

ARMA modely časť 3: zmiešané modely (ARMA)

Beáta Stehlíková
Časové rady, FMFI UK, 2011/2012

AR a MA modely - zhrnutie

Majme stacionárny a invertovateľný proces:

	$AR(p)$	$MA(q)$
$ACF(\tau)$	nenulová	0 pre $\tau > q$
$PACF(\tau)$	0 pre $\tau > p$	nenulová
$AR(\infty)$ reprezentácia	konečný súčet	nekonečný súčet
$MA(\infty)$ repr. (Wold)	nekonečný súčet	konečný súčet

- Žiadny z týchto modelov neprípúšťa možnosť, že sa ani ACF, ani PACF nevynuluje po konečnom počte členov
- Na to by sme potrebovali proces s nekonečnou AR aj MA reprezentáciou
- Túto vlastnosť majú zmiešané ARMA modely (zmiešané = AR aj MA členy)

VII.

Model ARMA(1,1)

ARMA(1,1) - definícia

- Nech u_t je biely šum, definujeme

$$x_t = \delta + \alpha x_{t-1} + u_t - \beta u_{t-1},$$

pričom $\alpha \neq \beta$. Proces x_t sa potom nazýva ARMA(1,1) proces.

- Zápis pomocou operátora posunu L :

$$(1) \quad \begin{aligned} (x_t - \alpha x_{t-1}) &= \delta + (u_t - \beta u_{t-1}) \\ (1 - \alpha L)x_t &= \delta + (1 - \beta L)u_t \end{aligned}$$

ARMA(1,1) - Woldova repr. a stacionarita

- Vyjadríme z (1) proces x_t :

$$(2) \quad x_t = (1 - \alpha L)^{-1}\delta + (1 - \alpha L)^{-1}(1 - \beta L)u_t$$

- Vieme, že $(1 - \alpha L)^{-1}$ existuje, ak $|\alpha| < 1$ a v tomto prípade platí:

$$(1 - \alpha L)^{-1} = 1 + \alpha L + \alpha^2 L^2 + \dots$$

- Dosadíme do (2):

$$\begin{aligned} x_t &= \delta/(1 - \alpha) + (1 + \alpha L + \alpha^2 L^2 + \dots)(1 - \beta L)u_t \\ &= \delta/(1 - \alpha) + u_t + (\alpha - \beta)u_{t-1} + \alpha(\alpha - \beta)u_{t-2} + \dots \end{aligned}$$

teda vo Woldovej reprezentácii

$$\psi_0 = 1, \psi_1 = \alpha(\alpha - \beta), \psi_2 = \alpha^2(\alpha - \beta), \dots, \psi_k = \alpha^k(\alpha - \beta), \dots$$

- Podmienka stacionarity $|\alpha| < 1$ sa dá zapísat' aj tak, že koreň polynómu $1 - \alpha L$ musí byť mimo jednotkového kruhu

ARMA(1,1) - invertovateľnosť

- Vyjadríme z (1) proces bieleho šumu u_t , aby sme dostali proces x_t vyjadrený pomocou jeho starších hodnôt + aktuálnej hodnoty bieleho šumu:

$$\begin{aligned} -\delta + (1 - \alpha L)x_t &= (1 - \beta L)u_t \\ -(1 - \beta L)^{-1}\delta + (1 - \beta L)^{-1}(1 - \alpha L)x_t &= u_t \end{aligned}$$

- Vieme, že inverzný operátor $(1 - \beta L)^{-1}$ existuje, ak $|\beta| < 1$
- Táto podmienka invertovateľnosti sa dá zapísat' aj tak, že koreň polynómu $1 - \beta L$ musí byť mimo jednotkového kruhu

ARMA(1,1) - zhrnutie

- Pripomeňme si proces (1):

$$(1 - \alpha L)x_t = \delta + (1 - \beta L)u_t$$

- Podmienka stacionarity:
 - ◊ koreň polynómu $1 - \alpha L$ je mimo jednotkového kruhu
 - ◊ závisí teda iba od AR časti procesu
- Podmienka invertovateľnosti:
 - ◊ koreň polynómu $1 - \beta L$ je mimo jednotkového kruhu
 - ◊ závisí teda iba od MA časti procesu

ARMA(1,1) - momenty

- Stredná hodnota μ :

$$x_t = \delta + \alpha x_{t-1} + u_t - \beta u_{t-1} \quad / \quad E[.]$$

$$\mu = \delta + \alpha\mu + 0 \Rightarrow \mu = \frac{\delta}{1 - \alpha}$$

- Variancia, autokovariancie - pre $\delta = 0$:

$$x_t = \alpha x_{t-1} + u_t - \beta u_{t-1} \quad / \quad \times x_{t-s}, \quad E[.]$$

$$E[x_t x_{t-s}] = \alpha E[x_{t-1} x_{t-s}] + E[u_t x_{t-s}] - \beta E[u_{t-1} x_{t-s}]$$

$$(3) \quad \gamma(s) = \alpha \gamma(s-1) + E[u_t x_{t-s}] - \beta E[u_{t-1} x_{t-s}]$$

Stredná hodnota $E[u_t x_{t-s}]$ je nenulová len pre $s = 0$,
stredná hodnota $E[u_{t-1} x_{t-s}]$ je nenulová len pre $s = 0$ a
pre $s = 1$

ARMA(1,1) - momenty (pokračovanie)

- Konkrétné hodnoty $E[u_t x_{t-s}]$ a $E[u_{t-1} x_{t-s}]$ vypočítame z Woldovej reprezentácie

$$x_{t-s} = u_{t-s} + (\alpha - \beta)u_{t-s-a} + \alpha(\alpha - \beta)u_{t-s-2} + \dots$$

Dostaneme:

$$E[u_t x_{t-s}] = \begin{cases} \sigma^2 & \text{pre } \tau = 0 \\ 0 & \text{pre } \tau = 1, 2, 3, \dots \end{cases}$$

$$E[u_{t-1} x_{t-s}] = \begin{cases} (\alpha - \beta)\sigma^2 & \text{pre } \tau = 0 \\ \sigma^2 & \text{pre } \tau = 1 \\ 0 & \text{pre } \tau = 2, 3, \dots \end{cases}$$

a dosadíme do (3).

ARMA(1,1) - momenty (pokračovanie)

- Nakoniec z (3) dostaneme pre $s = 0, s = 1$:

$$\begin{aligned}s = 0 \Rightarrow \gamma(0) &= \alpha\gamma(1) + \sigma^2 - \beta(\alpha - \beta)\sigma^2 \\ s = 1 \Rightarrow \gamma(1) &= \alpha\gamma(0) - \beta\sigma^2\end{aligned}$$

→ sústava 2 rovníc s 2 neznámymi, jej riešením je

$$\begin{aligned}\gamma(0) &= \frac{1 + \beta^2 - 2\alpha\beta}{1 - \alpha^2}\sigma^2, \gamma(1) = \frac{(\alpha - \beta)(1 - \alpha\beta)}{1 - \alpha^2}\sigma^2 \\ (4)\end{aligned}$$

- Pre $s = 2, 3, \dots$ dostaneme rekurentný predpis pre ďalšie $\gamma(s)$:

$$\gamma(s) = \alpha\gamma(s - 1)$$

ARMA(1,1) - ACF

- Pre $s = 2, 3, \dots$ máme

$$\begin{aligned}\gamma(s) &= \alpha\gamma(s-1) && \left/ \frac{1}{\gamma(0)} \right. \\ \rho(s) &= \alpha\rho(s-1)\end{aligned}$$

→ tá istá diferenčná rovnica pre ACF, ako by bola pre proces bez MA časti

- ale s inou začiatočnou podmienkou - zo vztahu (4) máme

$$\rho(1) = \frac{\gamma(1)}{\gamma(0)} = \frac{(\alpha - \beta)(1 - \alpha\beta)}{(1 + \beta^2 - 2\alpha\beta)}$$

- závisí aj od MA časti

ARMA(1,1) - PACF

- PACF počítame rovnako ako predtým pomocou determinantov:

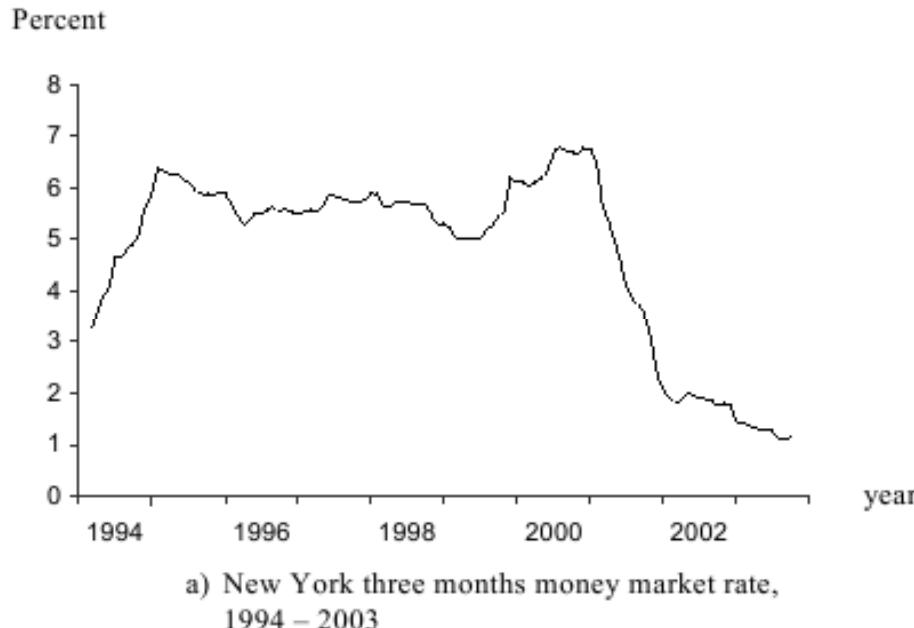
$$(5) \quad \Phi_{kk} = \frac{\det \begin{pmatrix} 1 & \rho(1) & \dots & \rho(1) \\ \rho(1) & 1 & \dots & \rho(2) \\ \dots & \dots & \dots & \dots \\ \rho(k-1) & \rho(k-2) & \dots & \rho(k) \end{pmatrix}}{\det \begin{pmatrix} 1 & \rho(1) & \dots & \rho(k-1) \\ \rho(1) & 1 & \dots & \rho(k-2) \\ \dots & \dots & \dots & \dots \\ \rho(k-1) & \rho(k-2) & \dots & 1 \end{pmatrix}}$$

pričom teraz $\rho(k) = \alpha^{k-1}\rho(1)$

Príklad - reálne dáta

[Kirchgässner, Wolters], example 2.15

- USA, marec 1994 - august 2003
- USR_t = 3-mesačná úroková miera



Príklad - reálne dáta

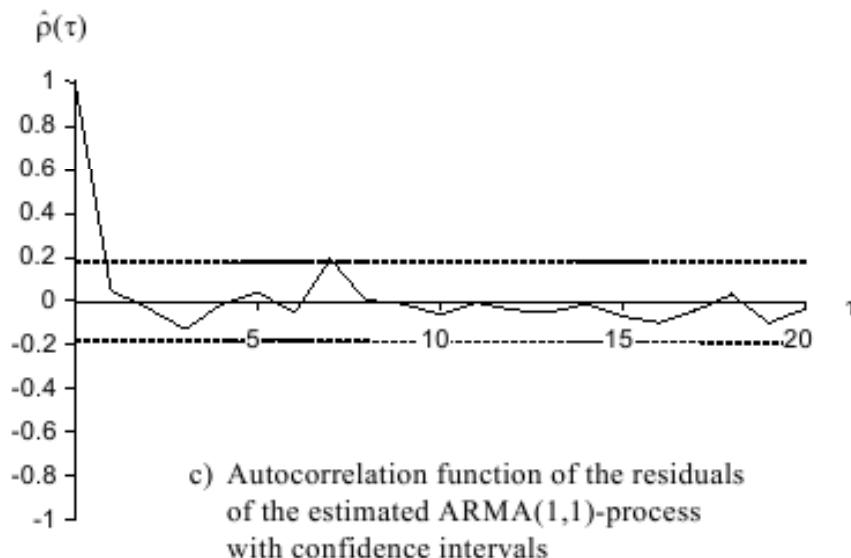
Odhadnutý model pre diferencie premennej *USR*:

The following ARMA(1,1) model has been estimated for this time series:

$$\Delta \text{USR}_t = -0.006 + 0.831 \Delta \text{USR}_{t-1} + \hat{u}_t - 0.457 \hat{u}_{t-1}, \\ (-0.73) \quad (10.91) \quad \quad \quad (-3.57)$$

$$\bar{R}^2 = 0.351, \text{ SE} = 0.166, \text{ Q}(10) = 7.897 \text{ (p} = 0.639).$$

The AR(1) as well as the MA(1) terms are different from zero at the 0.1 percent significance level. The autocorrelogram of the estimated residuals, which is also given in *Figure 2.10*, as well as the Box-Ljung Q statistic, which is calculated for this model with 12 autocorrelation coefficients (i.e. with 10 degrees of freedom), do not provide any evidence of a higher order process.



Príklad - reálne dáta

Otázky k výstupu:

- Je odhadnutý model stacionárny? Je invertovateľný?
- "*The autocorrelogram of the estimated residuals... not provide any evidence of a higher order process*" - vysvetlite
- "...*the Box-Ljung Q statistic, which is calculated for this model with 12 autocorrelation coefficients (i.e. with 10 degrees of freedom)*..."
 - ◊ sformulujte nulovú hypotézu, ktorá sa tu testuje
 - ◊ zdôvodnite počet stupňov volnosti
 - ◊ aký je záver testu?

VIII.

Model ARMA(p,q)

ARMA(p,q) - definícia

- Nech u_t je biely šum, definujeme

$$x_t = \delta + \alpha_1 x_{t-1} + \dots + \alpha_p x_{t-p} + u_t - \beta_1 u_{t-1} - \dots - \beta_q u_{t-q},$$

tento proces sa potom nazýva ARMA(p,q) proces.

- Zápis pomocou operátora posunu L :

$$(1 - \alpha_1 L - \dots - \alpha_p L^p)x_t = \delta + (1 - \beta_1 L - \dots - \beta_q L^q)u_t$$

(6) $\alpha(L)x_t = \delta + \beta(L)u_t$

pričom požadujeme, aby polynómy $\alpha(L)$, $\beta(L)$ nemali spoločný koreň (podrobnejšie o tejto podmienke neskôr)

$ARMA(p,q)$ - Woldova repr., stacionarita

- Z rovnice (6) vyjadríme x_t :

$$\begin{aligned}\alpha(L)x_t &= \delta + \beta(L)u_t \\ x_t &= \alpha(L)^{-1}\delta + \alpha(L)^{-1}\beta(L)u_t\end{aligned}$$

- Potrebujeme $\alpha(L)^{-1}\beta(L)$:

$$\begin{aligned}\alpha(L)^{-1}\beta(L) &= \psi_0 + \psi_1 L + \psi_2 L^2 + \dots \\ \beta(L) &= \alpha(L)(\psi_0 + \psi_1 L + \psi_2 L^2 + \dots) \\ (1 - \beta_1 L - \dots - \beta_q L^q) &= (1 - \alpha_1 L - \dots - \alpha_p L^p) \times \\ &\quad \times (\psi_0 + \psi_1 L + \psi_2 L^2 + \dots)\end{aligned}$$

Roznásobíme a porovnáme koeficinety pri L^j

$ARMA(p,q)$ - Woldova repr., stacionarita

- Pre koeficinety ψ_j Woldovej reprezentácie dostaneme:
 - ◊ diferenčnú rovnicu
$$\psi_k - \alpha_1\psi_{k-1} - \dots - \alpha_p\psi_{k-p} = 0$$
 - ◊ začiatočné podmienky
- Kvôli konvergencii radu $\sum \phi_j^2$ musia byť korene charakteristického polynómu $\lambda^p - \alpha_1\lambda^{p-1} - \dots - \alpha_p = 0$ vnútri, t.j. korene $\alpha(L) = 0$ mimo jednotkového kraja

ARMA(p,q) - invertovateľnosť

- Z rovnice (6) vyjadríme u_t :

$$\begin{aligned}\alpha(L)x_t &= \delta + \beta(L)u_t \\ \beta(L)u_t &= -\delta + \alpha(L)x_t \\ u_t &= -\beta(L)^{-1}\delta + \beta(L)^{-1}\alpha(L)x_t\end{aligned}$$

- Toto sa dá spraviť, ak existuje inverzný operátor $\beta(L)^{-1}$, čo je vtedy, keď korene $\beta(L) = 0$ sú mimo jednotkového kruhu

ARMA(p,q) - momenty

- Stredná hodnota: μ :

$$x_t = \delta + \alpha_1 x_{t-1} + \dots + \alpha_p x_{t-p} + u_t - \beta_1 u_{t-1} - \dots - \beta_q u_{t-q}$$

$$\mu = \delta + \alpha_1 \mu + \dots + \alpha_p \mu \Rightarrow \mu = \frac{\delta}{1 - \alpha_1 - \dots - \alpha_p}$$

- Variancia, autokovariancie - nech $\delta = 0$:

$$x_t = \alpha_1 x_{t-1} + \dots + \alpha_p x_{t-p} + u_t - \beta_1 u_{t-1} - \dots - \beta_q u_{t-q}$$

$$\quad / \quad \times x_{t-s}, E[.]$$

$$\begin{aligned}\gamma(s) &= \alpha_1 \gamma(s-1) + \dots + \alpha_p \gamma(s-p) \\ &\quad + E[u_t x_{t-s}] - \beta_1 E[u_{t-1} x_{t-s}] - \dots - \beta_q E[u_{t-q} x_{t-s}]\end{aligned}$$

$ARMA(p,q)$ - momenty

- Pre $s > q$ sú všetky stredné hodnoty

$$E[u_t x_{t-s}], E[u_{t-1} x_{t-s}], \dots, E[u_{t-p} x_{t-s}]$$

nulové \Rightarrow pre $s > q \wedge s > p$ (lebo na použitie nasledujúcej diferenčnej rovnice potrebujeme aspoň p začiatočných hodnôt) máme diferenčnú rovnicu pre autokovariancie:

$$(7) \quad \gamma(s) = \alpha_1 \gamma(s-1) + \dots + \alpha_p \gamma(s-p)$$

- ACF - vydelením (7) varianciou $\gamma(0)$ dostaneme diferenčnú rovnicu pre autokorelácie $\rho(s)$,
 $s > \max(p, q)$:

$$(8) \quad \rho(s) = \alpha_1 \rho(s-1) + \dots + \alpha_p \rho(s-p)$$

- rovnaká diferenčná rovnica ako pre proces bez MA časti, začiatočné pomienky však MA koeficienty obsahujú

ARMA(p,q) - spoločné AR a MA korene

- Pripomeňme si definíciu ARMA(p,q) procesu:

$$(1 - \alpha_1 L - \dots - \alpha_p L^p)x_t = \delta + (1 - \beta_1 L - \dots - \beta_q L^q)u_t$$
$$\alpha(L)x_t = \delta + \beta(L)u_t$$

pričom požadujeme, aby polynómy $\alpha(L)$, $\beta(L)$ nemali spoločné korene

- Prečo nemôžu mať polynómy $\alpha(L)$, $\beta(L)$ spoločné korene?

$ARMA(p,q)$ - spoločné AR a MA korene

- Uvažujme "ARMA(2,2)" proces

$$(1 - \alpha_1 L - \alpha_2 L^2)x_t = \delta + (1 - \beta_1 L - \beta_2 L^2)u_t,$$

kde $1 - \alpha_1 L - \alpha_2 L^2 = (1 - \gamma L)(1 - \gamma_1 L)$

$$1 - \beta_1 L - \beta_2 L^2 = (1 - \gamma L)(1 - \gamma_2 L)$$

t.j. AR a MA polynómy majú spoločný koreň γ

- Potom sa proces dá zapísat' nasledovne:

$$(1 - \gamma L)(1 - \gamma_1 L)x_t = \delta + (1 - \gamma L)(1 - \gamma_2 L)u_t$$

$$(1 - \gamma_1 L)x_t = (1 - \gamma L)^{-1}\delta + (1 - \gamma_2 L)u_t$$

teda je to ARMA(1,1), a nie ARMA(2,2) model

- Prakticky - ak dostaneme veľmi blízky AR a MA koreň, treba namiesto ARMA(p,q) skúsiť ARMA($p-1,q-1$) model

$ARMA(p,q)$ - príklad

- Príklad: ARMA(1,2) model pre diferencie zlogaritmovaných cien kakaa (dáta z minulej prednášky):

Dependent Variable: D(LOGPCOCOA)
Method: Least Squares
Sample (adjusted): 1960M03 2002M09
Included observations: 511 after adjustments
Convergence achieved after 21 iterations
Backcast: 1960M01 1960M02

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.003280	0.003372	0.972740	0.3311
AR(1)	0.966348	0.057950	16.67548	0.0000
MA(1)	-0.617571	0.069076	-8.940414	0.0000
MA(2)	-0.346508	0.043644	-7.939449	0.0000
R-squared	0.113498	Mean dependent var	0.002484	
Adjusted R-squared	0.108252	S.D. dependent var	0.066356	
S.E. of regression	0.062662	Akaike info criterion	-2.694338	
Sum squared resid	1.990726	Schwarz criterion	-2.661176	
Log likelihood	692.4033	F-statistic	21.63688	
Durbin-Watson stat	1.984577	Prob(F-statistic)	0.000000	
Inverted AR Roots	.97			
Inverted MA Roots	.97	-.36		

$ARMA(p,q)$ - príklad

- Model vyzera vyhovujúco - je stacionárny aj invertovateľný:

Inverse Roots of AR/MA Polynomial(s)
Specification: D(LOGPCOCOA) C AR(1) MA(1) MA(2)
Sample: 1960M01 2002M09
Included observations: 511

AR Root(s)	Modulus	Cycle
0.966348	0.966348	

No root lies outside the unit circle.
ARMA model is stationary.

MA Root(s)	Modulus	Cycle
0.973508	0.973508	
-0.355937	0.355937	

No root lies outside the unit circle.
ARMA model is invertible.

$ARMA(p,q)$ - príklad

- Má aj dobré rezíduá:

Correlogram of Residuals						
Sample: 1960M03 2002M09 Included observations: 511 Q-statistic probabilities adjusted for 3 ARMA term(s)						
	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
:			1	0.005	0.005	0.0125
:			2	-0.000	-0.000	0.0126
:			3	-0.010	-0.010	0.0623
:			4	0.037	0.037	0.7712 0.380
:			5	-0.052	-0.053	2.1866 0.335
:			6	0.041	0.042	3.0601 0.382
:			7	-0.057	-0.058	4.7707 0.312
:			8	0.030	0.029	5.2347 0.388
:			9	0.037	0.041	5.9483 0.429
:			10	0.092	0.085	10.352 0.170
:			11	-0.000	0.007	10.352 0.241
:			12	-0.004	-0.012	10.359 0.322
:			13	-0.010	-0.004	10.416 0.405
:			14	-0.009	-0.017	10.460 0.490
:			15	0.000	0.000	0.0000

$ARMA(p,q)$ - príklad

- Ale: AR koreň je blízko jedného z MA koreňov:

Dependent Variable: D(LOGPCOCOA)		
Method: Least Squares		
Sample (adjusted): 1960M03 2002M09		
Included observations: 511 after adjustments		
Convergence achieved after 21 iterations		
Backcast: 1960M01 1960M02		
Variable	Coefficient	Std. Error
C	0.003280	0.003372
AR(1)	0.966348	0.057950
MA(1)	-0.617571	0.069076
MA(2)	-0.346508	0.043644
R-squared	0.113498	Mean dependent var
Adjusted R-squared	0.108252	S.D. dependent var
S.E. of regression	0.062662	Akaike info criterion
Sum squared resid	1.990726	Schwarz criterion
Log likelihood	692.4033	F-statistic
Durbin-Watson stat	1.984577	Prob(F-statistic)
Inverted AR Roots	.97	
Inverted MA Roots	.97	-36

Inverse Roots of AR/MA Polynomial(s)
Specification: D(LOGPCOCOA) C AR(1) MA(1) MA(2)
Sample: 1960M01 2002M09
Included observations: 511

AR Root(s)	Modulus	Cycle
0.966348	0.966348	

No root lies outside the unit circle.
ARMA model is stationary.

MA Root(s)	Modulus	Cycle
0.973508	0.973508	

No root lies outside the unit circle.
ARMA model is invertible.

- Mali by sme teda namiesto $ARMA(1,2)$ skúsiť $ARMA(0,1) = MA(1)$ model, a ten naozaj na minulej prednáške vyšiel ako dobrý model pre tieto dátá