

Autoregresné modely: AR(p) model, stacionarita a Woldova reprezentácia

Beáta Stehlíková

Časové rady

Fakulta matematiky, fyziky a informatiky, UK v Bratislave

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

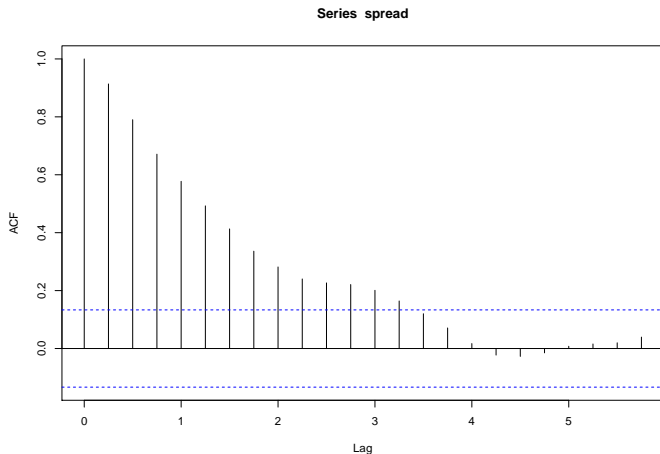
- ▶ Štvrťročné dáta, 1952Q1 - 2005Q4
- ▶ Premenné:
 - ▶ krátkodobá úroková miera (3 mesiace)
 - ▶ dlhodobá úroková miera (20 rokov)
- ▶ Budeme modelovať *spread*, teda rozdiel dlhodobej a krátkodobej úrokovej miery

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 α .

Príklad: Úrokové miery - parametre AR(1) modelu


Parameter α 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 - rezíduá AR(2) modelu

Rezíduá AR(2) modelu sú v poriadku:

ACF of Residuals



p values for Ljung-Box statistic



Príklad: Úrokové miery - parametre AR(2) modelu

- ▶ Potrebujeme ešte odvodiť podmienku stacionarity AR(2), teda ako zistiť, že toto je stacionárny model:

##		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

- ▶ Potom pre $\alpha_1 = \text{ar1}$, $\alpha_2 = \text{ar2}$, $\mu = \mathbb{E}(x_s) = \text{xmean}$ platí:

$$x_t = \delta + \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + u_t \quad / \mathbb{E}().$$

$$\mu = \delta + \alpha_1 \mu + \alpha_2 \mu \Rightarrow \delta = \mu(1 - \alpha_1 - \alpha_2)$$

- ▶ Model je $x_t = 0.1125 + 1.1809x_{t-1} - 0.2886x_{t-2} + u_t$

Proces vyššieho rádu, ukážka stacionárneho a nestacionárneho procesu, operátor posunu

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)
```

- ▶ Budeme sa teraz zaoberať **AR(2) modelom** (podstatný rozdiel oproti AR(1)), potom AR(p) už bude analogický AR(2).

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 α_1, α_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 α_1, α_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)
```



Stratégia pre odvodenie podmienky stacionarity

- ▶ **Proces prepíšeme inak, aby sa s ním lepšie pracovalo** → definujeme tzv. **operátor posunu**.
- ▶ **Operátor posunu (lag operator) L** - vráti hodnotu procesu o jedno pozorovanie dozadu:

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

- ▶ **Dôležité**, budeme ho používať v mnohých odvozeniach

Operátor posunu

- ▶ Zopakovanie definície: $Lx_t = x_{t-1}$
- ▶ 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:
 $(1 - 0.2L + 0.3L^2)c = c - 0.2c + 0.3c = 1.1c$
- ▶ **Príklad.** AR(3) proces

$$x_t = 10 + 0.3x_{t-1} + 0.2x_{t-2} - 0.1x_{t-3} + u_t$$

sa dá zapísať ako

$$x_t = 10 + 0.3Lx_t + 0.2L^2x_t - 0.1L^3x_t + u_t$$

$$(1 - 0.3L - 0.2L^2 + 0.1L^3)x_t = 10 + u_t$$

Podmienka stacionarity pre AR(2)

Podmienka stacionarity: odvodenie

- ▶ Máme proces:

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

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

- ▶ Potrebujeme ho **zapísať v tvare Woldovej reprezentácie**.
- ▶ Chceli by sme teda 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

- ▶ 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:

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

$$\psi_k - \alpha_1 \psi_{k-1} - \alpha_2 \psi_{k-2} = 0$$

- ▶ Woldova reprezentácia obsahuje podmienku $\sum_{k=0}^{\infty} \psi_k^2 < \infty$
(zabezpečí existenciu potrebného inverzného operátora)

- Rekurentne počítané ψ_k pre dve dvojice parametrov α_1, α_2 (zo stacionárneho a nestacionárneho procesu):

	A	B	C	D
1	alpha_1		0,5	1,2
2	alpha_2		0,6	-0,8
3				
4	phi_0 = 1	1	1	1
5	phi_1 = alpha_1	2	0,5	1,2
6	phi_k = alpha_1 phi_{k-1} + alpha_2 phi_{k-2}	3	0,85	0,64
7		4	0,725	-0,192
8		5	0,8725	-0,7424
9		6		=D\$1*D8+D\$2*D7
10		7	0,959125	-0,290816
11		8	1,0023125	0,2408448
12		9	1,07663125	0,52166656
13		10	1,139703125	0,433324032
203		200	148555,43	-1,71356E-10
204		201	158054,2172	-2,71857E-10
205		202	168160,3666	-1,89143E-10
206		203	178912,7136	-9,48602E-12
207		204	190352,5768	1,39931E-10

- ▶ Riešenie rovnice $\psi_k - \alpha_1\psi_{k-1} - \alpha_2\psi_{k-2} = 0$ hľadáme v tvare $\psi_k = \lambda^k$.
- ▶ Dosadením dostaneme, že nenulové ψ_k je riešením práve vtedy, ak

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

- ▶ Ak má táto kvadratická rovnica dva korene (reálne alebo komplexné), máme dve riešenia a všeobecné riešenie je

$$\psi_k = c_1\lambda_1^k + c_2\lambda_2^k.$$

- ▶ Ak je koreň dvojnásobný, druhé riešenie je $k\lambda^k$ a všeobecné riešenie

$$\psi_k = c_1\lambda^k + c_2k\lambda^k.$$

- ▶ Konštanty c_1, c_2 zo začiatočných podmienok ψ_0, ψ_1

Podmienka stacionarity: záver

- ▶ **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

Podmienka 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 $p(x)$

Podmienka 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 δ 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

- ▶ Nájďeme 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


- ▶ Pripomeňme si dobré 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)

AR(2) model pre spread: predikcie na 2 roky

```
sarima.for(spread, 8, 2, 0, 0) # kvartálne -> 8 hodnot
```



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 reprezentacia 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 $x_t = 5 + 0.4x_{t-1} - 0.1x_{t-2} + u_t$

```
# na kontrolu Woldova reprezentacia z R-ka
ARMAtoMA(ar = c(0.4, -0.1), lag.max = 5)
```

```
## [1] 0.40000 0.06000 -0.01600 -0.01240 -0.00336
```

- ▶ Zo začiatočných podmienok a rekurentného vzťahu je jasné, že hodnoty ψ_k . Upravte do predpis pre ψ_k do tvaru, ktorý neobsahuje imaginárne čísla.
- ▶ Výsledok z predchádzajúceho bodu budeme ešte potrebovať pri analýze autokorelačnej funkcie.

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 ϕ_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.