

# Ekonometryczne modele nieliniowe

## Wykład 6

Modele progowe c.d.

# Literatura

## Testing for two-regime threshold cointegration in vector error-correction models

Bruce E. Hansen<sup>a, \*</sup>, Byeongseon Seo<sup>b</sup>

*Journal of Econometrics* 110 (2002) 293–318

Testing and Modeling Threshold Autoregressive Processes

Author(s): Ruey S. Tsay

Source: *Journal of the American Statistical Association*, Vol. 84, No. 405 (Mar., 1989), pp. 231-240

Testing and Modeling Multivariate Threshold Models

Author(s): Ruey S. Tsay

Source: *Journal of the American Statistical Association*, Vol. 93, No. 443 (Sep., 1998), pp. 1188-1202

# Test Tsaya (1989)

- Model TAR z wieloma reżimami:

$$Y_t = \Phi_0^{(j)} + \sum_{i=1}^p \Phi_i^{(j)} Y_{t-i} + a_t^{(j)},$$

$$r_{j-1} \leq Y_{t-d} < r_j,$$

- Po posortowaniu obserwacji względem zmiennej progowej (dla 2 reżimów):

$$Y_{\pi_i+d} = \Phi_0^{(1)} + \sum_{v=1}^p \Phi_v^{(1)} Y_{\pi_i+d-v} + a_{\pi_i+d}^{(1)} \quad \text{if } i \leq s$$

$$= \Phi_0^{(2)} + \sum_{v=1}^p \Phi_v^{(2)} Y_{\pi_i+d-v} + a_{\pi_i+d}^{(2)} \quad \text{if } i > s,$$

where  $s$  satisfies  $Y_{\pi_s} < r_1 \leq Y_{\pi_{s+1}}$

# Test Tsaya (1989) c.d.

- Rekursywna estymacja parametrów (obserwacja nr  $m+1$ ):

$$\hat{\beta}_{m+1} = \hat{\beta}_m + K_{m+1}[Y_{d+\pi_{m+1}} - x'_{m+1}\hat{\beta}_m],$$

$$D_{m+1} = 1.0 + x'_{m+1}P_m x_{m+1},$$

$$P_m = (X_m' X_m)^{-1}$$

$$K_{m+1} = P_m x_{m+1} / D_{m+1},$$

$$P_{m+1} = \left( I - P_m \frac{x_{m+1} x'_{m+1}}{D_{m+1}} \right) P_m$$

- ...i błędów prognozy

$$\hat{a}_{d+\pi_{m+1}} = Y_{d+\pi_{m+1}} - x'_{m+1}\hat{\beta}_m$$

$$\hat{e}_{d+\pi_{m+1}} = \hat{a}_{d+\pi_{m+1}} / \sqrt{D_{m+1}}.$$

# Test Tsaya (1989) c.d.

- Oszacowanie dodatkowej regresji:

$$\hat{e}_{\pi_i+d} = \omega_0 + \sum_{v=1}^p \omega_v Y_{\pi_i+d-v} + \varepsilon_{\pi_i+d},$$

- H0: Model AR (parametry w regresji = 0)
- H1: Model TAR

$$\hat{F}(p, d) = \frac{(\sum \hat{e}_t^2 - \sum \hat{\varepsilon}_t^2)/(p + 1)}{\sum \hat{\varepsilon}_t^2/(n - d - b - p - h)} \sim F$$

- $p+1$  – liczba parametrów w modelu AR
- $n-d-b-p-h$  – liczba obserwacji w dodatkowej regresji minus liczba parametrów

# Modele TVAR, TVECM

- Model liniowy (VECM)

$$\Delta x_t = A' X_{t-1}(\beta) + u_t,$$

$$w_t(\beta) = \beta' x_t$$

$$\Sigma = E(u_t u_t')$$

$$\tilde{u}_t = \Delta x_t - \tilde{A}' X_{t-1}(\tilde{\beta})$$

$$X_{t-1}(\beta) = \begin{pmatrix} 1 \\ w_{t-1}(\beta) \\ \Delta x_{t-1} \\ \Delta x_{t-2} \\ \vdots \\ \Delta x_{t-l} \end{pmatrix}$$

- Model progowy (TVECM)

$$\Delta x_t = \begin{cases} A_1' X_{t-1}(\beta) + u_t & \text{if } w_{t-1}(\beta) \leq \gamma, \\ A_2' X_{t-1}(\beta) + u_t & \text{if } w_{t-1}(\beta) > \gamma, \end{cases}$$

$$\Delta x_t = A_1' X_{t-1}(\beta) d_{1t}(\beta, \gamma) + A_2' X_{t-1}(\beta) d_{2t}(\beta, \gamma) + u_t,$$

$$d_{1t}(\beta, \gamma) = 1(w_{t-1}(\beta) \leq \gamma),$$

$$d_{2t}(\beta, \gamma) = 1(w_{t-1}(\beta) > \gamma)$$

# Estymacja TVECM

- Maksymalizujemy funkcję wiarygodności

$$\mathcal{L}_n(A_1, A_2, \Sigma, \beta, \gamma) = -\frac{n}{2} \log|\Sigma| - \frac{1}{2} \sum_{t=1}^n u_t(A_1, A_2, \beta, \gamma)' \Sigma^{-1} u_t(A_1, A_2, \beta, \gamma),$$

$$u_t(A_1, A_2, \beta, \gamma) = \Delta x_t - A_1' X_{t-1}(\beta) d_{1t}(\beta, \gamma) - A_2' X_{t-1}(\beta) d_{2t}(\beta, \gamma).$$

- Załóżmy, że wektor kointegrujący i parametr progowy są znane...

$$\hat{A}_1(\beta, \gamma) = \left( \sum_{t=1}^n X_{t-1}(\beta) X_{t-1}(\beta)' d_{1t}(\beta, \gamma) \right)^{-1} \left( \sum_{t=1}^n X_{t-1}(\beta) \Delta x_t' d_{1t}(\beta, \gamma) \right)$$

$$\hat{A}_2(\beta, \gamma) = \left( \sum_{t=1}^n X_{t-1}(\beta) X_{t-1}(\beta)' d_{2t}(\beta, \gamma) \right)^{-1} \left( \sum_{t=1}^n X_{t-1}(\beta) \Delta x_t' d_{2t}(\beta, \gamma) \right)$$

$$\hat{u}_t(\beta, \gamma) = u_t(\hat{A}_1(\beta, \gamma), \hat{A}_2(\beta, \gamma), \beta, \gamma) \quad \hat{\Sigma}(\beta, \gamma) = \frac{1}{n} \sum_{t=1}^n \hat{u}_t(\beta, \gamma) \hat{u}_t(\beta, \gamma)'$$

# Estymacja TVECM

- Szukamy wartości parametru progowego i wektora kointegrującego

– „concentrated likelihood function”:

$$\begin{aligned}\mathcal{L}_n(\beta, \gamma) &= \mathcal{L}_n(\hat{A}_1(\beta, \gamma), \hat{A}_2(\beta, \gamma), \hat{\Sigma}(\beta, \gamma), \beta, \gamma) \\ &= -\frac{n}{2} \log |\hat{\Sigma}(\beta, \gamma)| - \frac{np}{2}.\end{aligned}$$

– „grid search”

$$(\beta, \gamma)$$



# Estymacja TVECM

298

*B.E. Hansen, B. Seo / Journal of Econometrics 110 (2002) 293–318*

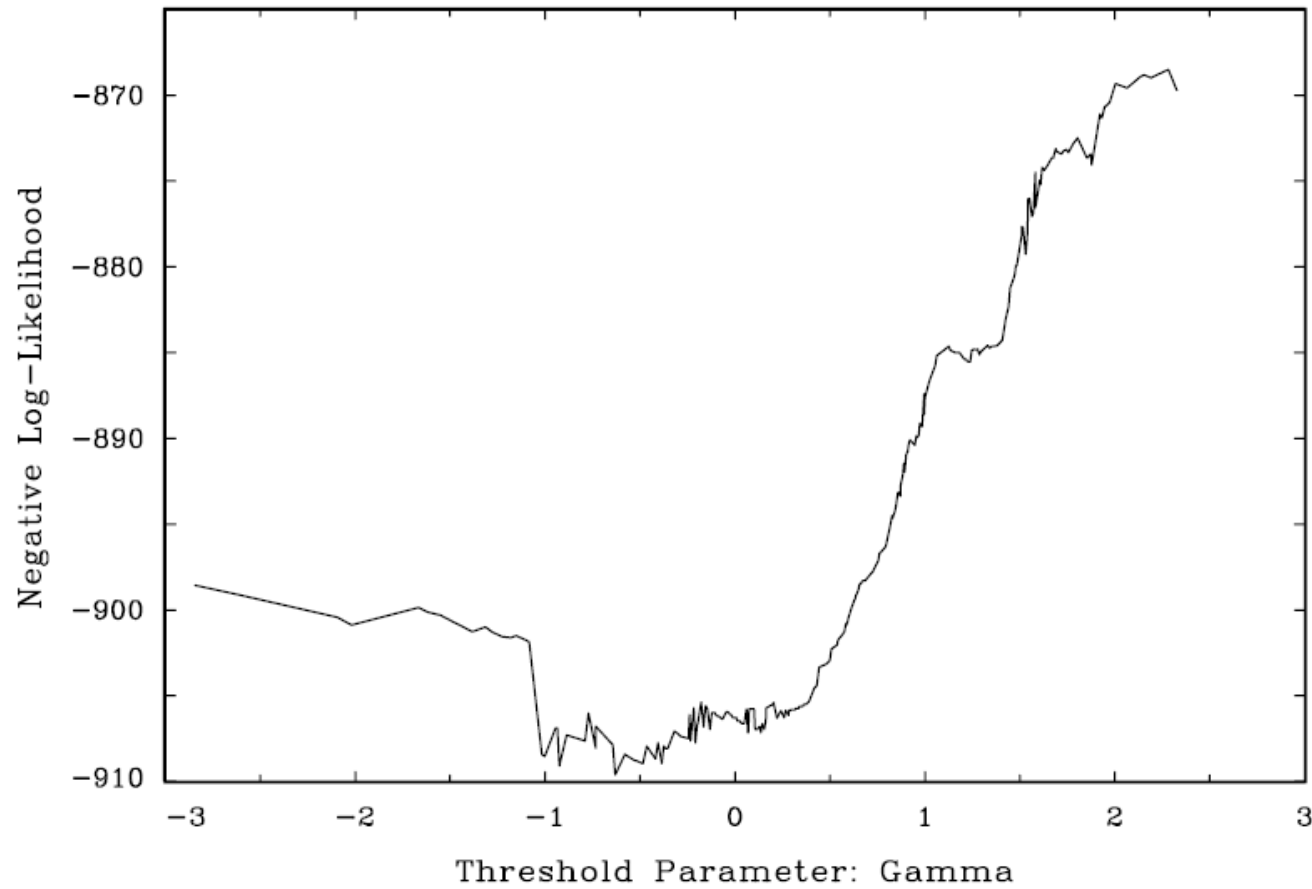


Fig. 1. Concentrated negative log likelihood.

# Procedura estymacji

- Hansen, Seo (2002):

1. Form a grid on  $[\gamma_L, \gamma_U]$  and  $[\beta_L, \beta_U]$  based on the linear estimate  $\tilde{\beta}$  as described above.
2. For each value of  $(\beta, \gamma)$  on this grid, calculate  $\hat{A}_1(\beta, \gamma)$ ,  $\hat{A}_2(\beta, \gamma)$ , and  $\hat{\Sigma}(\beta, \gamma)$  as defined in (4), (5), and (6), respectively.
3. Find  $(\hat{\beta}, \hat{\gamma})$  as the values of  $(\beta, \gamma)$  on this grid which yields the lowest value of  $\log|\hat{\Sigma}(\beta, \gamma)|$ .
4. Set  $\hat{\Sigma} = \hat{\Sigma}(\hat{\beta}, \hat{\gamma})$ ,  $\hat{A}_1 = \hat{A}_1(\hat{\beta}, \hat{\gamma})$ ,  $\hat{A}_2 = \hat{A}_2(\hat{\beta}, \hat{\gamma})$ , and  $\hat{u}_t = \hat{u}_t(\hat{\beta}, \hat{\gamma})$ .

- brak teorii dla zgodności estymatorów i asymptotycznej normalności

# Testowanie: TVECM czy VECM

- H0: VECM
- H1: TVECM
- Test LM

$$\begin{aligned} \text{LM}(\beta, \gamma) = & \text{vec}(\hat{A}_1(\beta, \gamma) - \hat{A}_2(\beta, \gamma))' (\hat{V}_1(\beta, \gamma) + \hat{V}_2(\beta, \gamma))^{-1} \\ & \times \text{vec}(\hat{A}_1(\beta, \gamma) - \hat{A}_2(\beta, \gamma)). \end{aligned}$$

# Testowanie...

- techniczne wyprowadzenia wyrażeń w LM

– Macierze wariancji dla:  $\text{vec } \hat{A}_1(\beta, \gamma)$   
 $\text{vec } \hat{A}_2(\beta, \gamma)$

$$\hat{V}_1(\beta, \gamma) = M_1(\beta, \gamma)^{-1} \Omega_1(\beta, \gamma) M_1(\beta, \gamma)^{-1}$$

$$\hat{V}_2(\beta, \gamma) = M_2(\beta, \gamma)^{-1} \Omega_2(\beta, \gamma) M_2(\beta, \gamma)^{-1}$$

$$\Omega_1(\beta, \gamma) = \xi_1(\beta, \gamma)' \xi_1(\beta, \gamma),$$

$$\Omega_2(\beta, \gamma) = \xi_2(\beta, \gamma)' \xi_2(\beta, \gamma).$$

$$M_1(\beta, \gamma) = I_p \otimes X_1(\beta, \gamma)' X_1(\beta, \gamma),$$

$$M_2(\beta, \gamma) = I_p \otimes X_2(\beta, \gamma)' X_2(\beta, \gamma)$$

$\xi_2(\beta, \gamma)$  macierz z  
ustawionych na  
sobie wektorów  
 $\tilde{u}_t \otimes X_{t-1}(\beta) d_{2t}(\beta, \gamma)$

... podobnie jak  $X_2(\beta, \gamma)$

z  $X_{t-1}(\beta) d_{2t}(\beta, \gamma)$

# Testowanie...

$$\text{SupLM} = \sup_{\gamma_L \leq \gamma \leq \gamma_U} \text{LM}(\tilde{\beta}, \gamma).$$

- Procedura „fixed regressor bootstrap”

$$y_{bt} = \tilde{u}_t e_{bt} \quad e \text{ z rozkładu } N(0,1)$$

- wektor kointegrujący i inne zmienne objaśniające – stałe wartości w symulacjach
  - Test odporny na heteroskedastyczność nieznanego rodzaju
- Procedura „residual bootstrap”
    - Generowanie reszt i  $X$  (z modelu liniowego)

# Test Tsaya (1998)

- Model VAR  $z_t = AX_t + \varepsilon_t,$
- Sortowanie obserwacji według wartości zmiennej progowej ( $d$  – opóźnienie zmiennej progowej)

$$z_{t(i)+d} = AX_{t(i)+d} + \varepsilon_{t(i)+d}, \quad i = 1, \dots, n.$$

- Rekursywne błędy predykcji („predictive residuals”)

$$\hat{\varepsilon}_{t(l+1)+d} = z_{t(l+1)+d} - \hat{A}_l X_{t(l+1)+d},$$

$$\hat{\eta}_{t(l+1)+d} = \frac{\hat{\varepsilon}_{t(l+1)+d}}{[1 + (X_{t(l+1)+d})' V_l (X_{t(l+1)+d})]^{0.5}},$$

$$V_l = [\sum_{i=1}^l (X_{t(i)+d})(X_{t(i)+d})']^{-1}$$

# Test Tsaya c.d.

- Regresja błędów predykcji na X

$$\hat{\eta}_{t(l+1)+d} = \Psi X_{t(l+1)+d} + v_{t(l+1)+d}, \quad l = l_0, \dots, n-1$$

$$S_0 = \frac{1}{n - l_0} \sum_{l=l_0}^{n-1} (\hat{\eta}_{t(l+1)+d})(\hat{\eta}_{t(l+1)+d})'$$

$$S_1 = \frac{1}{n - l_0} \sum_{l=l_0}^{n-1} (\hat{v}_{t(l+1)+d})(\hat{v}_{t(l+1)+d})'$$

- Statystyka

$$C(d) = [n - l_0 - (2m + 1)][\ln |S_0| - \ln |S_1|],$$

ma rozkład chi-kwadrat( $w(w^*m+1)$ ) przy  $H_0$

–  $w$  - liczba równań,  $m$  – liczba opóźnień w VAR