

# *Autoregresné (AR) procesy*

Beáta Stehlíková

Cvičenia z časových radov, FMFI UK

# Príklad 1

- AR(2) proces z prednášky:  $x_t = 1.4x_{t-1} - 0.85x_{t-2} + u_t$
- Počítali sme:
  - diferenčnú rovnicu pre autokorelácie
  - korene charakteristického polynómu
  - explicitný predpis pre autokorelácie
  - parciálnu autokorelačnú funkciu
- Teraz to isté v R-ku:
  - korene charakteristického polynómu - overíme stacionaritu procesu
  - hodnoty ACF a PACF
- Potom:
  - vygenerujeme realizáciu procesu
  - odhadneme koeficienty (mali by byť blízke skutočným)

## Príklad 1: Stacionarita AR procesu

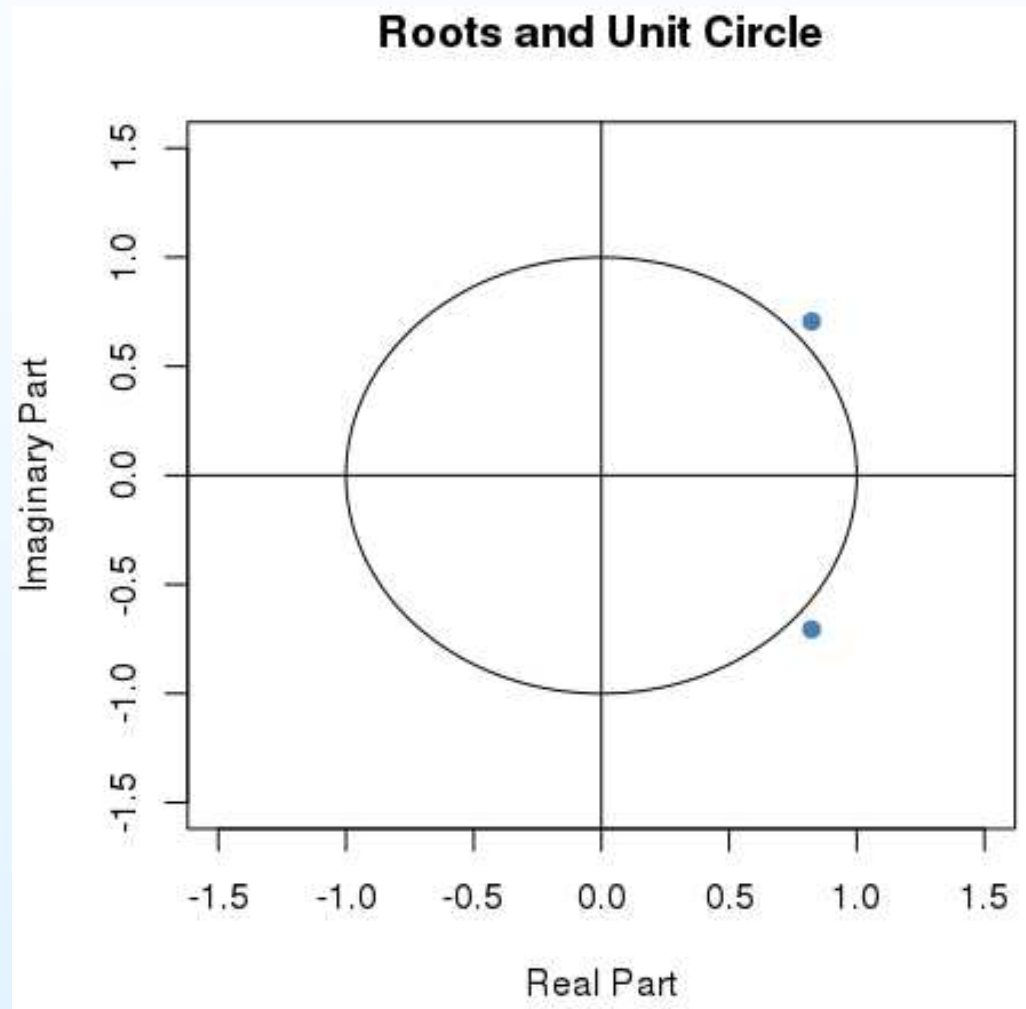
- Máme proces:  $x_t = 1.4x_{t-1} - 0.85x_{t-2} + u_t$
- Prepíšeme:  $(1 - 1.4L + 0.85L^2)x_t = u_t$
- Korene polynómu  $1 - 1.4L + 0.85L^2 = 0$  majú byť mimo jednotkového kruhu
- V R-ku:
  - knižnica `library(fArma)` (ak treba, najprv nainštalovať)
  - potom (pozor na znamienka): `armaRoots(c(1.4,-0.85))`
- Prvý výstup: tabuľka s koreňmi

```
> armaRoots(c(1.4, -0.85))
      re      im      dist
1 0.8235  0.7059  1.0847
2 0.8235 -0.7059  1.0847
```

v nej aj absolútna hodnota koreňov

# Príklad 1: Stacionarita AR procesu

- Druhý výstup: grafické znázornenie koreňov



## Príklad 1: Komplexné korene a perióda

- Komplexné korene  $\rightarrow$  periodický charakter procesu  $\rightarrow$  chceme vypočítať periódu
- Využívame pritom zápis komplexného čísla v tvare  $a + ib = \rho(\cos \varphi + i \sin \varphi) = \rho e^{i\varphi}$  a z neho hodnotu  $\varphi$
- Získame ju napr. takto:


```
> x=complex(real=0.8235, imaginary=0.7059)
> Arg(x)
[1] 0.7086563
```

- *Opakovanie:* Ako z tohto vypočítame periódu?

# Príklad 1: ACF a PACF

- Vypísanie hodnôt:
  - `ARMAacf(ar=c(1.4,-0.85),lag.max=10)` (vratane nulového lagu)
  - `ARMAacf(ar=c(1.4,-0.85),lag.max=10, partial="true")`
- Graficky napríklad takto:


```
barplot(ARMAacf(ar=c(1.4,-0.85),lag.max=20))
```



# Príklad 1: Realizácia, výberová (P)ACF

- Realizácia procesu:

```
x=arima.sim(n=100, list(ar = c(1.4,-0.85)),sd=1)
```



- Výberová ACF a PACF:
  - `acf(x)` (vrátane nulového lagu), `acf(x,type="partial")`
  - z knižnice `library(asts)` funkcia `acf2(x)` (ACF aj PACF na jednom obrázku; ACF bez nulového lagu)

# Príklad 1: Odhadovanie parametrov


---

- Budeme používať knižnicu `astsa`
- Odhadovnie AR(p) modelu: `sarima(x,p,0,0,details="false")`
- Dostaneme:
  - **výstup**: odhadnuté koeficienty, signifikantnosť, odhad štandardnej odchýlky náhodnej zložky, informačné kritériá
  - **graficky**: priebeh rezíduí, testovanie normality, ACF rezíduí, P-hodnota Ljung-Boxovej štatistiky



## Príklad 2

- Model z prednášky, úroková miera v Nemecku:



- Odhadnutý 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)

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


## Príklad 2

---

- Úlohy (niečo sme robili na prednáške ručne, teraz v R-ku):
  - Overte stacionaritu procesu a znázornite korene - kde majú ležať?
  - Interpretujte komplexné korene a ilustrujte ich na priebehu ACF
  - Vygenerujte dáta, ktoré zodpovedajú tomuto procesu. Znázornite ich priebeh a výberovú ACF a PACF. Spätne model odhadnite a porovnajte odhady s parametrami, z ktorých boli dáta generované.

## Príklad 3: Reálne dáta


- Počet oviec v tisícoch v Anglicku a Walese, 1867-1939
- Zdroj: <http://datamarket.com/data/set/22px/>
- Po načítaní dát  $x=ts(x)$  - spravíme z vektora časový rad



Zdá sa, že dáta nie sú stacionárne, ale majú klesajúci trend

## Príklad 3: Reálne dáta

- Budeme pracovať s diferenciami:



- Ak o dhadjeme  $AR(p)$  model pre  $k$ -te diferencie:  
`sarima(x,p,k,0)` - užitočné pri predikciách (predikcie budú pre pôvodné dáta)

## Príklad 3: Reálne dáta

---

- Úlohy:
  - Zobrazte výberovú ACF a PACF. Použite ich na nájdenie vhodného modelu.
  - Overte, že získaný model je stacionárny. Aké má korene?
  - Skomentujte rezíduá; vysvetlite, prečo sa model dá považovať za vyhovujúci.
  - Spravte predikcie. Predikcie pre  $M$  períód (ak pre  $k$ -te diferencie máme  $AR(p)$  model): `sarima.for(x,M,p,k,0)`

# Príklady

## PRÍKLAD 4

- Nájdite príklad iného stacionárneho AR(2) procesu, ktorého charakteristický polynóm má komplexné korene.
- Ukážte, ako sa tento fakt prejaví na priebehu procesu a na jeho ACF.

## PRÍKLAD 5

- Najskôr: príklad 7 z príkladov na precvičenie k prednáške
- Vytvorte vlastný príklad typu "*prirad'te k sebe proces, jeho realizáciu, ACF a PACF*" (pozri príklady na precvičenie k prednáške), pričom budete uvažovať dva AR(2) procesy. Vysvetlite jeho riešenie.

# Príklady

## PRÍKLAD 5


- Budeme analyzovať dáta vyjadrujúce veľkosť populácie múch druhu *Lucilia cuprina* v určitých podmienkach:  
<http://robjhyndman.com/tsdldata/blowfly/readme.txt>
- Dáta: <http://robjhyndman.com/tsdldata/blowfly/total.dat>



[http://en.wikipedia.org/wiki/File:Australian\\_sheep\\_blowfly.jpg](http://en.wikipedia.org/wiki/File:Australian_sheep_blowfly.jpg)

# Príklady

- Zoberme na konštrukciu predikcí druhú časť dát, zdá sa, že sa zmenil ich charakter (menej pravidelná periodickosť):



- Nájdite vhodný AR model a spravte predikcie.
- Skúste pracovať aj s logaritmi a vyberte si vhodnejší model (upozornenie: rôzne dáta → nedajú sa porovnávať AIC, BIC).



# Príklady

---

## PRÍKLAD 6

- Nájdite prvé členy Woldovej reprezentácie zvoleného stacionárneho AR procesu.
- Ide vlastne o hľadanie  $MA(\infty)$  reprezentácie procesu
- V R-ku: `ARMAtoMA(ar=c(...),lag.max=...)` - skontrolujte si váš výpočet