \underbrace{\alpha(1 - \rho)}_{\alpha^*} + \beta \underbrace{(X_t - \rho X_{t-1})}_{X^*} + \underbrace{\varepsilon_t - \rho \varepsilon_{t-1}}_{u_t}$$

Para $t = 2, \dots, n$

$$\text{Var}(\varepsilon_t - \rho \varepsilon_{t-1}) = \text{var}(\varepsilon_t) + \rho^2 \text{var}(\varepsilon_{t-1}) - 2\rho \text{cov}(\varepsilon_t \varepsilon_{t-1})$$

$$= \sigma_\varepsilon^2 + \rho^2 \sigma_\varepsilon^2 - 2\rho^2 \sigma_\varepsilon^2 = (1 - \rho^2) \sigma_\varepsilon^2 = \sigma_u^2$$

uma vez que $\sigma_\varepsilon^2 = \frac{\sigma_u^2}{1 - \rho^2}$

Para $t = 1$

$$\sqrt{1-\rho^2}Y_t = \sqrt{1-\rho^2}\alpha + \sqrt{1-\rho^2}X_t + \sqrt{1-\rho^2}\varepsilon_t$$

$$\text{Var}\left[\left(\sqrt{1-\rho^2}\right)\varepsilon_t\right] = (1-\rho^2)\sigma_\varepsilon^2 = \sigma_u^2$$

Então, voltando aos dados pooling,

$$\varepsilon_{it} = \rho_i \varepsilon_{it-1} + u_{it} \quad 0 < |\rho_i| < 1$$

$$\text{Var}(\varepsilon_{it}) = \sigma_i^2 = \frac{\sigma_{ui}^2}{1-\rho_i^2} \quad \text{cov}(\varepsilon_{it}, \varepsilon_{it-s}) = \frac{\rho_i^s \sigma_{ui}^2}{1-\rho_i^2}$$

$$\sigma_i^2 V_i = \underbrace{\frac{\sigma_{ui}^2}{1-\rho_i^2}}_{\sigma_i^2} \begin{bmatrix} 1 & \rho_i & \rho_i^2 & \cdots & \rho_i^{T-1} \\ \rho_i & 1 & \rho_i & & \rho_i^{T-2} \\ \vdots & & & & \vdots \\ \rho_i^{T-1} & \rho_i^{T-2} & \rho_i^{T-3} & \cdots & 1 \end{bmatrix}$$

Suponha que r_i é um estimador consistente de ρ_i , então podemos transformar os dados usando a transformação de Prais-Winsten.

$$y_{*i} = \begin{bmatrix} \sqrt{1-r_i^2} Y_{i1} \\ Y_{i2} - r_i Y_{i1} \\ \vdots \\ Y_{iT} - r_i Y_{iT-1} \end{bmatrix} \quad X_{*i} = \begin{bmatrix} \sqrt{1-r_i^2} X_{i1} \\ X_{i2} - r_i X_{i1} \\ \vdots \\ X_{iT} - r_i X_{iT-1} \end{bmatrix}$$

Como estimar ρ_i :

Aplica-se MQO as nT observações e obtém-se b , então estima-se

$$e_i = Y_i - bX_i \quad \text{para cada } i$$

$$r_i = \frac{\sum_{t=2}^T e_{it} \cdot e_{i,t-1}}{\sum_{t=2}^T e_{i,t-1}^2} \quad t = 2, \dots, T$$

que é o coeficiente da regressão:

$$e_{it} = \rho_i e_{i,t-1} + \xi_{it}$$

Se $|r_i| > 1$ então usar $r_i = \frac{\sum e_{it} e_{it-1}}{\sqrt{\sum e_{it}^2} \sqrt{\sum e_{it-1}^2}}$ que estará sempre entre 1 e -1

Com os dados transformados, o modelo é agora somente heterocedástico, isto é, a matriz de variância e covariância é:

$$\Omega = \begin{bmatrix} \sigma_1^2 I & 0 & \cdots & 0 \\ 0 & \sigma_2^2 I & & \vdots \\ & \vdots & & \\ 0 & 0 & \cdots & \sigma_n^2 I \end{bmatrix}$$

e o estimador é:

$$\hat{\beta} = \left(X_*' \Omega^{-1} X_* \right)^{-1} X_*' \Omega^{-1} Y_*$$

Para obter $\hat{\Omega}$, aplica-se MQO aos nT dados transformados e obtém-se b^* , então utiliza-o para encontrar:

$$e_i^* = Y_i^* - b^* X_i^*$$

Com base nestes resíduos estima-se σ_i^2

$$\hat{\sigma}_{ui}^2 = \frac{e_i^{*'} e_i^*}{T} \quad \text{e} \quad \hat{\sigma}_i^2 = \frac{\hat{\sigma}_{ui}^2}{1 - r_i^2}$$

Após estimar a matriz Ω pode-se estimar os parâmetros utilizando:

$$\hat{\beta} = \left(X_*' \hat{\Omega}^{-1} X_* \right)^{-1} X_*' \hat{\Omega}^{-1} Y_*$$

Ou, com $\hat{\sigma}_i^2$ aplica-se MQO ao modelo:

$$Y_i^{**} = \beta X_i^{**} + \varepsilon_i^{**}$$

onde

$$Y_i^{**} = \frac{Y_i^*}{\hat{\sigma}_i} \quad \text{e} \quad X_i^{**} = \frac{X_i^*}{\hat{\sigma}_i} \quad \text{e} \quad \varepsilon_i^{**} = \frac{\varepsilon_i^*}{\hat{\sigma}_i}$$

Teste para autocorrelação:

$$H_0 : \rho_i = 0 \quad \frac{(T-1)r_i^2}{1-r_i^2} \sim \chi^2(1)$$

Permitindo ainda a existência de correlação entre as unidades cross-section.

$$\text{cov}(u_{it}, u_{jt}) = \sigma_{u_{ij}}$$

então a matriz Ω que era

$$\Omega = \begin{bmatrix} \sigma_{11}I & \sigma_{12}I & \cdots & \sigma_{1n}I \\ \sigma_{21}I & \sigma_{22}I & & \sigma_{2n}I \\ \vdots & & & \\ \sigma_{n1}I & \sigma_{n2}I & & \sigma_{nn}I \end{bmatrix}$$

ficará ao invés de $\sigma_{ij}I$, $\sigma_{ij}V_{ij}$ fora da diagonal principal e na diagonal $\sigma_i^2V_i$

$$\sigma_{ij}V_{ij} = \underbrace{\frac{\sigma_{u_{ij}}}{1 - \rho_i \rho_j}}_{\sigma_{ij}} \begin{bmatrix} 1 & \rho_j & \rho_j^2 & \cdots & \rho_j^{T-1} \\ \rho_i & 1 & \rho_j & & \rho_j^{T-2} \\ \rho_i^2 & \rho_i & 1 & & \rho_j^{T-3} \\ \vdots & & & & \\ \rho_i^{T-1} & \rho_i^{T-2} & \rho_i^{T-3} & \cdots & 1 \end{bmatrix}$$

onde $\sigma_{u_{ij}} = \text{cov}(u_{it}, u_{jt})$

Para $s = 1$

$$\begin{aligned}\text{cov}(\varepsilon_{it}, \varepsilon_{jt-1}) &= E\left[(u_{it} + \rho_i u_{it-1} + \rho_i^2 u_{it-2} + \dots)(u_{jt-1} + \rho_j u_{jt-2} + \rho_j^2 u_{jt-3} + \dots)\right] \\ &= \rho_i \sigma_{uij} + \rho_i^2 \rho_j \sigma_{uij} + \rho_i^3 \rho_j^2 \sigma_{uij} \dots\end{aligned}$$

Para $s = 2$

$$\begin{aligned}\text{cov}(\varepsilon_{it}, \varepsilon_{jt-2}) &= E\left[(u_{it} + \rho_i u_{it-1} + \rho_i^2 u_{it-2} + \rho_i^3 u_{it-3} + \dots)(u_{jt-2} + \rho_j u_{jt-3} + \rho_j^2 u_{jt-4} + \dots)\right] \\ &= \rho_i^2 \sigma_{uij} + \rho_i^3 \rho_j \sigma_{uij} + \rho_i^4 \rho_j^2 \sigma_{uij} + \dots\end{aligned}$$

Generalizando:

$$\begin{aligned}\text{cov}(\varepsilon_{it}, \varepsilon_{jt-s}) &= \rho_i^s \rho_j^0 \sigma_{uij} + \rho_i^{s+1} \rho_j^1 \sigma_{uij} + \rho_i^{s+2} \rho_j^2 \sigma_{uij} + \dots \\ &= \rho_i^s \sigma_{uij} (1 + \rho_i \rho_j + \rho_i^2 \rho_j^2 + \dots) = \frac{\rho_i^s \sigma_{uij}}{1 - \rho_i \rho_j}\end{aligned}$$

Estimação:

Com as nT observações estima-se b e e_i .

Utiliza-se e_i para estimar ρ_i e transformar os dados (transformação de Prais-Winsten).

Aplica-se MQO aos dados transformados para obter e_{*i} e $\hat{\sigma}_{ij}$

e utiliza o estimador:

$$\hat{\beta} = \left(X_*' \Omega^{-1} X_* \right)^{-1} X_*' \Omega^{-1} Y_*$$

onde

$$\hat{\sigma}_{uij} = \frac{e_{*i}' e_{*j}}{T} \quad \text{e} \quad \hat{\sigma}_{ij} = \frac{\hat{\sigma}_{uij}}{1 - r_i r_j}$$