

## ARMA modely II. - moving average modely (kĺzavé priemery, MA)

Beáta Stehlíková

2-EFM-102 Časové rady

Fakulta matematiky, fyziky a informatiky, UK v Bratislave

## Motivácia

└ Motívacia

└ Príklad: Ceny kakaá

## Príklad: Ceny kakaá

# Dáta

Ben Vogelvang: *Econometrics. Theory and Applications with EViews.*, Pearson Education Limited, 2005.

Chapter 14.7. - The Box-Jenkins Approach in Practice


- ▶ Mesačné dátá, január 1960 - september 2002
- ▶ pcocoa - cena kakka, zlogaritmujeme a kvôli stacionarite budeme pracovať s diferenciami
- ▶ Modelujeme teda percentuálnu zmenu ceny

$$\begin{aligned}\Delta \ln(p_t) &= \ln(p_t) - \ln(p_{t-1}) = \ln\left(\frac{p_t}{p_{t-1}}\right) \\ &= \ln\left(1 + \frac{p_t - p_{t-1}}{p_{t-1}}\right) \approx \frac{p_t - p_{t-1}}{p_{t-1}}\end{aligned}$$

(lebo  $\ln(1 + x) \approx x$  pre  $x$  malé)


# Dáta

Priebeh dát - pôvodné, zlogaritmované, diferencie logaritmov:



## Odhadnutá ACF

- ▶ Odhadnutá ACF diferencií logaritmov:



## Odhadnutá ACF

- ▶ Prvá výrazne nenulová, ostatné skoro nulové
- ▶ Nevyzerá to ako typický priebeh pre AR proces:
  - ▶ tam klesala ACF postupne
  - ▶ priebeh tohto typu mala PACF

## Príklad z prvej prednášky

- ▶ Nech  $u_t$  je biely šum, definujme

$$x_t = u_t + u_{t-1}$$

- ▶ Vypočítali sme:

$$\mathbb{E}(x_t) = 0, \mathbb{D}(x_t) = 2\sigma^2$$

$$\text{Cov}(x_t, x_{t+k}) = \begin{cases} \sigma^2 & \text{pre } k = 1, \\ 0 & \text{pre } k = 2, 3, \dots \end{cases}$$

$$\text{Cor}(x_t, x_{t+k}) = \begin{cases} 1/2 & \text{pre } k = 1, \\ 0 & \text{pre } k = 2, 3, \dots \end{cases}$$

- ▶ ACF je nulová pre  $k = 2, 3, \dots$  - presne tá vlastnosť, ktorú potrebujeme

## Zovšeobecnenie príkladu a plán prednášky

- ▶ Príklad zovšeobecníme tak, aby
  - ▶ sa zachovala nulovosť korelácií okrem prvej
  - ▶ prvá korelácia mohla nadobádať aj iné hodnoty ako  $1/2 \Rightarrow$  MA(1) procesy
- ▶ Procesy, ktoré majú prvých  $q$  nenulových a ostatné nulové  $\Rightarrow$  MA(q) procesy

## MA(1) procesy

Definícia, stacionarita, momenty, ACF, PACF

- ▶ Nech  $u_t$  je biely šum, potom

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

sa nazýva moving average proces prvého rádu - MA(1)

- ▶ Woldova reprezentácia:  $x_t = \mu + \sum_{j=0}^{\infty} \psi_j u_{t-j}$ , pre MA(1) proces:  $\psi_0 = 1, \psi_1 = -\beta, \psi_j = 0$  pre  $j = 2, 3, \dots \rightarrow$  vždy stacionárny
- ▶ Momenty a ACF:

$$\mathbb{E}(x_t) = \mu, \mathbb{D}(x_t) = (1 + \beta^2)\sigma^2$$

$$\text{Cov}(x_t, x_{t+k}) = \begin{cases} -\beta\sigma^2 & \text{pre } k = 1, \\ 0 & \text{pre } k = 2, 3, \dots \end{cases}$$

$$\text{Cor}(x_t, x_{t+k}) = \begin{cases} -\frac{\beta}{1+\beta^2} & \text{pre } k = 1, \\ 0 & \text{pre } k = 2, 3, \dots \end{cases}$$

- ▶ Pripomeňme si PACF:

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

- ▶ Pre MA(1) proces dosadzujeme  $\rho(k) = 0$  pre  $k = 2, 3, \dots$

$$\Phi_{11} = \rho(1)$$

$$\Phi_{22} = \frac{\det \begin{pmatrix} 1 & \rho(1) \\ \rho(1) & \rho(2) \end{pmatrix}}{\det \begin{pmatrix} 1 & \rho(1) \\ \rho(1) & 1 \end{pmatrix}} = \frac{\det \begin{pmatrix} 1 & \rho(1) \\ \rho(1) & 0 \end{pmatrix}}{\det \begin{pmatrix} 1 & \rho(1) \\ \rho(1) & 1 \end{pmatrix}} = \frac{-\rho(1)^2}{1 - \rho(1)^2}$$

$$\Phi_{33} = \frac{\det \begin{pmatrix} 1 & \rho(1) & \rho(1) \\ \rho(1) & 1 & \rho(2) \\ \rho(2) & \rho(1) & \rho(3) \end{pmatrix}}{\det \begin{pmatrix} 1 & \rho(1) & \rho(2) \\ \rho(1) & 1 & \rho(1) \\ \rho(2) & \rho(1) & 1 \end{pmatrix}} = \frac{\det \begin{pmatrix} 1 & \rho(1) & \rho(1) \\ \rho(1) & 1 & 0 \\ 0 & \rho(1) & 0 \end{pmatrix}}{\det \begin{pmatrix} 1 & \rho(1) & 0 \\ \rho(1) & 1 & \rho(1) \\ 0 & \rho(1) & 1 \end{pmatrix}}$$

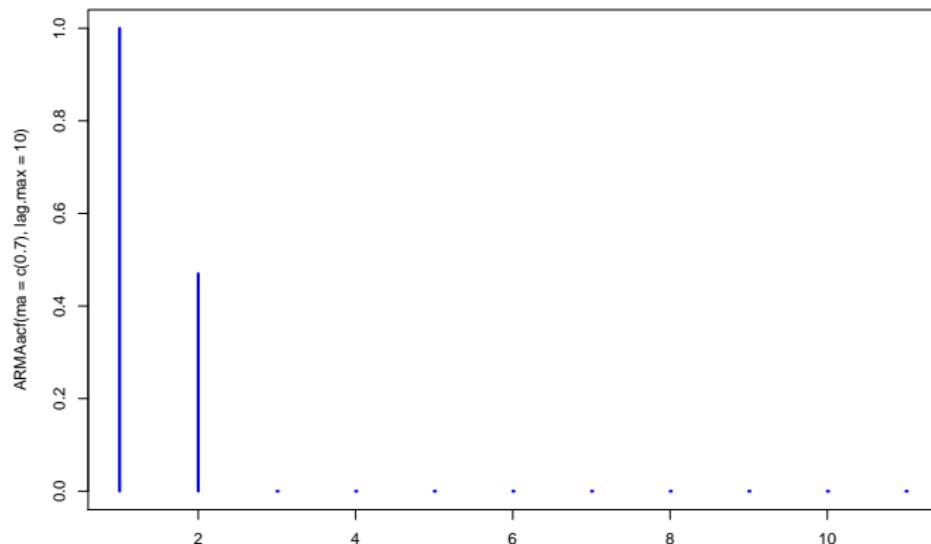
$$= \frac{\rho(1)^3}{1 - 2\rho(1)^2}$$

**Cvičenie:** Odvodťte ďalší člen PACF:


$$\Phi_{44} = \frac{-\rho(1)^4}{(1 - \rho(1)^2)^2 - \rho(1)^2}$$

Príklad 1: výpočet PACF v R-ku,  $x_t = u_t + 0.7u_{t-1}$ 

```
plot(ARMAacf(ma = c(0.7), lag.max = 10),
      type = "h", col = "blue", lwd = 3)
```

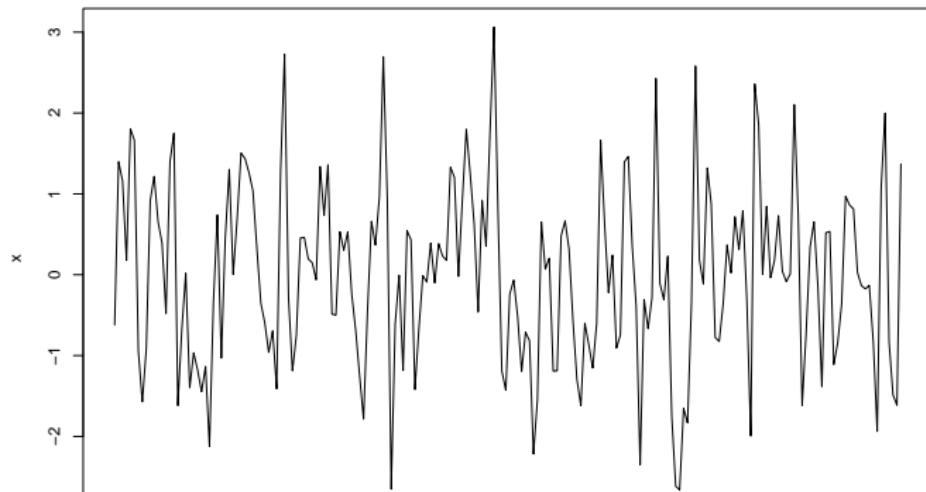


```
plot(ARMAacf(ma = c(0.7), lag.max = 10, pacf = TRUE),  
      type = "h", col = "blue", lwd = 3)  
abline(h = 0, col = "grey", lty = 2)
```





## Príklad 2: simulované dáta, $x_t = u_t + 0.7u_{t-1}$

```
set.seed(123)
x <- arima.sim(model = list(ma = c(0.7)), n = 200)
plot(x)
```



## Odhad ACF a PACF:

```
acf2(x) # naraz ACF (bez lagu 0) a PACF, balik astsa
```



## Príklad 3, 4: výpočet ručne

- Nech  $u_t$  je biely šum s rozdelením  $N(0, 4)$ , definujme

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

Potom:  $\mathbb{E}(x_t) = 0$ ,  $\mathbb{D}(x_t) = (1 + (1/2)^2) \times 4 = 5$

$$\text{Cor}(x_t, x_{t+k}) = \begin{cases} \frac{1/2}{1+1/4} = 2/5 & \text{pre } k = 1, \\ 0 & \text{pre } k = 2, 3, \dots \end{cases}$$

- Nech  $u_t$  je biely šum s rozdelením  $N(0, 1)$ , definujme

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

Potom:  $\mathbb{E}(x_t) = 0$ ,  $\mathbb{D}(x_t) = (1 + 2^2) \times 1 = 5$

$$\text{Cor}(x_t, x_{t+k}) = \begin{cases} \frac{2}{1+4} = 2/5 & \text{pre } k = 1, \\ 0 & \text{pre } k = 2, 3, \dots \end{cases}$$

└ MA(1) procesy

└ MA(1) procesy s danou ACF, invertovateľnosť

MA(1) procesy s danou ACF, invertovateľnosť

## MA(1) procesy s danou ACF

- ▶ Zovšeobecníme predchádzajúce dva príklady (vyšla pre ne rovnaká ACF)
- ▶ Majme MA(1) proces, teda ACF tvaru

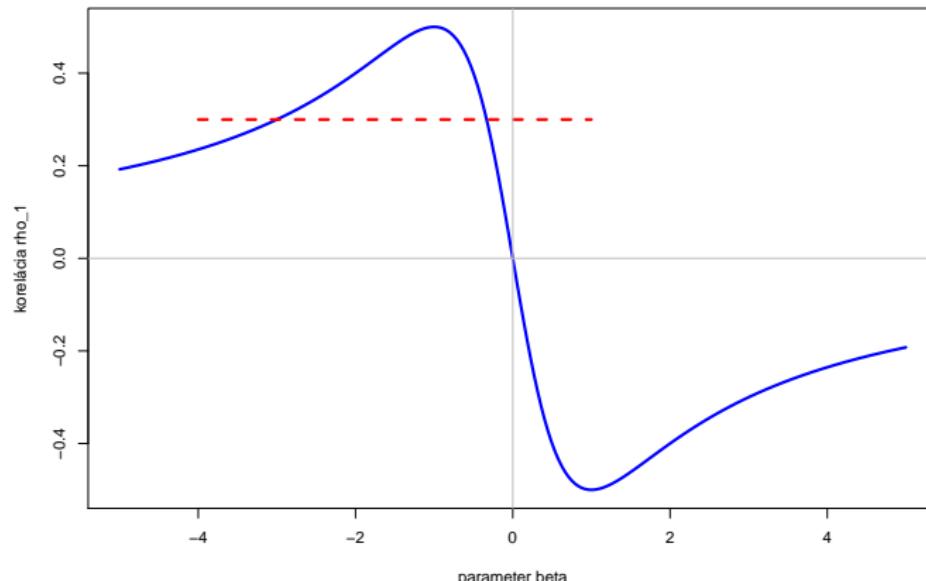
$$\text{Cor}(x_t, x_{t+k}) = \begin{cases} -\frac{\beta}{1+\beta^2} & \text{pre } k = 1, \\ 0 & \text{pre } k = 2, 3, \dots \end{cases}$$

- ▶ Predpokladjme teraz, že máme danú hodnotu  $\rho_1 = \rho(1)$  a chceme z nej späťne určiť koeficient  $\beta$ :

$$\rho_1 = -\frac{\beta}{1 + \beta^2} \Rightarrow \beta = ?$$

► Máme teda rovnicu

$$\rho_1 = -\frac{\beta}{1 + \beta^2} \Rightarrow \beta^2 + \frac{1}{\rho_1}\beta + 1 = 0$$



- ▶ Rovnica  $\beta^2 + \frac{1}{\rho_1}\beta + 1 = 0$  má pre  $|\rho_1| < 1/2$  dve riešenia  $\beta_1, \beta_2$ , ktoré spĺňajú  $\beta_1\beta_2 = 1$
- ▶ Procesy

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

majú rovnakú ACF

- ▶ Ak chceme jednoznačnú parametrizáciu, potrebujeme dodať ďalšiu podmienku

## Invertovateľnosť

- Budeme sa snažiť zapísať proces v tvare AR( $\infty$ ):

$$x_t = \tilde{\mu} + u_t + \psi_1 x_{t-1} + \psi_2 x_{t-2} + \psi_3 x_{t-3} + \dots$$

Ak sa to dá spraviť, proces sa nazýva invertovateľný

- Pre MA(1) proces:

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

inverzia  $(1 - \beta L)^{-1}$  existuje pre  $|\beta| < 1$ , vtedy

$$(1 + \beta L + \beta^2 L^2 + \dots) x_t = \frac{\mu}{1 - \beta} + u_t$$

$$x_t + \beta x_{t-1} + \beta^2 x_{t-2} + \dots = \frac{\mu}{1 - \beta} + u_t$$

$$x_t = \frac{\mu}{1 - \beta} + u_t - \beta x_{t-1} - \beta^2 x_{t-2} - \dots$$

- ▶ Dostali sme teda podmienku invertovateľnosti MA(1) procesu:  
 $|\beta| < 1$
- ▶ Iný zápis tejto podmienky:
  - ▶ máme proces  $x_t = \mu + (1 - \beta L)u_t$
  - ▶ koreň polynómu  $1 - \beta L$  je  $1/\beta$
  - ▶ podmienka invertovateľnosti teda hovorí, že koreň polynómu  $1 - \beta L$  musí byť v absolútnej hodnote väčší ako 1, pri zakreslení do komplexnej roviny mimo jednotkového kruhu

Reálne dáta: ceny kakaa zo začiatku



- Odhadneme MA(1) model pre diferencie logaritmov cien (teda percentuálne zmeny cien):

```
##           Estimate      SE t.value p.value
## ma1       0.3520  0.0402  8.7585  0.0000
## xmean     0.0024  0.0037  0.6501  0.5159
```


- Zapíšeme model pre premennú  $x_t = \Delta \ln(pcocoa_t)$ :

$$x_t = 0.0024 + u_t + 0.3520u_{t-1}$$

- Rezíduá sú v poriadku - model je dobrý



- ▶ Predikcie z R-ka na nasledujúci rok.
- ▶ Všimnime si, že nie sú konštantné. Prečo nie sú konštantné predikcie z modelu  $x_t = \mu + u_t - \beta u_{t-1}$  - k tomu sa vrátíme.



## MA(q) procesy

Definícia, momenty, ACF, PACF, invertovateľnosť

- ▶ Nech  $u_t$  je biely šum, potom

$$x_t = \mu + u_t - \beta_1 u_{t-1} - \beta_2 u_{t-2} - \cdots - \beta_q u_{t-q}$$

sa nazýva moving average proces rádu  $q$  - MA(q)

- ▶ Woldova reprezentácia:  $x_t = \mu + \sum_{j=0}^{\infty} \psi_j u_{t-j}$ , pre MA(q)  
proces:  $\psi_0 = 1, \psi_1 = -\beta_1, \dots, \psi_q = -\beta_q, \psi_j = 0$  pre  $j > q \rightarrow$   
**vždy je stacionárny**
- ▶ Momenty a ACF:

$$\mathbb{E}(x_t) = \mu, \mathbb{D}(x_t) = (1 + \beta_1^2 + \dots + \beta_q^2)\sigma^2$$

$$\text{Cov}(x_t, x_{t+k}) = 0 \text{ pre } k = q+1, q+2, \dots$$

$$\text{Cor}(x_t, x_{t+k}) = 0 \text{ pre } k = q+1, q+2, \dots$$

► Výpočet prvých  $q$  autokorelácií:

$$\text{Cov}(x_t, x_{t+k}) = \mathbb{E}[(u_t - \beta_1 u_{t-1} - \cdots - \beta_q u_{t-q}) \times (u_{t+k} - \beta_1 u_{t+k-1} - \cdots - \beta_q u_{t+k-q})]$$

► Postupne dostaneme

$$k = 1 \Rightarrow \gamma(1) = (-\beta_1 + \beta_1 \beta_2 + \cdots + \beta_{q-1} \beta_q) \sigma^2$$

$$k = 2 \Rightarrow \gamma(2) = (-\beta_2 + \beta_1 \beta_3 + \cdots + \beta_{q-2} \beta_q) \sigma^2$$

...

$$k = q \Rightarrow \gamma(q) = (-\beta_q) \sigma^2$$

- Pre konkrétny model je praktickejšie počítať to priamo, namiesto dosadzovania do týchto vzťahov (tie sú užitočné kvôli postupu)
- ACF: autokovariancie vydelíme disperziou
- PACF: ACF dosadzujeme do všeobecného vzorca

## Cvičenie

Uvažujme proces  $x_t = 10 + u_t + 0.5u_{t-1} - 0.2u_{t-2} + 0.1u_{t-3}$

- ▶ Ukážte, že je invertovateľný.
- ▶ Vypočítajte jeho ACF
- ▶ Vypočítajte prvé tri hodnoty jeho PACF

Na kontrolu:

```
ARMAacf(ma=c(0.5,-0.2,0.1), lag.max = 4) [-1]
```


```
##           1           2           3           4
## 0.29230769 -0.11538462  0.07692308  0.00000000
```

```
ARMAacf(ma=c(0.5,-0.2,0.1), lag.max = 3, pacf = TRUE)
```

```
## [1] 0.2923077 -0.2195911  0.2093677
```


## Reálne dátá

```
library(quantmod)
data <- getSymbols.oanda("GBP/USD", auto.assign=FALSE)
```



Budeme modelovať percentuálnu zmenu výmenného kurzu


```
acf1(diff(log(data)))
```



Odhadneme MA(2) model:

```
##           Estimate      SE t.value p.value
## ma1       0.5164 0.0725  7.1242  0.0000
## ma2       0.1303 0.0750  1.7384  0.0839
## xmean    0.0006 0.0005  1.1641  0.2460
```

Rezíduá nám potvrdia vhodnosť modelu:



p values for Ljung-Box statistic

