

# Rozdział 6. Strukturalne modele VAR

## MODELOWANIE POLSKIEJ GOSPODARKI z R

# Wprowadzenie do modeli SVAR

Krytyka modeli wielorównaniowych z lat 50-tych i 60-tych postaci:

$$By_t + \Gamma x_t = \epsilon_t,$$

- arbitralny podział zmiennych modelu na endogeniczne i egzogeniczne;
- narzucenie a-priori postaci dynamicznej modelu;
- narzucanie warunków zerowych na macierze  $B$  i  $\Gamma$  (niekoniecznie spójnych z danymi oraz teorią ekonomii) w celu zapewnienia identyfikowalności modelu;
- słabe własności prognostyczne oraz symulacyjne;
- brak odporności na krytykę Lucasa, tj. nieuwzględnienie oczekiwań podmiotów gospodarczych.

# Wprowadzenie do modeli SVAR

Sims (1980) zaproponował nowe podstawy łącznego modelowania wielu zmiennych ekonomicznych za pomocą strukturalnych modeli VAR, które:

- nie zakładają podziału a-priori na zmienne endogeniczne i egzogeniczne;
- nie nakładają warunków zerowych;
- mają bogatą specyfikację dynamiczną;
- są odporne na krytykę Lucasa.

# Wprowadzenie do modeli SVAR

Modele SVAR a zmiana myślenia o funkcjonowaniu gospodarki:

**Tradycyjny model wielorównaniowy:**

Interpretacja pojedynczych współczynników, określanych jako mnożniki

**Model SVAR**

Interpretacja dynamicznej reakcji na zewnętrzne szoki strukturalne

# Przyczynowość

Uwzględnienie zależności między zmiennymi  $z$  i  $x$ :

Tradycyjny model wielorównaniowy:

Uwzględnienie zmiennej  $x$  w roli regresora w równaniu dla zmiennej  $z$

Model VAR

Testy przyczynowości

Definicja przyczynowości (Granger, 1969):

*Zmienna  $x$  jest przyczyną  $z$ , jeżeli bieżące wartości  $z$  można prognozować z większą dokładnością przy użyciu przeszłych wartości  $x$  niż bez ich wykorzystania, przy nie zmienionej pozostałej informacji.*

# Przyczynowość

Niech wektor zmiennych endogenicznych  $y_t = [z_t, x_t]$ , gdzie  $z_t$  i  $x_t$  są wymiarów  $N_1$  oraz  $N_2$ ,  $N_1 + N_2 = N$ . Model VAR można zapisać jako:

$$\begin{bmatrix} z_t \\ x_t \end{bmatrix} = \sum_{p=1}^P \begin{bmatrix} A_{p(11)} & A_{p(12)} \\ A_{p(21)} & A_{p(22)} \end{bmatrix} \begin{bmatrix} z_{t-i} \\ x_{t-i} \end{bmatrix} + \begin{bmatrix} \epsilon_t^z \\ \epsilon_t^x \end{bmatrix}.$$

W celu ustalenia czy  $x$  jest przyczyną wektora  $z$  testujemy:

$$H_0 : \forall 1 \leq p \leq P A_{p(12)} = 0$$

$$H_1 : \exists i \leq p \leq P A_{p(12)} \neq 0.$$

Przy prawdziwości  $H_0$  statystyka testu Walda ma rozkład  $F$ -Snedecora o  $v_1 = P \times N_1 \times N_2$  oraz  $v_2 = TN - PN^2$  stopniach swobody.

# Przyczynowość

- Przyczynowość w sensie Grangera nie analizuje występowania jednoczesnych zależności (instantaneous causality), które są opisywane przez macierz kowariancji:

$$\Sigma = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{bmatrix},$$

- Zespół hipotez dla jednoczesnej przyczynowości:

$$H_0 : \Sigma_{12} = 0$$

$$H_1 : \Sigma_{12} \neq 0.$$

Przy prawdziwości  $H_0$  odpowiednia statystyka ma rozkład  $\chi^2$  o  $N_1 \times N_2$  stopniach swobody.

- Symetryczność testu: jeżeli  $z$  jest „jednoczesną przyczyną” dla  $x$  to jest to równoznaczne z faktem, że  $x$  jest „jednoczesną przyczyną” dla  $z$

# Postać modelu SVAR

- Model VAR w postaci strukturalnej (postać SVAR):

$$Ay_t = C_0 + C_1y_{t-1} + \dots + C_Py_{t-P} + B\eta_t, \eta_t \sim N(0, I_N)$$

- Składniki losowe  $\eta_{nt}$  względem siebie niezależne - można im nadać interpretacji ekonomicznej. Z tego względu określane są jako **szoki strukturalne**
- $A$  i  $B$  określają jednoczesne zależności między zmiennymi endogenicznymi, zaś macierze  $\{C_i : i = 1, 2, \dots, P\}$  dynamiczne własności modelu
- Bezpośrednia estymacja modelu SVAR niemożliwa ze względu na problem identyfikowalności: parametry modelu SVAR są uzyskiwane na podstawie oszacowań modelu VAR, zaś proces określany jest jako strukturalizacja modelu VAR.



# Funkcja reakcji na impuls

- W modelu *SVAR* analiza funkcjonowania gospodarki dokonywana poprzez analizę dynamicznej reakcji  $\{y_i : i = 1, 2, \dots, N\}$  na szoki strukturalne  $\{\eta_j : j = 1, 2, \dots, N\}$ .
- Reakcja określana jako **funkcja reakcji na impuls** (impulse-response function, IRF):

$$IRF_{k(ij)} = \frac{\partial y_{i,t+k}}{\partial \eta_{jt}}$$

- Wartość IRF dla wszystkich zmiennych względem wszystkich szoków:

$$IRF_k = \frac{\partial y_{t+k}}{\partial \eta_t} = [IRF_{k(ij)}]_{N \times N}$$

można obliczyć poprzez zapisanie modelu w postaci  $SVMA(\infty)$ :

$$y_t = \mu + \sum_{k=0}^{\infty} \Psi_k \eta_{t-k}$$

gdzie  $\Psi_k = IRF_k$  są macierzami o wymiarach  $N \times N$ :

# Funkcja reakcji na impuls

Etapy przekształcenia modelu SVAR do postaci SVMA( $\infty$ ) dokonuje się w następujących krokach.

- 1 Zapisać model SVAR w postaci zredukowanej (model VAR):

$$y_t = A^{-1}C_0 + A^{-1}C_1y_{t-1} + \dots + A^{-1}C_Py_{t-P} + A^{-1}B\eta_t, \epsilon_t = A^{-1}B\eta_t$$

- 2 Zapisać model VAR w postaci VMA( $\infty$ ):

$$y_t = \mu + \epsilon_t + \sum_{i=1}^{\infty} \Theta_i \epsilon_{t-i}.$$

- 3 Biorąc pod uwagę zależność  $\epsilon_t = A^{-1}B\eta_t$  wartości IRF liczymy jako:

$$\Psi_j = \Theta_j A^{-1}B.$$

# Funkcja skumulowanej reakcji na impuls

- Niech  $y_{it} = \Delta z_{it}$ , np.  $y_{it}$  jest dynamiką PKB, zaś  $z_{it}$  określa poziom PKB.
- W modelu VAR występuje zmienna  $y_{it}$ , a nas interesuje wpływ  $j$ -tego szoku strukturalnego  $\eta_j$  na zmienną  $z_i$
- W takim przypadku liczy się skumulowany IRF:

$$AIRF_{k(ij)} = \frac{\partial z_{i,t+k}}{\partial \eta_{jt}} = \sum_{m=0}^k IRF_{k(ij)}$$

- Wariancja błędu losowego prognozy dla  $y_t$  na  $k$  okresów do przodu wynosi:

$$\Sigma_k = \text{Var}(y_{T+k} - y_{T+k}^f) = \sum_{m=0}^{k-1} \Psi_m \Psi_m'$$

- Wartość błędu losowego prognozy dla  $y_{it}$  na  $k$  okresów do przodu wynosi:

$$\Sigma_{k(ii)} = \sum_{j=1}^N (\Psi_{0(ij)}^2 + \Psi_{1(ij)}^2 + \dots + \Psi_{k-1(ij)}^2).$$

- Dekompozycja wariancji błędu prognozy (forecast error variance decomposition, FEVD) określa jaka część  $\Sigma_{k(ii)}$  wynika z występowania kolejnych szoków strukturalnych  $\{\eta_{jt} : j = 1, 2, \dots, N\}$ .

$$FEVD_{k(ij)} = \frac{\Psi_{0(ij)}^2 + \Psi_{1(ij)}^2 + \dots + \Psi_{k-1(ij)}^2}{\Sigma_{k(ii)}}$$

- Dla  $k \rightarrow \infty$  FEVD jest interpretowana jako dekompozycja wariancji dla zmiennych endogenicznych modelu VAR

# Strukturalizacja modelu VAR

- Parametry modelu SVAR uzyskujemy na podstawie oszacowań parametrów modelu VAR postaci:

$$\text{Model SVAR : } Ay_t = C_0 + C_1y_{t-1} + \dots + C_Py_{t-P} + B\eta_t, \text{ Var}(\eta_t) = I$$

$$\text{Model VAR : } y_t = A_0 + A_1y_{t-1} + \dots + A_Py_{t-P} + \epsilon_t, \text{ Var}(\epsilon_t) = \Sigma.$$

- Liczba parametrów modelu SVAR:  $K_{SVAR} = (P + 2)N^2 + N$ , modelu VAR:  $K_{VAR} = PN^2 + N + \frac{N(N+1)}{2}$ . Ostatnia część sumy dla  $K_{VAR}$  wynika z występowania parametrów w macierzy  $\Sigma$
- Liczba niezbędnych restrykcji (tj. warunków identyfikujących):

$$K = K_{SVAR} - K_{VAR} = N^2 + \frac{N(N-1)}{2}$$

- Zależności:  $\epsilon_t = A^{-1}B\eta_t$  oraz  $\Sigma = A^{-1}BB'(A^{-1})'$ .

# Strukturalizacja krótkookresowa

- Strukturalizacja rekursywna:

$$A = \begin{bmatrix} 1 & 0 & \dots & 0 \\ * & 1 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ * & * & \dots & 1 \end{bmatrix} \quad \text{oraz} \quad B = \begin{bmatrix} * & 0 & \dots & 0 \\ 0 & * & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & * \end{bmatrix}$$

- Parametry można wyznaczyć rozwiązując układ  $N(N+1)/2$  równań z  $N(N+1)/2$  niewiadomymi postaci  $\Sigma = A^{-1}BB'(A^{-1})'$
- **Dekompozycja Cholesky'ego**: dla każdej dodatnio określonej symetrycznej macierzy kwadratowej  $\Sigma$  wymiaru  $N \times N$  o wartościach rzeczywistych istnieje unikalna (co do znaku), nieosobliwa dolnotrójkątna macierz  $P$ , taka że  $\Sigma = PP'$ .

# Strukturalizacja krótkookresowa

- Przykład strukturalizacji nierekursywnej (Kim i Roubini, 2000): dla wektora  $y_t$  składającego się z pięciu zmiennych: PKB, cen, podaży pieniądza, stóp procentowych oraz kursu walutowego:

$$A = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ * & 1 & 0 & 0 & 0 \\ * & * & 1 & * & 0 \\ 0 & 0 & * & 1 & * \\ * & * & * & * & 1 \end{bmatrix} \quad \text{oraz} \quad B = \begin{bmatrix} * & 0 & 0 & 0 & 0 \\ 0 & * & 0 & 0 & 0 \\ 0 & 0 & * & 0 & 0 \\ 0 & 0 & 0 & * & 0 \\ 0 & 0 & 0 & 0 & * \end{bmatrix}$$

- Strukturalizacja ta oznacza, że:
  - PKB nie reaguje na bieżące wartości pozostałych zmiennych;
  - Ceny reagują jedynie na zmiany PKB;
  - Pieniądz reaguje na zmiany PKB, cen i stopy procentowej;
  - Bank centralny ustala stopy procentowe wykorzystując informację na temat podaży pieniądza oraz kursy walutowego, a także pośrednio poziomu PKB i cen;
  - Kurs walutowy dyskontuje wszystkie dostępne informacje.

# Strukturalizacja długookresowa

- W wielu przypadkach teoria ekonomii wskazuje, że pewne szoki nie mają długookresowego wpływu na jedną ze zmiennych występujących w modelu SVAR (np. szok monetarny nie ma długookresowego wpływu na wielkość produktu)
- strukturalizacji modelu VAR poprzez narzucenie długookresowych restrykcji identyfikujących (metoda Blancharda i Quah)
- Nakładanie restrykcji na macierz:

$$\Phi = \lim_{k \rightarrow \infty} AIRF_k = (I - A_1 - \dots - A_p)^{-1} A^{-1} B.$$




# Przykład - model pass-through dla Polski

Zmienne wchodzące w skład wektora  $y_t$ :

- Dynamika cen ropy:  $\Delta OIL_t$ ;
- Dynamika produkcji przemysłowej w Polsce:  $\Delta PROD_t$ ;
- Dynamika nominalnego, efektywnego kursu złotego:  $\Delta NEER_t$ ;
- Inflacja cen importu:  $\Delta PM_t$ ;
- Inflacja cen produkcji w przemyśle:  $\Delta PPI_t$ ;
- Inflacja cen konsumenta:  $\Delta CPI_t$ .

Próba: 1993:2 - 2010:5.

# Przykład - model pass-through dla Polski



## Przykład - model pass-through dla Polski

Oszacowanie macierzy B modelu SVAR:

	dOIL	dProd	dNEER	dPM	dPPI	dCPI
dOIL	9.100	0.000	0.000	0.000	0.000	0.000
dProd	0.028	2.267	0.000	0.000	0.000	0.000
dNEER	-0.261	0.091	2.127	0.000	0.000	0.000
dPM	-0.060	0.109	0.773	2.301	0.000	0.000
dPPI	0.043	-0.001	0.237	-0.021	0.546	0.000
dCPI	0.004	-0.028	0.004	-0.019	0.225	0.362

## Przykład - model pass-through dla Polski

Skumulowany IRF na szok kursowy

	NEER	PM	PPI	CPI
k=0	2.13	0.77	0.24	0.00
k=1	2.74	1.72	0.39	0.05
k=2	2.66	1.70	0.41	0.14
k=4	2.78	1.69	0.59	0.32
k=10	3.13	2.02	0.95	0.70
k=20	3.42	2.33	1.32	1.10
k=40	3.65	2.58	1.63	1.45
k=60	3.72	2.66	1.72	1.55

## Przykład - model pass-through dla Polski

Dekompozycja wariancji prognozy dla dCPI

	dOIL	dProd	dNEER	dPM	dPPI	dCPI
FEVD, k=0	0.0	0.4	0.0	0.2	27.6	71.8
FEVD, k=1	0.6	0.3	1.0	0.2	29.6	68.3
FEVD, k=2	1.1	1.8	3.9	0.7	28.3	64.2
FEVD, k=3	1.0	3.0	6.3	0.8	28.3	60.7
FEVD, k=4	0.8	2.6	7.3	0.8	30.0	58.5
FEVD, k=10	0.7	2.3	10.4	0.9	31.1	54.6
FEVD, k=20	0.6	2.1	11.9	0.8	31.7	52.9
FEVD, k=60	0.6	2.1	12.4	0.7	32.0	52.3

## Przykład - model BQ dla Polski

Model SVAR dla tempa wzrostu PKB oraz stopy bezrobocia w Polsce (model VAR analizowany w rozdziale 5)

Oszacowania modelu SVAR:

Reakcja natychmiastowa (macierz B):

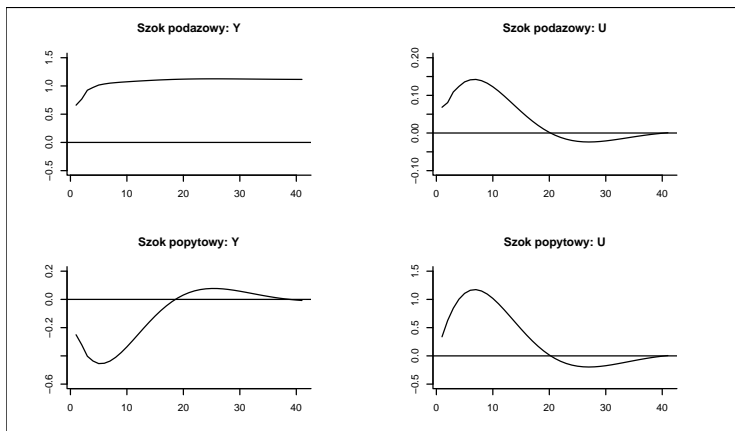
	eta_1	eta_2
dY	0.66	-0.25
U	0.07	0.34

Reakcja długookresowa (macierz Phi):

	eta_1	eta_2
dY	1.12	0.0
U	1.48	11.9

# Przykład - model BQ dla Polski

## Funkcja reakcji na impuls



# Egzogeniczność w modelach VAR

- Model VARX (dynamiczny model o równaniach współzależnych)

$$y_t = A_0 + A_1 y_{t-1} + \dots + A_P y_{t-P} + B_0 x_t + \dots + B_S x_{t-S} + \epsilon_t,$$

- Zmienne  $x_t$  są egzogeniczne, tj. nie są objaśniane przez model
- Różne definicje egzogeniczności



# Egzogeniczność w modelach VAR

- **Słaba egzogeniczność:** oszacowania parametrów  $\theta$  rozkładu warunkowego  $g(y|x)$  nie zależą od rozkładu brzegowego  $h(x)$ , tj.  
$$\text{Cov}(y - E(y|x), x - E(x)) = 0$$
- **Silna egzogeniczność:** warunkowa prognoza  $y$  względem  $x$  nieistotnie różna od prognozy na podstawie całego modelu (w którym  $x$  zależy także od  $y$ ). Czyli, wynik prognozy dla  $y$  nie wpływa na założenia dla przyszłych wartości  $x$  (połączenie słabej egzogeniczności z przyczynowością Grangera).
- **Super egzogeniczność:** kształt IRF dla  $y$  nie zależy od tego, czy jest obliczany na podstawie modelu warunkowego  $g(y|x)$  (np. VARX) czy pełnego modelu  $f(y, x)$  (np. VAR).
- **Całkowita egzogeniczność:** wartości składnika losowego  $\omega = y - E(y|x)$  są niezależne względem przeszłych, teraźniejszych oraz przyszłych wartości zmiennej  $x$ , tj.  $\text{Cov}(\omega_t, x_{t+s}) = 0$  dla  $s \in \mathcal{C}$ .