

---

# ENDOGENEIDADE E VARIÁVEIS INSTRUMENTAIS

Wooldridge §15

## 0.1 Motivação e Consequências para o OLS

Uma das hipóteses clássicas ( $M1 - M5$ ) do MRLM,

$$y_i = \beta_1 + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + u_i = x_i' \beta + u_i, i = 1, \dots, n, \quad (1)$$

é  $M2$  de exogeneidade estrita entre erros e regressores

$$E(u_i | X) = E(u_i | x_1, \dots, x_n) = 0, i = 1, \dots, n \Leftrightarrow E(u | X) = 0_{n \times 1}, \quad (2)$$

uma condição que implica  $E(u_i) = 0$  e

$$Cov(u_i, x_{ij}) = E(u_i x_{ij}) = 0, j = 1, \dots, k, i = 1, \dots, n. \quad (3)$$

Portanto, quando derivámos as propriedades do OLS assumimos que, no modelo em causa, os erros e os regressores não estavam autocorrelacionados - eram exógenos. Na prática existem casos de modelizações nas quais esta hipótese pode não ser válida. Eis três exemplos de modelos com endogeneidade.

**Example 1**  $Sal = \beta_1^* + \beta_2^* Exp + u$ , onde  $Sal$  é salário,  $Exp$  é anos de experiência e  $u$  inclui a variável idade que está correlacionada com  $Exp$ .

Este é um exemplo de um modelo em que se encontra omitida uma variável relevante. Quando se admite que a variável idade é estatisticamente significativa para explicar o nível de salários, o verdadeiro modelo é

$$Sal = \beta_1 + \beta_2 Exp + \beta_3 Id + u, \beta_3 \neq 0. \quad (4)$$

Como foi demonstrado num capítulo anterior,

$$\widehat{\beta}_2^* = \frac{\sum_{i=1}^n (Exp_i - \overline{Exp}) Sal_i}{\sum_{i=1}^n (Exp_i - \overline{Exp})^2}, \quad (5)$$

em que, porque a verdadeira especificação é (4),

$$E(\widehat{\beta}_2^* | Exp, Id) = \beta_2 + \beta_3 \frac{\sum_{i=1}^n (Exp_i - \overline{Exp}) Id_i}{\sum_{i=1}^n (Exp_i - \overline{Exp})^2} = \beta_2 + \beta_3 \widehat{\delta}_2 \neq \beta_2, \quad (6)$$

onde  $Id = \delta_1 + \delta_2 Exp + u$ . O estimador  $\widehat{\beta}_2^*$  não é centrado porque  $\beta_3 \neq 0$  (idade é relevante) e  $\widehat{\delta}_2 \neq 0$ . Este segundo resultado é verdadeiro pois  $E(Id|Exp) = \delta_1 + \delta_2 Exp$ , uma função de  $Exp$ ! Apesar de ser enviesado, será que o estimador é consistente (corrige o bias assintoticamente)? A resposta é negativa pois, como  $Cov(Id, Exp) \neq 0$ ,

$$p \lim_{n \rightarrow \infty} \widehat{\beta}_2^* = \beta_2 + \beta_3 \frac{Cov(Id, Exp)}{V(Exp)} \neq \beta_2 \quad (7)$$

O sentido do bias (enviesamento) para amostras finitas e assintoticamente depende do sinal da correlação na amostra e nas variáveis, respectivamente, para além do sinal de  $\beta_3$ . Este podemos tomar como positivo,  $\beta_3 > 0$ , em que maiores salários são, em média, pagos a trabalhadores de maior idade. Por outro lado podemos assumir que  $\sum_{i=1}^n (Exp_i - \overline{Exp}) Id_i$  e  $Cov(Id, Exp)$  são de sinal positivo - experiência aumenta com a idade. Consequentemente, os enviesamentos (finito ou assintótico) são de sinal positivo,

$$\beta_3 \frac{\sum_{i=1}^n (Exp_i - \overline{Exp}) Id_i}{\sum_{i=1}^n (Exp_i - \overline{Exp})^2} > 0; \beta_3 \frac{Cov(Id, Exp)}{V(Exp)} > 0, \quad (8)$$

o que significa que  $\widehat{\beta}_2^*$  sobreavalia o verdadeiro valor  $\widehat{\beta}_2$ .

**Example 2**  $Sav = \beta_1 + \beta_2 Inc^* + u$ , onde  $Sav$  é poupança e  $Inc^*$  é rendimento disponível mas que é medido com erro:  $e = Inc - Inc^*$ ,  $E(e) = 0$ ,  $V(e) = \sigma_e^2$ , onde  $Inc$  é o verdadeiro valor.

Este é um exemplo de erro de medida na variável independente em que o verdadeiro modelo é

$$Sav = \beta_1 + \beta_2 (Inc - e) + u = \beta_1 + \beta_2 Inc + (u - \beta_2 e), \quad (9)$$

onde

$$Cov(u - \beta_2 e, Inc) = Cov(u, Inc) + Cov(-\beta_2 e, Inc) = -\beta_2 \sigma_e^2 \neq 0, \quad (10)$$

assumindo que  $Cov(u, Inc) = 0$  e  $Cov(e, Inc^*) = 0$ :

$$Cov(e, Inc) = E(e.Inc) = E(e^2) - E(e.Inc^*) = \sigma_e^2. \quad (11)$$

Foi provado anteriormente que  $\widehat{\beta}_2$  é inconsistente:

$$p \lim_{n \rightarrow \infty} \widehat{\beta}_2 = \beta_2 + \frac{Cov(u - \beta_2 e, Inc)}{V(Inc)} = \beta_2 \left( \frac{\sigma_{Inc^*}^2}{\sigma_{Inc^*}^2 + \sigma_e^2} \right) < \beta_2. \quad (12)$$

**Example 3**  $\begin{cases} q^d = \beta p + u \\ q^s = \delta p + e \end{cases}$ , onde, para um dado mercado (bens, serviços, trabalho,...),  $p$  é preço,  $q^d$  é a quantidade procurada,  $q^s$  é a quantidade oferecida.

Este é um exemplo de um modelo de equações simultâneas. Como a quantidade observada é determinada em equilíbrio de procura e oferta, nenhuma das curvas (procura ( $\beta$ ) e oferta ( $\delta$ )) é identificada. Se  $q^s = \delta p + \gamma z + e$ ,  $z$  é uma variável exógena, então a oferta não é identificada (não é possível estimar  $\delta, \gamma$ ) mas a procura é identificável (é possível estimar  $\beta$ ). De qualquer forma, a estimação de  $\beta$  em  $q^d = q = \beta p + u$  por OLS é inconsistente:

$$p = \frac{q - \gamma z - e}{\delta} = \frac{\beta p + u - \gamma z - e}{\delta} \Leftrightarrow p = \pi z + \eta(u - e),$$

o que implica na equação de procura  $E(u|p) = E(u|\pi z + \eta(u - e)) \neq 0$ . De uma forma semelhante,  $Cov(u, p) = E(up) = E(u[\pi z + \eta(u - e)]) \neq 0$ . Portanto, o OLS é enviesado e inconsistente.

O que estes exemplos nos permitem concluir é que quando existe endogeneidade no modelo o OLS é enviesado e inconsistente. Este resultado não é de estranhar visto que a hipótese  $M2$  (que implica  $M2'$ ) é uma condição necessária para que o OLS seja centrado (e, conseqüentemente, consistente). Esta é uma situação mais "grave" para o OLS quando comparada com os casos de heterocedasticidade e autocorrelação dos erros. Para além destes problemas, e como consequência, a inferência com o OLS standard torna-se errônea; não faz sentido falar em estimação robusta de  $V(\hat{\beta})$  e o estimador não é BLUE (não é U - unbiased!), nem assintoticamente. Nestas condições, importa definir um método de estimação alternativo ao OLS. O método é de variáveis instrumentais (ou 2SLS) e será discutido nas próximas secções.

## 0.2 Variáveis Instrumentais e o Estimador IV

Tal como o OLS e o MLE, o estimador IV (variáveis instrumentais) pertence à classe de estimadores GMM. O IV é um GMM linear e a sua utilização justifica-se principalmente em modelos com endogeneidade,

$$Cov(u_i, x_{ij}) = E(u_i x_{ij}) \neq 0, \text{ para algum } j = 1, \dots, k \text{ e } i = 1, \dots, n, \quad (13)$$

onde se mantém a hipótese de  $E(u) = 0$ . Na estimação IV é necessário recorrer ao uso de variáveis instrumentais a(s) qual(is) estão associadas a um particular regressor endógeno.

**Definition 1**  $z$  é uma variável instrumental para  $x$  se (i)  $z$  é exógeno em relação ao erro  $u$ ,  $Cov(u, z) = E(uz) = 0$ ; e (ii)  $z$  está (fortemente) correlacionado com o regressor  $x$ ,  $Cov(x, z) \neq 0$

**Example 4** Anos de experiência do pai pode ser um instrumento para Exp. Nível de escolaridade dos pais e número de irmãos/irmãs podem ser instrumentos para Educ. Teste IQ pode ser

um instrumento para talento/aptidão. Salário pode ser um instrumento para Inc\*. No mercado agrícola, o número de dias de chuva pode ser uma variável exógena na equação da oferta.

Para que um instrumento  $z$  para  $x$  seja estatisticamente válido, temos de verificar ambas condições  $Cov(u, z) = 0$  e  $Cov(x, z) \neq 0$ . Em relação à primeira, e como não observamos  $u$ , partimos apenas de pressupostos da teoria económica ou senso comum. A análise da correlação amostral entre  $z$  e os resíduos  $\hat{u}$  é um tanto quanto simplista e não rigorosa. Para verificar que  $Cov(x, z) \neq 0$  e qual a intensidade da relação entre eles, uma das possibilidades é usar um teste  $t$  na regressão auxiliar

$$x = \delta_1 + \delta_2 z + u; \delta_2 = \frac{Cov(x, z)}{V(z)}. \quad (14)$$

Após a definição de variável instrumental é muito simples a expressão do estimador IV. No MRLS,

$$y = \beta_1 + \beta_2 x + u, Cov(u, x) = E(ux) \neq 0, \quad (15)$$

para uma amostra de dimensão  $n$  e um único instrumento para  $x$ ,

$$\hat{\beta}_{2,IV} = \frac{\sum_{i=1}^n (z_i - \bar{z})(y_i - \bar{y})}{\sum_{i=1}^n (z_i - \bar{z})(x_i - \bar{x})} = \beta_2 + \frac{\sum_{i=1}^n (z_i - \bar{z}) u_i}{\sum_{i=1}^n (z_i - \bar{z})(x_i - \bar{x})}. \quad (16)$$

Naturalmente,  $\hat{\beta}_{1,IV} = \bar{y} - \hat{\beta}_{2,IV}\bar{x}$ . Ao contrário do OLS e GLS, o IV não resulta de minimização de quadrados de erros. A sua expressão pode no entanto ser justificada pelo método dos momentos: de (15),

$$\begin{aligned} Cov(y, z) &= Cov(\beta_1 + \beta_2 x + u, z) = \beta_2 Cov(x, z) + Cov(u, z) = \beta_2 Cov(x, z) \Leftrightarrow \\ \beta_2 &= \frac{Cov(y, z)}{Cov(x, z)}. \end{aligned} \quad (17)$$

Alternativamente, resulta dos momentos  $E(u) = 0$  e  $E(uz) = 0$ . Quando a variável instrumental é válida, o estimador IV é consistente,  $p \lim_{n \rightarrow \infty} \hat{\beta}_{IV} = \beta^1$ . Mas vejamos o seguinte. Num modelo com endogeneidade,  $Corr(u, x) \neq 0$ ,

$$p \lim_{n \rightarrow \infty} \hat{\beta}_{2,OLS} = \beta_2 + Corr(u, x) \frac{\sigma_u}{\sigma_x} \neq \beta_2, \quad (18)$$

$$p \lim_{n \rightarrow \infty} \hat{\beta}_{2,IV} = \beta_2 + \frac{Corr(u, z)}{Corr(x, z)} \frac{\sigma_u}{\sigma_x} = \beta_2, \quad (19)$$

porque o instrumento é válido,  $Corr(u, z) = 0$  e  $Corr(x, z) \neq 0$ . Mas, se o instrumento não é válido, no sentido de que  $Corr(u, z) \neq 0$ , então o IV também é inconsistente,  $p \lim_{n \rightarrow \infty} \hat{\beta}_{IV} \neq \beta$ . O IV tem um menor enviesamento assintótico do que o OLS se  $Corr(u, x) > \frac{Corr(u, z)}{Corr(x, z)}$ , condição

---

<sup>1</sup>Nada pode ser dito em relação a amostras de dimensão finita pois a hipótese que assumimos é de  $Cov(z, u) = 0$ . Estudos de Monte Carlo podem mostrar que existe um enviesamento para pequenas amostras.

esta que não é fácil de testar a não ser de uma forma intuitiva em que se calculam as correlações amostrais onde  $u$  é representado pelos resíduos  $\hat{u}$ .

Sob a hipótese de  $E(u^2|z) = \sigma^2 = V(u)$ ,

$$V(\hat{\beta}_{2,IV}|\mathbf{x}, \mathbf{z}) = \frac{\sigma^2}{n\sigma_x^2 \text{Corr}(x, z)^2}, \quad (20)$$

que pode ser consistentemente estimada por

$$V(\widehat{\hat{\beta}}_{2,IV}|\mathbf{x}, \mathbf{z}) = \frac{\hat{\sigma}^2}{n\hat{\sigma}_x^2 R_{x,z}^2}, \quad (21)$$

onde  $\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n \hat{u}_i^2$  e  $\hat{u}_i$  são os resíduos IV,  $\hat{u}_i = y_i - \hat{\beta}_{1,IV} - \hat{\beta}_{2,IV}x_i$ ,  $\hat{\sigma}_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$ , e  $R_{x,z}^2$  resulta do modelo (14). Portanto, para  $n$  elevado,

$$se(\hat{\beta}_{2,IV}) = \sqrt{\frac{\hat{\sigma}^2}{SST_x R_{x,z}^2}} = \frac{\hat{\sigma} \sqrt{\sum_{i=1}^n (z_i - \bar{z})^2}}{\sum_{i=1}^n (z_i - \bar{z})(x_i - \bar{x})}, \quad (22)$$

que coincide com a expressão para o estimador inconsistente OLS  $\sqrt{\frac{\hat{\sigma}^2}{SST_x}}$  se  $R_{x,z}^2 = 1$ , isto é, se  $x$  e  $z$  são linearmente dependentes na amostra! Em geral, isso não acontece, e porque  $0 < R_{x,z}^2 < 1$ , o IV é menos eficiente (maior *se* do que o OLS). Mas, não nos esqueçamos que, ao contrário do IV, o OLS é inconsistente sob a hipótese de endogeneidade. Quanto maior é a correlação entre  $x$  e  $z$  (melhor qualidade do instrumento), maior é a precisão na estimação IV do modelo.

Passamos agora à análise geral no MRLM,

$$y_i = x_i' \beta + u_i, i = 1, \dots, n, \Leftrightarrow y = X\beta + u, \quad (23)$$

em que

$$\text{Cov}(u, X) = E(X'u) = p \lim_{n \rightarrow \infty} \frac{X'u}{n} = p \lim_{n \rightarrow \infty} \left( \frac{1}{n} \sum_{i=1}^n x_i u_i \right) \neq 0_{k \times 1}. \quad (24)$$

Suponhamos em primeiro lugar que existem tantos instrumentos como regressores,

$$Z_{n \times k} = \begin{pmatrix} z_1' \\ \dots \\ z_n' \end{pmatrix} = \begin{pmatrix} z_{11} & \dots & z_{1k} \\ \dots & & \dots \\ z_{n1} & \dots & z_{nk} \end{pmatrix}; Z_{k \times n}' = (z_1, \dots, z_n); \quad (25)$$

$$p \lim_{n \rightarrow \infty} \frac{Z'u}{n} = p \lim_{n \rightarrow \infty} \left( \frac{1}{n} \sum_{i=1}^n z_i u_i \right) = 0_{k \times 1}. \quad (26)$$

Nestas condições, (23) é equivalente a  $Z'y = Z'X\beta + Z'u$  e por isso, supondo que a matriz  $Z'X = \sum_{i=1}^n z_i x_i'$  não é singular,

$$p \lim_{n \rightarrow \infty} \frac{Z'y}{n} = \left( p \lim_{n \rightarrow \infty} \frac{Z'X}{n} \right) \beta + p \lim_{n \rightarrow \infty} \frac{Z'u}{n} \Leftrightarrow \beta_{k \times 1} = \left( p \lim_{n \rightarrow \infty} \frac{Z'X}{n} \right)^{-1} \cdot p \lim_{n \rightarrow \infty} \frac{Z'y}{n}, \quad (27)$$

$$\widehat{\beta}_{IV} = \left( \frac{Z'X}{n} \right)^{-1} \frac{Z'y}{n} = (Z'X)^{-1} Z'y = \left( \sum_{i=1}^n z_i x_i' \right)^{-1} \sum_{i=1}^n z_i y_i \quad (28)$$

$$= \beta + (Z'X)^{-1} Z'u = \beta + \left( \sum_{i=1}^n z_i x_i' \right)^{-1} \sum_{i=1}^n z_i u_i. \quad (29)$$

O IV é consistente,

$$p \lim_{n \rightarrow \infty} \widehat{\beta}_{IV} = \beta + p \lim_{n \rightarrow \infty} \left( \frac{1}{n} \sum_{i=1}^n z_i x_i' \right)^{-1} \cdot p \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n z_i u_i = \beta, \quad (30)$$

e, sob  $V(u|Z) = \sigma^2 I_n$ , tem como matriz consistente de variâncias-covariâncias,

$$\widehat{\Sigma}_{k \times k} = V(\widehat{\beta}_{IV} | X, Z) = E \left( (\widehat{\beta}_{IV} - \beta) (\widehat{\beta}_{IV} - \beta)' | X, Z \right) \quad (31)$$

$$= \widehat{\sigma}^2 (Z'X)^{-1} (Z'Z) (X'Z)^{-1} = \widehat{\sigma}^2 \left( \sum_{i=1}^n z_i x_i' \right)^{-1} \left( \sum_{i=1}^n z_i z_i' \right) \left( \sum_{i=1}^n x_i z_i' \right)^{-1}; \quad (32)$$

$$\widehat{\sigma}^2 = \frac{1}{n-k} \sum_{i=1}^n \widehat{u}_{i,IV}^2. \quad (33)$$

Note que se a amostra é *i.i.d.*, pela (U)LLN,  $p \lim_{n \rightarrow \infty} \left( \frac{1}{n} \sum_{i=1}^n z_i x_i' \right) = E(z_1 x_1')$ . Se  $V(u|Z) = \sigma^2 \Omega$ , então

$$\Sigma = \sigma^2 (Z'X)^{-1} (Z'\Omega Z) (X'Z)^{-1}. \quad (34)$$

Pode-se provar que  $\widehat{\Sigma}$  é "menor" (maior eficiência) quando "X e Z" estão mais correlacionados e que o IV é, em geral, menos eficiente do que o OLS. As matrizes de variâncias-covariâncias (e o próprio estimador) do IV e do OLS coincidem quando  $Z = X$ . Mas o OLS é inconsistente! Assintoticamente, e sob algumas condições de regularidade,  $\sqrt{n}(\widehat{\beta}_{IV} - \beta)$  é normalmente distribuído.

Na prática, no entanto, o modelo pode ser sobre-identificado: O número de instrumentos  $m$  é superior ao número de regressores  $k$ ,

$$Z_{n \times m} = \begin{pmatrix} z_1' \\ \dots \\ z_n' \end{pmatrix} = \begin{pmatrix} z_{11} & \dots & z_{1m} \\ \dots & & \dots \\ z_{n1} & \dots & z_{nm} \end{pmatrix}; Z'_{m \times n} = (z_1, \dots, z_n); m > k; \quad (35)$$

$$p \lim_{n \rightarrow \infty} \frac{Z'u}{n} = p \lim_{n \rightarrow \infty} \left( \frac{1}{n} \sum_{i=1}^n z_i u_i \right) = 0_{m \times 1}. \quad (36)$$

Quando  $m > k$ , a matriz  $Z'X$  de dimensão  $m \times k$  não é quadrada e por isso não admite uma inversa. Neste caso, pré-multiplicamos (23) por  $X'Z(Z'Z)^{-1}Z'$  para obter

$$\widehat{\beta}_{IV} = \left( X'Z(Z'Z)^{-1}Z'X \right)^{-1} X'Z(Z'Z)^{-1}Z'y; \quad (37)$$

$$\widehat{\Sigma} = \widehat{\sigma}^2 \left[ \left( X'Z \right) \left( Z'Z \right)^{-1} \left( Z'X \right) \right]^{-1}. \quad (38)$$

- Escolha do número de instrumentos. Escolha dos instrumentos.

### 0.3 Estimador 2SLS

Nesta secção apresentamos um método de estimação alternativo que se baseia em mínimos quadrados a dois passos (2SLS). Para efeitos de simplicidade na exposição consideremos o modelo estrutural

$$y = \beta_1 + \beta_2x + \beta_3z + u; Cov(u, x) \neq 0, Cov(u, z) = 0, \quad (39)$$

em que  $x$  é endógeno,  $z$  é exógeno e  $z_1, z_2$  são instrumentos válidos para  $x$ . Num primeiro passo, estima-se consistentemente por OLS o modelo ( $v$  satisfaz as hipóteses standard)

$$x = \delta_1 + \delta_2z + \delta_3z_1 + \delta_4z_2 + v; \delta_3 \neq 0, \delta_4 \neq 0, \quad (40)$$

em que  $x$  tem como regressores todas as variáveis exógenas (instrumentos e do modelo estrutural). Como a combinação linear de todas as variáveis exógenas  $E(x|z, z_1, z_2) = \delta_1 + \delta_2z + \delta_3z_1 + \delta_4z_2$  é o "melhor" instrumento para  $x$ , este é estimado por

$$E(x|\widehat{z}, z_1, z_2) = \widehat{x} = \widehat{\delta}_1 + \widehat{\delta}_2z + \widehat{\delta}_3z_1 + \widehat{\delta}_4z_2. \quad (41)$$

No segundo passo, estima-se consistentemente por OLS o modelo estrutural (39)

$$y = \beta_1 + \beta_2\widehat{x} + \beta_3z + u, \quad (42)$$

onde  $\widehat{x}$  é determinado no primeiro passo e o estimador resultante para  $\beta$  coincide com o IV. No entanto, os  $se$  para o 2SLS não são os mesmos que do IV (22).

E para o MRLM, numa forma mais geral? Como sabemos, o estimador 2SLS coincide com o estimador IV (ver (27) e (37)). A ideia é a seguinte: No modelo

$$y = X_1\beta_1 + X_2\beta_2 + u, X = (X_1, X_2), \beta' = (\beta'_1, \beta'_2), \quad (43)$$

em que  $X_1$  é o conjunto de variáveis endógenas,

$$Cov(u, X_1) = E(X_1'u) = p \lim_{n \rightarrow \infty} \frac{X_1'u}{n} \neq 0. \quad (44)$$

No primeiro passo, do sistema  $X_1 = Z\pi + v$ , resulta o OLS  $\hat{\pi} = (Z'Z)^{-1} Z'X_1$  e  $\hat{X}_1 = Z\hat{\pi} = Z(Z'Z)^{-1} Z'X_1$ . Fazendo a substituição no modelo original, e após alguma cálculos, o 2SLS (37) é o OLS em

$$y = (\hat{X}_1 + \hat{v})\beta_1 + X_2\beta_2 + u \Leftrightarrow y = Z(Z'Z)^{-1} Z'X_1\beta_1 + X_2\beta_2 + u^*. \quad (45)$$

A expressão do 2SLS é dada em (37). Uma condição necessária é que o número de instrumentos (colunas de  $Z$ ) seja igual ou superior ao número total de regressores  $(X_1, X_2)$ ,  $k$ . Alternativamente, podia-se tomar  $y = X\beta + u$  em que no primeiro passo  $\hat{\pi} = (Z'Z)^{-1} Z'X$  e  $\hat{X} = Z(Z'Z)^{-1} Z'X$  e o 2SLS era o OLS em  $y = \hat{X}\beta + v$ ,  $\hat{\beta} = (\hat{X}'\hat{X})^{-1} \hat{X}'y$ .

#### 0.4 Testes: Endogeneidade e Sobre-Identificação

Tal como apresentámos nos capítulos de heterocedasticidade e autocorrelação dos erros, torna-se necessário nesta discussão apresentar testes à exogeneidade dos regressores. No caso de mais do que um instrumento por regressor endogeno, também podemos testar a validade de algum dos instrumentos no sentido de não estarem correlacionados com os erros.

O teste de Hausman é o procedimento de referência para inferir sobre a exogeneidade dos regressores. Podendo ser utilizado noutro contexto, o teste de Hausman procura comparar estatisticamente dois estimadores  $\hat{\beta}_E$  e  $\hat{\beta}_C$  para o mesmo modelo e vector de parâmetros  $\beta$ . O estimador  $\hat{\beta}_C$  é consistente sob ambas as hipóteses  $H_0$  e  $H_1$  enquanto que o estimador  $\hat{\beta}_E$  apenas é consistente sob a nula  $H_0$ . Por outro lado, sob a hipótese nula  $H_0$ ,  $\hat{\beta}_E$  é (assimptoticamente) mais eficiente do que  $\hat{\beta}_C$ . No contexto deste capítulo, onde  $H_0$  é exogeneidade e  $H_1$  é endogeneidade,  $\hat{\beta}_C$  é o IV e  $\hat{\beta}_E$  é o OLS.

Vejamos o teste de Hausman com o recurso a regressão auxiliar. Porque  $Cov(u, x) \neq 0$ , os erros  $u$  e  $v$  dos modelos (39) e (40) estão autocorrelacionados,  $Cov(u, v) \neq 0$ . O teste à exogeneidade é muito simplesmente o teste rácio t ao coeficiente  $\delta$  na regressão auxiliar (aumentada em relação ao modelo estrutural em  $\delta\hat{v}$ )

$$y = \beta_1 + \beta_2x + \beta_3z + \delta\hat{v} + u, \quad (46)$$

onde  $\hat{v}$  são os resíduos do primeiro passo. Se existirem mais do que uma variável endogena (por exemplo, 5) então usa-se o teste F à significância conjunta dos 5 coeficientes associados aos 5 resíduos do primeiro passo.

A fórmula geral da estatística de Hausman é dada por

$$H = n(\hat{\beta}_C - \hat{\beta}_E)' \left( AV(\hat{\beta}_C) - AV(\hat{\beta}_E) \right)^{-1} (\hat{\beta}_C - \hat{\beta}_E), \quad (47)$$

onde  $AV(\hat{\beta})$  é a variância-covariância assimptótica, em que sob a hipótese nula é assimptoticamente



distribuída  $\chi_k^2$ . No nosso caso de interesse,

$$H = \left( \widehat{\beta}_{IV} - \widehat{\beta}_{OLS} \right)' \left( V \left( \widehat{\beta}_{IV} \right) - V \left( \widehat{\beta}_{OLS} \right) \right)^{-1} \left( \widehat{\beta}_{IV} - \widehat{\beta}_{OLS} \right) \xrightarrow{d} \chi_k^2, \quad (48)$$

onde  $\widehat{\beta}_{IV}, \widehat{\beta}_{OLS}, V \left( \widehat{\beta}_{IV} \right), V \left( \widehat{\beta}_{OLS} \right)$  foram definidos anteriormente. Para testar se um particular regressor  $x$ , que tem associado o parâmetro  $\beta_2$  no modelo, não é endógeno

$$H_0 : Cov(u, x) = E(ux) = 0 \Leftrightarrow p \lim_{n \rightarrow \infty} \left( \frac{1}{n} \sum_{i=1}^n x_i u_i \right) = 0, \quad (49)$$

pode-se utilizar a estatística

$$\frac{\left( \widehat{\beta}_{2,IV} - \widehat{\beta}_{2,OLS} \right)^2}{V \left( \widehat{\beta}_{2,IV} \right) - V \left( \widehat{\beta}_{2,OLS} \right)} \xrightarrow{d} \chi_1^2. \quad (50)$$

Para finalizar, apresentamos um teste à não autocorrelação de erros e instrumentos onde o número de instrumentos é pelo menos dois. Num contexto IV ou GMM linear, procura-se testar a hipótese nula de  $H_0 : E(uZ) = 0, Z_{m \times 1}$  em que os  $m > 1$  instrumentos para  $x$  não estão autocorrelacionados com  $u$ . Se  $H_0$  não é aceite então concluímos que pelo menos um dos instrumentos não é válido e está correlacionado com os erros  $u$ . O modelo diz-se sobre-identificado pois  $m > 1$ . No caso de exacta identificação,  $m = 1$ , não é possível desenvolver este teste<sup>2</sup>.

O teste é similar ao anterior de Hausman em que se recorre a resíduos. Neste caso, no entanto, a estatística de teste é  $nR^2$  em que o  $R^2$  resulta do modelo auxiliar,

$$\widehat{u} = \delta_1 + \delta_2 z + \pi_1 z_1 + \pi_2 z_2 + \dots + \pi_m z_m + e, \quad (51)$$

onde  $\widehat{u}$  são os resíduos IV do modelo estrutural e  $z_1, z_2, \dots, z_m$  são os (possíveis) instrumentos para  $x$ . A estatística é assintoticamente distribuída como  $\chi_{m-1}^2$ . Na prática, pode-se estimar o modelo por IV com um instrumento existente e depois testar a introdução de **um** novo instrumento em que  $m - 1 = 1$ . De uma forma mais geral, pode-se testar para  $r$  regressores endógenos a introdução de  $q$  instrumentos adicionais no modelo. A estatística seria distribuída como  $\chi_q^2$ , onde  $q$  é a diferença entre o número de instrumentos disponíveis (fora do modelo estrutural) e o número de regressores endógenos  $r$ .

## Aplicações

(...)

<sup>2</sup>Na verdade, o GMM linear considera  $E(u(\beta) \cdot Z) = 0_{m \times 1}$  onde  $m \geq k$  (número de instrumentos é maior ou igual ao número de parâmetros).

---

## Exercícios

1. Discuta a questão de endogeneidade e a escolha de instrumentos no modelo  $Nota = \beta_1 + \beta_2 Faltas + u$ , em que  $Nota$  é a nota do exame e  $Faltas$  é o numero de aulas que o aluno faltou.
2. Provar que o 2SLS no modelo  $y = \beta_1 + \beta_2 x + u$  e apenas  $z$  é instrumento para  $x$  coincide com o IV (16).
3. ...