

# GMM e Análise Longitudinal

(rascunho de notas de aula)

**Victor Gomes**

*Universidade de Brasilia*

15/04/2019

## GMM

- Hipótese mais importante de OLS: ortogonalidade entre termo de erro e regressores. Sem essa hipótese OLS não é nem mesmo consistente.
- Em diversas aplicações em economia não garantimos a condição de ortogonalidade. Estimação por GMM é fundamental e (quase) obrigatória.
- GMM inclui como casos especiais OLS, IV, regressão multivariada e 2SLS.

## Viés de Endogeneidade

- Clássico exemplo de Working (1927)
- Exemplo para mercado intermediário de café  
- commodity
- Modelo simples de oferta e demanda

$$q_i^d = \alpha_0 + \alpha_1 p_i + u_i \quad (1)$$

$$q_i^s = \beta_0 + \beta_1 p_i + v_i \quad (2)$$

$$q_i^d = q_i^s \quad (3)$$

- $q$  = quantidade,  $p$  = preço. Indicadoras são: tempo  $i$ , demanda  $d$ , e oferta  $s$ .  $u$  é o termo de erro da demanda e  $v$  o termo de erro da oferta.

## Viés de Endogeneidade

- Vamos assumir  $E(u_i) = 0$  e  $E(v_i) = 0$ , e por simplicidade,  $Cov(u_i, v_i) = 0$ .
- Fazendo  $q_i^d = q_i^s = q_i$ , temos:

$$q_i = \alpha_0 + \alpha_1 p_i + u_i \quad (4)$$

$$q_i = \beta_0 + \beta_1 p_i + v_i \quad (5)$$

## Viés de Endogeneidade

- Dissemos que um *regressor é endógeno* se ele não é predeterminado, i.e. não é ortogonal ao erro.
- Em nosso caso,  $p_i$  é endógeno em ambas as equações:

$$p_i = \frac{\beta_0 - \alpha_0}{\alpha_1 - \beta_1} + \frac{v_i - u_i}{\alpha_1 - \beta_1} \quad (6)$$

$$q_i = \frac{\alpha_1\beta_0 - \alpha_0\beta_1}{\alpha_1 - \beta_1} + \frac{\alpha_1v_i - \beta_1u_i}{\alpha_1 - \beta_1} \quad (7)$$

## Viés de Endogeneidade

- Desse sistema de equações podemos calcular a covariância de  $p_i$ :

$$\text{Cov}(p_i, u_i) = \frac{-\text{Var}(u_i)}{\alpha_1 - \beta_1}, \quad \text{Cov}(p_i, u_i) = \frac{-\text{Var}(v_i)}{\alpha_1 - \beta_1} \quad (8)$$

- Observe que as covariâncias não são zero. Nesse caso a endogeneidade é resultado do equilíbrio de mercado.

## Viés de Endogeneidade

- Quando rodados uma regressão de quantidade contra preço e uma constante, estamos estimando a oferta ou demanda? Como preço é endógeno em ambas equações a resposta não é clara.

- Da projeção do OLS sabemos que:

$$\text{plim da estimativa de OLS de } p_i = \frac{\text{Cov}(p_i, q_i)}{\text{Var}(p_i)} \quad (9)$$

- Para explicitar o efeito-preço na curva de demanda use  $q_i = \alpha_0 + \alpha_1 p_i + u_i$  e faça:

$$\text{Cov}(p_i, q_i) = \alpha_1 \text{Var}(p_i) + \text{Cov}(p_i, u_i) \quad (10)$$

## Viés de Endogeneidade

- Substituindo (10) em (9), temos o **viés assintótico** para  $\alpha_1$ :

$$\text{plim da estimativa de OLS de } p_i - \alpha_1 = \frac{\text{Cov}(p_i, u_i)}{\text{Var}(p_i)} \quad (11)$$

- Similarmente o **viés assintótico** para  $\beta_1$  é dado por:

$$\text{plim da estimativa de OLS de } p_i - \beta_1 = \frac{\text{Cov}(p_i, v_i)}{\text{Var}(p_i)} \quad (12)$$

- Então como a covariância não é zero, a estimativa OLS não é consistente para  $\alpha_1$  e para  $\beta_1$ .

## Viés de Endogeneidade

- Isto é conhecido como **viés de endogeneidade**.
- Porque o erro e o regressor são relacionados por meio de um sistema de equações simultâneas, esse viés também é conhecido como **viés de equações simultâneas** ou **viés de simultaneidade**.
- Sem viés o plim da estimativa OLS do coeficiente de preço seria:

$$= \frac{\alpha_1 \text{Var}(v_i) + \beta_1 \text{Var}(u_i)}{\text{Var}(v_i) + \text{Var}(u_i)}$$

## Mudanças na oferta

- Como identificar se as mudanças nos preços são devido a alterações na curva de oferta ou na demanda?
- Suponha que uma mudança na oferta  $v_i$  possa ser dividida em um fator observável  $x_i$  e em um fator não observável  $\zeta_i$  não-correlacionado com  $x_i$ . Assim:

$$q_i = \beta_0 + \beta_1 p_i + \beta_2 x_i + \zeta_i \text{ com } \beta_2 \neq 0 \quad (13)$$

- Imagine que esta variável  $x_i$  que provoca mudanças na curva de oferta é predeterminada (i.e. não-correlacionada com o termo do erro)

## Mudanças na oferta

- Na equação em questão, uma variável pre-determinada que é correlacionada com o regressor endógeno é chamada de *variável instrumental* ou um *instrumento*. Em nosso exemplo, o deslocador da curva de oferta  $x_i$  pode servir como um instrumento para a equação de demanda.
- Usando equação (13) e (7) temos:

$$p_i = \frac{\beta_0 - \alpha_0}{\alpha_1 - \beta_1} + \frac{\beta_2}{\alpha_1 - \beta_1} x_i + \frac{\zeta_i - u_i}{\alpha_1 - \beta_1} \quad (14)$$

$$q_i = \frac{\alpha_1 \beta_0 - \alpha_0 \beta_1}{\alpha_1 - \beta_1} + \frac{\alpha_1 \beta_2}{\alpha_1 - \beta_1} x_i + \frac{\alpha_1 \zeta_i - \beta_1 u_i}{\alpha_1 - \beta_1} \quad (15)$$

## Mudanças na oferta: condições do instrumento

- Como  $\text{Cov}(x_i, \zeta_i) = 0$  por construção e  $\text{Cov}(x_i, u_i) = 0$  por hipótese (no momento).

- A partir da equação  $p_i = \frac{\beta_0 - \alpha_0}{\alpha_1 - \beta_1} + \frac{\beta_2}{\alpha_1 - \beta_1} x_i + \frac{\zeta_i - u_i}{\alpha_1 - \beta_1}$

$$\text{Cov}(x_i, p_i) = \frac{\beta_2}{\alpha_1 - \beta_1} \text{Var}(x_i) \neq 0 \quad (16)$$

- Estas são as condições de validade de um instrumento

## Mudanças na oferta

- Com um instrumento válido podemos estimar  $\alpha_1$  consistentemente.
- Usando a curva de demanda podemos calcular  $Cov(x_i, q_i)$ :

$$Cov(x_i, q_i) = \alpha_1 Cov(x_i, p_i) + Cov(x_i, u_i) = \alpha_1 Cov(x_i, p_i)$$

dado que  $Cov(x_i, u_i) = 0$ .

## Mudanças na oferta

- Dividindo ambos os lados por  $Cov(x_i, p_i)$ , temos

$$\alpha_1 = \frac{Cov(x_i, q_i)}{Cov(x_i, p_i)}$$

Assim um estimador natural de  $\alpha_1$  é:

$$\hat{\alpha}_{1,IV} = \frac{\text{covariância amostral entre } x_i \text{ e } q_i}{\text{covariância amostral entre } x_i \text{ e } p_i}$$

- Este é o estimador de variável instrumental (IV) com  $x_i$  como instrumento.

## 2SLS

- Outro estimador popular é o de mínimos quadrados de dois estágios (2SLS).
- (Estágio 1) regressão de  $p_i$  contra  $x_i$
- (Estágio 2) regressão de  $q_i$  contra  $\hat{p}_i$  (onde  $\hat{p}_i$  é o valor predito no primeiro estágio).
- Então o estimador 2SLS pode ser escrito da seguinte forma:

$$\hat{\alpha}_{1,2SLS} = \frac{\text{covariância amostral entre } \hat{p}_i \text{ e } q_i}{\text{variância amostral de } \hat{p}_i}$$

- Para relacionar a equação de demanda com o 2SLS:

$$q_i = \alpha_0 + \alpha_1 \hat{p}_i + [u_i + \alpha_1(p_i - \hat{p}_i)]$$

A estimativa de  $\alpha_1$  é consistente pela seguinte razão: se o valor previsto  $\hat{p}$  é exatamente igual a projeção de mínimos quadrados  $\hat{E}^*(p|1, x)$ , então nem  $u_i$  nem  $(p_i - \hat{p}_i)$  devem ser correlacionados com  $\hat{p}_i$ .  $u_i$  não é correlacionado porque não é correlacionado com  $x_i$  e  $\hat{p}_i$  é uma função linear de  $x_i$  e  $(p_i - \hat{p}_i)$  é não correlacionado porque é uma projeção de mínimos quadrados do erro. Esses resultados valem quando  $N \rightarrow \infty$

- No caso destes exemplos os estimadores IV e 2SLS são os numericamente os mesmos. O estimador IV é um caso de GMM.

## Exemplos: Modelo Macro

- Modelo de consumo de Haavelmo (1943)

$$C_i = \alpha_0 + \alpha_1 Y_i + u_i \quad (17)$$

$$Y_i = C_i + I_i \quad (18)$$

- Variáveis:  $C_i$  consumo agregado;  $Y_i$  é PNB;  $\alpha_i$  é a propensão marginal a consumir ( $0 < \alpha_1 < 1$ ).
- GNP em equilíbrio é:

$$Y_i = \frac{\alpha_0}{1 - \alpha_1} + \frac{I_i}{1 - \alpha_i} + \frac{u_i}{1 - \alpha_i} \quad (19)$$

## Exemplos: Modelo Macro

- Se o investimento é predeterminado, i.e.,  $Cov(I_i, u_i) = 0$  segue que

$$Cov(Y_i, u_i) = \frac{Var(u_i)}{1 - \alpha_i} > 0$$

$$Cov(Y_i, I_i) = \frac{Var(I_i)}{1 - \alpha_i} > 0$$

- Nesse caso,  $Y_i$  é endógena por meio da função consumo. O investimento é um instrumento válido para o regressor endógeno.
- O plim da estimativa de OLS da equação de consumo é assintoticamente viesado:

$$\text{plim} \hat{\alpha}_{1,OLS} - \alpha_1 = \frac{Cov(Y_i, u_i)}{Var(Y_i)} = \frac{1 - \alpha_1}{1 + \frac{Var(I_i)}{Var(u_i)}} > 0$$

- O viés assintótico pode ser corrigido pelo uso do investimento como instrumento para a renda. Aqui se usa o mesmo papel do descolador de oferta no exemplo de Working.

## Exemplos: Função de Produção

- Em muitas aplicações é comum se aplicar uma hipótese sobre a estrutura de informação. Neste exemplo, a idéia fundamental é que a empresa possui mais informações do que o economista. Portanto, o que não é conhecido quando estimamos um modelo pode ser conhecido no mercado.
- A endogeneidade surge quando regressores são decisões realizadas pelo agente com base em fatores que não são observáveis por quem estima.

## Exemplos: Função de Produção

- Suponha uma amostra cross-section onde firmas escolhem o insumo trabalho para maximizar seus lucros. A função de produção para a firm  $i$  é:

$$Q_i = A_i(L_i)^{\phi_1} \exp(v_i), 0 < \phi_1 < 1 \quad (20)$$

- Tal que  $Q_i$  é o produto,  $L_i$  é o trabalho contratado,  $A_i$  é o nível de eficiência da conhecido pela firma, e  $v_i$  é o choque tecnológico. Em contraste a  $A_i$ ,  $v_i$  não é observado pela firma quando ela escolhe  $L_i$ . Nem  $A_i$  nem  $v_i$  é observável pelo economista.
- Assuma que  $B = E[\exp(v_i)]$  é o mesmo para todas as firmas (ver hipóteses no texto).

O nível de produto que as firmas esperam quando escolhem  $L_i$  é

$$A_i(L_i)^{\phi_1} B$$

- Assuma indústria competitiva. Então  $p$  (preço de  $Q_i$ ) e  $w$  (salário) são constantes entre as firmas  $i$ . O objetivo da firma é maximizar lucros

$$\max_{L_i} \{ p A_i (L_i)^{\phi_1} B - w L_i \}$$

solucionando para  $L_i$  temos:

$$L_i = \left( \frac{w}{p} \right)^{\frac{1}{\phi_1 - 1}} (A_i B \phi_1)^{\frac{1}{1 - \phi_1}}$$

## Exemplos: Função de Produção - Viés

- Faça  $u_i$  ser o desvio da firma  $i$  da média do log da eficiência:  $u_i = \log(A_i) - E[\log(A_i)]$ . Faça  $\phi_0 = E[\log(A_i)]$  ( $E(u_i) = 0$  e  $A_i = \exp(\phi_0 + u_i)$ ). As equações para estimação são as seguintes:

$$\log(Q_i) = \phi_0 + \phi_1 \log(L_i) + (v_i + u_i) \quad (21)$$

$$\log(L_i) = \beta_0 + \frac{1}{1 - \phi_1} u_i \quad (22)$$

tal que  $\beta_0 = \frac{1}{\phi_1 - 1} [\log(w/p) - \phi_0 - \log(\phi_1 B)]$

- A estimativa OLS de  $\phi_1$  é viesada. Isto ocorre porque  $L_i$  é um regressor endógeno que é relacionado com o termo de erro  $(v_i + u_i)$  por meio de  $u_i$ . Este exemplo ilustra outra fonte de endogeneidade: *a variável escolhida pelo agente possui um termo de erro que não é conhecido pelo econometrista.*

## Formulação Geral

**Hip. 3.1 (linearidade):**  $y_i = z_i' \delta + \varepsilon_i$  ( $i = 1, 2, \dots$ ).  $z$  é o vetor de regressores,  $\delta$  é o vetor dos coeficientes ( $L \times 1$ ).

**Hip. 3.2 (estacionaridade ergódica):** Seja  $x_i$  o vetor dos instrumentos (dimensão  $K$ ), e faça  $w_i$  serem os elementos únicos e não-constantemente de  $(y_i, z_i, x_i)$ .  $\{w_i\}$  é conjuntamente estacionária e ergódica.

**Hip. 3.3 (regressores pré-determinados):** Todas as variáveis em  $x_i$  são pré-determinadas no sentido de que todas são ortogonais ao erro:  $E(x_{ik} \varepsilon_i) = 0$  para todo  $i$  e  $k (= 1, 2, \dots, K)$ .

Ou seja:  $E[x_i(y_i - z_i' \delta)] = 0$  ou  $E(g_i) = 0$ , tal que  $g_i \equiv x_i \varepsilon_i$ .

## Formulação Geral

**Exemplo 3.2 (equação de salário):** Considere a seguinte equação de salário:

$$\log W_i = \delta_1 + \delta_2 S_i + \delta_3 EXP R_i + \delta_4 IQ_i + \varepsilon_i,$$

Então

$$y_i = \log W_i, L = 4,$$

$$z_i = \begin{bmatrix} 1 \\ S_i \\ EXP R_i \\ IQ_i \end{bmatrix}, K = 5, x_i = \begin{bmatrix} 1 \\ S_i \\ EXP R_i \\ AGE_i \\ MED_i \end{bmatrix}, w_i = \begin{bmatrix} \end{bmatrix}$$

## Identificação

Um instrumento deve ser predeterminado e correlacionado com os regressores.

### Hipótese 3.4 (condição de posto para identificação)

A matriz  $E(\mathbf{x}_i \mathbf{z}_i')$  é posto-completo. Representamos por  $\Sigma_{xz}$

Para enfatizar a dependência de  $\mathbf{g}_i \equiv \mathbf{x}_i \varepsilon_i$  sobre o vetor de parâmetros e os dados escrevemos  $\mathbf{g}_i$  como  $\mathbf{g}_i(\mathbf{w}_i; \boldsymbol{\delta}) = E[\mathbf{x}_i(y_i - \mathbf{z}_i' \boldsymbol{\delta})] = 0$ . Deste modo a *condição de ortogonalidade* é rescrita como:

$$\mathbf{g}_i(\mathbf{w}_i; \boldsymbol{\delta}) = 0 \quad (23)$$

Agora faça  $\tilde{\boldsymbol{\delta}}(L \times 1)$  ser um valor hipotético de  $\boldsymbol{\delta}$  e considere o sistema de  $K$  equações simultâneas em  $L$  incognitas (os elementos do valor hipotético):

$$\mathbf{g}_i(\mathbf{w}_i; \tilde{\boldsymbol{\delta}}) = 0 \quad (24)$$

As condições de ortogonalidade (23) implicam que os valores do vetor de coeficientes  $\delta$  são uma solução para o sistema (24) de  $K$  equações simultâneas. As quatro hipóteses GMM garantem que existe solução para o sistema de equações simultâneas.

Dizemos que o vetor de coeficientes é *identificado* se  $\tilde{\delta} = \delta$  é a *única* solução.

(24) é um sistema de  $K$  equações lineares:

$$E(x_i y_i) - E(x_i z_i') \tilde{\delta} = 0 \quad (25)$$

ou

$$\begin{matrix} \Sigma_{xz} \\ (K \times L) \end{matrix} \begin{matrix} \tilde{\delta} \\ (L \times 1) \end{matrix} = \begin{matrix} \sigma_{xy} \\ (K \times 1) \end{matrix} \quad (26)$$

tal que

$$\Sigma_{xz} = E(x_i z_i'); \quad \sigma_{xy} = E(x_i y_i)$$

$\tilde{\delta} = \delta$  é a única solução para o sistema se e somente se  $\Sigma_{xz}$  é posto completo (que é a condição da hipótese 3.4).

## Condição de Ordem para Identificação

Como o posto de  $\Sigma_{xz} < L$  se  $K < L$ , uma condição para identificação é que

$$K(\# \text{ variáveis predeterminadas}) \geq L(\# \text{ regressores}) \quad (27)$$

Esta condição possui como equivalentes:

- $\#$  condições de ortogonalidade  $\geq \#$  parâmetros
- $\#$  variáveis predeterminadas excluídas da equação  $\geq \#$  regressores endógenos

## Taxonomia para Identificação

A equação pode ser:

**Sobreidentificada** condição de ordem é satisfeita com  $K > L$

**Exatamente identificada** quando a condição de ordem é satisfeita com  $K = L$

**Subidentificada** a condição de ordem não é satisfeita,  $K < L$

## Normalidade Assintótica

**Hipótese 3.5 ( $g_i$  é um mds com segundos momentos finitos):** Faça  $g_i = x_i \varepsilon_i$ .  $\{g_i\}$  é uma sequência martingale diferença ( $E(g_i) = 0$ ). A matriz dos momentos cruzados ( $K \times K$ ),  $E(g_i g_i')$ , é não-singular. Usamos  $S$  para  $Avar(\bar{g})$ . Pela Hip. 3.2 e pelo teorema do limite central (ergódico diferença martingale estacionário),  $S = E(g_i g_i')$ .

## Normalidade Assintótica

- Se os instrumentos incluem uma constante, então esta hipótese implica que o termo de erro é uma sequência martingale em diferenças.
- Uma condição suficiente:

$$E(\varepsilon_i \mid \varepsilon_{i-1}, \dots, \varepsilon_1, \mathbf{x}_i, \mathbf{x}_{i-1}, \dots, \mathbf{x}_1) = 0$$

o que significa que o termo de erro é ortogonal não apenas ao instrumento contemporaneamente mas a todos os instrumentos passados.

- Como  $\mathbf{g}_i \mathbf{g}_i' = \varepsilon_i^2 \mathbf{x}_i \mathbf{x}_i'$ ,  $\mathbf{S}$  é uma matriz de quarto momentos. A estimativa consistente de  $\mathbf{S}$  irá requerer uma hipótese de quarto momento (3.6).

- Se  $\{g_i\}$  é seriamente correlacionado, então  $S$  não é igual a  $E(g_i g_i')$  e será necessária uma forma mais complicada para estimação.

## Definição GMM

- As condições de ortogonalidade afirmam que um conjunto de momentos da população são todos iguais a zero –  $E[g(w_i; \delta)]$ .
- O princípio básico do método dos momentos é escolher uma estimativa dos parâmetros tal que corresponda aos momentos amostrais que também são iguais a zero.

$$g_n(\tilde{\delta}) \equiv \frac{1}{n} \sum_{i=1}^n g(w_i; \tilde{\delta})$$

## Definição GMM

- Aplicando o princípio do método dos momentos, devemos escolher o  $\tilde{\delta}$  que soluciona o sistema de K equações simultâneas e L incógnitas:  $g_n(\tilde{\delta}) = 0$ .
- Como o sistema é linear podemos escrever:

$$g_n(\tilde{\delta}) = \frac{1}{n} \sum_{i=1}^n x_i (y_i - z_i' \tilde{\delta}) = \frac{1}{n} \sum_{i=1}^n x_i y_i - \left( \frac{1}{n} \sum_{i=1}^n x_i z_i' \right) \tilde{\delta} \quad (28)$$

$$g_n(\tilde{\delta}) = s_{xy} - S_{xz} \tilde{\delta} \quad (29)$$

$$s_{xy} = \frac{1}{n} \sum_{i=1}^n x_i y_i \quad \text{e} \quad S_{xz} = \frac{1}{n} \sum_{i=1}^n x_i z_i'$$

- O análogo amostral de  $g_n(\tilde{\delta}) = 0$  é um sistema de K equações lineares com L incógnitas:

$$S_{xz} \tilde{\delta} = s_{xy} \quad (30)$$

- Se  $K > L$  então o sistema pode não ter uma solução. A extensão do método dos momentos que lida com este caso é o GMM.

## Método dos Momentos

- Pela hip. 3.2,  $S_{xz}$  converge para  $\Sigma_{xz}$  –  $S_{xz}$  é inversível em amostras grandes.
- Então, quando possuímos amostras grandes o sistema tem solução:

$$\tilde{\delta}_{IV} = S_{xz}^{-1} s_{xy} \quad (31)$$

Este é o estimador de variáveis intrumentais (IV) para  $x_i$  servindo como instrumento.

## Método dos Momentos

- Se  $z_i = x_i$  então todos os regressores são pré-determinados, então  $\tilde{\delta}_{IV}$  se reduz ao estimador OLS. Portanto, a estimação OLS é um estimador do método dos momentos.

## Método dos Momentos Generalizado

- Se a equação é sobre-identificada ( $K > L$ ) então não podemos escolher em geral um  $\tilde{\delta}$  que satisfaça as  $K$  equações do sistema em questão.
- Podemos então escolher um  $\tilde{\delta}$  tal que  $g_n(\tilde{\delta})$  seja o mais perto de 0.
- Para definir “perto”, determinamos a **distância** entre dois vetores quaisquer (dimensão  $K$ )  $\xi$  e  $\eta$  pela forma quadrática

$$(\xi - \eta)' \widehat{W} (\xi - \eta)$$

$\widehat{W}$  é uma matriz simétrica e positiva definida que define a distância.

## Método dos Momentos Generalizado

**Definição 3.1 (Estimador GMM)** Faça  $\widehat{\mathbf{W}}$  ser uma matriz simétrica e positiva definida, dependente da amostra, tal que  $\widehat{\mathbf{W}} \rightarrow_p \mathbf{W}$  a medida que  $n \rightarrow \infty$ , com  $\mathbf{W}$  simétrica e positiva definida. O **estimador GMM** de  $\delta$ , representado por  $\widehat{\delta}(\widehat{\mathbf{W}})$ , é

$$\widehat{\delta}(\widehat{\mathbf{W}}) \equiv \underset{\tilde{\delta}}{\operatorname{argmin}} J(\tilde{\delta}, \widehat{\mathbf{W}})$$

onde

$$J(\tilde{\delta}, \widehat{\mathbf{W}}) \equiv n \left[ \mathbf{g}_n(\tilde{\delta})' \widehat{\mathbf{W}} \mathbf{g}_n(\tilde{\delta}) \right].$$

## Método dos Momentos Generalizado

- Como  $g_n(\tilde{\delta})$  é linear em  $\tilde{\delta}$ , a função objetivo é quadrática em  $\tilde{\delta}$  quando a equação é linear:

$$J(\tilde{\delta}, \widehat{W}) \equiv n(s_{xy} - S_{xz}\tilde{\delta})'\widehat{W}(s_{xy} - S_{xz}\tilde{\delta}) \quad (32)$$

A FOC com respeito a  $\tilde{\delta}$  é:

$$S'_{xz}\widehat{W}s_{xy} = S'_{xz}\widehat{W}S_{xz}\tilde{\delta}$$

- Como  $\widehat{W}$  é positiva semidefinida a matriz  $(L \times L)$   $S'_{xz}\widehat{W}s_{xy}$  é não singular. A única solução pode ser obtida multiplicando ambos os lados por pela inversa de  $S'_{xz}\widehat{W}s_{xy}$ . A única solução forma o estimador GMM:

$$\text{estimador GMM: } \hat{\delta}(\widehat{W}) = (S'_{xz}\widehat{W}S_{xz})^{-1}S'_{xz}\widehat{W}s_{xy} \quad (33)$$

- Se  $K = L$ , então  $S_{xz}$  é uma matriz quadrática e o estimador GMM se reduz ao estimador IV.

## GMM: Sampling Error

Multiplying both sides of the estimation equation  $y_i = z_i' \delta + \varepsilon_i$  by  $x_i$  and taking the averages we get:

$$s_{xy} = S_{xz} \delta + \hat{g} \quad (34)$$

such that

$$\hat{g} = \frac{1}{n} \sum_{i=1}^n x_i \varepsilon_i = \frac{1}{n} \sum_{i=1}^n g(w_i; \delta) = g_n(\delta)$$

Substituting (34) into the GMM estimator equation (33):

$$\hat{\delta}(\widehat{W}) - \delta = (S'_{xz} \widehat{W} S_{xz})^{-1} S'_{xz} \widehat{W} \hat{g} \quad (35)$$

## Distribuição assintótica do estimador GMM

### Proposição 3.1 (distribuição assintótica do estimador GMM):

(a) (Consistência) Sob as hipóteses 3.1-3.4,  $\text{plim}_{n \rightarrow \infty} \hat{\delta}(\widehat{W}) = \delta$ .

(b) (Normalidade assintótica) Se a hipótese 3.3 é expandida como a hipótese 3.5, então

$$\sqrt{n}(\hat{\delta}(\widehat{W}) - \delta) \rightarrow_d N(0, \text{Avar}(\hat{\delta}(\widehat{W})))$$
 a medida tal que

$$\text{Avar}(\hat{\delta}(\widehat{W})) = (\Sigma'_{xz} W \Sigma_{xz})^{-1} \Sigma'_{xz} W S W \Sigma_{xz} (\Sigma'_{xz} W \Sigma_{xz})^{-1}$$

sendo que  $\Sigma_{xz} \equiv E(x_i z'_i)$ ,  $S = E(g_i g'_i)$ ,  $W \equiv \text{plim} \widehat{W}$ .

## Distribuição assintótica do estimador GMM

### Proposição 3.1 (distribuição assintótica do estimador GMM):

- (c) (Consistência da estimativa de  $\text{Avar}(\widehat{\delta}(\widehat{\mathbf{W}}))$ )  
Suponha que é disponível um estimador consistente,  $\widehat{\mathbf{S}}$ , de  $\mathbf{S}(K \times K)$ . Então, sob a hipótese 3.2,  $\text{Avar}(\widehat{\delta}(\widehat{\mathbf{W}}))$  é consistentemente estimada por

$$\widehat{\text{Avar}}(\widehat{\delta}(\widehat{\mathbf{W}})) = (\mathbf{S}'_{xz} \widehat{\mathbf{W}} \mathbf{S}_{xz})^{-1} \mathbf{S}'_{xz} \widehat{\mathbf{W}} \widehat{\mathbf{S}} \widehat{\mathbf{W}} \mathbf{S}_{xz} (\mathbf{S}'_x$$

tal que  $\mathbf{S}_{xx}$  é a média amostral de  $\mathbf{x}_i \mathbf{x}'_i$ :

$$\mathbf{S}_{xx} \equiv \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}'_i = \frac{1}{n} \mathbf{X} \mathbf{X}'$$

## Distribuição assintótica do estimador GMM

**Proposição 3.2 (estimação consistente da variância do erro):** Para qualquer estimador consistente,  $\hat{\delta}$ , de  $\delta$ , defina  $\hat{\varepsilon}_i \equiv y_i - z_i' \hat{\delta}$ . Sob as hipóteses 3.1, 3.2, mais a hipótese que  $E(z_i z_i')$  existe e é finita,

$$\frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_i^2 \rightarrow_p E(\hat{\varepsilon}_i^2)$$

dado que  $E(\hat{\varepsilon}_i^2)$  existe e é finito.

## Teste de Hipótese

**Proposição 3.3 (razão  $t$  robusta e estatística de Wald):** Suponha que as hipóteses 3.1-3.5 valem, e suponha que é disponível uma estimativa consistente  $\hat{S}$  de  $S$ . Faça

$$\widehat{\text{Avar}}(\hat{\delta}(\widehat{W})) = (S'_{xz} \hat{W} S_{xz})^{-1} S'_{xz} \hat{W} \hat{S} \hat{W} S_{xz} (S'_{xz} \hat{W})$$

Então

(a) Sob a hipótese nula  $H_0 : \delta_\ell = \bar{\delta}_\ell$ ,

$$t_\ell \equiv \frac{\sqrt{n}(\hat{\delta}_\ell(\widehat{W}) - \bar{\delta}_\ell)}{\sqrt{(\widehat{\text{Avar}}(\hat{\delta}(\widehat{W})))_{\ell\ell}}} = \frac{\hat{\delta}_\ell(\widehat{W}) - \bar{\delta}_\ell}{SE_\ell^*} \rightarrow_d N(0, 1)$$

tal que  $(\widehat{\text{Avar}}(\hat{\delta}(\widehat{W})))_{\ell\ell}$  é o elemento  $(\ell\ell)$  da  $\widehat{\text{Avar}}(\hat{\delta}(\widehat{W}))$  e

$$SE_\ell^* \equiv \sqrt{\frac{1}{n} (\widehat{\text{Avar}}(\hat{\delta}(\widehat{W})))_{\ell\ell}}$$

- (b) Sob a hipótese nula  $H_0 : \mathbf{R}\boldsymbol{\delta} = \mathbf{r}$  tal que  $\#r$  é o número de restrições e  $\mathbf{R}(\#r \times L)$  é posto completo em linha,

$$W \equiv n.(\mathbf{R}\hat{\boldsymbol{\delta}}(\widehat{\mathbf{W}}) - \mathbf{r})' \{ \mathbf{R}[\widehat{\text{Avar}}(\hat{\boldsymbol{\delta}}(\widehat{\mathbf{W}}))] \mathbf{R}' \}^{-1} (\mathbf{R}\hat{\boldsymbol{\delta}}(\widehat{\mathbf{W}}) - \mathbf{r})$$

- (c) Sob a hipótese nula  $H_0 : \mathbf{a}(\boldsymbol{\delta}) = \mathbf{0}$  tal que  $\mathbf{A}(\boldsymbol{\delta})$ , a matriz  $(\#a \times L)$  de primeira derivada de  $\mathbf{a}(\boldsymbol{\delta})$  é contínua e de posto completo,

$$W \equiv n.\mathbf{a}(\hat{\boldsymbol{\delta}}(\widehat{\mathbf{W}}))' \{ \mathbf{A}(\hat{\boldsymbol{\delta}}(\widehat{\mathbf{W}})) [\widehat{\text{Avar}}(\hat{\boldsymbol{\delta}}(\widehat{\mathbf{W}}))] \mathbf{A}(\hat{\boldsymbol{\delta}}(\widehat{\mathbf{W}})) \}^{-1} \mathbf{a}(\hat{\boldsymbol{\delta}}(\widehat{\mathbf{W}}))$$

Restrições:  $H_0 : \mathbf{R}\boldsymbol{\delta} = \mathbf{r}$ , exemplo:  $\mathbf{R} = \begin{bmatrix} \mathbf{I}_q & \mathbf{0}_{q \times (k+1-q)} \end{bmatrix}$  e  $\mathbf{r} = \mathbf{0}_q$  (veja Stock e Watson, p. 760).

## Estimativa de $S$

- Vimos anteriormente que uma estimativa consistente era

$$\hat{S} \equiv \frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_i^2 \mathbf{x}_i \mathbf{x}_i'$$

tal que  $\hat{\varepsilon}_i = y_i - \mathbf{z}'\hat{\boldsymbol{\delta}}$ .

## Estimando $S$ consistentemente

Generalização da hip. 2.6.

**Hipótese 3.6 (quarto momento finito):**  $E[(x_{ik}z_{il})^2]$  existe e é finito para todo  $k, j = (1, 2, \dots, K)$ , e  $l (= 1, \dots, L)$ .

## Estimando $S$ consistentemente

### Proposição 3.4 (estimativa consistente de $S$ ):

Suponha o coeficiente estimado  $\hat{\delta}$  usado para calcular o resíduo  $\hat{\varepsilon}_i$  para  $\hat{S}$  de  $(1/n) \sum_{i=1}^n \hat{\varepsilon}_i^2 x_i$  e suponha que  $S = E(g_i g_i')$  exista e é finito. Então, sob as hips 3.1, 3.2 e 3.6,  $\hat{S}$  é consistente para  $S$ .

## Estimador eficiente GMM

### Proposição 3.5 (escolha ótima da matriz $\widehat{W}$ ):

Um limite inferior para a variância assintótica dos estimadores GMM, indexados por  $\widehat{W}$ , é dado por  $(\Sigma'_{xz}S^{-1}\Sigma_{xz})^{-1}$ . Esse limite inferior é alcançado se  $\widehat{W}$  é tal que  $\widehat{W}(\equiv \text{plim}\widehat{W}) = S^{-1}$ .

Portanto, o **estimador GMM eficiente** é aquele que satisfaz  $\text{plim}\widehat{W} = S^{-1}$ .

Simplesmente substituindo  $\widehat{W}$  por  $S^{-1}$  (que é consistente para  $S^{-1}$ ) nas fórmulas da Proposição 3.1 obtemos:

$$\text{estimador GMM: } \hat{\delta}(\hat{S}^{-1}) = (S'_{xz}\hat{S}^{-1}S_{xz})^{-1}S'_{xz}\hat{S}^{-1}s \quad (36)$$

$$\text{Avar}(\hat{\delta}(\hat{S}^{-1})) = (\Sigma'_{xz}S^{-1}\Sigma_{xz})^{-1} \quad (37)$$

$$\text{Avar}(\widehat{\delta}(\widehat{\mathbf{S}}^{-1})) = (\mathbf{S}'_{xz}\widehat{\mathbf{S}}^{-1}\mathbf{S}_{xz})^{-1} \quad (38)$$

Com  $\widehat{\mathbf{W}} = \mathbf{S}^{-1}$ , as fórmulas para o teste t robusto e estatística de Wald da Proposição 3.3 passa a ser:

$$t_\ell = \frac{\widehat{\delta}_\ell(\widehat{\mathbf{S}}^{-1}) - \bar{\delta}_\ell}{SE_\ell^*} \quad (39)$$

o  $SE_\ell^*$  é o erro-robusto dado por

$$SE_\ell^* = \sqrt{\frac{1}{n}((\mathbf{S}'_{xz}\widehat{\mathbf{S}}^{-1}\mathbf{S}_{xz})^{-1})_{\ell\ell}}$$

$$W = n.a(\widehat{\delta}(\widehat{\mathbf{S}}^{-1}))' \{ \mathbf{A}(\widehat{\delta}(\widehat{\mathbf{S}}^{-1})) (\mathbf{S}'_{xz}\widehat{\mathbf{S}}^{-1}\mathbf{S}_{xz})^{-1} \mathbf{A}(\widehat{\delta}(\widehat{\mathbf{S}}^{-1})) \} \quad (40)$$

## Estimador GMM eficiente

- Para se calcular um estimador GMM eficiente precisamos de uma estimativa consistente de  $\hat{S}$ .
- A proposição 3.4 garante que  $\hat{S}$  baseado em qualquer estimador consistente de  $\delta$  é consistente para  $S$ .

## Estimador GMM eficiente

- Procedimento de dois estágios de estimador GMM eficiente.
  1. Escolha uma matriz  $\hat{W}$  que converge em probabilidade para uma matriz simétrica positiva definida, e minimize  $J(\tilde{\delta}, \hat{W})$  sobre  $\tilde{\delta}$  para obter  $\tilde{\delta}(\hat{W})$ . Usualmente fazemos  $\hat{W} = S_{xx}^{-1}$ . Esse estimador é o conhecido método de mínimos quadrados de dois estágios (2SLS). Use isto para calcular o resíduo  $\hat{\varepsilon}$  e obter um estimador consistente  $\hat{S}$  de  $S$ .
  2. Minimize  $J(\tilde{\delta}, \hat{S}^{-1})$  sobre  $\tilde{\delta}$ . O minimizador é o estimador GMM eficiente.

## Teste de Hansen de Restrições Sobre-identificado (Hansen, 1982)

Quando a equação é sobre-identificada então a distância  $J(\tilde{\delta}, \widehat{W}) \equiv n \left[ \mathbf{g}_n(\tilde{\delta})' \widehat{W} \mathbf{g}_n(\tilde{\delta}) \right]$  (ver Definição 3.1) não é exatamente zero. Se a matriz de pesos  $\widehat{W}$  é escolhida otimamente então  $\text{plim} \widehat{W} = S^{-1}$ , assim a distância minimizada é assintoticamente qui-quadrada.

**Proposição 3.6 (Teste de Hansen de sobre-identificação de restrições:)** Suponha que disponível um estimador consistente de  $S$ ,  $\widehat{S} (= E(\mathbf{g}_i \mathbf{g}_i'))$ . Sob as hipóteses 3.1-3.5,

$$J(\widehat{\delta}(\widehat{S}^{-1}), \widehat{S}^{-1}) = n \cdot \mathbf{g}_n(\widehat{\delta}(\widehat{S}^{-1}))' \widehat{S}^{-1} \mathbf{g}_n(\widehat{\delta}(\widehat{S}^{-1})) \rightarrow \chi^2_r \quad (41)$$

Comentários:

- Este é um teste de especificação: se todas as restrições do modelo são satisfeitas. Se a estatística  $J$  é grande significa que tanto as condições de ortogonalidade e/ou outras hipóteses são falsas. Apenas quando temos confiança nas outras hipóteses podemos interpretar a estatística  $J$  grande como evidência para endogeneidade de algum dos  $K$  instrumento incluídos em  $x_i$ .
- O teste não é consistente contra algumas falhas das condições de ortogonalidade.
- Existem preocupações quanto a aplicação do teste para amostras pequenas.

## Testando subconjuntos para condições de ortogonalidade

Suponha que podemos dividir os  $K$  instrumentos em dois grupos:

1. o vetor  $\mathbf{x}_{i1}$  de  $K_1$  instrumentos confiáveis e,
2. o vetor  $\mathbf{x}_{i2}$  dos demais instrumentos  $K - K_1$  que podem ser suspeitos de violar a hipótese de ortogonalidade.

Como a ordenação dos instrumentos não muda os valores da estimação e das estatísticas de teste, podemos assumir que os últimos  $K$  elementos de  $\mathbf{x}_i$  são os suspeitos:

$$\mathbf{x}_i = \left[ \begin{array}{l} \mathbf{x}_{i1} \\ \mathbf{x}_{i2} \end{array} \right] \left. \begin{array}{l} \} \\ \} \end{array} \right\} \begin{array}{l} K_1 \text{ linhas} \\ K - K_1 \text{ linhas} \end{array}$$

A parte do modelo que queremos testar é:

$$E(\mathbf{x}_{i2}\varepsilon_i) = \mathbf{0} \quad (42)$$

Esta restrição é testável se existe ao menos instrumentos não suspeitos quanto os coeficientes:  $K_1 \geq L$ .

A idéia é comparar duas estatísticas  $J$  de duas estimativas GMM do mesmo coeficiente  $\delta$ : uma usando o subconjunto de instrumentos  $\mathbf{x}_{i1}$  e outra utilizando todos os instrumentos  $\mathbf{x}_i$ . Se a inclusão dos instrumentos eleva a estatística  $J$  então existe uma boa razão para duvidar da predeterminação dos  $\mathbf{x}_{i2}$ .

De acordo com as partições de  $\mathbf{x}_{i1}$  as condições de ortogonalidade podem ser escritas assim:

$$\mathbf{g}_n(\tilde{\delta}) = \begin{bmatrix} \mathbf{g}_{1n}(\tilde{\delta}) \\ \mathbf{g}_{2n}(\tilde{\delta}) \end{bmatrix}, \quad \mathbf{S} = \begin{bmatrix} \mathbf{S}_{11} & \mathbf{S}_{12} \\ \mathbf{S}_{21} & \mathbf{S}_{22} \end{bmatrix} \quad (43)$$

tal que  $S_{11} = E(\varepsilon_i^2 \mathbf{x}_{i1} \mathbf{x}'_{i1})$ , etc.

**Proposição 3.7 (Testando um subconjunto de condições de ortogonalidade:)** Suponha que as hipóteses 3.1-3.5 valem. Faça  $\mathbf{x}_i$  ser um subvetor de  $\mathbf{x}_i$ , e expanda a hipótese 3.4 pelo requerimento da condição do posto para identificação seja satisfeita para  $\mathbf{x}_{i1}$ . Então para qualquer estimador consistente  $\hat{S}$  de  $S$  e  $\hat{S}_{11}$  de  $S_{11}$ ,

$$C \equiv J - J_1 \rightarrow_d \chi^2(K - K_1).$$

**Exemplo 3.3** (testando o quanto escolaridade é predeterminado na equação salarial) Na equação salarial do exemplo 3.2, suponha que escolaridade  $S_i$  é suspeita de ser endógena. Para testar esta situação faça:

$$\mathbf{x}_{i1} = \begin{bmatrix} 1 \\ \text{EXPR}_i \\ \text{AGE}_i \\ \text{MED}_i \end{bmatrix}, \quad \mathbf{x}_{i2} = [S_i]$$

O vetor de regressores  $\mathbf{z}_i$  é o mesmo. O primeiro passo é estimar  $\delta$  pelo GMM eficientes de duas etapas com  $\mathbf{x}_i = [\mathbf{x}_{i1} \mathbf{x}_{i2}]'$  como instrumentos. Isto produz  $J$  e a matriz  $(5 \times 5)$   $\hat{S}$ . Utilize a matriz  $\hat{S}$  da primeira estimação para formar a matriz  $\hat{S}_{11}$  e estime os mesmos coeficientes  $\delta$  por GMM (usando  $\mathbf{x}_{i1}$  e  $\hat{S}_{11}$ ). A diferença das estatísticas  $J$  deve ser assintoticamente  $\chi^2(1)$ .

## Teste de Hipótese por Princípio Razão da Verosimilhança (LR)

Na seção 3.5 foi derivada as estatísticas de teste chi-quadrada para as hipóteses nula  $H_0 : \mathbf{a}(\boldsymbol{\delta}) = \mathbf{0}$  pelo princípio de Wald. Aqui é feito o mesmo pelo princípio LR: examina a diferença na função objetivo com e sem a imposição da hipótese nula.

Na estimativa GMM eficiente a função objetivo é  $J(\tilde{\boldsymbol{\delta}}, \hat{\mathbf{S}}^{-1})$  para uma estimativa consistente  $\hat{\mathbf{S}}$  de  $\mathbf{S}$ .

### Estimador GMM eficiente restrito

$$\bar{\boldsymbol{\delta}}(\hat{\mathbf{S}}^{-1}) \equiv \underset{\tilde{\boldsymbol{\delta}}}{\operatorname{argmin}} J(\tilde{\boldsymbol{\delta}}, \hat{\mathbf{S}}^{-1}) \text{ s.t. } H_0 \quad (44)$$

O princípio LR sugere que

$$LR \equiv J(\bar{\boldsymbol{\delta}}(\hat{\mathbf{S}}^{-1}), \hat{\mathbf{S}}^{-1}) - J(\hat{\boldsymbol{\delta}}(\hat{\mathbf{S}}^{-1}), \hat{\mathbf{S}}^{-1}) \quad (45)$$

deve ser assintoticamente  $\chi$ -quadrado.

### **Proposição 3.8 (estatística de teste pelo princípio**

Suponha que as Hipóteses 3.1-3.5 valem e suponha que seja disponível um estimador consistente  $\hat{S}$  de  $S(= E(g_i g_i'))$ . Considere a hipótese nula de  $\#a$  restrições  $H_0 : a(\delta) = 0$  tal que  $A(\delta) = 0$ , a matriz ( $\#a \times L$ ) das primeiras derivadas, é contínua e de posto completo. Defina duas estatísticas,  $W$  e  $LR$ , por (40) e (45), respectivamente. Então, sob a hipótese nula, o seguinte vale:

- (a)** As duas estatísticas são assintoticamente equivalentes – as distribuições assintóticas são as mesmas ( $\chi^2(\#a)$ ).
- (b)** As duas estatísticas são assintoticamente equivalentes no sentido mais forte que suas diferenças numéricas convergem em probabilidade para zero:  $LR - W \rightarrow_p 0$ .

(c) Além disso, se a hipótese é linear tal que as restrições podem ser escritas como  $R\delta = r$ , então as duas estatísticas são numericamente iguais.

## Teste de Hipótese por Princípio Razão da Verosimilhança (LR)

- A vantagem da  $LR$  sobre  $W$  é invariante: o valor numérico da LR não depende de como as restrições são representadas por  $a(\cdot)$ . Quando a hipótese é não linear é necessário escrever um programa para o teste.
- Proposição 3.8 requer que a matriz de distância  $\hat{W}$  satisfaça a condição  $\text{plim} \hat{W} = S^{-1}$ . Caso contrário LR não é estatisticamente  $\chi$ -quadrado. (A estatística de Wald é assintoticamente  $\chi$ -quadrado sem satisfazer esta condição de eficiência).
- A mesma estimativa de  $S$  deve ser usada para calcular a LR (os dois  $J$ ).

- Para existir equivalência numérica,  $LR = W$ , no caso linear então a mesma estimativa  $\hat{S}$  deve ser a mesma para ambos. Caso contrário,  $LR$  e  $W$  são apenas assintoticamente equivalentes.

## Teste de Hipótese por Princípio Razão da Verosimilhança (LR)

**Estatística LR para OLS:** OLS é caso especial de GMM. A estatística LR pode ser escrita da seguinte forma: em OLS fazemos  $x_i = z_i$ , então o modelo GMM eficiente irrestrito é OLS e  $J(\hat{\delta}(\hat{S}^{-1}), \hat{S}^{-1}) = 0$ . Portanto,

$$LR = J(\bar{\delta}(\hat{S}^{-1}), \hat{S}^{-1}) \quad (46)$$

Aqui  $\bar{\delta}(\hat{S}^{-1})$  é o estimador GMM eficiente restrito.

Pela Proposição 3.8 esta estatística é assintoticamente  $\chi$ -quadrada e é numericamente igual a estatística de Wald se a hipótese nula é linear. (Assumindo homocedasticidade condicional a LR é a diferença na soma do quadrado dos resíduos normalizado pela variância do erro).

## Implicações da Homocedasticidade Condicional

A análise anterior não assume homocedasticidade. Esta análise é apresentada na seção 3.8 do livro de Hayashi como caso particular de GMM.

### Hipótese 3.7 (homocedasticidade condicional:)

$$E(\varepsilon_i^2 | \mathbf{x}_i) = \sigma^2$$

- Nesse caso, a matriz do quarto momento é  $\mathbf{S} = E(\mathbf{g}_i \mathbf{g}_i')$  pode ser escrito como o produto de segundos momentos:

$$\mathbf{S} = \sigma^2 \Sigma_{\mathbf{x}\mathbf{x}} \quad (47)$$

tal que  $\Sigma_{\mathbf{x}\mathbf{x}} = E(\mathbf{x}_i \mathbf{x}_i')$ .

## Implicações da Homocedasticidade Condicional

- Como  $S$  é não singular pela hipótese 3.5 isso implica que  $\sigma^2 > 0$  e  $\Sigma_{xx}$  é não-singular.
- Para este caso, o estimador de  $S$  é:

$$\hat{S} = \hat{\sigma}^2 \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' = \hat{\sigma}^2 \mathbf{S}_{xx} \quad (48)$$

Aqui  $\hat{\sigma}^2$  é um estimador consistente a ser especificado depois. Por estacionariedade ergódica  $\mathbf{S}_{xx} \rightarrow_{a.s.} \Sigma_{xx}$ . Dado um  $\hat{\sigma}^2$ , não precisamos da Hip. 3.6 do quarto momento para  $\hat{S}$  ser consistente.

**Implicações da Homocedasticidade Condicional** Com homocedasticidade condicional simplesmente vários resultados podem ser simplificados com a substituição de  $S$  por  $\hat{\sigma}^2 S_{xx}$  e a expressão  $\hat{S}$  de  $(1/n) \sum_{i=1}^n \hat{\varepsilon}_i^2 x_i x_i'$  por  $\hat{S}$  em (48). As simplificações são as seguintes:

- O estimador GMM eficiente se torna 2SLS:

$$\begin{aligned} \tilde{\delta}(\hat{S}^{-1}) &= [S'_{xz}(\hat{\sigma}^2 S_{xx})^{-1} S_{xz}] S'_{xz}(\hat{\sigma}^2 S_{xx})^{-1} s_{xy} \\ &= [S'_{xz} S_{xx}^{-1} S_{xz}] S'_{xz} S_{xx}^{-1} s_{xy} \\ &= \tilde{\delta}(S_{xx}^{-1}) \equiv \tilde{\delta}_{2SLS} \end{aligned} \quad (49)$$

- Sob homocedasticidade condicional, não há necessidade do primeiro passo do estimador GMM porque o segundo passo se reduz ao estimador GMM com  $S_{xx}$  sendo usado para  $\hat{S}$ . Este estimador é chamado de Mínimo Quadrado de Dois-Estágios (2SLS) – Proposto por Theil (1953).

**Implicações da Homocedasticidade Condicional** –  $\text{Avar}(\tilde{\delta}_{2SLS})$  Podemos calcular a Avar para o caso do 2SLS:

$$\text{Avar}(\tilde{\delta}_{2SLS}) = \sigma^2 (\Sigma'_{xz} \Sigma_{xx}^{-1} \Sigma_{xz})^{-1}.$$

Um estimador natural para a Avar é:

$$\widehat{\text{Avar}}(\tilde{\delta}_{2SLS}) = \hat{\sigma}^2 (\mathbf{S}'_{xz} \mathbf{S}_{xx}^{-1} \mathbf{S}_{xz})^{-1}.$$

Para  $\hat{\sigma}^2$ , considere a variância amostral do resíduo do 2SLS:

$$\hat{\sigma}^2 \equiv \frac{1}{n} \sum_{i=1}^n (y_i - z'_i \hat{\delta}_{2SLS})^2.$$

Pela proposição 3.2,  $\hat{\sigma}^2 \rightarrow_p \sigma^2$  se  $E(z_i z'_i)$  existe é finito. Portanto, se  $\hat{\mathbf{S}}$  é definida como (48) com este  $\hat{\sigma}^2$  acima.

Substituindo (48) nas equações da razão t e da estatística de Wald, se tem:

$$t_\ell = \frac{\hat{\delta}_{2SLS,\ell} - \bar{\delta}_\ell}{SE_\ell} \quad (50)$$

com

$$SE_{\ell} \equiv \sqrt{\frac{\hat{\sigma}^2}{n} \left( (\mathbf{S}'_{xz} \mathbf{S}_{xx}^{-1} \mathbf{S}_{xz})^{-1} \right)_{\ell\ell}}$$
$$W = n \cdot \frac{\mathbf{a}(\hat{\delta}_{2SLS})' \left[ \mathbf{A}(\hat{\delta}_{2SLS})' (\mathbf{S}'_{xz} \mathbf{S}_{xx}^{-1} \mathbf{S}_{xz})^{-1} \mathbf{A}(\hat{\delta}_{2SLS})' \right]}{\hat{\sigma}^2} \quad (51)$$

## Implicações da Homocedasticidade Condicional

- Quando  $\hat{W} = (\hat{\sigma}^2 \mathbf{S}_{xx})^{-1}$ :

$$J(\tilde{\delta}, (\hat{\sigma}^2 \mathbf{S}_{xx})^{-1}) = n \frac{(\mathbf{s}_{xy} - \mathbf{S}_{xz} \tilde{\delta})' \mathbf{S}_{xx}^{-1} (\mathbf{s}_{xy} - \mathbf{S}_{xz} \tilde{\delta})}{\hat{\sigma}^2}$$

Para o estimador  $\tilde{\delta}_{2SLS}$ , a distância  $J$  é chamada de estatística de Sargan (1958):

$$\text{Estatística de Sargan} = n \frac{(\mathbf{s}_{xy} - \mathbf{S}_{xz} \tilde{\delta}_{2SLS})' \mathbf{S}_{xx}^{-1} (\mathbf{s}_{xy} - \mathbf{S}_{xz} \tilde{\delta}_{2SLS})}{\hat{\sigma}^2}$$

## 2SLS

### Proposição 3.9 (Propriedades assintóticas do 2SLS):

- (a) Sob as hipóteses 3.1-3.4, o estimador 2SLS é consistente. Se adicionamos a hipótese 3.5, o estimador é assintoticamente normal com a variância assintótica dada por  $Avar(\hat{\delta}_{2SLS})$  com  $\mathbf{W} = (\sigma^2 \Sigma_{xx})^{-1}$ . Se a hip. 3.7 é adicionada às hips. 3.1-3.5, então o estimador GMM é eficiente.

Além disso, se  $E(z_i z_i')$ , então:

- (b) a variância assintótica é consistentemente estimada por  $Avar(\tilde{\delta}_{2SLS})$ .

(c)  $t_\ell = \frac{\hat{\delta}_{2SLS,\ell} - \bar{\delta}_\ell}{SE_\ell} \rightarrow_d N(0, 1),$

$$W = n \frac{a(\hat{\delta}_{2SLS})' \{A(\hat{\delta}_{2SLS})(S'_{xz} S_{xx}^{-1} S_{xz})^{-1} A(\hat{\delta}_{2SLS})'\}^{-1}}{\hat{\sigma}^2} \chi^2(\#r), \text{ e}$$

(d) a estatística de Sargan  $\rightarrow_d \chi^2(K - L)$ .

## **GMM com múltiplas equações**

Estimar mais de uma equação conjuntamente por GMM.

O "payoff" de dominar a estimação de múltiplas equações é considerável. Quando se assume homocedasticidade condicional, o GMM se reduz ao "full-information instrumental variable efficient (FIVE) estimator", que se reduz no 3SLS se o conjunto de variáveis instrumentais é comum para todas as equações. Se assumirmos que todos os regressores são pre-determinados, 3SLS se reduz no estimador SUR (seemingly unrelated regressions), que por sua vez se reduz na regressão multivariada quando todas as equações possuem os mesmos regressores.

Será mostrado que o sistema de múltiplas equações pode ser escrito como um sistema de equação

com os coeficientes restritos a serem os mesmos entre equações. O estimador GMM para este sistema é de novo um caso especial do GMM de equação única. O estimador GMM quando todos os regressores são predeterminados e os erros são condicionalmente homocedásticos é chamado do estimador de efeitos aleatórios (RE). Assim sendo, SUR e RE são estimadores equivalentes.

## GMM com múltiplas equações

**Hip. 4.1 (linearidade):** Existem  $M$  equações lineares:

$$y_{im} = z'_{im}\delta_m + \varepsilon_{im} \quad (i = 1, 2, \dots)(m = 1, \dots, M).$$

$z$  é o vetor de regressores,  $\delta$  é o vetor dos coeficientes ( $L \times 1$ ). O modelo não faz hipóteses sobre a correlação entre os erros das equações. Além disso, não há restrições sobre os coeficientes de equações diferentes.

**Hip. 4.2 (estacionaridade ergódica):** Faça  $w_i$  serem os elementos únicos e não-constantemente de  $(y_{i1}, \dots, y_{iM}, z_{i1}, \dots, z_{iM}, x_{i1}, \dots, x_{iM})$ .  $\{w_i\}$  é conjuntamente estacionária e ergódica.

Condições de ortogonalidade é o conjunto das condições de ortogonalidade das condições individuais.

**Hip. 4.3 (condições de ortogonalidade):** Para cada equação  $m$ , as  $K_m$  variáveis em  $\mathbf{x}_{im}$  são pré-determinadas no sentido de que todas são ortogonais ao erro:  $E(\mathbf{x}_{im}\varepsilon_{im}) = \mathbf{0}$  para todo  $i$  e  $m(= 1, 2, \dots, M)$ . Ou seja, existem  $\sum_m K_m$  condições de ortogonalidade no total. Se nós definirmos

$$\left(\sum_{m=1}^M K_m \times 1\right) \mathbf{g}_i \equiv \begin{bmatrix} \mathbf{x}_{i1} \cdot \varepsilon_{i1} \\ \vdots \\ \mathbf{x}_{iM} \cdot \varepsilon_{iM} \end{bmatrix}. \quad (52)$$

então todas as condições de ortogonalidade podem ser escritas compactamente como

$$E(\mathbf{g}_i) = \mathbf{0} \quad (53)$$

Não é assumido *ortogonalidade cruzada*. Por exemplo,  $\mathbf{x}_{i1}$  não precisa ser ortogonal a  $\varepsilon_{i2}$ , embora tenha que ser a  $\varepsilon_{i1}$ . Todavia, se a variável for incluída em ambos os vetores, então a hipótese implica que a variável é ortogonal a ambos  $\varepsilon_{i1}$  e  $\varepsilon_{i2}$ .

Exemplo. Assuma  $\sum_m K_m$  como  $8(= 4 + 4)$  e  $g_i$  é

$$g_i = \begin{bmatrix} \varepsilon_{i1} \\ S_i \varepsilon_{i1} \\ EXP R_i \varepsilon_{i1} \\ MED_i \varepsilon_{i1} \\ \varepsilon_{i2} \\ S_i \varepsilon_{i2} \\ EXP R_i \varepsilon_{i2} \\ MED_i \varepsilon_{i2} \end{bmatrix}$$

Este é o caso pois  $x_{i1}$  e  $x_{i2}$  possuem o mesmo conjunto de instrumentos, cada instrumento é ortogonal a  $\varepsilon_{i1}$  e  $\varepsilon_{i2}$ .

## Identificação

Com as condições de ortogonalidade podemos derivar as condições de indentificação.

- Na versão de equação múltipla:

$$g(\mathbf{w}_i; \boldsymbol{\delta}) \equiv \begin{bmatrix} \mathbf{x}_{i1} \cdot (y_{i1} - \mathbf{z}'_{i1} \delta_1) \\ \vdots \\ \mathbf{x}_{iM} \cdot (y_{iM} - \mathbf{z}'_{iM} \delta_M) \end{bmatrix} \quad (54)$$

e  $\boldsymbol{\delta}$  sem o subscrito é o vetor "empilhado" dos coeficientes:

$$\boldsymbol{\delta} = [\delta_1 \dots \delta_M]'$$

## Identificação

- O vetor de coeficientes é identificado se  $\tilde{\delta} = \delta$  é a única solução para o sistema de equações:

$$E[g(w_i; \tilde{\delta})] = 0. \quad (55)$$

Nesse caso,

$$E[g(w_i; \tilde{\delta})] = \begin{bmatrix} E(x_{i1} \cdot y_{i1}) \\ \vdots \\ E(x_{iM} \cdot y_{iM}) \end{bmatrix} - \begin{bmatrix} E(x_{i1} \cdot z'_{i1}) & \cdots & \\ & \cdots & \\ & & E(x_{iM} \cdot z'_{iM}) \end{bmatrix} \begin{bmatrix} \\ \\ \\ \end{bmatrix}$$
$$E[g(w_i; \tilde{\delta})] \equiv \sigma_{xy} - \Sigma_{xz} \tilde{\delta}.$$

Logo, o sistema de equações determinando  $\tilde{\delta}$  pode ser escrito como:

$$\Sigma_{xz} \tilde{\delta} = \sigma_{xy}. \quad (56)$$

## Identificação

- Uma condição para identificação é que  $\Sigma_{xz}$  tenha posto completo. Mas como esta matriz é bloco-diagonal, esta condição é equivalente a:

### Hipótese 4.4 (condição de posto para identificação)

Para cada  $m = 1, \dots, M$ , a matriz  $E(\mathbf{x}_{im}\mathbf{z}'_{im})$  é posto-completo (de ordem  $K_m \times L_m$ ).

## Normalidade Assintótica

**Hipótese 4.5** ( $g_i$  é um mds com segundos momentos)  $\{g_i\}$  é uma sequência diferença martingale conjunta.  $S = E(g_i g_i')$  é não-singular.

- A matriz tem a seguinte estrutura:

$$S = \begin{matrix} E(g_i g_i') & = & (57) \\ (\sum_{m=1}^M K_m \times \sum_{m=1}^M K_m) \end{matrix}$$
$$= \begin{bmatrix} E(\varepsilon_{i1} \varepsilon_{i1} \mathbf{x}_{i1} \mathbf{x}'_{i1}) & \dots & E(\varepsilon_{i1} \varepsilon_{iM} \mathbf{x}_{i1} \mathbf{x}'_{iM}) \\ \vdots & & \vdots \\ E(\varepsilon_{iM} \varepsilon_{i1} \mathbf{x}_{iM} \mathbf{x}'_{i1}) & \dots & E(\varepsilon_{iM} \varepsilon_{iM} \mathbf{x}_{iM} \mathbf{x}'_{iM}) \end{bmatrix}$$

- Em suma, o modelo de múltiplas equações é um sistema onde se aplicam todas as hipóteses que fizemos para o modelo de equação simples, com a adição da estacionariedade conjunta.

## Definição GMM

Definição como em única equação. Faça  $\tilde{\delta}$  ser um valor hipotético dos parâmetros verdadeiros  $\delta$  e defina  $\mathbf{g}_n(\tilde{\delta})$ . A definição GMM é a mesma, mas a matriz de pesos  $\hat{\mathbf{W}}$  é agora  $(\sum_{m=1}^M K_m \times \sum_{m=1}^M K_m)$ . Agora podemos escrever a mesma de definição de  $\mathbf{g}$  para o análogo amostral:

$$\begin{aligned} \mathbf{g}_n(\tilde{\delta}) &= \quad (58) \\ &= \begin{bmatrix} \frac{1}{n} \sum_{i=1}^n \mathbf{x}_{i1} (y_{i1} - \mathbf{z}'_{i1} \tilde{\delta}_1) \\ \vdots \\ \frac{1}{n} \sum_{i=1}^n \mathbf{x}_{iM} (y_{iM} - \mathbf{z}'_{iM} \tilde{\delta}_M) \end{bmatrix} \\ &= \mathbf{s}_{xy} - \mathbf{S}_{xz} \tilde{\delta} \end{aligned}$$

## Teoria para Amostras-Grandes

A teoria de amostras grandes é a mesma de GMM de única equação. Apenas é realizada a substituição dos indicadores.

- (Teste de hipóteses) No caso presente de equações múltiplas,  $\delta$  é um vetor empilhado composto por coeficientes de equações diferentes. As proposições 3.3 e 3.8 (testes t, W e LR) permitem testar restrições entre equações.
- (Teste de restrições sobre-identificadas) O número de condições de ortogonalidade é  $\sum_{m=1}^M K_m$  e o número de coeficientes é  $\sum_{m=1}^M L_m$ . Os graus de liberdade para a estatística  $J$  na Proposição 3.6 são  $\sum_{m=1}^M K_m - \sum_{m=1}^M L_m$  e para a estatística  $C$  na Proposição 3.7 são o total de instrumentos suspeitos de diferentes equações.

**Proposição 4.1 (estimação consistente do erro contemporâneo dos momentos entre equações):** Faça  $\hat{\delta}_m$  ser um estimador consistente de  $\delta_m$  e faça  $\hat{\varepsilon}_{im} \equiv y_{im} - z'_{im}\hat{\delta}_m$  ser o resíduo de  $m = 1, 2, \dots, M$ . Sob as hips 4.1 e 4.2, mais a hipótese de que  $E(z_{im}z'_{ih})$  existe e é finito para todo  $m$ , e  $h (= 1, \dots, M)$ ,

$$\hat{\sigma}_{mh} \rightarrow_p \sigma_{mh}$$

tal que

$$\hat{\sigma}_{mh} = \frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_{im} \hat{\varepsilon}'_{ih} \text{ e } \sigma_{mh} \equiv E(\varepsilon_{im} \varepsilon'_{ih})$$

dado que  $E(\varepsilon_{im} \varepsilon'_{ih})$  existe e é finito.

$$\hat{\sigma}_{mh} \rightarrow_p \sigma_{mh} \quad (59)$$

tal que

$$\hat{\sigma}_{mh} \equiv \frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_{im} \hat{\varepsilon}_{ih} \text{ e } \sigma_{mh} \equiv E(\varepsilon_{im} \varepsilon_{ih})$$

dado que  $E(\varepsilon_{im} \varepsilon_{ih})$  existe e é finito.

## Estimando $S$ consistentemente

**Hipótese 4.6 (quarto momento finito):**  $E[(x_{imk}z_{ihj}]$  existe e é finito para todo  $k, j = (1, 2, \dots, K)$ ,  $m$  e  $h (= 1, \dots, M)$ , tal que  $x_{imk}$  é o  $k$ -ésimo elemento de  $\mathbf{x}_{im}$  e  $z_{ihj}$  é o  $j$ -ésimo elemento de  $\mathbf{z}_{ih}$ .

**Proposição 4.2 (estimação consistente de  $S$ , a v**

Faça  $\hat{\delta}_m$  ser um estimador consistente de  $\delta_m$ , e faça  $\hat{\varepsilon}_{im} \equiv y_{im} - \mathbf{z}'_{im}\hat{\delta}_m$  ser o resíduo para  $m = 1, \dots, M$ . Sob as hipóteses 4.1, 4.2 e 4.6,  $\hat{S}$  é consistente para  $S$ . Tal que:

$$\hat{S} = \frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_{im} \hat{\varepsilon}_{im} \mathbf{x}_{im} \mathbf{x}'_{im}$$

**Table 4.1: Multiple-Equation GMM in the Single-Equation Format**

Sample Analogue of  
 Orthogonality Conditions:  $\mathbf{g}_n(\hat{\delta}) = \mathbf{s}_{xy} - \mathbf{S}_{xz}\hat{\delta} = \mathbf{0}$   
 GMM Estimator:  $\hat{\delta}(\hat{\mathbf{W}}) = (\mathbf{S}'_{xz}\hat{\mathbf{W}}\mathbf{S}_{xz})^{-1}\mathbf{S}'_{xz}\hat{\mathbf{W}}\mathbf{s}_{xy}$   
 Its Sampling Error:  $\hat{\delta}(\hat{\mathbf{W}}) - \delta = (\mathbf{S}'_{xz}\hat{\mathbf{W}}\mathbf{S}_{xz})^{-1}\mathbf{S}'_{xz}\hat{\mathbf{W}}\hat{\mathbf{g}}$   
 Asymptotic Variance of  
 Optimal GMM:  $\text{Avar}(\hat{\delta}(\hat{\mathbf{S}}^{-1})) = (\boldsymbol{\Sigma}'_{xz}\mathbf{S}^{-1}\boldsymbol{\Sigma}_{xz})^{-1}$   
 Its Estimator:  $\text{Avar}(\hat{\delta}(\hat{\mathbf{S}}^{-1})) = (\mathbf{S}'_{xz}\hat{\mathbf{S}}^{-1}\mathbf{S}_{xz})^{-1}$   
 J Statistic:  $J(\hat{\delta}(\hat{\mathbf{S}}^{-1}), \hat{\mathbf{S}}^{-1}) = n \cdot \mathbf{g}'_n(\hat{\delta}(\hat{\mathbf{S}}^{-1}))\hat{\mathbf{S}}^{-1}\mathbf{g}_n(\hat{\delta}(\hat{\mathbf{S}}^{-1}))$

	Single-Equation GMM applied to the equation in question	Multiple-Equation GMM
$\mathbf{g}_i$	$\mathbf{x}_i \cdot \varepsilon_i$	(4.1.4)
$\delta$	$\beta$	(4.1.6)
$\mathbf{s}_{xy}$	$\frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \cdot y_i$	(4.2.2)
$\mathbf{S}_{xz}$	$\frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}'_i$	(4.2.2)
Size of $\mathbf{W}$	$K \times K$	$\sum_m K_m \times \sum_m K_m$
$\boldsymbol{\Sigma}_{xz}$	$E(\mathbf{x}_i \varepsilon'_i)$	(4.1.9)
$\mathbf{S}$ (= $\text{Avar}(\hat{\mathbf{g}})$ )	$E(\varepsilon_i^2 \mathbf{x}_i \mathbf{x}'_i)$	(4.1.11)
$\hat{\mathbf{S}}$	$\frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_i^2 \mathbf{x}_i \mathbf{x}'_i$	(4.3.2)
Estimator consistent under which assumptions?	3.1–3.4	4.1–4.4
Estimator asymptotic normal under which assumptions?	3.1–3.5	4.1–4.5
$\hat{\mathbf{S}} \rightarrow_p \mathbf{S}$ under which assumptions?	3.1, 3.2, 3.6, $E(\mathbf{g}_i \mathbf{g}'_i)$ finite	4.1, 4.2, 4.6, $E(\mathbf{g}_i \mathbf{g}'_i)$ finite
d.f. of $J$	$K - L$	$\sum_m (K_m - L_m)$

Se pelo menos uma das  $M$  equações é sobreidentificada então a escolha de  $\hat{\mathbf{W}}$  afeta o valor do estimador GMM, quando comparado com a alternativa de estimar cada  $M$  equação em separado.

### **Proposição 4.3 (equivalência entre estimação GMM)**

Se todas as equações são exatamente identificadas, então a estimação GMM equação por equação e por múltiplas equações são numericamente os mesmos e igual ao estimador IV.

- Se ao menos uma equação é sobreidentificada mas a equação é “não-relacionada” no sentido de  $E(\varepsilon_{im}\varepsilon_{ih})\mathbf{x}_{im}\mathbf{x}'_{ih} = 0$ , então a estimativa eficiente equação por equação e por equação múltipla são assintoticamente equivalentes dado que  $\sqrt{n}$  vezes a diferença converge em probabilidade para zero.

## Homocedasticidade Condicional

Assumindo homocedasticidade condicional:

### Hipótese 4.7 (homocedasticidade condicional:)

$$E(\varepsilon_{im}\varepsilon_{ih} \mid \mathbf{x}_{im}, \mathbf{x}_{ih}) = \sigma_{mh}$$

para todo  $m, h = 1, 2, \dots, M$ .

Portanto, os momentos cruzados condicionais  $E(\varepsilon_{im}\varepsilon_{ih})$  é igual a  $\sigma_{mh}$  pelo lei das expectativas totais.

Portanto a  $S$  em (4.1.11) pode ser escrita como:

$$S = \begin{bmatrix} \sigma_{11}E(\mathbf{x}_{i1}\mathbf{x}'_{i1}) & \dots & \sigma_{1M}(E\mathbf{x}_{i1}\mathbf{x}'_{iM}) \\ \vdots & & \vdots \\ \sigma_{M1}E(\mathbf{x}_{iM}\mathbf{x}'_{i1}) & \dots & \sigma_{MM}(E\mathbf{x}_{iM}\mathbf{x}'_{iM}) \end{bmatrix} \quad (60)$$

Como pela Hipótese 4.5  $\mathcal{S}$  é finita, esta decomposição implica que  $E(\mathbf{x}_{im}\mathbf{x}'_{ih})$  existe e é finito para todo  $m, h (= 1, 2, \dots, M)$ .

## FIVE: Full-Information Instrumental Variables Efficient

Um estimador de  $\mathcal{S}$  explorando a estrutura do quarto momento mostrado em (60)

$$\hat{\mathcal{S}} = \begin{bmatrix} \hat{\sigma}_{11} \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_{i1} \mathbf{x}'_{i1} \right) & \cdots & \hat{\sigma}_{1M} \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_{i1} \mathbf{x}'_{iM} \right) \\ \vdots & & \vdots \\ \hat{\sigma}_{M1} \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_{iM} \mathbf{x}'_{i1} \right) & \cdots & \hat{\sigma}_{MM} \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_{iM} \mathbf{x}'_{iM} \right) \end{bmatrix} \quad (61)$$

Neste caso, para algum estimador consistente  $\hat{\delta}_m$  de  $\delta$ ,

$$\hat{\sigma}_{mh} \equiv \frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_{im} \hat{\varepsilon}_{ih}, \quad \text{com } \hat{\varepsilon}_{ih} \equiv y_{im} - \mathbf{z}'_i \hat{\delta}_m \quad (62)$$

## FIVE: Full-Information Instrumental Variables Efficient

Estimador FIVE  $\hat{\delta}_{FIVE} \equiv \hat{\delta}(\hat{S}^{-1})$ , com  $\hat{S}^{-1}$  dada por (61).

### Proposição 4.4 (propriedades de amostras grand

Suponha que as Hipóteses 4.1-4.5 e 4.7 valem. Suponha também que  $E(z_{im}z'_{ih})$  existe para todo  $m$  e  $h$ . Faça  $S$  e  $\hat{S}$  como definido em (60) e (61), respectivamente. Então:

- $\hat{S} \rightarrow_p S$ ;
- $\hat{\delta}_{FIVE} \equiv \hat{\delta}(\hat{S}^{-1})$  é consistente, assintoticamente normal e eficiente com  $Avar(\hat{\delta}_{FIVE})$  dado por (37) (ver GMM cap. 3);
- A variância assintótica estimada dada por (38) é consistente para  $Avar(\hat{\delta}_{FIVE})$ ;

- Estatística Sargan dada por

$$J(\hat{\delta}_{FIVE}, \hat{S}^{-1}) = n \cdot \mathbf{g}_n(\hat{\delta}_{FIVE})' \hat{S}^{-1} \mathbf{g}_n(\hat{\delta}_{FIVE}) \rightarrow \quad (63)$$

tal que  $\mathbf{g}_n(\cdot)$  é dada por (58).

### 3SLS

Quando os instrumentos do modelo FIVE são os mesmos entre equações então temos o estimador 3SLS:  $\hat{\delta}_{3SLS} \equiv \hat{\delta}(\hat{S}^{-1})$ .

Defina:

$$\underset{(M \times 1)}{\varepsilon_i} = \begin{bmatrix} \varepsilon_{i1} \\ \vdots \\ \varepsilon_{iM} \end{bmatrix}$$

A matriz dos momentos cruzados de  $\varepsilon_i$  é:

$$\underset{(M \times M)}{\Sigma} = E(\varepsilon_i \varepsilon_i') = \begin{bmatrix} \sigma_{11} & \dots & \sigma_{1M} \\ \vdots & & \vdots \\ \sigma_{M1} & \dots & \sigma_{MM} \end{bmatrix} \quad (64)$$

Para estimar  $\Sigma$  precisamos de um estimador inicial consistente de  $\delta_m$  para calcular  $\hat{\varepsilon}_{im}$ . Um estimador 2SLS é usado para calcular esta estimativa inicial. Dados estes resíduos um estimador natural de

$$\hat{\Sigma} = \frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_i \hat{\varepsilon}_i' \quad (65)$$

Se  $\mathbf{x}_i = \mathbf{x}_{i1} = \mathbf{x}_{i2} = \dots$  é o conjunto comum de instrumentos (dimensão  $K$ ), então  $\mathbf{g}_i$  dado por (52),  $\mathbf{S}$  por (60) e  $\hat{\mathbf{S}}$  por (61) pode ser escrito como:

$$\underset{(MK \times 1)}{\mathbf{g}_i} = \boldsymbol{\varepsilon}_i \otimes \mathbf{x}_i \quad (66)$$

$$\underset{(MK \times MK)}{\mathbf{S}} = \underset{(M \times M)}{\boldsymbol{\Sigma}} \otimes \underset{(K \times K)}{\mathbf{E}(\mathbf{x}_i \mathbf{x}'_i)} \quad (67)$$

com

$$\begin{aligned} \mathbf{S}^{-1} &= \boldsymbol{\Sigma}^{-1} \otimes [\mathbf{E}(\mathbf{x}_i \mathbf{x}'_i)]^{-1} \\ \hat{\mathbf{S}} &= \hat{\boldsymbol{\Sigma}} \otimes \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}'_i \right) \end{aligned} \quad (68)$$

então

$$\hat{\mathbf{S}}^{-1} = \hat{\boldsymbol{\Sigma}}^{-1} \otimes \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}'_i \right)^{-1}$$

( $\boldsymbol{\Sigma}$  e  $\mathbf{E}(\mathbf{x}_i \mathbf{x}'_i)$  não são singulares.) A matriz e

pesos é:

$$\widehat{W}_{mh} = \widehat{\sigma}^{mh} \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}'_i \right)^{-1} \quad (69)$$

aqui  $\widehat{\sigma}^{mh}$  é o elemento  $(m, h)$  de  $\widehat{\Sigma}^{-1}$ . Substitua  $\widehat{W}$  na equação  $\widehat{\delta}(\widehat{W})$  (4.2.6):

$$\widehat{\delta}_{3SLS} = \begin{bmatrix} \widehat{\sigma}^{11} \widehat{A}_{11} & \dots & \widehat{\sigma}^{1M} \widehat{A}_{1M} \\ \vdots & & \vdots \\ \widehat{\sigma}^{M1} \widehat{A}_{M1} & \dots & \widehat{\sigma}^{MM} \widehat{A}_{MM} \end{bmatrix}^{-1} \begin{bmatrix} \widehat{\sigma}^{11} \widehat{c}_{11} & \dots \\ \vdots & \\ \widehat{\sigma}^{M1} \widehat{c}_{M1} & \dots \end{bmatrix} \quad (70)$$

tal que

$$\widehat{A}_{mh} = \left( \frac{1}{n} \sum_{i=1}^n z_{im} \mathbf{x}'_i \right) \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}'_i \right)^{-1} \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i z'_{ih} \right) \quad (71)$$

$$\widehat{c}_{mh} = \left( \frac{1}{n} \sum_{i=1}^n z_{im} \mathbf{x}'_i \right) \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}'_i \right)^{-1} \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i y_{ih} \right) \quad (72)$$

A expressão para a variância é:

$$\text{Avar}(\hat{\delta}_{3SLS}) = \begin{bmatrix} \sigma^{11} \mathbf{A}_{11} & \dots & \sigma^{1M} \mathbf{A}_{1M} \\ \vdots & & \vdots \\ \sigma^{M1} \mathbf{A}_{M1} & \dots & \sigma^{MM} \mathbf{A}_{MM} \end{bmatrix}^{-1} \quad (73)$$

para  $\hat{\mathbf{A}}_{mh} = E(z_{im} \mathbf{x}'_i) E(\mathbf{x}_i \mathbf{x}'_i)^{-1} E(\mathbf{x}_i z'_{ih})$ . A matriz da variância é consistentemente estimada por:

$$\widehat{\text{Avar}}(\hat{\delta}_{3SLS}) = \begin{bmatrix} \hat{\sigma}^{11} \hat{\mathbf{A}}_{11} & \dots & \hat{\sigma}^{1M} \hat{\mathbf{A}}_{1M} \\ \vdots & & \vdots \\ \hat{\sigma}^{M1} \hat{\mathbf{A}}_{M1} & \dots & \hat{\sigma}^{MM} \hat{\mathbf{A}}_{MM} \end{bmatrix}^{-1} \quad (74)$$

### Proposição 4.5 (propriedades de amostras grand

Suponha que as Hipóteses 4.1-4.5 e 4.7 valem e que os instrumentos são comuns:  $\mathbf{x}_{im} = \mathbf{x}_i$ . Suponha também que  $E(z_{im} z'_{ih})$  existe para todo  $m$  e  $h$ . Faça  $\hat{\Sigma}$  ser a matriz de momentos cruzados do termo de erro calculada por (65) usando os resíduos de 2SLS. Então:

- $\hat{\delta}_{3SLS}$  dado por (70) é consistente, assintoticamente normal e eficiente com  $\text{Avar}(\hat{\delta}_{3SLS})$  dada por (73);
- A variância assintótica estimada dada por (74) é consistente para  $\text{Avar}(\hat{\delta}_{3SLS})$ ;
- Estatística Sargan dada por

$$J(\hat{\delta}_{3SLS}, \hat{\mathbf{S}}^{-1}) = n \cdot \mathbf{g}_n(\hat{\delta}_{3SLS})' \hat{\mathbf{S}}^{-1} \mathbf{g}_n(\hat{\delta}_{3SLS}) \rightarrow_d \quad (75)$$

tal que  $\mathbf{g}_n(\cdot)$  é dada por (58),  $K$  é o número de instrumentos comuns e  $\hat{\mathbf{S}} = \hat{\Sigma} \otimes \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)$ .

## SUR – Seemingly Unrelated Regression

3SLS pode ser simplificado se

$$\mathbf{x}_i = \text{união de } (z_{i1}, \dots, z_{iM}) \quad (76)$$

Isto é equivalente a condição

$$E(z_{im}\varepsilon_{ih}) = 0 \quad (77)$$

Isto significa que os regressores predeterminados satisfazem as ortogonalidades cruzadas. Aqui eles não são apenas determinados em cada equação,  $E(z_{im}\varepsilon_{im}) = 0$ , mas também predeterminados entre equações,  $E(z_{im}\varepsilon_{ih}) = 0$ , para  $h \neq m$ . Esta forma simplificada é chamada de estimativa SUR,  $\hat{\delta}_{SUR}$ .

Como SUR é um caso especial do 3SLS as fórmulas que se aplicam para ambos os casos. A implicação do estimador SUR é que nas expressões para  $\hat{A}_{mh}$ ,  $\hat{c}_{mh}$  e  $A_{mh}$  o  $\mathbf{x}_i$  desaparece.

$$\hat{A}_{mh} = \frac{1}{n} \sum_{i=1}^n z_{im} z'_{ih} \quad (78)$$

$$\hat{c}_{mh} = \frac{1}{n} \sum_{i=1}^n z_{im} y_{ih} \quad (79)$$

$$\hat{A}_{mh} = E(z_{im} z'_{ih}) \quad (80)$$

### Proposição 4.6 (propriedades de amostras grand

Suponha que as Hipóteses 4.1-4.5 e 4.7 valem e que os instrumentos são:  $x_i =$  união de  $(z_{i1}, \dots, z_{iM})$ . Faça  $\hat{\Sigma}$  ser a matriz de momentos cruzados do termo de erro calculada por (65) usando os resíduos OLS. Então:

- $\hat{\delta}_{SUR}$  com  $\hat{A}_{mh}$  dada por (78),  $\hat{c}_{mh}$  dado por (79) é consistente, assintoticamente normal e eficiente com  $Avar(\hat{\delta}_{SUR})$  dada por (73) com  $\hat{A}_{mh}$  dado por (80).
- A variância assintótica estimada dada por (74),  $\hat{A}_{mh}$  dada por (78), é consistente para  $Avar(\hat{\delta}_{SUR})$ ;

- Estatística Sargan dada por

$$J(\hat{\delta}_{SUR}, \hat{S}^{-1}) = n \cdot \mathbf{g}_n(\hat{\delta}_{SUR})' \hat{S}^{-1} \mathbf{g}_n(\hat{\delta}_{SUR}) \rightarrow_d \chi^2 \quad (81)$$

tal que  $\mathbf{g}_n(\cdot)$  é dada por (58),  $K$  é o número de instrumentos comuns e  $\hat{S} = \hat{\Sigma} \otimes \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)$ .

Eficiência do SUR: exemplo modelo de regressão multivariada com restrições de exclusão – SUR mais eficiente do que OLS equação por equação. Suponha o sistema:

$$LW_i = \phi_1 + \beta_1 S_i + \gamma_1 IQ_i + \pi_1 EXP R_i + \varepsilon_{i1}$$

$$KWW_i = \phi_2 + \beta_2 S_i + \gamma_2 IQ_i + \pi_2 EXP R_i + \varepsilon_{i2}$$

O conjunto de instrumentos comuns é  $(1, S_i, IQ_i, EXP R_i)$ . Este sistema é um modelo de regressão multivariada com o mesmo conjunto de regressores. Mas se  $\pi_2$  é a priori restrito para ser 0, significando que  $EXP R_i$  é excluída da segunda equação, então o modelo se torna o SUR. O SUR é mais eficiente do que o modelo multivariado pois explora a restrição de exclusão.

## Coeficiente Comum

Panel data: caso particular do modelo GMM de múltiplas equações impondo restrição de regressores comuns.

O sistema agora pode ser escrito como:

**Hip. 4.1 (linearidade):** Existem  $M$  equações lineares:

$$y_{im} = z'_{im}\delta + \varepsilon_{im} \quad (i = 1, 2, \dots)(m = 1, \dots, M).$$

$z$  é o vetor de regressores,  $\delta$  é o vetor dos coeficientes ( $L \times 1$ ) comum a todas as equações. O modelo não faz hipóteses sobre a correlação entre os erros das equações. Além disso, não há restrições sobre os coeficientes de equações diferentes.

Apenas é necessário modificar a Hipótese 4.4 (identificação). A versão de  $g(\cdot)$  é a seguinte:

$$g(w_i; \tilde{\delta}) \equiv \begin{bmatrix} x_{i1} \cdot (y_{i1} - z'_{i1} \tilde{\delta}) \\ \vdots \\ x_{iM} \cdot (y_{iM} - z'_{iM} \tilde{\delta}) \end{bmatrix} \quad (82)$$

neste caso temos

$$E[g(w_i; \tilde{\delta})] = \begin{bmatrix} E(x_{i1} \cdot y_{i1}) \\ \vdots \\ E(x_{iM} \cdot y_{iM}) \end{bmatrix} - \begin{bmatrix} E(x_{i1} \cdot z'_{i1}) \tilde{\delta} \\ \vdots \\ E(x_{iM} \cdot z'_{iM}) \tilde{\delta} \end{bmatrix} \quad (83)$$

$$E[g(w_i; \tilde{\delta})] = \begin{matrix} \sigma_{xy} \\ (\sum_{m=1}^M K_m \times 1) \end{matrix} - \begin{matrix} \Sigma_{xz} \\ (\sum_{m=1}^M K_m \times L) \end{matrix} \begin{matrix} \tilde{\delta} \\ (L \times 1) \end{matrix}$$

A implicação de coeficientes comuns significa que a matriz  $\Sigma_{xz}$  é agora empilhada, não uma matriz bloco diagonal.

A condição para identificação é:

**Hipótese 4.4' (condição de posto):** A matriz  $\Sigma_{xz}$  definida em (83) é posto completo.  $(\sum_{m=1}^M K_m \times L)$

Essa condição é mais fraca do que a Hipótese 4.4, que requer que cada equação do sistema seja identificada. Portanto, uma condição suficiente para identificação é que  $E(x_{im} \cdot z'_{im})$  seja posto completo para algum  $m$ . É possível que o sistema seja identificado mesmo se nenhuma das equações seja identificada individualmente.

## GMM – Coeficiente Comum

O estimador GMM é:

$$\begin{aligned} \hat{\delta}(\hat{W}) &= \\ &= \left[ \sum_{m=1}^M \sum_{h=1}^M \left\{ \left( \frac{1}{n} \sum_{i=1}^n z_{im} \cdot \mathbf{x}'_{im} \right) \hat{W}_{mh} \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_{ih} \cdot \mathbf{z}'_{ih} \right) \right\} \right]^{-1} \\ &\quad \left[ \sum_{m=1}^M \sum_{h=1}^M \left\{ \left( \frac{1}{n} \sum_{i=1}^n z_{im} \cdot \mathbf{x}'_{im} \right) \hat{W}_{mh} \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_{ih} \cdot y_{ih} \right) \right\} \right] \end{aligned} \quad (84)$$

O estimador eficiente é obtido com  $\hat{W}$  sendo substituído pela inversa de  $\hat{S}$ .

## Impondo Homocedasticidade Condicional

Como antes se pode impor homocedasticidade condicional. O estimador FIVE é obtido se é aplicada a correspondente matriz  $\hat{S}$ .

Assumindo que os conjuntos de instrumentos são os mesmos entre as equações, então, se tem a estimativa de  $\hat{S}$ :

$$\hat{S} = \hat{\Sigma} \otimes \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}'_i \right) \quad (85)$$

data a estimativa de  $\hat{W}_{mh}$  se chega no estimador 3SLS com coeficientes comuns:

$$\begin{aligned} \hat{\delta}_{3SLS} &= \\ &= \left[ \sum_{m=1}^M \sum_{h=1}^M \left\{ \hat{\sigma}^{mh} \left( \frac{1}{n} \sum_{i=1}^n \mathbf{z}_{im} \cdot \mathbf{x}'_i \right) \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \cdot \mathbf{x}'_i \right)^{-1} \left( \frac{1}{n} \sum_{i=1}^n \mathbf{z}_{im} \cdot \mathbf{y}_i \right) \right. \right. \\ &\quad \left. \left[ \sum_{m=1}^M \sum_{h=1}^M \left\{ \hat{\sigma}^{mh} \left( \frac{1}{n} \sum_{i=1}^n \mathbf{z}_{im} \cdot \mathbf{x}'_i \right) \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \cdot \mathbf{x}'_i \right)^{-1} \left( \frac{1}{n} \sum_{i=1}^n \mathbf{z}_{im} \cdot \mathbf{y}_i \right) \right. \right. \end{aligned}$$

tal que  $\hat{\sigma}^{mh}$  é o elemento  $(m, h)$  de  $\hat{\Sigma}^{-1}$ .

## Estimador de Efeitos Aleatórios

Assumindo as condições do estimador SUR, “desaparecimento de  $x$ ,” o estimador GMM passa a ser o estimador de *efeitos-aleatórios*:

$$\hat{\delta}_{RE} = \left[ \sum_{m=1}^M \sum_{h=1}^M \hat{\sigma}^{mh} \left( \frac{1}{n} \sum_{i=1}^n z_{im} \cdot z'_{ih} \right) \right]^{-1} \left[ \sum_{m=1}^M \sum_{h=1}^M \left( \frac{1}{n} \sum_{i=1}^n z_{im} \cdot y_{ih} \right) \right] \quad (87)$$

A variância assintótica é

$$\text{Avar}(\hat{\delta}_{RE}) = \left[ \sum_{m=1}^M \sum_{h=1}^M \sigma^{mh} \mathbb{E} \left( z_{im} \cdot z'_{ih} \right) \right]^{-1} \quad (88)$$

$$\widehat{\text{Avar}}(\hat{\delta}_{RE}) = \left[ \sum_{m=1}^M \sum_{h=1}^M \hat{\sigma}^{mh} \left( \frac{1}{n} \sum_{i=1}^n z_{im} \cdot z'_{ih} \right) \right]^{-1} \quad (89)$$

## Estimador de Efeitos Aleatórios

### Proposição 4.7 (propriedades de amostras grand

Suponha que as Hipóteses 4.1', 4.2, 4.3, 4.4', 4.5 e 4.7 valem e que os instrumentos são:  $\mathbf{x}_i =$  união de  $(z_{i1}, \dots, z_{iM})$ . Faça  $\hat{\Sigma}$  ser a matriz de momentos cruzados do termo de erro calculada por (65) usando os resíduos OLS e  $\hat{\Sigma}$  uma estimativa consistente de  $\Sigma$ . Então:

- $\hat{\delta}_{RE}$  é consistente, assintoticamente normal e eficiente com  $Avar(\hat{\delta}_{RE})$  dada por (88).
- A variância assintótica estimada dada por (89) é consistente para  $Avar(\hat{\delta}_{RE})$ ;
- Estatística Sargan dada por

$$J(\hat{\delta}_{RE}, \hat{\mathbf{S}}^{-1}) = n \cdot \mathbf{g}_n(\hat{\delta}_{RE})' \hat{\mathbf{S}}^{-1} \mathbf{g}_n(\hat{\delta}_{RE}) \rightarrow_d \chi^2(M) \quad (90)$$

tal que  $\mathbf{g}_n(\cdot)$  é dada por (58),  $K$  é o número de instrumentos comuns e  $\hat{\mathbf{S}} = \hat{\Sigma} \otimes \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)$ .

## Pooled OLS

Para o modelo SUR foi estimado  $\hat{\Sigma}$  a partir dos resíduos OLS (equação por equação). Vamos assumir que os coeficientes a serem estimados são os mesmos para todas as equações na estimação de  $\hat{\Sigma}$ . Então considere determinar  $\hat{W}$  como

$$\mathbf{I}_M \otimes \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)^{-1} \quad (91)$$

ao invés de

$$\hat{\Sigma}^{-1} \otimes \left( \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' \right)^{-1} \quad (92)$$

no primeiro estágio da estimativa GMM para obter a estimativa consistente inicial de  $\delta$ . Este estimador é o RE (87) com  $\hat{\sigma}^{mh} = 1$  para  $m = h$  e 0 para  $m \neq h$ , que pode ser escrito

como:

$$\begin{aligned}\hat{\delta}_{POLS} &= \left[ \sum_{m=1}^M \left( \frac{1}{n} \sum_{i=1}^n z_{im} \cdot z'_{im} \right) \right]^{-1} \left[ \sum_{m=1}^M \left( \frac{1}{n} \sum_{i=1}^n z_{im} \cdot y_{im} \right) \right] \\ &= \left( \sum_{i=1}^n \sum_{m=1}^M z_{im} \cdot z'_{im} \right)^{-1} \left( \sum_{i=1}^n \sum_{m=1}^M z_{im} \cdot y_{im} \right)\end{aligned}\tag{93}$$

Este é o modelo OLS com amostra de tamanho  $nM$  onde as observações são empilhadas nas equações. Por esta razão o estimador é chamado de *Pooled OLS*.

A variância assintótica para o POLS é

$$\text{Avar}(\hat{\delta}_{POLS}) = \left( \sum_{m=1}^M \text{E}(z_{im} \cdot z'_{im}) \right)^{-1} \sum_{m=1}^M \sum_{h=1}^M \sigma_{mh} \text{E}(z_{im} \cdot z'_{ih})\tag{94}$$

$$\widehat{\text{Avar}}(\hat{\delta}_{POLS}) = \left( \sum_{m=1}^M \frac{1}{n} \sum_{i=1}^n z_{im} \cdot z'_{im} \right)^{-1} \sum_{m=1}^M \sum_{h=1}^M \hat{\sigma}_{mh} \frac{1}{n} \sum_{i=1}^n z_{im} \cdot z'_{ih}\tag{95}$$

Como o estimador é consistente, então o resíduo pode ser usado para calcular  $\hat{\sigma}_{mh}$  nesta expressão. Os erros-padrão corretos do Pooled OLS são a raiz quadrada de  $(1/n \times)$  os elementos da diagonal desta matriz.

## Flexibilidade definições

Um modelo completo de duas equações se encaixa na Definição 4.1'. Suponha o exemplo 4.1 e defina as matrizes da seguinte forma:

$$z_{i1} = \begin{bmatrix} 1 \\ S_i \\ IQ_i \\ EXPR_i \\ 0 \\ 0 \\ 0 \end{bmatrix}, \quad z_{i1} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 1 \\ S_i \\ EXPR_i \end{bmatrix}, \quad z_{i1} = \begin{bmatrix} \phi_1 \\ \beta_1 \\ \gamma_1 \\ \pi \\ \phi_2 \\ \beta_2 \\ \gamma_2 \end{bmatrix}$$

Um sistema com apenas um subconjunto de variáveis comuns também pode ser escrito na forma da Hipótese 4.1. Considere o Exemplo 4.2 assumindo que  $IQ$  e  $S$  são constantes no tempo. Então:

$$z_{i1} = \begin{bmatrix} 1 \\ 0 \\ S69_i \\ IQ_i \\ EXPR69_i \end{bmatrix}, \quad z_{i1} = \begin{bmatrix} 1 \\ 0 \\ S80_i \\ IQ_i \\ EXPR80_i \end{bmatrix}, \quad z_{i1} = \begin{bmatrix} \phi_1 \\ \phi_2 \\ \beta \\ \gamma \\ \pi \end{bmatrix}$$

Assim a restrição de coeficientes comuns não é tão restritiva.

## Modelo de Componentes de Erro (Cap.5)

Modelo de múltiplas equações com coeficientes comuns (Proposição 4.7).

Considere um sistema de  $M$  equações lineares, amostras aleatórias e as hipóteses "SUR":

$$\mathbf{y}_i = \mathbf{Z}_i \boldsymbol{\delta} + \boldsymbol{\varepsilon}_i \quad (96)$$

$$\{\mathbf{y}_i, \mathbf{Z}_i\} \text{ são i.i.d.} \quad (97)$$

$$E(z_{im} \varepsilon_{ih}) = 0 \quad (98)$$

neste caso  $E(\boldsymbol{\varepsilon}_i \otimes \mathbf{x}_i) = 0$  tal que  $\mathbf{x}$  é a união de todos os  $\mathbf{z}$ .

Identificação:  $E(\mathbf{Z}_i \otimes \mathbf{x}_i)$  é posto completo.

Homocedasticidade condicional:

$$E(\boldsymbol{\varepsilon}_i \boldsymbol{\varepsilon}_i' | \mathbf{x}_i) = E(\boldsymbol{\varepsilon}_i \boldsymbol{\varepsilon}_i') = \boldsymbol{\Sigma} \quad (99)$$

$$E(\mathbf{g}_i \mathbf{g}_i') \text{ é não singular, com } \mathbf{g}_i = \boldsymbol{\varepsilon}_i \otimes \mathbf{x}_i \quad (100)$$

Como notado na seção 4.5,  $E(\mathbf{g}_i \mathbf{g}_i') = \Sigma \otimes E(\mathbf{x}_i \mathbf{x}_i')$  sob homocedasticidade condicional, (5.1.6) é equivalente a condição

$$\Sigma \text{ e } E(\mathbf{x}_i \mathbf{x}_i') \text{ são não singulares.} \quad (101)$$

*Componente de Erros:* Se assume que o termo de erro possa ser decomposto como:

$$\varepsilon_{im} = \alpha_i + \eta_{im} \quad (102)$$

O termo  $\alpha_i$  é chamado de *efeito individual*, *heterogeneidade individual*, ou o *efeito fixo*.

Defina o modelo em forma matricial:

$$\mathbf{y}_i = \mathbf{Z}_i \boldsymbol{\delta} + \mathbf{1}_M \cdot \alpha_i + \boldsymbol{\eta}_i \quad (103)$$

tal que:

$$\begin{bmatrix} y_{i1} \\ \vdots \\ y_{iM} \end{bmatrix} = \begin{bmatrix} z_{i1}\boldsymbol{\delta} \\ \vdots \\ z_{iM}\boldsymbol{\delta} \end{bmatrix} + \begin{bmatrix} \alpha_i \\ \vdots \\ \alpha_i \end{bmatrix} + \begin{bmatrix} \boldsymbol{\eta}_{i1} \\ \vdots \\ \boldsymbol{\eta}_{iM} \end{bmatrix} \quad (104)$$

A condições de ortogonalidade (98) são satisfeitas se os regressores do sistema são ortogonais a ambos componentes de erro, isto é, se

$$E(z_{im}\alpha_i) = 0 \quad (105)$$

e

$$E(z_{im}\boldsymbol{\eta}_i) = 0 \quad (106)$$

Todavia em muitas aplicações não é uma hipótese razoável. Isto ocorre porque o efeito fixo representa algumas características permanentes da unidade económica individual. Ver exemplo.

## Modelo de Componentes de Erro

### Função de produção com heterogeneidade

Continuação exemplo da sec. 3.2.

Usando o exemplo da função de produção log-linear, suponha que a eficiência da firma,  $u_i$ , permaneça constante ao longo do tempo. Então a equação para o ano  $m$  é:

$$\log(Q_{im}) = \phi_0 + \phi_1 \log(L_{im}) + u_i + v_{im}$$

onde  $Q_{im}$  é a produção da firma  $i$  no tempo  $m$ ,  $L_{im}$  é o fator trabalho e  $v_{im}$  é o choque tecnológico. Esta equação pode ser escrita na forma matricial (vetorial) fazendo:

$$y_{im} = \log(Q_{im}); z_{im} = (1, \log(L_{im}))'; \delta = (\phi_0, \phi_1)';$$

$$\alpha_i = u_i; \eta_{im} = v_{im}$$

Além disso,

$$x_i = (1, \log(L_{i1}), \dots, \log(L_{iM}))'$$

sob concorrência perfeita, o efeito fixo  $u_i$  deveria ser positivamente correlacionado com o insumo trabalho porque firmas eficientes, dado que  $u_i$  é maior do que a média, deveriam contratar mais trabalho para expandir suas atividades. Se  $v_{im}$  representa choques não esperados pela firma *quando* ela escolhe insumos, é razoável supor que  $v_{im}$  não é relacionado com os regressores.

## Modelo de Componentes de Erro

**equação salarial** Continuação exemplo 4.2.

Suponha o exemplo sem experiência (*EXPR*), mas com  $m = 1969, 1980, 1982$ . Suponha coeficientes para escolaridade  $S$  e  $IQ$  constantes ao longo do tempo, mas o intercepto pode variar. Com a decomposição do termo de erro o sistema é

$$LW69_i = \phi_1 + \beta S69_i + \gamma IQ_i + \alpha_i + \eta_{i1}$$

$$LW80_i = \phi_1 + \beta S80_i + \gamma IQ_i + \alpha_i + \eta_{i1}$$

$$LW82_i = \phi_1 + \beta S82_i + \gamma IQ_i + \alpha_i + \eta_{i1}$$

Escrevendo usando a definição de *coeficientes comuns*:

$$\mathbf{Z}_i = \begin{bmatrix} z'_{i1} \\ z'_{i2} \\ z'_{i3} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & S69_i & IQ_i \\ 0 & 1 & 0 & S80_i & IQ_i \\ 0 & 0 & 1 & S82_i & IQ_i \end{bmatrix}, \quad \boldsymbol{\delta}' = (\phi_1, \phi_2, \phi_3, \beta, \gamma)$$

(107)

$$\mathbf{x}_i = (1, S69_i, S80_i, S82_i, IQ_i)'$$

O termo de erro inclui os determinantes que não estão na equação salarial. Pode ser razoável assumir que eles são divididos entre o que é permanente para o indivíduo (afetando escolha de educação, por exemplo) e o que não é relacionado com determinantes do salário (erro de medida do salário, por exemplo).

## Média de Grupos

Método de efeitos fixos resolve o problema de (105). O estimador é aplicado a um sistema de  $M$ -equações transformada do sistema original (103). A matriz usada é a aniquiladora associada com  $\mathbf{1}_M$ :

$$\begin{aligned} \mathbf{Q}_{(M \times M)} &= \mathbf{I}_M - \mathbf{1}_M(\mathbf{1}'_M \mathbf{1}_M)^{-1} \mathbf{1}'_M \quad (108) \\ &= \mathbf{I}_M - \frac{1}{M} \mathbf{1}'_M \mathbf{1}_M \\ &= \mathbf{I}_M - \begin{bmatrix} \frac{1}{M} & \cdots & \frac{1}{M} \\ \vdots & & \vdots \\ \frac{1}{M} & \cdots & \frac{1}{M} \end{bmatrix} \end{aligned}$$

O que essa matriz faz é extrair desvios da média dos grupos. Por exemplo, multiplicando pela esquerda o vetor  $\mathbf{y}_i$  de dimensão  $M$

por  $Q$ , temos:

$$\tilde{\mathbf{y}}_i = Q\mathbf{y}_i = \begin{bmatrix} y_{i1} - \bar{y}_i \\ \vdots \\ y_{im} - \bar{y}_M \end{bmatrix} = \mathbf{y}_i - \mathbf{1}_M \bar{y}_i \quad (109)$$

tal que a média do grupo da variável dependente é:

$$\bar{y}_i = \frac{1}{M} \mathbf{1}'_M \mathbf{y}_i = \frac{1}{M} \sum_{m=1}^M y_{im}$$

Essa transformação é similar para os regressores:  $Q\mathbf{Z}_i$  é o vetor de desvios de  $\mathbf{Z}_i$ .

## Uma Reparemetrização

A robustez em relação a (105) possui um preço: alguns parâmetros do modelo podem não se identificados após a transformação por  $Q$ . Dois exemplos sobre o tema:

1. O caso óbvio é o coeficiente comum para todas as equações. Por exemplo,  $IQ$  é um coeficiente comum em todas as equações no exemplo 5.2. Então a coluna de  $Z_i$  correspondente a  $IQ$  é  $\mathbf{1}_M \cdot IQ_i$  e a quinta coluna de  $QZ_i$  é de zeros. Consequentemente o coeficiente de  $IQ$ ,  $\gamma$ , não pode ser identificado após as transformações. Para separar os coeficientes comuns dos demais faça  $\mathbf{b}_i$  ser o vetor de regressores comuns e escreva a matriz  $M \times L$  de regressores  $Z_i$  como:

$$Z_i = (F : \mathbf{1}_M \mathbf{b}_i') \quad (110)$$

o vetor de coeficientes pode ser particionado como:

$$\delta = \begin{bmatrix} \beta \\ \gamma \end{bmatrix} \quad (111)$$

O vetor de coeficientes  $\gamma$  não pode ser identificado após a transformação.

2. Também pode ser o caso, em adição a  $\gamma$ , que algum coeficiente de  $\beta$  seja não identificado após a reparametrização.

A condição geral de identificação da estimação FE é que  $F_i$  e  $b_i$  são definidos tal que

$$E(QF_i \otimes x_i) \text{ é (coluna) posto completo} \quad (112)$$

tal que  $x_i$  é a união de  $(z_{i1}, \dots, z_{iM})$ . Por que esta é uma condição de identificação? Porque o estimador de efeitos fixos é uma especialização do RE aplicado a regressão transformada de  $Qy$  em  $QF$ . (Esta condição é apenas uma adaptação da anterior.)

Com  $Z_i$  dividido entre  $F_i$  e  $b_i$ , o sistema (103) pode ser rescrito como:

$$y_i = F_i\beta + 1_M b_i\gamma + 1_M\alpha_i + \eta_i, \text{ ou} \quad (113)$$

$$y_{im} = f'_{im}\beta + b_i\gamma + \alpha_i + \eta_i \quad (114)$$

tal que  $f'_{im}$  é a linha  $m$  de  $F_i$ . Os estimadores RE e FE são bem definidos para o mesmo modelo.

## Estimador de Efeitos Fixos

Estimador de efeitos fixos definido como o sistema transformado (dado que  $Q\mathbf{I}_M = \mathbf{0}$ ):

$$Q\mathbf{y}_i = Q\mathbf{F}_i\boldsymbol{\beta} + Q\boldsymbol{\eta}_i \quad (115)$$

ou

$$\tilde{\mathbf{y}}_i = \tilde{\mathbf{F}}_i\boldsymbol{\beta} + \tilde{\boldsymbol{\eta}}_i \quad (116)$$

tal que:

$$\underset{(M \times 1)}{\tilde{\mathbf{y}}_i} = Q\mathbf{y}_i; \quad \underset{(M \times \#\beta)}{\tilde{\mathbf{F}}_i} = Q\mathbf{F}_i; \quad \underset{M \times 1}{\tilde{\boldsymbol{\eta}}_i} = Q\boldsymbol{\eta}_i$$

Forme uma amostra “pooled” das transformadas  $\tilde{\mathbf{y}}_i$  e  $\tilde{\mathbf{F}}_i$  como

$$\underset{(nM \times 1)}{\tilde{\mathbf{y}}} = \begin{pmatrix} \tilde{\mathbf{y}}_1 \\ \vdots \\ \tilde{\mathbf{y}}_n \end{pmatrix}, \quad \underset{(nM \times \#\beta)}{\tilde{\mathbf{F}}} = \begin{pmatrix} \tilde{\mathbf{F}}_1 \\ \vdots \\ \tilde{\mathbf{F}}_n \end{pmatrix}. \quad (117)$$

O estimador de efeitos fixos de  $\boldsymbol{\beta}$ , representado por  $\hat{\boldsymbol{\beta}}_{FE}$ , é o estimador “Pooled OLS,” i.e., o

estimador OLS aplicado a amostra “pooled”  $(\tilde{\mathbf{y}}, \tilde{\mathbf{F}})$  de tamanho  $nM$ . Assim,

$$\begin{aligned}
 \hat{\beta}_{FE} &= (\tilde{\mathbf{F}}_i' \tilde{\mathbf{F}}_i)^{-1} \tilde{\mathbf{F}}_i' \tilde{\mathbf{y}}_i \\
 &= \left( \frac{1}{n} \sum_{i=1}^n \tilde{\mathbf{F}}_i' \tilde{\mathbf{F}}_i \right)^{-1} \frac{1}{n} \sum_{i=1}^n \tilde{\mathbf{F}}_i' \tilde{\mathbf{y}}_i \\
 &= \left[ \left( \frac{1}{n} \sum_{i=1}^n (\mathbf{Q}\mathbf{F}_i)' (\mathbf{Q}\mathbf{F}_i) \right) \right]^{-1} \frac{1}{n} \sum_{i=1}^n (\mathbf{Q}\mathbf{F}_i)' (\mathbf{Q}\mathbf{y}_i) \\
 &= \left( \frac{1}{n} \sum_{i=1}^n (\mathbf{F}_i' \mathbf{Q}\mathbf{Q}\mathbf{F}_i) \right)^{-1} \frac{1}{n} \sum_{i=1}^n \mathbf{F}_i' \mathbf{Q}\mathbf{Q}\mathbf{y}_i \\
 &= \left( \frac{1}{n} \sum_{i=1}^n (\mathbf{F}_i' \mathbf{Q}\mathbf{Q}\mathbf{F}_i) \right)^{-1} \frac{1}{n} \sum_{i=1}^n \mathbf{F}_i' \mathbf{Q}\mathbf{Q}\mathbf{y}_i \text{ (uma vez que } \mathbf{Q}
 \end{aligned}$$

Substituindo (116) em (118) se pode obter o sampling error:

$$\begin{aligned}
 \hat{\beta}_{FE} - \beta &= (\tilde{\mathbf{F}}_i' \tilde{\mathbf{F}}_i)^{-1} \tilde{\mathbf{F}}_i' \tilde{\boldsymbol{\eta}}_i \\
 &= \left( \frac{1}{n} \sum_{i=1}^n (\mathbf{F}_i' \mathbf{Q}\mathbf{Q}\mathbf{F}_i) \right)^{-1} \frac{1}{n} \sum_{i=1}^n \mathbf{F}_i' \mathbf{Q}\mathbf{Q}\boldsymbol{\eta}_i \quad (119)
 \end{aligned}$$

Como o estimador de efeitos fixos é desvio da médio de grupos, ele também é conhecido como *within estimator* ou estimador covariância. Outra aplicação comum é o LSDV (Least Square Dummy Variable): estimar o modelo em nível por OLS adicionando dummies de grupo ( $i$ ).

### Proposição 5.1 (propriedades de amostras grand

Suponha as Hipóteses do modelo de componentes de erro, mas relaxe as hipóteses SUR requerendo apenas que

$$E(\mathbf{f}'_{im}\eta_{ih}) = 0$$

onde  $\mathbf{f}'_{im}$  é a linha  $m$  de  $\mathbf{F}_i$ . Defina  $\tilde{\mathbf{F}}_i$ ,  $\tilde{\mathbf{y}}_i$  e  $\tilde{\boldsymbol{\eta}}_i$  por (116). Então

- O estimador de efeitos fixos (118) é consistente e assintoticamente normal com

$$\text{Avar}(\hat{\boldsymbol{\beta}}_{FE}) = [E(\tilde{\mathbf{F}}'_i\tilde{\mathbf{F}}_i)]^{-1}E[\tilde{\mathbf{F}}'_iE(\tilde{\boldsymbol{\eta}}_i\tilde{\boldsymbol{\eta}}'_i)\tilde{\mathbf{F}}_i][E(\tilde{\mathbf{F}}'_i\tilde{\mathbf{F}}_i)]$$

- A variância assintótica é consistentemente estimada dada por

$$\widehat{\text{Avar}}(\hat{\beta}_{FE}) = \left[ \frac{1}{n} \sum \tilde{F}_i' \tilde{F}_i \right]^{-1} \left[ \frac{1}{n} \sum \tilde{F}_i' \tilde{V} \tilde{F}_i \right] \left[ \frac{1}{n} \sum \tilde{F}_i' \right]$$

aqui  $\tilde{V}$  é a matriz dos momentos cruzados dos resíduos transformados associados com o estimador FE:

$$\underset{(M \times M)}{\tilde{V}} = \frac{1}{n} \sum (\tilde{y}_i - \tilde{F}_i \hat{\beta}_{FE})(\tilde{y}_i - \tilde{F}_i \hat{\beta}_{FE})' \quad (120)$$

## **Função de Custo Translog (sec. 4.7)**

Função de custo translog é uma generalização da função de custo Cobb-Douglas. Uma boa característica da translog é que as equações de demanda otimizada por insumo se forem transformadas em participação no custo total são lineares no (log) do produto e preço dos fatores. Os coeficientes inerentes a este sistema são um subconjunto de parâmetros da função custo que descrevem a tecnologia.

Será assumida a hipótese de homocedasticidade condicional. Assumir também que os regressores no sistema são predeterminados. Como foi argumentado no cap. 1, esta é uma hipótese que pode considerada razoável para o setor de geração de energial elétrica antes da desregulamentação.

## Função de Custo Translog (sec. 4.7)

A função custo translog: assumindo termos quadráticos e cruzados no log de todos os argumentos, a função custo log-linear com três insumos pode ser escrita como:

$$\begin{aligned} \log(C) = & \alpha_0 + \sum_{j=1}^3 \alpha_j \log(p_j) + \frac{1}{2} \sum_{j=1}^3 \sum_{k=1}^3 \gamma_{jk} \log(p_j) \log(p_k) \\ & + \alpha_Q \log(Q) + \frac{1}{2} \gamma_{QQ} (\log(Q))^2 + \sum_{j=1}^3 \gamma_{jQ} \log(p_j) \log(Q) \end{aligned} \quad (121)$$

Nessa expressão o termo  $\frac{1}{2} \sum_{j=1}^3 \sum_{k=1}^3 \gamma_{jk} \log(p_j) \log(p_k)$  é uma forma representando o efeito de segunda ordem dos preços dos fatores. Se pode assumir que a matriz  $3 \times 3$  de forma quadrática coeficientes é simétrica:

$$\gamma_{jk} = \gamma_{kj}, \quad (j, k = 1, 2, 3) \quad (122)$$

O grau de retorno de escala pode ser calculado como:

$$\frac{1}{\partial \log(C) / \partial \log(Q)} = \frac{1}{\alpha_Q + \gamma_{QQ} \log(Q) + \sum_{j=1}^3 \gamma_{jQ} \log(I_j)}$$

(123)

## Participação dos Fatores

A conexão entre os parâmetros da função custo e a demanda dos fatores é dado pelo Lemma de Shepard. Faça  $x_j$  ser a demanda minimizadora de custos para o insumo  $j$  dado o preço dos fatores  $(p_1, p_2, p_3)$  e produto  $Q$ . Então  $\sum_{j=1}^3 p_j x_j = C$ . O lema afirma que

$$\frac{\partial C}{\partial p_j} = x_j \quad (124)$$

Notando que:

$$\frac{\partial \log(C)}{\partial \log(p_j)} = \frac{p_j}{C} \frac{\partial C}{\partial p_j} \quad (125)$$

o lema também afirma que o log das derivas parciais da função custo é igual a participação dos fatores:

$$\frac{\partial \log(C)}{\partial \log(p_j)} = \frac{p_j x_j}{C} \quad (126)$$

Para o caso da função de custo translog a derivada parcial é:

$$\frac{\partial \log(C)}{\partial \log(p_j)} = \alpha_j + \sum_{k=1}^3 \gamma_{jk} \log(p_k) + \gamma_{jQ} \log(Q) \quad (127)$$

Combinando (127) e (126) e definindo o “cost share” como  $s_j = p_j x_j / C$ , temos o seguinte sistema de “cost share”:

$$s_j = \alpha_j + \sum_{k=1}^3 \gamma_{jk} \log(p_k) + \gamma_{jQ} \log(Q) \quad (128)$$

Restrições de simetria: o sistema  $s_j$  é sujeito as restrições cruzadas entre equações: o coeficiente de  $\log(p_k)$  em  $s_j$  é igual ao coeficiente de  $\log(p_j)$  em  $s_k$

## Elasticidades de Substituição

A elasticidade de substituição entre insumos  $j$  e  $k$ , representado por  $\eta_{jk}$  é relacionado com a função custo  $C$  pela fórmula:

$$\eta_{jk} = \frac{C \cdot \frac{\partial^2 C}{\partial p_j \partial p_k}}{\frac{\partial C}{\partial p_j} \cdot \frac{\partial C}{\partial p_k}} \quad (129)$$

Para a função de custo translog temos:

$$\eta_{jk} = \begin{cases} \frac{\gamma_{jk} + s_j s_k}{s_j s_k} & \text{para } j \neq k \\ \frac{\gamma_{jj} + s_j^2 - s_j}{s_j^2} & \text{para } j = k \end{cases} \quad (130)$$

## Propriedades da Função Custo

Homogeneidade:

$$\begin{pmatrix} \alpha_1 + \alpha_2 + \alpha_3 = 1 \\ \gamma_{11} + \gamma_{12} + \gamma_{13} = 0 \\ \gamma_{21} + \gamma_{22} + \gamma_{23} = 0 \\ \gamma_{31} + \gamma_{32} + \gamma_{33} = 0 \\ \gamma_{1Q} + \gamma_{2Q} + \gamma_{3Q} = 0 \end{pmatrix}$$

Monotonicidade: Participações (shares) não podem ser negativas. O lado direito das equações de shares não podem ser negativos para quaisquer combinações de preços de fator e produto.

Concavidade: esta condição requer que a matriz de elasticidade de substituição seja dada por (130) seja negativa semidefinida para qualquer combinação de  $s_j$ . É possível mostrar que uma condição necessária e suficiente é que a

matriz  $\gamma_{jk}$  seja negativa semidefinida. Os elementos da diagonal principal não podem ser positivos.

Especificação estocástica: adicionar termos de erro nas equações de share. Entretanto, justificativas diversas não suficientes para adicionar erros estocásticos nas equações de participação. Estimativa apenas das equações de shares.

## A natureza das restrições

Com a adições dos erros, o sistema é escrito como:

$$\begin{aligned} s_1 &= \alpha_1 + \gamma_{11} \log(p_1) + \gamma_{12} \log(p_2) + \gamma_{13} \log(p_3) + \gamma_{1Q} \log(p_Q) \\ s_2 &= \alpha_2 + \gamma_{21} \log(p_1) + \gamma_{22} \log(p_2) + \gamma_{23} \log(p_3) + \gamma_{2Q} \log(p_Q) \\ s_3 &= \alpha_3 + \gamma_{31} \log(p_1) + \gamma_{32} \log(p_2) + \gamma_{33} \log(p_3) + \gamma_{3Q} \log(p_Q) \end{aligned} \tag{131}$$

O sistema possui 15 coeficientes. As restrições cruzadas e as de homogeneidade formam um conjunto de 8 restrições. Isso significa que os 15 parâmetros podem ser descritos por 7 parâmetros.

$$\begin{pmatrix} \alpha_1 + \alpha_2 + \alpha_3 = 1 \\ \gamma_{11} + \gamma_{12} + \gamma_{13} = 0 \\ \gamma_{21} + \gamma_{22} + \gamma_{23} = 0 \\ \gamma_{31} + \gamma_{32} + \gamma_{33} = 0 \\ \gamma_{1Q} + \gamma_{2Q} + \gamma_{3Q} = 0 \end{pmatrix}$$

Homogeneidade:

$$\begin{pmatrix} \gamma_{11} + \gamma_{12} + \gamma_{13} = 0 \\ \gamma_{21} + \gamma_{22} + \gamma_{23} = 0 \\ \gamma_{31} + \gamma_{32} + \gamma_{33} = 0 \end{pmatrix}$$

Simetria:

$$\begin{pmatrix} \gamma_{12} = \gamma_{21} \\ \gamma_{13} = \gamma_{31} \\ \gamma_{23} = \gamma_{32} \end{pmatrix}$$

Impor a restrição de homogeneidade é direta, eliminando os parâmetros  $\gamma_{.3}$ :

$$\begin{aligned} s_1 &= \alpha_1 + \gamma_{11} \log(p_1/p_3) + \gamma_{12} \log(p_2/p_3) + \gamma_{1Q} \log(Q) + \varepsilon_1 \\ s_2 &= \alpha_2 + \gamma_{21} \log(p_1/p_3) + \gamma_{22} \log(p_2/p_3) + \gamma_{2Q} \log(Q) + \varepsilon_2 \\ s_3 &= \alpha_3 + \gamma_{31} \log(p_1/p_3) + \gamma_{32} \log(p_2/p_3) + \gamma_{3Q} \log(Q) + \varepsilon_3 \end{aligned} \tag{132}$$

Os shares somam 1 para todas as unidades. A soma dos termos de erro é sempre zero, logo a matriz de covariância é  $\Sigma = \text{Var}(\varepsilon_1, \varepsilon_2, \varepsilon_3)$  é singular. Solução: se a terceira equação for

eliminada para incorporar restrições de soma temos:

$$\begin{aligned} s_1 &= \alpha_1 + \gamma_{11} \log(p_1/p_3) + \gamma_{12} \log(p_2/p_3) + \gamma_{1Q} \log(Q) + \varepsilon_{1i} \\ s_2 &= \alpha_2 + \gamma_{21} \log(p_1/p_3) + \gamma_{22} \log(p_2/p_3) + \gamma_{2Q} \log(Q) + \varepsilon_{2i} \end{aligned} \quad (133)$$

Como os regressores são predeterminados o sistema com regressores comuns pode ser estimado por regressão multivariada s.a. restrição de simetria entre equações.

Esta estimação com restrição pode ser transformada em um estimação irrestrita. I.e., o sistema pode ser escrito no formato de coeficientes comuns.

$$\mathbf{y}_i = \begin{bmatrix} s_1 \\ s_2 \end{bmatrix}$$

$$\mathbf{Z}_i = \begin{bmatrix} 1 & 0 & \log(p_1/p_3) & \log(p_2/p_3) & 0 & \log(Q) \\ 0 & 1 & 0 & \log(p_1/p_3) & \log(p_2/p_3) & 0 \end{bmatrix}$$

$$\delta' = [\alpha_1, \alpha_2, \gamma_{11}, \gamma_{12}, \gamma_{22}, \gamma_{1Q}, \gamma_{2Q}] \quad (134)$$

Os demais parâmetros podem ser calculados como resíduo. Por exemplo,

$$\hat{\gamma}_{33} = \hat{\gamma}_{11} + 2\hat{\gamma}_{12} + \hat{\gamma}_{22}$$

## Translog

$\hat{\Sigma}^*$  calculado com OLS equação por equação.  
Estimativa do modelo por RE.

**Table 4.3: Simple Statistics (Sample Size = 99)**

	Output in kilowatt hours	Labor share	Capital share	Fuel share
Mean	9.0	0.141	0.227	0.631
Std. deviation	10.3	0.059	0.062	0.095

**Table 4.4: Random-Effects Estimates**

Parameter	Point estimate	Standard error	<i>t</i> -value
$\alpha_1$	-0.132	0.106	-1.25
$\alpha_2$	0.318	0.085	3.75
$\alpha_3$	0.813	0.094	8.69
$\gamma_{11}$	0.084	0.020	4.19
$\gamma_{12}$	-0.023	0.016	-1.46
$\gamma_{13}$	-0.060	0.015	-3.92
$\gamma_{22}$	0.122	0.020	6.19
$\gamma_{23}$	-0.099	0.017	-5.75
$\gamma_{33}$	0.159	0.023	6.90
$\gamma_{1Q}$	-0.0211	0.0025	-8.55
$\gamma_{2Q}$	-0.0086	0.0030	-2.87
$\gamma_{3Q}$	0.0297	0.0037	7.98

$$\hat{\Sigma} \text{ by pooled OLS} = \begin{bmatrix} 0.00173 & -0.000171 & -0.00156 \\ -0.000171 & 0.00253 & -0.00236 \\ -0.00156 & -0.00236 & 0.00391 \end{bmatrix}$$

**Table 4.5: Substitution Elasticities**

Labor-Capital	Capital-Fuel	Labor-Fuel
0.17	0.27	0.29

## Referências

**Hansen, Bruce** *Econometrics*. 2019.

**Hansen, Lars Peter** “Large Sample Properties of Generalized Method of Moments Estimators,” *Econometrica*, 50 (4), 1982.

**Hayashi, Fumio** *Econometrics*. Princeton University Press, 2000.

**Stock, James H. e Mark W. Watson** *Introduction to Econometrics*. 3a ed. Pearson, 2015.