

# Metoda zmiennych instrumentalnych i uogólniona metoda momentów

Wykład 14

# Literatura

- B. Hansen (2013) Econometrics, *strona internetowa autora*

# Problem endogenicznych zmiennych objaśniających

- Zmiany stóp procentowych → zmiany kursu walutowego → zmiany stóp procentowych
- Dynamika kredytu → wzrost gospodarczy → dynamika kredytu
- Inwestycje OFE (zmiana portfeli OFE) → zmiany cen akcji → zmiana portfeli OFE

# Problem endogenicznych zmiennych objaśniających

- Równanie „strukturalne”:

$$y_i = \mathbf{x}'_i \boldsymbol{\beta} + e_i \quad \mathbb{E}(\mathbf{x}_i e_i) \neq 0$$

$x$  – wektor  $k$ -elementowy

- Estymator KMNK obciążony
- Rozwiązanie: MZI lub UMM

# Zmienne instrumentalne

- Wykorzystanie zmiennych instrumentalnych, tzn. skorelowanych ze zmiennymi endogenicznymi ale nieskorelowanych z  $e$ :

$$\mathbb{E}(z_i e_i) = \mathbf{0}$$

- Zwykle część zmiennych jest egzogeniczna:

$$x_i = \begin{pmatrix} x_{1i} \\ x_{2i} \end{pmatrix} \begin{matrix} k_1 \\ k_2 \end{matrix}$$

- ...i może zostać zaliczona do zmiennych instrumentalnych:

$$z_i = \begin{pmatrix} x_{1i} \\ z_{2i} \end{pmatrix} \begin{matrix} k_1 \\ l_2 \end{matrix}$$

# Zmienne instrumentalne

- Przykłady:
  - Naturalne instrumenty (np. przelewy z ZUS do OFE)
  - Opóźnione zmienne endogeniczne
  - Identyfikacja przez heteroskedastyczność

# Zmienne instrumentalne

- Jeżeli  $l_2 = k_2$ , to model „jednoznacznie identyfikowalny” (just-identified)
- Jeżeli  $l_2 > k_2$ , to model „przeidentyfikowany” (over-identified)

# Uogólniona metoda momentów

- Generalized method of moments (GMM)
- Przykładowy model:

$$\begin{aligned}y_i &= x_i' \beta + e_i \\ &= x_{1i}' \beta_1 + x_{2i}' \beta_2 + e_i\end{aligned}$$

$$\mathbb{E}(x_i e_i) = 0$$

- Niech prawdziwa będzie restrykcja:  $\beta_2 = 0$
- MNK dla modelu  $y_i = x_{1i}' \beta_1 + e_i$  niekoniecznie efektywna, bo więcej restrykcji niż parametrów:  $\ell - k = r$   
→  $r$  „overidentifying restrictions”



# Uogólniona metoda momentów

- Niech  $g(y, \mathbf{x}, \mathbf{z}, \boldsymbol{\beta})$  będzie funkcją ( $\ell \times 1$ ) parametrów  $\boldsymbol{\beta}$  ( $k \times 1$ ),  $\ell \geq k$ :

$$\mathbb{E}g(y_i, \mathbf{x}_i, \mathbf{z}_i, \boldsymbol{\beta}_0) = \mathbf{0}$$

– funkcja momentów, np.

$$g(y, \mathbf{z}, \boldsymbol{\beta}) = \mathbf{z} \cdot (y - \mathbf{x}'_1 \boldsymbol{\beta}_1)$$

# Uogólniona metoda momentów

- Policzmy odpowiednik na danych z próby:

$$\bar{g}_n(\beta) = \frac{1}{n} \sum_{i=1}^n g_i(\beta) = \frac{1}{n} \sum_{i=1}^n z_i (y_i - x_i' \beta) = \frac{1}{n} (\mathbf{Z}' \mathbf{y} - \mathbf{Z}' \mathbf{X} \beta)$$

- Estymator momentów próbuje znaleźć takie  $\beta$ , że  $\bar{g}_n(\beta) = \mathbf{0}$
- Niech  $J_n(\beta) = n \cdot \bar{g}_n(\beta)' \mathbf{W}_n \bar{g}_n(\beta)$  będzie miarą „długości” wektora  $\bar{g}_n(\beta)$   
gdzie:  $\mathbf{W}_n > 0$  to macierz wag ( $\ell \times \ell$ )

# Uogólniona metoda momentów

- Na przykład dla  $\mathbf{W}_n = \mathbf{I}$

$$J_n(\boldsymbol{\beta}) = n \cdot \bar{\mathbf{g}}_n(\boldsymbol{\beta})' \bar{\mathbf{g}}_n(\boldsymbol{\beta}) = n \cdot \|\bar{\mathbf{g}}_n(\boldsymbol{\beta})\|^2$$

- Estymator GMM (UMM):

$$\hat{\boldsymbol{\beta}}_{GMM} = \underset{\boldsymbol{\beta}}{\operatorname{argmin}} J_n(\boldsymbol{\beta})$$

# Uogólniona metoda momentów

- Dla  $k = \ell$  jest to estymator momentów

$$\bar{\mathbf{g}}_n(\hat{\boldsymbol{\beta}}) = \mathbf{0}$$

- FOC: 
$$\begin{aligned} \mathbf{0} &= \frac{\partial}{\partial \boldsymbol{\beta}} J_n(\hat{\boldsymbol{\beta}}) \\ &= 2 \frac{\partial}{\partial \boldsymbol{\beta}} \bar{\mathbf{g}}_n(\hat{\boldsymbol{\beta}})' \mathbf{W}_n \bar{\mathbf{g}}_n(\hat{\boldsymbol{\beta}}) \\ &= -2 \left( \frac{1}{n} \mathbf{X}' \mathbf{Z} \right) \mathbf{W}_n \left( \frac{1}{n} \mathbf{Z}' (\mathbf{y} - \mathbf{X} \hat{\boldsymbol{\beta}}) \right) \end{aligned}$$

...czyli:

$$2 (\mathbf{X}' \mathbf{Z}) \mathbf{W}_n (\mathbf{Z}' \mathbf{X}) \hat{\boldsymbol{\beta}} = 2 (\mathbf{X}' \mathbf{Z}) \mathbf{W}_n (\mathbf{Z}' \mathbf{y})$$

# Uogólniona metoda momentów

- Definicja estymatora dla modelu liniowego:

$$\hat{\beta}_{GMM} = ((\mathbf{X}'\mathbf{Z}) \mathbf{W}_n (\mathbf{Z}'\mathbf{X}))^{-1} (\mathbf{X}'\mathbf{Z}) \mathbf{W}_n (\mathbf{Z}'\mathbf{y})$$

- Efektywny estymator GMM dla  $\mathbf{W}_0 = \mathbf{\Omega}^{-1}$

gdzie  $\mathbf{\Omega} = \mathbb{E} (z_i z_i' e_i^2) = \mathbb{E} (g_i g_i')$      $g_i = z_i e_i$

$$\hat{\beta} = (\mathbf{X}'\mathbf{Z}\mathbf{\Omega}^{-1}\mathbf{Z}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Z}\mathbf{\Omega}^{-1}\mathbf{Z}'\mathbf{y}$$

- Asymptotyczny rozkład estymatora:

$$\sqrt{n} (\hat{\beta} - \beta) \xrightarrow{d} N \left( \mathbf{0}, (\mathbf{Q}'\mathbf{\Omega}^{-1}\mathbf{Q})^{-1} \right) \quad \mathbf{Q} = \mathbb{E} (z_i x_i')$$

# Estymacja macierzy wag

- Wybierz macierz startową:  $\mathbf{W}_n = (\mathbf{Z}'\mathbf{Z})^{-1}$

- Policz:  $\hat{e}_i = y_i - \mathbf{x}_i' \hat{\boldsymbol{\beta}}$

$$\hat{\mathbf{g}}_i = \mathbf{z}_i \hat{e}_i = \mathbf{g}(y_i, \mathbf{x}_i, \mathbf{z}_i, \hat{\boldsymbol{\beta}})$$

- Policz:  $\bar{\mathbf{g}}_n = \bar{\mathbf{g}}_n(\hat{\boldsymbol{\beta}}) = \frac{1}{n} \sum_{i=1}^n \hat{\mathbf{g}}_i$

$$\hat{\mathbf{g}}_i^* = \hat{\mathbf{g}}_i - \bar{\mathbf{g}}_n$$

$$\mathbf{W}_n = \left( \frac{1}{n} \sum_{i=1}^n \hat{\mathbf{g}}_i^* \hat{\mathbf{g}}_i^{*'} \right)^{-1} = \left( \frac{1}{n} \sum_{i=1}^n \hat{\mathbf{g}}_i \hat{\mathbf{g}}_i' - \bar{\mathbf{g}}_n \bar{\mathbf{g}}_n' \right)^{-1}$$

# „Two-step” GMM

- Wzór dla modelu liniowego:

$$\hat{\beta} = \left( \mathbf{X}'\mathbf{Z} (\hat{g}'\hat{g} - n\bar{g}_n\bar{g}'_n)^{-1} \mathbf{Z}'\mathbf{X} \right)^{-1} \mathbf{X}'\mathbf{Z} (\hat{g}'\hat{g} - n\bar{g}_n\bar{g}'_n)^{-1} \mathbf{Z}'\mathbf{y}$$

- Błędy szacunku parametrów = pierwiastki z głównej przekątnej macierzy  $\frac{1}{n} \hat{\mathbf{V}}$

$$\hat{\mathbf{V}} = n \left( \mathbf{X}'\mathbf{Z} (\hat{g}'\hat{g} - n\bar{g}_n\bar{g}'_n)^{-1} \mathbf{Z}'\mathbf{X} \right)^{-1}$$

# Alternatywny estymator UMM

- Minimalizuj:

$$J(\beta) = n \cdot \bar{g}_n(\beta)' \left( \frac{1}{n} \sum_{i=1}^n g_i^*(\beta) g_i^*(\beta)' \right)^{-1} \bar{g}_n(\beta)$$

$$g_i^*(\beta) = g_i(\beta) - \bar{g}_n(\beta)$$

„continuously-updated GMM estimator”



# UMM dla modeli nieliniowych

- Minimalizuje:  $J(\beta) = n \cdot \bar{g}_n(\beta)' W_n \bar{g}_n(\beta)$

$$\bar{g}_n(\beta) = \frac{1}{n} \sum_{i=1}^n g_i(\beta)$$

$$W_n = \left( \frac{1}{n} \sum_{i=1}^n \hat{g}_i \hat{g}_i' - \bar{g}_n \bar{g}_n' \right)^{-1}$$

- startuje:  $W_n = I$
- możliwe wiele iteracji

# UMM dla modeli nieliniowych

- Rozkład asymptotyczny estymatora:

$$\sqrt{n}(\hat{\beta} - \beta) \xrightarrow{d} N(0, (G'\Omega^{-1}G)^{-1})$$

$$\Omega = \mathbb{E}(g_i g_i')$$

$$G = \mathbb{E} \frac{\partial}{\partial \beta'} g_i(\beta).$$

- Wariancja szacunków parametrów:

$$\hat{V}_\beta = (\hat{G}'\hat{\Omega}^{-1}\hat{G})^{-1}$$

$$\hat{\Omega} = n^{-1} \sum_i \hat{g}_i^* \hat{g}_i^{*'}$$

$$\hat{G} = n^{-1} \sum_i \frac{\partial}{\partial \beta'} g_i(\hat{\beta})$$

# Testowanie „nadliczbowych” restrykcji

- Test of overidentifying restrictions:

$$H_0 : \mathbb{E} \mathbf{g}_i = \mathbf{0}$$

$$\begin{aligned} J_n &= n \bar{\mathbf{g}}_n' \mathbf{W}_n \bar{\mathbf{g}}_n \\ &= n^2 \bar{\mathbf{g}}_n' (\hat{\mathbf{g}}' \hat{\mathbf{g}} - n \bar{\mathbf{g}}_n \bar{\mathbf{g}}_n')^{-1} \bar{\mathbf{g}}_n \end{aligned}$$

$$J_n = J_n(\hat{\boldsymbol{\beta}}) \xrightarrow{d} \chi_{\ell-k}^2$$

- Wykrywa możliwe wady modelu:  
słabe instrumenty, zbyt dużo instrumentów, zła postać modelu, itp.

# Forma zredukowana modelu

- Sprawdźmy relację między  $x$  i  $z$ :

$$\mathbf{x}_i = \mathbf{\Gamma}' \mathbf{z}_i + \mathbf{u}_i$$

$$\mathbf{\Gamma} = \mathbb{E} (\mathbf{z}_i \mathbf{z}_i')^{-1} \mathbb{E} (\mathbf{z}_i \mathbf{x}_i')$$

$$\mathbb{E}(\mathbf{z}_i \mathbf{u}_i') = \mathbf{0}$$

- Estymator MNK:  $\hat{\mathbf{\Gamma}} = (\mathbf{Z}'\mathbf{Z})^{-1} (\mathbf{Z}'\mathbf{X})$

# Metoda zmiennych instrumentalnych

- Podstawmy tę relację do równania (1):

$$\begin{aligned}y &= (Z\Gamma + U)\beta + e \\ &= Z\lambda + v,\end{aligned}$$

gdzie:  $\lambda = \Gamma\beta$      $v = U\beta + e$

- Zauważmy, że:  $\mathbb{E}(z_i v_i) = \mathbb{E}(z_i u'_i) \beta + \mathbb{E}(z_i e_i) = 0$   
...dlatego można zastosować MNK:

$$\begin{aligned}y &= Z\hat{\lambda} + \hat{v}, \\ \hat{\lambda} &= (Z'Z)^{-1} (Z'y)\end{aligned}$$

# MZI i pośrednia MNK

(  $k = \ell$  )

- MZI to szczególny przypadek UMM:

$$\begin{aligned}\hat{\beta} &= (X'Z W_n Z'X)^{-1} X'Z W_n Z'y \\ &= (Z'X)^{-1} W_n^{-1} (X'Z)^{-1} X'Z W_n Z'y \\ &= (Z'X)^{-1} Z'y\end{aligned}$$

- Pośrednia MNK (Indirect least squares):

$$\begin{aligned}\hat{\beta} &= \hat{\Gamma}^{-1} \hat{\lambda} \\ &= \left( (Z'Z)^{-1} (Z'X) \right)^{-1} \left( (Z'Z)^{-1} (Z'y) \right) \\ &= (Z'X)^{-1} (Z'Z) (Z'Z)^{-1} (Z'y) \\ &= (Z'X)^{-1} (Z'y).\end{aligned}$$

# Dodatek

- Literatura:

R.Rigobon, B. Sack (2004) The impact of Monetary Policy on Asset Prices, *Journal of Monetary Economics* 51, 1553–1575.

# Metoda „identyfikacji przez heteroskedastyczność”

$$c_{it} = \alpha y_{it} + Ax_{it} + \varepsilon_{it}$$

$$y_{it} = \beta c_{it} + Bx_{it} + \eta_{it}$$

Forma zredukowana modelu:

$$c_{it} = \frac{1}{1 - \alpha\beta} [Gx_{it} + \varepsilon_{it} + \alpha\eta_{it}]$$

$$y_{it} = \frac{1}{1 - \alpha\beta} [Hx_{it} + \beta\varepsilon_{it} + \eta_{it}]$$



# Różne wariancje w podpróbach

Macierze wariancji zmiennych objaśnianych w podpróbach  $T1$  i  $T2$ :

$$\Omega^{T_1} = \frac{1}{(1-\alpha\beta)^2} \begin{bmatrix} G\Omega_x^{T_1}G' + \sigma_\varepsilon^{T_1} + \alpha^2\sigma_\eta^{T_1} & G\Omega_x^{T_1}H' + \beta\sigma_\varepsilon^{T_1} + \alpha\sigma_\eta^{T_1} \\ \cdot & H\Omega_x^{T_1}H' + \beta^2\sigma_\varepsilon^{T_1} + \sigma_\eta^{T_1} \end{bmatrix}$$

$$\Omega^{T_2} = \frac{1}{(1-\alpha\beta)^2} \begin{bmatrix} G\Omega_x^{T_2}G' + \sigma_\varepsilon^{T_2} + \alpha^2\sigma_\eta^{T_2} & G\Omega_x^{T_2}H' + \beta\sigma_\varepsilon^{T_2} + \alpha\sigma_\eta^{T_2} \\ \cdot & H\Omega_x^{T_2}H' + \beta^2\sigma_\varepsilon^{T_2} + \sigma_\eta^{T_2} \end{bmatrix}$$

# Różnica między wariancjami w podpróbach

Różnica macierzy wariancji:

$$\Delta\Omega = \Omega^{T_2} - \Omega^{T_1} = \frac{(\sigma_{\varepsilon}^{T_2} - \sigma_{\varepsilon}^{T_1})}{(1 - \alpha\beta)^2} \begin{bmatrix} 1 & \beta \\ \beta & \beta^2 \end{bmatrix}$$

Wyznaczamy  $\beta$ :

$$\beta = \frac{\Delta\Omega_{12}}{\Delta\Omega_{11}} \qquad \beta = \frac{\Delta\Omega_{22}}{\Delta\Omega_{12}}$$

# Metoda zmiennych instrumentalnych

Estymatory MZI:

$$\hat{\beta} = \frac{\frac{1}{N_2} (\mathbf{c}_{T_2})' \mathbf{y}_{T_2} - \frac{1}{N_1} (\mathbf{c}_{T_1})' \mathbf{y}_{T_1}}{\frac{1}{N_2} (\mathbf{c}_{T_2})' \mathbf{c}_{T_2} - \frac{1}{N_1} (\mathbf{c}_{T_1})' \mathbf{c}_{T_1}}$$

$$\hat{\beta} = \frac{\frac{1}{N_2} (\mathbf{y}_{T_2})' \mathbf{y}_{T_2} - \frac{1}{N_1} (\mathbf{y}_{T_1})' \mathbf{y}_{T_1}}{\frac{1}{N_2} (\mathbf{c}_{T_2})' \mathbf{y}_{T_2} - \frac{1}{N_1} (\mathbf{c}_{T_1})' \mathbf{y}_{T_1}}$$

# Metoda zmiennych instrumentalnych

Estymatory MZI:

$$\hat{\beta} = (\mathbf{vc}'\mathbf{c})^{-1} (\mathbf{vc}'\mathbf{y})$$

$$\hat{\beta} = (\mathbf{vy}'\mathbf{c})^{-1} (\mathbf{vy}'\mathbf{y})$$

# Metoda zmiennych instrumentalnych

Różnica między wektorami Średnich dla zmiennych objaśnianych w podpróbach:

$$\Delta E \begin{pmatrix} c_{it} \\ y_{it} \end{pmatrix} = \frac{E^{T_2}(\varepsilon_{it}) - E^{T_1}(\varepsilon_{it})}{1 - \alpha\beta} \begin{bmatrix} 1 \\ \beta \end{bmatrix}$$

Estymator MZI:

$$\hat{\beta} = \frac{\frac{1}{N_2} \mathbf{e}' \mathbf{y}_{T_2} - \frac{1}{N_1} \mathbf{e}' \mathbf{y}_{T_1}}{\frac{1}{N_2} \mathbf{e}' \mathbf{c}_{T_2} - \frac{1}{N_1} \mathbf{e}' \mathbf{c}_{T_1}} \quad \hat{\beta} = (\mathbf{m}' \mathbf{c})^{-1} (\mathbf{m}' \mathbf{y})$$

# Metoda zmiennych instrumentalnych

- Konstrukcja instrumentów:
  - uwzględniających zmiany w wariancji

$$vc_{it} = \begin{cases} c_{it}/N & \text{kiedy } it \in T_1 \\ -c_{it}/N & \text{kiedy } it \in T_2 \end{cases}$$

- uwzględniających zmiany w średniej

$$m_{it} = \begin{cases} 1/N & \text{kiedy } it \in T_1 \\ -1/N & \text{kiedy } it \in T_2 \end{cases}$$