

# ARMA modely

Beáta Stehlíková

Časové rady

Fakulta matematiky, fyziky a informatiky, UK v Bratislavе

ARMA modely

└ ARMA procesy, motivácia ku kombinácii AR a MA členov

## ARMA procesy, motivácia ku kombinácii AR a MA členov

## ARMA procesy

- ▶ ARMA procesy
  - ▶ obsahujú autoregresné (AR) členy typu  $x_{t-1}, x_{t-2}, \dots$
  - ▶ obsahujú *moving average* (MA) členy typu  $u_{t-1}, u_{t-2}, \dots$
- ▶ ARMA(p,q) má tvar

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

- ▶ Odhadovanie v balíku astsa:

```
sarima(data, p, 0, q) # ARMA(p,q) pre data  
sarima(data, p, k, q) # ARMA(p,q) pre k-te diferencie
```

## Ukážka použitia ARMA modelov

*D. Rawat et al.: Modeling of rainfall time series using NAR and ARIMA model over western Himalaya, India. Arabian Journal of Geosciences, 15(23), 2022.*

---

### Himachal Pradesh

---

Month/season/year	Model
Jan	ARIMA (1, 1, 1)
Feb	ARIMA (3, 1, 1)
Mar	ARIMA (2, 1, 4)
April	ARIMA (1, 1, 1)
May	ARIMA (1, 1, 1)
June	ARIMA (1, 1, 1)
July	ARIMA (4, 1, 0)
Aug	ARIMA (2, 1, 1)
Sep	ARIMA (1, 1, 1)
Oct	ARIMA (1, 1, 1)

---

Month/season/year	Model
Jan	ARIMA (1, 1, 1)
Feb	ARIMA (3, 1, 1)
Mar	ARIMA (2, 1, 4)
April	ARIMA (1, 1, 1)
May	ARIMA (1, 1, 1)
June	ARIMA (1, 1, 1)
July	ARIMA (4, 1, 0)
Aug	ARIMA (2, 1, 1)
Sep	ARIMA (1, 1, 1)
Oct	ARIMA (1, 1, 1)

---


## Reálne dátá: výmenné kurzy

- ▶ Dáta o výmenných kurzoch z prednášky o MA procesoch
- ▶ Zoberieme výmenný kurz s CZK v rokoch 2020-2021.
- ▶ Znovu modelujeme diferencie logaritmov


```
library(astsa)
load("ARMAprednaska.Rdata")
head(dataCZK)
```

```
##           Date      CZK
## 946 2020-01-02 25.411
## 945 2020-01-03 25.360
## 944 2020-01-06 25.301
## 943 2020-01-07 25.276
## 942 2020-01-08 25.265
## 941 2020-01-09 25.253
```

```
plot(dataCZK$CZK, type = "l")
```



```
x <- diff(log(dataCZK$CZK))  
acf2(x)
```



## Čo v takejto situácii:

- ▶ Odhadneme ACF a PACF z dát a nepodobajú sa ani na AR, ani na MA proces
- ▶ Žiadny z AR a MA modelov nepripúšťa možnosť, že sa ani ACF, ani PACF nevynuluje po konečnom počte členov

## Konkrétnie v našom prípade:

- ▶ Tu by sme odhadovali AR(5) alebo MA(5)
- ▶ Otázka je, či by sa nedal nájsť model v inom tvare s menším počtom členov

- Pripomeňme si:

	AR( $p$ )	MA( $q$ )
ACF( $k$ )	nenulová	nulová pre $k > q$
PACF( $k$ )	nulová pre $k > p$	nenulová
MA( $\infty$ ) - Wold	nekonečná suma	konečná suma
AR( $\infty$ )	konečná suma	nekonečná suma

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

- ▶ Pre naše dátá - testujeme rezíduá Ljung-Boxovým testom:
  - ▶ AR(1), AR(2), AR(3), AR(4) majú zlé rezíduá
  - ▶ AR(5) je v poriadku
  - ▶ MA(1), MA(2), MA(3), MA(4) majú zlé rezíduá
  - ▶ MA(5) je v poriadku
  - ▶ ARMA(3,1) je tiež dobrý model
- ▶ Porovnáme Bayesovo informačné kritérium → **ARMA(3,1)** je **najlepší**

```
BICkrit <- c(sarima(x, 5, 0, 0, details = FALSE)$BIC,
              sarima(x, 0, 0, 5, details = FALSE)$BIC,
              sarima(x, 3, 0, 1, details = FALSE)$BIC)
names(BICkrit) <- c("AR(5)", "MA(5)", "ARMA(3,1)")
sort(BICkrit, decreasing = TRUE)
```

```
##      AR(5)      MA(5) ARMA(3,1)
## -8.320808 -8.325124 -8.330932
```

- ▶ Odhadnuté koeficienty:

```
arma31 <- sarima(x, 3, 0, 1, details = FALSE)  
arma31$fit$coef
```

```
##           ar1           ar2           ar3           ma1  
## -7.533214e-01  1.361270e-01  2.511709e-01  7.051347e-01
```

- ▶ Ak predpokladáme stacionaritu (podmienky odvodíme neskôr), odhadnutý model je

$$x_t = \delta - 0.753x_{t-1} + 0.136x_{t-2} + 0.251x_{t-3} + u_t + 0.705u_{t-1},$$

pričom  $\delta$  je taká, aby platilo, že  $\mathbb{E}(x_t) = -0.753$

ARMA modely

└ Model ARMA(1,1)

## Model ARMA(1,1)

## Definícia

- ▶ Nech  $u_t$  je biely šum, definujme ARMA(1,1) proces ako

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

pričom  $\alpha \neq \beta$  (k tej podmienke sa ešte vrátime)

- ▶ Zápis pomocou operátora  $L$ :

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

## Woldova reprezentácia a stacionarita

- ▶ Vyjadríme proces  $x_t$ :

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

- ▶ Inverzný operátor  $(1 - \alpha L)^{-1}$  existuje pre  $|\alpha| < 1$  (podmienka stacionarity pre AR(1) proces), v tom prípade

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

- ▶ Podmienka stacionarity ARMA(1,1) procesu
  - ▶ je teda rovnaká ako pre AR(1) proces
  - ▶ je ňou nerovnosť  $|\alpha| < 1$
  - ▶ to sa dá zapísať aj tak, že koreň polynómu  $1 - \alpha L$  je mimo jednotkového kruhu

- ▶ Woldova reprezentácia potom je

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

teda jej koeficienty sú

$$\phi_0 = 1, \phi_1 = \alpha - \beta, \phi_2 = \alpha(\alpha - \beta), \dots, \phi_k = \alpha^{k-1}(\alpha - \beta)$$

## O podmienke $\alpha \neq \beta$

- ▶ Máme Woldovu reprezentáciu

$$x_t = \frac{\delta}{1 - \alpha} + u_t + (\alpha - \beta)u_{t-1} + \alpha(\alpha - \beta)u_{t-2} + \dots$$

- ▶ Ak by bolo  $\alpha = \beta$ , tak máme

$$x_t = \frac{\delta}{1 - \alpha} + u_t$$

a teda náš proces by bol iba biely šum posunutý o konštantu.

## Invertovateľnosť

- ▶ Vyjadríme z proces  $u_t$ , aby sme dostali proces  $x_t$  vyjadrený pomocou jeho starších hodnôt a aktuálnej hodnoty bieleho šumu

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

- ▶ Vieme, že podmienkou pre existenciu  $(1 - \beta L)^{-1}$  je nerovnosť  $|\beta| < 1$
- ▶ Táto podmienka invertovateľnosti sa dá zapísať aj tak, že koreň polynómu  $1 - \beta L$  musí byť mimo jednotkového kruhu

## Zhrnutie

- ▶ Uvažujeme proces

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

- ▶ Podmienka *stacionarity*
  - ▶ koreň polynómu  $1 - \alpha L$  mimo jednotkového kruhu
  - ▶ závisí teda iba od *AR* časti
- ▶ Podmienka *invertovateľnosti*
  - ▶ koreň polynómu  $1 - \beta L$  mimo jednotkového kruhu
  - ▶ závisí teda iba od *MA* časti

**Cvičenie 1.** Odvodte (t. j. spravte všetky kroky odvodenia, nedosadzujte do získaných všeobecných výsledkov) Woldovu reprezentáciu ARMA(1,1) procesu

$$x_t = 2 + 0.5x_{t-1} + u_t - 0.7u_{t-1}$$

ARMA modely

└ Model ARMA(p,q)

Model ARMA(p,q)

## Definícia

- ▶ Nech  $u_t$  je biely šum, definujme ARMA(p,q) proces ako

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

teda v operátorovom tvare

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

resp. po označení polynómov

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

- ▶ Požadujeme, aby polynómy  $\alpha(L), \beta(L)$  nemali spoločné korene (k tejto podmienke sa vrátim, ide o zovšeobecnenie podmienky  $\alpha \neq \beta$  z ARMA(1,1) procesu)

## Woldova reprezentácia a stacionarita

- ▶ Vyjadríme proces  $x_t$ :

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

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

$$\alpha(L)^{-1}\beta(L) = \psi_0 + \psi_1 L + \psi_2 L^2 + \dots$$

$$\beta(L) = \alpha(L)(\psi_0 + \psi_1 L + \psi_2 L^2 + \dots)$$

$$\beta(L) = (1 - \alpha_1 L - \dots - \alpha_p L^p)$$

$$\times (\psi_0 + \psi_1 L + \psi_2 L^2 + \dots)$$

roznásobíme a porovnáme mocniny pri  $L^j$

- ▶ Pre koeficienty  $\psi_j$  Woldovej reprezentácie dostaneme
  - ▶ diferenčnú rovnicu  $\psi_k - \alpha_1\psi_{k-1} - \dots - \alpha_p\psi_{k-p} = 0$
  - ▶ začiatočné podmienky
- ▶ Kvôli požiadavke na konvergenciu sumy  $\sum \psi_j^2$  musia byť korene charakteristického polynómu  $\lambda^p - \alpha_1\lambda^{p-1} - \dots - \alpha_{p-1}\lambda - \alpha_p$  v absolútnej hodnote menšie ako 1, teda korene polynómu  $\alpha(L)$  musia byť v absolútnej hodnote väčšie ako 1

## Invertovateľnosť

- Z predpisu pre ARMA proces

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

potrebujeme vyjadriť  $u_t$ :

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

- Analogicky ako pri odvodzovaní stacionarity dostaneme, že toto sa dá spraviť, ak korene polynómu  $\beta(L)$  sú v absolútnej hodnote väčšie ako 1
- Geometricky: korene polynómu

$$\beta(L) = 1 - \beta_1L - \dots - \beta_qL^q$$

musia byť mimo jednotkového kruhu

**Cvičenie 2.** Overíme stacionaritu a invertovateľnosť ARMA procesu

$$x_t = 2 + 0.5x_{t-1} - 0.15x_{t-2} + u_t - 0.35u_{t-1} + 0.6u_{t-2}$$

**Riešenie:** Proces prepíšeme ako

$$(1 - 0.5L + 0.15L^2)x_t = 2 + (1 - 0.35L + 0.6L^2)u_t$$

```
abs(polyroot(c(1, -0.5, 0.15))) # -> stacionarita
```

```
## [1] 2.581989 2.581989
```

```
abs(polyroot(c(1, -0.35, 0.6))) # -> invertovatelnost
```

```
## [1] 1.290994 1.290994
```

**Cvičenie 3.** Overte stacionaritu a invertovateľnosť modelu, ktorý sme dostali na str. 10. Spravte tieto výpočty s presnými hodnotami.

## Stredná hodnota

- Zoberme stacionárny ARMA proces

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

- Spravíme strednú hodnotu z oboch strán.
- Zo stacionarity vyplýva, že v každom čase  $s$  je stredná hodnota rovnaká, označme ju  $\mu$ :

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

**Cvičenie 4.** Čomu sa rovná konštantă  $\delta$  v modeli pre dátá výmenných kurzov (str. 10)?

## Disperzia, autokovariancie

- Môžeme znova predpokladať, že  $\delta = 0$  (posun procesu o konštantu nezmení disperziu ani autokovariancie)
- Proces

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

vynásobíme  $x_{t-s}$  (pre  $s = 0, 1, 2, \dots$ ) a spravíme strednú hodnotu:

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

- ▶ Pre  $s > q$  sú nulové všetky stredné hodnoty

$$\mathbb{E}(u_t x_{t-s}), \mathbb{E}(u_{t-1} x_{t-s}), \dots, \mathbb{E}(u_{t-q} x_{t-s})$$

- ▶ Vtedy platí diferenčná rovnica

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

- ▶ Táto diferenčná rovnica potrebuje  $p$  začiatočných podmienok
- ▶ Začiatočné podmienky sa počítajú zo sústavy rovníc
- ▶ Preto (1) budeme používať pre  $s > \max(p, q)$
- ▶ Začiatočné podmienky dostaneme z rovníc získaných pre  $s = 0, 1, \dots, \max(p, q)$

## Autokorelačná funkcia

- ▶ Rovnicu (1) vydelíme disperziou  $\gamma(0)$  a dostaneme diferenčnú rovnicu pre autokorelácie  $\rho(s)$

$$\rho(s) = \alpha_1\rho(s-1) + \cdots + \alpha_p\rho(s-p)$$

pre  $s > \max(p, q)$

- ▶ Diferenčná rovnica pre ACF nezávisí od MA časti, od tej závisia len začiatočné podmienky

**Cvičenie 5.** Uvažujme proces

$$x_t = \frac{1}{2}x_{t-1} + u_t - \frac{1}{3}u_{t-1}$$

Odvodíme diferenčnú rovnicu pre

- ▶ autokovariancie
- ▶ autokorelácie

**Cvičenie 6.** Rovnakým postupom ukážte, že pre všeobecný stacionárny ARMA(1,1) proces  $x_t = \delta + \alpha x_{t-1} + u_t - \beta u_{t-1}$  platí:

- ▶ Jeho disperzia je  $\mathbb{D}(x_t) = \frac{1+\beta^2-2\alpha\beta}{1-\alpha^2}\sigma^2$ , kde  $\sigma^2$  je disperzia bieleho šumu  $u$
- ▶ ACF je daná predpisom  $\rho(k) = \alpha^{k-1}\rho(1)$ , pričom  $\rho(1) = \frac{(\alpha-\beta)(1-\alpha\beta)}{1+\beta^2-2\alpha\beta}$

## Parciálna autokorelačná funkcia

- ▶ Dosadzujeme korelácie do všeobecných vzťahov pre ACF
- ▶ UPOZORNENIE: **NEPLATÍ**, že  $ACF(k) = 0$  pre  $k > q$  a  
 $PACF(k) = 0$  pre  $k > p$  (v minulých rokoch častá chyba pri komentovaní ACF a PACF)
- ▶ Napríklad pre nasledovný ARMA(2, 2) proces:

```
ARMAacf(ar = c(1.2, -0.8), ma = c(-0.2, -0.9), lag.max = 4)
```


```
##          0           1           2           3           4
## 1.0000000  0.5996344 -0.1791590 -0.6946984 -0.6903108
```

```
ARMAacf(ar = c(1.2, -0.8), ma = c(-0.2, -0.9), lag.max = 4)
```

```
## [1] 0.5996344 -0.8411742  0.0400243 -0.4416171
```


# ARMA model -> ACF sa nevynuluje

```
plot(ARMAacf(ar = c(1.2, -0.8), ma = c(-0.2, -0.9),  
lag.max = 20, pacf = FALSE), type = "h", lwd =
```



# ARMA model -> PACF sa nevynuluje

```
plot(ARMAacf(ar = c(1.2, -0.8), ma = c(-0.2, -0.9),  
lag.max = 20, pacf = TRUE), type = "h", lwd =
```




## Príklad: Reálne dátá

# Dáta

Prebraté z učebnice *Kirchgässner & Wolters, example 2.15*

- ▶ USA, marec 1994 - august 2003
- ▶  $USR_t$  je trojmesačná úroková miera



## Odhadnutý model


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

$$\Delta \text{USR}_t = -0.006 + 0.831 \Delta \text{USR}_{t-1} + \hat{u}_t - 0.457 \hat{u}_{t-1},$$

$$(-0.73) \quad (10.91) \quad (-3.57)$$

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

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.



## Otázky k modelu

- ▶ Ukážte, že získaný model je stacionárny a invertovateľný
- ▶ Vysvetlite tvrdenie: “*The autocorrelogram of the estimated residuals (...) not provide any evidence of a higher order process*”
- ▶ Píše sa: “*the Box-Ljung Q statistic, which is calculated for this model with 12 autocorrelation coefficients (i.e. with 10 degrees of freedom)...*”
  - ▶ sformulujte hypotézu, ktorá sa testuje
  - ▶ zdôvodnite počet stupňov voľnosti
  - ▶ aký je záver testu?

ARMA modely

└ Spoločné korene AR a MA časti

## Spoločné korene AR a MA časti

Pripomeňme si definíciu ARMA(p,q) procesu:

- ▶ Nech  $u_t$  je biely šum, definujme ARMA(p,q) proces ako

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

teda v operátorovom tvare

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

resp. po označení polynómov

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

- ▶ Požadujeme, aby polynómy  $\alpha(L), \beta(L)$  nemali spoločné korene
- ▶ Teraz sa pozrieme na túto podmienku na korene

- ▶ Majme "ARMA(2,2)" proces

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

pričom polynómy majú tvar

$$1 - \alpha_1 L - \alpha L^2 = (1 - \gamma L)(1 - \gamma_1 L), \quad 1 - \beta_1 L - \beta_2 L^2 = (1 - \gamma L)(1 - \gamma_2 L),$$

teda majú spoločný koreň  $1/\gamma$

- ▶ Potom sa proces dá písať nasledovne:

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

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

- ▶ Ide teda v skutočnosti nie o ARMA(2,2), ale o ARMA(1,1) proces

## Blízke korene AR a MA časti pri práci s dátami

- ▶ Ak dostaneme blízky koreň AR a MA časti, treba namiesto ARMA(p,q) modelu skúsiť ARMA(p-1, q-1)

### Príklad 1:

- ▶ Vygenerujeme dáta z ARMA(1,1) procesu a budeme pre ne odhadovať ARMA(2,2) model
- ▶ Čo očakávame: malo by nám výjsť, že model treba zjednodušiť

```
set.seed(2020)
x <- arima.sim(model = list(ar = c(0.8), ma = c(0.5)),
                 n = 100, sd = 1)
```

```
library(astsa)
model <- sarima(x, 2, 0, 2, details = FALSE)
model$fit$coef

##          ar1          ar2          ma1          ma2      xmean
## 0.3521183 0.2290491 1.0511979 0.2299059 0.6243467


ar.korene <- polyroot(c(1, -model$fit$coef[1:2]))
ma.korene <- polyroot(c(1, model$fit$coef[3:4]))
ar.korene

## [1] 1.457713-0i -2.995018+0i

ma.korene

## [1] -1.349736-0i -3.222561+0i
```

- Červené AR korene a modré MA korene:



- Blízky AR a MA koreň → mali by sme skúsiť namiesto ARMA(2,2) odhadnúť ARMA(1,1) (čo sedí, tak boli tie dátá generované)

**Príklad 2.** ARMA(3,1) model pre dátá výmenných kurzov - AR a MA korene nie sú blízko seba

