

Fakulta hospodárskej informatiky EU Bratislava
Katedra štatistiky

Eva Rublíková

Inauguračná prednáška

Dynamické regresné modelovanie makroekonomických premenných

Študijný odbor: 3.3.24 Kvantitatívne metódy v ekonómii

Bratislava 28.1.2010

Tézy prednášky

- Autoregresné modely
- Stacionárne a nestacionárne procesy
- Model transferovej funkcie
- Dynamický regresný model s jednou vysvetľujúcou premennou
- Lineárny regresný model s korelovanými rezíduami
- Všeobecný dynamický regresný model

Autoregresný model rozložených časových oneskorení

ADL(p, k, τ) – *Autoregressive distributed lag*

$$y_t = \alpha_0 + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^k \sum_{i=0}^{\tau} \beta_{j,i} x_{j,t-i} + \varepsilon_t$$

kde

$t = 1, 2, \dots, T$

ε_t je biely šum,

$\left| \sum_{i=1}^p \phi_i \right| < 1$ t.j. y_t je stacionárny časový rad,

$x_{j,t-i}$ je hodnota nestochastickej premennej X_j v oneskorení $t-i$; alebo premenná X_j je stochastická pre ktorú platí $E(\varepsilon_t, x_{j,t-i}) = 0$ pre všetky $t, i = 1, 2, \dots, \tau$ a $j = 1, 2, \dots, k$,

p je počet oneskorení stochastickej premennej Y ,

k je počet vysvetľujúcich premenných v modeli,

τ je maximálny počet oneskorení i v premennej X_j

α_0 konštanta modelu

ϕ_i pre $i = 1, 2, \dots, p$ autoregresné koeficienty

$\beta_{j,i}$ parciálne regresné koeficienty resp. krátkodobé multiplikátory pri $X_{j,t-i}$

Časový rad ako stochastický proces

Časový rad y_1, y_2, \dots, y_T chápeme ako jeden výsledok (realizáciu) stochastického procesu.

Stochastickým procesom rozumieme v čase usporiadanú postupnosť T náhodných premenných Y_1, Y_2, \dots, Y_T , ktoré majú združené rozdelenie pravdepodobnosti.

Stochastické procesy

- stacionárne
- nestacionárne

Nestacionárne procesy v strednej hodnote

- s deterministickým trendom
- so stochastickým trendom

Nestacionárne procesy v rozptyle

Stacionárne procesy

Striktná stacionarita

Pravdepodobnostné rozdelenie náhodného vektora $(y_t, y_{t+1}, \dots, y_{t+k})$ je rovnaké ako pravdepodobnostné rozdelenie vektora $(y_{t+m}, y_{t+m+1}, \dots, y_{t+m+k})$, t.j. ich združené distribučné funkcie sa rovnajú

$$F(y_t, y_{t+1}, \dots, y_{t+k}) = F(y_{t+m}, y_{t+m+1}, \dots, y_{t+m+k})$$

Slabá stacionarita

$\{y_t, t \in T\}$ má vlastnosti:

- stredná hodnota $\mu_t = E(y_t) = \mu$
- rozptyl $\sigma_{y,t}^2 = D(y_t) = E(y_t - \mu_t)^2 = \sigma_y^2$
- autokovariančná funkcia medzi y_t a y_{t-k}

$$\gamma_k = E(y_t - \mu)(y_{t-k} - \mu)$$

- autokorelačná funkcia y_t a y_{t-k}

$$\rho_k = \frac{\gamma_k}{\sigma_{y,t} \cdot \sigma_{y,t-k}} = \frac{\gamma_k}{\sigma_y^2} = \frac{\gamma_k}{\gamma_0}$$

Proces bieleho šumu

ε_t nekorelované náhodné premenné s rovnakým rozdelením pravdepodobnosti pre $t = 1, 2, \dots, T$, ak pre všetky t platí

- $E(\varepsilon_t) = 0$
- $D(\varepsilon_t) = E(\varepsilon_t^2) = \sigma_\varepsilon^2 = \text{konšt.}$
- $\text{cov}(\varepsilon_t, \varepsilon_{t-k}) = 0, k \neq 0$
- $\rho_k = 1$ pre $k = 0$ a $\rho_k = 0$ pre $k \neq 0$
- $\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$

ε_t pre $t = 1, 2, \dots, T$ je stacionárny proces,

ε_t je gaussovský proces, ak jeho združené rozdelenie pravdepodobnosti je normálne

Lineárny proces

Wold (1938)

$$y_t - \mu = \varepsilon_t + \psi_1 \varepsilon_{t-1} + \psi_2 \varepsilon_{t-2} + \dots = \sum_{i=0}^{\infty} \psi_i \varepsilon_{t-i}, \quad \psi_0 = 1$$

Vlastnosti

$$E(y_t) = \mu \quad \text{a} \quad D(y_t) = \sigma_{\varepsilon}^2 \sum_{i=0}^{\infty} \psi_i^2, \quad \sum_{i=0}^{\infty} \psi_i^2 < \infty$$

Nestacionárne procesy

Proces náhodnej prechádzky (RW)

$$\text{RW} \sim \text{AR}(1) \quad \text{ak } \phi_1 = 1$$

$$y_t = y_{t-1} + \varepsilon_t$$

Ak začiatok procesu je v čase $t = 0$ a deterministická začiatočná podmienka je $y_0 = 0$

$$y_t = y_0 + \sum_{j=1}^t \varepsilon_j = \sum_{j=1}^t \varepsilon_j$$

Vlastnosti RW

$E(y_t) = y_0 = 0$ nezávisí od času,

$D(y_t) = t\sigma_\varepsilon^2$ rozptyl závisí na čase,

$\text{cov}(y_t, y_{t-k}) = E(y_t - y_0)(y_{t-k} - y_0) = (t-k)\sigma_\varepsilon^2$ závisí od $(t-k)$,

$\rho_k = \frac{t-k}{\sqrt{(t-k)t}} = \frac{\sqrt{t-k}}{\sqrt{t}} = \sqrt{1 - \frac{k}{t}}$, závisí od času t , a při $t \rightarrow \infty$ $\rho_k \rightarrow 1$

RW - nestacionární proces, zdrojom nestacionarity je stochastický trend $\sum_{j=1}^t \varepsilon_j$.

$E(y_{t+k}|y_t) = y_t$

Proces náhodnej prechádzky s posunom (RW with drift)

$$y_t = \alpha t + y_0 + \sum_{i=1}^t \varepsilon_{t-i}$$

Vlastnosti RW s posunom

Ak $y_0 = 0$

$E(y_t) = \alpha t$ závisí na čase

$D(y_t) = t\sigma_\varepsilon^2$ rozptyl závisí na čase

$\rho_k = \frac{t-k}{\sqrt{(t-k)t}} = \frac{\sqrt{t-k}}{\sqrt{t}} = \sqrt{1 - \frac{k}{t}}$ závisí na čase

$E(y_{t+k}|y_t) = \alpha k + y_t$

Transformácia nestacionárneho procesu na stacionárny

Transformácia nestacionárneho procesu s deterministickým trendom na stacionárny

$$y_t = \alpha_0 + \alpha_1 t + \varepsilon_t$$

$\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$ je stacionárny proces

$y_t - \alpha_0 - \alpha_1 t = \varepsilon_t$ je stacionárny

y_t je **trendovo stacionárny**

Transformácia nestacionárneho procesu so stochastickým trendom na stacionárny

RW

$$y_t = y_{t-1} + \varepsilon_t$$

$$(1 - B)y_t = \varepsilon_t$$

$$y_t = \frac{1}{1 - B} \varepsilon_t = \varepsilon_t + \varepsilon_{t-1} + \varepsilon_{t-2} + \dots$$

$$E(y_t) = 0$$

$$D(y_t) = \sigma_\varepsilon^2 + \sigma_\varepsilon^2 + \sigma_\varepsilon^2 + \dots = \infty$$

y_t je nestacionárny v rozptyle, stacionárny v strednej hodnote

$$y_t \sim I(1)$$

RW s posunom

$$y_t = \phi_0 + y_{t-1} + \varepsilon_t$$

$$\Delta y_t = y_t - y_{t-1} = (1 - B)y_t = \phi_0 + \varepsilon_t$$

Označenie

$$\Delta y_t \sim I(0)$$

$$y_t \sim I(1)$$

Integrované procesy

$$y_t \sim I(d) \text{ pre } d = 0, 1, 2 \quad z_t = (1 - B)^d y_t$$

$$z_t \sim \text{AR}(p) \text{ t.j. } \phi_p(B) z_t = \varepsilon_t$$

$$y_t \sim \text{ARI}(p, d) \text{ t.j. } \phi_p(B) (1 - B)^d y_t = \varepsilon_t$$

Testovanie stacionarity testom jednotkového koreňa

Random Walk versus AR(1)

$$\text{RW} \sim y_t = y_{t-1} + \varepsilon_t \text{ proti } \text{AR}(1) \sim y_t = \phi_1 y_{t-1} + \varepsilon_t \quad |\phi_1| < 1$$

$$H_0 : \phi_1 = 1 \text{ proti } H_1 : \phi_1 < 1$$

$$\Delta y_t = (\phi_1 - 1)y_{t-1} + \varepsilon_t$$

$$\text{Označme } \beta_c = \phi_1 - 1$$

$$\Delta y_t = \beta_c y_{t-1} + \varepsilon_t$$

$$H_0 : \beta_c = 0 \text{ proti } H_1 : \beta_c < 0$$

Ak $y_t \sim \text{RW} \rightarrow \phi_1 = 1 \rightarrow \beta_c = 0$ a $\Delta y_t = \varepsilon_t \sim \text{I}(0)$ stac.

Dickey a Fuller (1979)

$$\Delta y_t = \beta_c y_{t-1} + \varepsilon_t \quad \sim \text{RW}$$

$$\Delta y_t = c_1 + \beta_c y_{t-1} + \varepsilon_t \quad \sim \text{RW s posunom } c_1 \text{ a trendom}$$

$$\Delta y_t = c_1 + c_2 t + \beta_c y_{t-1} + \varepsilon_t \sim \text{RW s posunom a det.trend}$$

Testovacia štatistika $DF = \frac{\hat{\beta}_c}{s_{\hat{\beta}_c}}$

Dickey a Fuller tabelovali kritické hodnoty, závisiace od typu modelu a dĺžky časového radu T

Kritické hodnoty označili DF_{RW} alebo DF_{c_1} alebo DF_{c_1, c_2}

Kritický odbor na α

ak $DF <$ ako príslušná kritická hodnota

H_0 zamietame, t.j. y_t je stacionárny proces

Rozšířený Dickeyho-Fullerov (ADF) test

Random Walk versus AR(p)

$$\text{RW} \sim y_t = y_{t-1} + \varepsilon_t \text{ proti}$$

$$\text{AR}(p) \sim y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad \sum_{i=1}^p \phi_i < 1$$

$$\Delta y_t = \beta_c y_{t-1} + \sum_{i=2}^p \phi_i \Delta y_{t-i+1} + \varepsilon_t$$

$$\Delta y_t = c_1 + \beta_c y_{t-1} + \sum_{i=2}^p \phi_i \Delta y_{t-i+1} + \varepsilon_t$$

$$\Delta y_t = c_1 + c_2 t + \beta_c y_{t-1} + \sum_{i=2}^p \phi_i \Delta y_{t-i+1} + \varepsilon_t$$

$$H_0 : \sum_{i=1}^p \phi_i = 1 \text{ proti } H_1 : \sum_{i=1}^p \phi_i < 1$$

$$\Delta y_t = c_1 + \beta_c y_{t-1} + c_2 t + \sum_{i=2}^p \phi_i \Delta y_{t-i+1} + \varepsilon_t$$

$$\text{kde } \beta_i = \sum_{i=1}^p \phi_i \text{ a } \beta_c = \left(\sum_{i=1}^p \phi_i \right) - 1$$

Ak $\sum_{i=1}^p \phi_i = 1$ a $\beta_c = 0$ proces má jednotkový koreň

Identifikácia krátkodobej dynamiky autoregresných procesov

Autokorelačná funkcia (TACF) stacionárneho procesu y_t

$$\rho_k = \frac{E(y_t - \mu)(y_{t-k} - \mu)}{E(y_t - \mu)^2}$$

Vlastnosti

- $\rho_0 = 1$,
- $|\gamma_k| \leq \gamma_0 = \sigma_y^2$ a $|\rho_k| \leq 1$,
- $\gamma_k = \gamma_{-k}$ a $\rho_k = \rho_{-k}$ symetria okolo $k = 0$, pretože časová vzdialenosť medzi dvojicami premenných y_t, y_{t+k} a y_{t-k}, y_t je rovnaká.

Empirická ACF

$$r_k = \frac{\sum_{t=k+1}^T (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2} = \hat{\rho}_k \text{ pre } k = 0, 1, 2, \dots$$

Bartlettov test (1946)

$$H_0: \rho_k = 0 \text{ proti } H_1: \rho_k \neq 0$$

ak $\rho_k = 0$ pre $k > q$ a za predpokladu asymptotickej normality

$$r_k \sim N\left\{0, \frac{1}{T} \left(1 + 2 \sum_{j=1}^q r_j^2\right)\right\}$$

Kritický odbor pre $\alpha = 0,05$

$$|r_k| > \frac{2}{\sqrt{\frac{1}{T} \left(1 + 2 \sum_{j=1}^q r_j^2\right)}}$$

Parciálna autokorelačná funkcia (TPACF)

ρ_{kk} miera závislosti y_t a y_{t-k} , ak $y_{t-k+1}, y_{t-k+2}, \dots, y_{t-1}$ sa nemenia.

Empirická PACF (Darbin 1960)

$$r_{kk} = \frac{r_k - \sum_{j=1}^{k-1} r_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} r_{k-1,j} r_j} = \hat{\rho}_{kk}$$

$$r_{kj} = r_{k-1,j} - r_{kk} r_{k-1,k-j} \quad \text{pre } j = 1, 2, \dots, k-1$$

Queunouille 1949

$$H_0: \rho_{k,k} = 0 \text{ proti } H_1: \rho_{k,k} \neq 0$$

$$r_{kk} \sim N\left(0, \frac{1}{T}\right)$$

$$\text{Kritický odbor pre } \alpha = 0,05 \quad |r_k| > \frac{2}{\sqrt{\frac{1}{T}}}$$

Autoregresné modely
Modely ADL($p, 0, 0$) = AR(p)

Autoregresný proces AR(1)

$$E(y_t) = \mu \neq 0 \qquad y_t^* = y_t - \mu \qquad E(y_t^*) = 0$$

$$y_t^* = \phi_1 y_{t-1}^* + \varepsilon_t$$

$$(1 - \phi_1 B) y_t^* = \varepsilon_t$$

$$y_t^* = \frac{1}{(1 - \phi_1 B)} \varepsilon_t = \varepsilon_t + \phi_1 \varepsilon_{t-1} + \phi_1^2 \varepsilon_{t-2} + \dots$$

$$\text{Pre } |\phi_1| < 1$$

$$y_t^* = (1 + \phi_1 B + \phi_1^2 B^2 + \phi_1^3 B^3 + \dots) \varepsilon_t = \frac{1}{1 - \phi_1 B} \varepsilon_t$$

Vlastnosti AR(1)

Podmienka stacionarity: $|\phi_1| < 1$

Stredná hodnota: $\mu = \frac{\phi_0}{1 - \phi_1}$

Rozptyl procesu: $\sigma_y^2 = \frac{\sigma_\varepsilon^2}{1 - \phi_1^2}$

TACF: $\rho_k = \phi_1^k$,

- pre $k \geq 0$ exponenciálne klesá k nule,
- ak $\phi_1 > 0$, indukuje zotrvačnosť v znamienku susedných hodnôt, ACF klesá v kladných hodnotách,
- ak $\phi_1 < 0$, treba očakávať časté zmeny v znamienkach susedných hodnôt časového radu, ACF klesá s alternujúcimi znamienkami, začínajúc so záporným znamienkom.

TPACF

$\rho_{11} = \phi_1$ a pre $k > 1$ sú $\rho_{kk} = 0$, bod zlomu v $k_0 = 1$.

Autoregresný proces AR(2)

$$E(y_t^*) = 0$$

$$y_t^* = \phi_1 y_{t-1}^* + \phi_2 y_{t-2}^* + \varepsilon_t$$

$$(1 - \phi_1 B - \phi_2 B^2) y_t^* = \varepsilon_t$$

$$y_t^* = \frac{1}{(1 - \phi_1 B - \phi_2 B^2)} \varepsilon_t$$

Vlastnosti AR(2)

Podmienky stacionarity: $\phi_1 + \phi_2 < 1$, $-\phi_1 + \phi_2 < 1$,
 $-1 < \phi_2 < 1$

Stredná hodnota: $\mu = \frac{\phi_0}{1 - \phi_1 - \phi_2}$

Rozptyl procesu: $\sigma_y^2 = \frac{\sigma_\varepsilon^2}{1 - \phi_1\rho_1 - \phi_2\rho_2}$

TACF: $\rho_k = \phi_1\rho_{k-1} + \phi_2\rho_{k-2}$, pre $k = 1, 2, \dots$

má tvar lineárnej kombinácie dvoch exponenciálne klesajúcich postupností, alebo tvar sínusoidy s exponenciálne klesajúcou amplitúdou.

TPACF: $\rho_{11} = \frac{\phi_1}{1 - \phi_2}$, $\rho_{22} = \phi_2$,

$\rho_{kk} = 0$ pre $k = 3, 4, \dots$. $k_0 = 2$ je bod zlomu.

Prítomnosť cyklu

Ak $\phi_2 < 0$, $\phi_1^2 + 4\phi_2 < 0$

dĺžka cyklu v nesezónnej časti radu

$$p^* = \frac{360^\circ}{\cos^{-1}\left[\phi_1 / 2(-\phi_2)^{1/2}\right]}, \text{ mesiacov (štvrt'rokov)}$$

Ak $\Phi_{1,s}^2 + 4\Phi_{2,s} < 0$,

dĺžka cyklu v sezónnej časti

$$p^* = \frac{360^\circ}{\cos^{-1}\left[\Phi_{1,s} / 2(-\Phi_{2,s})^{1/2}\right]}, \text{ roky (s.p}^*)$$

Autoregresný proces AR(p)

$$E(y_t^*) = 0$$

$$y_t^* = \phi_1 y_{t-1}^* + \dots + \phi_p y_{t-p}^* + \varepsilon_t,$$

$$(1 - \phi_1 B - \dots - \phi_p B^p) y_t^* = \varepsilon_t$$

Podmienky stacionarity

$$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p) = 0$$

$$(1 - \phi_1 B - \dots - \phi_p B^p) = (1 - \phi_1 B)(1 - \phi_2 B) \dots (1 - \phi_p B) = 0$$

$$|B| > 1 \Leftrightarrow \left| \frac{1}{\phi_i} \right| > 1 \Rightarrow |\phi_i| < 1 \text{ pre } i = 1, 2, \dots, p$$

Vlastnosti AR(p)

Podmienka stacionarity: $|\phi_1| < 1, \dots, |\phi_p| < 1$

Stredná hodnota: $\mu = \frac{\phi_0}{1 - \phi_1 - \phi_2 - \dots - \phi_p}$

Rozptyl procesu: $\sigma_y^2 = \frac{\sigma_a^2}{1 - \phi_1 \rho_1 - \dots - \phi_p \rho_p}$

TACF: $\rho_k = \phi_1 \rho_{k-1} + \dots + \phi_p \rho_{k-p}$, pre $k = 1, 2, \dots$

Ak sú korene rovnice $\phi_p(B) = 0$ reálne, ACF exponenciálne klesá k nule.

Ak sú korene rovnice $\phi_p(B) = 0$ komplexné, ACF exponenciálne klesá k nule v sínusových vlnách.

TPACF: $\rho_{kk} \neq 0$ je v oneskoreniach $k = 1, 2, \dots, p$

$$\rho_{kk} = 0 \quad k > p$$

Odhad a verifikácia modelu

Test normality náhodných porúch

$H_0 : \varepsilon_t$ má normálne rozdelenie

$H_1 : \varepsilon_t$ nemá normálne rozdelenie

Jarque-Bera test (1987)

$\gamma_1(\hat{\varepsilon}_t)$ koeficient šikmosti rezíduí

$\gamma_2(\hat{\varepsilon}_t)$ koeficient špicatosti rezíduí

$$W = T \left(\frac{\gamma_1^2}{6} + \frac{\gamma_2^2}{24} \right) \approx \chi^2(2)$$

Kritický odbor pre α $W \geq \chi_{1-\alpha}^2(2)$

Opatrenia pri zamietnutí H_0 o normalite náhodných porúch

- Transformovať asymetriu rozdelenia Boxovou-Coxovou (1964) transformáciou
 - ▶ \log , ak sú dáta zošikmené vpravo
 - ▶ $\sqrt{\cdot}$, ak dáta sú dané ako počet napr. osôb a pod.
- Prijat' H_1 a doplnit' AR model modelom ARCH, GARCH pre rezíduá.
- Modelovať odľahlé pozorovania pomocou umelých premenných.
- Použit' robustné metódy odhadu.

Test neautokorelovanosti náhodných porúch pomocou ACF

$$H_0 : \rho_k(\varepsilon) = 0 \text{ proti } H_1 : \rho_k(\varepsilon) \neq 0$$

$$z = r_k(\hat{\varepsilon})\sqrt{T} \sim N(0,1)$$

$$r_k(\hat{\varepsilon}) = \frac{\sum_{t=k+1}^T \hat{\varepsilon}_t \cdot \hat{\varepsilon}_{t-k}}{\sum_{t=1}^T \hat{\varepsilon}_t^2}$$

Kritický odbor pre $\alpha = 0,05$ $|r_k(\hat{\varepsilon})| > 2\sqrt{T}$

Boxov-Pierceov Q – test (1970) a Ljungov-Boxov Q^* – test (1978)

$$H_0 : \rho_1(\varepsilon) = \rho_2(\varepsilon) = \dots = \rho_m(\varepsilon) = 0$$

$$H_1 : \text{non } H_0$$

$$Q_m = T \sum_{k=1}^m (r_k(\hat{\varepsilon}))^2 \sim \chi^2(m-p)$$

$$Q_m^* = T(T+2) \sum_{k=1}^m \frac{1}{T-k} (r_k(\hat{\varepsilon}))^2 \sim \chi^2(m-p)$$

Kritický odbor pre α

$$Q_m \text{ alebo } Q_m^* \geq \chi_{1-\alpha}^2(m-p)$$

Breuschov-Godfreyov všeobecný test autokorelácie (1978)

$$y_t = \alpha_0 + \beta_{1,0} x_{1,t} + \beta_{2,0} x_{2,t} + \dots + \beta_{k,0} x_{k,t} + \varepsilon_t, \quad t = 1, 2, \dots, T$$

$$\varepsilon_t \sim AR(p) \quad \varepsilon_t = \phi_1 \varepsilon_{t-1} + \phi_2 \varepsilon_{t-2} + \dots + \phi_p \varepsilon_{t-p} + u_t$$

$$u_t \sim N(0, \sigma_\varepsilon^2) \quad p \approx s \text{ (počet sezón)}$$

$$H_0 : \phi_1 = \phi_2 = \dots = \phi_p = 0 \text{ proti } H_1 : \phi_i \neq 0 \text{ aspoň jeden}$$

Odhadneme LRM model

Vytvoríme pomocnú rovnicu rezíduí a vysvetľujúcich premenných

$$\hat{\varepsilon}_t = \gamma_0 + \gamma_1 x_{1,t} + \dots + \gamma_{k,t} x_{k,t} + \phi_1 \hat{\varepsilon}_{t-1} + \dots + \phi_p \hat{\varepsilon}_{t-p} + u_t$$

pre $t = p + 1, p + 2, \dots, T$, získame R^2

$$\text{Kritický odbor pre } \alpha \quad (T - p)R^2 \geq \chi_{1-\alpha}^2(p)$$

Príčiny autokorelácie náhodných porúch

- zotrvačnosť vo vývoji radu
- zlá špecifikácia modelu
- výber počtu posunov
- výber premenných

Dôsledky autokorelácie rezíduí

- Odhad modelu MNŠ neskreslený, konzistentný, ale nie je výdatný.
- Štandardné odchýlky odhadnutých parametrov podhodnotené → parametre významné, t -test a F -test nevhodný.
- Štandardná odchýlka rezíduí podhodnotená → R^2 nadhodnotený.

Dynamické modely s jednou vysvetľujúcou premennou

$ADL(0, 1, \infty) = DL(1, \infty)$ model s nekonečným rozloženým oneskorením

Koyckov prístup k modelu s ∞ rozloženým oneskorením (1976)

$ADL(1, 1, 0)$ model s adaptívnym očakávaním

ADL(0, 1, ∞) = DL(1, ∞)
Model s nekonečným rozloženým oneskorením

$$y_t = \alpha_0 + \beta_0 x_t + \beta_1 x_{t-1} + \beta_2 x_{t-2} + \dots + \varepsilon_t$$

$$y_t = \alpha_0 + \sum_{i=0}^{\infty} \beta_i x_{t-i} + \varepsilon_t$$

kde

ε_t biely šum,

α_0 je regulačná konštanta,

β_i multiplikátory

$$y_t = \alpha_0 + \beta_0 x_t + \beta_1 x_{t-1} + \beta_2 x_{t-2} + \dots + \varepsilon_t$$

β_0 krátkodobý multiplikátor,

$\beta(\tau) = \sum_{i=0}^{\tau} \beta_i$ kumulovaný (priebežný) multiplikátor τ -teho obdobia,

$\beta = \sum_{i=0}^{\infty} \beta_i$ dlhodobý multiplikátor, odráža vplyv vysvetľujúcej premennej X po jej prechode do rovnovážneho stavu t.j. ak sa hodnota x_t nemení dlhší čas, potom

rovnovážna hodnota $\bar{y} = \alpha_0 + \bar{x} \sum_{i=0}^{\infty} \beta_i$,

štandardizované koeficienty $\beta_i^* = \frac{\beta_i}{\sum_{i=0}^{\infty} \beta_i}$,

t.j. koľko percent z celkového vplyvu jednotkovej zmeny X sa premietlo do priemernej zmeny Y za obdobie $t, t-1, t-2, \dots, t-\tau$.

Koyckov prístup k modelu s ∞ rozloženým oneskorením (1976)

$$y_t = \alpha_0 + \beta_0 x_t + \beta_1 x_{t-1} + \beta_2 x_{t-2} + \dots + \varepsilon_t$$

$$\beta_i = \beta_0 \lambda^i > 0 \quad i = 1, 2, \dots, \quad 0 < \lambda < 1$$

λ miera poklesu (rate of decline)

$1 - \lambda$ rýchlosť prispôsobovania sa

$$\sum_{i=0}^{\infty} \beta_i = \beta_0 (1 + \lambda + \lambda^2 + \lambda^3 + \dots) = \beta_0 \frac{1}{1 - \lambda}$$

Koyckova transformácia

$$y_t = \alpha_0 + \beta_0 x_t + \beta_0 \lambda x_{t-1} + \beta_0 \lambda^2 x_{t-2} + \dots + \varepsilon_t$$

$$y_t - \lambda y_{t-1} = \alpha_0(1 - \lambda) + \beta_0 x_t + (\varepsilon_t - \lambda \varepsilon_{t-1})$$

$$y_t = \alpha_0(1 - \lambda) + \beta_0 x_t + \lambda y_{t-1} + u_t$$

kde $u_t = \varepsilon_t - \lambda \varepsilon_{t-1} \sim \text{MA}(1)$, pretože $\lambda < 1$.

Dôsledky Koyckovej transformácie

- zníženie počtu parametrov v DL
- vylúčenie možného problému multikolinearity
- z modelu ADL $(0,1,\infty) = DL(1,\infty)$ sme získali model ADL $(1,1,0)$
- prítomnosť časovo oneskorenej vysvetľovanej premennej ako vysvetľujúcej stochastickej premennej porušuje predpoklad týkajúci sa požiadavky nekorelovanosti s u_t
- vznikol problém autokorelácie, u_t sú autokorelované
- treba preskúmať platnosť $E(y_{t-1}, u_t) = 0$, Durbin h test

Durbin h test pre model typu Koycka ADL(1, 1, 0)

$$y_t = \alpha_0(1 - \lambda) + \beta_0 x_t + \lambda y_{t-1} + u_t,$$

$$H_0 : \rho_1(u_t) = 0 \text{ proti } H_1 : \rho_1(u_t) \neq 0$$

$$h = \hat{\rho}_1(u_t) \sqrt{\frac{T}{1 - T \cdot \text{var}(\hat{\lambda})}} \sim N(0, 1)$$

$$\hat{\rho} = \frac{\sum_{t=2}^T \hat{u}_t \cdot \hat{u}_{t-1}}{\sum_{t=1}^T \hat{u}_t^2} \approx 1 - \frac{DW}{2}$$

kde

$\text{var}(\hat{\lambda})$ rozptyl odhadnutého parametra λ ,

T délka časového radu.

DW je Darbinova a Watsonova štatistika rezíduí \hat{u}_t

Kritický odbor pre α

$$|h| > z_{1-\frac{\alpha}{2}}$$

ADL(1, 1, 0) model s adaptívnym očakávaním

$$y_t = \alpha_0 + \beta_1 x_t^* + \varepsilon_t, \quad t = 1, 2, \dots, T$$

Y dopyt po peniazoch,
 X^* očakávaná dlhodobá úroková miera,
 ε náhodná zložka.

Cagan, P. (1956) a Friedman, M. (1957) - Hypotéza adaptívnych očakávaní

$$x_t^* - x_{t-1}^* = \gamma(x_t - x_{t-1}^*)$$

γ koeficient očakávania, $0 \leq \gamma \leq 1$.

$$x_t^* = \gamma x_t + (1 - \gamma)x_{t-1}^*$$

Ak $\gamma = 1 \rightarrow x_t^* = x_t$ okamžitá realizácia

Ak $\gamma = 0 \rightarrow x_t^* = x_{t-1}^*$ statické očakávania t. j. $x_t^* = x_t$

$$y_t = \gamma\alpha_0 + \gamma\beta_1 x_t + (1 - \gamma)y_{t-1} + u_t, \quad u_t = \varepsilon_t - (1 - \gamma)\varepsilon_{t-1}.$$

Porovnanie modelov

Koyckov model

$$y_t = \alpha_0(1 - \lambda) + \beta_0 x_t + \lambda y_{t-1} + u_t \quad u_t = \varepsilon_t - \lambda \varepsilon_{t-1}$$

Model s adaptívnym očakávaním

$$y_t = \gamma \alpha_0 + \gamma \beta_1 x_t + (1 - \gamma) y_{t-1} + u_t \quad u_t = \varepsilon_t - (1 - \gamma) \varepsilon_{t-1}$$

- Formálna podobnosť modelov ale odlišná interpretácia.
- λ nemá ekonomickú interpretáciu, naopak γ je koeficient očakávania.
- Modely sú typu ADL.
- Náhodné poruchy sú autokorelované.

Viacnásobný statický LRM s autokorelovanými rezíduami
ADL(0, k , 0)

ADL(0, k, 0) viacnásobný statický LRM

$$y_t = \alpha_0 + \beta_{1,0} x_{1,t} + \beta_{2,0} x_{2,t} + \dots + \beta_{k,0} x_{k,t} + \varepsilon_t, \quad t = 1, 2, \dots, T$$

$$y_t = \alpha_0 x_{1,t}^{\beta_{1,0}} x_{2,t}^{\beta_{2,0}} \dots x_{k,t}^{\beta_{k,0}} e^{\varepsilon_t}, \quad t = 1, 2, \dots, T$$

$$\ln y_t = \ln \alpha_0 + \beta_{1,0} \ln x_{1,t} + \beta_{2,0} \ln x_{2,t} + \dots + \beta_{k,0} \ln x_{k,t} + \ln \varepsilon_t$$

$\beta_{j,0}$ - parciálne regresné koeficienty

- marginálne efekty, reakcia na zmenu v X_j pre $j = 1, 2, \dots, k$ sa uskutoční priamo, v tom istom časovom období t

- marginálne elasticity

Dynamický LRM - SLRM s korelovanými náhodnými poruchami

$$y_t = \alpha_0 + \beta_{1,0}x_{1,t} + \beta_{2,0}x_{2,t} + \dots + \beta_{k,0}x_{k,t} + \varepsilon_t,$$

$$\mathbf{AR(1)} \quad \varepsilon_t = \phi_1 \varepsilon_{t-1} + u_t$$

$$\mathbf{AR(p)} \quad \varepsilon_t = \phi_1 \varepsilon_{t-1} + \phi_2 \varepsilon_{t-2} + \dots + \phi_p \varepsilon_{t-p} + u_t$$

$$\mathbf{MA(q)} \quad \varepsilon_t = u_t - \theta_1 u_{t-1} - \theta_2 u_{t-2} - \dots - \theta_q u_{t-q}$$

ARMA(p, q)

$$\varepsilon_t = \phi_1 \varepsilon_{t-1} + \phi_2 \varepsilon_{t-2} + \dots + \phi_p \varepsilon_{t-p} + u_t - \theta_1 u_{t-1} - \dots - \theta_q u_{t-q}$$

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \varepsilon_t = (1 - \theta_1 B - \dots - \theta_q B^q) u_t$$

$$\varepsilon_t = \frac{\theta_q(B)}{\phi_p(B)} u_t$$

Simultánný odhad: LRM a $\varepsilon_t = \frac{\theta_q(B)}{\phi_p(B)} u_t$

nový model LRM+AR(1)

$$y_t = \alpha_0 + \beta_1 x_t + \beta_2 x_2 + \dots + \beta_k x_k + \phi_1 \varepsilon_{t-1} + u_t$$

alebo

model LRM+ARMA(p, q)=MARMA(p, q)

$$y_t = \alpha_0 + \beta_0 x_t + \beta_2 x_2 + \dots + \beta_k x_k + \frac{\theta_q(B)}{\phi_p(B)} u_t$$

Problém falošnej regresie

Granger, C. W. J. a Newbold, P. (1974)

- generovali dvojice nezávislých premenných
 $X \sim RW$ a $Y \sim RW$
- metódou Monte Carlo zistili: 75 % výsledkov potvrdilo lineárnu závislosť
 X, Y (prijali nesprávnu hypotézu)
- Formulovali pravidlo:

Ak $R^2 > D - W$ ide o falošnú regresiu

Autoregresný model rozložených časových oneskorení

ADL(p, k, τ) – *Autoregressive distributed lag*

$$y_t = \alpha_0 + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^k \sum_{i=0}^{\tau} \beta_{j,i} x_{j,t-i} + \varepsilon_t$$

kde

$t = 1, 2, \dots, T$

ε_t je biely šum,

$\left| \sum_{i=1}^p \phi_i \right| < 1$ t.j. y_t je stacionárny časový rad,

$x_{j,t-i}$ je hodnota nestochastickej premennej X_j v oneskorení $t-i$; alebo premenná X_j je stochastická pre ktorú platí $E(\varepsilon_t, x_{j,t-i}) = 0$ pre všetky $t, i = 1, 2, \dots, \tau$ a $j = 1, 2, \dots, k$,

p je počet oneskorení stochastickej premennej Y ,

k je počet vysvetľujúcich premenných v modeli,

τ je maximálny počet oneskorení i v premennej X_j

α_0 konštanta modelu

ϕ_i pre $i = 1, 2, \dots, p$ autoregresné koeficienty

$\beta_{j,i}$ parciálne regresné koeficienty resp. krátkodobé multiplikátory pri $X_{j,t-i}$

LITERATÚRA

1. ARLT, J.: Moderní metody modelování ekonomických časových řad. Praha: Grada Publishing, 1999.
2. BOX, G. E. P., JENKINS, G. M.: Time Series Analysis: Forecasting and Control. New Jersey: Prentice Hall International, Inc. 1994.
3. CIPRA, T. : Finanční ekonometrie, Ekopress, Praha.
4. GUJARATI, D. N.: Basic Econometrics: McGraw-Hill International Editions, New York. 1995.
5. HAMILTON, J. D.: Time Series Analysis. New Jersey: Princeton University Press, 1994.
6. HARVEY, A. C.: The Econometric Analysis of Time Series. 2nd Edition. London: Philip Allan, 1990.
7. HATRÁK, M. : Ekonometria. Bratislava. Iura Edition, 2007.
8. MILLS, T. C.: Time series techniques for economists. Cambridge: Cambridge University Press, 1990.
9. PANKRATZ, A.: Forecasting with Dynamic Regression Models. Willey and Sons. Inc., New York.
10. RUBLÍKOVÁ, E., PRÍHODOVÁ, I.: Analýza vybraných časových radov-ARIMA modely. Bratislava: Vydavateľstvo Ekonóm, 2008. s214.

11. RUBLÍKOVÁ, E., HANČLOVÁ, J.: Short-run Dynamics In: Monetary Model of Exchange Rate. In: *Ekonomika a Informatika*, č. 1. 2006, roč, IV. s. 150 – 156.
12. RUBLÍKOVÁ, E.: *Analýza časových radov*. Bratislava: Iura Edition, 2007.
13. RUBLÍKOVÁ, E.: ARCH and GARCH Models for Daily Exchange Rate of SKK/USD. In: *Ekonomické rozhľady* roč. XXXIII, č.3, (2004), s. 314 – 323.
14. RUBLÍKOVÁ, E., RUTKOWSKA, M.: Determinants of Exchange Rates for Slovakia, the Czech Republic and Poland. In: *ECON'5 (Selected Research Papers)*. Technical University of Ostrava, Faculty of Economics, Volume 12, 2005, s. 308 – 316.
15. RUBLÍKOVÁ, E., IVANIČOVÁ, Z.: Modelling Conditional Variance of Monthly Rates SKK/USD. In: *ECON'02 Ostrava. (Selected Research Papers)*. Research Work Proceedings, s. 174 – 179.
16. RUBLÍKOVÁ, E., RUTKOWSKA, M.: Estimating Cyclical Component in CPI of Slovakia and Poland. In: *Prace Naukowe Akademii Ekonomicznej we Wroclawiu: Inwesycje finansowe i ubezpieczenia – tendencje swiatowe a polski rynek*. Nr. 1133, (2006), s. 438 – 446.
17. RUBLÍKOVÁ, E., MAGALHAES-HILL, M.: A Non-linear Approach to Modelling Asymmetry in a Time Series. In: *Temas em Métodos Quantitativos*. No. 4, s. 51 – 59 Lisboa, 2004.
18. VINCÚR, P.: *Makroekonomická analýza a prognóza*. Bratislava: Sprint, 2000.
19. RUBLÍKOVÁ, E., MAREK, L. Linear transfer function model for outflow rates. *Ekonomické rozhľady*. Bratislava: Ekonomická univerzita v Bratislave, roč. 30, č. 4., s. 457-466.

Ďakujem za pozornosť