

ARMA modely
časť 4: Predikcie, odhadovanie parametrov

Beáta Stehlíková
Časové rady, FMFI UK, 2011/2012

IX.

Predikcie

Predikcie

- Sme v čase t , chceme **predikciu** hodnoty $x_{t+\tau}$, t. j. hodnotu procesu o τ období.
- Označme túto predikciu $\hat{x}_t(\tau)$, teda
 - ◇ index t označuje čas, v ktorom konštruujeme predikciu
 - ◇ argument τ označuje, na koľko období dopredu tá predikcia je
- Predikciou bude **očakávaná hodnota procesu** v tom čase, pri danej informácii, ktorú máme k dispozícii:

$$\hat{x}_t(\tau) = E_t[x_{t+\tau}]$$


(index t vo výraze E_t znamená, že strednú hodnotu počítame v čase t)

Predikcie pre AR proces

- Majme proces

$$x_t = 1.4x_{t-1} - 0.85x_{t-2} + u_t$$

a dáta:



- Chceme predikcie pre hodnoty v nasledujúcich časoch.

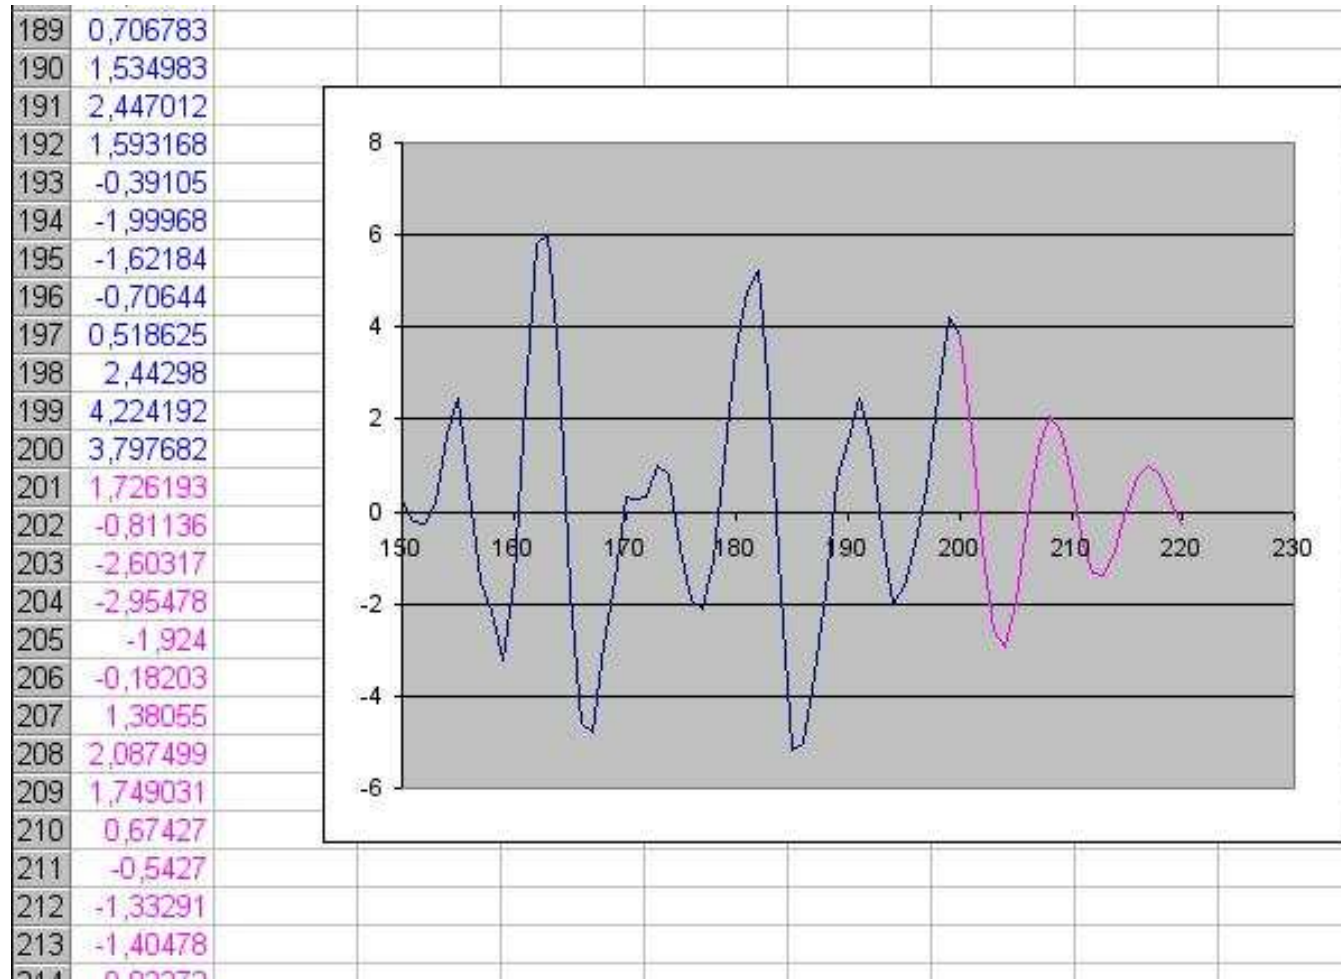
Predikcie pre AR proces

- Intuitívne:
 - ◇ do diferenčnej rovnice dosadzujeme známe hodnoty procesu a keď už k dispozícii nie sú, dosadzujeme predikcie
 - ◇ biely šum nahradíme nulou



Predikcie pre AR proces

- Výsledok:



Predikcie pre AR proces

- Vzt'ah $\hat{x}_t(\tau) = E_t[x_{t+\tau}]$ sa zhoduje s touto intuíciou.
- Majme AR(p) proces

$$x_t = \delta + \alpha_1 x_{t-1} + \dots + \alpha_p x_{t-p} + u_t.$$

Potom:

$$\begin{aligned} x_{t+\tau} &= \delta + \alpha_1 x_{t+\tau-1} + \dots + \alpha_p x_{t+\tau-p} + u_{t+\tau}, \\ \underbrace{E_t[x_{t+\tau}]}_{\hat{x}_t(\tau)} &= \delta + \alpha_1 E_t[x_{t+\tau-1}] + \dots + \alpha_p E_t[x_{t+\tau-p}] \\ &\quad + \underbrace{E_t[u_{t+\tau}]}_0 \end{aligned}$$

pričom

$$E_t[x_{t+s}] = \begin{cases} \hat{x}_t(s) & \text{pre } s > 0 \\ x_{t+s} & \text{pre } s \leq 0 \end{cases}$$

Predikcie pre MA proces

- Majme MA(1) proces

$$x_t = \mu + u_t - \beta u_{t-1}$$

a počítajme predikcie $\hat{x}_t(\tau)$:

$$\begin{aligned} x_{t+s} &= \mu + u_{t+s} - \beta u_{t+s-1}, \\ \underbrace{E_t[x_{t+s}]}_{\hat{x}_t(s)} &= \mu + \underbrace{E_t[u_{t+s}]}_0 - \beta \underbrace{E_t[u_{t+s-1}]}_{u_t \text{ pre } s=1, \text{ inak } 0} \end{aligned}$$

Teda:

$$\hat{x}_t(s) = \begin{cases} \mu - \beta u_t & \text{pre } s = 1 \\ \mu & \text{pre } s = 2, 3, \dots \end{cases}$$

- CVIČENIE: Dokážte, že pre MA(q) proces platí $\hat{x}_t(s) = \mu$ pre $s > q$ a že pre $s \leq q$ predikcie obsahujú realizované hodnoty bieleho šumu u

Predikcie pre MA proces

- Predikcie pre MA(1) proces $x_t = \mu + u_t - \beta u_{t-1}$ sú

$$\hat{x}_t(s) = \begin{cases} \mu - \beta u_t & \text{pre } s = 1 \\ \mu & \text{pre } s = 2, 3, \dots \end{cases}$$

- obsahujú hodnotu bieleho šumu u_t . Táto hodnota už bola v čase konštrukcie predikcií realizovaná, **nie sme však schopní ju pozorovať**.

- Cvičenie z predch. slajdu \Rightarrow podobná situácia nastáva pre ľubovoľný MA(q) proces
- **Ako prakticky počítať predikcie?**
Myšlienka: **vyjadríme u_t pomocou hodnôt procesu x**
- Tento výpočet si ukážeme na MA(1) procese

Predikcie pre MA proces

- Vyjadrujeme teda u_t pomocou x_1, x_2, \dots, x_t
- Využijeme pritom:

- ◇ Pre MA(1) sme odvodili

$$(1) \quad \hat{x}_t(1) = \mu - \beta u_t$$

- ◇ Pre predikčnú chybu platí

$$(2) \quad x_t - \hat{x}_{t-1}(1) = u_t$$

- Budeme postupne počítat' $\hat{x}_t(1)$ pre $t = 0, 1, 2, \dots$

$$(3) \quad \hat{x}_0(1) \stackrel{(1)}{=} \mu - \beta u_0$$

Predikcie pre MA proces

- Pre $t = 1$:

$$\hat{x}_1(1) \stackrel{(1)}{=} \mu - \beta u_1$$

$$\stackrel{(2)}{=} \mu - \beta[x_1 - \hat{x}_0(1)]$$

$$\stackrel{(3)}{=} \mu - \beta[x_1 - (\mu - \beta u_0)]$$

$$(4) \quad = \mu(1 + \beta) - \beta x_1 - \beta^2 u_0$$

- Pre $t = 2$:

$$\hat{x}_2(1) \stackrel{(1)}{=} \mu - \beta u_2$$

$$\stackrel{(2)}{=} \mu - \beta[x_2 - \hat{x}_1(1)]$$

$$\stackrel{(4)}{=} \mu - \beta[x_2 - (\mu(1 + \beta) - \beta x_1 - \beta^2 u_0)]$$

$$(5) \quad = \mu(1 + \beta + \beta^2) - \beta x_2 - \beta^2 x_1 - \beta^3 u_0$$

Predikcie pre MA proces

- Pre všeobecné t :

$$\begin{aligned}\hat{x}_t(1) &= \mu(1 + \beta + \beta^2 + \dots + \beta^t) \\ &\quad - \beta x_t - \beta^2 x_{t-1} - \dots - \beta^t x_1 - \beta^{t+1} u_0\end{aligned}$$

- Aj tu vystupuje nepozorovateľná hodnota u_0 , ale vplyv člena $\beta^{t+1} u_0$ ide k nule pre $t \rightarrow \infty$ (kde t je počet dát)
 \Rightarrow môžeme ho zanedbať

X.

Odhadovanie parametrov

Odhadovanie parametrov - EViews

- Viac možných prístupov k odhadovaniu parametrov, ukážeme si, čo robí softvér EViews, ktorý budeme používať na cvičeniach
- Ekonometria, 3. roč. - zápis odhadovanej rovnice napr.

$$y = c_0 + c_1 x_1 + c_2 x_2 + \varepsilon$$

- model $y = c_0 + c_1 x_1 + c_2 x_2 + \varepsilon$, kde ε je biely šum

- Vo všeobecnosti ε nemusí byť biely šum. Ak je ε napr. AR(1) proces, zapíšeme to

$$y = c_0 + c_1 x_1 + c_2 x_2 + \varepsilon_t$$

- V modeloch, ktorými sa teraz zaoberáme, nie sú regresory, takže AR(1) model píšeme

$$y = c_0 + \varepsilon_t$$

a znamená to $y = c_0 + \varepsilon_t$, kde ε_t je AR(1) proces s $\delta = 0$

Odhadovanie parametrov - EViews

- Vo všeobecnosti ARMA(p,q) model:

- ◊ Zápis ARMA(2,2) modelu:

$$y_t = c + ar(1) + ar(2) + ma(1) + ma(2)$$

- ◊ Výstup:

Dependent Variable: Y
Method: Least Squares
Date: 10/02/09 Time: 18:30
Sample (adjusted): 3 216
Included observations: 214 after adjustments
Convergence achieved after 16 iterations
Backcast: 1 2

$y_t = 0.945871 + \text{eps}_t$
 $\text{eps}_t = 0.009916 \text{eps}_{t-1} + 0.745537 \text{eps}_{t-2} + u_t + 1.172727 u_{t-1} + 0.327399 u_{t-2}$
u - biely šum

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.945871	0.481295	1.965263	0.0507
AR(1)	0.009916	0.117163	0.084634	0.9326
AR(2)	0.745537	0.110194	6.765656	0.0000
MA(1)	1.172727	0.118986	9.856026	0.0000
MA(2)	0.327399	0.069595	4.704361	0.0000

- Podrobnejšie na cvičení

Odhadovanie parametrov - AR

- Lineárny model s AR(1) chybami:

$$y_t = \mathbf{x}_t^T \boldsymbol{\beta} + \varepsilon_t$$

$$\varepsilon_t = \alpha \varepsilon_{t-1} + u_t$$

kde \mathbf{x}_t je vektor regresorov, u_t je biely šum

- Model sa dá upraviť do tvaru

$$(6) \quad y_t = \alpha y_{t-1} - (\mathbf{x}_t - \alpha \mathbf{x}_{t-1})^T \boldsymbol{\beta} + u_t$$

- Parametre α , $\boldsymbol{\beta}$ sa odhadujú z transformovaného modelu (6) nelineárnou metódou najmenších štvorcov
- Analogicky AR(p) model

Odhadovanie parametrov - MA

- Lineárny model s MA(q) chybami:

$$y_t = \mathbf{x}_t^T \boldsymbol{\beta} + \varepsilon_t$$

$$\varepsilon_t = u_t + \theta_1 u_{t-1} + \dots + \theta_q u_{t-q}$$

kde \mathbf{x}_t je vektor regresorov, u_t je biely šum

- Dáta sú pozorované v časoch $t = 1, 2, \dots, T$

Odhadovanie parametrov - MA

Postup I.

- Pre dané hodnoty θ, β :
 1. vypočítame rezíduá $\hat{\varepsilon}_t = y_t - \mathbf{x}_t^T \hat{\beta}$
 2. hodnoty bieleho šumu u pre $t = 0, -1, \dots, -(q + 1)$ (pred začiatkom pozorovania dát) položíme rovné nule: $\hat{u}_0 = 0, \hat{u}_{-1} = 0, \dots, \hat{u}_{-(q-1)} = 0$
 3. nasledujúce hodnoty u počítame rekurzívne:
$$\hat{u}_t = \hat{\varepsilon}_t - \hat{\phi}_1 \hat{u}_{t-1} - \dots - \hat{\phi}_q \hat{u}_{t-q}$$
 4. nakoniec minimalizujeme sumu štvorcov rezíduí
$$\sum_{t=1}^T \left(y_t - \mathbf{x}_t^T \beta - \phi_1 \hat{u}_{t-1} - \dots - \phi_q \hat{u}_{t-q} \right)^2 \rightarrow \min_{\theta, \beta}$$
- S novými hodnotami θ, β cyklus opakujeme, kým neskonverguje

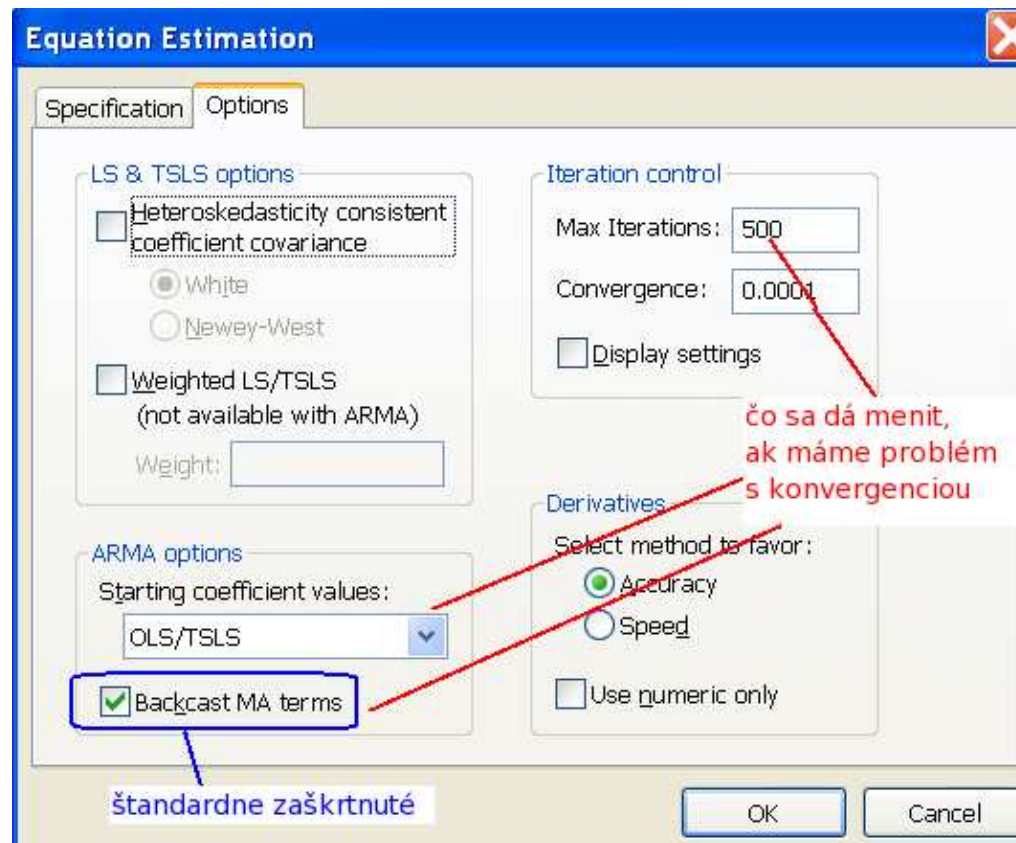
Odhadovanie parametrov - MA

Postup II. - backcasting

- Pre dané hodnoty θ, β :
 1. vypočítame rezíduá - *rovnako ako v postupe I.*
 2. **Backcast step** - hodnoty bieleho šumu u pre $t = T + 1, T + 2, \dots, T + q$ (po skončení pozorovania dát) položíme rovné nule: $\hat{u}_{T+1} = 0, \hat{u}_{T+2} = 0, \dots, \hat{u}_{T+q} = 0$ a spätne dorátame u_t až po $\hat{u}_0, \hat{u}_{-1}, \dots, \hat{u}_{-(q-1)}$
 3. nasledujúce hodnoty bieleho šumu u počítame rekurzívne - *rovnako ako v postupe I.*
 4. minimalizujeme sumu štvorcov rezíduí - *rovnako ako v postupe I.*
- S novými hodnotami θ, β cyklus opakujeme, kým neskongverguje

Odhadovanie parametrov - MA

- Backcasting v EViews:
 - ◇ V záložke *Options* pri odhadovaní modelu:



- ◇ Štandardne je táto možnosť zaškrtnutá

Odhadovanie parametrov

- Ukážka výstupu - treba si skontrolovať konvergenciu:

Dependent Variable: D(LOGPCOAO)
Method: Least Squares
Date: 10/18/11 Time: 12:29
Sample (adjusted): 1960M02 2002M09
Included observations: 512 after adjustments
Convergence achieved after 6 iterations
MA Backcast: 1960M01

	Coefficient	Std. Error	t-Statistic	Prob.
C	0.002454	0.003738	0.656614	0.5117
MA(1)	0.352651	0.041550	8.487292	0.0000
R-squared	0.112273	Mean dependent var		0.002398
Adjusted R-squared	0.110532	S.D. dependent var		0.066320
S.E. of regression	0.062548	Akaike info criterion		-2.701880
Sum squared resid	1.995221	Schwarz criterion		-2.685324
Log likelihood	693.6813	Hannan-Quinn criter.		-2.695390
F-statistic	64.50096	Durbin-Watson stat		1.987519
Prob(F-statistic)	0.000000			
Inverted MA Roots	-0.35			