

Rozdział 5. Modele wektorowej autoregresji

MODELOWANIE POLSKIEJ GOSPODARKI z R

Wielowymiarowe modele szeregów czasowych

Modele VAR

- uwzględniają wzajemne powiązania między zmiennymi ekonomicznymi
- narzędzie statystyczne pomocne w opisie dynamicznych właściwości wielowymiarowej zmiennej
- VAR jako model ekonomiczny (SVAR)

Specyfikacja modelu VAR

Model VAR jest postaci dla wektora $y_t = [y_{1t}, y_{2t}, \dots, y_{nt}]'$:

$$y_t = A_0 + A_1 y_{t-1} + A_2 y_{t-2} + \dots + A_p y_{t-p} + \epsilon_t, \epsilon_t \sim N(0, \Sigma)$$

lub szybciej:

$$(I - A_1 L - \dots - A_p L^p) y_t = A(L) y_t = A_0 + \epsilon_t$$

Liczba parametrów wynosi:

$$A_0: N \times 1$$

$$A_p: N \times N$$

$$\Sigma: \frac{N(N+1)}{2}$$

Stacjonarność modelu VAR

Ważną cechą modelu VAR jest stacjonarność, którą można zdefiniować w kategoriach wygasania wpływu szoku ϵ_t na wartość wektora y_t :

$$\lim_{k \rightarrow \infty} \frac{\partial y_{t+k}}{\partial \epsilon_t} = 0.$$

W takim przypadku istnieje długookresowa wartość μ do której powraca proces y_t :

$$\mu = A(1)^{-1}A_0,$$

Tempo powrotu do równowagi jest dane przez pierwiastki równania:

$$|A(z)| = 0,$$

Dla stacjonarnego modelu VAR pierwiastki (których liczba wynosi $P \times N$) znajdują się poza kołem jednostkowym, tj.: $\{|z_i| > 1 : i = 1, 2, \dots, PN\}$

Stacjonarność modelu VAR

Stacjonarny model VAR ma reprezentację nieskończonej wektorowej średniej ruchomej (vector moving average, VMA):

$$y_t = A(L)^{-1}(A_0 + \epsilon_t) = \mu + \sum_{i=0}^{\infty} \Theta_i \epsilon_{t-i},$$

gdzie:

$$\Theta_i = \frac{\partial y_{t+i}}{\partial \epsilon_t}.$$

Stacjonarność modelu VAR - przykład VAR(1)

Dla modelu VAR(1) postaci $y_t = A_0 + Ay_t + \epsilon_t$:

$$\Theta_k = \frac{\partial y_{t+k}}{\partial \epsilon_t} = A^k.$$

Czyli model VAR(1) jest stacjonarny jeżeli:

$$\lim_{k \rightarrow \infty} A^k = 0.$$

Postać nieskończonej średniej ruchomej jest następująca:

$$y_t = (I - A)^{-1}A_0 + \sum_{i=0}^{\infty} (A)^i \epsilon_{t-i}.$$

Stacjonarność modelu VAR - przykład VAR(1) cd

Przy liczeniu granicy ciągu A^k przydatna jest dekompozycja Jordanowska:

$$A = V\Lambda V^{-1},$$

gdzie Λ i V są macierzami zawierającymi wartości własne oraz odpowiadające im wektory własne macierzy A :

$$\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$$

$$V = [v_1, v_2, \dots, v_n],$$

Zdefiniujmy $\tilde{y}_t = V^{-1}y_t$, $\tilde{A}_0 = V^{-1}A_0$ oraz $\tilde{\epsilon}_t = V^{-1}\epsilon_t$ i zapiszmy model VAR(1) jako:

$$\tilde{y}_t = \tilde{A}_0 + \Lambda\tilde{y}_{t-1} + \tilde{\epsilon}_t,$$

Macierz Λ jest diagonalna o elementach na przekątnej $\{\lambda_n : n = 1, 2, \dots, N\}$, zaś równanie dla n -tej składowej wektora \tilde{y}_t jest następujące:

$$\tilde{y}_{nt} = \tilde{\alpha}_{0n} + \lambda_n\tilde{y}_{n,t-1} + \tilde{\epsilon}_{nt}.$$

Zmienna \tilde{y}_{nt} jest stacjonarna, jeżeli $|\lambda_n| < 1$. Model VAR(1) jest stacjonarny jeżeli $|\lambda_n| < 1$ dla $n = 1, 2, \dots, N$.

Stacjonarność modelu VAR - przykład VAR(1) cd

Zauważmy, że:

$$A^k = V\Lambda^k V^{-1},$$

a zatem $\lim_{k \rightarrow \infty} \Lambda^k = 0$ implikuje, że $\lim_{k \rightarrow \infty} A^k = 0$.

Dla modelu VAR(1) wartości własne λ_n macierzy A są odwrotnością pierwiastków równania $|A(z)| = 0$, tj. $z_n = \frac{1}{\lambda_n}$

Wartości własne: $|A - \lambda I| = 0$

Pierwiastki równania: $|I - Az| = 0$

Stacjonarność modelu VAR(P)

Stacjonarność modelu VAR(P) można ustalić poprzez zapisanie go w postaci kanonicznej (tj. modelu VAR(1)):

$$\begin{bmatrix} y_t \\ y_{t-1} \\ y_{t-2} \\ \dots \\ y_{t-P+1} \end{bmatrix} = \begin{bmatrix} A_0 \\ 0 \\ 0 \\ \dots \\ 0 \end{bmatrix} + \begin{bmatrix} A_1 & A_2 & A_3 & \dots & A_P \\ I & 0 & 0 & \dots & 0 \\ 0 & I & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 0 \end{bmatrix} \begin{bmatrix} y_{t-1} \\ y_{t-2} \\ y_{t-3} \\ \dots \\ y_P \end{bmatrix} + \begin{bmatrix} \epsilon_t \\ 0 \\ 0 \\ \dots \\ 0 \end{bmatrix} .$$

oraz obliczenie $N \times P$ wartości własnych dla macierzy kanonicznej.

Estymacja modelu VAR

- Najczęściej stosowana metoda: MNK oddzielnie dla wszystkich równań
- Stosowanie MNK jest uzasadnione bo zmienne objaśniane są z góry ustalone i tym samym niezależne względem składnika losowego ϵ_t (brak problemu endogeniczności zmiennych objaśniających)

Estymacja modelu VAR

Niech $x_t = [1 \ y'_{t-1} \ \dots \ y'_{t-p}]'$ oraz $A = [A_0 \ A_1 \ \dots \ A_p]$, zaś model VAR będzie postaci:

$$y_t = Ax_t + \epsilon_t,$$

Estymator MNK dla parametrów n -tego równania modelu VAR:

$$y_{nt} = a_n x_t + \epsilon_{nt},$$

gdzie a_n jest n -tym wierszem macierzy A , wynosi:

$$\hat{a}_n = \left(\sum_{t=1}^T y_{nt} x_t' \right) \left(\sum_{t=1}^T x_t x_t' \right)^{-1}.$$

Estymator MNK dla całej macierzy parametrów:

$$\hat{A} = \left(\sum_{t=1}^T y_t x_t' \right) \left(\sum_{t=1}^T x_t x_t' \right)^{-1}.$$

Estymacja modelu VAR

Dla $\epsilon_t \sim N(0, \Sigma)$, tj. $y_t \sim N(Ax_t, \Sigma)$, wartość funkcji wiarygodności wynosi:

$$\mathcal{L}(A, \Sigma) = (2\pi)^{-TN/2} |\Sigma|^{-T/2} \prod_{t=1}^T \exp \left\{ -\frac{1}{2} (y_t - Ax_t)' \Sigma^{-1} (y_t - Ax_t) \right\}.$$

Estymator MNW macierzy A pokrywa się z estymatorem MNK, zaś estymator macierzy kowariancji składnika losowego wynosi:

$$\hat{\Sigma} = \frac{1}{T} \sum_{t=1}^T e_t^2,$$

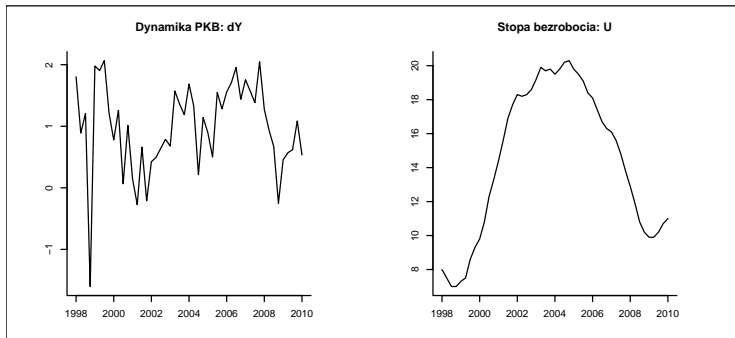
gdzie $e_t = y_t - \hat{A}x_t$.

Wartość funkcji wiarygodności w maksimum jest proporcjonalna do $|\hat{\Sigma}|$:

$$\mathcal{L}(\hat{A}, \hat{\Sigma}) = (2\pi)^{-TN/2} |\hat{\Sigma}|^{-T/2} \exp \left\{ -\frac{TN}{2} \right\}.$$

Estymacja modelu VAR - Przykład

Model VAR(2) dla tempa wzrostu PKB oraz stopy bezrobocia w Polsce



Estymacja modelu VAR - Przykład

Odwrotność modulu pierwiastków równania charakterystycznego:

0.916 0.916 0.554 0.386

Oszacowania równania tempa wzrostu PKB (dY):

$dY = dY.11 + U.11 + dY.12 + U.12 + \text{const}$

	Estimate	Std. Error	t value	Pr(> t)
dY.11	0.1718	0.1525	1.13	0.27
U.11	-0.0826	0.1672	-0.49	0.62
dY.12	0.2097	0.1521	1.38	0.18
U.12	0.1036	0.1656	0.63	0.53
const	0.2877	0.3981	0.72	0.47

Estymacja modelu VAR - Przykład

Oszacowania równania bezrobocia (U):

$$U = dY.l1 + U.l1 + dY.l2 + U.l2 + \text{const}$$

	Estimate	Std. Error	t value	Pr(> t)	
dY.l1	-0.0648	0.0746	-0.87	0.390	
U.l1	1.8056	0.0818	22.08	< 2e-16	***
dY.l2	0.0412	0.0744	0.55	0.582	
U.l2	-0.8340	0.0810	-10.30	4.6e-13	***
const	0.4645	0.1947	2.39	0.022	*

Macierz korelacji dla reszt

	dY	U
dY	1.000	-0.162
U	-0.162	1.000

Estymacja modelu VAR - Przykład

Postać VMA(∞)

	Theta0		Theta1		Theta2	
dY	1.00	0.00	0.17	-0.08	0.24	-0.06
U	0.00	1.00	-0.06	1.80	-0.09	2.43

	Theta3		Theta4		Theta100	
dY	0.08	-0.04	0.06	-0.01	...	0.00 0.00
U	-0.11	2.89	-0.12	3.18	...	0.00 0.00

Dobór opóźnienia modelu VAR

1 Kryteria informacyjne:

$$AIC = \ln(|\hat{\Sigma}|) + 2\frac{K}{T}$$

$$BIC = \ln(|\hat{\Sigma}|) + \frac{K}{T} \ln T$$

$$HQIC = \ln(|\hat{\Sigma}|) + 2\frac{K}{T} \ln(\ln T)$$

gdzie $K = N(1 + NP)$ określa liczbę parametrów.

2 Testy na autokorelacje oraz istotność opóźnień

Dobór opóźnienia modelu VAR

Wartosci kryteriow informacyjnych

	P = 1	P = 2	P = 3	P = 4	Wybor
AIC(n)	-1.815	-2.976	-3.017	-2.947	P = 3
HQ(n)	-1.725	-2.827	-2.807	-2.677	P = 2
SC(n)	-1.574	-2.574	-2.455	-2.224	P = 2

Test ilorazu wiarygodności na istotność opóźnień

Zespół hipotez:

$$H_0 : A_P = 0$$

$$H_1 : A_P \neq 0.$$

Statystyka testu ilorazu funkcji wiarygodności:

$$LR = T(\ln |\hat{\Sigma}_r| - \ln |\hat{\Sigma}_u|),$$

ma asymptotyczny rozkład $\chi^2(m)$, gdzie $m = N^2$ jest równe liczbie restrykcji zerowych.

Testy na autokorelację reszt

① Autokorelacja:

- estymator MNK jest obciążony
- oznaka złej specyfikacji modelu VAR (zbyt niskie opóźnienie)

② Podstawowe testy

- Ljung-Box
- Breusch-Godfrey

Test Ljung-Boxa

Zespół hipotez:

$$H_0 : \forall_{1 \leq j \leq J} \Gamma_j = 0$$

$$H_1 : \exists_{1 \leq j \leq J} \Gamma_j \neq 0,$$

gdzie $\Gamma_j = Cov(\epsilon_t, \epsilon_{t-j})$ jest macierzą autokowariancji rzędu j dla składnika losowego modelu VAR.

Statystyka:

$$LB = T^2 \sum_{j=1}^J \frac{1}{T-j} tr(\hat{\Gamma}'_j \hat{\Gamma}_0^{-1} \hat{\Gamma}_j \hat{\Gamma}_0^{-1}) \quad (1)$$

gdzie $\hat{\Gamma}_s = \frac{1}{T} \sum_{t=s+1}^T y_t y'_{t-s}$ przy prawdziwości H_0 ma rozkład χ^2 o $N^2 \times (J - P)$ stopniach swobody.

Test Ljung-Boxa - Przykład

Dla modelu VAR(2)

Wyniki testu Ljung-Boxa

J	stat.	df	prawd.
3	12.1	4	0.017
4	14.9	8	0.061
5	16.7	12	0.156
6	23.2	16	0.107
7	24.6	20	0.218
8	30.1	24	0.183

Test Breuscha-Godfrey

Test Breuscha-Godfrey'a = wielowymiarowy test mnożników Lagrange'a.

Dla regresji postaci:

$$e_t = F_0 + F_1 y_{t-1} + \dots + F_p y_{t-p} + G_1 e_{t-1} + \dots + G_J e_{t-J} + \nu_t,$$

weryfikowany jest zespół hipotez:

$$H_0 : \forall_{1 \leq j \leq J} G_j = 0$$

$$H_1 : \exists_{1 \leq j \leq J} G_j \neq 0.$$

Statystyka testu:

$$BG = T(N - \text{tr}(\hat{\Omega}_r^{-1} \hat{\Omega}_u)),$$

gdzie $\hat{\Omega}_r$ i $\hat{\Omega}_u$ oznaczają oszacowanie macierzy kowariancji składnika losowego dla modelu z restrykcjami oraz bez restrykcji, przy prawdziwości hipotezy zerowej ma rozkład χ^2 o JN^2 stopniach swobody.

Test Breusch-Godfrey'a - Przykład

Dla modelu VAR(2)

Breusch-Godfrey'a

J	stat.	df1	prawd.
1	8.09	4	0.088
2	10.10	8	0.258
3	18.57	12	0.099
4	20.53	16	0.197

Normalność rozkładu składnika losowego

Zespół hipotez testu Dornika-Hansena (wielowymiarowe uogólnienie testu Jarque-Bera):

$$H_0 : \epsilon_t \sim N(0, \Sigma)$$

$$H_1 : \epsilon_t \not\sim N(0, \Sigma)$$

Dla standaryzowanych reszty modelu VAR: $u_t = \hat{\Sigma}^{-1/2} e_t$, liczone są skośność s_n i kurtoza k_n dla $n = 1, 2, \dots, N$. Statystka testu:

$$DH = \frac{T}{6} \sum_{n=1}^N s_n^2 + \frac{T}{24} \sum_{n=1}^N (k_n - 3)^2$$

przy prawdziwości H_0 ma rozkład χ^2 o $2N$ stopniach swobody.

Stabilność modelu VAR

Metody testowania stabilności modelu VAR:

- 1 rekursywna estymacja parametrów
- 2 formalne testy na zmianę postaci strukturalnej, np. wielowymiarowe testy Chowa
- 3 analizie błędów prognozy *ex-post* o horyzoncie jednego okresu

Stabilność modelu VAR

Etapy testu Chowa (typu *break-point*):

- 1 ustal obserwację T_1 zmiany strukturalnej modelu
- 2 oszacuj model VAR na podstawie dwóch podprób oraz pełnej próby:
 - model 1:** $t \in \{1, 2, \dots, T_1\}$, reszty $e_{t(1)}$, macierz $\hat{\Sigma}_{(1)} = T_1^{-1} \sum_{t=1}^{T_1} e_{(1)} e'_{(1)t}$
 - model 2:** $t \in \{T_1 + 1, \dots, T\}$, reszty $e_{t(2)}$, macierz $\hat{\Sigma}_{(2)} = T_2^{-1} \sum_{t=1}^{T_2} e_{(2)t} e'_{(2)}$
 - model 3:** $t \in \{1, 2, \dots, T\}$, reszty e_t , macierz $\hat{\Sigma} = T^{-1} \sum_{t=1}^T e_t e'_t$
- 3 oblicz statystykę:

$$LR_{BP} = T \ln |\hat{\Sigma}| - (T_1 \ln |\hat{\Sigma}_{(1)}| + T_2 \ln |\hat{\Sigma}_{(2)}|)$$

która przy prawdziwości H_0 o stabilności modelu ma rozkład χ^2 o $N(PN + 1) + \frac{(N+1)N}{2}$ stopniach swobody (całkowita liczba parametrów modelu VAR, wliczając parametry macierzy Σ).

Stabilność modelu VAR

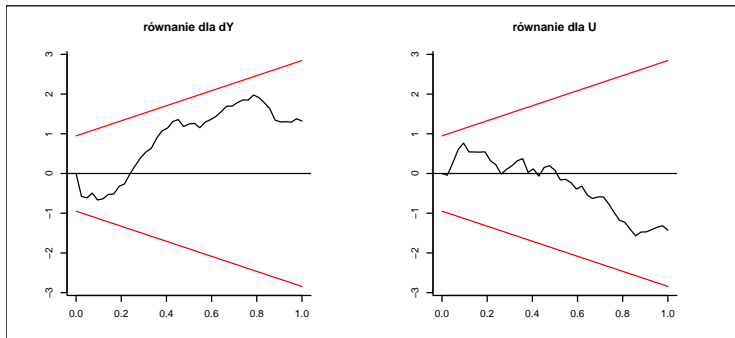
Procedura dla testowania stabilności na podstawie rekursywnych błędów prognozy o horyzoncie jednego okresu:

- 1 Ustalić moment początkowy liczenia rekursywnych reszt: T_1
- 2 Oszacować parametry $T - T_1$ modeli VAR na podstawie obserwacji $t = 1, 2, \dots, T^*$, gdzie $T^* = T_1, T_1 + 1, \dots, T - 1$
- 3 Obliczyć prognozę punktową na okres $T^* + 1$
- 4 Obliczyć błąd prognozy na jeden okres do przodu oraz średni błąd prognozy *ex-ante* (e_{iT}^P oraz S_{nT}^P)
- 5 Skonstruować szereg oraz jego przedział ufności:

$$CUMSUM_{nT^\diamond} = \sum_{\tau=T_1+1}^{T^\diamond} \frac{e_{n\tau}^P}{S_{n\tau}^P}$$

- 6 Jeżeli szereg znajduje się w przedziale ufności: brak podstaw do odrzucenia hipotezy o stabilności modelu

Stabilność modelu VAR



Prognozowanie z modelem VAR

Dla modelu VAR(P):

$$y_t = A_0 + A_1 y_{t-1} + \dots + A_P y_{t-P} + \epsilon_t.$$

Prognoza punktowa:

$$y_{T+1}^f = E(y_{T+1}) = A_0 + A_1 y_T + \dots + A_P y_{T+1-P}$$

$$y_{T+2}^f = A_0 + A_1 y_{T+1}^f + \dots + A_P y_{T+2-P}$$

$$y_{T+3}^f = A_0 + A_1 y_{T+2}^f + \dots + A_P y_{T+3-P}$$

...

$$y_{T+k}^f = A_0 + A_1 y_{T+k-1}^f + \dots + A_P y_{T+k-P}^f \text{ dla } k > P$$

Prognozowanie z modelem VAR

Postać nieskończonej średniej ruchomej:

$$y_t = \mu + \sum_{i=0}^{\infty} \Theta_i \epsilon_{t-i}$$

Błąd prognozy wynikający z występowania składnika losowego wynosi:

$$y_{T+1} - y_{T+1}^f = \epsilon_{T+1}$$

$$y_{T+2} - y_{T+2}^f = \epsilon_{T+2} + \Theta_1 \epsilon_{T+1}$$

⋮

$$y_{T+k} - y_{T+k}^f = \sum_{i=0}^{k-1} \Theta_i \epsilon_{T+k-i}$$

Wariancja prognozy na k okresów:

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

Prognoza przedziałowa dla n -tej zmiennej:

$$P(y_{n,T+k} \in [y_{n,T+k}^f - c_\alpha \sqrt{\sigma_{k(nn)}}; y_{n,T+k}^f + c_\alpha \sqrt{\Sigma_{k(nn)}}]) = 1 - \alpha,$$

gdzie c_α jest wartością krytyczną rozkładu normalnego dla poziomu istotności 5%.

Prognozowanie z modelem VAR

