

# AR, MA a ARMA procesy

Beáta Stehlíková  
FMFI UK Bratislava

# Overovanie stacionarity a invertovateľnosti

## Opakovanie - stacionarita AR procesu

Zistite, či je proces

$$x_t = 1.2x_{t-1} + 0.5x_{t-2} + 0.3x_{t-3} + u_t$$

stacionárny.

- ▶ Napíšte polynóm, ktorého korene idete počítať. Aké musia byť, aby bol proces stacionárny?
- ▶ Vypočítajte korene a rozhodnite o stacionarite.

## Invertovateľnosť MA procesu

Zistite, či je proces

$$x_t = 0.2 + u_t - 0.2u_{t-1} + 0.1u_{t-2}$$

invertovateľný.

- ▶ Napíšte polynóm, ktorého korene idete počítať. Aké musia byť, aby bol proces invertovateľný?
- ▶ Vypočítajte korene a rozhodnite o invertovateľnosti. *Pozor na znamienka pri volaní funkcie `armaRoots`.*

Zopakujte pre proces

$$x_t = 0.5 + u_t + 0.3u_{t-1} + 0.4u_{t-2} - 0.1u_{t-3}$$

## Stacionarita a invertovateľnosť ARMA procesu

Rozhodnite, či sú nasledujúce procesy stacionárne a invertovateľné.

- ▶  $x_t = 5 + 0.2x_{t-1} - 0.3x_{t-2} + u_t - 0.15u_{t-1} - 0.1u_{t-2}$
- ▶  $x_t = 1 + 0.6x_{t-1} + 0.9x_{t-2} + u_t + 0.3u_{t-1}$
- ▶  $x_t = 1.5 + 0.6x_{t-1} + u_t - 0.3u_{t-1} - 0.2u_{t-2}$

Vypočítajte strednú hodnotu stacionárnych procesov.

# ACF a PACF

## Autokorelačná funkcia

**Opakovanie:** Už vieme: ACF napríklad pre autoregresný proces

$$x_t = 1 + 0.5x_{t-1} + u_t :$$

```
acf1 <- ARMAacf(ar=c(0.5), lag.max=10)  
barplot(acf1)
```

**Analogicky:** ACF pre moving average proces

$$x_t = 1 + u_t + 0.5u_{t-1} :$$

```
acf2 <- ARMAacf(ma=c(0.5), lag.max=10)  
barplot(acf2)
```

Aké sú presné hodnoty týchto autokorelačných funkcií?

## Parciálna autokorelačná funkcia

Pri výpočte PACF doplníme do funkcie `ARMAacf` parameter `pacf=TRUE`.

PACF pre autoregresný proces

$$x_t = 1 + 0.5x_{t-1} + u_t :$$

```
pacf1 <- ARMAacf(ar=c(0.5), pacf=TRUE, lag.max=10)  
barplot(pacf1)
```

PACF pre moving average proces

$$x_t = 1 + u_t + 0.5u_{t-1} :$$

```
pacf2 <- ARMAacf(ma=c(0.5), pacf=TRUE, lag.max=10)  
barplot(pacf2)
```



## ACF a PACF

ACF a PACF pre ARMA proces

$$x_t = 1 + 0.3x_{t-1}u_t + 0.5u_{t-1}$$

```
acf3 <- ARMAacf(ar=c(0.3), ma=c(0.5), lag.max=10)  
barplot(acf3)
```

```
pacf3 <- ARMAacf(ar=c(0.3), ma=c(0.5), pacf=TRUE,  
                 lag.max=10)  
barplot(pacf3)
```

## ACF a PACF

Zobrazte ACF a PACF pre nasledujúce stacionárne procesy.

O ktorých hodnotách vopred vieme, že budú nulové?

- ▶  $x_t = 1 + u_t + 0.3u_{t-1}$
- ▶  $x_t = 3 + 0.2x_{t-1} + u_t - 0.3u_{t-1}$
- ▶  $x_t = 1 + 0.2x_{t-1} + 0.1x_{t-2} + u_t$

# Identifikácia a odhadovanie ARMA modelov

## Postup

- ▶ Zobrazíme ACF a PACF dát, jedným príkazom sa to dá spraviť funkciou `acf2(data)` z balíka `astsa`.
- ▶ “Podozrenie” na AR proces máme vtedy, ak sa PACF vynuluje, počet signifikantných hodnôt je rád procesu.
- ▶ “Podozrenie” na MA proces máme vtedy, ak sa ACF vynuluje, počet signifikantných hodnôt je rád procesu.
- ▶ Môžeme odhadovať aj zmiešané ARMA procesy s AR aj MA členmi.
- ▶ ARMA( $p, q$ ) model pre  $k$ -te diferencie sa odhadne funkciou `sarima(data, p, k, q)`, analogicky predikcie `sarima.for`
- ▶ Treba overiť stacionaritu a invertovateľnosť a rezíduá (ACF rezíduí a Ljung-Boxovu štatistiku)
- ▶ Ak existujú blízke korene z AR a MA časti, treba skúsiť ARMA( $p-1, q-1$ ) model

## Cvičenie 1

Z minulého týždňa:



```
data(gas)  
gas <- window(gas, start=c(2006,1))
```

Modelujeme diferencie premennej gas.

- ▶ Minulý týžden sme našli AR(4) model. Ako to súvisí s ACF a PACF?
- ▶ Dal by sa nájsť aj dobrý MA model? ARMA model?

# Cvičenie 1

```
acf2(diff(gas))
```



## Cvičenie 2

Počet oviec v tisícoch v Anglicku a Walese, ročné dáta, 1867-1939

Na stránke cvičení v súbore `ovce.txt`

V dátach je klesajúci trend, preto budeme pracovať s diferenciami.

## Cvičenie 3

Ceny kakaa z prednášky

Na stránke cvičení v súbore kakao.txt

Budeme modelovať s diferencie logaritmov.

Ukážte, že sa tieto dáta dajú dobre modelovať aj pomocou AR aj pomocou MA procesu.



# Porovnanie Woldových reprezentácií

## Modely pre diff(gas)

Máme AR(4) a MA(3) model pre dáta diff(gas). Porovnajme ich Woldove reprezentácie.

Postup:

```
k <- as.factor(rep(1:10, 2))  
psi <- NA # zatiaľ  
model <- rep(c("ar4", "ma3"), each=10)  
wold <- data.frame(k, psi, model)
```

Pozrite si *data frame* wold, aby ste videli, akú má štruktúru.

Potom doplňte hodnoty premennej psi, ktorá bude v každom riadku obsahovať koeficient psi.k pre príslušný model.


## Modely pre diff(gas)

Porovnanie spravíme pomocou knižnice ggplot2:

```
library(ggplot2)

# v jednom riadku:
ggplot(wold, aes(x=k, y=psi, fill=model)) +
  geom_bar(stat="identity", position="dodge")
```

## Modely pre diff(gas)



# Modelovanie ceny kakaa

Takisto pre diferencie logaritmov cien kakaa máme k dispozícii aj AR aj MA proces.

Spravte podobné porovnanie Woldovych reprezentácií.

# Cvičenia

## AR(1) proces pozorovaný s chybou

Vygenerujeme AR(1) proces  $y$ :


```
set.seed(12345)  
y <- arima.sim(n=200, list(ar = c(0.9)), sd=0.1)
```

Porovnať ho ale budeme s chybou  $\epsilon$ , vidíme teda proces  $x$ :

```
eps <- rnorm(200)/15  
x <- y+eps
```

Zobrazte vygenerované procesy  $y$  (pôvodný - čiernou) a  $x$  (pozorovaný - modrou).

## AR(1) proces pozorovaný s chybou





## AR(1) proces pozorovaný s chybou

Ukážte, že:

- ▶ AR(1) je dobrý model pre dáta  $y$  - to je prirodzené, tak sme ich generovali
- ▶ Ale AR(1) nie je dobrý model pre dáta  $x$ .
- ▶ ARMA(1,1) je dobrý model pre dáta  $x$ .

Poslednú vlastnosť dokážeme v pondelok analyticky (nielen pre vygenerované dáta).

## Stacionarita AR(2) procesu

vCo je na obálke knihy Woltera Endersa *Applied Econometric Time Series*? <http://www.amazon.com/>

`Applied-Econometric-Time-Series-Edition/dp/0471230650`

“Experimentálne zistíme” podmienku stacionarity AR(2) procesu a jej súvislosť s obrázkom.

## Stacionarita AR(2) procesu

Náhodne vygenerujeme parametre alpha1 a alpha2:

```
n <- 2000 # najskor menej, po odladeni napr. 2000
set.seed(123)

# runif ~ rovnomerne na (min, max)
alpha1 <- runif(n, min = -2.5, max = 2.5)
alpha2 <- runif(n, min = -2.5, max = 2.5)
```

a budeme zisťovať, či je pre jednotlivé kombinácie parametrov príslušný proces stacionárny alebo nie.

## Stacionarita AR(2) procesu

Vytvoríme *data frame*:

```
stationary <- rep(NA,n)
df <- data.frame(alpha1,alpha2,stationary)
head(df)
```

```
##      alpha1      alpha2 stationary
## 1 -1.0621124 -1.70163010         NA
## 2  1.4415257 -1.77742074         NA
## 3 -0.4551154 -1.75409804         NA
## 4  1.9150870  0.07217130         NA
## 5  2.2023364 -0.03586347         NA
## 6 -2.2722175  0.58171384         NA
```

## Stacionarita AR(2) procesu

Doplňte pomocou funkcie `armaRoots`:

```
for (i in 1:n) {  
  # doplňte cyklus  
  # TRUE, FALSE podľa toho, či je proces stacionárny  
  df$stationary[i] <-  
}
```

## Stacionarita AR(2) procesu

Potom môžeme kresliť graf pomocou funkcie `qplot` z knižnice `ggplot2`:

```
qplot(alpha1, alpha2, colour=stationary, data=df)
```

Napríklad pri  $n=2000$  dostaneme výstižný obrázok.