

M0130 – 8. PRAKTIKUM : M0130pr08 (*Modelování sezónnosti*)**A. Model I: Metoda malého trendu**

Uvažujme regresní model ve tvaru:

$$Y_t = Tr_t + Sz_t + \varepsilon_t \quad \varepsilon_t \sim WN(0, \sigma^2).$$

Přeindexujme  $Y_1, \dots, Y_n$  na  $Y_{jk}$ ,  $j = 1, \dots, r$   $r$  ... počet sezón  
 $\varepsilon_1, \dots, \varepsilon_n$   $\varepsilon_{jk}$ ,  $k = 1, \dots, d$   $d$  ... délka sezóny.

Předpokládejme, že trend je konstantní pro  $j$ -tou sezónu, tj.  $Tr_j = m_j$   
a rovněž sezónní hodnota je konstantní pro  $k$ -tou sezónní složku, tj.  $Sz_k = s_k$ .

Regresní model můžeme napsat ve tvaru

$$\boxed{M_I}: Y_{jk} = m_j + s_k + \varepsilon_{jk} \quad \varepsilon_{jk} \sim WN(0, \sigma^2) \quad j = 1, \dots, r \quad k = 1, \dots, d.$$

Maticově, lze tento model rozepsat takto

$$\begin{pmatrix} Y_{11} \\ \vdots \\ Y_{1d} \\ \hline Y_{21} \\ \vdots \\ Y_{2d} \\ \hline \vdots \\ Y_{r1} \\ \vdots \\ Y_{rd} \end{pmatrix} = \left( \begin{array}{cccc|cc|ccccc} 1 & 0 & \cdots & \cdots & \cdots & \cdots & 0 & 1 & 0 & \cdots & 0 \\ \vdots & 0 & 1 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 1 & 0 & \cdots & \cdots & \cdots & \cdots & 0 & 0 & \cdots & 0 & 1 \\ \hline 0 & 1 & 0 & \cdots & \cdots & \cdots & 0 & 1 & 0 & \cdots & 0 \\ \vdots & 0 & 1 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & 1 & 0 & \cdots & \cdots & \cdots & 0 & 0 & \cdots & 0 & 1 \\ \hline 0 & 0 & 0 & \cdots & 0 & 1 & 0 & 1 & 0 & \cdots & 0 \\ \vdots & 0 & 1 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & 0 & 0 & \cdots & \cdots & 1 & 0 & 0 & \cdots & 0 & 1 \\ \hline 0 & 0 & 0 & \cdots & \cdots & 0 & 1 & 1 & 0 & \cdots & 0 \\ \vdots & 0 & 1 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & 0 & 0 & \cdots & \cdots & 0 & 1 & 0 & \cdots & 0 & 1 \end{array} \right) \begin{pmatrix} \varepsilon_{11} \\ \vdots \\ \varepsilon_{1d} \\ \hline \varepsilon_{21} \\ \vdots \\ \varepsilon_{2d} \\ \hline \vdots \\ \varepsilon_{r1} \\ \vdots \\ \varepsilon_{rd} \end{pmatrix} + \begin{pmatrix} m_1 \\ \vdots \\ m_r \\ \hline s_1 \\ \vdots \\ s_d \\ \hline \vdots \\ \varepsilon_{r1} \\ \vdots \\ \varepsilon_{rd} \end{pmatrix}$$

Blokově lze psát

$$\begin{pmatrix} \mathbf{Y}_1 \\ \vdots \\ \mathbf{Y}_r \end{pmatrix} = \underbrace{\left( \begin{array}{cc|c} \mathbf{1}_d & \mathbf{0} & \cdots & \cdots & \cdots & \cdots & 0 & \mathbf{I}_d \\ \mathbf{0} & \ddots & \ddots & & & & \vdots & \vdots \\ \vdots & \ddots & \ddots & \ddots & & & \vdots & \vdots \\ \vdots & & \ddots & \ddots & \ddots & & \vdots & \vdots \\ \vdots & & & \ddots & \ddots & \ddots & 0 & \vdots \\ \hline \mathbf{0} & \cdots & \cdots & \cdots & \mathbf{0} & \mathbf{1}_d & \mathbf{I}_d \end{array} \right)}_{\text{označme } \mathbf{X}_{M_I} = \mathbf{X} = (\mathbf{X}_{(1)} | \mathbf{X}_{(2)})} \begin{pmatrix} m_1 \\ \vdots \\ m_r \\ \hline s_1 \\ \vdots \\ s_d \\ \hline \vdots \\ \varepsilon_r \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \vdots \\ \vdots \\ \vdots \\ \vdots \\ \vdots \\ \varepsilon_r \end{pmatrix}$$

kde  $\mathbf{1}_d$  je sloupcový vektor délky  $d$  samých jedniček a  $\mathbf{I}_d$  je diagonální jednotková matice typu  $d \times d$ .

Matrice plánu  $\mathbf{X}_{M_I} = \mathbf{X} = (\mathbf{X}_{(1)} | \mathbf{X}_{(2)})$  však není plné hodnosti, neboť když sečteme prvních  $r$  sloupců, dostaneme vektor samých jedniček, což je rovno také součtu posledních

$d$  sloupců. Proto přidejme ještě jednu podmíinku, a to

$$s_1 + \dots + s_d = 0$$

Potom

$$\mathbf{X}'\mathbf{X} = \left( \begin{array}{cccc|cccccc} d & 0 & \cdots & 0 & 1 & \cdots & \cdots & 1 \\ 0 & d & \ddots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \ddots & \ddots & 0 & \vdots & \vdots & \vdots & \vdots \\ 0 & \cdots & 0 & d & 1 & \cdots & \cdots & 1 \\ \hline 1 & \cdots & \cdots & 1 & r & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & 0 & r & \ddots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \ddots & 0 \\ 1 & \cdots & \cdots & 1 & 0 & \cdots & 0 & r \end{array} \right) \quad \text{a} \quad \mathbf{X}'\mathbf{Y} = \begin{pmatrix} Y_{1\cdot} \\ \vdots \\ \frac{Y_{r\cdot}}{Y_{\cdot 1}} \\ \vdots \\ Y_{d\cdot} \end{pmatrix},$$

kde využíváme tzv. tečkové notace

$$Y_{j\cdot} = \sum_{i=1}^d Y_{ji} \quad Y_{\cdot k} = \sum_{i=1}^r Y_{ik}.$$

Normální rovnice  $\mathbf{X}'\mathbf{X}\beta = \mathbf{X}'\mathbf{Y}$  můžeme přepsat (pro  $j = 1, \dots, r$ ,  $k = 1, \dots, d$ ) do tvaru

$$\begin{aligned} dm_j + \underbrace{\sum_{i=1}^d s_i}_{=0} &= Y_{j\cdot} \Rightarrow m_j = \frac{1}{d} Y_{j\cdot} = \bar{Y}_j \\ \sum_{i=1}^r m_i + rs_k &= Y_{\cdot k} \Rightarrow rs_k = Y_{\cdot k} - \sum_{i=1}^r m_i = \sum_{i=1}^r (Y_{ik} - m_i) \\ &\Rightarrow s_k = \frac{1}{r} \sum_{i=1}^r (Y_{ik} - m_i) \end{aligned}$$

### PŘÍKLAD 1: Návštěvnost v Moravském krasu

Načteme datový soubor pomocí příkazu `read.table()` s parametrem `header=TRUE`, neboť v prvním řádku jsou názvy proměnných. Příkazem `str()` vypíšeme strukturu právě načteného datového rámce.

```
> fileDat <- paste(data.library, "MorKrasNavstevnost.txt", sep = "")  
> MorKras <- read.table(fileDat, header = TRUE)  
> str(MorKras)

'data.frame':      34 obs. of  6 variables:  
 $ Rok           : int  1999 1999 1999 1999 1999 1999 1999 1999 1999 1999 ...  
 $ Mesic          : Factor w/ 12 levels "březen","červen",...: 6 11 1 4 5 2 3 10 12 9 ...  
 $ Punkevni       : int  2002 1694 4927 14186 29207 32158 39025 38629 19381 13625 ...  
 $ SloupskoSosuvsko: int  0 240 314 1498 4136 5343 12306 11725 2993 1629 ...  
 $ Katerinska     : int  0 292 508 2141 7510 8822 18225 19681 3669 2212 ...  
 $ Balcarka       : int  0 198 231 1265 4310 7445 10353 11243 1752 1400 ...
```

Pomocí funkce `ts()` vytvoříme vícerozměrnou časovou řadu. Příkazem `str()` se podíláme na její strukturu.

```
> MorKrasTS <- ts(MorKras[, -(1:2)], start = 1999, frequency = 12)  
> str(MorKrasTS)
```


```

int [1:34, 1:4] 2002 1694 4927 14186 29207 32158 39025 38629 19381 13625 ...
- attr(*, "dimnames")=List of 2
..$ : NULL
..$ : chr [1:4] "Punkevni" "SloupskoSosuvské" "Katerinska" "Balcarka"
- attr(*, "tsp")= num [1:3] 1999 2002 12
- attr(*, "class")= chr [1:2] "mts" "ts"

```

Časové řady vykreslíme pomocí příkazu `plot()`.

```
> plot(MorKrasTS, type = "o", pch = 20, cex = 3)
```



Obrázek 1: Počty návštěvníků ve vybraných jeskyních Moravského Krasu v letech 1999–2001

V prostředí R se design matice plánu pro kategoriální proměnné řídí pomocí kontrastů.

Chceme-li použít model

$$\boxed{M_I}: \quad Y_{jk} = m_j + s_k + \varepsilon_{jk} \quad \varepsilon_{jk} \sim WN(0, \sigma^2) \quad j = 1, \dots, r \quad k = 1, \dots, d$$

s dodatečnou podmínkou

$$s_1 + \dots + s_d = 0,$$

budeme muset správně nastavit kontrasty.

Protože na roční úrovně (parametry  $m_1, \dots, m_r$ ) nejsou dodatečné podmínky a matici plánu jsme (dost neobvykle) navrhli tak, že neobsahuje vektor jedniček, tak pro parametry  $m_1, \dots, m_r$  platí

$$\begin{pmatrix} 1 & 0 & \cdots & 0 \\ 0 & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & 1 \end{pmatrix} \begin{pmatrix} m_1 \\ \vdots \\ m_r \end{pmatrix} = \begin{pmatrix} m_1 \\ \vdots \\ m_r \end{pmatrix}$$

Vidíme, že matice kontrastů vztahující se k  $m_1, \dots, m_r$  bude jednotková diagonální matice řádu  $r \times r$ .

Na rozdíl od ročních úrovní  $m_j$  jsou sezónní kolísání vázána podmínkou

$$s_1 + \cdots + s_d = 0.$$

Takže jednu složku můžeme vyjádřit pomocí ostatních, nejčastěji jde o poslední, tj.

$$s_d = -s_1 - \cdots - s_{d-1}.$$

Díky tomu můžeme vypustit poslední složku. Celou reparametrizaci lze vyjádřit maticově takto

$$\underbrace{\begin{pmatrix} 1 & 0 & \cdots & \cdots & 0 \\ 0 & \ddots & \ddots & & \vdots \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ \vdots & & \ddots & \ddots & 0 \\ 0 & \cdots & \cdots & 0 & 1 \\ -1 & -1 & \cdots & -1 & -1 \end{pmatrix}}_{\text{contr.sum}} \begin{pmatrix} s_1 \\ \vdots \\ s_{d-1} \end{pmatrix} = \begin{pmatrix} s_1 \\ \vdots \\ s_{d-1} \\ s_1 - \cdots - s_{d-1} \end{pmatrix}$$

a matice typu  $d \times (d - 1)$ , kterou jsme označili jako **contr.sum**, je již v kontrastech předem nachystaná.

Vrátíme se k načteným datům. Ze čtyř časových řad si vybereme první a vytvoříme datový rámec s kategoriálními proměnnými **grY** a **grS**, který dále použijeme při definici regresního modelu.

```
> xts <- MorKrasTS[, 1]
> d <- frequency(xts)
> n <- length(xts)
> m <- ceiling(n/d)
> shift <- start(xts)[2] - 1
> r <- m * d - n - shift
> Season <- factor(as.integer(gl(d, 1, n)) - shift)
> Year <- factor(floor(time(xts)))
> data <- data.frame(x = as.vector(xts), grS = Season, grY = Year)
> str(data)

'data.frame':      34 obs. of  3 variables:
 $ x : int  2002 1694 4927 14186 29207 32158 39025 38629 19381 13625 ...
 $ grS: Factor w/ 12 levels "1","2","3","4",...: 1 2 3 4 5 6 7 8 9 10 ...
 $ grY: Factor w/ 3 levels "1999","2000",...: 1 1 1 1 1 1 1 1 1 1 ...
```

Pomocí funkce **lm()** odhadneme regresní model. Nesmíme zapomenout potlačit první sloupec jedniček a správně nastavit kontrasty.

```

> M1 <- lm(x ~ grY + grS - 1, data, contrasts = list(grY = diag(1, length(levels(data$grY))), grS = contr.sum))
> summary(M1)

Call:
lm(formula = x ~ grY + grS - 1, data = data, contrasts = list(grY = diag(1,
length(levels(data$grY))), grS = contr.sum))

Residuals:
    Min      1Q  Median      3Q     Max 
-1628.21 -252.20  -47.25  320.60 1280.83 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
grY1999   16730.2    229.6   72.870 < 2e-16 ***
grY2000   17462.6    229.6   76.060 < 2e-16 ***
grY2001   17967.1    261.8   68.637 < 2e-16 ***
grS1      -15629.3   441.6  -35.391 < 2e-16 ***
grS2      -15513.6   441.6  -35.129 < 2e-16 ***
grS3      -12933.0   441.6  -29.285 < 2e-16 ***
grS4      -2467.6    441.6  -5.588  1.81e-05 ***
grS5       14105.0   441.6   31.939 < 2e-16 ***
grS6       15960.4   441.6   36.140 < 2e-16 ***
grS7       22575.4   441.6   51.119 < 2e-16 ***
grS8       22070.4   441.6   49.976 < 2e-16 ***
grS9        3104.4   441.6    7.029  8.09e-07 ***
grS10      -4128.3   441.6   -9.348  9.71e-09 ***
grS11      -13099.9   538.4  -24.330  2.49e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 795.3 on 20 degrees of freedom
Multiple R-squared:  0.9993,    Adjusted R-squared:  0.9988 
F-statistic: 2074 on 14 and 20 DF,  p-value: < 2.2e-16

```

Vidíme, že všechny koeficienty jsou vysoce signifikantní, což znamená že se statisticky významně liší od nuly (testováno pomocí statistik  $t$ ).

Také  $p$ -hodnota u statistiky  $F$  naznačuje významnost modelu jako celku.

Jestliže pracujeme s regresním modelem, kde matice plánu nemá první sloupec tvořený jednotkami (ve výpisu chybí proměnná (**Intercept**)), koeficient determinace (**Multiple R-squared**), popř. upravený koeficient determinace (**Adjusted R-squared**) nemá interpretaci. Proto je lepsí takovému modelu se spíše vyhnout.

Chceme-li posoudit významnost faktorů **grY** a **grS** ne po složkách (jak to nabízí jednotlivé  $t$ -testy) ale jako celek, musíme použít  $F$ -testy, jejichž hodnotu získáme použitím funkce **anova()**.

```
> anova(M1)
```

### Analysis of Variance Table

```
Response: x
          Df     Sum Sq   Mean Sq F value    Pr(>F)
grY       3 1.1295e+10 3765109314  5952.4 < 2.2e-16 ***
grS      11 7.0702e+09 642748531   1016.1 < 2.2e-16 ***
Residuals 20 1.2651e+07   632534
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Výsledky F testů ukazují, že jak faktor roku (grY), tak faktor sezóny (grS) jsou statisticky významné.

Abychom dostali koeficienty

$$m_j \quad (j = 1, \dots, r) \quad \text{a} \quad s_k \quad (k = 1, \dots, d)$$

použijeme funkci `predict()` s volbou `type="terms"`. Protože neuvádíme parametr `newdata`, počítají se predikce z dat, která vstupovala do modelu. Matici `M1.terms` si podrobně prohlédneme.

```
> M1.terms <- predict(M1, type = "terms")
> str(M1.terms)
```

```
num [1:34, 1:2] 16730 16730 16730 16730 16730 ...
- attr(*, "dimnames")=List of 2
..$ : chr [1:34] "1" "2" "3" "4" ...
..$ : chr [1:2] "grY" "grS"
- attr(*, "constant")= num 0
```

Ukážeme, že fitované hodnoty jsou součtem dvou sloupců matice `M1.terms` označených grY a grS .

```
> pom <- cbind(M1.terms, M1.terms[, 1] + M1.terms[, 2], fitted(M1))
> colnames(pom) <- c(colnames(M1.terms), "grY+grS", "fitted(M1)")
> print(pom[1:6, ])
```

	grY	grS	grY+grS	fitted(M1)
1	16730.17	-15629.292	1100.875	1100.875
2	16730.17	-15513.625	1216.542	1216.542
3	16730.17	-12932.958	3797.208	3797.208
4	16730.17	-2467.625	14262.542	14262.542
5	16730.17	14105.042	30835.208	30835.208
6	16730.17	15960.375	32690.542	32690.542

Ze všech hodnot matice `M1.terms` vybereme právě ty, které se týkají koeficientů  $m_j$  a  $s_k$ .

```
> (M1.mj <- M1.terms[seq(1, n, d), 1])
```


```
1      13      25
16730.17 17462.58 17967.12
```

```
> (M1.sk <- M1.terms[1:d, 2])
```

1	2	3	4	5	6	7	8
-15629.292	-15513.625	-12932.958	-2467.625	14105.042	15960.375	22575.375	22070.375
9	10	11	12				
3104.375	-4128.292	-13099.875	-14043.875				

Sezónní kolísání graficky znázorníme.


```
> SK <- M1.sk
> nf <- layout(matrix(c(1, 2), nrow = 1), width = c(2.75, 1.25))
> txtS <- paste("S", 1:length(SK), " =", sep = "")
> par(mar = c(2, 2, 0, 0) + 0.05)
> plot(1:length(SK), SK, type = "o")
> plot(c(0, 1), c(0, length(SK)), type = "n", axes = FALSE)
> text(rep(0, length(SK)), rev(1:length(SK)), txtS, adj = c(0, 1), cex = 1.125)
> text(rep(1, length(SK)), rev(1:length(SK)), round(SK), adj = c(1, 1),
cex = 1.125)
```



Obrázek 2: Sezónní složky získané metodou malého trendu pro data *Počty návštěvníků v Punkevních jeskyních v Moravském Krasu v letech 1999–2001*

Výsledky celé dekompozice vykreslíme do jediného grafu.

```
> tt <- as.vector(time(xts))
> xx <- as.vector(xts)
> fit <- fitted(M1)
> tr <- rep(M1.mj, each = d, length.out = n)
> ylim <- range(range(xx), range(fit), tr)
> par(mfrow = c(1, 1), mar = c(2, 2, 2, 0) + 0.5)
> plot(tt, xx, type = "o", pch = 20, col = "black", ylim = ylim)
> lines(tt, fit, type = "o", pch = 22, col = "red", bg = "yellow", cex = 0.85)
> lines(tt, tr, type = "s", col = "dodgerblue", lwd = 2)
> abline(v = as.numeric(as.character(levels(data$grY))), col = "gray",
lty = 2)
> legend(par("usr")[1], par("usr")[4], bty = "n", legend = c("původní",
"odhad"), lty = c(1, 1), pch = c(20, 22), bg = c("black", "yellow"),
col = c("black", "red"))
```



Obrázek 3: Metoda malého trendu pro data Počty návštěvníků v Punkevních jeskyních v Moravském Krasu v letech 1999–2001

Pokusme se výchozí model  $M_I$  modifikovat tak, aby matice plánu měla v prvním sloupci samé jedničky.

Toho lze dosáhnout, budeme-li uvažovat následující model

$$M_I^{modif} : Y_{jk} = \mu + m_j + s_k + \varepsilon_{jk} \quad \varepsilon_{jk} \sim WN(0, \sigma^2), \quad j = 1, \dots, r, \quad k = 1, \dots, d$$

Přidáním nového parametru  $\mu$  (celkový průměr) dostaneme opět model s neúplnou hodnotou. Protože budeme chtít jediné řešení, přidáme dvě doplňující podmínky, a to

$$s_1 + \dots + s_d = 0 \quad \text{a} \quad m_1 + \dots + m_r = 0.$$

Regresní model dostaneme obdobným způsobem jako u modelu  $M_I$ , pouze změníme kontrasty pro kategoriální proměnnou grY a nevynecháme konstantní člen.

```
> M1m <- lm(x ~ grY + grS, data, contrasts = list(grY = contr.sum, grS = contr.sum))
> summary(M1m)
```

```
Call:
lm(formula = x ~ grY + grS, data = data, contrasts = list(grY = contr.sum,
grS = contr.sum))

Residuals:
    Min      1Q  Median      3Q     Max 
-1628.21 -252.20  -47.25  320.60 1280.83 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 17386.62     139.02 125.063 < 2e-16 ***
grY1        -656.46     192.09 -3.417  0.00273 ** 
grY2         75.96     192.09  0.395  0.69671    

```

```

grS1      -15629.29   441.62 -35.391 < 2e-16 ***
grS2      -15513.62   441.62 -35.129 < 2e-16 ***
grS3      -12932.96   441.62 -29.285 < 2e-16 ***
grS4      -2467.63    441.62 -5.588 1.81e-05 ***
grS5      14105.04    441.62 31.939 < 2e-16 ***
grS6      15960.38    441.62 36.140 < 2e-16 ***
grS7      22575.38    441.62 51.119 < 2e-16 ***
grS8      22070.38    441.62 49.976 < 2e-16 ***
grS9      3104.37     441.62 7.029 8.09e-07 ***
grS10     -4128.29    441.62 -9.348 9.71e-09 ***
grS11     -13099.88   538.43 -24.330 2.49e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

```

Residual standard error: 795.3 on 20 degrees of freedom
Multiple R-squared:  0.9982,        Adjusted R-squared:  0.9971
F-statistic: 871.2 on 13 and 20 DF,  p-value: < 2.2e-16

```

> `anova(M1m)`

#### Analysis of Variance Table

```

Response: x
          Df   Sum Sq  Mean Sq F value Pr(>F)
grY       2   93946520 46973260 74.262 5.542e-10 ***
grS      11  7070233840 642748531 1016.149 < 2.2e-16 ***
Residuals 20   12650673   632534
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

Z výpisu výsledků vidíme, že souhrnné charakteristiky (statistika F, koeficient determinace a upravený koeficient determinace) jsou úplně stejné. Tato situace však musela nastat, neboť jsme provedli pouze reparametrizaci.

Parametry  $m_1, \dots, m_r$  v tomto případě však mají jinou interpretaci. Nejsou roční hladinou, ale ukazují kolísání kolem průměrné hladiny dané parametrem (`Intercept`), který je odhadem parametru  $\mu$  v modelu  $M_I^{modif}$ .

Pro získání koeficientů

$$m_j \quad (j = 1, \dots, r) \quad \text{a} \quad s_k \quad (k = 1, \dots, d)$$

opět použijeme funkci `predict()` s volbou parametru `type="terms"` a bez volby `newdata`, takže se predikce počítají z dat, která vstupovala do modelu.

```

> M1m.terms <- predict(M1m, type = "terms")
> str(M1m.terms)

```

```

num [1:34, 1:2] -622 -622 -622 -622 -622 ...
- attr(*, "dimnames")=List of 2
..$ : chr [1:34] "1" "2" "3" "4" ...
..$ : chr [1:2] "grY" "grS"
- attr(*, "constant")= num 18151

```

Ukážeme, že tentokrát (protože model obsahuje (`Intercept`)) fitované hodnoty jsou součtem dvou sloupců matice `M1m.terms` označených `grY` a `grS` a konstanty, kterou získáme volbou `attr(M1m.terms, "constant")`.

```
> pom <- cbind(M1m.terms, M1m.terms[, 1] + M1m.terms[, 2] + attr(M1m.terms,
  "constant"), fitted(M1m))
> colnames(pom) <- c(colnames(M1m.terms), "grY+grS+constant", "fitted(M1m)")
> print(pom[1:6, ])
```

	grY	grS	grY+grS+constant	fitted(M1m)
1	-622.3113	-16427.637	1100.875	1100.875
2	-622.3113	-16311.971	1216.542	1216.542
3	-622.3113	-13731.304	3797.208	3797.208
4	-622.3113	-3265.971	14262.542	14262.542
5	-622.3113	13306.696	30835.208	30835.208
6	-622.3113	15162.029	32690.542	32690.542

Vybereme nyní příslušné koeficienty  $s_k = a - \mu + m_j$

```
> (M1m.sk <- M1m.terms[1:d, 2])
```


1	2	3	4	5	6	7	8
-16427.637	-16311.971	-13731.304	-3265.971	13306.696	15162.029	21777.029	21272.029
9	10	11	12				
2306.029	-4926.637	-13898.221	-14842.221				

```
> (M1m.mj <- attr(M1m.terms, "constant") + M1m.terms[seq(1, n, d), 1])
```

1	13	25
17528.51	18260.93	18765.47

Sezónní kolísání  $s_k$  vykresleme opět do grafu.


```
> SK <- M1m.sk
> nf <- layout(matrix(c(1, 2), nrow = 1), width = c(2.75, 1.25))
> txtS <- paste("S", 1:length(SK), " =", sep = "")
> par(mar = c(2, 2, 0, 0) + 0.05)
> plot(1:length(SK), SK, type = "o")
> plot(c(0, 1), c(0, length(SK)), type = "n", axes = FALSE)
> text(rep(0, length(SK)), rev(1:length(SK)), txtS, adj = c(0, 1), cex = 1.125)
> text(rep(1, length(SK)), rev(1:length(SK)), round(SK), adj = c(1, 1),
  cex = 1.125)
```



Obrázek 4: Sezónní složky získané modifikovanou metodou malého trendu pro data *Počty návštěvníků v Punkevních jeskyních v Moravském Krasu v letech 1999–2001*

Výsledky celé dekompozice vykreslíme do jediného grafu.

```
> fit <- fitted(M1m)
> tr <- rep(M1m.mj, each = d, length.out = n)
> ylim <- range(range(xx), range(fit), tr)
> par(mfrow = c(1, 1), mar = c(2, 2, 2, 0) + 0.5)
> plot(tt, xx, type = "o", pch = 20, col = "black", ylim = ylim)
> lines(tt, fit, type = "o", pch = 22, col = "red", bg = "yellow", cex = 0.85)
> lines(tt, tr, type = "s", col = "dodgerblue", lwd = 2)
> abline(v = as.numeric(as.character(levels(data$grY))), col = "gray",
  lty = 2)
> abline(h = attr(M1m.terms, "constant"), lty = 2, col = "gray35")
> legend(par("usr")[1], par("usr")[4], bty = "n", legend = c("puvodni",
  "odhadu"), lty = c(1, 1), pch = c(20, 22), bg = c("black", "yellow"),
  col = c("black", "red"))
```



Obrázek 5: Modifikovaná metoda malého trendu pro data *Počty návštěvníků v Punkevních jeskyních v Moravském Krasu v letech 1999–2001*

Přesvědčeme se na závěr, že obě dvě metody dávají úplně stejné odhady.

```
> cbind(fitted(M1), fitted(M1m))[1:6, ]
```

	[,1]	[,2]
1	1100.875	1100.875
2	1216.542	1216.542
3	3797.208	3797.208
4	14262.542	14262.542
5	30835.208	30835.208
6	32690.542	32690.542

Abychom mohli obě dvě metody použít i na jiná data, vytvoříme dvě nové funkce, nejdříve funkci `SzSmallTrend()` a následně `SzSmallTrendModif()`. Doplníme ještě jednu pomocnou funkci `FindPositionForLegend()`, která hledá nejvhodnější pozici pro uvedení legendy grafu.

```
> SzSmallTrend <- function(xts, figure = TRUE) {
  if (class(xts) != "ts")
    stop("xts must be a time series (ts)")
  d <- frequency(xts)
  n <- length(xts)
  m <- ceiling(n/d)
  shift <- start(xts)[2] - 1
  r <- m * d - n - shift
  Season <- factor(as.integer(gl(d, 1, n)) - shift)
  Year <- factor(floor(time(xts)))
  data <- data.frame(x = as.vector(xts), grS = Season, grY = Year)
  M11 <- lm(x ~ grY + grS - 1, data, contrasts = list(grY = diag(1,
    length(levels(data$grY))), grS = contr.sum))
  M11.terms <- predict(M11, type = "terms")
  M11.sk <- M11.terms[1:d, 2]
  M11.mj <- M11.terms[seq(1, n, d), 1]
  if (figure) {
    tt <- as.vector(time(xts))
    xx <- as.vector(xts)
    fit <- fitted(M11)
    tr <- rep(M11.mj, each = d, length.out = n)
    ylim <- range(range(xx), range(fit), tr)
    par(mfrow = c(1, 1), mar = c(2, 2, 2, 0) + 0.5)
    plot(tt, xx, type = "o", pch = 20, col = "black", ylim = ylim)
    lines(tt, fit, type = "o", pch = 22, col = "red", bg = "yellow",
      cex = 0.85)
    lines(tt, tr, type = "s", col = "dodgerblue", lwd = 2)
    abline(v = as.numeric(as.character(levels(data$grY))), col = "gray",
      lty = 2)
    legend(FindPositionForLegend(xx), bty = "n", legend = c("original",
      "estimate"), lty = c(1, 1), pch = c(20, 22), bg = c("black",
      "yellow"), col = c("black", "red")))
  }
  return(list(model = M11))
}
> SzSmallTrendModif <- function(xts, figure = TRUE) {
  if (class(xts) != "ts")
    stop("xts must be a time series (ts)")
  d <- frequency(xts)
  n <- length(xts)
```

```

m <- ceiling(n/d)
shift <- start(xts)[2] - 1
r <- m * d - n - shift
Season <- factor(as.integer(gl(d, 1, n)) - shift)
Year <- factor(floor(time(xts)))
data <- data.frame(x = as.vector(xts), grS = Season, grY = Year)
M1m <- lm(x ~ grY + grS, data, contrasts = list(grY = contr.sum,
                                                 grS = contr.sum))
M1m.terms <- predict(M1m, type = "terms")
M1m.sk <- M1m.terms[1:d, 2]
M1m.mj <- attr(M1m.terms, "constant") + M1m.terms[seq(1, n, d),
                                                 1]
if (figure) {
  tt <- as.vector(time(xts))
  xx <- as.vector(xts)
  fit <- fitted(M1m)
  tr <- rep(M1m.mj, each = d, length.out = n)
  ylim <- range(range(xx), range(fit), tr)
  par(mfrow = c(1, 1), mar = c(2, 2, 2, 0) + 0.5)
  plot(tt, xx, type = "o", pch = 20, col = "black", ylim = ylim)
  lines(tt, fit, type = "o", pch = 22, col = "red", bg = "yellow",
        cex = 0.85)
  lines(tt, tr, type = "s", col = "dodgerblue", lwd = 2)
  abline(v = as.numeric(as.character(levels(data$grY))), col = "gray",
          lty = 2)
  abline(h = attr(M1m.terms, "constant"), lty = 2, col = "gray")
  legend(FindPositionForLegend(xx), bty = "n", legend = c("original",
                                                          "estimate"),
         lty = c(1, 1), pch = c(20, 22), bg = c("black",
                                                   "yellow"), col = c("black", "red"))
}
return(list(model = M1m, mu = coef(M1m)[1], mj = M1m.mj, sk = M1m.sk))
}

> FindPositionForLegend <- function(x) {
  if (min(dim(as.matrix(x))) > 1)
    stop("x is not a vector")
  n <- length(x)
  m <- trunc(n/3)
  MaxT <- c(max(x[1:m]), max(x[(m + 1):(n - m)]), max(x[(n - m + 1):n]))
  MinB <- c(min(x[1:m]), min(x[(m + 1):(n - m)]), min(x[(n - m + 1):n]))
  indT <- which.min(MaxT)
  indB <- which.max(MinB)
  if (max(abs(diff(MaxT[c(1:3, 1)]))) > max(abs(diff(MinB[c(1:3, 1)]))))
    PositionLegend <- c("topleft", "top", "topright")[indT]
  else PositionLegend <- c("bottomleft", "bottom", "bottomright")[indB]
  return(PositionLegend)
}

```

## B. Model II: polynomický trend za celé období spolu se sezónností

Uvažujme regresní model ve tvaru  $Y_t = Tr_t + Sz_t + \varepsilon_t$ ,  $\varepsilon_t \sim WN(0, \sigma^2)$ .

Přeindexujme  $Y_1, \dots, Y_n$  na  $Y_{jk}$ ,  $j = 1, \dots, r$   $r \dots$  počet sezón  
 $\varepsilon_1, \dots, \varepsilon_n$   $\varepsilon_{jk}$ ,  $k = 1, \dots, d$   $d \dots$  délka sezóny.

Je-li trend polynomický za celé období  $Tr_t = \beta_0 + \beta_1 t + \dots + \beta_m t^m$

a  $k$ -tá sezónní složka je rovna  $Sz_k = s_k$ ,

pak regresní model můžeme napsat ve tvaru:

$$\boxed{MII} : Y_{jk} = \beta_0 + \beta_1 t + \dots + \beta_m t^m + s_k + \varepsilon_{jk}, \quad j = 1, \dots, r \quad k = 1, \dots, d \\ t = (j-1)d + k$$

Matice plánu je pak tvaru

$$\mathbf{X}^* = \left( \begin{array}{cccc|cccc} 1 & 1 & \dots & 1^m & 1 & 0 & 0 & \dots & 0 \\ 1 & 2 & \dots & 2^m & 0 & 1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & 0 & 0 & \ddots & \ddots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \ddots & 0 \\ 1 & d & \dots & d^m & 0 & 0 & \dots & 0 & 1 \\ \hline 1 & d+1 & \dots & (d+1)^m & 1 & 0 & 0 & \dots & 0 \\ 1 & d+2 & \dots & (d+2)^m & 0 & 1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & 0 & 0 & \ddots & \ddots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \ddots & 0 \\ 1 & 2d & \dots & (2d)^m & 0 & 0 & \dots & 0 & 1 \\ \hline \vdots & \vdots & \vdots & \vdots & 1 & 0 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & 0 & 1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & 0 & 0 & \ddots & \ddots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \ddots & 0 \\ \vdots & \vdots & \vdots & \vdots & 0 & 0 & \dots & 0 & 1 \\ \hline 1 & (r-1)d+1 & \dots & [(r-1)d+1]^m & 1 & 0 & 0 & \dots & 0 \\ 1 & (r-1)d+2 & \dots & [(r-1)d+2]^m & 0 & 1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & 0 & 0 & \ddots & \ddots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \ddots & 0 \\ 1 & rd & \dots & (rd)^m & 0 & 0 & \dots & 0 & 1 \end{array} \right)$$

Matice plánu však není plné hodnosti, neboť když sečteme posledních  $d$  sloupců, dostaneme vektor samých jedniček. Proto použijeme tvz. *metodu horního rohu* a položíme první sezónu rovnu nule

$$s_1 = 0.$$

Této reparametrizaci na matici plné hodnosti v prosředí R odpovídá implicitně nastavený kontrast `contr.treatment`.

Za těchto předpokladů lze model maticově napsat ve tvaru

$$\begin{array}{c}
 \left( \begin{array}{c} Y_{11} \\ \vdots \\ Y_{1d} \\ \hline Y_{21} \\ \vdots \\ \vdots \\ \hline Y_{2d} \\ \vdots \\ \hline Y_{r1} \\ \vdots \\ \hline Y_{rd} \end{array} \right) = \underbrace{\left( \begin{array}{cc|cc|cc} 1 & 1 & \cdots & 1^m & 0 & 0 & \cdots & 0 \\ 1 & 2 & \cdots & 2^m & 1 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots & 0 & \ddots & \ddots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \ddots & 0 \\ \hline 1 & d & \cdots & d^m & 0 & \cdots & 0 & 1 \\ 1 & d+1 & \cdots & (d+1)^m & 0 & 0 & \cdots & 0 \\ 1 & d+2 & \cdots & (d+2)^m & 1 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots & 0 & \ddots & \ddots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \ddots & 0 \\ \hline 1 & 2d & \cdots & (2d)^m & 0 & \cdots & 0 & 1 \\ \vdots & \vdots & \ddots & \vdots & 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & 1 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \ddots & 0 \\ \vdots & \vdots & \ddots & \vdots & 0 & \ddots & \ddots & 0 \\ \hline \vdots & \vdots & \ddots & \vdots & 0 & \cdots & 0 & 1 \\ \hline 1 & (r-1)d+1 & \cdots & [(r-1)d+1]^m & 0 & 0 & \cdots & 0 \\ 1 & (r-1)d+2 & \cdots & [(r-1)d+2]^m & 1 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots & 0 & \ddots & \ddots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \ddots & 0 \\ \hline 1 & rd & \cdots & (rd)^m & 0 & \cdots & 0 & 1 \end{array} \right)}_{\text{označme } \mathbf{X}_{MII} = \mathbf{X}} + \underbrace{\left( \begin{array}{c} \varepsilon_{11} \\ \vdots \\ \vdots \\ \hline \frac{\varepsilon_{1d}}{\varepsilon_{21}} \\ \vdots \\ \vdots \\ \hline \frac{\beta_0}{s_2} \\ \beta_1 \\ \vdots \\ \hline \frac{\beta_m}{s_2} \\ \vdots \\ s_d \\ \hline \text{ozn. } \boldsymbol{\beta} \\ \vdots \\ \hline \frac{\varepsilon_{2d}}{\varepsilon_{r1}} \\ \vdots \\ \vdots \\ \hline \varepsilon_{r1} \\ \vdots \\ \vdots \\ \hline \varepsilon_{rd} \end{array} \right)}_{\text{označme } \mathbf{Y}_{MII} = \mathbf{Y}}
 \end{array}$$

Odhad vektoru neznámých parametrů metodou nejmenších čtverců je dán vztahem

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

### PŘÍKLAD 2: Návštěvnost v hromadných ubytovacích zařízeních v ČR v letech 2000–2010

V datovém souboru `NavstevnostHromadUbytZar2000_2010Q.dat` jsou obsažena čtvrtletní data, která se týkají návštěvnosti v hromadných ubytovacích zařízeních v ČR v letech 2000–2010. Hromadným ubytovacím zařízením se rozumí zařízení s minimálně pěti pokoji nebo deseti lůžky.

Čtvrtletní data v jednotlivých sloupcích obsahují

1. sloupec – počet hostů
2. sloupec – počet přenocování

Datový soubor načteme pomocí příkazu `read.table()`. Vzhledem k tomu, že obsahuje v prvním řádku názvy proměnných, v příkazu `read.table` nesmíme zapomenout nastavit `header=TRUE`. Příkazem `str()` vypíšeme strukturu datového rámce.

```
> fileDat <- paste(data.library, "NavstevnostHromadUbytZar2000_2010Q.dat",
+ sep = "")  
> navstevnost <- read.table(fileDat, header = TRUE)
```


Vedle načteného datového rámce vytvoříme i vícerozměrnou časovou řadu, pomocí příkazu `str()` se podíváme na její strukturu.

```
> TS <- ts(navstevnost, start = 2000, frequency = 4)
> str(TS)
```

```
int [1:44, 1:2] 2082827 2915857 3903838 1961250 2089561 ...
- attr(*, "dimnames")=List of 2
..$ : NULL
..$ : chr [1:2] "pocet_hostu" "pocet_prenocovani"
- attr(*, "tsp")= num [1:3] 2000 2011 4
- attr(*, "class")= chr [1:2] "mts" "ts"
```

Časové řady vykreslíme pomocí příkazu `plot()`.

```
> plot(TS, type = "o", pch = 20, cex = 3)
```



Obrázek 6: Návštěvnost v hromadných ubytovacích zařízeních v ČR v letech 2000–2010

Uvažujme nejprve regresní model plné hodnosti (s  $m = 1$ )

$$\boxed{M_{II}}: Y_{jk} = \beta_0 + \beta_1 t + \cdots + \beta_m t^m + s_k + \varepsilon_{jk}, \quad j = 1, \dots, r \quad k = 2, \dots, d$$

$$t = (j-1)d+k$$

ve kterém se předpokládá, že  $s_1 = 0$ .

Ze dvou časových řad vybereme například první. Protože data nabývají hodnot v řádu miliónů, budeme je dále uvažovat v tisících. Z takto upravených hodnot vytvoříme nový datový rámec s kategoriálními proměnnými pro rok i sezónu, i když bychom v našem

případě vystačili s jedinou kategoriální proměnnou, a to sezónou. Ale bude praktické mít datový rámec nachystaný i pro využití metod malého trendu.

```
> xts <- TS[, 1]/1000
> d <- frequency(xts)
> n <- length(xts)
> m <- ceiling(n/d)
> shift <- start(xts)[2] - 1
> r <- m * d - n - shift
> Season <- factor(as.integer(gl(d, 1, n)) - shift)
> Year <- factor(floor(time(xts)))
> Time <- (1:n) - mean(1:n)
> Data <- data.frame(x = as.vector(xts), grS = Season, grY = Year, Time = Time)
> str(Data)

'data.frame':      44 obs. of  4 variables:
 $ x   : num  2083 2916 3904 1961 2090 ...
 $ grS : Factor w/ 4 levels "1","2","3","4": 1 2 3 4 1 2 3 4 1 2 ...
 $ grY : Factor w/ 11 levels "2000","2001",...: 1 1 1 1 2 2 2 2 3 3 ...
 $ Time: num  -21.5 -20.5 -19.5 -18.5 -17.5 -16.5 -15.5 -14.5 -13.5 -12.5 ...
```

V prostředí R použijeme pro odhad parametrů modelu  $M_{II}$  funkci `lm()`, ve které jsou pro kategoriální proměnné implicitně nastaveny kontrasty `contr.treatment`, takže je nemusíme uvádět.

```
> summary(MP1 <- lm(x ~ Time + grS, Data))

Call:
lm(formula = x ~ Time + grS, data = Data)

Residuals:
    Min      1Q  Median      3Q     Max 
-791.15  -91.76   25.92  101.63  365.18 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 2242.113    60.124  37.292 < 2e-16 ***
Time         11.668     2.372   4.918 1.62e-05 ***
grS2        893.463    84.912  10.522 5.93e-13 ***
grS3        1951.342   85.011  22.954 < 2e-16 ***
grS4        114.688    85.176   1.346   0.186  
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 199.1 on 39 degrees of freedom
Multiple R-squared:  0.9475,    Adjusted R-squared:  0.9421 
F-statistic: 175.8 on 4 and 39 DF,  p-value: < 2.2e-16
```

```
> anova(MP1)

Analysis of Variance Table

Response: x
          Df  Sum Sq Mean Sq F value    Pr(>F)    

```

```

Time      1 1154275 1154275 29.131 3.552e-06 ***
grS       3 26716293 8905431 224.748 < 2.2e-16 ***
Residuals 39 1545337   39624
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

K vykreslení časové řady po jednotlivých složkách je třeba je nejprve získat, což se děje příkazem `predict()`.

```

> MP1.terms <- predict(MP1, type = "terms")
> str(MP1.terms)

num [1:44, 1:2] -251 -239 -228 -216 -204 ...
- attr(*, "dimnames")=List of 2
..$ : chr [1:44] "1" "2" "3" "4" ...
..$ : chr [1:2] "Time" "grS"
- attr(*, "constant")= num 2982

```

Také tentokrát, protože model obsahuje (`Intercept`), fitované hodnoty jsou součtem dvou sloupců matice `MP1.terms` označených `Time` a `grS` a konstanty, kterou získáme volbou `attr(MP1.terms, "constant")`.

```

> pom <- cbind(MP1.terms, MP1.terms[, 1] + MP1.terms[, 2] + attr(MP1.terms,
  "constant"), fitted(MP1))
> colnames(pom) <- c(colnames(MP1.terms), "Time+grS+constant", "fitted(MP1)")
> print(pom[1:6, ])

```

	Time	grS	Time+grS+constant	fitted(MP1)
1	-250.8655	-739.8733	1991.248	1991.248
2	-239.1973	153.5897	2896.379	2896.379
3	-227.5291	1211.4689	3965.926	3965.926
4	-215.8610	-625.1852	2140.940	2140.940
5	-204.1928	-739.8733	2037.920	2037.920
6	-192.5247	153.5897	2943.051	2943.051

Sezónní složky  $s_k$  vykreslíme do grafu.


```

> (MP1.sk <- MP1.terms[1:d, 2])

      1         2         3         4
-739.8733  153.5897 1211.4689 -625.1852

> SK <- MP1.sk
> nf <- layout(matrix(c(1, 2), nrow = 1), width = c(2.75, 1.25))
> txtS <- paste("S", 1:length(SK), " =", sep = "")
> par(mar = c(2, 2, 0, 0) + 0.05)
> plot(1:length(SK), SK, type = "o")
> plot(c(0, 1), c(0, length(SK)), type = "n", axes = FALSE)
> text(rep(0, length(SK)), rev(1:length(SK)), txtS, adj = c(0, 1), cex = 1.125)
> text(rep(1, length(SK)), rev(1:length(SK)), round(SK), adj = c(1, 1),
  cex = 1.125)

```




Obrázek 7: Sezónní složky získané modelem  $M_{II}$  pro data Návštěvnost (v tisících) v hromadných ubytovacích zařízeních v ČR v letech 2000–2010 (počet hostů)

Do jediného grafu se budeme snažit zakreslit fitované hodnoty a trendovou komponentu modelu.

```

> tt <- as.vector(time(xts))
> xx <- as.vector(xts)
> fit <- fitted(MP1)
> tr <- attr(MP1.terms, "constant") + MP1.terms[, 1]
> ylim <- range(range(xx), range(fit), tr)
> par(mfrow = c(1, 1), mar = c(2, 2, 2, 0) + 0.5)
> plot(tt, xx, type = "o", pch = 20, col = "black", ylim = ylim)
> lines(tt, fit, type = "o", pch = 22, col = "red", bg = "yellow", cex = 0.85)
> lines(tt, tr, col = "dodgerblue", lwd = 2)
> abline(v = as.numeric(as.character(levels(Data$grY))), col = "gray",
  lty = 2)
> abline(h = attr(MP1.terms, "constant"), lty = 2, col = "gray35")
> legend(par("usr")[1], par("usr")[4], bty = "n", legend = c("original",
  "estimate"), lty = c(1, 1), pch = c(20, 22), bg = c("black", "yellow"),
  col = c("black", "red"))

```



Obrázek 8: Dekompozice pomocí modelu  $M_{II}$  pro data Návštěvnost (v tisících) v hromadných ubytovacích zařízeních v ČR v letech 2000–2010 (počet hostů)

Mnohem vhodnějším modelem vzhledem k interpretaci sezónních složek bude jistě model, ve kterém dodatečnou podmítku  $s_1 = 0$  nahradíme součtovou podmítku

$$s_1 + \cdots + s_d = 0$$

a budeme uvažovat modifikovaný model ve tvaru (s  $m = 1$ )

$$\boxed{M_{II}^{modif}} : Y_{jk} = \beta_0 + \beta_1 t + \cdots + \beta_m t^m + s_k + \varepsilon_{jk}, \quad j = 1, \dots, r \quad k = 1, \dots, d-1 \\ t = (j-1)d+k$$

V prostředí R použijeme pro odhad parametrů tohoto modelu funkci `lm()`, ve které vhodně nastavíme kontrasty.

```
> Time <- (1:n) - mean(1:n)
> summary(MP1m <- lm(x ~ Time + grS, Data, contrasts = list(grS = contr.sum)))
```

Call:

```
lm(formula = x ~ Time + grS, data = Data, contrasts = list(grS = contr.sum))
```

Residuals:

Min	1Q	Median	3Q	Max
-791.15	-91.76	25.92	101.63	365.18

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	2981.986	30.009	99.369	< 2e-16 ***
Time	11.668	2.372	4.918	1.62e-05 ***
grS1	-739.873	52.099	-14.201	< 2e-16 ***
grS2	153.590	51.991	2.954	0.00529 **
grS3	1211.469	51.991	23.302	< 2e-16 ***

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

```
Residual standard error: 199.1 on 39 degrees of freedom
Multiple R-squared: 0.9475, Adjusted R-squared: 0.9421
F-statistic: 175.8 on 4 and 39 DF, p-value: < 2.2e-16
```

```
> anova(MP1m)
```

Analysis of Variance Table

```
Response: x
          Df  Sum Sq Mean Sq F value    Pr(>F)
Time       1 1154275 1154275  29.131 3.552e-06 ***
grS        3 26716293 8905431 224.748 < 2.2e-16 ***
Residuals 39 1545337   39624
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Opět, abychom byli schopni vykreslit dekompozici časové řady po jednotlivých složkách, použijeme příkaz `predict()` k jejich získání.

```
> MP1m.terms <- predict(MP1m, type = "terms")
> str(MP1m.terms)
```

```

num [1:44, 1:2] -251 -239 -228 -216 -204 ...
- attr(*, "dimnames")=List of 2
..$ : chr [1:44] "1" "2" "3" "4" ...
..$ : chr [1:2] "Time" "grS"
- attr(*, "constant")= num 2982

```

Také tentokrát, protože model obsahuje (**Intercept**), fitované hodnoty jsou součtem dvou sloupců matice **MP1m.terms** označených Time a grS a konstanty, kterou získáme volbou `attr(MP1m.terms, "constant")`.

```

> pom <- cbind(MP1m.terms, MP1m.terms[, 1] + MP1m.terms[, 2] + attr(MP1m.terms,
  "constant"), fitted(MP1m))
> colnames(pom) <- c(colnames(MP1m.terms), "Time+grS+constant", "fitted(MP1m)")
> print(pom[1:6, ])

```

	Time	grS	Time+grS+constant	fitted(MP1m)
1	-250.8655	-739.8733	1991.248	1991.248
2	-239.1973	153.5897	2896.379	2896.379
3	-227.5291	1211.4689	3965.926	3965.926
4	-215.8610	-625.1852	2140.940	2140.940
5	-204.1928	-739.8733	2037.920	2037.920
6	-192.5247	153.5897	2943.051	2943.051

Sezónní kolísání  $s_k$  vykresleme opět do grafu.

```
> (MP1m.sk <- MP1m.terms[1:d, 2])
```

```


 1      2      3      4
-739.8733 153.5897 1211.4689 -625.1852

```

```

> SK <- MP1m.sk
> nf <- layout(matrix(c(1, 2), nrow = 1), width = c(2.75, 1.25))
> txtS <- paste("S", 1:length(SK), " =", sep = "")
> par(mar = c(2, 2, 0, 0) + 0.05)
> plot(1:length(SK), SK, type = "o")
> plot(c(0, 1), c(0, length(SK)), type = "n", axes = FALSE)
> text(rep(0, length(SK)), rev(1:length(SK)), txtS, adj = c(0, 1), cex = 1.125)
> text(rep(1, length(SK)), rev(1:length(SK)), round(SK), adj = c(1, 1),
  cex = 1.125)

```




Obrázek 9: Sezónní složky získané modelem  $M_{II}^{modif}$  pro data *Návštěvnost (v tisících)* v hromadných ubytovacích zařízeních v ČR v letech 2000–2010 (počet hostů)

Do jediného grafu se zakreslíme fitované hodnoty a trendovou komponentu modelu.

```

> tt <- as.vector(time(xts))
> xx <- as.vector(xts)
> fit <- fitted(MP1m)
> tr <- attr(MP1m.terms, "constant") + MP1m.terms[, 1]
> ylim <- range(range(xx), range(fit), tr)
> par(mfrow = c(1, 1), mar = c(2, 2, 2, 0) + 0.5)
> plot(tt, xx, type = "o", pch = 20, col = "black", ylim = ylim)
> lines(tt, fit, type = "o", pch = 22, col = "red", bg = "yellow", cex = 0.85)
> lines(tt, tr, col = "dodgerblue", lwd = 2)
> abline(v = as.numeric(as.character(levels(Data$grY))), col = "gray",
  lty = 2)
> abline(h = attr(MP1m.terms, "constant"), lty = 2, col = "gray35")
> legend(par("usr")[1], par("usr")[4], bty = "n", legend = c("original",
  "estimate"), lty = c(1, 1), pch = c(20, 22), bg = c("black", "yellow"),
  col = c("black", "red"))

```



Obrázek 10: Dekompozice pomocí modelu  $M_{II}^{modif}$  pro data Návštěvnost (v tisících) v hromadných ubytovacích zařízeních v ČR v letech 2000–2010 (počet hostů)

Nyní ještě vytvoříme funkci `SzPolTrend()`, která pro zadaný stupeň polynomu provede dekompozici časové řady podle modelu  $M_{II}^{modif}$ .

```

> SzPolTrend <- function(xts, Dgr = 1, figure = TRUE) {
  if (class(xts) != "ts")
    stop("xts must be a time series (ts)")
  nn <- 300
  d <- frequency(xts)
  n <- length(xts)
  m <- ceiling(n/d)
  shift <- start(xts)[2] - 1
  r <- m * d - n - shift
  grS <- factor(as.integer(gl(d, 1, n)) - shift)
  grY <- factor(floor(time(xts)))
  Time <- (1:n) - mean(1:n)
  Data <- data.frame(x = as.vector(xts), grS = grS, Time = Time)

```

```

T.terms <- "Time"
if (Dgr > 1)
  T.terms <- c(T.terms, paste("I(Time^", 2:Dgr, ")"), sep = ""))
strF <- paste("x~", paste(T.terms, collapse = "+"), "+grS", sep = "")
pomf <- as.formula(strF)
M <- lm(pomf, Data, contrasts = list(grS = contr.sum))
m.terms.grS <- predict(M, type = "terms", terms = "grS")
m.sk <- m.terms.grS[1:d]
if (figure) {
  tt <- as.vector(time(xts))
  xx <- as.vector(xts)
  TTime <- Time
  TT <- tt
  if (n < nn) {
    TTime <- seq(Time[1], Time[n], length.out = nn)
    TT <- seq(tt[1], tt[n], length.out = nn)
  }
  newdata <- data.frame(Time = TTime, grS = rep(grs[1:d], length = length(TTime)))
  m.terms.Time <- predict(M, newdata = newdata, type = "terms",
                           terms = T.terms)
  Constant <- attr(m.terms.Time, "constant")
  tr <- Constant + apply(m.terms.Time, 1, sum)
  fit <- fitted(M)
  ylim <- range(range(xx), range(fit), tr)
  plot(tt, xx, type = "o", pch = 20, col = "black", ylim = ylim)
  lines(tt, fit, type = "o", pch = 22, col = "red", bg = "yellow",
        cex = 0.85)
  lines(TT, tr, col = "dodgerblue", lwd = 2)
  abline(v = as.numeric(as.character(levels(Data$grY))), col = "gray",
          lty = 2)
  abline(h = Constant, lty = 2, col = "gray35")
  legend(FindPositionForLegend(xx), bty = "n", legend = c("original",
              "estimate"), lty = c(1, 1), pch = c(20, 22), bg = c("black",
              "yellow"), col = c("black", "red"))
}
return(list(model = M, sk = m.sk))
}

```


Funkci vyzkoušíme u časové řady uložené v proměnné `xts`, a to pro různé stupně polynomu (například 3, 5, 7, 9).

Výsledky necháme vykreslit do grafu. Kromě toho do každého grafu doplníme odhady sezónních složek, abychom mohli posoudit, jak velký vliv má volba stupně polynomu na odhadu sezónních složek.

```

> par(mfrow = c(2, 2), mar = c(2, 2, 2, 0) + 0.5)
> for (dgr in c(3, 5, 7, 9)) {
  vysl <- SzPolTrend(xts, Dgr = dgr)
  txtS <- paste(paste("S", 1:length(vysl$sk), "=",
                      round(vysl$sk),
                      sep = ""), collapse = " ")
  txtDgr <- paste("degree of polynom =", dgr)
  mtext(txtDgr)
  mtext(txtS, side = 1, line = -1, cex = 0.85)
}

```



Obrázek 11: Dekompozice pomocí  $M_{II}^{modif}$  pro různé stupně polynomu pro data Návštěvnost (v tisících) v hromadných ubytovacích zařízeních v ČR v letech 2000–2010 (počet hostů)

### C. Funkce `decompose()` a `stl()` v prostředí R

Pro dekompozici časové řady jsou v prostředí R k dispozici dvě funkce `decompose()` a `stl()`.

- (a) Funkce `decompose()` – *Classical Seasonal Decomposition by Moving Averages*

```
> dec1 <- decompose(xts)
> str(dec1)


List of 5
$ seasonal: Time-Series [1:44] from 2000 to 2011: -748 153 1216 -621 -748 ...
$ trend    : Time-Series [1:44] from 2000 to 2011: NA NA 2717 2738 2766 ...
```

```
$ random  : Time-Series [1:44] from 2000 to 2011: NA NA -29 -155.8 70.6 ...
$ figure  : num [1:4] -748 153 1216 -621
$ type    : chr "additive"
- attr(*, "class")= chr "decomposed.ts"

> dec1$seasonal[1:d]

[1] -747.5080 152.6937 1216.0461 -621.2319

> plot(dec1)
```



Obrázek 12: Dekompozice pomocí funkce `decompose()` pro data *Návštěvnost (v tisících) v hromadných ubytovacích zařízeních v ČR v letech 2000–2010 (počet hostů)*

- (b) Funkce `stl()` – *Seasonal Decomposition of Time Series by Loess*

```
> dec2 <- stl(xts, "periodic")
> str(dec2)


List of 8
 $ time.series: mts [1:44, 1:3] -745 150 1213 -617 -745 ...
 ..- attr(*, "dimnames")=List of 2
 ... .$. : NULL
 ... .$ : chr [1:3] "seasonal" "trend" "remainder"
 ..- attr(*, "tsp")= num [1:3] 2000 2011 4
 ..- attr(*, "class")= chr [1:2] "mts" "ts"
 $ weights   : num [1:44] 1 1 1 1 1 1 1 1 1 ...
 $ call      : language stl(x = xts, s.window = "periodic")
 $ win       : Named num [1:3] 441 7 5
 ..- attr(*, "names")= chr [1:3] "s" "t" "l"
```

```
$ deg      : Named int [1:3] 0 1 1
..- attr(*, "names")= chr [1:3] "s" "t" "l"
$ jump     : Named num [1:3] 45 1 1
..- attr(*, "names")= chr [1:3] "s" "t" "l"
$ inner    : int 2
$ outer    : int 0
- attr(*, "class")= chr "stl"

> dec2$time.series[1:d, 1]

[1] -745.4963 150.1728 1212.5610 -617.2366

> plot(dec2)
```



Obrázek 13: Dekompozice pomocí funkce `stl()` pro data *Návštěvnost (v tisících) v hromadných ubytovacích zařízeních v ČR v letech 2000–2010 (počet hostů)*

## D. Úkoly:

- (a) Na právě načtenou časovou řadu vyzkoušejte s využitím funkcí `SzSmallTrend()` a `SzSmallTrendModif()` obě dvě metody malého trendu.
- (b) Totéž vyzkoušejte na vhodné sezónní časové řadě, kterou si sami najdete.
- (c) Na vaši časové řadě také odhadněte model  $M_{II}^{modif}$  pomocí funkce `SzPolTrend()`.
- (d) Prostudujte a aplikujte funkce `decompose()` a `stl()` na vaši sezónní časovou řadu.