

# Modelovanie trendu: exponenciálne zhladzovanie, Holt-Wintersova metóda, Hodrick-Prescottov filter

Beáta Stehlíková

2-EFM-102 Časové rady

Fakulta matematiky, fyziky a informatiky, UK v Bratislave

# Obsah

- ▶ **Exponenciálne zhladzovanie** - nájdenie strednej hodnoty v časovom rade bez trendu a sezónnosti
- ▶ **Holt - Wintersova metóda** - zovšeobecnenie pre dáta s trendom a sezónnosťou
- ▶ **Hodrick - Prescottov filter** - vyhladenie dát bez sezónnosti pomocou dvoch kritérií: zhoda s dátami a malá krivosť krivky

## Exponenciálne zhladzovanie

## Označenie

- ▶ Máme dáta  $x_1, x_2, \dots, x_n$  a chceme predikovať hodnotu  $x_{n+k}$
- ▶ V tejto časti predpokladáme, že v dátach **nie je ani trend, ani sezónnosť**
- ▶ Model:

$$x_t = \mu_t + w_t,$$

kde

- ▶  $\mu_t$  je stredná hodnota (môže závisieť od času)
  - ▶  $w_t$  sú nezávislé náhodné odchýlky s nulovou strednou hodnotou
- ▶ Označme  $a_t$  náš odhad strednej hodnoty  $\mu_t$

## Model

- ▶ Základná myšlienka exponenciálneho zhladzovania: ďalší odhad strednej hodnoty (teda  $a_t$ ) bude váženým priemerom predchádzajúceho odhadu (teda  $a_{t-1}$ ) a novej realizovanej hodnoty  $x_t$ :

$$a_t = \alpha x_t + (1 - \alpha) a_{t-1}$$

- ▶ Parameter zhladzovania  $\alpha$ :
  - ▶  $\alpha \approx 1$  - slabé zhladzovanie,  $a_t \approx x_t$
  - ▶  $\alpha \approx 0$  - silné zhladzovanie,  $a_t \approx a_{t-1}$
- ▶ Iný zápis  $a_t$ :

$$a_t = \alpha x_t + \alpha(1 - \alpha)x_{t-1} + \alpha(1 - \alpha)^2 x_{t-2} + \dots$$

- váhy exponenciálne klesajú, preto názov exponenciálne zhladzovanie

## Predikcie a optimálna $\alpha$

- ▶ Označenie:  $\hat{x}_{n+k|n}$  - predikcia dát  $x$  na čas  $n+k$ , ak je dnešný čas  $n$
- ▶ Keďže nemáme trend ani sezónnosť, vieme spraviť iba

$$\hat{x}_{n+k|n} = a_n$$

- ▶ Pre daný parameter  $\alpha$ :
  - ▶  $a_1 = x_1$  a potom rekurentne
  - ▶ máme teda predikčné chyby:

$$e_t = x_t - \hat{x}_{t|t-1} = x_t - a_{t-1}$$

- ▶ Optimálny parameter  $\alpha$  - minimalizujeme sumu štvorcov predikčných chýb:

$$\sum_{t=2}^n e_t^2 \rightarrow \min$$

└ Exponenciálne zhladzovanie

└ Exponenciálne zhladzovanie v R-ku

## Exponenciálne zhladzovanie v R-ku




## Dáta

- ▶ *P. S. P.Cowpertwait, A. V. Metcalfe: Introductory Time Series with R. Springer, 2009. Complaints to a motoring organization, pp. 56-58.*
- ▶ počet sťažností, mesačné dáta, 1996/01 - 1999/12
- ▶ dáta na stránke (`complaints.txt`)

```
y <- read.table("complaints.txt")  
y <- ts(y$V1, frequency = 12, start = c(1996, 1))
```

## plot(y)



## Odhadnutie modelu

- ▶ funkcia `HoltWinters` s nastavením `beta = FALSE` a `gamma = FALSE` - je špeciálny to prípad všeobecnejšieho modelu, pre ktorý máme funkciu `HoltWinters` - uvedieme neskôr

```
model1 <- HoltWinters(y, beta = FALSE, gamma = FALSE)
model1
```

```
## Holt-Winters exponential smoothing without trend and with seasonality
##
```

```
## Call:
```

```
## HoltWinters(x = y, beta = FALSE, gamma = FALSE)
```

```
##
```

```
## Smoothing parameters:
```


```
## alpha: 0.1429622
```

```
## beta : FALSE
```

```
## gamma: FALSE
```

## Graf

```
plot(model1)
```



- ▶ Prístup k hodnote *sum of squared errors*, podľa ktorej sa vyberala optimálna  $\alpha$ :

```
model1$SSE
```


```
## [1] 2502.028
```

- ▶ Použitie našej hodnoty parametra  $\alpha$ : napríklad

```
model_nas <- HoltWinters(y, alpha = 0.2,  
                        beta = FALSE, gamma = FALSE)
```

## Cvičenie: optimálna hodnota parametra $\alpha$

- ▶ Vykreslíme závislosť SSE od parametra  $\alpha$  pre naše dáta.
- ▶ Tento výpočet má potvrdiť optimálnu hodnotu  $\alpha$  z R-ka



## Holt - Wintersova metóda

- ▶ Charakteristiky časového radu:
  - ▶  $a_t = \text{level}$ , sezónne očistená stredná hodnota
  - ▶  $b_t = \text{slope}$ , zmena hodnoty level z jednej periódy na druhú (zachytáva rôzne, aj krátkodobé trendy)
  - ▶  $s_t = \text{seasonal component}$ , sezónna zložka (závisí napr. od mesiaca)
- ▶ Typ sezónnosti:
  - ▶ aditívna - napr. v januári je hodnota o 100 vyššia
  - ▶ multiplikatívna - napr. v januári je hodnota o 10 percent vyššia
- ▶ Predikcia pri aditívnej sezónnosti:

$$\hat{x}_{n+k|n} = a_n + kb_n + s_{n+k-p}$$



pre  $k \leq p$  (napr.  $p = 12$  pri mesačných dátach)

- ▶ Pri multiplikatívnej sezónnosti:

$$\hat{x}_{n+k|n} = (a_n + kb_n)s_{n+k-p}$$



- Ukážka typického priebehu: vľavo aditívna sezónnosť, vpravo multiplikatívna:



## Rekurentné vzťahy

- ▶ Analogicky ako pri exponenciálnom zhladzovaní: vážené priemery hodnôt typu “*nová hodnota*” a “*stará hodnota*”
- ▶ Pre aditívnu sezónnosť:

$$a_t = \alpha(x_t - s_{t-p}) + (1 - \alpha)(a_{t-1} + b_{t-1})$$

$$b_t = \beta(a_t - a_{t-1}) + (1 - \beta)b_{t-1}$$

$$s_t = \gamma(x_t - a_t) + (1 - \gamma)s_{t-p}$$

kde  $\alpha, \beta, \gamma \in (0, 1)$

- ▶ Analogicky pre multiplikatívnu (rovnice sú napr. aj v popise funkcie HoltWinters)
- ▶ Optimálne  $\alpha, \beta, \gamma$  sa znovu určia minimalizáciou SSE

## Holt-Wintersova metóda v R-ku


## Dáta

- ▶ tržby v obchode so suvenírmi v lodenici na pláži v Austrálii; mesacné dáta od januára 1987 do decembra 1993
- ▶ `suveniry.txt` na stránke

```
y <- read.table("data/suveniry.txt", header = FALSE)
y <- ts(y, frequency = 12, start = c(1987, 1))
head(y)
```

```
##           V1
## [1,] 1664.81
## [2,] 2397.53
## [3,] 2840.71
## [4,] 3547.29
## [5,] 3752.96
## [6,] 3714.74
```

## plot(y)



## Odhad modelu


- ▶ Vidíme multiplikatívnu sezónnosť, takže:

```
HW_suveniry <- HoltWinters(y, seasonal = "multiplicative")  
HW_suveniry
```

```
## Holt-Winters exponential smoothing with trend and multip  
##  
## Call:  
## HoltWinters(x = y, seasonal = "multiplicative")  
##  
## Smoothing parameters:  
## alpha: 0.4889037  
## beta : 0.04653724  
## gamma: 0.947455  
##  
## Coefficients:
```

## Grafické znázornenie

```
plot(HW_suveniry)
```




└ Holt - Wintersova metóda

└ Holt-Wintersova metóda v R-ku

## Predikcie


```
HW_suveniry_pred <- predict(HW_suveniry, n.ahead = 48)  
plot(HW_suveniry_pred)
```





V jednom grafe spolu s dátami:

```
ts.plot(y, HW_suvenir_y_pred, col = c("black", "blue"))
```



## Hodrick-Prescottov filter: odhadovanie trendu

## Model

- ▶ Predpoklad: v dátach nie je sezónnosť
- ▶ Cieľ: chceme odhadnúť trendovú zložku dát
- ▶ Myšlienka: potrebujeme dosiahnuť dve kritériá, ktoré sú v protiklade, preto im priradíme váhy:
  - ▶ vyhladené hodnoty by mali byť blízko skutočných
  - ▶ malá krivosť grafu vyhladených hodnôt (nie veľké fluktuácie), tú vieme merať druhými diferenciami (analógia druhej derivácie)
- ▶ Optimalizačná úloha, kde  $y_1, \dots, y_n$  sú dáta,  $\lambda > 0$  je parameter a  $\tilde{y}_1, \dots, \tilde{y}_n$  sú vyhladené hodnoty

$$\sum_{t=1}^n (y_t - \tilde{y}_t)^2 + \lambda \sum_{t=2}^{n-1} (\tilde{y}_{t+1} - 2\tilde{y}_t + \tilde{y}_{t-1})^2 \rightarrow \min_{\tilde{y}_1, \dots, \tilde{y}_n}$$

## Hodrick-Prescottov filter v R-ku

- ▶ Balík mFilter
- ▶ Funkcia hpfilter, napr.

```
hp <- hpfilter(data, freq = 100) # lambda = 100
```

- ▶ Odhadnutý trend je potom v hp\$trend


## Príklad: vplyv parametra $\lambda$

Zoberme dáta o sťažnostiach

```
y <- read.table("complaints.txt")  
y <- ts(y$V1, frequency = 12, start = c(1996, 1))
```

Porovnáme:

```
plot(y)  
  
hpf1 <- hpfilter(y, freq = 500)  
lines(hpf1$trend, col="blue")  
  
hpf2 <- hpfilter(y, freq = 10000)  
lines(hpf2$trend, col="red")
```



Vyskúšajte iné hodnoty. Čo sa deje pre  $\lambda \rightarrow 0$  a pre  $\lambda \rightarrow \infty$ ?

## Odporúčané hodnoty $\lambda$

- ▶  $\lambda = 100$  pre ročné dáta
- ▶  $\lambda = 1600$  pre kvartálne dáta
- ▶  $\lambda = 14400$  pre mesačné dáta

Vyskúšajte pre naše dáta o sťažnostiach



Modelovanie trendu: exponenciálne zhladzovanie, Holt-Wintersova metóda, Hodrick-Prescottov filter

└ Hodrick-Prescottov filter: odhadovanie trendu

└ Aplikácia: produkčná medzera

## Aplikácia: produkčná medzera

- ▶ Potenciálny hrubý domáci produkt a produkčná medzera:
  - ▶ potenciálny HDP: maximálny výstup, ktorý vie ekonomika pri daných faktoroch vyprodukovať bez inflačných tlakov
  - ▶ skutočný HDP osciluje okolo potenciálneho (hospodárske cykly)
  - ▶ produkčná medzera: rozdiel medzi potenciálnym a reálnym výstupom
- ▶ Aplikácia HP filtra na skúmanie produkčnej medzery:
  - ▶ trendom z HP filtra odhadneme potenciálny HDP
  - ▶ zopakujeme tento postup pre niekoľko štátov a porovnáme