

Ekonometryczne modele nieliniowe

Wykład 7

Modele łagodnego przejścia,
sieci neuronowe w ekonometrii

Literatura

- Timo Teräsvirta, *Specification, Estimation, and Evaluation of Smooth Transition Autoregressive Models*, Journal of the American Statistical Association, Vol. 89, No. 425 (Mar., 1994), pp. 208-218
- Dick van Dijk, Timo Teräsvirta and Philip Hans Franses, *Smooth transition autoregressive models - A survey of recent developments*, Econometric Reviews, 2002, vol. 21, issue 1, pp. 1-47.

Literatura

- Marcelo C. Medeiros & Timo Terasvirta, 2001, *Statistical methods for modelling neural networks*, Textos para discussão 445, Department of Economics PUC-Rio (Brazil).
- Timo Teräsvirta, Dick van Dijk, Marcelo C. Medeiros, *Linear models, smooth transition autoregressions, and neural networks for forecasting macroeconomic time series: A re-examination*, International Journal of Forecasting, Volume 21, Issue 4, 2005, pp. 755-774.

Literatura

Książka:

- P.H. Frances, D. van Dijk, *Non-linear time series models in empirical finance*, Cambridge University Press, Cambridge, UK.

Przejs̄cie z modelu progowego...

- Model z dwoma reŹimami

$$y_t = (\alpha_0 + \alpha_1 x_{1,t} + \dots + \alpha_k x_{k,t})I(z_t \leq \gamma) + \\ + (\beta_0 + \beta_1 x_{1,t} + \dots + \beta_k x_{k,t})I(z_t > \gamma) + \varepsilon_t$$

- ...inaczej zapisany

$$y_t = (\alpha_0 + \alpha_1 x_{1,t} + \dots + \alpha_k x_{k,t}) + \\ + [(\beta_0 - \alpha_0) + (\beta_1 - \alpha_1)x_{1,t} + \dots + (\beta_k - \alpha_k)x_{k,t}]I(z_t > \gamma) + \varepsilon_t$$

$$y_t = \alpha' \mathbf{x}_t + (\boldsymbol{\beta} - \boldsymbol{\alpha})' \mathbf{x}_t I(z_t > \gamma) + \varepsilon_t$$

Model STR

- Smooth Transition (Auto-)Regression

$$y_t = \phi_1' x_t [1 - G(z_t; \gamma, c)] + \phi_2' x_t G(z_t; \gamma, c) + \varepsilon_t \quad \varepsilon_t \sim i.i.d.(0, \sigma^2)$$

$$y_t = \phi_1' x_t + (\phi_2 - \phi_1)' x_t G(z_t; \gamma, c) + \varepsilon_t$$

Funkcja przejścia

- G – funkcja logistyczna

$$G(z_t; \gamma, c) = \{1 + \exp[-\gamma(z_t - c_k)]\}^{-1}$$

- gdy $\gamma = 0$, to model liniowy
- gdy $\gamma \rightarrow \infty$, to model progowy

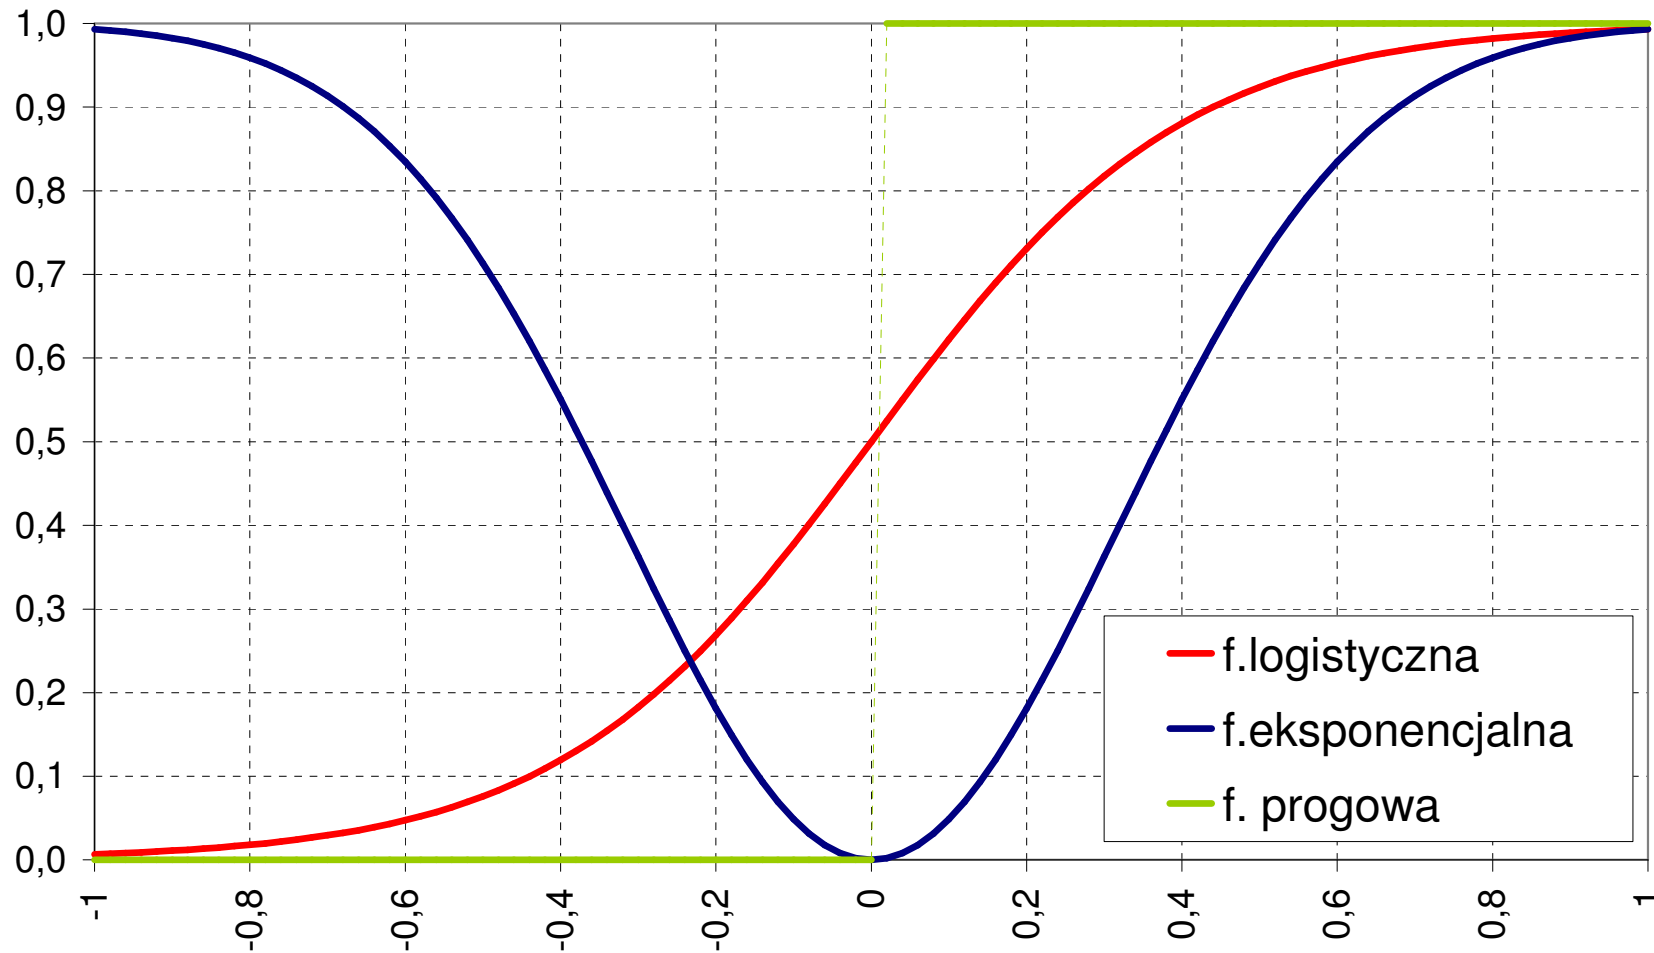
Funkcja przejścia

- G – funkcja eksponencjalna

$$G(z_t; \gamma, c) = 1 - \exp(-\gamma(z_t - c)^2)$$

- gdy $\gamma = 0$, to model liniowy
- gdy $\gamma \rightarrow \infty$, to model liniowy

Funkcja przejścia



$$\gamma = 5 \quad c = 0$$

Estymacja

Teräsvirta (1994) „*conditional least squares*”:

$$y_t = g(\mathbf{a}, F_{t-1}) + \varepsilon_t \quad F_t = \{y_t, y_{t-1}, \dots, y_1\}$$

$$E(\varepsilon_t | F_{t-1}) = 0$$

$$\text{var}(\varepsilon_t | F_{t-1}) = \sigma^2$$

$$Q_T(\mathbf{a}) = \sum_{t=1}^T [y_t - g(\mathbf{a}, F_{t-1})]^2$$

Estymacja

- Estymator zgodny i asymptotycznie normalny
- Problemy techniczne metody gradientowej:
 - ESTR: γ silnie skorelowane z parametrami ϕ_2 (bez stałej)
 1. standardyzuj wykładnik w G przez podzielenie go przez wariancję y
 2. ustal startową wartość γ , np. $\gamma \approx 1$
 3. jeśli algorytm gradientowy nie zbiega, to „grid search” - γ

Estymacja

- Estymator zgodny i asymptotycznie normalny
- Problemy techniczne metody gradientowej:
 - LSTR: γ, c do oszacowania i gdy $\gamma \rightarrow \infty$, to model TR (duży błąd oszacowania γ)
 1. Skaluj parametry startowe (zmniejsz γ i zwiększ c [??]), podziel wykładnik w G przez odchylenie stand. y
 2. Jeśli algorytm gradientowy nie zbiega, to „grid search”- c

Estymacja

- Możliwa estymacja MNK pod warunkiem, że znane γ, c

$$\hat{\phi}(\gamma, c) = \left(\sum_{t=1}^T x_t(\gamma, c) x_t(\gamma, c)' \right)^{-1} \left(\sum_{t=1}^T x_t(\gamma, c) y_t \right)$$

$$x_t(\gamma, c) = (x_t'(1 - G(s_t; \gamma, c)), x_t'G(s_t; \gamma, c))'$$

Specyfikacja

- wybór modelu liniowego (np. AR(p))
- testowanie liniowości modelu (przeciw STR) dla różnych zmiennych przejścia (*transition variables*)
+ wybór optymalnej zmiennej przejścia
- wybór między LSTR i ESTR

Testowanie modelu STR

- Hipotezy $H_0 : \phi_1 = \phi_2$
 $H_1 : \phi_1 \neq \phi_2$
- Problem z parametrami γ, c nieidentyfikowalnymi przy $H_0 \rightarrow$ niestandardowe rozkłady statystyk testowych
- Hipotezy $H_0 : \gamma = 0$
 $H_1 : \gamma \neq 0$
- Problem z parametrami c, ϕ_1, ϕ_2 nieidentyfikowalnymi przy $H_0 \rightarrow$ niestandardowe rozkłady statystyk testowych

Testowanie modelu STR

- Luukkonen, Saikkonen, Teräsvirta (1988):
 - Rozwinięcie modelu STR w szereg Taylora wokół $\gamma = 0$
 - Zastosowanie testu LM

Testowanie LSTR

- Szereg Taylora 1. rzędu:

$$y_t = \phi_1' x_t + (\phi_2 - \phi_1)' x_t G(z_t; \gamma, c) + \varepsilon_t$$

$$y_t = \beta_0' x_t + \beta_1'(x_t z_t) + e_t$$

$$e_t = \varepsilon_t + (\phi_2 - \phi_1)' x_t R_1(z_t; \gamma, c)$$

- Przy H_0

$$e_t = \varepsilon_t \quad R_1(z_t; \gamma, c) = 0$$

...dlatego test LM

Testowanie LSTR c.d.

- Testowanie $\phi_1 = \phi_2$ ($\gamma = 0$) równoważne z
 $H_0 : \beta_1 = 0$
 $H_1 : \beta_1 \neq 0$
- Standardowy test LM (szczegóły później)
 - Nazywany tutaj: „*LM-type test*”
- Problem: kiedy $z_t = x_{i,t}$, trzeba usunąć $\beta_{1,0} z_t$ z „testowego” modelu regresji (współliniowość)
 - test nie nadaje się do testowania zmian stałej

Testowanie LSTR c.d.

- Rozwiązanie: szereg Taylora 3. rzędu

$$y_t = \beta'_0 x_t + \beta'_1(x_t z_t) + \beta'_2(x_t z_t^2) + \beta'_3(x_t z_t^3) + e_t$$

bez $\beta_{1,0} z_t$, $\beta_{2,0} z_t^2$, $\beta_{3,0} z_t^3$

lub uproszczona wersja:

$$y_t = \beta'_0 x_t + \beta'_1(x_t z_t) + \beta_2 z_t^2 + \beta_3 z_t^3 + e_t$$

- Test LM $H_0 : \beta_1 = \beta_2 = \beta_3 = 0$

Testowanie ESTR

- Rozwinięcie ESTR w szereg Taylora 1. rzędu:

$$y_t = \beta'_0 x_t + \beta'_1(x_t z_t) + \beta'_2(x_t z_t^2) + e_t$$

$$e_t = \varepsilon_t + (\phi_2 - \phi_1)' x_t R_1(z_t; \gamma, c)$$

- lub uwzględniając 2 punkty przegięcia w ESTR – rozwinięcie 2. rzędu:

$$y_t = \beta'_0 x_t + \beta'_1(x_t z_t) + \beta'_2(x_t z_t^2) + \beta'_3(x_t z_t^3) + \beta'_4(x_t z_t^4) + e_t$$

Testowanie ESTR c.d.

- Test typu LM

$$H_0 : \beta_1 = \beta_2 = (\beta_3 = \beta_4) = 0$$

Obliczanie statystyk LM

- Oszacuj model przy założeniu H_0

$$y_t = \hat{\beta}'_0 x_t + \hat{e}_t \quad RSS_0 = \sum_{t=1}^T \hat{e}_t^2$$

- Oszacuj „testową” regresję: $y \leftarrow x, xz$

$$RSS_1 = \sum_{t=1}^T \tilde{e}_t^2$$

- Statystyka: $LM = \frac{T(RSS_0 - RSS_1)}{RSS_0} \sim \chi^2_{(l.\text{dodatkowych parametrow})}$

lub w małych próbach:

$$LM_F = \frac{(RSS_0 - RSS_1)/(l.\text{dodatkowych parametrow})}{RSS_1/(T - l.\text{wszystkich parametrow})} \sim F$$

Autokorelacja składnika losowego

- Niech $F(x_t; \theta) = \phi_1' x_t [1 - G(z_t; \gamma, c)] + \phi_2' x_t G(z_t; \gamma, c)$
- Oszacuj model STR i oblicz reszty $\hat{\varepsilon}_t$
- Oblicz $\nabla F(x_t; \hat{\theta}) = \partial F(x_t; \hat{\theta}) / \partial \theta$ gdzie
$$\theta = [\phi_1 \quad \phi_2 \quad \gamma \quad c]'$$
- Oszacuj model liniowy i oblicz R-kwadrat:
$$\hat{\varepsilon}_t \leftarrow \nabla F(x_t; \hat{\theta}), \hat{\varepsilon}_{t-1}, \hat{\varepsilon}_{t-2}, \dots, \hat{\varepsilon}_{t-q}$$
- Rozszerzenie testu Godfrey'a (1979):
 $H_0: \text{brak autokorelacji} \quad LM = TR^2 \overset{a}{\sim} \chi_q^2$

Test pozostałej nieliniowości

- Model rozszerzony:

$$y_t = \phi_1' x_t + (\phi_2 - \phi_1)' x_t G_1(s_t; \gamma_1, c_1) + (\phi_3 - \phi_2)' x_t G_2(s_t; \gamma_2, c_2) + \varepsilon_t$$

- $H_0: \gamma_2 = 0$ lub $\phi_3 = \phi_2$

- Zamień G_2 na rozwinięcie w szereg Taylora 3. rzędu:

$$y_t = \beta_0' x_t + (\phi_2 - \phi_1)' x_t G_1(s_t; \gamma_1, c_1) + \beta_1' x_t s_t + \beta_2' x_t s_t^2 + \beta_3' x_t s_t^3 + e_t$$

- Po przekształceniu, $H_0: \beta_1 = \beta_2 = \beta_3 = 0$

Test pozostałej nieliniowości

- Niech $F(x_t; \theta) = \phi_1' x_t [1 - G(z_t; \gamma, c)] + \phi_2' x_t G(z_t; \gamma, c)$

- Oszacuj model STR i oblicz reszty $\hat{\varepsilon}_t$

- Oblicz $\nabla F(x_t; \hat{\theta}) = \partial F(x_t; \hat{\theta}) / \partial \theta$ gdzie
 $\theta = [\phi_1 \quad \phi_2 \quad \gamma \quad c]'$

- Oszacuj model liniowy i oblicz R-kwadrat:

$$\hat{\varepsilon}_t \leftarrow \nabla F(x_t; \hat{\theta}), x_t z_t, x_t z_t^2, x_t z_t^3$$

- Statystyka LM

$$LM = TR^2 \sim \chi^2_{(l.\text{dodatkowych parametrow})}$$

Wybór funkcji przejścia

- Sekwencja testów (statystyki LM):


$$H_{01} : \beta_3 = 0$$

$$H_{02} : \beta_2 = 0 | \beta_3 = 0$$

$$H_{03} : \beta_1 = 0 | \beta_2 = 0, \beta_3 = 0$$

- Reguła decyzyjna:
 - Jeśli empiryczny poziom istotności (p-value) najmniejszy dla H_{02} , to wybierz model ESTR
 - Jeśli empiryczny poziom istotności najmniejszy dla H_{01} lub H_{03} , to wybierz model LSTR

Sieci neuronowe



Źródło: <http://kik.pcz.czyst.pl/nn/arch.php?art=3>

Sieci neuronowe

- Model z jedną warstwą ukrytą

$$y_t = G(\mathbf{x}_t; \boldsymbol{\psi}) + \varepsilon_t = \boldsymbol{\alpha}' \tilde{\mathbf{x}}_t + \sum_{i=1}^h \lambda_i F(\tilde{\boldsymbol{\omega}}_i' \mathbf{x}_t - \beta_i) + \varepsilon_t$$

$$\boldsymbol{\psi} = [\boldsymbol{\alpha}', \lambda_1, \dots, \lambda_h, \tilde{\boldsymbol{\omega}}_1', \dots, \tilde{\boldsymbol{\omega}}_h', \beta_1, \dots, \beta_h]'$$

- Funkcja logistyczna F lub inna sigmoidalna

$$F(\tilde{\boldsymbol{\omega}}_i' \mathbf{x}_t - \beta_i) = (1 + e^{-(\tilde{\boldsymbol{\omega}}_i' \mathbf{x}_t - \beta_i)})^{-1}$$

$$\varepsilon_t \sim n.i.d.(0, \sigma^2)$$

Sieci neuronowe

- Dokładne dopasowanie modelu do danych
 - możliwe dowolnie dokładne przybliżenie funkcji ciągłej
 - nie proces generujący dane, ale model przybliżający prawdziwy proces
- Prognozowanie
- Ekonomiczna interpretacja zależności?
Nie.

Identyfikowalność parametrów

- 3 problemy z identyfikowalnością
 - $h!$ permutacji neuronów (funkcji przejścia) ma taką samą wartość funkcji wiarygodności
 - dodatkowo: $F(x) = 1 - F(-x)$
 - duża liczba funkcji przejścia
- Rozwiązanie:
 - restrykcje: $\beta_1 \leq \dots \leq \beta_h$ lub $\lambda_1 \geq \dots \geq \lambda_h$
 $\tilde{\omega}_{1i} > 0, i = 1, \dots, h$
 - odpowiednia specyfikacja modelu

Budowa modelu

- Wybór zmiennych
- Wybór liczby funkcji przejścia
 - wymaga estymacji modelu

Budowa modelu

- Wybór zmiennych
 - przybliżenie sieci neuronowej przez wielomian k -tego rzędu

$$G(\mathbf{x}_t; \boldsymbol{\psi}) = \boldsymbol{\pi}' \tilde{\mathbf{x}}_t + \sum_{j_1=1}^q \sum_{j_2=j_1}^q \theta_{j_1 j_2} x_{j_1, t} x_{j_2, t} \\ + \dots + \sum_{j_1=1}^q \dots \sum_{j_k=j_{k-1}}^q \theta_{j_1 \dots j_k} x_{j_1, t} \dots x_{j_k, t} + R(\mathbf{x}_t; \boldsymbol{\psi})$$

- szacowanie modeli i optymalizacja kryterium informacyjnego: AIC, SBIC

Estymacja modelu

- Metoda Największej Wiarygodności
– równoważna: Nieliniowa MNK
- Przydatna reparametryzacja

$$F(\gamma_i(\boldsymbol{\omega}'_i \mathbf{x}_t - c_i)) = \left(1 + e^{-\gamma_i(\boldsymbol{\omega}'_i \mathbf{x}_t - c_i)}\right)^{-1}$$

$$\gamma_i > 0, i = 1, \dots, h$$

$$\|\boldsymbol{\omega}_i\| = 1 \quad \omega_{i1} = \sqrt{1 - \sum_{j=2}^q \omega_{ij}^2} > 0, i = 1, \dots, h$$

Estymacja modelu

- Wektor parametrów

$$\psi = [\alpha', \lambda_1, \dots, \lambda_h, \gamma_1, \dots, \gamma_h, \omega_{12}, \dots, \omega_{1q}, \dots, \omega_{h2}, \dots, \omega_{hq}, c_1, \dots, c_h]'$$

- Standaryzowanie zmiennych wejściowych:

$$\text{Var}(x)=1$$

- Możliwość „koncentracji” funkcji wiarygodności – tzn. szacowanie parametrów w grupach

Estymacja c.d.

- Przyjmij za znane:

$$\boldsymbol{\phi} = [\gamma_1, \dots, \gamma_h, \boldsymbol{\omega}'_1, \dots, \boldsymbol{\omega}'_h, c_1, \dots, c_h]'$$

- Zbuduj macierz \mathbf{Z} dla regresji: $\mathbf{y} = \mathbf{Z}(\boldsymbol{\phi})\boldsymbol{\theta} + \boldsymbol{\varepsilon}$

$$\mathbf{y}' = [y_1, y_2, \dots, y_T], \boldsymbol{\varepsilon}' = [\varepsilon_1, \varepsilon_2, \dots, \varepsilon_T], \boldsymbol{\theta}' = [\boldsymbol{\alpha}', \lambda_1, \dots, \lambda_h]$$

$$\mathbf{Z}(\boldsymbol{\phi}) = \begin{pmatrix} \tilde{\mathbf{x}}'_1 & F(\gamma_1(\boldsymbol{\omega}'_1\mathbf{x}_1 - c_1)) & \cdots & F(\gamma_h(\boldsymbol{\omega}'_h\mathbf{x}_1 - c_h)) \\ \vdots & \vdots & \ddots & \vdots \\ \bar{\mathbf{x}}'_T & F(\gamma_1(\boldsymbol{\omega}'_1\mathbf{x}_T - c_1)) & \cdots & F(\gamma_h(\boldsymbol{\omega}'_h\mathbf{x}_T - c_h)) \end{pmatrix}$$

Estymacja c.d.

- Szacuj parametry MNK:

$$\hat{\theta} = \left(\mathbf{Z}(\phi)' \mathbf{Z}(\phi) \right)^{-1} \mathbf{Z}(\phi)' \mathbf{y}$$

- Parametry $\phi = [\gamma_1, \dots, \gamma_h, \omega'_1, \dots, \omega'_h, c_1, \dots, c_h]'$ szacuj minimalizując sumę kwadratów reszt
 - algorytmy optymalizacji: BFGS, Levenberg-Marquardt

Wybór liczby funkcji przejścia

- Metoda „od małego do dużego”
– dodawanie neuronów (*hidden units*)

- Testowanie czy $h+1$ neuron zbędny

$$y_t = \alpha' \tilde{\mathbf{x}}_t + \sum_{i=1}^h \lambda_i F(\gamma_i(\boldsymbol{\omega}'_i \mathbf{x}_t - c_i)) + \lambda_{h+1} F(\gamma_{h+1}(\boldsymbol{\omega}'_{h+1} \mathbf{x}_t - c_{h+1})) + \varepsilon_t$$

$$H_0 : \gamma_{h+1} = 0$$

Testowanie funkcji przejścia

- Rozwinięcie modelu w szereg Taylora 3. rzędu:

$$y_t = \boldsymbol{\pi}' \tilde{\mathbf{x}}_t + \sum_{i=1}^h \lambda_i F(\gamma_i(\boldsymbol{\omega}'_i \mathbf{x}_t - c_i)) + \sum_{i=1}^q \sum_{j=i}^q \theta_{ij} x_{i,t} x_{j,t} + \sum_{i=1}^q \sum_{j=i}^q \sum_{k=j}^q \theta_{ijk} x_{i,t} x_{j,t} x_{k,t} + \varepsilon_t^*$$

- Oszacuj model z h neuronami i oblicz reszty $\hat{\varepsilon}_t$

- Wyznacz wektor „score” $\hat{\mathbf{h}}_t = \left. \frac{\partial G(\mathbf{x}_t; \boldsymbol{\psi})}{\partial \boldsymbol{\psi}'} \right|_{\boldsymbol{\psi}=\hat{\boldsymbol{\psi}}}$

– Jeśli $\hat{\varepsilon}_t$ i $\hat{\mathbf{h}}_t$ nie są ortogonalne, to oszacuj regresję tych zmiennych i wyznacz reszty $\tilde{\varepsilon}_t$

Testowanie c.d.

- Oblicz $SSR_0 = \sum_{t=1}^T \tilde{\varepsilon}_t^2$

- Oszacuj regresję $\tilde{\varepsilon}_t$ na $\hat{\mathbf{h}}_t$ i \mathbf{v}_t

$$\mathbf{v}_t = [x_{1,t}^2, x_{1,t}x_{2,t}, \dots, x_{i,t}x_{j,t}, \dots, x_{1,t}^3, \dots, x_{i,t}x_{j,t}x_{k,t}, \dots, x_{h,t}^3]$$

$$SSR_1 = \sum_{t=1}^T \hat{v}_t^2$$

- Oblicz reszty oraz

Testowanie c.d.

- Statystyka: $LM_{\chi^2}^{hn} = T \frac{SSR_0 - SSR_1}{SSR_0}$

z m stopniami swobody

$$m = q(q + 1)/2 + q(q + 1)(q + 2)/6$$

- W małych próbach:

$$LM_F^{hn} = \frac{(SSR_0 - SSR_1)/m}{SSR_1/(T - n - m)}$$

ma w przybliżeniu rozkład $F(m, T-n-m)$

$$n = (q + 2)h + p + 1$$

Ewaluacja modelu

- Testy aukorelacji, niestabilności parametrów
- Analiza prognoz