

# SARIMA modely: modelovanie sezónnych časových radov


Beáta Stehlíková

Časové rady

Fakulta matematiky, fyziky a informatiky, UK v Bratislave

## Obsah

- Modelovanie sezónnych dát: kvartálny HDP (sezónne neočistený), mesačný prietok riek, mesačný počet návštevníkov v turistických oblastiach



- ▶ Niekoľko teoretických príkladov so sezónnymi členmi: aký priebeh ACF a PACF môžeme pri nich očakávať
- ▶ Sezónne diferencovanie
- ▶ SARIMA modely

## Príklady ARMA procesov so sezónnymi členmi, ich ACF PACF

## Príklad 1: $x_t = \alpha x_{t-12} + u_t$

- ▶ Stacionarita:  $(1 - \alpha L^{12})x_t = u_t \Rightarrow \alpha < 1$
- ▶ Prenásobíme  $x_{t-s}$  a spravíme strednú hodnotu → rovnice pre autokovariancie:

$$\gamma(s) = \alpha\gamma(s-12), \quad (s > 0)$$

$$\gamma(0) = \alpha\gamma(12) + \sigma^2$$

- ▶ Riešenie:

$$\text{disperzia: } \gamma(0) = \frac{\sigma^2}{1 - \alpha^2}$$

$$\gamma(12k) = \alpha^k \gamma(0), \text{ ostatné } \gamma(s) = 0$$

- ▶ ACF:

$$\rho(12k) = \alpha^k, \text{ ostatné } \rho(s) = 0$$

Proces  $x_t = \alpha x_{t-12} + u_t$  v R-ku

Máme vlastne AR(12) proces s mnohými nulovými koeficientami:

$$x_t = \alpha x_{t-12} + u_t$$

$$x_t = 0x_{t-1} + \dots 0x_{t-11} + \alpha x_{t-12} + u_t$$


# ACF

```
acf_pr1 <- ARMAacf(ar = c(rep(0, 11), 0.8), lag.max = 60)
plot(acf_pr1, type = "h")
```


# PACF

```
pacf_pr1 <- ARMAacf(ar = c(rep(0, 11), 0.8), lag.max = 60,
                      pacf = TRUE)
plot(pacf_pr1, type = "h")
```

## Autokorelačná funkcia:



Parciálna autokorelačná funkcia:



Príklad 2:  $x_t = 0.8 x_{t-12} - 0.3 x_{t-24} + u_t$

- ▶ Stacionarita:

$$(1 - 0.8L^{12} + 0.3L^{24})x_t = u_t$$


substitúcia  $L^{12} = y \rightarrow$  overujeme korene polynómu

$1 - 0.8y + 0.3y^2$  (z každej hodnoty  $y$  dostaneme 12 koreňov  $L$ , pre ktoré  $|L|^{12} = |y|$ )


- ▶ Koeficienty do výpočtu ACF a PACF

```
ar_koef <- c(rep(0, 11), 0.8, rep(0, 11), -0.3)
acf_pr2 <- ARMAacf(ar = ar_koef, lag.max = 60)
pacf_pr2 <- ARMAacf(ar = ar_koef, lag.max = 60, pacf = TRUE)
```

## Autokorelačná funkcia:



## Parciálna autokorelačná funkcia:



Príklad 3:  $(1 - 0.5L)(1 + 0.8L^{12})x_t = u_t$

- ▶ V SARIMA modeloch sa budú klasické a sezónne polynómy **násobiť**
- ▶ Máme teraz:

$$(1 - 0.5L)(1 + 0.8L^{12}) = 1 - 0.5L + 0.8L^{12} - 0.4L^{13},$$


proces teda je

$$x_t = 0.5x_{t-1} - 0.8x_{t-12} + 0.4x_{t-13} + u_t$$


- ▶ Koeficienty do výpočtu ACF a PACF

```
ar_koef <- c(0.5, rep(0, 10), -0.8, 0.4)
acf_pr3 <- ARMAacf(ar = ar_koef, lag.max = 60)
pacf_pr3 <- ARMAacf(ar = ar_koef, lag.max = 60, pacf = TRUE)
```

## Autokorelačná funkcia:



Parciálna autokorelačná funkcia:




## Príklad 4: $x_t = u_t - 0.5u_{t-12}$


- ▶ Teoretická ACF: jediná nenulová hodnota je pre lag 12
- ▶ Koeficienty do výpočtu ACF a PACF

```
ma_koef <- c(rep(0, 11), -0.5)
acf_pr4 <- ARMAacf(ma = ma_koef, lag.max = 60)
pacf_pr4 <- ARMAacf(ma = ma_koef, lag.max = 60, pacf = TRUE)
```

## Autokorelačná funkcia:



Parciálna autokorelačná funkcia:



**Príklad 5:**  $x_t = 0.8x_{t-12} + u_t - 0.5u_{t-1}$

**Cvičenie.** Odvodte ACF pre všeobecný model tohto tvaru:

### Example 3.47 A Mixed Seasonal Model

Consider an  $\text{ARMA}(0, 1) \times (1, 0)_{12}$  model

$$x_t = \Phi x_{t-12} + w_t + \theta w_{t-1},$$

where  $|\Phi| < 1$  and  $|\theta| < 1$ . Then, because  $x_{t-12}$ ,  $w_t$ , and  $w_{t-1}$  are uncorrelated, and  $x_t$  is stationary,  $\gamma(0) = \Phi^2\gamma(0) + \sigma_w^2 + \theta^2\sigma_w^2$ , or

$$\gamma(0) = \frac{1 + \theta^2}{1 - \Phi^2} \sigma_w^2.$$

In addition, multiplying the model by  $x_{t-h}$ ,  $h > 0$ , and taking expectations, we have  $\gamma(1) = \Phi\gamma(11) + \theta\sigma_w^2$ , and  $\gamma(h) = \Phi\gamma(h-12)$ , for  $h \geq 2$ . Thus, the ACF for this model is


$$\begin{aligned}\rho(12h) &= \Phi^h \quad h = 1, 2, \dots \\ \rho(12h-1) &= \rho(12h+1) = \frac{\theta}{1 + \theta^2} \Phi^h \quad h = 0, 1, 2, \dots, \\ \rho(h) &= 0, \quad \text{otherwise.}\end{aligned}$$

```
#  $x_t = 0.8 x_{t-12} + u_t - 0.5 u_{t-1}$ 
```


```
acf_pr5 <- ARMAacf(ar = c(rep(0, 11), 0.8),  
                     ma = c(-0.5),  
                     lag.max = 60)
```

```
pacf_pr5 <- ARMAacf(ar = c(rep(0, 11), 0.8),  
                     ma = c(-0.5),  
                     lag.max = 60,  
                     pacf = TRUE)
```

## Autokorelačná funkcia:



Parciálna autokorelačná funkcia:



## Sezónne diferencovanie

## Vzorový príklad

- ▶ Predstavme si model pre časový rad  $x_t$ :

$$x_t = S_t + u_t$$

so sezónnou zložkou  $S_t$  a bielym šumom  $u_t$

- ▶ Sezónnu zložku modelujeme ako

$$S_t = S_{t-12} + w_t,$$

kde  $w$  je biely šum nezávislý od  $u$

- ▶ Potom náš proces  $x$  je

$$\begin{aligned} x_t &= S_t + u_t = (S_{t-12} + w_t) + u_t \\ &= (x_{t-12} - u_{t-12} + w_t) + u_t \end{aligned}$$

$$(1 - L^{12})x_t = w_t + u_t - u_{t-12}$$

- ▶ Náš proces teda nie je stacionárny kvôli jednotkovému koreňu
- ▶ Polynóm  $1 - L^{12}$  má okrem  $L = 1$  ešte ďalších 11 koreňov s absolútou hodnotou 1.
- ▶ Vizuálne na ACF: hodnoty pre násobky 12 klesajú príliš pomaly
- ▶ V takomto prípade zoberieme **sezónne diferencie**  $x_t - x_{t-12}$
- ▶ V R-ku `diff(x, lag = 12)`


## Príklad sezónneho diferencovania I.

- ▶ Zoberieme dáta o počte cestujúcich aerolinkami od Boxa a Jenkinsa
- ▶ Zlogaritmujeme, aby sme odstránili rastúcosť disperzie
- ▶ Zdiferencujeme kvôli trendu


Pozrieme sa pre tieto diferencie na:

- ▶ priebeh dát
- ▶ výberovú ACF
- ▶ ADF test

```
plot(diff(log(AirPassengers)))
```




```
acf(diff(log(AirPassengers)), lag.max = 60)
```



```
library(urca)
# kritické hodnoty: -3.46 -2.88 -2.57
ur.df(diff(log(AirPassengers)),
      type = "drift", lags = 13, selectlags = "BIC")


##
## #####
## # Augmented Dickey-Fuller Test Unit Root / Cointegration
## #####
## #####
## The value of the test statistic is: -3.0152 4.5457
```

Korene polynómu AR procesu vyplývajúceho z predchádzajúcej regresie:



- ▶ P-hodnota medzi 0.05 a 0.01
- ▶ Tieto dáta sú už stacionárne, vizuálne aj ADF testom

```
acf(diff(diff(log(AirPassengers))), lag = 12), lag.max = 60)
```



## Príklad sezónneho diferencovania II.


Tie isté dátá, iný postup:

- ▶ Zoberieme dátá o počte cestujúcich aerolinkami od Boxa a Jenkinsa
- ▶ Zlogaritmujeme, aby sme odstránili rastúcosť disperzie
- ▶ S cieľom zbaviť sa trendu tiež spravíme diferencie, ale tentokrát sezónne, budeme sa teda pozerať na medziročné zmeny (čo má interpretáciu)

```
plot(diff(log(AirPassengers), lag = 12))
```



```
acf1(diff(log(AirPassengers), lag = 12))
```




```
## [1] 0.71 0.62 0.48 0.44 0.39 0.32 0.24 0.19 0.04 / 46
```

```
# kritické hodnoty -3.46 -2.88 -2.57
ur.df(diff(log(AirPassengers), lag = 12),
      type = "drift", lag = 5, selectlags = "BIC")

##
## #####
## # Augmented Dickey-Fuller Test Unit Root / Cointegration
## #####
## #####
## #####
## #####
## The value of the test statistic is: -3.2637 5.3267
```

- ▶ V dátach je ešte možno jednotkový koreň (p medzi 0.01 a 0.05, ACF klesá pomaly)
- ▶ Po zdiferencovaní dostaneme tie isté dáta na hľadanie modelu ako predtým

```
library(astsa)
acf2(diff(diff(log(AirPassengers))), lag = 12))
```



## SARIMA modely

- ▶ Dáta môžu byť klasicky a/alebo sezónne diferencované
- ▶ AR členy
  - ▶ klasické, napr.  $(1 - \alpha_1 L)x_t, (1 - \alpha_1 L - \alpha_2 L^2)x_t, \dots$
  - ▶ sezónne, napr.  $(1 - \phi_1 L^{12})x_t, (1 - \phi_1 L^{12} - \phi_2 L^{24})x_t, \dots$
  - ▶ vynásobia sa
- ▶ MA členy
  - ▶ klasické, napr.  $(1 - \beta_1 L)u_t, (1 - \beta_1 L - \beta_2 L^2)u_t, \dots$
  - ▶ sezónne, napr.  $(1 - \theta_1 L^{12})u_t, (1 - \theta_1 L^{12} - \theta_2 L^{24})u_t, \dots$
  - ▶ vynásobia sa

## Príklady

**Príklad 1.** Model pre mesačné dáta:

$$(1 - \alpha_1 L - \alpha_2 L^2)(1 - \psi L^{12})y_t = (1 - \beta_1 L)(1 - \theta_1 L^{12})u_t,$$

kde  $y_t$  sú diferencie pôvodných dát  $x_t$ :

$$y_t = (1 - L)x_t$$

**Príklad 2.** Model pre kvartálne dáta:

$$(1 - \alpha_1 L)(1 - \psi L^4)y_t = (1 - \beta_1 L)(1 - \theta_1 L^4 - \theta_2 L^8)u_t,$$

kde  $y_t$  vzniknú z pôvodných dát  $x_t$  differencovaním a následným sezónnym differencovaním:

$$y_t = (1 - L^4)(1 - L)x_t$$

## Terminológia SARIMA modelov

- ▶ Pripomeňme si ARIMA( $p, d, q$ ) modely:
  - ▶  $p$  = počet AR členov
  - ▶  $d$  = koľkokrát dátá diferencujeme
  - ▶  $q$  = počet MA členov
- ▶ SARIMA( $p, d, q) \times (P, D, Q)_s$  modely majú navyše
  - ▶  $P$  = počet sezónnych AR členov (vo výstupe z R-ka sar1, sar2, ...)
  - ▶  $D$  = koľkokrát dátá sezónne diferencujeme
  - ▶  $Q$  = počet sezónnych MA členov (vo výstupe z R-ka sma1, sma2, ...)
  - ▶  $s$  = períoda dát
- ▶ SARIMA( $p, d, q) \times (P, D, Q)_s$  model v R-ku:

```
sarima(data, p, d, q, P, D, Q, s) #model  
sarima.for(data, N, p, d, q, P, D, Q, s) # predikcie
```

**Príklad 1.** Model pre mesačné dátá:

$$(1 - \alpha_1 L - \alpha_2 L^2)(1 - \psi L^{12})y_t = (1 - \beta_1 L)(1 - \theta_1 L^{12})u_t,$$

kde  $y_t$  sú diferencie pôvodných dát  $x_t$ :

$$y_t = (1 - L)x_t$$

Je to

$$SARIMA(2, 1, 1) \times (1, 0, 1)_{12}$$

**Príklad 2.** Model pre kvartálne dáta:

$$(1 - \alpha_1 L)(1 - \psi L^4)y_t = (1 - \beta_1 L)(1 - \theta_1 L^4 - \theta_2 L^8)u_t,$$

kde  $y_t$  vzniknú z pôvodných dát  $x_t$  diferencovaním a následným sezónnym diferencovaním:

$$y_t = (1 - L^4)(1 - L)x_t$$

Je to

$$SARIMA(1, 1, 1) \times (1, 1, 2)_4$$

- ▶ Z prehľadového článku *J. Kaur et al. (2023). Autoregressive models in environmental forecasting time series: a theoretical and application review. Environmental Science and Pollution Research, 30(8), 19617-19641.*
- ▶ Aký tvar má odhadnutý model?


The hourly and monthly concentrations of CO spread over 7 years of data of Hong Kong were analyzed by Lau et al. (2009) using ARIMA modeling. Association of hourly concentration of CO with different days of the week was examined. The hourly data of CO was like traffic data. This strong association was proven by SARIMA (0, 1, 1) (0, 1, 1)<sub>24</sub> model.

Liu T, Lau AK, Sandbrink K, Fung JC (2018) Time series forecasting of air quality based on regional numerical modeling in Hong Kong. J Geophysical Res Atmos 123(8):4175–4196

## Hľadanie SARIMA modelu pre zadané dátá

## Príklad 1: počet cestujúcich

Dokončíme hľadanie SARIMA modelu pre  $\log(\text{AirPassengers})$  (zatiaľ vieme, že dátu budeme diferencovať klasicky aj sezónne, alebo aspoň jedno z týchto diferencovaní):



## Príklad 2: ceny kurčiat (z balíka astsa)

Nájdite model pre mesačné ceny kurčiat:

```
plot(chicken)
```

