

AR(p) modely: CVIČENIA

Beáta Stehlíková

2-PMS-10 Časové rady

Fakulta matematiky, fyziky a informatiky, UK v Bratislave

Cvičenie 1: Overovanie stacionarity AR procesov I.

Zistite, či sú nasledovné AR procesy stacionárne:

▶ $x_t = 5 + 1.3x_{t-1} - 0.4x_{t-2} + u_t$


▶ $x_t = 15 + 0.3x_{t-1} - 0.5x_{t-2} - 0.1x_{t-3} + 0.2x_{t-4} + u_t$

▶ $(1 - 0.8L - 0.3L^2 - 0.2L^3)x_t = 10 + u_t$

Cvičenie 2: Grafické znázornenie koreňov

- ▶ Cieľom je znázorniť korene v komplexnej rovine spolu s jednotkovým kruhom (podobne, ako to bolo na prednáškových slajdoch) - pre nejaký AR proces.
- ▶ Užitočné funkcie a parametre:
 - ▶ ak dostne `plot` ako vstup komplexné číslo, nakreslí na x-ovú os ich reálnu a na y-ovú os imaginárnu časť
 - ▶ parameter `asp = 1` zabezpečí rovnakú mierku na obidvoch osiach
 - ▶ funkcia `curve` nakreslí zadanú krivku pre zadaný rozsah nezávislej premennej, s parameterom `add = TRUE` ju dokreslí do pôvodného obrázku
 - ▶ osi môžeme kresliť pomocou `abline` (horizontálnu s parameterom `h`, vertikálnu s parameterom `v`)

Ukážka pre $x_t = 0.9x_{t-1} - 0.4x_{t-2} - 0.2x_{t-3} + 0.2x_{t-4} + u_t$:




Cvičenie 3: Overovanie stacionarity AR procesov II.

- ▶ Ak riešime úlohy typu “pre aké hodnoty parametra je daný proces stacionárny” analyticky, je dobré mať numerickú kontrolu.
- ▶ **Príklad 1:** Pre aké hodnoty parametra k je stacionárny proces $x_t = x_{t-1} + kx_{t-2} + u_t$?
- ▶ **Numerická simulácia:**
 - ▶ Vytvoríme vektor hodnôt k vektor a pre každú jeho zložku zistíme, či je získaný proces stacionárny.
 - ▶ Dopíšte funkciu, ktorá pre zadanú hodnotu k vráti hodnotu TRUE alebo FALSE podľa toho, či je proces stacionárny.

```
kvektor <- seq(from = -3, to = 3, by = 0.1)
stacionarita <- sapply(kvektor, function(k) .... )
```

- Tieto hodnoty TRUE alebo FALSE sa potom dajú napríklad kresliť do grafu ako hodnoty 1 a 0:

```
plot(kVektor, stacionarita)
```



Alebo si vypíšeme:

```
kVektor[stacionarita] # kVektor[stacionarita == TRUE]
```

```
## [1] -0.9 -0.8 -0.7 -0.6 -0.5 -0.4 -0.3 -0.2 -0.1
```

```
kVektor[!stacionarita] # kVektor[stacionarita == FALSE]
```

```
## [1] -2.0 -1.9 -1.8 -1.7 -1.6 -1.5 -1.4 -1.3 -1.2 -1.1 -
```

```
## [16] 0.4 0.5 0.6 0.7 0.8 0.9 1.0 1.1 1.2 1.3
```

```
## [31] 1.9 2.0
```

Spravte numerickú simuláciu k príkladu:

- ▶ **Príklad 2:** Pre aké hodnoty parametra k je stacionárny proces

$$x_t = x_{t-1} + kx_{t-2} - x_{t-3} + u_t?$$

Cvičenie 4: Woldova reprezentácia procesu

- ▶ Funkcia `ARMAtoMA`, napríklad pre proces $x_t = 0.5 + 0.3x_{t-1} - 0.6x_{t-2} + u_t$ spravíme:

```
ARMAtoMA(ar = c(0.5, -0.6), lag.max = 20)
```

```
## [1] 0.500000000 -0.350000000 -0.475000000 -0.027500000
## [6] 0.152125000 -0.086687500 -0.134618750 -0.015296875
## [11] 0.045739531 -0.021003922 -0.037945680 -0.006370487
## [16] 0.013613374 -0.004942612 -0.010639330 -0.002354098
```

Cvičenie. Uvažujme procesy:

$$x_t = 0.5 + 0.3x_{t-1} - 0.6x_{t-2} + u_t$$

$$y_t = 0.5 + 0.5x_{t-1} + 0.2x_{t-2} + u_t$$

- ▶ Ukážte, že sú stacionárne. Všimnite si, či sú korene reálne alebo komplexné.
- ▶ Zobrazte koeficienty Woldovej reprezentácie. Ako ich priebeh súvisí s koreňmi? Vyskúšajte aj na príkladoch iných procesov.


Cvičenie 5: Woldova reprezentácia pre odhadnuté modely

Dáta z predchádzajúceho cvičenia:

- ▶ Z balíka `priceR` použijeme `retrieve_inflation_data` na získanie dát z *World Bank API*
- ▶ Vytvorili sme z týchto dát časový rad `x` s hodnotami inflácie a hľadali sme AR model bez konštanty pre diferencie.

```
library(priceR)
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
```



Zadanie 1.

- ▶ Nájdeme koeficienty Woldovej reprezentácie pre procesy dané modelmi rádov 1 až 5.
- ▶ Najskôr si zapíšeme vektory koeficientov týchto modelov (budeme ich ešte potrebovať a nechceme ich odhadovať znovu).
 - ▶ Analogické ako pri použití funkcie `sapply`
 - ▶ Ale teraz sa nedajú zapísať výsledky do matice, lebo vektory koeficientov budú mať rôzne dĺžky
 - ▶ Použijeme preto funkciu `lapply` a výstupom z nej bude `list` (zoznam)

```
koefAR <- lapply(1:5, function(p) ... )  
# function(p) ...  
# vstup: rad procesu p pre pre diferencie bez konst.  
# vystup: vektor ar koeficientov
```


```
## [[1]]
##          ar1
## 0.1987695
##
## [[2]]
##          ar1          ar2
## 0.2574264 -0.4166409
##
## [[3]]
##          ar1          ar2          ar3
## 0.2130452 -0.3919758 -0.1111052
##
## [[4]]
##          ar1          ar2          ar3          ar4
## 0.19254716 -0.45430245 -0.08302077 -0.15911670
##
## [[5]]
```

- ▶ Teraz použijeme jednotlivé zložky zoznamu ako vstup do funkcie, ktorá pre zadaný vektor AR koeficientov vypočíta koeficienty Woldovej reprezentácie (vypočítajme prvých 15).
- ▶ Tu už bude výstupom matica (rozmery sú dané počtom modelov a počtom Woldových koeficientov), preto môžeme použiť funkciu `sapply`

```
koefWold <- sapply(koefAR, function(ARvektor) ... )  
# vstup funkcie: vektor AR koef. modelu  
# vystup: prvych 15 hodnot Woldovej reprezentacie
```

##		[,1]	[,2]	[,3]	[,4]
##	[1,]	1.987695e-01	0.2574263627	0.213045191	0.1925471
##	[2,]	3.950932e-02	-0.3503726009	-0.346587550	-0.4172280
##	[3,]	7.853250e-03	-0.1974495042	-0.268452589	-0.2508314
##	[4,]	1.560987e-03	0.0951508597	0.054990968	-0.0338512
##	[5,]	3.102766e-04	0.1067598854	0.155450166	0.1114365
##	[6,]	6.167353e-05	-0.0121609340	0.041389265	0.1240476
##	[7,]	1.225882e-05	-0.0476110833	-0.058224703	0.0159809
##	[8,]	2.436680e-06	-0.0071896051	-0.045899408	-0.0571433
##	[9,]	4.843376e-07	0.0179859323	0.008445463	-0.0462929
##	[10,]	9.627156e-08	0.0076255369	0.026259791	-0.0040180
##	[11,]	1.913585e-08	-0.0055306614	0.007383769	0.0224585
##	[12,]	3.803624e-09	-0.0046008489	-0.009658461	0.0190854
##	[13,]	7.560446e-10	0.0011199201	-0.007869547	0.0011714
##	[14,]	1.502786e-10	0.0022051989	0.001288939	-0.0096702
##	[15,]	2.987081e-11	0.0001010718	0.004432380	-0.0075521

- Pri kreslení sa môže zísť funkcia `matplotlib` (spoločná x-ová os 1:15, na y-ovej stĺpce zadanej matrice)



- ▶ Porovnajte Woldove reprezentácie.
- ▶ Z minulého cvičenia: ktoré z týchto modelov mali dobré rezíduá?

Cvičenie 6: Autokorelačná funkcia procesu

- ▶ Odvodenie na prednáške, teraz spravíme numerický výpočet
- ▶ Funkcia `ARMAacf`, napríklad pre proces
 $x_t = 0.5 + 0.3x_{t-1} - 0.6x_{t-2} + u_t$ spravíme:

```
ARMAacf(ar = c(0.3, -0.6), lag.max = 20)
```

```
##          0          1          2          3
## 1.00000000 0.18750000 -0.54375000 -0.27562500 0.2
##          6          7          8          9
## -0.074604375 -0.165447562 -0.004871644 0.097807044 0.0
##          12         13         14         15
## -0.034060469 0.019184677 0.026191684 -0.003653301 -0.0
##          18         19         20
## 0.009231205 0.004480153 -0.004194677
```

Cvičenie. Uvažujme znovu procesy:

$$x_t = 0.5 + 0.3x_{t-1} - 0.6x_{t-2} + u_t$$

$$y_t = 0.5 + 0.5x_{t-1} + 0.2x_{t-2} + u_t$$

- ▶ Zobrazte pre každý z nich priebeh autokorelačnej funkcie, vynechajte pritom nultý lag, ktorý sa vždy rovná nule.
- ▶ Ako súvisí priebeh ACF s koreňmi (reálne/komplexné)? Ako súvisí s priebehom koeficientov Woldovej reprezentácie? Vyskúšajte aj na príkladoch iných procesov.

Cvičenie 7: ACF pre odhadnuté modely

Zadanie 2 pre dáta o inflácii:

- ▶ Uvažujme modely, ktorých koeficienty máme uložené v zozname koefAR.
- ▶ Pomocou `sapply` vypočítajte pre každý z nich hodnoty ACF, zobrazte ich graficky a porovnajte.
- ▶ Porovnajte aj s výstupom z cvičenia, v ktorom sme porovnávali koeficienty Woldovej reprezentácie.

Cvičenie 8: Stacionarita AR(2) procesu

Vytvorte funkciu, ktorá pre zadaný vektor parametrov (α_1, α_2) vráti TRUE, resp. FALSE podľa toho, či je AR(2) proces s týmito koeficientami stacionárny alebo nie.

```
stacAR2 <- function(alpha12) {  
  # vstup: dvojzložkový vektor koeficientov  
  # vytup: TRUE/FALSE podľa stacionarity  
  ....  
}
```

Otestujte:

```
stacAR2(c(1.2, -0.5))
```

```
## [1] TRUE
```

```
stacAR2(c(1.2, 0.5))
```

```
## [1] FALSE
```

```
stacAR2(c(0.5, 0)) # ar(1), ale stacionarny
```

```
## [1] TRUE
```

```
stacAR2(c(0, 0)) # konstanta + biely sum -> stacionarny
```

```
## [1] TRUE
```

- ▶ Správime sieť bodov (α_1, α_2) a zakreslíme, ktoré sú stacionárne a ktoré nie sú.
- ▶ Na vytvorenie dvojíc bodov použijeme náhodne generované čísla z rovnomerného rozdelenia na štvorci $(-2, 2) \times (-2, 2)$.

```
set.seed(123)
alfa1 <- runif(1000, min = -2, max = 2)
alfa2 <- runif(1000, min = -2, max = 2)
df <- data.frame(alfa1, alfa2)
head(df)
```

```
##           alfa1           alfa2
## 1 -0.8496899 -0.90550906
## 2  1.1532205  0.37546773
## 3 -0.3640923 -1.35926075
## 4  1.5320696  1.41372096
## 5  1.7618691  1.39095663
## 6  1.0477710  0.00045075
```

- ▶ Teraz pridáme do *data frame* tretí stĺpec, v ktorom bude výsledok overovania stacionarity.
- ▶ Namiesto for-cyklu použijeme funkciu `apply`. Tá umožňuje aplikovať zadanú funkciu na riadky alebo stĺpce objektu (matica, data frame).

Ukážka použitia apply

```
set.seed(123)
dfUkazka <- data.frame(a = sample.int(5),
                       b = sample.int(5),
                       c = sample.int(5))
dfUkazka # nejake cisla
```

```
##   a b c
## 1 3 3 2
## 2 2 1 3
## 3 5 2 1
## 4 4 5 4
## 5 1 4 5
```

```
f <- function(x) (x[1] + x[2]) * x[3] # nejaka funkcia
```

```
# POUZITIE APPLY
```

```
apply(dfUkazka, # vstupne data pre funkciu  
      MARGIN = 1, # po riadkoch  
      FUN = f)   # pouzita funkcia
```

```
## [1] 12  9  7 36 25
```

```
# priradenie ako novy stlpec
```

```
dfUkazka$vysledok <- apply(dfUkazka, 1, f)  
dfUkazka
```

```
##   a b c vysledok
```

```
## 1 3 3 2         12
```

```
## 2 2 1 3          9
```

```
## 3 5 2 1          7
```

```
## 4 4 5 4         36
```

```
## 5 1 4 5         25
```

```
# DALŠIE POUZITIE APPLY: teraz nie je vstupom celý riadok  
g <- function(x) x[2]/x[1] + x[1] # zase nejaka funkcia  
dfUkazka$vysledok2 <- apply(dfUkazka[ , 3:4], 1, g)  
dfUkazka
```

```
##   a b c vysledok vysledok2  
## 1 3 3 2      12         8  
## 2 2 1 3       9         6  
## 3 5 2 1       7         8  
## 4 4 5 4      36        13  
## 5 1 4 5      25        10
```


Vrátime sa k overovaniu stacionarity:

- Pomocou `apply` a vytvorenej funkcie `stacAR2` pridajte do *data frame* `df` stĺpec s informáciou o stacionarite procesu s danými parametrami.

```
# na kontrolu  
head(df)
```

```
##          alfa1          alfa2 stacionarita  
## 1 -0.8496899 -0.90550906             TRUE  
## 2  1.1532205  0.37546773             FALSE  
## 3 -0.3640923 -1.35926075             FALSE  
## 4  1.5320696  1.41372096             FALSE  
## 5  1.7618691  1.39095663             FALSE  
## 6 -1.8177740 -0.08845275             FALSE
```

- ▶ Vykreslite body farebne odližené podľa toho, či je proces stacionárny alebo nie.



Cvičenie 9: Hľadanie AR modelu pre zadané dáta

Všetky nasledujúce dáta majú spoločné zadanie:

- ▶ nájsť vhodný autoregresný model pre zadané dáta
- ▶ vysvetliť, prečo sú rezíduá vyhovujúce - skomentovať ACF rezíduí aj Ljung-Boxov test, pričom treba presne povedať, aká hypotéza sa testuje a či sa v tomto prípade zamietá alebo nie (a prečo sme s tým výsledkom spokojní)
- ▶ overiť stacionaritu získaného modelu (napísať polynóm, ktorého korene overujete, aké absolútne hodnoty koreňov vyšli a prečo sme s tým spokojní)
- ▶ spraviť predikcie


V prípade modelovania diferencií sa treba na základe prítomnosti, resp. neprítomnosti trendu treba rozhodnúť, či do modelu zahrnúť konštantu alebo nie.

Dáta I. Ceny benzínu

Dáta z knižnice `astsa`, z popisu v helpe: *New York Harbor conventional regular gasoline weekly spot price FOB (in cents per gallon) from 2000 to mid-2010*. Zoberieme dáta od roku 2006.

```
library(astsa)
x <- window(gas, start = c(2006, 1))
```

Nájdite model pre premennú x tak, že budete jej diferencie modelovať AR procesom.


`plot(x)`

Dáta II. Indikátor od Boxa a Jenkinsa

Dáta z knižnice `astsa`, z popisu v helpe: *Leading indicator, 150 months; taken from Box and Jenkins (1970).*

```
library(astsa)  
x <- lead
```

Nájdite model pre premennú `x` tak, že budete jej diferencie modelovať AR procesom.

`plot(x)`

Dáta III. Hladina Hurónskeho jazera

Dáta z knižnice `datasets`, z popisu v helpe: *Annual measurements of the level, in feet, of Lake Huron 1875–1972*. Použijeme dáta od roku 1900.

```
library(datasets)
x <- window(LakeHuron, start = 1900)
```

Dáta nediferencujeme, AR model hľadáme priamo pre tieto dáta.

`plot(x)`