

M5201 – 9. CVIČENÍ:
Exponenciální vyrovnávání

1 Exponenciální vyrovnávání

Hlavní myšlenka **lokální (vážené) metody nejmenších čtverců** spočívá v tom, že provedeme odhad trendu polynomem na **lokálním intervalu** $(t-s, t+s)$ na rozdíl od klasické (vážené) metody nejmenších čtverců, kdy trend odhadujeme polynomem na celém intervalu možných hodnot parametru t .

Exponenciální vyrovnávání aproximuje neznámý trend polynomem stupně m , který se odhaduje na základě pozorování z asymetrického vyhlazovacího okénka směrem do minulosti. Exponenciální vyrovnávání vychází z polynomiální lokální **vážené** metody nejmenších čtverců, kde váhy jednotlivých čtverců se směrem do minulosti exponenciálně snižují – odtud název metody.

Uvažujeme-li vyhlazovací okno pouze směrem do minulosti, pak pro každé $t, \tau = 0, 1, \dots$ dostaneme regresní model tvaru

$$Y_{t-\tau} = \sum_{j=0}^m (-\tau)^j \beta_j(t) + \varepsilon_{t-\tau}, \quad E\varepsilon_{t-\tau} = 0; \quad E\varepsilon_q \varepsilon_s = 0, \quad q \neq s; \quad D\varepsilon_{t-\tau} = \alpha^{-\tau} \sigma^2; \quad \alpha \in (0, 1).$$

tj. matice vah je rovna

$$\mathbf{W} = \text{diag}\{w_1, \dots, w_n, \dots\} = \text{diag}\{\alpha^0, \alpha^1, \dots, \alpha^\tau \dots\}.$$

Odhad parametrů β provedeme metodou **nejmenších vážených čtverců** (neboť rozptyly nejsou konstantní) která je dána vzorcem:

$$\hat{\beta} = (\mathbf{X}'\mathbf{W}\mathbf{X})^{-1}\mathbf{X}'\mathbf{W}\mathbf{Y}$$

kde

$$\mathbf{X}'\mathbf{W}\mathbf{X} = \begin{pmatrix} \sum_{\tau=0}^{\infty} \alpha^\tau & \sum_{\tau=0}^{\infty} (-\tau)^1 \alpha^\tau & \dots & \sum_{\tau=0}^{\infty} (-\tau)^m \alpha^\tau \\ \sum_{\tau=0}^{\infty} (-\tau)^1 \alpha^\tau & \sum_{\tau=0}^{\infty} (-\tau)^2 \alpha^\tau & \dots & \sum_{\tau=0}^{\infty} (-\tau)^{m+1} \alpha^\tau \\ \vdots & \vdots & \ddots & \vdots \\ \sum_{\tau=0}^{\infty} (-\tau)^m \alpha^\tau & \sum_{\tau=0}^{\infty} (-\tau)^{m+1} \alpha^\tau & \dots & \sum_{\tau=0}^{\infty} (-\tau)^{2m} \alpha^\tau \end{pmatrix}, \quad \mathbf{X}'\mathbf{W}\mathbf{Y} = \begin{pmatrix} \sum_{\tau=0}^{\infty} \alpha^\tau Y_{t-\tau} \\ \sum_{\tau=0}^{\infty} (-\tau)^1 \alpha^\tau Y_{t-\tau} \\ \vdots \\ \sum_{\tau=0}^{\infty} (-\tau)^m \alpha^\tau Y_{t-\tau} \end{pmatrix}.$$

Tento přístup založený na vážené polynomiální metodě nejmenších čtverců se nazývá *Brownův přístup*.

ZNAČENÍ:

Pro dobrou srozumitelnost zavedeme následující značení. Necht' $\{Y_t, t \in \mathbb{Z}\}$ je náhodná posloupnost, její realizace v časových okamžicích t_1, t_2, \dots, t_n označme y_1, y_2, \dots, y_n . Symbolem $\hat{y}_{t|k}$ označme odhad hodnoty Y_t v čase t na základě hodnot do časového okamžiku k včetně.

- Jestliže $k < t$, pak $\hat{y}_{t|k}$ nazýváme **predikcí**,

- pokud $k = t$, $\hat{y}_{t|t}$ nazýváme **filtrací**
- a je-li $k = n > t$, pak $\hat{y}_{t|n}$ nazýváme **vyrovnáním** (*smoothing*).

2 Jednoduché exponenciální vyrovnávání

Exponenciální vyrovnávání pro $m = 0$ se nazývá jednoduché exponenciální vyrovnávání. Použijeme-li označení $\hat{\beta}_0(t) = b_0(t)$ a uvážíme-li, že pro $\alpha \in (0, 1)$ je $\sum_{\tau=0}^{\infty} \alpha^\tau = \frac{1}{1-\alpha}$, dostaneme

$$b_0(t) \sum_{\tau=0}^{\infty} \alpha^\tau = \sum_{\tau=0}^{\infty} \alpha^\tau Y_{t-\tau} \Rightarrow \boxed{b_0(t) = \hat{Y}_t = (1-\alpha) \sum_{\tau=0}^{\infty} \alpha^\tau Y_{t-\tau}}$$

Abychom získali rekurentní vztah, upravujme

$$\begin{aligned} \hat{Y}_t &= (1-\alpha) \sum_{\tau=0}^{\infty} \alpha^\tau Y_{t-\tau} = (1-\alpha) Y_t + (1-\alpha) \sum_{\tau=1}^{\infty} \alpha^\tau Y_{t-\tau} = \left| \begin{array}{l} \text{subst.} \\ k = \tau - 1 \end{array} \right| \\ &= (1-\alpha) Y_t + (1-\alpha) \sum_{k=0}^{\infty} \alpha^{k+1} Y_{t-1-k} \\ &= (1-\alpha) Y_t + \underbrace{\alpha (1-\alpha) \sum_{k=0}^{\infty} \alpha^k Y_{t-1-k}}_{\hat{Y}_{t-1}} = (1-\alpha) Y_t + \alpha \hat{Y}_{t-1} \end{aligned}$$

Protože predikce o τ ($\tau > 0$) kroků dopředu pro jednoduché exponenciální vyrovnávání je rovna $\hat{Y}_{t+\tau|t} = \hat{Y}_t = b_0(t)$, můžeme předchozí rekurentní vztah přepsat pro realizace a dále upravovat

$$\begin{aligned} \hat{y}_{t+1|t} &= (1-\alpha)y_t + \alpha\hat{y}_{t|t-1} \\ &= (1-\alpha)y_t + \alpha\hat{y}_{t|t-1} + \hat{y}_{t|t-1} - \hat{y}_{t|t-1} \\ &= \hat{y}_{t|t-1} + (1-\alpha) \underbrace{(y_t - \hat{y}_{t|t-1})}_{\text{chyba predikce } \hat{\varepsilon}_{t|t-1}} \end{aligned}$$

a o rekurentním vzorci s chybou predikce $\hat{\varepsilon}_{t|t-1}$ se říká, že je ve formě korekce chyby předpovědi (*error correction form*).

3 Ad hoc přístupy Holta a Winterse

Pokud chceme na základě pozorování y_1, \dots, y_t sestavit předpověď budoucí hodnoty y_{t+1} v čase $t+1$, označme ji $\hat{y}_{t+1|t}$, pak nejjednodušším odhadem může být obyčejný průměr. Tato předpověď je vhodná, pokud hodnoty časové řady náhodně kolísají kolem střední hodnoty, která se v čase nemění. Jako rozumnější se však jeví použít pro predikci budoucí hodnoty ve větší míře pozorování, která jsou časově nejbližší. Pak se nabízejí vážené průměry

$$\hat{y}_{t+1|t} = \sum_{j=0}^{t-1} w_{j,t} y_{t-j}, \quad (1)$$

kde součet vah je roven jedné, tj. $\sum_{j=0}^n w_{j,t} = 1$.

Exponenciální vyrovnávání je založeno na myšlence použití vah, které do minulosti klesají exponenciálně.

S využitím vztahu

$$\sum_{j=0}^{t-1} \alpha^j = \frac{1 - \alpha^t}{1 - \alpha}, \quad \text{pro } \alpha \in (0, 1), \quad (2)$$

chceme-li, aby součet vah, které exponenciálně klesají, byl roven jedné, položíme

$$w_{j,t} = \frac{1 - \alpha}{1 - \alpha^t} \alpha^j. \quad (3)$$

Protože pro $t \rightarrow \infty$ konvergují váhy $w_{j,t} \rightarrow w_j = (1 - \alpha)\alpha^j$, můžeme uvažovat jednokrokovou předpověď ze všech minulých pozorování ve tvaru

$$\hat{y}_{t+1|t} = (1 - \alpha) \sum_{j=0}^{\infty} \alpha^j y_{t-j}, \quad \text{pro } \alpha \in (0, 1). \quad (4)$$

Analogicky jako u Brownova přístupu odvodíme rekurentní vztahy

$$\begin{aligned} \hat{y}_{t+1|t} &= (1 - \alpha)y_t + (1 - \alpha) \sum_{j=1}^{\infty} \alpha^j y_{t-j} \\ &= (1 - \alpha)y_t + \alpha(1 - \alpha) \sum_{k=0}^{\infty} \alpha^k y_{t-1-k} \\ &= (1 - \alpha)y_t + \alpha \hat{y}_{t|t-1} \end{aligned}$$

Obdobně získáme i tvar využívající korekci chyby předpovědi

$$\begin{aligned} \hat{y}_{t+1|t} &= (1 - \alpha)y_t + \alpha \hat{y}_{t|t-1} + \hat{y}_{t|t-1} - \hat{y}_{t|t-1} \\ &= \hat{y}_{t|t-1} + (1 - \alpha)(y_t - \hat{y}_{t|t-1}) \\ &= \hat{y}_{t|t-1} + (1 - \alpha)\hat{\varepsilon}_{t|t-1} \end{aligned}$$

Na tomto ad-hoc přístupu se nám podařilo ukázat, že se v podstatě jedná o **jednoduché exponenciální vyrovnávání**, které přepokládá model

$$Y_t = \beta_0(t) + \varepsilon_t$$

s lokální hladinou $\beta_0(t)$.

Použijeme-li značení obvyklá pro tento přístup, kdy váhy mají tvar

$$w_j = \beta(1 - \beta)^j, \quad (5)$$

tj. $\alpha = 1 - \beta$, místo $\widehat{\beta_0(t)}$, píšeme L_t (level). Odvozené vztahy v novém značení:

$$\hat{y}_{t+1|t} = \beta y_t + (1 - \beta)\hat{y}_{t|t-1} = \hat{y}_{t|t-1} + \beta\hat{\varepsilon}_{t|t-1} \quad (6)$$

$$L_{t+1} = L_t + \beta\hat{\varepsilon}_{t+1|t} \quad (7)$$

4 Holtovo exponenciální vyrovnávání

Oproti jednoduchému exponenciálnímu vyrovnávání Holtova metoda předpokládá lokálně lineární trend, jehož koeficienty $\beta_0(t)$ i $\beta_1(t)$ se v čase mění. Hodnota časové řady v okamžiku t je určena jednak její úrovní $\beta_0(t)$, jednak směrnici $\beta_1(t)$. V Holtově metodě se úroveň v čase t značí symbolem L_t (zkratka pro *level*) a směrnice jako T_t (zkratka pro *trend*).

Úroveň L_t je zároveň vyrovnanou hodnotou realizace y_t v okamžiku t . Směrnice lokálně lineárního trendu T_t (někdy mluvíme krátce o trendu) vyjadřuje očekávanou změnu úrovně časové řady při jednotkové časové změně. Pokud chceme pomocí Holtovy metody předpovídat hodnotu časové řady o $h > 0$ jednotek dopředu, položíme

$$\hat{y}_{t+h|t} = L_t + T_t h . \quad (8)$$

Takže, je-li $h = 1$, dostaneme jednokrokovou předpověď jako

$$\hat{y}_{t+1|t} = L_t + T_t . \quad (9)$$

Protože by přibližně mělo platit, že realizace $y_{t+1} \approx L_{t+1}$, pak se jeví vhodné získat L_{t+1} , jako konvexní lineární kombinaci hodnot $(L_t + T_t)$ a y_{t+1} . V Holtově metodologii bývá zvykem místo $\alpha \in (0, 1)$ používat $\beta = 1 - \alpha$, takže konvexní lineární kombinace bude mít tvar

$$L_{t+1} = (1 - \beta)(L_t + T_t) + \beta y_{t+1} . \quad (10)$$

Hodnota β se nazývá *vyrovnávací konstanta pro úroveň řady*.

Analogickou úvahu použijeme i pro směrnici trendu T_t . Z předpokladu, že řada má lokálně lineární trend vyplývá, že by přibližně mělo platit

$$T_{t+1} \approx T_t,$$

ale zároveň má také smysl očekávat, že směrnice trendu je přibližně rozdílem sousedních úrovní, tj.

$$T_{t+1} \approx L_{t+1} - L_t .$$

Novou hodnotu směrnice T_{t+1} budeme uvažovat jako konvexní lineární kombinaci

$$T_{t+1} = (1 - \gamma)T_t + \gamma(L_{t+1} - L_t), \quad \text{kde } \gamma \in (0, 1) \quad (11)$$

γ je tzv. *vyrovnávací konstanta pro lineární růst (pro směrnici)*.

Na závěr odstavce ještě ukážeme přepsání předchozích rekurentních vztahů do chybového

tvaru.

$$\begin{aligned} L_{t+1} &= (1 - \beta)(L_t + T_t) + \beta y_{t+1} = (1 - \beta)(L_t + T_t) + \beta y_{t+1} + \beta \hat{y}_{t+1|t} - \beta \hat{y}_{t+1|t} \\ &= \beta \underbrace{(y_{t+1} - \hat{y}_{t+1|t})}_{\hat{\varepsilon}_{t+1|t}} + (1 - \beta)(L_t + T_t) + \beta \underbrace{\hat{y}_{t+1|t}}_{L_t + T_t} \\ &= \beta \hat{\varepsilon}_{t+1|t} + L_t + T_t \end{aligned}$$

$$\begin{aligned} T_{t+1} &= (1 - \gamma)T_t + \gamma(L_{t+1} - L_t) = T_t - \gamma T_t + \gamma \underbrace{L_{t+1}}_{L_t + T_t + \beta \hat{\varepsilon}_{t+1|t}} - \gamma L_t \\ &= T_t - \gamma T_t + \gamma(L_t + T_t + \beta \hat{\varepsilon}_{t+1|t}) - \gamma L_t \\ &= T_t + \gamma \beta \hat{\varepsilon}_{t+1|t} . \end{aligned}$$

5 Holtovo-Wintersovo exponenciální vyrovnávání

V případě, kdy časová řada má sezónní charakter, nevystačíme se žádnou z předchozích metod. Rozšíření Holtovy metody na sezónní časové řady je známo jako **Holtova–Wintersova metoda**. Autorem je Holtův student Peter R. Winters.

Holtova-Wintersova metoda je založena na třech vyrovnávacích konstantách. Jedna je pro hladinu, druhá pro trend a třetí pro sezónnost. Dle charakteru dat využívá aditivní nebo multiplikační notaci.

Uvažujme časovou řadu s lokálně lineárním trendem a sezónností s periodou $p \geq 2$. Stejně jako u Holtovy metody označme symbolem L_t úroveň v čase t , symbolem T_t směrnici lokálně lineárního trendu a symbolem S_t sezónní výkyv čase t . Součet úrovně L_t s hodnotou sezónního výkyvu S_t představuje v okamžiku t vyrovnanou hodnotu realizace y_t . Předpověď hodnoty časové řady o $h > 0$ jednotek dopředu je pak dána vztahem

$$\hat{y}_{t+h|t} = L_t + S_{t-p+h} + T_t h, \quad (12)$$

takže v případě jednokrokové predikce platí

$$\hat{y}_{t+1|t} = L_t + S_{t+1-p} + T_t \quad (13)$$

Protože by mělo přibližně platit

$$y_{t+1} \approx L_{t+1} + S_{t+1-p}$$

a

$$L_{t+1} \approx L_t + T_t,$$

má smysl získat úroveň L_{t+1} jako konvexní lineární kombinaci hodnot $(L_t + S_t)$ a $(y_{t+1} - S_{t+1-p})$, tj.

$$L_{t+1} = (1 - \beta)(L_t + T_t) + \beta(y_{t+1} - S_{t+1-p}). \quad (14)$$

Protože řada má lokálně lineární trend, mělo by přibližně platit

$$T_{t+1} \approx T_t,$$

ale zároveň lze směrnici lokálně lineárního trendu vyjádřit pomocí rozdílu sousedních hladin

$$T_{t+1} \approx L_{t+1} - L_t.$$

Oba předchozí vztahy využijeme při konstrukci směrnice lokálně lineárního trendu díky konvexní lineární kombinaci

$$T_{t+1} = (1 - \gamma)T_t + \gamma(L_{t+1} - L_t),$$

kde $\gamma \in (0, 1)$ se nazývá *vyrovnávací konstanta pro směrnici trendu*. Pro sezónní výkyvy musí platit vztah

$$S_{t+1} \approx S_{t+1-p},$$

a také

$$S_{t+1} \approx y_{t+1} - L_{t+1}$$

Tedy označíme-li symbolem $\delta \in (0, 1)$ *vyrovnávací konstantu pro sezónní výkyvy*, pak

$$S_{t+1} = (1 - \delta)S_{t+1-p} + \delta(y_{t+1} - L_{t+1})$$

Na závěr odstavce odvodíme rekurentní vztahy v chybové formě. Tedy upravujeme

$$\begin{aligned} L_{t+1} &= (1 - \beta)(L_t + T_t) + \beta(y_{t+1} - S_{t+1-p}) \\ &= (1 - \beta)(L_t + T_t) + \beta(y_{t+1} - S_{t+1-p}) + \beta\hat{y}_{t+1|t} - \beta\hat{y}_{t+1|t} \\ &= \beta(y_{t+1} - \hat{y}_{t+1|t}) + L_t + T_t - \beta L_t - \beta T_t - \beta S_{t+1-p} + \beta \underbrace{\hat{y}_{t+1|t}}_{L_t + S_{t+1-p} + T_t} \\ &= L_t + T_t + \beta\hat{\varepsilon}_{t+1|t} \end{aligned}$$

$$\begin{aligned} T_{t+1} &= (1 - \gamma)T_t + \gamma(L_{t+1} - L_t) = T_t - \gamma T_t + \gamma \underbrace{L_{t+1}}_{L_t + T_t + \beta\hat{\varepsilon}_{t+1|t}} - L_t \\ &= T_t - \gamma T_t + \gamma(L_t + T_t + \beta\hat{\varepsilon}_{t+1|t} - L_t) \\ &= T_t + \gamma\beta\hat{\varepsilon}_{t+1|t} \end{aligned}$$

$$\begin{aligned} S_{t+1} &= (1 - \delta)S_{t+1-p} + \delta(y_{t+1} - L_{t+1}) \\ &= S_{t+1-p} - \delta(S_{t+1-p} - y_{t+1}) - \delta(L_t + T_t + \beta\hat{\varepsilon}_{t+1|t}) \\ &= S_{t+1-p} + \delta y_{t+1} - \delta(L_t + T_t + S_{t+1-p}) - \delta\beta\hat{\varepsilon}_{t+1|t} \\ &= S_{t+1-p} + \delta(1 - \beta)\hat{\varepsilon}_{t+1|t}. \end{aligned}$$

6 Exponenciální vyrovnávání v prostředí R

V prostředí R je pro exponenciální vyhlazování v balíčku `stats` k dispozici funkce `HoltWinters()`, která například v případě aditivního modelu uvažuje rekurentní vztahy

- úroveň (*level*) • $L_t = \alpha(y_t - S_{t-p}) + (1 - \alpha)(L_{t-1} + T_{t-1})$
- lineární růst (*growth*) • $T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$
- sezónní výkyvy (*seasonal*) • $S_t = \gamma(y_t - L_{t-1} - T_{t-1}) + (1 - \gamma)S_{t-p}$
- předpověď (*forecast*) • $\hat{y}_{t+h|t} = L_t + T_t h + S_{t-p+h_p^+}$

kde $h_p^+ = [(h - 1) \text{ mod } p] + 1$.

Počáteční stavy $L_0, T_0, S_{1-p}, \dots, S_0$ a tzv. vyrovnávací konstanty α, β, γ jsou odhadnuty na základě dat. Na podrobný popis funkce se podívejte pomocí příkazu `?HoltWinters`.

Mnohem komplexnější možnosti nabízí funkce `ets()` z balíčku `forecast`, která navíc dovoluje tzv. tlumící faktor.

Tak například, označíme-li

$$\mu_t = \hat{y}_t,$$

pak model s **tlumeným lineárním trendem**, kdy

$$\mu_t = \hat{y}_t = L_{t-1} + T_{t-1}$$

a který je ve formě korekce chyby predikce (*error correction form*), bude definován rekuretními vztahy

$$\begin{aligned} y_t &= L_{t-1} + \phi T_{t-1} + \varepsilon_t \\ L_t &= L_{t-1} + \phi T_{t-1} + \alpha \varepsilon_t \\ T_t &= \phi T_{t-1} + \beta(L_t - L_{t-1} - \phi T_{t-1}) = \phi T_{t-1} + \alpha \beta \varepsilon_t \end{aligned}$$

Optimální model je vybrán na základě tzv. AIC kritéria

$$AIC = -2 \log(\text{Likelihood}) + 2m,$$

kde m je počet parametrů.

Při výstupu procedura `ets()` používá následující notaci

Trendová komponenta	Sezónní komponenta		
	N (None)	A (Additive)	M (Multiplicative)
N (None)	N, N	N, A	N, M
A (Additive)	A, N	A, A	A, M
A_d (Additive damped)	A_d, N	A_d, A	A_d, M
M (Multiplicative)	M, N	M, A	M, M
M_d (Multiplicative damped)	M_d, N	M_d, A	M_d, M

Označení optimálního modelu tvoří trojici $ETS(E, T, S)$, kde

E	<i>error</i>	možné hodnoty	A, M
T	<i>trend</i>		N, A, A_d, M, M_d
S	<i>seasonal</i>		N, A, M

PŘÍKLAD 1

Metodu exponenciálního vyrovnávání aplikujeme na časovou řadu v souboru `wool.txt`. Jedná se o čtvrtletní údaje o množství vlny (v tunách) vyprodukované v Austrálii v letech 1965-1994. Datový soubor obsahuje pouze jeden sloupec s daty, proto bude nejjednodušší k načtení použít funkci `scan`:


```
> fileDat <- paste(data.library, "wool.txt", sep = "")
> wool <- scan(fileDat)
```

Z načtených dat vytvoříme časovou řadu a vykreslíme ji.

```
> woolTS <- ts(wool, start = 1965, frequency = 4)
> str(woolTS)
```

```
Time-Series [1:119] from 1965 to 1994: 6172 6709 6633 6660 6786 ...
```

```
> par(mar = c(2, 2, 0, 0) + 0.5)
> plot(woolTS)
```



Obrázek 1: *Produkce vlny v Austrálii v letech 1965-1994.*

Na načtená data nejprve použijeme jednoduché exponenciální vyrovnávání (lokálně konstantní trend). Potřebujeme určit jedinou vyrovnávací konstantu α . Model bude ve tvaru

$$\hat{Y}_{t+h} = L_t,$$

kde L_t je dáno vztahem

$$L_t = \alpha Y_t + (1 - \alpha)L_{t-1}$$

K tomu můžeme použít funkci `HoltWinters`, která je sice určena pro obecnější Holt–Wintersovo exponenciální vyrovnávání, kde počítáme nejen s úrovní (jako v případě jednoduchého exponenciálního vyrovnávání), ale i s lineárním trendem a sezónní složkou. Abychom odhadli pouze model jednoduchého exponenciálního vyrovnávání s jedinou vyrovnávací konstantou α , je třeba zadat, že nás nezajímají vyrovnávací konstanty β a γ , a toho dosáhneme zadáním argumentu `beta=FALSE`, `gamma=FALSE`.

Odhadnutou konstantu L_t pro úroveň v čase t odpovídající poslednímu pozorování zobrazíme pomocí funkce `coefficients`. V R je tato konstanta označena jako `a`.

```
> x <- woolTS
> model1 <- HoltWinters(x, beta = FALSE, gamma = FALSE)
> summary(model1)
```

```
      fitted      Length Class  Mode
fitted      236      mts     numeric
x           119      ts      numeric
alpha        1      -none-  numeric
beta         1      -none-  logical
gamma        1      -none-  logical
coefficients 1      -none-  numeric
seasonal     1      -none-  character
SSE          1      -none-  numeric
call        4      -none-  call
```

```
> model1$alpha
```

```
[1] 0.376407
```

```
> coefficients(model1)
```

```
      a
5711.117
```

Na základě tohoto modelu provedeme predikci na dva roky dopředu. Ta by měla vypadat takto


$$\hat{y}_{t+h|t} = L_t = a$$

Výsledky jednoduchého exponenciálního vyrovnávání i predikci vykreslíme do grafu.

```
> pred1 <- predict(model1, n.ahead = 12, prediction.interval = TRUE)
> summary(pred1)
```

```
      fit      upr      lwr
Min.  :5711  Min.  :6951  Min.  :3727
1st Qu.:5711  1st Qu.:7173  1st Qu.:3885
Median :5711  Median :7365  Median :4057
Mean   :5711  Mean   :7349  Mean   :4073
3rd Qu.:5711  3rd Qu.:7537  3rd Qu.:4250
Max.   :5711  Max.   :7695  Max.   :4471
```

```
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(model1, predicted.values = pred1)
```



Obrázek 2: Jednoduché exponenciální vyrovnávání pomocí funkce `HoltWinters()` pro časovou řadu: *Produkce vlny v Austrálii v letech 1965-1994*

Z grafu je jasně patrné, že predikované hodnoty mají stejnou konstantní úroveň a ta se rovná odhadnuté úrovni pro poslední pozorování L_t – v R jí odpovídá konstanta a .

Zkusíme použít poněkud složitější model – Holtovo exponenciální vyrovnávání, které nevyužívá lokálně konstantní trend jako v předchozím případě, ale lokálně lineární trend. Tento typ exponenciálního vyrovnávání vyžaduje určení dvou vyrovnávacích konstant α a β .

Model exponenciálního vyrovnávání má tvar

$$\hat{Y}_{t+h} = L_t + T_t h,$$

kde L_t a T_t jsou dány

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + T_{t-1})$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$$

Opět použijeme funkci `HoltWinters`, tentokrát použijeme argument `gamma=FALSE`, protože sezónní složka nás zatím nezajímá.

```
> model2 <- HoltWinters(x, gamma = FALSE)
> summary(model2)
```

	Length	Class	Mode
fitted	351	mts	numeric
x	119	ts	numeric
alpha	1	-none-	numeric

```

beta          1  -none- numeric
gamma         1  -none- logical
coefficients  2  -none- numeric
seasonal      1  -none- character
SSE           1  -none- numeric
call          3  -none- call

```

```
> model2$alpha
```

```

alpha
0.4180789

```

```
> model2$beta
```

```

beta
0.1901893

```

```
> coefficients(model2)
```

```

      a      b
5888.1247 205.5479

```

Na základě druhého modelu znovu provedeme predikci na dva roky dopředu. Ta bude ve tvaru


$$\hat{Y}_{t+h|t} = a + bt = 5888.1247 + 205.5479t.$$

Výsledky jednoduchého exponenciálního vyrovnávání i predikci vykreslíme do grafu.

```
> pred2 <- predict(model2, n.ahead = 12, prediction.interval = TRUE)
> summary(pred2)
```

fit	upr	lwr
Min. :6094	Min. : 7432	Min. :4016
1st Qu.:6659	1st Qu.: 8503	1st Qu.:4406
Median :7224	Median : 9767	Median :4682
Mean :7224	Mean : 9880	Mean :4568
3rd Qu.:7789	3rd Qu.:11173	3rd Qu.:4784
Max. :8355	Max. :12694	Max. :4822

```
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(model2, predicted.values = pred2)
```



Obrázek 3: Holtova metoda pomocí funkce `HoltWinters()` pro časovou řadu: *Produkce vlny v Austrálii v letech 1965-1994*

Porovnáme-li tento graf s grafem pro jednoduché vyrovňávání, můžeme si všimnout rozdílu v predikci. U jednoduchého exponenciálního vyrovňávání je predikce konstantní, zatímco u Holtovy metody je to rostoucí lineární funkce. To souvisí s tím, že u jednoduchého exponenciálního vyrovňávání pracujeme s lokálním polynomem nultého stupně, u Holtovy metody s lokálním polynomem prvního stupně.

Protože data, která máme k dispozici, jsou čtvrtletní, je možné (a při pohledu „od oka“ to vypadá hodně pravděpodobně), že bychom v nich mohli objevit sezónní chování. Proto vyzkoušíme ještě třetí metodu – Holtovo–Wintersovo vyrovňávání, které bere v úvahu i sezónnost.

Model bude ve tvaru

$$\hat{Y}_{t+h} = L_t + T_t h + S_{t-p+h_p^+},$$

kde L_t , T_t a S_t jsou dány

$$\begin{aligned} L_t &= \alpha(Y_t - s_{t-p}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \\ S_t &= \gamma(Y_t - L_t) + (1 - \gamma)S_{t-p} \end{aligned}$$

Holtovo–Wintersovo vyrovňávání vyžaduje tři vyrovnávací konstanty α , β a γ . K jejich určení opět použijeme funkci `HoltWinters`, tentokrát již bez argumentů udávajících vynechané konstanty.

```
> model3 <- HoltWinters(x)
> summary(model3)
```

	Length	Class	Mode
fitted	460	mts	numeric
x	119	ts	numeric
alpha	1	-none-	numeric
beta	1	-none-	numeric
gamma	1	-none-	numeric
coefficients	6	-none-	numeric
seasonal	1	-none-	character
SSE	1	-none-	numeric
call	2	-none-	call

```
> model3$alpha
```

```
alpha
0.6521521
```

```
> model3$beta
```

```
beta
0.007690488
```

```
> model3$gamma
```


```
gamma
0.6478487
```

```
> coefficients(model3)
```

a	b	s1	s2	s3	s4
6222.72882	18.95975	-220.20379	-899.45453	-147.85037	168.78680

Hodnoty sezónních složek vykreslíme do grafu.

```
> par(mar = c(2, 2, 0, 0) + 0.5)
> plot(1:4, coefficients(model3)[3:6], type = "o")
> for (k in 1:4) abline(v = k, col = "gray", lty = 1)
```



Obrázek 4: Hodnoty sezónních složek z Holtova–Wintersova exponenciálního vyrovnávání pomocí funkce `HoltWinters()` pro časovou řadu: *Produkce vlny v Austrálii v letech 1965-1994*


Na základě tohoto modelu znovu provedeme predikci na dva roky dopředu. Výsledky Holtova-Wintersova exponenciálního vyrovnání i predikci vykreslíme do jednoho grafu. Predikci dostaneme ze vztahu

$$\hat{Y}_{t+h|t} = a + bh + s_{t+p+1+(h-1) \bmod p},$$

```
> pred3 <- predict(model3, n.ahead = 12, prediction.interval = T)
> summary(pred3)
```

fit	upr	lwr
Min. :5361	Min. :6397	Min. :3419
1st Qu.:5894	1st Qu.:7256	1st Qu.:4152
Median :6152	Median :7706	Median :4410
Mean :6071	Mean :7713	Mean :4430
3rd Qu.:6329	3rd Qu.:8229	3rd Qu.:4764
Max. :6619	Max. :8883	Max. :5156

```
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(model3, predicted.values = pred3)
```



Obrázek 5: Holtovo–Wintersovo exponenciální vyrovnávání pomocí funkce `HoltWinters()` pro časovou řadu: *Produkce vlny v Austrálii v letech 1965-1994*

Dále se podíváme, jak dopadnou výsledky v případě použití funkce `ets()` z balíčku `forecast`.

```
> library(forecast)
```

Funkce `ets()` umožňuje vyrovnávání jak v aditivních, tak v multiplikativních modelech (to umí i `HoltWinters()`), a navíc umí odhadnout i exponenciální vyrovnávání s tlumícím faktorem. My zatím nebudeme uvažovat tak komplikované modely, provedeme obyčejné Holtovo-Wintersovo exponenciální vyrovnávání bez tlumícího faktoru a budeme chtít pouze aditivní model, to znamená, že uděláme přibližně totéž co v předchozím modelu (`model3`).

Odhad vyrovnávacích konstant bez tlumícího faktoru provedeme v případě funkce `ets()` přidáním argumentu `damped=FALSE`, argumentem `additive.only=TRUE` vyloučíme možnost multiplikativních modelů.

```
> x <- woolTS
> modelETS1 <- ets(x, damped = FALSE, additive.only = TRUE)
> summary(modelETS1)
```

```
ETS(A,N,A)
```

```
Call:
```

```
ets(y = x, damped = FALSE, additive.only = TRUE)
```

```
Smoothing parameters:
```

```
alpha = 0.7488
```

```
gamma = 1e-04
```

```
Initial states:
```

```
l = 6644.9513
```

```
s=31.5458 408.2945 129.0941 -568.9344
```

```
sigma: 436.0035
```

```
      AIC      AICc      BIC
2027.196 2027.946 2043.871
```

```
In-sample error measures:
```

```
      ME      RMSE      MAE      MPE      MAPE
-7.8706447 436.0035123 340.1038656 -0.5567476 6.0128422
      MASE
0.6055871
```

Prohlédneme si odhadnuté parametry.


```
> modelETS1$par
```

```
      alpha      gamma      l      s0      s1
7.487666e-01 1.000492e-04 6.644951e+03 3.154583e+01 4.082945e+02
      s2
1.290941e+02
```

Na základě AIC kritéria funkce `ets()` vybrala pro naše data jednoduché exponenciální vyrovnávání se sezónní složkou – tj. lokálně konstantní trend s odchylkami odpovídajícím čtvrtletím (značení $ETS(A, N, A)$). Všechny komponenty jsou aditivní. Odhadnutý model se liší od modelu 3 v tom, že se v něm nevyskytuje lineární trend.


Výsledky exponenciálního vyhlazení opět vykreslíme. Pokud použijeme funkci `plot` na model, který je výstupem funkce `ets`, dostaneme graf, v němž jsou vykreslena zvláště původní data, odhadnuté úrovně L_t , trendová komponenta T_t a cyklická komponenta S_t . Pokud zadáme argument `plot.type=single`, vše se zobrazí do jediného grafu.

```
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(modelETS1)
```



Obrázek 6: Dekompozice pomocí funkce `ets()` pro časovou řadu: *Produkce vlny v Austrálii v letech 1965-1994*

```
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(modelETS1, plot.type = "single", col = 1:3, ylab = "")
```



Obrázek 7: Holtovo–Wintersovo exponenciální vyrovnávání pomocí funkce `ets()` pro časovou řadu: *Produkce vlny v Austrálii v letech 1965-1994*

Opět se podíváme na predikované hodnoty pro dva následující roky.

```
> predETS1 <- forecast(modeLETS1)
> summary(predETS1)
```

Forecast method: ETS(A,N,A)

Model Information:
ETS(A,N,A)

Call:
ets(y = x, damped = FALSE, additive.only = TRUE)

Smoothing parameters:
alpha = 0.7488
gamma = 1e-04

Initial states:
l = 6644.9513
s=31.5458 408.2945 129.0941 -568.9344

sigma: 436.0035

AIC	AICc	BIC
2027.196	2027.946	2043.871

In-sample error measures:


ME	RMSE	MAE	MPE	MAPE
-7.8706447	436.0035123	340.1038656	-0.5567476	6.0128422

MASE
0.6055871

Forecasts:

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
1994 Q4	5975.187	5416.426	6533.948	5120.636	6829.738
1995 Q1	5374.703	4676.665	6072.741	4307.146	6442.260
1995 Q2	6072.705	5258.858	6886.552	4828.034	7317.377
1995 Q3	6351.917	5436.827	7267.007	4952.407	7751.427
1995 Q4	5975.187	4968.989	6981.384	4436.341	7514.033
1996 Q1	5374.703	4284.989	6464.417	3708.129	7041.277
1996 Q2	6072.705	4905.415	7239.995	4287.489	7857.921
1996 Q3	6351.917	5111.913	7591.921	4455.495	8248.339

```
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(predETS1)
```



Obrázek 8: Predikce pomocí funkce `forecast()` pro časovou řadu: *Produkce vlny v Austrálii v letech 1965-1994*

Pro zajímavost si můžeme ještě na závěr vyzkoušet, jak by dopadlo exponenciální vyrovnání naší časové řady v případě, že bychom funkci `ets()` povolili použít všechny možnosti, které umí, včetně tlumícího faktoru a multiplikativních modelů.

```
> x <- woolTS
> modelETS2 <- ets(x)
> summary(modelETS2)
```

ETS(M,N,A)

Call:

```
ets(y = x)
```

Smoothing parameters:

```
alpha = 0.941
gamma = 1e-04
```

Initial states:

```
l = 6650.654
s=33.2949 461.4852 135.7959 -630.576
```

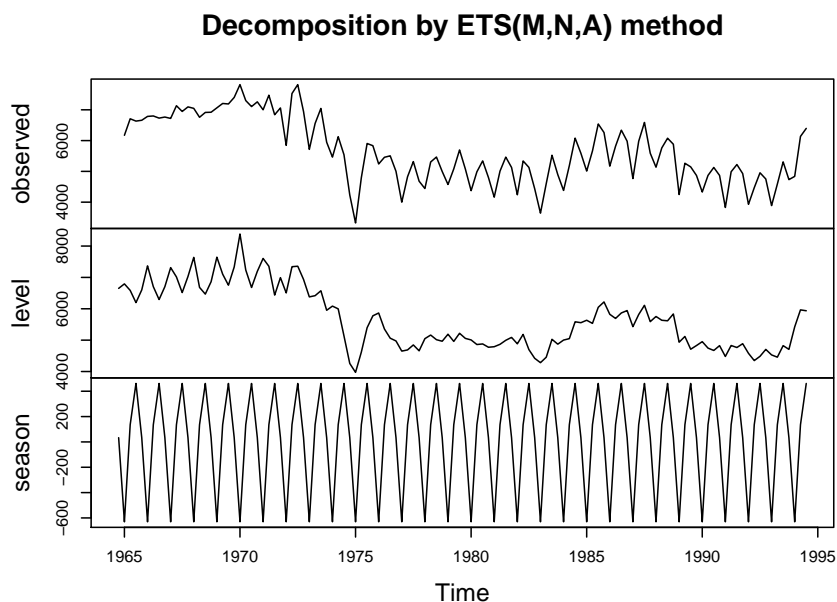
```
sigma: 0.0748
```

```
      AIC      AICc      BIC
2016.480 2017.230 2033.155
```

In-sample error measures:


```
      ME      RMSE      MAE      MPE      MAPE
-6.3777596 443.0083548 349.5425906 -0.4032783 6.0751771
      MASE
0.6223936
```

```
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(modelETS2)
```



Obrázek 9: Dekompozice pomocí funkce `ets()`: *Produkce vlny v Austrálii v letech 1965-1994*

```
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(modelETS2, plot.type = "single", col = 1:3, ylab = "")
```



Obrázek 10: Holtovo–Wintersovo exponenciální vyrovnávání pomocí funkce `ets()` pro časovou řadu: *Produkce vlny v Austrálii v letech 1965-1994*

```
> predETS2 <- forecast(modelETS2)
> summary(predETS2)
```

Forecast method: ETS(M,N,A)

Model Information:
ETS(M,N,A)

Call:
ets(y = x)

Smoothing parameters:
alpha = 0.941
gamma = 1e-04

Initial states:
l = 6650.654
s=33.2949 461.4852 135.7959 -630.576

sigma: 0.0748

AIC	AICc	BIC
2016.480	2017.230	2033.155

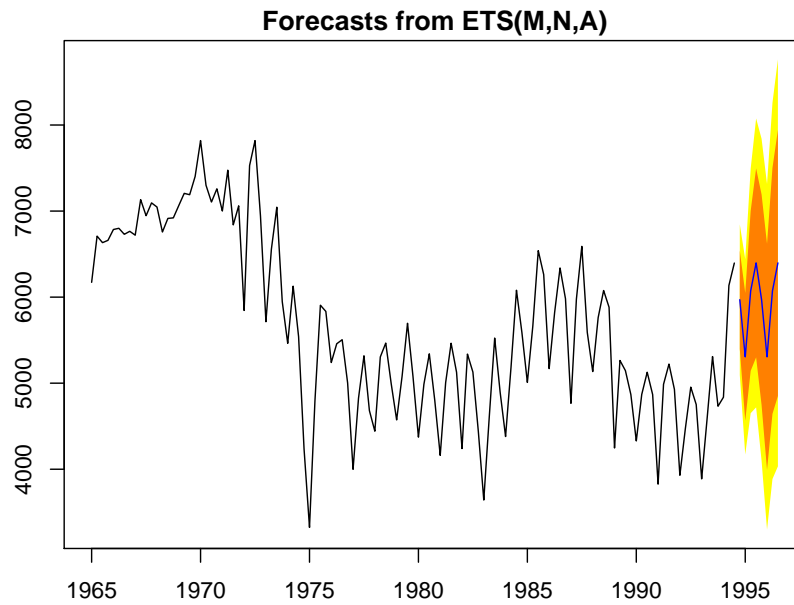
In-sample error measures:

ME	RMSE	MAE	MPE	MAPE
-6.3777596	443.0083548	349.5425906	-0.4032783	6.0751771
MASE				
0.6223936				

Forecasts:

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
1994 Q4	5969.934	5397.324	6542.543	5094.203	6845.664
1995 Q1	5306.109	4563.842	6048.377	4170.909	6441.310
1995 Q2	6072.065	5142.938	7001.192	4651.088	7493.042
1995 Q3	6397.812	5299.973	7495.651	4718.813	8076.812
1995 Q4	5969.934	4746.830	7193.037	4099.358	7840.509
1996 Q1	5306.109	3992.769	6619.450	3297.529	7314.690
1996 Q2	6072.065	4642.732	7501.397	3886.090	8258.040
1996 Q3	6397.812	4851.590	7944.034	4033.069	8762.555

```
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(predETS2)
```



Obrázek 11: Predikce pomocí funkce `forecast()` pro časovou řadu: *Produkce vlny v Austrálii v letech 1965-1994*

7 Úkol:

Aplikujte exponenciální vyhlazování na časovou řadu s měsíčními údaji o počtu smrtelných úrazů v USA v letech 1973-1978 v souboru `deaths.dat`.