

AR(1) model: CVIČENIA

Beáta Stehlíková

2-PMS-10 Časové rady

Fakulta matematiky, fyziky a informatiky, UK v Bratislave

Cvičenie 1: Opakovanie, odhadnutie AR(1) modelu

```
x <- window(Nile, start = 1905)
```

- ▶ Pre dáta o prietokoch Nílu sme Ljung-Boxovým testom zistili, že majú signifikantné autokorelácie. Nejde preto iba o biely šum posunutý o konštantu, ale treba modelovať závislosť pozorovaných hodnôt.
- ▶ Odhadnite pre tieto dáta AR(1) model a na základe Ljung-Boxovho testu pre rezíduá (ktorý je súčasťou výstupu) rozhodnite, či ide o dobrý model pre tieto dáta.
- ▶ Prečo sa Ljung-Boxov test začína až od testovania prvých dvoch autokorelácií (pri testovaní pôvodných dát sme testovali aj prvú koreláciu)?

Cvičenie 2: Predikcie a ich porovnanie s dátami

- ▶ Vychajme z dát posledných 5 pozorovaní.
- ▶ Zo zostávajúcich dát odhadneme AR(1) model.
- ▶ Funkciou `sarima.for` spravíme predikcie pre nasledujúcich 5 rokov.
- ▶ Doplníme pre tieto časy reálne pozorované dáta (dá sa to napr. pomocou `lines` a nastavenia hodnôt na x-ovej osi)

- ▶ Pri kreslení grafov a pri výpočtoch je niekedy užitočné mať k dispozícii číselné hodnoty predikcií a štandardných odchýlok:

```
# AR(1) pre vsetky data x, 3 predikcie  
predikcie <- sarima.for(x, n.ahead = 3, 1, 0, 0)  
  
str(predikcie)   # pozrite si strukturu  
predikcie$pred  # casovy rad predikcii
```

Cvičenie 3: AR modely vyššieho rádu

- ▶ Analogicky ako AR(1) sa definuje AR(p):

$$x_t = \delta + \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + \dots + \alpha_p x_{t-p} + u_t$$

- ▶ V balíku `astsa`

```
model <- sarima(data, p, k, 0) # AR(p) pre k-te dif.
model <- sarima(data, p, k, 0
```

- ▶ Odhadnite AR(p) pre $p \in \{1, 2, 3, 4, 5\}$ model pre dáta o prietokoch Nílu. Pre modely s dobrými rezíduami vyberte model s najnižším Bayesovým informačným kritériom.

```
model$BIC # získanie hodnoty BIC
```

Cvičenie 4: Volebné preferencie v Nemecku

- ▶ Zrekonštruujeme (do istej miery) model z prednášky o volebných preferenciách v Nemecku.
- ▶ Dáta sú dostupné na webe (odkaz na stránke tohto predmetu), ale vo formáte wf1 (pre softvér EViews). Načítanie do R spravíme pomocou balíka `hexView`

```
library(hexView)
data <- readEViews("chapter_2_example_2_2.wf1")
```

- ▶ Pozrite si štruktúru získaných dát a vytvorte na základe nich časový rad s pozorovaniami.
- ▶ Odhadnite AR(1) model pre tieto dáta a zhodnoťte jeho rezíduá

- Uložte do objektu ar1 výsledok odhadovania tohto modelu

```
ar1 <- sarima(...)
```

```
# ak nechceme vypisat a vykreslit vystupy
```

```
ar1 <- sarima(..., details = FALSE)
```

```
str(ar1)
```

```
## List of 6
## $ fit :List of 14
## ..$ coef : Named num [1:2] 0.835 48.212
## ..$ attr(*, "names")= chr [1:2] "ar1" "xmean"
## ..$ sigma2 : num 2.48
## ..$ var.coef : num [1:2, 1:2] 0.00227 0.00095 0.00095
## ..$ attr(*, "dimnames")=List of 2
## ..$ : chr [1:2] "ar1" "xmean"
## ..$ : num [1:2] "1" "0"
```

- ▶ Napríklad odhady koeficientov:

```
ar1$fit$coef
```

```
##          ar1          xmean  
## 0.8349926 48.2122716
```

```
ar1$fit$coef[1]      # prva zlozka vektora
```

```
##          ar1  
## 0.8349926
```

```
ar1$fit$coef["ar1"] # zlozka s nazvom ar1
```

```
##          ar1  
## 0.8349926
```

Cvičenie. Zapišeme model v tvare $x_t = \delta + \alpha_1 x_{t-1} + u_t$.

- ▶ Koeficient α_1 je vo výstupe označený ako ar1
- ▶ Koeficient δ dopočítame pomocou `xmean` a `ar1` (s presnými hodnotami, nie odpísanými zo zaokrúhleného výstupu)

► Rezíduá modelu

```
ar1$fit$residuals
```

```
## Time Series:
## Start = 1
## End = 137
## Frequency = 1
## [1] -1.76758832  0.46995143 -1.36504117 -1.53004857  2
## [7]  0.63495883  0.29996622  0.88246992  0.54747731 -5
## [13] -0.86006336  0.13993664 -0.69505596 -0.69505596 -1
## [19]  2.13993664 -0.36504117  0.63495883 -3.20003378  1
## [25] -0.53004857 -0.53004857 -2.53004857  0.63993664  1
## [31] -0.78253748  0.63495883  0.79996622 -0.03502639 -1
## [37]  1.12998101  0.29498840  0.29498840  2.29498840  0
## [43]  0.12998101 -2.87001899  0.13495883  0.21746252  5
## [49]  0.79001058  0.79001058  0.79001058 -2.20998942  0
## [55]  1.07001058  0.79001058  0.00498840  0.79001058  10
```

Cvičenie: Chceme získať číselnú hodnotu Ljung-Boxovej štatistiky a príslušnú p-hodnotu z testovania prvých 12 autokorelácií. (V texte boli číselné hodnoty, nielen obrázok.)

- ▶ Pri použití funkcie `Box.test` potrebujeme dodať informáciu o tom, že ide o rezíduá z AR(1) modelu.
- ▶ Spraví sa to parametrov `fitdf`, ktorého hodnota sa rovná počtu odhadovaných ARMA parametrov (teraz počet AR parametrov)
- ▶ Vo výstupe si všimnite počet stupňov voľnosti `df`

```
Box.test(..., fitdf = ...)
```

```
##  
## Box-Ljung test  
##  
## data: ar1$fit$residuals  
## X-squared = 12.762, df = 11, p-value = 0.3092
```

Cvičenie 5: Balík priceR, modelovanie inflácie


- ▶ Z balíka priceR použijeme `retrieve_inflation_data` na získanie dát z *World Bank API*
- ▶ Vytvorte z týchto dát časový rad s hodnotami inflácie.

```
library(priceR) # ak treba, nainstalujte  
data <- retrieve_inflation_data("US")
```

```
## Validating iso2Code for US  
## Generating URL to request all 297 results  
## Retrieving inflation data for US  
## Generating URL to request all 63 results
```

```
str(data)
```

```
## 'data.frame':    63 obs. of  8 variables:
## $ indicator      :'data.frame': 63 obs. of  2 variables
## ..$ id       : chr  "FP.CPI.TOTL.ZG" "FP.CPI.TOTL.ZG" "FP.CPI.TOTL.ZG" ...
## ..$ value: chr  "Inflation, consumer prices (annual %)" "Inflation, consumer prices (annual %)" "Inflation, consumer prices (annual %)" ...
## $ country        :'data.frame': 63 obs. of  2 variables
## ..$ id       : chr  "US" "US" "US" "US" ...
## ..$ value: chr  "United States" "United States" "United States" ...
## $ countryiso3code: chr  "USA" "USA" "USA" "USA" ...
## $ date           : chr  "2022" "2021" "2020" "2019" ...
## $ value          : num  8 4.7 1.23 1.81 2.44 ...
## $ unit           : chr  "" "" "" "" ...
## $ obs_status     : chr  "" "" "" "" ...
## $ decimal        : int  1 1 1 1 1 1 1 1 1 ...
```

`plot(x)`

- ▶ Neskôr uvidíme, že takéto dáta treba diferencovať, aj keď v nich nie je trend.
- ▶ Preto teraz **budeme pracovať s diferenciami**
- ▶ Pri modelovaní si treba uvedomiť, že **konštantný člen v modeli pre diferencie znamená lineárny trend v pôvodných dátach** a tento trend sa dostane aj do predikcií


Príklad 1. Diferencie sú “ar(0)” s danou hodnotou $x_0 = u_0$:

$$x_t - x_{t-1} = c + u_t \Rightarrow x_t = ct + \sum_{i=0}^t u_i$$


$$x_t - x_{t-1} = u_t \Rightarrow x_t = \sum_{i=0}^t u_i$$

Príklad 2. Simulácie priebehu, ak sú diferencie AR(1)

```
set.seed(123)
x1 <- arima.sim(model = list(ar = c(0.8)), n = 200)
y1 <- ts(cumsum(x1)) # diferencie su ar(1) bez konst.
plot(y1)
```



```
set.seed(123)
x2 <- 0.5 + arima.sim(model = list(ar = c(0.8)), n = 200)
y2 <- ts(cumsum(x2)) # diferencie su ar(1) s konst.
plot(y2)
```



- ▶ V dátach o inflácii nie je trend \Rightarrow chceme odhadnúť model pre diferencie bez konštanty
- ▶ Vo funkcii `sarima` pridáme parameter `no.constant` na `TRUE`
- ▶ Ak sa diferencuje viac ako raz, spraví sa to automaticky

```
# ar(p) model bez konštanty pre 1. diferencie  
sarima(data, p, 1, 0, no.constant = TRUE)
```

- ▶ Odhadnite model bez konštanty a pozrite si vektor koeficientov.

- ▶ Pre diferencie zistite či sú pre ne na základe rezíduí dobrými modelmi $AR(p)$ pre $p \in \{0, 1, 2, 3, 4, 5\}$ bez konštanty
- ▶ Z vyhovujúcich modelov vyberte ten, ktorý má najnižšie BIC.

Zopakujte pre infláciu v štátoch (všade treba diferencovať):

- ▶ Francúzsko (FR)
- ▶ Japonsko (JP)
- ▶ Kanada (CA)

Cvičenie 6: Teoretický príklad

Nech x je stacionárny AR(1) proces. Definujme

$$y_t = x_t - x_{t-1}.$$

Vypočítajte strednú hodnotu, disperziu a autokorelačnú funkciu procesu y a ukážte, že je stacionárny.