

Autoregresné (AR) procesy

Beáta Stehlíková
Časové rady, FMFI UK

Príklad 1

- AR(2) proces z prednášky:

$$x_t = 1.4x_{t-1} - 0.85x_{t-2} + u_t$$

- V R-ku:
 - ◇ korene charakteristického polynómu - overíme stacionaritu procesu
 - ◇ hodnoty ACF a PACF
 - ◇ vygenerujeme realizáciu procesu

Príklad 1(a): Stacionarita AR procesu

- Z informácií o skúške na webe:
 - súčasťou písomky budú dve otázky z kostry predmetu (zistovanie stacionarity a invertovateľnosti ARMA procesu; nájdenie vyhovujúceho ARIMA modelu pre zadané "pekné" dáta a vysvetlenie použitých testov), ich zodpovedanie aspoň na 60 percent je nutnou podmienkou spravenia skúšky. Ukážky takýchto zadaní budú zverejnené po odprednášaní príslušných tém.
- Stacionarita AR procesu:
 - ◇ špeciálny prípad uvedeného zadania
 - ◇ možný príklad z kostry predmetu na skúške
 - ◇ nutné na vyriešenie všeobecnejšieho zadania

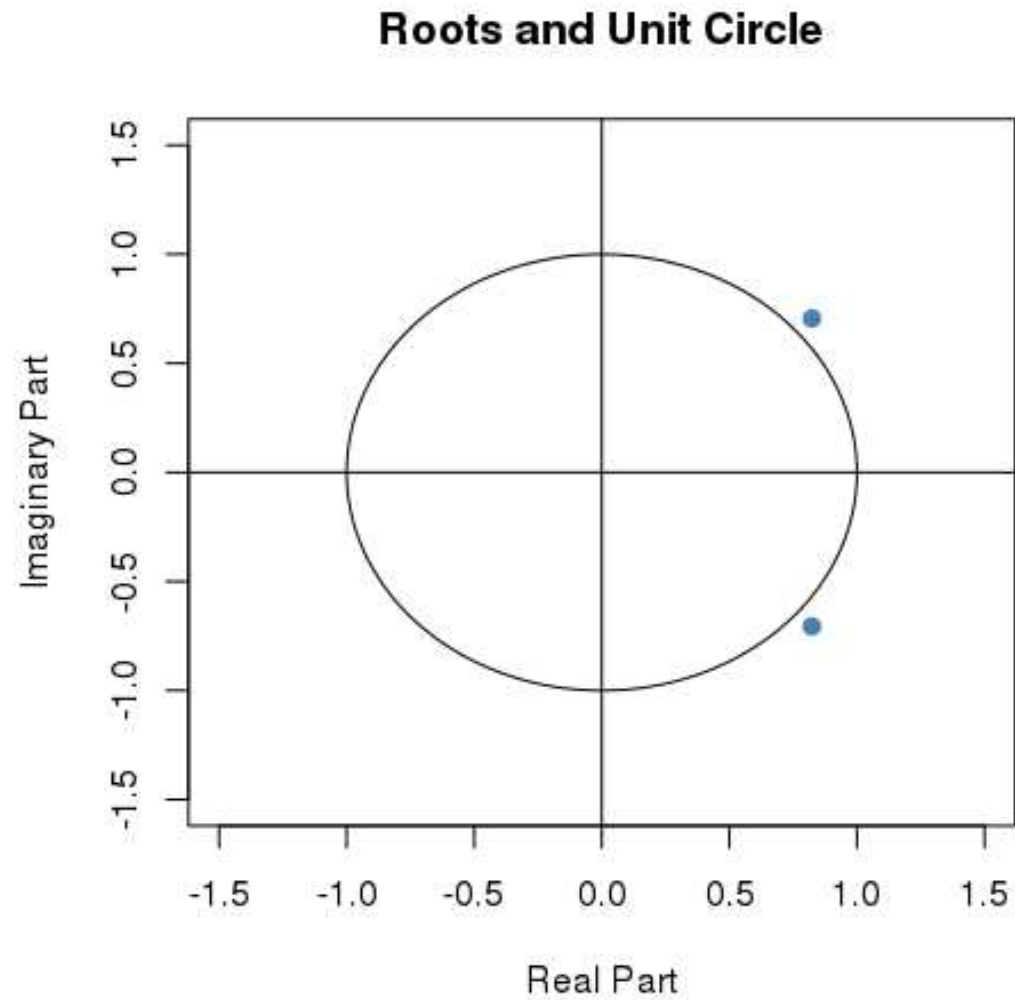
Príklad 1(a): Stacionarita AR procesu

- 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))`
- Výstup: tabuľka s koreňmi, aj ich absolútnymi hod.

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

Príklad 1(a): Stacionarita AR procesu

- Druhý výstup: grafické znázornenie koreňov



Cvičenia 1(a): Stacionarita AR procesu

Zistite, či sú nasledovné AR procesy stacionárne. Pre každý z procesov napíšte:

- polynóm, ktorého korene majú byť mimo jednotkového kruhu
- stupeň polynómu, a teda počet jeho koreňov
- absolútnu hodnotu každého koreňa

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

2. $(1 - 0.25L + 0.4L^2)x_t = 1 + u_t$

3. $x_t = 0.35x_{t-2} + u_t$

4. $(1 - 0.7L - 0.4L^2)(1 + 0.5L)x_t = 10 + u_t$

5. $(1 - 0.2L)^2(1 + 0.25L)x_t = 1 + u_t$

6. $(1 - 0.2L^2)(1 + 0.25L)x_t = 1 + u_t$

Príklad 1(b): Komplexné korene


- 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 φ
- Získame ju napr. takto:

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

- *Opakovanie z prednášky:* Ako z tohto vypočítame periódu?

Cvičenia 1(b): Komplexné korene

- 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)

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


Cvičenia 1(b): Komplexné korene

- Overte stacionaritu procesu.
- Vysvetlite nasledovné tvrdenie z knihy (str.49) a vypočítajte uvedené hodnoty:
"The two roots of the process are $0.70 \pm 0.06i$, i.e. they indicate cycles ... the frequency $f = 0.079$ corresponds to a period of 79.7 quarters and therefore of nearly 20 years."

Príklad 1(c): 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))
```




Cvičenia 1(c): ACF a PACF

- Zobrazte ACF a PACF stacionárnych procesov zo str. 6.
- Čo vieme dopredu povedať o PACF pre každý z týchto procesov?

Príklad 1(d): Realizácia procesu

- Realizácia procesu:

`x=arima.sim(n=100, list(ar = c(1.4,-0.85)),sd=0.1)`



Príklad 2: Odhadovanie parametrov

- Budeme používať knižnicu `astsa`
- Postup:
 - ◇ výberová ACF a PACF → identifikácia modelu
 - ◇ odhadnutie modelu
 - ◇ kontrola rezíduí - ak nie sú bielym šumom, treba skúsiť iný model
 - ◇ keď už máme dobrý model, môžeme spraviť predikcie

Príklad 2(a): Výberová (P)ACF

- Dve možnosti:
 - ◇ `acf(x)`, `acf(x, type="partial")`
 - ◇ `acf2(x)` z knižnice `astsa` - spolu ACF (bez nulového lagu) a PACF v jednom obrázku
- Vyskúšame pre dáta v premennej `x` - vygenerované z AR(2) procesu

Príklad 2(b): Odhad parametrov

- Budeme používať funkciu `sarima` z knižnice `astsa`
- AR(p) model pre dáta v premennej `x`:

`sarima(x,p,0,0)`

- Výstup pre naše dáta:

```
Coefficients:
              ar1      ar2  xmean
              1.3571 -0.7737 0.0049
s.e.          0.0877  0.0883 0.0282
```

To znamená, že odhadnutý model je:

$$x_t = \delta + 1.3571x_{t-1} - 0.7737x_{t-2} + u_t$$

Dopočítajte parameter δ tak, aby platilo $\mathbb{E}[x_t] = 0.0049$ (ako vidíme vo výstupe). Sú rezíduá bielym šumom?

Príklad 2(c): Konštrukcia predikcií

- Budeme používať funkciu `sarima.for` z knižnice `astsa`
- AR(p) model pre dáta v premennej `x`, predikcie na `N` období do budúcnosti:

`sarima.for(x,N,p,0,0)`

- Výstup obsahuje graf, na ktorom sú
 - ◇ dáta
 - ◇ predikcie - odhadnutá stredná hodnota v budúcnosti
 - ◇ intervaly spoľahlivosti pre predikcie

Cvičenie 2

- Proces 1 zo str. 6: $x_t = 2 + 0.2x_{t-1} + 0.5x_{t-2} + u_t$
- Vygenerujte realizáciu procesu s dĺžkou **250**, pričom $\mathbb{D}[u_t] = 0.0625$

NÁVOD: (`set.seed` - aby sme mali rovnaké výsledky:

```
set.seed(12345)
```

```
x=arima.sim(n=..., list(ar = c(...)), sd=...) + c
```

pričom `sd` je štandardná odchýlka u_t a `c` je vhodná konštanta

- Vypočítajte výberovú ACF a PACF, porovnajte ich s presnými.

Príklad 3: Reálne dáta

- Spotreba kávy v USA v rokoch 1910 - 1970
- Zdroj: <http://robjhyndman.com/tsdldata/data/coffee.dat>
- Na stránke cvičení: [kava.txt](#)
- Načítanie dát:


```
x <-  
read.table("http://www.iam.fmph.uniba.sk/institute/  
stehlikova/cr14/data/kava.txt")
```
- Z týchto dát spravíme časový rad pomocou funkcie `ts`:

```
x <- ts(x, frequency=..., start=c(...))
```

namiesto `start` sa dá použiť `end` (podrobnejšie na stránke)
- Vykreslíme → zdá sa, že v dátach je trend → budeme pracovať s diferenciami (potrebujeme stacionárne dáta)

Príklad 3: Reálne dáta


- Priebeh diferencií - `plot(diff(x))`:



- Ďalej je postup analogický ako pri simulovaných dátach v predchádzajúcom príklade
- Ak odhadujeme **AR(p)** model pre **k**-te diferencie, príkazy sú: `sarima(x,p,k,0)`, resp. `sarima.for(x,N,p,k,0)`


Cvičenie 3: Reálne dáta

- Počet oviec v tisícoch v Anglicku a Walese, ročné dáta, 1867-1939
- Zdroj: <http://datamarket.com/data/set/22px/>
- Na stránke: [ovce.txt](#)



Cvičenie 3: Reálne dáta

- Zdá sa, že dáta nie sú stacionárne, ale majú klesajúci trend → budeme pracovať s diferenciami:



Cvičenie 3: Reálne dáta

súčasťou písomky budú dve otázky z kostry predmetu (zistovanie stacionarity a invertovateľnosti ARMA procesu; **nájdenie vyhovujúceho ARIMA modelu pre zadané "pekné" dáta a vysvetlenie použitých testov**), ich zodpovedanie aspoň na 60 percent je nutnou podmienkou spravenia skúšky. Ukážky takýchto zadaní budú zverejnené po odprednášaní príslušných tém.

Zatiaľ poznáme AR modely, na tieto dáta stačia. Úlohy:

- Zobrazte výberovú ACF a PACF. Použite ich na nájdenie vhodného modelu.
- Overte, že získaný model je stacionárny. Aké má korene?
- Skomentujte rezíduá; vysvetlite použité testy a prečo sa model dá považovať za vyhovujúci.
- Spravte predikcie.