

ARMA modely I. - autoregresné modely (AR), časť 2

Beáta Stehlíková

2-PMS-101 Časové rady

Fakulta matematiky, fyziky a informatiky, UK v Bratislave

Výpočet momentov a autokorelačnej funkcie (ACF) autoregresných procesov

Stredná hodnota

AR(2) - stredná hodnota

- ▶ Majme stacionárny AR(2) proces

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

- ▶ Označme jeho strednú hodnotu $\mu = \mathbb{E}(x_t)$
- ▶ Potom platí

$$\begin{aligned}\mu &= \delta + \alpha_1 \mu + \alpha_2 \mu \\ \mu &= \frac{\delta}{1 - \alpha_1 - \alpha_2}\end{aligned}\tag{1}$$

- ▶ V menovateli nevznikne nula (to by znamenalo, že $L = 1$ je koreňom polynómu $1 - \alpha_1 L - \alpha_2 L^2$, ale tie majú absolútnu hodnotu väčšiu ako 1)

AR(2) model pre spread: zápis modelu

- 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
```

- Čo sme doteraz vedeli spraviť:

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

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

- Teraz už dopočítame aj δ zo vzťahu:

$$1.0449 = \frac{\delta}{1 - 1.1809 + 0.2886}$$

Stredná hodnota AR(p)

- ▶ Majme stacionárny AR(p) proces

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

- ▶ Označme $\mu = \mathbb{E}(x_t)$ a spravme strednú hodnotu z oboch strán:


$$\mu = \delta + \alpha_1 \mu + \dots + \alpha_p \mu \Rightarrow \mu = \frac{\delta}{1 - \alpha_1 - \dots - \alpha_p}$$

- ▶ Dá sa dokázať, že stredná hodnota procesu a parameter δ majú rovnaké znamienko.

Autokorelačná funkcia

AR(2) - autokorelačná funkcia - motivácia

- ▶ Videli sme výberovú ACF pre spread:



AR(2) - autokorelačná funkcia - motivácia

Poznámky a otázky:

- ▶ Výberová ACF pre spread sa podobala na AR(1) proces
- ▶ Napriek tomu AR(1) nebol dobrý model kvôli rezíduám, ale AR(2) už áno
- ▶ Aký priebeh má ACF pre AR(2) proces?
- ▶ *Môže mať podobný priebeh ako pre AR(1)? Zdá sa totiž, že áno.*
- ▶ *Môže mať "úplne iný" priebeh ako pre AR(1)? Teda, môžeme niekedy povedať, že "toto určite nie je AR(1), ale AR(2) by to mohol byť"?*

AR(2) - autokovariancie

- Môžeme uvažovať $\delta = 0$ (posun procesu o konštantu nezmení autokovariancie a autokorelácie - premyslite si presné zdôvodnenie):

$$x_t = \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + u_t / \times x_{t-s}, \mathbb{E}(\cdot)$$

$$\mathbb{E}(x_t x_{t-s}) = \alpha_1 \mathbb{E}(x_{t-1} x_{t-s}) + \alpha_2 \mathbb{E}(x_{t-2} x_{t-s}) + \mathbb{E}(x_{t-s} u_t)$$

- Pre $s = 0, 1, 2$ dostaneme:

$$\gamma(0) = \alpha_1 \gamma(1) + \alpha_2 \gamma(2) + \sigma^2$$

$$\gamma(1) = \alpha_1 \gamma(0) + \alpha_2 \gamma(1)$$

$$\gamma(2) = \alpha_1 \gamma(1) + \alpha_2 \gamma(0)$$

- sústava rovníc \rightarrow z nej $\gamma(0) = \mathbb{D}(x_t)$, $\gamma(1)$, $\gamma(2)$

- Pre $s \geq 2$ diferenčná rovnica

$$\gamma(s) - \alpha_1 \gamma(s-1) - \alpha_2 \gamma(s-2) = 0, \quad (2)$$

AR(2) - odbočka

Príklad na teoretické cvičenie:

Uvažujme AR(2) proces $x_t = 0,6x_{t-1} + 0,2x_{t-2} + u_t$, pričom disperzia bieleho šumu je 0,25.

- ▶ Ukážte, že je stacionárny.
- ▶ Odvodte (t.j. spravte všetky odvodenia, nedosadzte do všeobecných vzťahov z prednášky) diferenčnú rovnicu pre autokovariancie a sústavu rovníc pre začiatočné podmienky.
- ▶ Vyriešte v R-ku sústavu rovníc z predchádzajúceho bodu a rekurentne počítajte autokovariancie.
- ▶ Čomu sa rovná disperzia procesu?
- ▶ Vypočítajte z autokovariancií autokorelácie.

AR(2) - autokorelácie

- Diferenčnú rovnicu (2) a začiatočné podmienky vydelíme $\gamma(0)$:

$$\rho(s) - \alpha_1\rho(s-1) - \alpha_2\rho(s-2) = 0$$

$$\rho(0) = 1, \rho(1) = \frac{\alpha_1}{1 - \alpha_2}$$

AR(2) model pre spread: ACF modelu

- ▶ Spread máme modelovaný AR(2) procesom


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

- ▶ Nájďme ACF tohto procesu
- ▶ Diferenčná rovnica pre autokorelácie:

$$\rho(s) - 1.1809\rho(s-1) + 0.2886\rho(s-2) = 0$$


$$\rho(0) = 1, \rho(1) = \frac{1.1809}{1 - 0.2886}$$

AR(2) model pre spread: ACF modelu




AR(2) - charakter priebehu ACF - príklad 1

```
barplot(ARMAacf(ar=c(0.3, 0.2), lag.max = 15)[-1])
```



AR(2) - charakter priebehu ACF - príklad 2

```
barplot(ARMAacf(ar=c(0.8, -0.6), lag.max = 15)[-1])
```



AR(2) - charakter priebehu ACF

- ▶ ACF je riešením diferenčnej rovnice

$$\rho(s) - \alpha_1 \rho(s-1) - \alpha_2 \rho(s-2) = 0$$

⇒ priebeh závisí od koreňov charakteristickej rovnice

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

- ▶ λ_1, λ_2 reálne a rôzne: ACF má tvar

$$\rho(s) = c_1 \lambda_1^s + c_2 \lambda_2^s$$

zo stacionarity: $|\lambda_{1,2}| < 1$

- ▶ λ_1, λ_2 komplexné: ACF je tlmená kombinácia sínusu a kosínusu

$$\rho(s) = r^s (c_1 \cos(ks) + c_2 \sin(ks))$$

zo stacionarity: $|r| < 1$

AR(2) - ACF - príklad

- ▶ proces: $x_t = 1.4x_{t-1} - 0.85x_{t-2} + u_t$
- ▶ korelácie spĺňajú diferenčnú rovnicu

$$\rho(k) = 1.4\rho(k-1) - 0.85\rho(k-2)$$


- ▶ jej všeobecné riešenie

$$\rho(k) = 0.922^k (c_1 \cos(0.709k) + c_2 \sin(0.709k))$$

- ▶ konštanty c_1, c_2 zo začiatočných podmienok $\rho(0), \rho(1)$
- ▶ $\cos(nt), \sin(nt) \rightarrow$ perióda $\frac{2\pi}{n}$
- ▶ v našom prípade $\frac{2\pi}{n} = \frac{2\pi}{0.709} = 8.862 \approx 9 \Rightarrow$ v dátach generovaných týmto procesom sa dá čakať takáto perióda


AR(2) - ACF - príklad

```
x <- arima.sim(model = list(ar = c(1.4, -0.85)), n = 100)
plot(x, lwd = 2, col = "blue")
```



AR(2) - ACF - príklad

```
acf(x, lwd = 2, col = "blue")
```



ACF pre AR(p) proces

Variancia, autokovariancie

- ▶ Znovu môžeme predpokladať nulovú strednú hodnotu, teda
 $x_t = \alpha_1 x_{t-1} + \dots + \alpha_p x_{t-p} + u_t$
- ▶ Vynásobíme obidve strany členom x_{t-s} a spravíme strednú hodnotu:

$$x_t = \alpha_1 x_{t-1} + \dots + \alpha_p x_{t-p} + u_t \quad / \times x_{t-s}, \mathbb{E}(\cdot)$$

$$\gamma(s) = \alpha_1 \gamma(s-1) + \dots + \alpha_p \gamma(s-p) + \mathbb{E}(u_t x_{t-s})$$

Variancia, autokovariancie

- Pre $s = 0, 1, \dots, p \rightarrow$ sústava $p + 1$ rovníc s neznámymi $\gamma(0), \gamma(1), \dots, \gamma(p)$:

$$\begin{aligned}\gamma(0) &= \alpha_1\gamma(1) + \alpha_2\gamma(2) + \dots + \alpha_p\gamma(p) + \sigma^2 \\ \gamma(1) &= \alpha_1\gamma(0) + \alpha_2\gamma(1) + \dots + \alpha_p\gamma(p-1) \\ &\dots \\ \gamma(p) &= \alpha_1\gamma(p-1) + \alpha_2\gamma(p-2) + \dots + \alpha_p\gamma(0)\end{aligned}\quad (3)$$

- Ostatné autokovariancie z diferenciálnej rovnice

$$\gamma(s) - \alpha_1\gamma(s-1) - \dots - \alpha_p\gamma(s-p) = 0 \quad (4)$$

Autokorelácie

- ▶ Diferenčná rovnica pre autokorelácie - rovnicu (4) vydelíme disperziou $\gamma(0)$: $\rho(s) - \alpha_1\rho_{s-1} - \dots - \alpha_p\rho(s-p) = 0$
- ▶ Začiatkové podmienky - posledných p vydelíme $\gamma(0)$:

$$\begin{aligned}\rho(1) &= \alpha_1\rho(0) + \alpha_2\rho(1) + \dots + \alpha_p\rho(p-1) \\ &\dots \\ \rho(p) &= \alpha_1\rho(p-1) + \alpha_2\rho(p-2) + \dots + \alpha_p\rho(0)\end{aligned}$$

Cvičenie

Uvažujme proces $x_t = 0.2x_{t-1} + 0.3x_{t-2} - 0.6x_{t-3} + u_t$ (overovali sme jeho stacionaritu). Odvodte:

- ▶ jeho disperziu, ak je $\mathbb{D}(u_t) = 10$
- ▶ Yule-Wolkerove rovnice
- ▶ ACF pre lags 1- 5

pre kontrolu, funkcia ARMAacf

```
ARMAacf(ar = c(0.2, 0.3, -0.6), lag.max = 5)
```

```
##           0           1           2           3
## 1.0000000  0.04347826  0.28260870 -0.53043478 -0.04739
```


```
# kvoli prehľadnosti - hodnoty vypiseme pod seba  
cat(ARMAacf(ar = c(0.2, 0.3, -0.6), lag.max = 5),  
    sep = "\n")
```

```
## 1  
## 0.04347826  
## 0.2826087  
## -0.5304348  
## -0.0473913  
## -0.3381739
```

AR(p) model použitý na reálne dáta

Dáta

- ▶ 3-mesačná úroková miera, Nemecko, 1970q1 - 1998q4




a) Three months money market rate in Frankfurt
1970 – 1998

Odhadnutý AR(2) model

$$\text{GSR}_t = 0.577 + 1.407 \text{GSR}_{t-1} - 0.498 \text{GSR}_{t-2} + \hat{u}_t,$$

(2.82) (17.49) (-6.16)

$$\bar{R}^2 = 0.910, \text{ SE} = 0.812, Q(6) = 6.431 \text{ (} p = 0.377\text{)},$$



c) Estimated autocorrelation function of the residuals of the estimated AR(2) process with confidence intervals

Otázky k odhadnutému modelu

- ▶ Ukážte, že je stacionárny.
- ▶ Analyzujte rezíduá - autokorelogram a Q štatistiku. Aká hypotéza sa testuje, keď má Q štatistika rozdelenie so 6 stupňami voľnosti?
- ▶ Aká je stredná hodnota procesu?
- ▶ Aký je priebeh jeho autokorelačnej funkcie?
- ▶ Vysvetlite nasledovné tvrdenie z knihy: O aké korene ide? Odvodte aj ostatné hodnoty uvedené v texte. Ako sa z nich vypočíta perióda?

The two roots of the process are $0.70 \pm 0.06i$, i.e. they indicate cycles which are strongly dampened. The modulus (dampening factor) is $d = 0.706$; the frequency $f = 0.079$ corresponds to a period of 79.7 quarters and therefore of nearly 20 years.

Predikcie

Intuitívne postup

Máme model

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


pri predikciách postupujeme analogicky ako pri AR(1) modeli:

- ▶ 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
- ▶ Za x_{t-2} dosadíme
 - ▶ skutočnú hodnotu x_{t-2} , ak ju máme k dispozícii
 - ▶ predikciu hodnoty x_{t-2} , ak sa ešte nerealizovala

Rovnako by sme postupovali v prípade, ak by model obsahoval viac členov, t. j. $x_t = \delta + \alpha_1 x_{t-1} + \dots + \alpha_p x_{t-p} + u_t$

Príklad: predikcie pre spread


Predikcie a intervaly spoľahlivosti (+/- 1 a 2 štandardné odchýlky):



Záverečné poznámky k ACF


Autokorelácie - príklad 1

- ▶ AR(2) proces $x_t = 1.4x_{t-1} - 0.85x_{t-2} + u_t$




Autokorelácie - príklad 2

- AR(3) proces $x_t = 1.5x_{t-1} - 0.8x_{t-2} + 0.2x_{t-3} + u_t$




Autokorelácie - príklad 3

- ▶ AR(3) proces $x_t = 1.2x_{t-1} - 0.4x_{t-2} - 0.1x_{t-3} + u_t$
- ▶ Dajú sa očakávať komplexné korene



Autokorelácie - príklad 4



Autokorelácie - príklad 4

- ▶ Proces nie je stacionárny → predchádzajúci výpočet nemá zmysel

```
polyroot(c(1, -1.5, 0.8, 0.2))
```

```
## [1] 0.7610683+0.5711581i 0.7610683-0.5711581i -5.5221367
```

```
abs(polyroot(c(1, -1.5, 0.8, 0.2)))
```

```
## [1] 0.9515496 0.9515496 5.5221367
```

Autokorelácie - príklad 5 - motivácia pre PACF

- ▶ ACF - jedna pre AR(2), druhá pre AR(3) - nevieme ich rozlíšiť
- ▶ Pri práci s dátami máme navyše len odhad ACF

