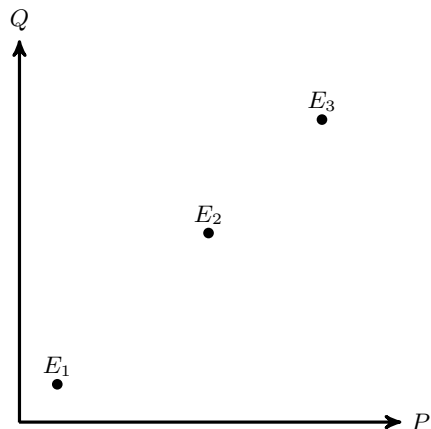


# Metody Ekonometryczne


## Modele wielorównaniowe

Jakub Mućk  
Szkoła Główna Handlowa w Warszawie

# Wprowadzenie



$Q$  to ilość dobra  
 $P$  to cena dobra  
 $E_1$ ,  $E_2$  oraz  $E_3$  to obserwowane wielkości.



$Q$  to ilość dobra


$P$  to cena dobra

$E_1$ ,  $E_2$  oraz  $E_3$  to obserwowane wielkości.

Zależność wynikająca z obserwacji empirycznych:

$$Q = \beta_0 + \beta_1 P + \varepsilon \quad (1)$$

Jakiego znaku jest  $\beta_1$ ?



$Q$  to ilość dobra


$P$  to cena dobra

$E_1$ ,  $E_2$  oraz  $E_3$  to obserwowane wielkości.

Krzywa podaży ( $S$ )

$$Q_S = \beta_0 + \beta_1 P + \varepsilon_s \quad (1)$$

gdzie  $\varepsilon_s$  to nieobserwowalna determinanta podaży (*unobservable supply shifter*)



$Q$  to ilość dobra  
 $P$  to cena dobra  
 $E_1, E_2$  oraz  $E_3$  to obserwowane wielkości.

Krzywa podaży ( $S$ )


$$Q_S = \beta_0 + \beta_1 P + \varepsilon_s \quad (1)$$

gdzie  $\varepsilon_s$  to nieobserwowalna determinanta podaży (*unobservable supply shifter*)

Krzywe popytu ( $D_i$ ) dla różnych wartości  $Z$

$$Q_D = \alpha_0 + \alpha_1 P + \alpha_2 Z + \varepsilon_d \quad (2)$$

gdzie  $Z$  to obserwowalna determinanta popytu (*observable demand shifter*), a  $\varepsilon_d$  to nieobserwowalna determinanta popytu (*unobservable demand shifter*).



$Q$  to ilość dobra

$P$  to cena dobra

$E_1$ ,  $E_2$  oraz  $E_3$  to obserwowane wielkości.

Krzywe podaży ( $S_i$ ) dla różnych wartości  $X$ :

$$Q_S = \beta_0 + \beta_1 P + \beta_2 X + \varepsilon_s \quad (1)$$

gdzie  $X$  to obserwowalna determinanta podaży (*observable demand shifter*), a  $\varepsilon_s$  to nieobserwowalna determinanta podaży (*unobservable supply shifter*)

Krzywe popytu ( $D_i$ ) dla różnych wartości  $Z$

$$Q_D = \alpha_0 + \alpha_1 P + \alpha_2 Z + \varepsilon_d \quad (2)$$

gdzie  $Z$  to obserwowalna determinanta popytu (*observable demand shifter*), a  $\varepsilon_d$  to nieobserwowalna determinanta popytu (*unobservable demand shifter*).

- Modele wielorównaniowe mogą pozwolić na wyeliminowanie obciążenia oszacowań wynikającego z jednoczesnej współzależności (*simultaneity bias*).
- Modele wielorównaniowe mogą pozwolić na uwzględnienie jednoczesnej współzależności pomiędzy zmiennymi endogenicznymi.
- Kluczowym problemem jest problem identyfikowalności.



## Oznaczenia i terminologia

- Postać strukturalna (*structural form*) to postać modelu wynikająca z teorii ekonomii.
- Dla układu  $M$  równań

$$\begin{array}{ccccccccccc}
 \gamma_{11}y_{1t} + & \dots + & \gamma_{1M}y_{Mt} + & \beta_{11}x_{1t} + & \dots + & \beta_{1K}x_{Kt} & = & \varepsilon_{1t} \\
 \gamma_{21}y_{2t} + & \dots + & \gamma_{2M}y_{Mt} + & \beta_{21}x_{2t} + & \dots + & \beta_{2K}x_{Kt} & = & \varepsilon_{2t} \\
 & & & & & & & \vdots \\
 \gamma_{M1}y_{1t} + & \dots + & \gamma_{MM}y_{Mt} + & \beta_{M1}x_{Mt} + & \dots + & \beta_{MK}x_{Kt} & = & \varepsilon_{Mt}
 \end{array}$$

- $M$  zmiennych endogenicznych:  $y_{1t}, y_{2t}, \dots, y_{Mt}$ .
- $K$  zmiennych egzogenicznych:  $x_{1t}, x_{2t}, \dots, x_{Kt}$ .
- $M$  strukturalnych zaburzeń losowych:  $\varepsilon_{1t}, \varepsilon_{2t}, \dots, \varepsilon_{Mt}$ .
- Przyjmując, że  $\varepsilon = [\varepsilon_{1t}, \varepsilon_{2t}, \dots, \varepsilon_{Mt}]$

$$\mathbb{E}(\varepsilon) = 0 \quad \text{oraz} \quad \mathbb{E}(\varepsilon\varepsilon^T) = \Sigma,$$

gdzie  $\Sigma$  to macierz wariancji-kowariancji pomiędzy zaburzeniami strukturalnymi.

- **Postać strukturalna (*structural form*):** przy pomocy zapisu macierzowego dla każdej obserwacji ( $t$ ):

$$\begin{aligned}
 & [y_1 \quad y_2 \quad \dots \quad y_M]_t \begin{bmatrix} \gamma_{11} & \gamma_{12} & \dots & \gamma_{1M} \\ \gamma_{21} & \gamma_{22} & \dots & \gamma_{2M} \\ & & \vdots & \\ \gamma_{M1} & \gamma_{M2} & \dots & \gamma_{MM} \end{bmatrix} + \\
 & + [x_1 \quad x_2 \quad \dots \quad x_K]_t \begin{bmatrix} \beta_{11} & \beta_{12} & \dots & \beta_{1M} \\ \beta_{21} & \beta_{22} & \dots & \beta_{2M} \\ & & \vdots & \\ \beta_{M1} & \beta_{M2} & \dots & \beta_{MM} \end{bmatrix} = [\varepsilon_1 \quad \dots \quad \varepsilon_2 \quad \varepsilon_M]_t
 \end{aligned}$$

- Postać strukturalna (*structural form*) – zapis macierzowy:

$$\mathbf{Y}\Gamma + \mathbf{X}\mathbf{B} = \varepsilon, \quad (3)$$

gdzie (przyjmując  $T$  jako liczbę obserwacji):

- ▶  $\mathbf{Y}$  to macierz zmiennych endogenicznych o wymiarach  $T \times M$ .
  - ▶  $\mathbf{X}$  to macierz zmiennych egzogenicznych o wymiarach  $T \times K$ .
  - ▶  $\varepsilon$  to macierz strukturalnych zaburzeń losowych o wymiarach  $T \times M$ .
  - ▶  $\Gamma$  macierz parametrów przy zmiennych endogenicznych o wymiarach  $M \times M$ .
  - ▶  $\mathbf{B}$  macierz parametrów przy zmiennych egzogenicznych o wymiarach  $K \times M$ .
- Ponadto:

$$\mathbb{E}(\varepsilon) = 0 \quad \text{oraz} \quad \mathbb{E}(\varepsilon\varepsilon^T) = \Sigma,$$

gdzie  $\Sigma$  to macierz wariancji-kowariancji pomiędzy zaburzeniami strukturalnymi.

- Zatem na postać strukturalną składają się:  $\Gamma$ ,  $\mathbf{B}$ , ale i  $\Sigma$ .

- Postać zredukowana (*reduced form*):

$$\mathbf{Y} = \mathbf{X}\Pi + \nu, \quad (4)$$

- Postać zredukowana (*reduced form*):

$$\mathbf{Y} = \mathbf{X}\Pi + \nu, \quad (4)$$

- gdzie

$$\Pi = -\mathbf{B}\Gamma^{-1} \quad (5)$$

oraz  $\nu$  to macierz zaburzeń formy zredukowanej:


$$\nu = \varepsilon\Gamma^{-1} \quad (6)$$

oraz

$$\mathbb{E}(\nu\nu^T) = (\Gamma^{-1})^T \Sigma\Gamma^{-1} = \Omega. \quad (7)$$


## Problem identyfikacji parametrów

Obserwacje empiryczne:  $E_1$ ,  $E_2$  oraz  $E_3$ .








Obserwacje empiryczne:  $E_1$ ,  $E_2$  oraz  $E_3$ .



Obserwacje empiryczne:  $E_1$ ,  $E_2$  oraz  $E_3$ .



- Postać strukturalna (*structural form*):

$$\mathbf{Y}\Gamma + \mathbf{X}\mathbf{B} = \varepsilon \quad (8)$$

- Postać zredukowana (*reduced form*):

$$\mathbf{Y} = \mathbf{X}\Pi + \nu \quad (9)$$

$$\Pi = -\mathbf{B}\Gamma^{-1} \quad (10)$$

- Intuicyjnie, kluczowy jest przypadek, gdy jedna postać zredukowana odpowiada dokładnie jednej postaci strukturalnej.
- W przypadku, gdy kilka postaci strukturalnych może prowadzić do tej samej postaci zredukowanej pojawia się problem braku identyfikowalności parametrów.
- Przykładowo, niech  $\mathbf{F}$  będzie pewną nieosobliwą macierzą. Zapiszemy nową, alternatywną postać strukturalną, która będzie transformacją **prawdziwej** postaci strukturalnej:

$$\mathbf{Y}\tilde{\Gamma} + \mathbf{X}\tilde{\mathbf{B}} = \tilde{\varepsilon} = \mathbf{Y}\Gamma\mathbf{F} + \mathbf{X}\mathbf{B}\mathbf{F} = \varepsilon\mathbf{F} \quad (11)$$

Wtedy postać zredukowana *nowej* postaci strukturalnej będzie taka sama jak prawdziwej!

$$\tilde{\Pi} = -\mathbf{B}\mathbf{F}\mathbf{F}^{-1}\Gamma^{-1} = \mathbf{B}\Gamma^{-1} = \Pi \quad (12)$$

- Zatem postacie strukturalne są ekwiwalentne pod względem obserwacji.
- **Kluczowe jest wykorzystanie informacji z poza próby (nonsample information)**, a więc restrykcji wynikających z teorii ekonomii.

- Przykład ( $q_d$  – popyt;  $q_s$  – podaż,  $p$  – cena;  $z$  – inna zmienna egzogeniczna):

$$q_d = \alpha_0 + \alpha_1 p + \alpha_2 z + \varepsilon_d \quad (13)$$

$$q_s = \beta_0 + \beta_1 p + \beta_2 z + \varepsilon_s \quad (14)$$

$$q_d = q_s \quad (15)$$

Po drobnej manipulacji postać zredukowana oraz przy założeniu, że  $\alpha_1 \neq \beta_1$ :

$$q = \frac{\alpha_1 \beta_0 - \alpha_0 \beta_1}{\alpha_1 - \beta_1} + \frac{\alpha_1 \beta_2 - \alpha_2 \beta_1}{\alpha_1 - \beta_1} z + \frac{\alpha_1 \varepsilon_s - \alpha_2 \varepsilon_d}{\alpha_1 - \beta_1} = \pi_{11} + \pi_{21} z + \nu_q, \quad (16)$$

$$p = \frac{\beta_0 - \alpha_0}{\alpha_1 - \beta_1} + \frac{\beta_1 - \alpha_2}{\alpha_1 - \beta_2} z + \frac{\varepsilon_s - \varepsilon_d}{\alpha_1 - \beta_1} = \pi_{12} + \pi_{22} z + \nu_p, \quad (17)$$

Postać zredukowana zawiera zaledwie cztery parametry ( $\pi_{11}$ ,  $\pi_{12}$ ,  $\pi_{21}$  i  $\pi_{22}$ ), a postać strukturalna aż sześć parametrów ( $\alpha_0$ ,  $\alpha_1$ ,  $\alpha_2$ ,  $\beta_0$ ,  $\beta_1$  i  $\beta_2$ ). Oczywiście zatem jest fakt, że **nie ma kompletnego rozwiązania dla wszystkich sześciu parametrów postaci strukturalnej w zależności od parametrów postaci zredukowanej.**

- Modyfikacja: w równaniu popytowym zamienimy  $z$  na  $x$

$$q_d = \alpha_0 + \alpha_1 p + \alpha_2 x + \varepsilon_d \quad (18)$$

$$q_s = \beta_0 + \beta_1 p + \beta_2 z + \varepsilon_s \quad (19)$$

$$q_d = q_s \quad (20)$$

Postać strukturalna

$$[q \ p] \begin{bmatrix} 1 & 1 \\ -\alpha_1 & -\beta_1 \end{bmatrix} + [1 \ x \ z] \begin{bmatrix} -\alpha_0 & -\beta_0 \\ -\alpha_2 & 0 \\ 0 & -\beta_2 \end{bmatrix} = [\varepsilon_d \ \varepsilon_s] \quad (21)$$

Postać zredukowana:

$$[q \ p] = [1 \ x \ z] \begin{bmatrix} (\alpha_1 \beta_0 - \alpha_0 \beta_1) / \gamma & (\beta_0 - \alpha_0) / \gamma \\ -\alpha_2 \beta_1 / \gamma & -\alpha_2 / \gamma \\ \alpha_1 \beta_2 / \gamma & \beta_2 / \gamma \end{bmatrix} + [\nu_1 \ \nu_2] \quad (22)$$

gdzie  $\gamma = \alpha_1 - \beta_1$

Zauważmy, że dopuszczalne postacie strukturalne, w tym nieprawdziwe, modelu mają następującą postać strukturalną:

$$\tilde{\mathbf{B}} = \mathbf{B}\mathbf{F} = \begin{bmatrix} \alpha_0 f_{11} + \beta_0 f_{12} & \alpha_0 + \beta_0 f_{22} \\ \alpha_2 f_{11} & \alpha_2 f_{12} \\ \beta_2 f_{21} & \beta_2 f_{22} \end{bmatrix},$$

Warto zauważyć, że

- ▶ gdy  $f_{12} \neq 0 \implies$  zmienna  $x$  pojawia się w równaniu podażowym. **Jest to niespójne z teorią opisaną przez postać strukturalną.**
- ▶ gdy  $f_{21} \neq 0 \implies$  zmienna  $z$  pojawia się w równaniu popytowym. **Jest to niespójne z teorią opisaną przez postać strukturalną.**

Zatem  $f_{12} = f_{21} = 0$  aby postać zredukowana była spójna z rozważaną teorią.  $\mathbf{F} = \mathbf{I}$  (jedyński przy zmiennej  $q$ ) będzie jedyną transformacją gwarantującą spójność postaci zredukowanej z formą strukturalną.

Unikalnym rozwiązaniem dla postaci strukturalnej jest zatem

$$\alpha_0 = \pi_{11} - \pi_{12} \left( \frac{\pi_{31}}{\pi_{32}} \right), \quad \alpha_1 = \frac{\pi_{31}}{\pi_{32}}, \quad \alpha_2 = \pi_{22} \left( \frac{\pi_{21}}{\pi_{22}} - \frac{\pi_{31}}{\pi_{32}} \right),$$

$$\beta_0 = \pi_{11} - \pi_{12} \left( \frac{\pi_{21}}{\pi_{22}} \right), \quad \beta_1 = \frac{\pi_{21}}{\pi_{22}}, \quad \beta_2 = \pi_{32} \left( \frac{\pi_{31}}{\pi_{32}} - \frac{\pi_{21}}{\pi_{22}} \right).$$

## ■ Postać strukturalna:

- ▶  $\Gamma$  jest nieosobliwą macierzą o wymiarach  $M \times M \implies M^2$  parametrów.
- ▶  $\mathbf{B}$  jest wymiarów  $K \times M \implies KM$  parametrów.
- ▶  $\Sigma$  jest macierzą symetryczną o wymiarach  $M \times M \implies \frac{1}{2}M(M+1)$  parametrów.

Zatem postać strukturalna posiada  $M^2 + KM + \frac{1}{2}M(M+1)$ .



## ■ Postać strukturalna:

- ▶  $\Gamma$  jest nieosobliwą macierzą o wymiarach  $M \times M \implies M^2$  parametrów.
- ▶  $\mathbf{B}$  jest wymiarów  $K \times M \implies KM$  parametrów.
- ▶  $\Sigma$  jest macierzą symetryczną o wymiarach  $M \times M \implies \frac{1}{2}M(M+1)$  parametrów.

Zatem postać strukturalna posiada  $M^2 + KM + \frac{1}{2}M(M+1)$ .

## ■ Postać zredukowana

- ▶  $\Pi$  jest wymiarów  $K \times M \implies KM$  parametrów.
- ▶  $\Omega$  jest macierzą symetryczną o wymiarach  $M \times M \implies \frac{1}{2}M(M+1)$  parametrów.

Zatem postać zredukowana posiada  $KM + \frac{1}{2}M(M+1)$ .

- Różnica w liczbie parametrów to  $M^2$ . Dlatego, kluczowe jest wykorzystanie informacji z poza próby (*non-sample information*).

- ① **Normalizacja (Normalization)** – w każdym równaniu jeden współczynnik powinien mieć wartość 1. Zazwyczaj, jest to parametr przy zmiennej endogenicznej.
  - ▶ Wtedy liczba restrykcji redukuje się do  $M(M - 1)$  (z  $M^2$ ).
- ② **Tożsamości (Identities).**
- ③ **Wykluczenia (Exclusion)** – zerowe restrykcje na macierze  $\Gamma$  i  $\mathbf{B}$ .
- ④ **Liniowe restrykcje (Linear restrictions).**
  - ▶ Aczkolwiek liniowe restrykcje mogą czasem prowadzić do *błędnej postaci strukturalnej*. Przykładowym problemem jest brak możliwości zidentyfikowania efektów korzyści skali przy identyfikacji postępu technologicznego dla zagregowanej funkcji produkcji.
- ⑤ **Restrykcje na macierz wariancji kowariancji zaburzeń losowych  $\Sigma$ .**
  - ▶ Współczesne badania makroekonomiczne wykorzystują modele wektorowej autoregresji VAR w celu zidentyfikowania wpływu (strukturalnych) szoków makroekonomicznych. Kluczowym założeniem jest tutaj sferyczność macierzy  $\Sigma$ .

- Rozważamy jedną zmienną endogeniczną  $y_j$  (tj.  $j$ -te równanie).

	Zmienne endogeniczne	Zmienne egzogeniczne
Włączone	$\mathbf{Y}_j$ $M_j$ zmiennych	$\mathbf{X}_j$ $K_j$ zmiennych
Pominięte	$\mathbf{Y}_j^*$ $M_j^*$ zmiennych	$\mathbf{X}_j^*$ $K_j^*$ zmiennych

- Liczba równań (zmiennych endogenicznych):  $M = M_j + M_j^* + 1$
- Liczba zmiennych egzogenicznych:  $K = K_j + K_j^*$
- Postać zredukowana:

$$[y_j \quad \mathbf{Y}_j \quad \mathbf{Y}_j^*] = [\mathbf{X}_j \quad \mathbf{X}_j^*] \begin{bmatrix} \pi_j & \tilde{\Pi}_j & \bar{\Pi}_j \\ \pi_j^* & \tilde{\Pi}_j^* & \bar{\Pi}_j^* \end{bmatrix} + [v_j \quad V_j \quad V_j^*] \quad (23)$$

- Na podstawie klasyfikacji zmiennych na włączone i pominięte, można zauważyć, że  $j$ -ta kolumny macierzy postaci strukturalnej są następujące:

$$\Gamma_j^T = [1 \quad -\gamma_j^T \quad 0] \quad \text{oraz} \quad \mathbf{B}_j^T = [-\beta_j^T \quad 0].$$

- Zależność między postacią strukturalną a zredukowaną można zapisać jako:

$$\Pi\Gamma = -\mathbf{B},$$

a w przypadku  $j$ -tego równania postaci strukturalnej:

$$\Pi\Gamma_j = -\mathbf{B}_j,$$

co pozwala nam wyznaczyć dwa układy równań

$$\begin{aligned}\pi_j - \tilde{\Pi}_j\gamma_j &= \beta_j, \\ \pi_j^* &= \Pi_j^*\gamma_j,\end{aligned}$$

- Drugie równanie ma  $K_j^*$  równań i  $M_j$  niewiadomych. Jeżeli równanie to posiada rozwiązanie to można wyznaczyć  $\beta_j$ .

Warunek konieczny (*order condition*) dla  $j$  tego równania

$$K_j^* \geq M_j. \quad (24)$$

Liczba zmiennych egzogenicznych wyłączonych/pomiętych z równania  $j$ -tego nie może być mniejsza od liczby zmiennych endogenicznych w równaniu  $j$ -tym.

Warunek ten gwarantuje, że równanie  $\pi_j^* = \Pi_j^* \gamma_j$  posiada przynajmniej jedno rozwiązanie.

Warunek wystarczający (*rank condition*) dla  $j$  tego równania

$$\text{rank} [\pi_j^*, \Pi_j^*] = \text{rank} [\Pi_j^*] = M_j \quad (25)$$

Spełnienie tego warunku gwarantuje dokładnie jedno rozwiązanie.

Analogicznie do metody zmiennych instrumentalnych można rozróżnić następujące przypadki identyfikowalności dla  $j$ -tego równania:

- 1 **Dokładnie identyfikowalne** (*exactly identified*) jeżeli  $M_j = K_j^*$ .
- 2 **Nadmiernie identyfikowalne** (*overidentified*) jeżeli  $M_j < K_j^*$ .
- 3 **Brak identyfikowalności** (*underidentified*) będzie równoznaczny sytuacji, gdy  $M_j > K_j^*$ .

gdzie

$K_j^*$  to liczba zmiennych egzogenicznych pominiętych z równania  $j$ -tego;

$M_j$  to liczba zmiennych endogenicznych w równaniu  $j$ -tym.

- Praktycznym sprawdzeniem warunku koniecznego (*order condition*) i wystarczającego *rank condition* jest metoda sprawdzająca rząd odpowiedniej podmacierzy.
- [Krok #1] Zapisujemy w tabeli parametry **postaci strukturalnej**, a więc:

$$\begin{array}{cccccccc} y_1 & y_2 & \dots & y_M & 1 & x_1 & x_2 & \dots & x_k \\ \hline & \Gamma^T & & & & & \mathbf{B}^T & & \end{array}$$

- [Krok #2] Dla każdego  $j$ -tego równania rozważamy macierz pozbawioną:
  - ▶  $j$ -tego wiersza;
  - ▶ kolumn, ze zmiennymi występującymi w  $j$ -tym równaniu.

Parametry  $j$ -tego równania będą identyfikowalne jeżeli macierz ta będzie miała pełny rząd (liczba wektorów niezależnych liniowo powinna odpowiadać liczbie wierszy).



$$q_d = \alpha_0 + \alpha_1 p + \varepsilon_d$$

$$q_s = \beta_0 + \beta_1 p + \varepsilon_s$$

$$q_d = q_s$$

$q_d$	$q_s$	1	$p$
1	0	$-\alpha_0$	$-\alpha_1$
0	1	$-\beta_0$	$-\beta_1$
1	-1	0	0

$$q_d = \alpha_0 + \alpha_1 p + \varepsilon_d$$

$$q_s = \beta_0 + \beta_1 p + \varepsilon_s$$

$$q_d = q_s$$

$q_d$	$q_s$	1	$p$
1	0	$-\alpha_0$	$-\alpha_1$
0	1	$-\beta_0$	$-\beta_1$
1	-1	0	0

równanie pierwsze: tylko wektor  $[1 \quad -1]^T \implies$  niepełny rząd, a więc brak identyfikowalności.

$$\begin{aligned}
 q_d &= \alpha_0 + \alpha_1 p + \varepsilon_d \\
 q_s &= \beta_0 + \beta_1 p + \varepsilon_s \\
 q_d &= q_s
 \end{aligned}$$

$q_d$	$q_s$	1	$p$
1	0	$-\alpha_0$	$-\alpha_1$
0	1	$-\beta_0$	$-\beta_1$
1	-1	0	0

równanie pierwsze: tylko wektor  $[1 \quad -1]^T \implies$  niepełny rząd, a więc brak identyfikowalności.

równanie drugie: tylko wektor  $[1 \quad 1]^T \implies$  niepełny rząd, a więc brak identyfikowalności.

$$q_d = \alpha_0 + \alpha_1 p + \alpha_2 z + \varepsilon_d$$

$$q_s = \beta_0 + \beta_1 p + \varepsilon_s$$

$$q_d = q_s$$

$q_d$	$q_s$	1	$p$	$z$
1	0	$-\alpha_0$	$-\alpha_1$	$-\alpha_2$
0	1	$-\beta_0$	$-\beta_1$	0
1	-1	0	0	0

$$q_d = \alpha_0 + \alpha_1 p + \alpha_2 z + \varepsilon_d$$

$$q_s = \beta_0 + \beta_1 p + \varepsilon_s$$

$$q_d = q_s$$

$q_d$	$q_s$	1	$p$	$z$
1	0	$-\alpha_0$	$-\alpha_1$	$-\alpha_2$
0	1	$-\beta_0$	$-\beta_1$	0
1	-1	0	0	0

równanie pierwsze: tylko wektor  $[1 \quad -1]^T \implies$  niepełny rząd, a więc brak identyfikowalności.

$$\begin{aligned}
 q_d &= \alpha_0 + \alpha_1 p + \alpha_2 z + \varepsilon_d \\
 q_s &= \beta_0 + \beta_1 p + \varepsilon_s \\
 q_d &= q_s
 \end{aligned}$$

$q_d$	$q_s$	1	$p$	$z$
1	0	$-\alpha_0$	$-\alpha_1$	$-\alpha_2$
0	1	$-\beta_0$	$-\beta_1$	0
1	-1	0	0	0

równanie pierwsze: tylko wektor  $[1 \quad -1]^T \implies$  niepełny rząd, a więc brak identyfikowalności.

równanie drugie: dwa wektory  $[1 \quad 1]^T$  oraz  $[-\alpha_2 \quad 0]^T$ . Co więcej,

$$\text{rank} \begin{bmatrix} 1 & -\alpha_2 \\ 1 & 0 \end{bmatrix} = 2$$

$\implies$  parametry drugie równania identyfikowalne.

$$\begin{aligned}
 q_d &= \alpha_0 + \alpha_1 p + \alpha_2 z + \varepsilon_d \\
 q_s &= \beta_0 + \beta_1 p + \beta_2 x + \varepsilon_s \\
 q_d &= q_s
 \end{aligned}$$

$q_d$	$q_s$	1	$p$	$z$	$x$
1	0	$-\alpha_0$	$-\alpha_1$	$-\alpha_2$	0
0	1	$-\beta_0$	$-\beta_1$	0	$-\beta_2$
1	-1	0	0	0	0

$$\begin{aligned}
 q_d &= \alpha_0 + \alpha_1 p + \alpha_2 z + \varepsilon_d \\
 q_s &= \beta_0 + \beta_1 p + \beta_2 x + \varepsilon_s \\
 q_d &= q_s
 \end{aligned}$$

$q_d$	$q_s$	1	$p$	$z$	$x$
1	0	$-\alpha_0$	$-\alpha_1$	$-\alpha_2$	0
0	1	$-\beta_0$	$-\beta_1$	0	$-\beta_2$
1	-1	0	0	0	0

równanie pierwsze: dwa wektory wektor  $[1 \quad -1]^T$  oraz  $[-\beta_2 \quad 0]^T$ . Ważniejsze, że

$$\text{rank} \begin{bmatrix} 1 & -\beta_2 \\ -1 & 0 \end{bmatrix} = 2$$

$\implies$  parametry pierwszego równania identyfikowalne.



$$\begin{aligned}
 q_d &= \alpha_0 + \alpha_1 p + \alpha_2 z + \varepsilon_d \\
 q_s &= \beta_0 + \beta_1 p + \beta_2 x + \varepsilon_s \\
 q_d &= q_s
 \end{aligned}$$

	$q_d$	$q_s$	1	$p$	$z$	$x$
$q_d = \alpha_0 + \alpha_1 p + \alpha_2 z + \varepsilon_d$	1	0	$-\alpha_0$	$-\alpha_1$	$-\alpha_2$	0
$q_s = \beta_0 + \beta_1 p + \beta_2 x + \varepsilon_s$	0	1	$-\beta_0$	$-\beta_1$	0	$-\beta_2$
$q_d = q_s$	1	-1	0	0	0	0

równanie pierwsze: dwa wektory wektor  $[1 \quad -1]^T$  oraz  $[-\beta_2 \quad 0]^T$ . Ważniejsze, że

$$\text{rank} \begin{bmatrix} 1 & -\beta_2 \\ -1 & 0 \end{bmatrix} = 2$$

$\implies$  parametry pierwszego równania identyfikowalne.

równanie drugie: dwa wektory  $[1 \quad 1]^T$  oraz  $[-\alpha_2 \quad 0]^T$ . Co więcej,

$$\text{rank} \begin{bmatrix} 1 & -\alpha_2 \\ 1 & 0 \end{bmatrix} = 2$$

$\implies$  parametry drugie równania identyfikowalne.

# Metody estymacji

## Metody estymacji parametrów równań (równanie - po - równaniu)

- Pośrednia Metoda Najmniejszych Kwadratów;
- Podwójna Metoda Najmniejszych Kwadratów;
- Uogólniona Metoda Momentów (GMM, *generalized methods of moments*);
- Estymator klasy k;
- Metoda Największej Wiarygodności z ograniczoną informacją (LIML, *limited information likelihood*).

## Metody estymacji parametrów równań (równanie - po - równaniu)

- Pośrednia Metoda Najmniejszych Kwadratów;
- Podwójna Metoda Najmniejszych Kwadratów;
- Uogólniona Metoda Momentów (GMM, *generalized methods of moments*);
- Estymator klasy k;
- Metoda Największej Wiarygodności z ograniczoną informacją (LIML, *limited information likelihood*).

## Metody estymacji łącznej/systemowej

- Potrójna Metoda Najmniejszych Kwadratów;
- Uogólniona Metoda Momentów (GMM, *generalized methods of moments*);
- Metoda Największej Wiarygodności z pełną informacją (FIML, *full-information likelihood*).

- **Postać strukturalna dla  $j$ -tego równania:**

$$\begin{aligned} \mathbf{y}_j &= \mathbf{Y}_j \boldsymbol{\gamma}_j + \mathbf{X}_j \boldsymbol{\beta}_j + \varepsilon_j \\ &= \mathbf{Z}_j \boldsymbol{\delta}_j + \varepsilon_j \end{aligned}$$

gdzie  $\mathbf{Z}_j$  to macierz zmiennych endogenicznych w  $j$ -tym równaniu oraz zmiennych egzogenicznych w  $j$ -tym równaniu, tj.  $\mathbf{Z}_j = [\mathbf{Y}_j \quad \mathbf{X}_j]$ .

- **Postać strukturalna dla  $j$ -tego równania:**

$$\begin{aligned} \mathbf{y}_j &= \mathbf{Y}_j \boldsymbol{\gamma}_j + \mathbf{X}_j \boldsymbol{\beta}_j + \boldsymbol{\varepsilon}_j \\ &= \mathbf{Z}_j \boldsymbol{\delta}_j + \boldsymbol{\varepsilon}_j \end{aligned}$$

gdzie  $\mathbf{Z}_j$  to macierz zmiennych endogenicznych w  $j$ -tym równaniu oraz zmiennych egzogenicznych w  $j$ -tym równaniu, tj.  $\mathbf{Z}_j = [\mathbf{Y}_j \quad \mathbf{X}_j]$ .

- **Postać zredukowana dla zmiennych endogenicznych występujących w  $j$ -tym równaniu**

$$\mathbf{Y}_j = \Pi_j \mathbf{X}_j + \boldsymbol{\nu}_j$$

gdzie  $\Pi_j$  to  $j$ -ta kolumna macierzy z postaci zredukowanej. A  $\boldsymbol{\nu} = \boldsymbol{\varepsilon} \boldsymbol{\Gamma}^{-1}$ .

■ **Postać strukturalna dla  $j$ -tego równania:**

$$\begin{aligned} \mathbf{y}_j &= \mathbf{Y}_j \gamma_j + \mathbf{X}_j \beta_j + \varepsilon_j \\ &= \mathbf{Z}_j \delta_j + \varepsilon_j \end{aligned}$$

gdzie  $\mathbf{Z}_j$  to macierz zmiennych endogenicznych w  $j$ -tym równaniu oraz zmiennych egzogenicznych w  $j$ -tym równaniu, tj.  $\mathbf{Z}_j = [\mathbf{Y}_j \quad \mathbf{X}_j]$ .

■ **Postać zredukowana dla zmiennych endogenicznych występujących w  $j$ -tym równaniu**

$$\mathbf{Y}_j = \Pi_j \mathbf{X}_j + \nu_j$$

gdzie  $\Pi_j$  to  $j$ -ta kolumna macierzy z postaci zredukowanej. A  $\nu = \varepsilon \Gamma^{-1}$ .

■ **Estymator najmniejszej metody kwadratów będzie niezgodny:**

$$\hat{\delta}_j^{OLS} = [\mathbf{Z}_j^T \mathbf{Z}_j]^{-1} \mathbf{Z}_j^T \mathbf{y}_j = \delta_j + \begin{bmatrix} \mathbf{Y}_j^T \mathbf{Y}_j & \mathbf{Y}_j^T \mathbf{X}_j \\ \mathbf{X}_j^T \mathbf{Y}_j & \mathbf{X}_j^T \mathbf{X}_j \end{bmatrix}^{-1} \begin{bmatrix} \mathbf{Y}_j^T \varepsilon_j \\ \mathbf{X}_j^T \varepsilon_j \end{bmatrix}$$

- ▶  $\text{plim} \frac{1}{N} \mathbf{X}_j^T \varepsilon_j$  dąży do zera, ponieważ zmienne  $\mathbf{X}_j$  są egzogeniczne.
- ▶ **Kluczowe jest tutaj komponent  $\text{plim} \frac{1}{N} \mathbf{Y}_j^T \varepsilon_j$ , który nie zbiega do 0**. Korelacja ta prowadzi do tzw. **simultaneous equations bias**.

## Modele rekurencyjne

to modele, w których macierz  $\Gamma$  (określająca zależność między zmiennymi endogenicznymi w postaci strukturalnej) jest trójkątna.



## Modele rekurencyjne

to modele, w których macierz  $\Gamma$  (określająca zależność między zmiennymi endogenicznymi w postaci strukturalnej) jest trójkątna.

## Przykład (3 zmienne endogeniczne)

$$\begin{aligned}y_1 &= X\beta_1 && +\varepsilon_1, \\y_2 &= X\beta_2 + \gamma_{12}y_1 && +\varepsilon_2, \\y_3 &= X\beta_3 + \gamma_{13}y_1 + \gamma_{23}y_2 && +\varepsilon_3.\end{aligned}$$

## Modele rekurencyjne

to modele, w których macierz  $\Gamma$  (określająca zależność między zmiennymi endogenicznymi w postaci strukturalnej) jest trójkątna.

### Przykład (3 zmienne endogeniczne)

$$\begin{aligned}y_1 &= X\beta_1 && +\varepsilon_1, \\y_2 &= X\beta_2 + \gamma_{12}y_1 && +\varepsilon_2, \\y_3 &= X\beta_3 + \gamma_{13}y_1 + \gamma_{23}y_2 && +\varepsilon_3.\end{aligned}$$

## Modele w pełni rekurencyjne

to modele, w których macierz  $\Gamma$  jest trójkątna oraz  $\Sigma$  (macierz wariancji kowariancji składnika losowego) jest diagonalna.

## Modele rekurencyjne

to modele, w których macierz  $\Gamma$  (określająca zależność między zmiennymi endogenicznymi w postaci strukturalnej) jest trójkątna.

### Przykład (3 zmienne endogeniczne)

$$\begin{aligned} y_1 &= X\beta_1 && +\varepsilon_1, \\ y_2 &= X\beta_2 + \gamma_{12}y_1 && +\varepsilon_2, \\ y_3 &= X\beta_3 + \gamma_{13}y_1 + \gamma_{23}y_2 && +\varepsilon_3. \end{aligned}$$

## Modele w pełni rekurencyjne

to modele, w których macierz  $\Gamma$  jest trójkątna oraz  $\Sigma$  (macierz wariancji kowariancji składnika losowego) jest diagonalna.

- W przypadku modelu w pełni rekurencyjnych, parametry postaci strukturalnej mogą być szacowane MNK.
- Wynika to z braku zależności między składnikiem losowym ( $\varepsilon$ ) a zmiennymi endogenicznymi. Dla przykładu:

$$\text{cov}(y_1, \varepsilon_2) = \text{cov}(X\beta_1 + \varepsilon_1, \varepsilon_2) = 0$$

## Modele rekurencyjne

to modele, w których macierz  $\Gamma$  (określająca zależność między zmiennymi endogenicznymi w postaci strukturalnej) jest trójkątna.

### Przykład (3 zmienne endogeniczne)

$$\begin{aligned}y_1 &= X\beta_1 && +\varepsilon_1, \\y_2 &= X\beta_2 + \gamma_{12}y_1 && +\varepsilon_2, \\y_3 &= X\beta_3 + \gamma_{13}y_1 + \gamma_{23}y_2 && +\varepsilon_3.\end{aligned}$$

## Modele w pełni rekurencyjne

to modele, w których macierz  $\Gamma$  jest trójkątna oraz  $\Sigma$  (macierz wariancji kowariancji składnika losowego) jest diagonalna.

- W przypadku model w pełni rekurencyjnych, parametry postaci strukturalnej mogą być szacowane MNK.
- Wynika to z braku zależności między składnikiem losowym ( $\varepsilon$ ) a zmiennymi endogenicznymi. Dla przykładu:

$$\text{cov}(y_1, \varepsilon_2) = \text{cov}(X\beta_1 + \varepsilon_1, \varepsilon_2) = 0$$

- **Pośrednia Metoda Najmniejszych Kwadratów** (*indirect least squares ILS*) polega na oszacowaniu parametrów postaci zredukowanej:

$$\mathbf{Y} = \Pi\mathbf{X} + \nu \quad (26)$$

Klasyczną metodą najmniejszych kwadratów:

$$\hat{\Pi}^{OLS} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}. \quad (27)$$

- Na podstawie oszacowań  $\hat{\Pi}^{OLS}$  można wyznaczyć oszacowania punktowe postaci strukturalnej, tj.  $\hat{\Gamma}^{ILS}$  oraz  $\hat{\mathbf{B}}^{ILS}$ .
- Jest to możliwe jedynie w przypadku dokładnej identyfikowalności każdego z równań.

- **Podwójna Metoda Najmniejszych Kwadratów (two-stage least squares 2SLS)** polega na wykorzystaniu wszystkich zmiennych egzogenicznych  $\mathbf{X}$  jako instrumentów dla zmiennych egzogenicznych  $\mathbf{Y}_j$  w  $j$ -tym równaniu.
- **[Krok #1]** Regresja(e) zmiennych endogenicznych występujących po prawej stronie równania  $j$  ( $\mathbf{Y}_j$ ) względem wszystkich zmiennych egzogenicznych.  
 $\implies$  Obliczamy wartości teoretyczne  $\hat{\mathbf{Y}}_j$ .
- **[Krok #2]** Regresja  $\mathbf{y}_j$  względem  $\hat{\mathbf{Y}}_j$  oraz  $\mathbf{X}_j$ .
  - ▶ Powyższa strategią ilustruje warunek konieczny identyfikowalności (*order condition*). Przypomnijmy:
 
$$K_j^* \geq M_j.$$
  - ▶ W przeciwnym przypadku liczba zmiennych egzogenicznych pominiętych w  $j$  tym warunku jest większa od liczby zmiennych endogenicznych. Wtedy macierz zmiennych objaśnających w drugim kroku, a więc  $[\hat{\mathbf{Y}}_j \quad \mathbf{X}_j]$  ma niepełny rząd.

- Estymator 2SLS dla parametrów  $j$ -tego równania wykorzystujący wartości teoretyczne z pierwszego kroku ( $\hat{\mathbf{Y}}_j$ ):

$$\hat{\delta}_j^{2SLS} = \begin{bmatrix} \hat{\mathbf{Y}}_j^T \mathbf{Y}_j & \hat{\mathbf{Y}}_j^T \mathbf{X}_j \\ \mathbf{X}_j^T \hat{\mathbf{Y}}_j & \mathbf{X}_j^T \mathbf{X}_j \end{bmatrix}^{-1} \begin{bmatrix} \hat{\mathbf{Y}}_j^T \mathbf{y}_j \\ \mathbf{X}_j^T \mathbf{y}_j \end{bmatrix}. \quad (28)$$

Po pewnych przekształceniach można uzyskać następującą postać estymatora 2SLS:

$$\hat{\delta}_j^{2SLS} = \begin{bmatrix} \hat{\mathbf{Y}}_j^T \hat{\mathbf{Y}}_j & \hat{\mathbf{Y}}_j^T \mathbf{X}_j \\ \mathbf{X}_j^T \hat{\mathbf{Y}}_j & \mathbf{X}_j^T \mathbf{X}_j \end{bmatrix}^{-1} \begin{bmatrix} \hat{\mathbf{Y}}_j^T \mathbf{y}_j \\ \mathbf{X}_j^T \mathbf{y}_j \end{bmatrix}. \quad (29)$$

- Asymptotyczna wariancja:

$$\text{Var}(\hat{\delta}_j^{2SLS}) = \hat{\sigma}_{jj} [\hat{\mathbf{Z}}_j^T \hat{\mathbf{Z}}_j]^{-1}, \quad (30)$$

gdzie macierz  $\mathbf{Z}_j$  to macierz zmiennych w  $j$ -tym równaniu. Z kolei, szacowana zmienność składnika losowego:

$$\hat{\sigma}_{jj} = \frac{(\mathbf{y}_j - \mathbf{Z}_j \hat{\delta}_j^{2SLS})^T (\mathbf{y}_j - \mathbf{Z}_j \hat{\delta}_j^{2SLS})}{N}, \quad (31)$$

zależy od obserwacji ( $\mathbf{Z}_j$ ) a nie od  $\hat{\mathbf{Z}}_j$

- **Potrójna Metoda Najmniejszych Kwadratów** (*three-stage least squares 3SLS*) jest metodą polegającą na **jednoczesnej** estymacji parametrów modelu wielorównaniowego.
- Idea polega na połączeniu:
  - ▶ Podwójnej Metody Najmniejszych Kwadratów dla każdego równania,
  - ▶ Estymatora GLS (Uogólnionej Metody Najmniejszych Kwadratów), który uwzględnia **korelację składnika losowego pomiędzy równaniami**.



Zapis ogólny:

$$\mathbf{y} = \mathbf{Z}\delta + \varepsilon, \quad (32)$$

Zapis macierzowy:

$$\begin{bmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \\ \vdots \\ \mathbf{y}_M \end{bmatrix} \begin{bmatrix} \mathbf{Z}_1 & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{0} & \mathbf{Z}_2 & \dots & \mathbf{0} \\ \vdots & \vdots & \vdots & \vdots \\ \mathbf{0} & \mathbf{0} & \dots & \mathbf{Z}_M \end{bmatrix} \begin{bmatrix} \delta_1 \\ \delta_2 \\ \vdots \\ \delta_M \end{bmatrix} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_M \end{bmatrix}, \quad (33)$$

gdzie  $\mathbf{Z}_i$  to zmienne (endogeniczne i egzogeniczne) w  $i$ -tym równaniu, a  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_M$  to wektory składników losowych.

## ■ Standardowe założenia:

- ▶  $\mathbb{E}(\varepsilon|\mathbf{X}) = 0$
- ▶  $\mathbb{E}(\varepsilon\varepsilon^T|\mathbf{X}) = \bar{\Sigma} = \Sigma \otimes I$ , gdzie  $I$  to macierz jednostkowa o wymiarach równych liczbie obserwacji.

## ■ Macierz kowariancji:

$$\Sigma \otimes I = \begin{bmatrix} \sigma_{11}^2 & \sigma_{12}^2 & \dots & \sigma_{1M}^2 \\ \sigma_{21}^2 & \sigma_{22}^2 & \dots & \sigma_{2M}^2 \\ \vdots & \vdots & \vdots & \vdots \\ \sigma_{M1}^2 & \sigma_{M2}^2 & \dots & \sigma_{MM}^2 \end{bmatrix} \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix} \quad (34)$$

a więc ...



- **Krok pierwszy** w 3SLS polega na oszacowaniu macierzy parametrów formy zredukowanej, tj.  $\Pi$ . Parametry  $\Pi$  są szacowane metodą najmniejszych kwadratów dla każdego z równań.
  - ▶ Dzięki tym oszacowaniom obliczane mogą zostać wartości teoretyczne zmiennych endogenicznych dla każdego z równań, tj.  $\hat{\mathbf{Y}}_j$ .
- **Krok drugi** w 3SLS to oszacowanie 2SLS (podwójnej metody najmniejszych kwadratów) wektora parametrów dla każdego z równań, tj.  $\hat{\delta}_j^{2SLS}$ . Na podstawie, uzyskanych oszacowań  $\hat{\delta}_j^{2SLS}$  wyznaczana jest macierz wariancji kowariancji, uwzględniająca zależność składnika losowego pomiędzy równaniami. Estymator kowariancji pomiędzy  $i$ -tym a  $j$ -tym równaniem:

$$\hat{\sigma}_{ij} = \frac{(\mathbf{y}_i - \mathbf{Z}_i \hat{\delta}_i^{2SLS})^T (\mathbf{y}_i - \mathbf{Z}_j \hat{\delta}_j^{2SLS})}{N}, \quad (35)$$

- **Krok trzeci** w 3SLS to wykorzystanie estymatora uogólnionej metody najmniejszych kwadratów GLS. Na podstawie szacunków:
  - ▶  $\hat{\mathbf{Y}}_j$ , a więc  $\hat{\mathbf{Z}}$  (pierwszy krok);
  - ▶ macierzy wariancji-kowariancji składnika losowego  $\hat{\Sigma}$  (drugi krok);
 możemy wyznaczyć estymator **Potrójnej Metody Najmniejszych Kwadratów**  $\hat{\delta}^{3SLS}$ :

$$\hat{\delta}^{3SLS} = [\hat{\mathbf{Z}}^T (\Sigma^{-1} \otimes I) \hat{\mathbf{Z}}]^{-1} \hat{\mathbf{Z}}^T (\Sigma^{-1} \otimes I) \mathbf{y}. \quad (36)$$

- Wariancja estymatora  $\hat{\delta}^{3SLS}$ :

$$\text{Var}(\hat{\delta}^{3SLS}) = [\bar{\mathbf{Z}}^T (\Sigma^{-1} \otimes I) \bar{\mathbf{Z}}]^{-1}, \quad (37)$$

gdzie  $\bar{\mathbf{Z}} = \text{diag}[\mathbf{X}\Pi_j, \mathbf{X}]$ .

## Dynamiczne modele wielorównaniowe

- **Strukturalne modele dynamiczne** (alternatywny zapis uwzględniający indeks obserwacji  $t$ ,  $t$  oznacza transpozycję):

$$\mathbf{y}'_t \Gamma + \mathbf{x}'_t \mathbf{B} + \mathbf{y}'_{t-1} \Phi = \varepsilon', \quad (38)$$

gdzie  $\mathbf{y}'_{t-1}$  to wektor opóźnionych zmiennych endogenicznych.

Macierz  $\Phi$  wyraża zależność pomiędzy  $\mathbf{y}'_{t-1}$  oraz  $\mathbf{y}'_t$ .

- Opóźnione zmienne endogeniczne  $\mathbf{y}'_{t-1}$  są **predeterminowane** (*predetermined*).
- W analizie problemu identyfikowalności  $\mathbf{y}'_{t-1}$  można zatem traktować jako zmienne egzogeniczne w tym przypadku.

- **Strukturalne modele dynamiczne** (alternatywny zapis uwzględniający indeks obserwacji  $t$ ,  $I$  oznacza transpozycję):

$$\mathbf{y}'_t \Gamma + \mathbf{x}'_t \mathbf{B} + \mathbf{y}'_{t-1} \Phi = \varepsilon', \quad (38)$$

gdzie  $\mathbf{y}'_{t-1}$  to wektor opóźnionych zmiennych endogenicznych.

Macierz  $\Phi$  wyraża zależność pomiędzy  $\mathbf{y}'_{t-1}$  oraz  $\mathbf{y}'_t$ .

- Opóźnione zmienne endogeniczne  $\mathbf{y}'_{t-1}$  są **predeterminowane** (*predetermined*).
- W analizie problemu identyfikowalności  $\mathbf{y}'_{t-1}$  można zatem traktować jako zmienne egzogeniczne w tym przypadku.
- Większą liczbę opóźnień można uwzględnić przez dodatkowe równania systemu.

$$[\mathbf{y}_t \quad \mathbf{y}_{t-1}]' \begin{bmatrix} \Gamma & 0 \\ 0 & I \end{bmatrix} + \mathbf{x}_t [\mathbf{B} \quad 0] + [\mathbf{y}_{t-1} \quad \mathbf{y}_{t-2}]' \begin{bmatrix} \Phi_1 & I \\ \Phi_2 & 0 \end{bmatrix} = [\varepsilon'_t \quad 0]. \quad (39)$$



- **Postać zredukowana** dynamicznego modelu wielorównaniowego:

$$\mathbf{y}'_t = \mathbf{x}'_t \mathbf{\Pi} + \mathbf{y}'_{t-1} \mathbf{\Xi} + \nu'_t, \quad (40)$$

gdzie:

$$\mathbf{\Xi} = -\mathbf{\Phi} \mathbf{\Gamma}^{-1}, \quad (41)$$

$$\mathbf{\Pi} = -\mathbf{B} \mathbf{\Gamma}^{-1}, \quad (42)$$

$$\nu'_t = \nu'_t \mathbf{\Gamma}^{-1}. \quad (43)$$

- **Postać zredukowana** dynamicznego modelu wielorównaniowego:

$$\mathbf{y}'_t = \mathbf{x}'_t \Pi + \mathbf{y}'_{t-1} \Xi + \nu'_t. \quad (44)$$

- **Mnożnik jednoczesny/ krótkookresowy/bezpośredni:** zmiennej  $k$ -tej egzogenicznej na  $m$ -tą zmienną endogeniczną.

$$\frac{\partial y_{t,m}}{\partial x_{t,k}} = \Pi_{k,m}, \quad (45)$$

to po prostu odpowiedni element macierzy określającej **bezpośredni** wpływ zmiennych egzogenicznych na zmienne endogeniczne w postaci zredukowanej.

- **Postać zredukowana** dynamicznego modelu wielorównaniowego:

$$\mathbf{y}'_t = \mathbf{x}'_t \Pi + \mathbf{y}'_{t-1} \Xi + \nu'_t. \quad (46)$$

- Substytucja  $\mathbf{y}'_{t-1}$  przez zależność wynikającą z postaci zredukowanej (tj.  $\mathbf{y}'_{t-1} = \mathbf{x}'_{t-1} \Pi + \mathbf{y}'_{t-2} \Xi + \nu'_{t-1}$ ):

$$\mathbf{y}'_t = \mathbf{x}'_t \Pi + \mathbf{x}'_{t-1} \Pi \Xi + \mathbf{y}'_{t-2} \Xi^2 + \nu'_t + \nu'_{t-1} \Xi, \quad (47)$$

- Kontynuując dla kolejnych opóźnień (oznaczanych przez  $s$ ):

$$\mathbf{y}'_t = \sum_{s=0}^{t-1} (\mathbf{x}'_{t-s} \Pi \Xi^s) + \mathbf{y}'_0 \Xi^t + \sum_{s=0}^{t-1} (\nu'_{t-s} \Xi^s), \quad (48)$$

gdzie  $\mathbf{y}'_0$  to początkowe wartości zmiennych endogenicznych.

- **Postać zredukowana** dynamicznego modelu wielorównaniowego:

$$\mathbf{y}'_t = \mathbf{x}'_t \Pi + \mathbf{y}'_{t-1} \Xi + \nu'_t. \quad (46)$$

- Substytucja  $\mathbf{y}'_{t-1}$  przez zależność wynikającą z postaci zredukowanej (tj.  $\mathbf{y}'_{t-1} = \mathbf{x}'_{t-1} \Pi + \mathbf{y}'_{t-2} \Xi + \nu'_{t-1}$ ):

$$\mathbf{y}'_t = \mathbf{x}'_t \Pi + \mathbf{x}'_{t-1} \Pi \Xi + \mathbf{y}'_{t-2} \Xi^2 + \nu'_t + \nu'_{t-1} \Xi, \quad (47)$$

- Kontynuując dla kolejnych opóźnień (oznaczanych przez  $s$ ):

$$\mathbf{y}'_t = \sum_{s=0}^{t-1} (\mathbf{x}'_{t-s} \Pi \Xi^s) + \mathbf{y}'_0 \Xi^t + \sum_{s=0}^{t-1} (\nu'_{t-s} \Xi^s), \quad (48)$$

gdzie  $\mathbf{y}'_0$  to początkowe wartości zmiennych endogenicznych.

- **Dynamiczny mnożnik:**

$$\frac{\partial y_{t,m}}{\partial x_{t-s,k}} = (\Pi \Xi^s)_{k,m} \quad (49)$$

pozwała ocenić wpływ zmiany  $k$  – tej zmiennej egzogenicznej na  $m$ -tą zmienną endogeniczną po  $s$  okresach.

■ **Postać końcowa modelu:**

$$\mathbf{y}'_t = \sum_{s=0}^{\infty} (\mathbf{x}'_{t-s} \Pi \Xi^s) + \sum_{s=0}^{\infty} (\nu'_{t-s} \Xi^s), \quad (50)$$

pozwała wyrazić zmienne endogeniczne jako sumę skumulowanych zmian zmiennych egzogenicznych oraz zaburzeń strukturalnych.

### ■ Postać końcowa modelu:

$$\mathbf{y}'_t = \sum_{s=0}^{\infty} (\mathbf{x}'_{t-s} \Pi \Xi^s) + \sum_{s=0}^{\infty} (\nu'_{t-s} \Xi^s), \quad (50)$$

pozwała wyrazić zmienne endogeniczne jako sumę skumulowanych zmian zmiennych egzogenicznych oraz zaburzeń strukturalnych.

### ■ Mnożniki długookresowe (równowagowe):

$$\Pi [I + \Xi + \Xi^2 + \dots] = \Pi [I - \Xi]^{-1} \quad (51)$$

określają łączny (skumulowany) wpływ zmian zmiennych egzogenicznych na zmienne endogeniczne.

- W przypadku mnożników długookresowych kluczowa jest stabilność, tj.  $\lim_{t \rightarrow \infty} \Xi^t = 0$ .

■ **Postać końcowa modelu:**

$$\mathbf{y}'_t = \sum_{s=0}^{\infty} (\mathbf{x}'_{t-s} \Pi \Xi^s) + \sum_{s=0}^{\infty} (\nu'_{t-s} \Xi^s), \quad (50)$$

pozwała wyrazić zmienne endogeniczne jako sumę skumulowanych zmian zmiennych egzogenicznych oraz zaburzeń strukturalnych.

■ **Możniki długookresowe (równowagowe):**

$$\Pi [I + \Xi + \Xi^2 + \dots] = \Pi [I - \Xi]^{-1} \quad (51)$$

określają łączny (skumulowany) wpływ zmian zmiennych egzogenicznych na zmienne endogeniczne.

- W przypadku mnożników długookresowych kluczowa jest stabilność, tj.  $\lim_{t \rightarrow \infty} \Xi^t = 0$ .
- **Skumulowane dynamiczne mnożniki:**

$$\Pi [I - \Xi]^{-1} [I - \Xi^s],$$

gdzie  $s$  jest horyzontem analizy.

- **Stabilność** jest kluczową charakterystyką dynamicznych modeli wielorównaniowych.
  - ▶ Stabilność oznacza, że wpływ zmian zmiennych egzogenicznych na zmienne endogeniczne będzie wygasał w czasie.



- **Stabilność** jest kluczową charakterystyką dynamicznych modeli wielorównaniowych.
  - ▶ Stabilność oznacza, że wpływ zmian zmiennych egzogenicznych na zmienne endogeniczne będzie wygasał w czasie.
- Wykorzystując dekompozycję spektralną macierzy  $\Xi$  (opisującą zależność między zmiennymi endogenicznymi a ich opóźnieniami):

$$\Xi = C\Lambda C^{-1}, \quad (52)$$

gdzie  $\Lambda$  to macierz diagonalna z wartościami własnymi na przekątnej, a  $C$  to macierz zawierająca wektory własne.

- **Stabilność** jest kluczową charakterystyką dynamicznych modeli wielorównaniowych.
  - ▶ Stabilność oznacza, że wpływ zmian zmiennych egzogenicznych na zmienne endogeniczne będzie wygasał w czasie.
- Wykorzystując dekompozycję spektralną macierzy  $\Xi$  (opisującą zależność między zmiennymi endogenicznymi a ich opóźnieniami):

$$\Xi = C\Lambda C^{-1}, \quad (52)$$

gdzie  $\Lambda$  to macierz diagonalna z wartościami własnymi na przekątnej, a  $C$  to macierz zawierająca wektory własne.

- Warto zauważyć, że:

$$\Xi^2 = C\Lambda C^{-1}C\Lambda C^{-1} = C\Lambda^2 C^{-1}, \quad (53)$$

a więc

$$\Xi^t = C\Lambda^t C^{-1}, \quad (54)$$

zatem stabilność ( $\lim_{t \rightarrow \infty} \Xi^t = 0$ ) jest zagwarantowana jeżeli  $\lim_{t \rightarrow \infty} \Lambda^t = 0$ . W powyższy przypadku jest to tożsame z sytuacją, gdy moduł wartości własnych (elementy diagonalne  $\Lambda$ ) jest mniejszy od jedności.