

# ARMA modely I. - autoregresné modely (AR), časť 1

Beáta Stehlíková

2-PMS-101 Časové rady

Fakulta matematiky, fyziky a informatiky, UK v Bratislave

## ARMA modely: plán prednášok

- ▶ Terminológia:
  - ▶ AR - autoregresný model - tieto slajdy
  - ▶ MA - kľzavé priemery, *moving average*
  - ▶ ARMA - ich kombinácia
- ▶ Najskôr: autoregresný model prvého rádu, AR(1)
  - ▶ definícia
  - ▶ podmienky stacionarity
  - ▶ výpočet momentov a ACF
  - ▶ simulované dáta
  - ▶ praktický príklad s reálnymi dátami
- ▶ Potom:
  - ▶ autoregresné procesy vyšších rádov
  - ▶ ako určiť vhodný rád procesu pre dané dáta
- ▶ V ďalších slajdoch: MA a ARMA modely

## Autoregresný proces prvého rádu - AR(1)

## Definícia, podmienky stacionarity, výpočet momentov a autokorelačnej funkcie (ACF)

## Rekurentná definícia a explicitné vyjadrenie

- ▶ AR(1) proces

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

kde  $\delta, \alpha$  sú konštanty a  $\{u_t\}$  je biely šum

- ▶ Nech pre  $t = t_0$  je daná hodnota  $x_{t_0}$ :

$$x_{t_0+1} = \delta + \alpha x_{t_0} + u_{t_0+1},$$

$$\begin{aligned} x_{t_0+2} &= \delta + \alpha x_{t_0+1} + u_{t_0+2} = \\ &\delta(1 + \alpha) + \alpha^2 x_{t_0} + (\alpha u_{t_0+1} + u_{t_0+2}) \end{aligned}$$

$$x_{t_0+3} = \dots$$

- ▶ Vo všeobecnosti:

$$x_{t_0+\tau} = \frac{1 - \alpha^\tau}{1 - \alpha} \delta + \alpha^\tau x_{t_0} + \sum_{j=0}^{\tau-1} \alpha^j u_{t_0+\tau-j}$$

## AR(1) - stacionarita

- ▶ Prepíšeme si explicitné vyjadrenie do tvaru

$$x_t = \frac{1 - \alpha^{t-t_0}}{1 - \alpha} \delta + \alpha^{t-t_0} x_{t_0} + \sum_{j=0}^{t-t_0-1} \alpha^j u_{t-j}$$

- ▶ *Deterministická začiatočná podmienka*

- ▶ stredná hodnota závisí od začiatočnej podmienky  $x_{t_0} \rightarrow$  proces nie je stacionárny

- ▶ *Náhodná začiatočná podmienka*

- ▶ proces je generovaný aj pred začiatkom našich pozorovaní  $\rightarrow$  naša prvá pozorovaná hodnota je náhodná
- ▶ ak  $-1 < \alpha < 1$ , tak pre  $t_0 \rightarrow -\infty$  dostaneme

$$x_t = \frac{1}{1 - \alpha} \delta + \sum_{j=0}^{\infty} \alpha^j u_{t-j}$$

- ▶ to je Woldova reprezentácia s  $\psi_j = \alpha^j \rightarrow$  **stacionarita**

## Stredná hodnota

- ▶ Ďalej pracujeme so stacionárnym procesom, teda  $-1 < \alpha < 1$
- ▶ Pripomeňme si explicitné vyjadrenie procesu:

$$x_t = \frac{1}{1 - \alpha} \delta + \sum_{j=0}^{\infty} \alpha^j u_{t-j}$$

- ▶ Stredná hodnota:

$$\begin{aligned} \mathbb{E}(x_t) &= \mathbb{E} \left( \frac{1}{1 - \alpha} \delta + \sum_{j=0}^{\infty} \alpha^j u_{t-j} \right) \\ &= \frac{1}{1 - \alpha} \delta + \sum_{j=0}^{\infty} \alpha^j \mathbb{E}(u_{t-j}) = \frac{1}{1 - \alpha} \delta \end{aligned}$$

- ▶ Teda vo všeobecnosti  $\mathbb{E}(x_t) \neq \delta$  (rovnosť je len pre  $\delta = 0$ ), ale  $\mathbb{E}(x_t)$  a  $\delta$  majú rovnaké znamienko (lebo  $|\alpha| < 1$ )



## Disperzia

$$\begin{aligned}\mathbb{D}(x_t) &= \mathbb{D}\left(\frac{1}{1-\alpha}\delta + \sum_{j=0}^{\infty} \alpha^j u_{t-j}\right) \\ &= \sum_{j=0}^{\infty} \mathbb{D}\left(\alpha^j u_{t-j}\right) = \sum_{j=0}^{\infty} \alpha^{2j} \mathbb{D}(u_{t-j}) = \frac{\sigma^2}{1-\alpha^2},\end{aligned}$$

kde

- ▶ sme využili, že disperzia súčtu nekorelovaných náhodných premenných je súčet ich disperzií
- ▶  $\sigma^2$  je disperzia bieleho šumu  $\{u_t\}$

## Autokovariancie

$$\begin{aligned}
 \text{Cov}(x_t, x_{t-s}) &= \mathbb{E} \left[ \left( \sum_{i=0}^{\infty} \alpha^i u_{t-i} \right) \left( \sum_{j=0}^{\infty} \alpha^j u_{t-s-j} \right) \right] \\
 &= \sum_{i=0}^{\infty} \sum_{j=0}^{\infty} \alpha^{i+j} \mathbb{E}(u_{t-i} u_{t-s-j}) \\
 &= \sigma^2 \sum_{j=0}^{\infty} \alpha^{s+2j} = \alpha^s \frac{\sigma^2}{1 - \alpha^2},
 \end{aligned}$$

kde sme využili, že

- ▶  $\text{Cov}(u_k, u_l) = 0$  pre  $k \neq l$
- ▶  $\text{Cov}(u_k, u_l) = \sigma^2$  pre  $k = l$

## Autorelácie

- ▶ Autokorelačná funkcia AR(1) procesu teda je

$$\text{Cor}(x_t, x_{t-s}) = \frac{\text{Cov}(x_t, x_{t-s})}{\sqrt{\mathbb{D}(x_t)}\sqrt{\mathbb{D}(x_{t-s})}} = \alpha^s$$

- ▶ Napríklad pre proces  $x_t = 10 + 0.4x_{t-1} + u_t$  je ACF rovná  $0.4^s$ ; numericky prvé členy:

```
## [1] 0.40000 0.16000 0.06400 0.02560 0.01024 0.00410
```

- ▶ *Otázka na opakovanie:* Aká je stredná hodnota tohto procesu?

## Simulované dáta

## Postup

- ▶ Budeme pracovať s AR(1) procesom

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

kde  $\delta = 0$  a  $\{u_t\}$  je biely šum s normálnym rozdelením a disperziou 10.

- ▶ Parameter  $\alpha \in (-1, 1)$ ,  $\alpha \neq 0$  zoberieme postupne z množiny  $\{0.9, 0.5, -0.9\}$  - uvidíme vplyv znamienka a absolútnej hodnoty
- ▶ Zobrazíme:
  - ▶ realizáciu procesu dĺžky 250 (funkcia `arima.sim` z balíka `stats`)
  - ▶ odhadnutú ACF z vygenerovaných dát - prvých 10 hodnôt (už poznáme funkciu `acf`)
  - ▶ presnú ACF - takisto prvých 10 hodnôt (máme odvodený vzorec)

## Prípád 1: $\alpha = 0.9$ - simulácia


```
set.seed(123) # kvoli reprodukovateľnosti  
x <- arima.sim(model = list(ar = c(0.9)),  
               n = 250, sd = sqrt(10))
```

### Poznámky:

- ▶ model je typu list, obsahuje vektory ar a ma členov (zatiaľ máme len jeden AR člen)
- ▶ n je dĺžka časového radu
- ▶ sd je štandardná odchýlka bieleho šumu (defaultne sd = 1)


## Prípád 1: $\alpha = 0.9$ , priebeh

```
plot(x)
```



Prípád 1:  $\alpha = 0.9$ , odhadnutá ACF z dát


```
acf(x, lag.max = 10)
```






Prípád 1:  $\alpha = 0.9$ , presná ACF

```
plot(0:11, 0.9^(0:11), type = "h", xlab = "Lag", ylab = "ACF")
```





## Cvičenie: Práca v R-ku

Porovnajme graficky presnú a odhadnutú ACF, pričom vynecháme lag 0 (zbytočný - korelácia so sebou je rovná vždy 1)





## Prípád 2: $\alpha = 0.5$ , priebeh



Prípád 2:  $\alpha = 0.5$ , odhadnutá a presná ACF

## Prípád 3: $\alpha = -0.9$ , priebeh



Prípád 3:  $\alpha = -0.9$ , odhadnutá a presná ACF

## Cvičenie: Proces s nenulovou strednou hodnotou

**Cvičenie 1.** Proces  $x_t = \delta + 0.9x_{t-1} + u_t$  simulujeme nasledovným kódom:

```
x <- 10 + arima.sim(model = list(ar = c(0.9)), n = 50)
```

Vyberte správnu hodnotu  $\delta$  :

- ▶  $\delta = 10$
- ▶  $\delta = 10 \times (1 - 0.9) = 1$
- ▶  $\delta = \frac{10}{1-0.9} = 100$

**Cvičenie 2.** Vygenerujte simuláciu procesu  $x_t = -1 + 0.6x_{t-1} + u_t$

## Odhadovanie modelu v R-ku



## Funkcia sarima z balíka astsa

- ▶ Na odhadovanie modelu použijeme funkciu sarima v tvare:


```
# AR(1) model pre k-te diferencie  
model <- sarima(data, 1, k, 0, details = FALSE)
```

- ▶ Napríklad pre simulované dáta:

```
# vygenerujeme simuláciu AR(1) procesu  
set.seed(123)  
x <- 10 + arima.sim(model = list(ar = c(0.9)), n = 50)  
  
# odhadneme pre získané dáta AR(1) model  
library(astsa)  
model <- sarima(x, 1, 0, 0, details = FALSE)
```

## Kontrola rezíduí

Čo znázorňuje ACF a interval na nej? Čo testuje Ljung-Boxov test?  
S akými výsledkami?



Všimnime si, že LB test začína pri lagu 2 (a nie 1) a pripomeňme si zo slajdov o LB teste: "Počet stupňov voľnosti sa zmení, ak ide o rezíduá z modelu". O čo ide: Počet stupňov voľnosti sa zníži o počet AR (a neskôr aj MA) členov modelu.

## Ljung-Boxov test pre rezíduá

- Funkcia `Box.test` obsahuje parameter `fitdf`, ktorý zabezpečí správny počet stupňov voľnosti

```
> Box.test()
```

◆ x =	<b>fitdf</b>
◆ lag =	number of degrees of freedom to be subtracted if x is a series of residuals.
◆ type =	
◆ fitdf =	Press F1 for additional help

- Pomocou `str(model)` si pozrieme štruktúru objektu `model`, aby sme vedeli pristupovať k jeho zložkám, napríklad `model$fit$residuals` (časový rad rezíduí)
- Pomoc *R Studio*:

```
> model$fit$
```

◆ coef
◆ sigma2
var.coef
◆ mask
◆ loglik

- ▶ Máme AR(1) model, testujme na ukážku pre jeho rezíduá hypotézu  $\rho(1) = \rho(2) = \rho(3) = \rho(4) = 0$ :

```
Box.test(model$fit$residuals,  
         lag = 4,      # testujeme 4 autokor.  
         type = "Ljung-Box",  
         fitdf = 1) # jeden AR koeficient
```

```
##  
## Box-Ljung test  
##  
## data:  model$fit$residuals  
## X-squared = 2.7667, df = 3, p-value = 0.429
```

- ▶ Môžeme porovnať s výstupom z funkcie `sarima` aj s tým, čo by vyšlo, keby sme zabudli na parameter `fitdf`.

## Ďalšie zložky odhadnutého modelu

```
model$BIC # Bayesovo informacne kriterium
```

```
## [1] 2.86438
```

```
model$ttable # odhady, SE, t statistky, p hodnoty
```

```
##      Estimate      SE t.value p.value
## ar1      0.8671 0.0704 12.3209      0
## xmean    10.5917 0.8525 12.4249      0
```

```
model$fit$coef # odhadnute parametre ako vektor
```

```
##      ar1      xmean
## 0.86707 10.59174
```

**Zápis odhadnutého modelu:** z vektora parametrov `model$fit$coef` vidíme, že odhadnutý model je

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

kde  $\alpha$  je parameter `ar1` (0.86707) a  $\delta$  je také, že stredná hodnota procesu  $\mathbb{E}(x_t)$  je rovná parametru `xmean` (10.59174).


### Cvičenia:

- ▶ Dopočítajte hodnotu parametra  $\delta$  pomocou uvedených zaokrúhlených hodnôt
- ▶ Dopočítajte hodnotu parametra  $\delta$  pomocou prístupu k presným hodnotám odhadnutých parametrov `xmean` a `ar1`.

## Reálne dáta: Volebné preferencie v Nemecku

## Dáta

- ▶ Nemecko, január 1971 - apríl 1982
- ▶  $CDU_t$  - volebné preferencie CDU/CSU



Prebraté z učebnice *Kirchgässner & Wolters, example 2.2*

Citovaný pôvodný zdroj dát: *G. Kirchgässner: Causality Testing of the Popularity Function: An Empirical Investigation for the Federal Republic of Germany, 1971-1982, Public Choice 45 (1985), p. 155-173.*



## Odhadnutý AR(1) model


V knihe sa píše:

$$\text{CDU}_t = 8.053 + 0.834 \text{CDU}_{t-1} + \hat{u}_t,$$

(3.43)    (17.10)

$$\bar{R}^2 = 0.683, \text{ SE} = 1.586, \text{ Q}(11) = 12.516 \text{ (} p = 0.326\text{)}.$$

The estimated t values are given in parentheses. The autocorrelogram, which is also given in *Figure 2.4*, does not indicate any higher-order process. Moreover, the Box-Ljung Q Statistic with 12 correlation coefficients (i.e. with 11 degrees of freedom) gives no reason to reject this model.



## Odhadnutý AR(1) model - otázky


- ▶ *Je odhadnutý model stacionárny? Z čoho to vyplýva?*
- ▶ *Rezíduá modelu by mali byť bielym šumom:*
  - ▶ Na grafe sú pri autokoreláciách zostrojené intervaly. Na čo slúžia? Vypočítajte pomocou známych údajov ich hranice.
  - ▶ V texte sa spomínajú autokorelácie rezíduí a Ljung-Boxova Q štatistika - aké hypotézy sa testujú (a prečo), akým spôsobom, s akými závermi?
- ▶ *Čomu sa rovná stredná hodnota premennej  $CDU_t$ ?*

Pripomeňme si znovu zo slajdov o LB teste: “Počet stupňov voľnosti sa zmení, ak ide o rezíduá z modelu” aj vysvetlenie: *Počet stupňov voľnosti sa zníži o počet AR (a neskôr aj MA) členov modelu.*

## Predikcie


## Podmienená a nepodmienená stredná hodnota (simulácie)

- Generujeme proces  $x_t = 0.9x_{t-1} + u_t$  a zaujíma nás očakávaná hodnota v čase 20 - je nulová





## Podmienená a nepodmienená stredná hodnota (simulácie)

- ▶ Ak už máme prvých 19 hodnôt a pýtame sa na očakávanú hodnotu v čase 20 - *je to iná situácia*



## Podmienená a nepodmienená stredná hodnota (simulácie)



- ▶ Vľavo: *nepodmienená* stredná hodnota procesu
- ▶ Vpravo: *podmienená* stredná hodnota procesu (podmienená doterajším priebehom) - toto nás zaujíma pri **predikciách**

## Podmienená a nepodmienená stredná hodnota (dáta)

- ▶ Máme stacionárny proces

$$x_t = 8.053 + 0.834x_{t-1} + u_t$$

ako model pre volebné preferencie  $x_t := CDU_t$

- ▶ Vieme nájsť *nepodmienenú strednú hodnotu procesu* - je samozrejme konštantná
- ▶ Môžeme sa však pýtať na **predikcie**:
  - ▶ Aká je očakávaná hodnota preferencií budúci mesiac, ak terajšie preferencie sú 40 percent?
  - ▶ Aká je očakávaná hodnota preferencií budúci mesiac, ak terajšie preferencie sú 55 percent?
- ▶ Odpovede budú **rôzne**. Pri týchto otázkach hľadáme *podmienenú strednú hodnotu*.

## Intuitívne postup

- ▶ Pri AR modeloch zostaneme pri intuitívnom postupe (presnejšie a formálnejšie potom pri tých modeloch, kde postup konštrukcie predikcií nebude zrejmý)
- ▶ Pripomeňme si, že pre  $x_t := CDU_t$  máme model

$$x_t = 8.053 + 0.834x_{t-1} + u_t$$

- ▶ Pri predikciách biely šum  $u_t$  nahradíme jeho strednou hodnotou - nulou
- ▶ Za  $x_{t-1}$  dosadíme
  - ▶ skutočnú hodnotu  $x_{t-1}$ , ak ju máme k dispozícii
  - ▶ predikciu hodnoty  $x_{t-1}$ , ak sa ešte nerealizovala



## Numerická realizácia

- Postup je dobre viditeľný pri použití tabuľkového editora:

	A	B
1	delta	8.053
2	alfa	0.834
3		
4		40
5	=B\$1+B\$2*A4	
6		


	A	B
1	delta	8.053
2	alfa	0.834
3		
4		40
5	41.413	
6	=B\$1+B\$2*A5	
7		

	A	B
1	delta	8.053
2	alfa	0.834
3		
4		40
5	41.413	
6	42.59144	
7	43.57426	
8	44.39394	
9	45.07754	
10	45.64767	
11	46.12316	
12	46.51971	
13	46.85044	
14	47.12627	
15	=B\$1+B\$2*A14	

## Numerická realizácia

- Predikcie pre začiatočné hodnoty 40 a 55 percent:



- Konvergujú k spoločnej hodnote, ktorá sa rovná nepodmienenej strednej hodnote procesu
- Prakticky - treba si zvážiť, na aké dlhé obdobie má zmysel použiť model pri predikovaní

## V R-ku: funkcia `sarima.for` z balíka `astsa`

- ▶ Naše simulované dáta:

```
set.seed(123)
x <- 10 + arima.sim(model = list(ar = c(0.9)), n = 50)
```

- ▶ Najskôr odhadneme a otestujeme model pomocou funkcie `sarima`:


```
sarima(x, 1, 0, 0) # odhadli sme AR(1) model - je OK
```

- ▶ Z dobrého modelu môžeme robiť predikcie:

```
sarima.for(x, n.ahead = 10, 1, 0, 0) # predikcie
                                     # 10 pozorovaní
sarima.for(x, 10, 1, 0, 0) # to iste (treba dať pozor na
                           # správne poradie parametrov)
```

Predikcie a intervaly spoľahlivosti ( $\pm 1$  a  $2$  štandardné odchýlky):

```
sarima.for(x, n.ahead = 10, 1, 0, 0)
```



## Autoregresný proces vyššieho rádu - AR(p)

## Motivácia - prečo nestačí AR(1)

## Prečo nestačí AR(1) - niekoľko pohľadov

- ▶ Celkom prirodzene môžeme očakávať, že na dobré popísanie vývoja  $x_t$  nám nebude stačiť  $x_{t-1}$ , ale budeme potrebovať aj  $x_{t-2}$  (prípadne aj  $x_{t-3}$  a  $x_{t-4}$  a pod.)
- ▶ AR(1) proces má dosť obmedzené možnosti pri zachytení priebehu ACF - napríklad neumožňuje modelovať periodický charakter
- ▶ Niekedy to nemusí byť dopredu zrejmé z dát, ani z odhadnutej ACF, ale AR(1) nebude vyhovovať kvôli rezíduám - *toto uvidíme na príklade*


## Príklad: Úrokové miery

- ▶ Štvrťročné dáta, 1952Q1 - 2005Q4
- ▶ Premenné:
  - ▶ krátkodobá úroková miera (3 mesiace)
  - ▶ dlhodobá úroková miera (20 rokov)
- ▶ Budeme modelovať *spread*, teda rozdiel dlhodobej a krátkodobej úrokovej miery


Mills, Markellos: *The Econometric Modelling of Financial Time Series*. Cambridge University Press, 2008



## Príklad: Úrokové miery - priebeh dát



## Príklad: Úrokové miery - odhadnutá ACF



Podobá sa na AR(1) proces s kladným parametrom  $\alpha$ .

## Príklad: Úrokové miery - parametre AR(1) modelu


Parameter  $\alpha$  AR(1) modelu (vo výstupe označený ako ar1) je medzi -1 a 1, teda získaný proces je stacionárny - toto je ok.

##		Estimate	SE	t.value	p.value
##	ar1	0.9156	0.0266	34.4589	0.0000
##	xmean	1.0473	0.5491	1.9075	0.0578


## Príklad: Úrokové miery - rezíduá AR(1) modelu

Rezíduá sa nesprávajú ako biely šum, model je nevyhovujúci.

ACF of Residuals



p values for Ljung-Box statistic



## Príklad: Úrokové miery - parametre AR(2) modelu


Zatiaľ sa na ne pozrime, analyzovať ich budeme neskôr.

##		Estimate	SE	t.value	p.value
##	ar1	1.1809	0.0650	18.1566	0.0000
##	ar2	-0.2886	0.0651	-4.4321	0.0000
##	xmean	1.0449	0.4212	2.4807	0.0139


## Príklad: Úrokové miery - rezíduá AR(2) modelu

Vieme však už teraz zhodnotiť rezíduá - tie sú v poriadku. AR(2) ako model je dobrý.

ACF of Residuals



p values for Ljung-Box statistic



## Definícia autoregresného procesu vyššieho rádu

## AR(2) a všeobecný AR(p) proces

- ▶ **AR(2) proces** modeluje  $x_t$  pomocou  $x_{t-1}$  a  $x_{t-2}$ :

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

Analogicky, **AR(p) proces** modeluje  $x_t$  pomocou  $p$  predchádzajúcich hodnôt  $x_{t-1}, \dots, x_{t-p}$ :

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

- ▶ Odhadovanie AR(p) modelu pre k-te diferencie v R-ku:


```
sarima(data, p, k, 0)
```



## Simulácie AR(2) procesov

**Príklad 1.** Proces  $x_t = 0.5x_{t-1} + 0.2x_{t-2} + u_t$

```
x1 <- arima.sim(model = list(ar = c(0.5, 0.2)), n = 100)
```



**Príklad 2.** Proces  $x_t = 0.5x_{t-1} + 0.6x_{t-2} + u_t$  spôsobí chybu - nie je stacionárny


```
> x2 <- arima.sim(model = list(ar = c(0.5, 0.6)), n = 100, sd = 1)
Error in arima.sim(model = list(ar = c(0.5, 0.6)), n = 100, sd = 1) :
  'ar' part of model is not stationary
```

- ▶ NEPLATÍ teda “zovšeobecnenie” z AR(1) prípadu, že ak je  $\alpha_1, \alpha_2$  v absolútnej hodnote menej ako 1, tak je proces  $x_t = \delta + \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + u_t$  stacionárny.

**Príklad 3.** Proces  $x_t = 1.2x_{t-1} - 0.8x_{t-2} + u_t$  chybu nespôsobí - je stacionárny

- ▶ NEPLATÍ teda ani také “zovšeobecnenie”, že ak je niektorá z hodnôt  $\alpha_1, \alpha_2$  v absolútnej hodnote väčšia ako 1, tak je proces  $x_t = \delta + \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + u_t$  nestacionárny.

```
x3 <- arima.sim(model = list(ar = c(1.2, -0.8)), n = 100)  
plot(x3)
```



- ▶ Nemôžeme však čakať také jednoduché explicitné vyjadrenie AR(p) procesu ako pre AR(1), lebo je zložitejšie aj bez bieleho šumu (diferenčná rovnica) → **proces prepíšeme inak, aby sa s ním lepšie pracovalo** → definujeme tzv. **operátor posunu**.

## Operátor posunu

Operátor posunu (lag operator)  $L$  - vráti hodnotu procesu o jedno pozorovanie dozadu:

$$Lx_t = x_{t-1}$$

Niektoré vlastnosti:

- ▶ dajú sa robiť mocniny:  $L^2x_t = L(Lx_t) = x_{t-2}$ ,  $L^3x_t = x_{t-3}$  a pod.
- ▶ počítanie s mocninami:  $L^2(L^3) = L^5$
- ▶  $L^0 = 1$  je identita
- ▶ násobenie:  $(1 - 0.5L)(1 + 0.2L) = 1 - 0.3L - 0.1L^2$
- ▶ konštanta je vlastne konštatný proces, posunom sa nezmení:  
 $(1 - 0.2L + 0.3L^2)c = c - 0.2c + 0.3c = 1.1c$

## Definícia a podmienky stacionarity pre AR(2)

## Rekurentná definícia a zápis pomocou operátora posunu

- ▶ Definíciu sme už videli:

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

- ▶ Teraz proces prepíšeme pomocou operátora posunu  $L$  :

$$x_t = \delta + \alpha_1 Lx_t + \alpha_2 L^2 x_t + u_t$$

a teda

$$(1 - \alpha_1 L - \alpha_2 L^2)x_t = \delta + u_t$$



## Podmienky stacionarity

- ▶ Potrebujeme proces zapísať v tvare Woldovej reprezentácie
- ▶ Chceli by sme spraviť:

$$x_t = (1 - \alpha_1 L - \alpha_2 L^2)^{-1} \delta + (1 - \alpha_1 L - \alpha_2 L^2)^{-1} u_t$$

- ▶ Treba teda zistiť, kedy existuje inverzný operátor  $(1 - \alpha_1 L - \alpha_2 L^2)^{-1}$  a čomu sa rovná

## Podmienky stacionarity

- ▶ Použijeme metódu neurčitých koeficientov:

$$(1 - \alpha_1 L - \alpha_2 L^2)^{-1} = \psi_0 + \psi_1 L + \psi_2 L^2 + \dots$$

- ▶ Z toho:

$$1 = (1 - \alpha_1 L - \alpha_2 L^2)(\psi_0 + \psi_1 L + \psi_2 L^2 + \dots)$$

- ▶ Porovnáme koeficienty pri  $L^j$  na oboch stranách:

$$\psi_0 = 1, \psi_1 = \alpha_1$$

$$\psi_j - \alpha_1 \psi_{j-1} - \alpha_2 \psi_{j-2} = 0$$

## Podmienky stacionarity

- **Podmienka stacionarity:** Kvôli splneniu podmienky  $\sum_{j=0}^{\infty} \psi_j^2 < \infty$  musia byť korene charakteristickej rovnice

$$\lambda^2 - \alpha_1 \lambda - \alpha_2 = 0$$

v absolútnej hodnote menšie ako 1.

- Inak povedané (obvyklá formulácia v súvislosti s časovými radmi): **korene rovnice**

$$1 - \alpha_1 L - \alpha_2 L^2 = 0$$

musia byť v absolútnej hodnote väčšie ako 1, teda **mimo jednotkového kruhu**

- Všimnime si, že to isté vyšlo pre AR(1) proces  $\alpha(L)x_t = \delta + u_t$ , kde  $\alpha(L) = 1 - \alpha L$  - koreň polynómu  $\alpha(L)$  musí byť mimo jednotkového kruhu

## Podmienky stacionarity v R-ku

- ▶ Funkcia `polyroot`:

A polynomial of degree  $n - 1$ ,

$$p(x) = z_1 + z_2 * x + \dots + z[n] * x^{(n-1)}$$

is given by its coefficient vector `z[1:n]`. `polyroot` returns the  $n-1$  complex zeros of  $p(x)$

## Podmienky stacionarity v R-ku: príklad

Overíme stacionaritu procesu

$$x_t = 1.2 + 0.3x_{t-1} - 0.8x_{t-2} + u_t,$$

teda

$$(1 - 0.3L + 0.8L^2)x_t = 1.2 + u_t$$

Je stacionárny, lebo všetky absolútne hodnoty sú väčšie ako 1:

```
polyroot(c(1, -0.3, 0.8)) # korene
```

```
## [1] 0.1875+1.1022i 0.1875-1.1022i
```

```
abs(polyroot(c(1, -0.3, 0.8))) # abs. hodnoty
```

```
## [1] 1.118034 1.118034
```

## AR(2) model pre spread: stacionarita

- ▶ Pripomeňme si výstup:

##		Estimate	SE	t.value	p.value
##	ar1	1.1809	0.0650	18.1566	0.0000
##	ar2	-0.2886	0.0651	-4.4321	0.0000
##	xmean	1.0449	0.4212	2.4807	0.0139

- ▶ Teda model je

$$x_t = \delta + 1.1809x_{t-1} - 0.2886x_{t-2} + u_t$$

parameter  $\delta$  je taký, aby platilo  $\mathbb{E}(x_t) = 1.0449$

- ▶ Prepíšeme pomocou polynómu v  $L$ :

$$(1 - 1.1809L + 0.2886L^2)x_t = \delta + u_t$$

## AR(2) model pre spread: stacionarita

- ▶ Nájďme presné hodnoty koeficientov modelu

$$(1 - 1.1809L + 0.2886L^2)x_t = \delta + u_t :$$

- ▶ Pripomeňme si štruktúru objektu ar2 pomocou `str(ar2)`, potrebujeme vytiahnuť hodnoty koeficientov:

```
ar2$fit$coef
```

```
##          ar1          ar2          xmean
## 1.1808724 -0.2885893  1.0449355
```

```
polyroot(c(1, -1.1809, 0.2886)) # priblizne
polyroot(c(1, -ar2$fit$coef[1:2])) # presne
```

## AR(2) model pre spread: stacionarita

- ▶ Rozdiel pri použití približných a presných koeficientov je malý, ale druhý postup sa dá používať automaticky, bez kopírovania výstupu

```
abs(polyroot(c(1, -ar2$fit$coef[1:2])))
```

```
## [1] 1.196978 2.894901
```


- ▶ Absolútne hodnoty sú všetky väčšie ako 1 → **stacionarita**




## AR(2) model pre spread: rezíduá

V rezíduách nie je významná autokorelácia, model je vyhovujúci:


ACF of Residuals



p values for Ljung-Box statistic



## AR(2) model pre spread: rezíduá



- ▶ Všimnime si, že LB štatistika začína od lagu 3
- ▶ Počet stupňov voľnosti je počet testovaných korelácií mínus 2 (tá 2 pochádza z toho, že máme AR(2) model)

## Cvičenia

**Cvičenie 1.** Uvažujme proces  $x_t = 5 - 0.4x_{t-1} + 0.1x_{t-2} + u_t$

- ▶ Ukážte, že je stacionárny.
- ▶ Odvodte diferenčnú rovnicu a začiatočné podmienky pre koeficienty Woldovej reprezentácie. Vypočítajte rekurentne niekoľko prvých členov. Potom odvodte explicitný predpis pre všeobecný člen.

*# na kontrolu Woldova reprezentácia z R-ka*

```
ARMAtoMA(ar = c(-0.4, 0.1), lag.max = 5)
```

```
## [1] -0.40000  0.26000 -0.14400  0.08360 -0.04784
```

**Cvičenie 2.** Zopakujte pre proces  $x_t = 5 + 0.4x_{t-1} - 0.1x_{t-2} + u_t$

## Definícia a podmienka stacionarity pre AR(p)

- ▶ AR(p) proces:

$$x_t = \delta + \alpha_1 x_{t-1} + \dots + \alpha_p x_{t-p} + u_t, \quad (1)$$

teda  $\alpha(L)x_t = \delta + u_t$ , kde  $\alpha(L) = 1 - \alpha_1 L - \dots - \alpha_p L^p$

- ▶ Woldova reprezentácia a stacionarita:

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

inverzný operátor  $\alpha(L)^{-1}$  hľadáme v tvare

$$\alpha(L)^{-1} = 1 + \phi_1 L + \phi_2 L^2 + \dots$$

- ▶ Pre koeficienty  $\phi_j$  dostaneme diferenčnú rovnicu

$$\phi_k - \alpha_1 \phi_{k-1} - \dots - \alpha_p \phi_{k-p} = 0$$

⇒ kvôli konvergencii  $\sum \phi_j^2$  musia byť **korene polynómu  $\alpha(L)$  mimo jednotkového kruhu**

## Príklad 1

- ▶ Proces  $x_t = 0.2x_{t-1} + 0.3x_{t-1} - 0.6x_{t-3} + u_t$
- ▶ Je stacionárny, všetky korene  $1 - 0.2L - 0.3L^2 + 0.6L^3$  sú mimo jednotkového kruhu

```
abs(polyroot(c(1, -0.2, -0.3, 0.6)))
```


```
## [1] 1.218935 1.121728 1.218935
```

- ▶ Korene:

```
##           Re           Im           Mod
## 1  0.8109  0.9101  1.2189
## 2 -1.1217  0.0000  1.1217
## 3  0.8109 -0.9101  1.2189
```

## Príklad 1

► Grafické znázornenie koreňov



## Príklad 2

- ▶ Proces  $x_t = 0.2x_{t-1} + 0.3x_{t-1} - 0.6x_{t-3} + 0.5x_{t-4} + u_t$
- ▶ Nie je stacionárny, jeden z koreňov polynómu  $1 - 0.2L - 0.3L^2 + 0.6L^3 - 0.5L^4$  je vnútri jednotkového kruhu

```
abs(polyroot(c(1, -0.2, -0.3, 0.6, -0.5)))
```

```
## [1] 1.2494352 0.9493448 1.2494352 1.3495174
```


- ▶ Korene:

```
##      Re      Im      Mod
## 1  0.3999  1.1837  1.2494
## 2 -0.9493  0.0000  0.9493
## 3  0.3999 -1.1837  1.2494
## 4  1.3495  0.0000  1.3495
```



## Príklad 2

- ▶ Grafické znázornenie koreňov:



## Užitočnosť pridávania ďalších AR členov

### Predikovanie dopytu po elektrine:

Vu, D. H., Muttaqi, K. M., Agalgaonkar, A. P., & Bouzerdoum, A. (2016). **Intra-hour and hourly demand forecasting using selective order autoregressive model.** In 2016 IEEE International Conference on Power System Technology (POWERCON) (pp. 1-6). IEEE.




Fig. 5. Performance of the model with half hourly lags

When applying the autoregressive model given in (1) in load demand forecasting for the half hourly demand in NSW, the average performance of the model with different values of order  $p$  is recorded as shown in Fig. 5(a) and (b). It is noted that Fig. 5(b) is a zoom of Fig.5(a) from lag 2 to lag 6.

It can be seen from this Fig. 5(a) and (b) that the MAPE value reduces when adding more lag to the model until  $P = 5$ . After this critical value, the MAPE values get to the stationary state. Consequently, this critical value is selected as the order of the AR model for further development.