

Considere a estrutura básica do modelo de regressão:

$$y_{it} = x'_{it}\beta + z'_i\alpha + \varepsilon_{it}$$

Há  $K$  regressores em  $x$ , não incluindo a constante. A heterogeneidade ou efeito individual é  $z'_i\alpha$  onde  $z_i$  contém um termo constante e um conjunto de variáveis grupo específicas ou individuais, que podem ser observadas, como raça e sexo, ou não observadas, como habilidades, preferências, características familiares específicas, etc., todas consideradas constantes no tempo. Este é um modelo de regressão clássica. Se  $z_i$  é observado para todos os indivíduos, pode-se aplicar MQO.

1. Regressão Pooled – Se  $z_i$  contém somente um termo constante, então MQO fornece estimativas consistentes e eficientes de um  $\alpha$  comum e de  $\beta$ .

2. Efeitos Fixos – Se  $z_i$  não é observável, mas correlacionado com  $x_{it}$ , então o estimador de mínimos quadrados de  $\beta$  é tendencioso e inconsistente em consequência da omissão de variável. Entretanto, o modelo,

$$y_{it} = x'_{it}\beta + \alpha_i + \varepsilon_{it} \quad \text{onde} \quad \alpha_i = z'_i\alpha$$

contém todos os efeitos observáveis e especifica uma média condicional estimável. Este procedimento de efeito fixo considera  $\alpha_i$  como termo constante grupo-específico no modelo de regressão

3. Efeito Aleatório – Se a heterogeneidade individual não observável pode ser pressuposta não correlacionada com as variáveis incluídas, então o modelo pode ser formulado como:

$$y_{it} = x'_{it}\beta + \alpha + u_i + \varepsilon_{it}$$

Este procedimento de efeito aleatório especifica  $u_i$  como um elemento aleatório grupo-específico, semelhante ao  $\varepsilon_{it}$  só que para cada grupo.

## Modelo de Efeito Fixo

Pressupõe-se nesse modelo que as diferenças entre unidades cross-section podem ser obtidas por diferenças no termo constante. Portanto, considera-se  $\alpha_i$  um parâmetro desconhecido a ser estimado.

Se  $Y_i$  e  $X_i$  são  $T$  observações da  $i$ -ésima unidade, então

$$Y_i = \alpha_i + X_i\beta + \varepsilon_i$$

## Exemplos:

1) Na equação de rendimentos,  $Y_{it}$  poderá medir rendimento do chefe do domicílio, enquanto  $X_{it}$  poderá conter as variáveis educação, experiência, sexo, local de residência, etc. Observe que  $\alpha_i$  não varia com o tempo e representa um efeito individual específico que não foi incluído na regressão.

2) Na função de produção,  $Y_{it}$  medirá a produção e  $X_{it}$  os insumos. Os efeitos específicos das firmas não observados são capturados por  $\alpha_i$ , por exemplo, a habilidade gerencial dos executivos da firma.

$$Y_i = \iota \alpha_i + X_i \beta + \varepsilon_i$$

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} \iota & 0 & \cdots & 0 \\ 0 & \iota & & 0 \\ \vdots & & & \\ 0 & 0 & \cdots & \iota \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_n \end{bmatrix} + \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix}_{(nT \times K)} \beta + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

ou

$$Y = \begin{bmatrix} d_1 & d_2 & \cdots & d_n & X \end{bmatrix} \begin{bmatrix} \alpha \\ \beta \end{bmatrix} + \varepsilon$$

onde  $d_i$  são variáveis binárias indicando a  $i$ -ésima unidade.

Considere a matriz:

$$D = \begin{bmatrix} d_1 & d_2 & \cdots & d_n \end{bmatrix}_{(nT \times n)}$$

então,

$$Y = D\alpha + X\beta + \varepsilon$$

que é conhecido também como modelo de variável binária.

$$Y = \begin{bmatrix} D & X \end{bmatrix} \begin{bmatrix} \alpha \\ \beta \end{bmatrix} + \varepsilon$$

Partindo da equação normal obtém-se:

$$\begin{bmatrix} D' \\ X' \end{bmatrix} \begin{bmatrix} D & X \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} D' \\ X' \end{bmatrix} Y$$

$$\begin{bmatrix} D'D & D'X \\ X'D & X'X \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} D'Y \\ X'Y \end{bmatrix}$$

$$D'Da + D'Xb = D'Y \rightarrow a = (D'D)^{-1} D'Y - (D'D)^{-1} D'Xb$$



$$X'Da + X'Xb = X'Y$$

$$X'D\left[(D'D)^{-1}D'Y - (D'D)^{-1}D'Xb\right] + X'Xb = X'Y$$

$$X'D(D'D)^{-1}D'Y - X'D(D'D)^{-1}D'Xb + X'Xb = X'Y$$

$$X'Xb - X'D(D'D)^{-1}D'Xb = X'Y - X'D(D'D)^{-1}D'Y$$

$$X'\underbrace{\left[I - D(D'D)^{-1}D'\right]}_{M_d}Xb = X'\underbrace{\left[I - D(D'D)^{-1}D'\right]}_{M_d}Y$$

$$b = \left[X'\left(I - D(D'D)^{-1}D'\right)X\right]^{-1}\left[X'\left(I - D(D'D)^{-1}D'\right)Y\right]$$

Como  $M_d$  é uma matriz simétrica e idempotente, podemos escrever.

$$b = [X' M_d' M_d X]^{-1} [X' M_d' M_d Y]$$

$$b = (X_*' X_*)^{-1} (X_*' Y_*)$$

onde

$$X_* = M_d X \quad \text{e} \quad Y_* = M_d Y$$

$$M_d = \begin{bmatrix} M_0 & 0 & \cdots & 0 \\ 0 & M_0 & & 0 \\ \vdots & & & \\ 0 & 0 & \cdots & M_0 \end{bmatrix}$$

$$M_0 = I_T - \frac{1}{T} \iota \iota'$$

Observe que se  $n=2$  e  $T=3$  a matriz  $D$  fica:

$$D = \begin{bmatrix} 1 & 0 \\ 1 & 0 \\ 1 & 0 \\ 0 & 1 \\ 0 & 1 \\ 0 & 1 \end{bmatrix} \quad (D'D)^{-1} = \begin{bmatrix} 1/3 & 0 \\ 0 & 1/3 \end{bmatrix}$$

$$D(D'D)^{-1} = \begin{bmatrix} 1/3 & 0 \\ 1/3 & 0 \\ 1/3 & 0 \\ 0 & 1/3 \\ 0 & 1/3 \\ 0 & 1/3 \end{bmatrix}$$

$$M_d = I_{nT \times nT} - \underbrace{\begin{bmatrix} 1/3 & 1/3 & 1/3 & 0 & 0 & 0 \\ 1/3 & 1/3 & 1/3 & 0 & 0 & 0 \\ 1/3 & 1/3 & 1/3 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1/3 & 1/3 & 1/3 \\ 0 & 0 & 0 & 1/3 & 1/3 & 1/3 \\ 0 & 0 & 0 & 1/3 & 1/3 & 1/3 \end{bmatrix}}_{D(D'D)^{-1}D'}$$

$$M_d X = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} X_{11} \\ X_{12} \\ X_{13} \\ X_{21} \\ X_{22} \\ X_{23} \end{bmatrix} - \begin{bmatrix} 1/3 & 1/3 & 1/3 & 0 & 0 & 0 \\ 1/3 & 1/3 & 1/3 & 0 & 0 & 0 \\ 1/3 & 1/3 & 1/3 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1/3 & 1/3 & 1/3 \\ 0 & 0 & 0 & 1/3 & 1/3 & 1/3 \\ 0 & 0 & 0 & 1/3 & 1/3 & 1/3 \end{bmatrix} \begin{bmatrix} X_{11} \\ X_{12} \\ X_{13} \\ X_{21} \\ X_{22} \\ X_{23} \end{bmatrix}$$

$$M_dX = \begin{bmatrix} X_{11} - \frac{\Sigma X_{1t}}{3} \\ X_{12} - \frac{\Sigma X_{1t}}{3} \\ X_{13} - \frac{\Sigma X_{1t}}{3} \\ X_{21} - \frac{\Sigma X_{2t}}{3} \\ X_{22} - \frac{\Sigma X_{2t}}{3} \\ X_{23} - \frac{\Sigma X_{2t}}{3} \end{bmatrix}$$

$$\iota = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}$$

$$\iota \iota' = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

$$\sum X_i = \iota'X = T\overline{X}$$

$$\overline{X} = \frac{1}{T}\Sigma X_i = \frac{1}{T}\iota'X$$

$$\iota \overline{X} = \iota \frac{1}{T} \iota'X = \frac{1}{T} \iota \iota'X = \begin{bmatrix} \overline{X} \\ \overline{X} \\ \overline{X} \end{bmatrix}$$

$$\begin{bmatrix} X_1 - \bar{X} \\ X_2 - \bar{X} \\ X_3 - \bar{X} \end{bmatrix} = X - \iota \bar{X} = XI - \frac{1}{T} \iota \iota' X = \left[ I - \frac{1}{T} \iota \iota' \right] X$$

$$M_d = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} - \begin{bmatrix} 1/3 & 1/3 & 1/3 & 0 & 0 & 0 \\ 1/3 & 1/3 & 1/3 & 0 & 0 & 0 \\ 1/3 & 1/3 & 1/3 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1/3 & 1/3 & 1/3 \\ 0 & 0 & 0 & 1/3 & 1/3 & 1/3 \\ 0 & 0 & 0 & 1/3 & 1/3 & 1/3 \end{bmatrix} = \begin{bmatrix} M_0 & 0 \\ 0 & M_0 \end{bmatrix}$$

$$M_0 = I_T - \frac{1}{T} \iota \iota'$$

Considere qualquer vetor  $Z_i$  ( $T \times 1$ ), então

$$M_0 Z_i = Z_i - \bar{Z}_t$$

Portanto, a regressão de  $M_d Y$  em função de  $M_d X$  é equivalente a regressão de  $(Y_{it} - \bar{Y}_{i.})$  em função de  $(X_{it} - \bar{X}_{i.})$ , onde

$$\bar{Y}_{i.} = \frac{\sum_{t=1}^T Y_{it}}{T} \quad \text{e} \quad \bar{X}_{i.} = \frac{\sum_{t=1}^T X_{it}}{T}$$

Os coeficientes das variáveis binárias podem ser recuperados da outra equação normal da regressão particionada

$$D'Da + D'Xb = D'Y$$

ou

$$a = (D'D)^{-1} D'(Y - Xb)$$

ou

$$a_i = \bar{Y}_{i.} - b' \bar{X}_{i.}$$

$$Var(b) = s^2 (X' M_d X)^{-1}$$

$$Var(a) = \frac{s^2}{T} + \bar{X}'_i Var(b) \bar{X}_i.$$

$$s^2 = \frac{\sum_i \sum_t (Y_{it} - a_i - b' X_{it})^2}{nT - n - K}$$

$$e_{it} = Y_{it} - a_i - b' X_{it}$$



Este procedimento pode ser estendido para efeitos específicos de tempo, isto é,

$$Y_{it} = \alpha_i + \gamma_t + \beta'X_{it} + \varepsilon_{it}$$

As estimativas dos parâmetros  $\beta$  são obtidas da regressão de

$$Y_{*it} = Y_{it} - \bar{Y}_{i\cdot} - \bar{Y}_{\cdot t} + \bar{\bar{Y}}$$

em função de

$$X_{*it} = X_{it} - \bar{X}_{i\cdot} - \bar{X}_{\cdot t} + \bar{\bar{X}}$$

onde

$$\bar{Y}_{.t} = \frac{1}{n} \sum_{i=1}^n Y_{it}$$

$$\bar{\bar{Y}} = \frac{1}{nT} \sum_i \sum_t Y_{it}$$

$$a_i = \left( \bar{Y}_{i.} - \bar{\bar{Y}} \right) - b' \left( \bar{X}_{i.} - \bar{\bar{X}} \right)$$

$$c_t = \left( \bar{Y}_{.t} - \bar{\bar{Y}} \right) - b' \left( \bar{X}_{.t} - \bar{\bar{X}} \right)$$

## Teste F

$H_0$ : todos os termos constante são iguais

$$F(n-1, nT - n - K) = \frac{SQ_{res.restrito} - SQ_{res.nãorestrito} / n - 1}{SQ_{res.nãorestrito} / nT - n - K}$$

$$Y_{it} = \alpha + \beta' X_{it} + \varepsilon_{it} \quad (\text{modelo restrito})$$

$$Y_{it} = \alpha_i + \beta' X_{it} + \varepsilon_{it} \quad (\text{modelo não restrito})$$

Estimadores entre e dentro de grupos:

1) A formulação original é:

$$Y_{it} = \alpha_i + \beta' X_{it} + \varepsilon_{it}$$

2) em termos dos desvios da média

$$Y_{it} - \bar{Y}_{i.} = \beta' (X_{it} - \bar{X}_{i.}) + \varepsilon_{it} - \bar{\varepsilon}_{i.}$$

3) em termos da média

$$\bar{Y}_{i.} = \alpha_i + \beta' \bar{X}_{i.} + \bar{\varepsilon}_{i.}$$

	i=1	i=2	i=3
1970	10	10	5
1980	8	7	6
1990	4	5	6
2000	6	5	4

$$\bar{Y}_{.t} = \frac{10 + 10 + 5}{3} \quad \text{para } t = 1970$$

$$\bar{Y}_i = \frac{10 + 8 + 4 + 6}{4} \quad \text{para } i = 1$$

$$\bar{\bar{Y}} = \frac{10 + 8 + \dots + 4}{12}$$

$$S_{XX}^t = \sum_i \sum_t \left( X_{it} - \bar{\bar{X}} \right) \left( X_{it} - \bar{\bar{X}} \right)'$$

$$S_{XY}^t = \sum_i \sum_t \left( X_{it} - \bar{\bar{X}} \right) \left( Y_{it} - \bar{\bar{Y}} \right)$$

Em 2) como os dados estão em desvios, as médias de  $(Y_{it} - \bar{Y}_{i.})$  e  $(X_{it} - \bar{X}_{i.})$  são 0.

$$S_{XX}^w = \sum_i \sum_t \left( X_{it} - \bar{X}_{i.} \right) \left( X_{it} - \bar{X}_{i.} \right)'$$

$$S_{XY}^w = \sum_i \sum_t \left( X_{it} - \bar{X}_{i.} \right) \left( Y_{it} - \bar{Y}_{i.} \right)$$

Em 3)

$$S_{XX}^b = \sum_i T(\bar{X}_{i.} - \bar{\bar{X}})(\bar{X}_{i.} - \bar{\bar{X}})'$$

$$S_{XY}^b = \sum_i T(\bar{X}_{i.} - \bar{\bar{X}})(\bar{Y}_{i.} - \bar{\bar{Y}})$$

Observe que

$$S_{XX}^t = S_{XX}^b + S_{XX}^w \quad \text{e} \quad S_{XY}^t = S_{XY}^b + S_{XY}^w$$

Portanto, há 3 estimadores possíveis de mínimos quadrados de  $\beta$

$$b^t = (S_{XX}^t)^{-1} S_{XY}^t = (S_{XX}^w + S_{XX}^b)^{-1} (S_{XY}^w + S_{XY}^b)$$

$$b^w = \left(S_{XX}^w\right)^{-1} S_{XY}^w \longrightarrow \begin{array}{l} \text{Estimador de variáveis binárias} \\ = \text{within estimator} \end{array}$$

$$b^b = \left(S_{XX}^b\right)^{-1} S_{XY}^b \longrightarrow \text{Between estimator}$$

$$\text{como } S_{XY}^w = S_{XX}^w b^w \quad \text{e} \quad S_{XY}^b = S_{XX}^b b^b$$

substituindo em  $b^t$

$$b^t = \left(S_{XX}^w + S_{XX}^b\right)^{-1} \left(S_{XX}^w b^w + S_{XX}^b b^b\right) = \left(S_{XX}^w + S_{XX}^b\right)^{-1} S_{XX}^w b^w + \left(S_{XX}^w + S_{XX}^b\right)^{-1} S_{XX}^b b^b$$

ou

$$b^t = F^w b^w + F^b b^b \qquad F^w = I - F^b$$



$$F^w = \left( S_{XX}^w + S_{XX}^b \right)^{-1} S_{XX}^w = I - \left( S_{XX}^w + S_{XX}^b \right)^{-1} \underbrace{S_{XX}^b}_{S_{XX}^t - S_{XX}^w}$$

$$= I - \left( \underbrace{S_{XX}^w + S_{XX}^b}_{S_{XX}^t} \right)^{-1} S_{XX}^t + \left( S_{XX}^w + S_{XX}^b \right)^{-1} S_{XX}^w$$

$$= I - I + F^w = F^w$$

Exemplo:

Função custo para produção aérea nos EU.

6 firmas observadas durante 15 anos

$$\ln \text{cost}_{it} = \beta_1 + \beta_2 \ln \text{output}_{it} + \beta_3 \ln \text{fuel price}_{it} + \beta_4 \text{load factor}_{it} + \varepsilon_{it}$$

Output = receita por passageiro por milha

Fuel price = preço do combustível

Load factor = taxa de utilização de capacidade

## Modelo de Efeito Aleatório

Este modelo pressupõe que o erro aleatório associado com cada unidade *cross-section* não é correlacionado com outros regressores. Ademais,  $\alpha_i$ 's são aleatórios, isto é,

$$Y_{it} = \alpha_i + \beta'X_{it} + \varepsilon_{it}$$

onde

$$\alpha_i = \alpha + u_i$$

então,

$$Y_{it} = \alpha + \beta'X_{it} + u_i + \varepsilon_{it}$$

Pressupõe-se que:

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

$$E(\varepsilon_{it}^2) = \sigma_{\varepsilon}^2$$

$$E(u_i^2) = \sigma_u^2$$

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

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

O modelo em blocos de  $T$  observações para  $Y_i$ ,  $X_i$ ,  $u_i$  e  $\varepsilon_i$  fica:

$$w_{it} = \varepsilon_{it} + u_i$$

$$w_i = [w_{i1}, w_{i2}, \dots, w_{iT}]'$$

então

$$E(w_{it}^2) = \sigma_{\varepsilon}^2 + \sigma_u^2,$$

$$E(w_{it}, w_{is}) = E(\varepsilon_{it} + u_i, \varepsilon_{is} + u_i) = \sigma_u^2$$

Para as  $T$  observações da unidade  $i$ ,

$$V = E(w_i, w_i') = \begin{bmatrix} \sigma_\varepsilon^2 + \sigma_u^2 & \sigma_u^2 & \cdots & \sigma_u^2 \\ \sigma_u^2 & \sigma_\varepsilon^2 + \sigma_u^2 & & \sigma_u^2 \\ \vdots & & & \\ \sigma_u^2 & \sigma_u^2 & \cdots & \sigma_\varepsilon^2 + \sigma_u^2 \end{bmatrix}$$

$$V = \sigma_\varepsilon^2 I + \sigma_u^2 ii'$$

A matriz de variância e covariância dos erros para as  $nT$  observações é:

$$\Omega = \begin{bmatrix} V & 0 & \cdots & 0 \\ 0 & V & & 0 \\ \vdots & & & \\ 0 & 0 & \cdots & V \end{bmatrix} = I \otimes V$$

$$\begin{aligned} \hat{\beta} &= \left( X' \Omega^{-1} X \right)^{-1} \left( X' \Omega^{-1} Y \right) \\ &= \left( X' (I \otimes V)^{-1} X \right)^{-1} \left( X' (I \otimes V)^{-1} Y \right) \\ &= \left( X' \Omega^{-1/2'} \Omega^{-1/2} X \right)^{-1} \left( X' \Omega^{-1/2'} \Omega^{-1/2} Y \right) \end{aligned}$$

onde,

$$\Omega^{-1/2} = I \otimes V^{-1/2}$$

$$V^{-1/2} = I - \frac{\theta}{T} ii'$$

$$\theta = 1 - \frac{\sigma_{\varepsilon}}{\left(T\sigma_u^2 + \sigma_{\varepsilon}^2\right)^{1/2}} = 1 - \frac{\sigma_{\varepsilon}}{\sigma_1}$$



$$V^{-1} = \frac{D}{\sigma_{\varepsilon}^2} + \frac{ii'}{T\sigma_1^2}$$

$$D = I - \frac{ii'}{T}$$

$$\sigma_1^2 = T\sigma_u^2 + \sigma_{\varepsilon}^2$$

$$VV^{-1} = \left(\sigma_{\varepsilon}^2 I + \sigma_u^2 ii'\right) \left(\frac{D}{\sigma_{\varepsilon}^2} + \frac{ii'}{T\sigma_1^2}\right)$$

$$= \frac{\sigma_{\varepsilon}^2}{\sigma_{\varepsilon}^2} D + \frac{\sigma_{\varepsilon}^2}{T\sigma_1^2} ii' + \frac{\sigma_u^2}{\sigma_{\varepsilon}^2} Dii' + \frac{\sigma_u^2}{T\sigma_1^2} ii' \underbrace{ii'}_T$$

$$= D + \frac{\sigma_{\varepsilon}^2}{T\sigma_1^2} ii' + \underbrace{\frac{\sigma_u^2}{\sigma_{\varepsilon}^2} \left(I - \frac{ii'}{T}\right) ii'}_0 + \frac{\sigma_u^2}{\sigma_1^2} ii'$$

$$= I - \frac{ii'}{T} + \frac{\sigma_{\varepsilon}^2}{T\sigma_1^2}ii' + \frac{\sigma_u^2}{\sigma_1^2}ii'$$

$$= I + \frac{1}{T\sigma_1^2}[-\sigma_1^2ii' + \sigma_{\varepsilon}^2ii' + T\sigma_u^2ii'] = I$$

Lembrando que:

$$\sigma_1^2 = T\sigma_u^2 + \sigma_{\varepsilon}^2$$

$$V^{-1/2}V^{-1/2} = \sigma_{\varepsilon}^2 V^{-1} \qquad \theta = 1 - \frac{\sigma_{\varepsilon}}{\sigma_1}$$

$$\left(I - \frac{\theta}{T} \ddot{u}'\right) \left(I - \frac{\theta}{T} \ddot{u}'\right) = I - \frac{2\theta}{T} \ddot{u}' + \frac{\theta^2}{T} \ddot{u}'$$

$$= I - \frac{\ddot{u}'}{T} \left[ 2 \left( 1 - \frac{\sigma_{\varepsilon}}{\sigma_1} \right) - \left( 1 - 2 \frac{\sigma_{\varepsilon}}{\sigma_1} + \frac{\sigma_{\varepsilon}^2}{\sigma_1^2} \right) \right]$$

$$= I - \frac{\ddot{u}'}{T} \left[ 2 - 2 \frac{\sigma_{\varepsilon}}{\sigma_1} - 1 + 2 \frac{\sigma_{\varepsilon}}{\sigma_1} - \frac{\sigma_{\varepsilon}^2}{\sigma_1^2} \right]$$

$$= I - \frac{\ddot{u}'}{T} \left( 1 - \frac{\sigma_{\varepsilon}^2}{\sigma_1^2} \right) = \sigma_{\varepsilon}^2 \left[ \frac{\ddot{u}'}{T \sigma_1^2} + \frac{1}{\sigma_{\varepsilon}^2} \left( I - \frac{\ddot{u}'}{T} \right) \right]$$

$$V^{-1/2}Y_i = \begin{bmatrix} Y_{i1} - \theta \bar{Y}_{i\cdot} \\ Y_{i2} - \theta \bar{Y}_{i\cdot} \\ \vdots \\ Y_{iT} - \theta \bar{Y}_{i\cdot} \end{bmatrix}$$

MQG é obtido fazendo a regressão de  $V^{-1/2}Y_i$  em função de  $V^{-1/2}X_i$

Observe a similaridade deste modelo com o de variáveis binárias onde  $\theta=1$ .

Pode-se demonstrar que o estimador de MQG também é uma matriz de médias ponderadas dos estimadores dentro (within) e entre (between) unidades.

$$\hat{\beta} = \hat{F}^w b^w + (I - \hat{F}^w) b^b$$

onde,

$$\hat{F}^w = [S_{XX}^w + \lambda S_{XX}^b]^{-1} S_{XX}^w$$

$$\lambda = \frac{\sigma_{\varepsilon}^2}{\sigma_{\varepsilon}^2 + T\sigma_u^2} = (1 - \theta)^2$$

Observe que:

Se  $\lambda \rightarrow 1$  então MQG  $\rightarrow$  MQO  $\Rightarrow \sigma_u^2 \rightarrow 0$

Se  $\lambda \rightarrow 0$  então  $\sigma_\varepsilon^2 \rightarrow 0$

Mínimos Quadrados Generalizados quando  $\Omega$  é desconhecido

$$Y_{it} = \alpha + \beta' X_{it} + \varepsilon_{it} + u_i$$

$$Y_{i.} = \alpha + \beta' X_{i.} + \bar{\varepsilon}_{i.} + u_i$$

$$Y_{it} - \bar{Y}_{i.} = \beta' (X_{it} - \bar{X}_{i.}) + \varepsilon_{it} - \bar{\varepsilon}_{i.}$$

$$b = (X' M_d X)^{-1} (X' M_d Y)$$

$$\hat{\sigma}_{\varepsilon}^2 = \frac{\sum_i \sum_t (e_{it} - \bar{e}_{i.})^2}{nT - n - K}$$

$$\hat{\sigma}_u^2 = \hat{\sigma}_{**}^2 - \frac{\hat{\sigma}_{\varepsilon}^2}{T}$$

$$\hat{\sigma}_{**}^2 = \frac{e_{**}'e_{**}}{n-k}$$

$$\overline{Y}_{i.} - \alpha - \beta'\overline{X}_{i.} = \overline{\varepsilon}_{i.} + u_i = \varepsilon_{**i}$$

$$\theta = 1 - \frac{\sigma_{\varepsilon}}{\left(T\sigma_u^2 + \sigma_{\varepsilon}^2\right)^{1/2}}$$

$$\frac{\hat{\sigma}_{\varepsilon}^2}{\hat{\sigma}_{\varepsilon}^2 + T\hat{\sigma}_u^2} = \left(1 - \hat{\theta}\right)^2$$

$$\hat{\theta} = 1 - \left(\frac{\hat{\sigma}_{\varepsilon}^2}{\hat{\sigma}_{\varepsilon}^2 + T\hat{\sigma}_4^2}\right)^{1/2}$$



Para obter  $u_i$ ,

$$\hat{u}_i = \frac{\hat{\sigma}_u^2}{T\sigma_u^2 + \sigma_\varepsilon^2} \sum_{t=1}^T \left( Y_i - \hat{\beta} X_i \right)$$

Teste do multiplicador de Lagrange.

$$H_0 = \sigma_u^2 = 0$$

$$H_1 = \sigma_u^2 \neq 0$$

$$LM = \frac{nT}{2(T-1)} \left[ \frac{\sum_i \left( \sum_t e_{it} \right)^2}{\sum_i \sum_t e_{it}^2} - 1 \right]^2 \sim \chi^2(1)$$

### Teste de Hausman:

$H_0$ : não existe correlação entre  $u_i$  e  $X$ .

$$m = (b_F - b_A)' (Var(b_F) - Var(b_A))^{-1} (b_F - b_A) \sim \chi^2(K')$$

$b_F$  = coeficiente efeito fixo

$b_A$  = coeficiente efeito aleatório

$K'$  = número de inclinações

$$\text{cov}((b_F - b_A), b_A) = \text{cov}(b_F, b_A) - \text{Var}(b_A) = 0$$

$$\text{cov}(b_F, b_A) = \text{var}(b_A)$$

$$\begin{aligned}
 \text{Var}(b_F - b_A) &= \text{Var}(b_F) + \text{Var}(b_A) - 2\text{cov}(b_F, b_A) \\
 &= \text{Var}(b_F) - \text{Var}(b_A)
 \end{aligned}$$