

M0130 – 4. PRAKTIKUM : M0130pr04 (*Klasická regrese*)

## A. Lineární trend, polynomický trend

PŘÍKLAD 1

Máme k dispozici průměrné roční průtoky vody v řece Nigeru v Coulicouro (Mali). Údaje se vztahují k období 1907 až 1957 a jsou uvedena v  $\text{cfs} \cdot 10^{-3}$ .

Data jsou uložena v souboru `DataNiger.dat`. První řádek obsahuje popis časové řady, pak následuje volný řádek, teprve potom dva sloupce dat: rok a průměrný roční průtok.

Nejprve načteme nadpis.

```
> fileN <- "DataNiger.dat"
> fileDat <- paste(data.library, fileN, sep = "")
> (TXT <- paste(scan(fileDat, what = "", nlines = 1), collapse = " "))
```

```
[1] "Prumerne rocni prutoky vody v rece Nigeru v Coulicoure (Mali) v letech 1907 az 1957"
```

Pak načteme vlastní data do datového rámce, vypíšeme jeho strukturu a prvních šest řádků.

```
> dataNiger <- read.table(fileDat, header = F, skip = 2)
> str(dataNiger)


'data.frame':      51 obs. of  2 variables:
 $ V1: int  1907 1908 1909 1910 1911 1912 1913 1914 1915 1916 ...
 $ V2: num  39.8 42.9 69.1 43.7 56.7 ...
```

```
> head(dataNiger)
```

```
      V1      V2
1 1907 39.793
2 1908 42.892
3 1909 69.070
4 1910 43.653
5 1911 56.700
6 1912 45.990
```

Z načtených dat vytvoříme časovou řadu a vykreslíme ji.

```
> NigerTS <- ts(dataNiger[, 2], start = 1907, frequency = 1)
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(NigerTS, main = TXT, cex.main = 0.85)
```



Obrázek 1: Průměrné roční průtoky vody v řece Nigeru v Coulicoure (Mali).

Odhad **lineárního trendu** provedeme pomocí příkazu `lm()`. Pomocí příkazů `summary()` a `anova()` získáme důležité údaje o odhadech neznámých parametrů a o celém modelu.

```
> Time <- time(NigerTS)
> fitModel <- lm(NigerTS ~ Time)
> summary(fitModel)
```

Call:

```
lm(formula = NigerTS ~ Time)
```

Residuals:

Min	1Q	Median	3Q	Max
-21.667	-9.092	-2.412	7.895	30.325

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	-351.6125	239.0573	-1.471	0.1477
Time	0.2101	0.1237	1.698	0.0959

---

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

Residual standard error: 13.01 on 49 degrees of freedom

Multiple R-squared: 0.05556, Adjusted R-squared: 0.03629

F-statistic: 2.883 on 1 and 49 DF, p-value: 0.09587

```
> anova(fitModel)
```

Analysis of Variance Table

Response: NigerTS

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
Time	1	487.7	487.68	2.8828	0.09587
Residuals	49	8289.4	169.17		

---

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

Hodnota  $p$ -value označená jako  $\Pr(>|t|)$  ukazuje, že lineární trend není významný.


Dalším krokem bude zakreslení regresní přímky, intervalů spolehlivosti kolem regresní přímky a hodnot odhadů parametrů do grafu.

```
> gridt <- seq(start(NigerTS)[1], end(NigerTS)[1], length.out = 500)
> Pred <- predict(fitModel, data.frame(Time = gridt), se = T)
> str(Pred)
```

List of 4

```
$ fit          : Named num [1:500] 49 49 49.1 49.1 49.1 ...
..- attr(*, "names")= chr [1:500] "1" "2" "3" "4" ...
$ se.fit       : Named num [1:500] 3.59 3.58 3.57 3.56 3.55 ...
..- attr(*, "names")= chr [1:500] "1" "2" "3" "4" ...
$ df           : int 49
$ residual.scale: num 13
```

```
> alpha <- 0.05
> CV <- qt(1 - alpha/2, Pred$df)
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(NigerTS, main = TXT, cex.main = 0.85)
> koefText <- paste("a =", round(coef(fitModel)[1], 3), ", b =",
  round(coef(fitModel)[2], 3))
> mtext(koefText, side = 1, line = -1)
> matlines(gridt, cbind(Pred$fit, Pred$fit - CV * Pred$se.fit,
  Pred$fit + CV * Pred$se.fit), lty = c(1, 2, 2), col = c("red",
  "gray35", "gray35"))
```



Obrázek 2: Lineární trend pro průměrné roční průtoky vody v řece Nigeru v Coulicoure (Mali).

Chceme-li modelovat i cyklický charakter časové řady, použijeme nejprve polynomický trend třetího řádu.

```
> Time <- time(NigerTS)
> fitModel3 <- lm(NigerTS ~ Time + I(Time^2) + I(Time^3))
> summary(fitModel3)
```

```

Call:
lm(formula = NigerTS ~ Time + I(Time^2) + I(Time^3))

Residuals:
    Min       1Q   Median       3Q      Max
-22.2179  -7.0170  -0.9496   7.6885  27.1292

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -1.483e+07  4.903e+06  -3.024  0.00403 **
Time         2.302e+04  7.614e+03   3.023  0.00404 **
I(Time^2)   -1.191e+01  3.941e+00  -3.022  0.00405 **
I(Time^3)    2.055e-03  6.800e-04   3.022  0.00406 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 12.14 on 47 degrees of freedom
Multiple R-squared:  0.2108,    Adjusted R-squared:  0.1604
F-statistic: 4.183 on 3 and 47 DF,  p-value: 0.01050

```

```
> anova(fitModel3)
```

Analysis of Variance Table

```

Response: NigerTS
      Df Sum Sq Mean Sq F value Pr(>F)
Time    1  487.7   487.68   3.3088 0.07528 .
I(Time^2) 1   16.4    16.37   0.1111 0.74038
I(Time^3) 1 1345.7  1345.72   9.1304 0.00406 **
Residuals 47 6927.3  147.39
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

Oba dva lineární modely srovnáme pomocí příkazu `anova()`.

```
> anova(fitModel3, fitModel)
```

Analysis of Variance Table

```

Model 1: NigerTS ~ Time + I(Time^2) + I(Time^3)
Model 2: NigerTS ~ Time
  Res.Df  RSS Df Sum of Sq    F Pr(>F)
1     47 6927.3
2     49 8289.4 -2   -1362.1 4.6207 0.01472 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1


```

Protože p-hodnota srovnávacího testu  $\text{Pr}(>F)$  je menší než 0.05, model s polynomem třetího řádu je významně lepší. Výsledky modelu s polynomem řádu tři opět zakreslíme do grafu.

```

> Pred3 <- predict(fitModel3, data.frame(Time = gridt), se = T)
> alpha <- 0.05
> CV <- qt(1 - alpha/2, Pred3$df)
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(NigerTS, main = TXT, cex.main = 0.85)
> matlines(gridt, cbind(Pred3$fit, Pred3$fit - CV * Pred3$se.fit,
  Pred3$fit + CV * Pred3$se.fit), lty = c(1, 2, 2), col = c("red",
  "gray35", "gray35"))

```



Obrázek 3: Polynomický trend třetího řádu pro průměrné roční průtoky vody v řece Nigeru v Coulicoure (Mali).

Protože odhad parametru u polynomu třetího řádu je statisticky významný, budeme uvažovat model vyššího řádu, řekněme 6. řádu.

```

> fitModel6 <- lm(NigerTS ~ Time + I(Time^2) + I(Time^3) + I(Time^4) +
  I(Time^5) + I(Time^6))
> summary(fitModel6)

```

Call:

```
lm(formula = NigerTS ~ Time + I(Time^2) + I(Time^3) + I(Time^4) +
  I(Time^5) + I(Time^6))
```

Residuals:

Min	1Q	Median	3Q	Max
-22.2179	-7.0170	-0.9496	7.6885	27.1292

Coefficients: (3 not defined because of singularities)

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	-1.483e+07	4.903e+06	-3.024	0.00403 **
Time	2.302e+04	7.614e+03	3.023	0.00404 **
I(Time^2)	-1.191e+01	3.941e+00	-3.022	0.00405 **
I(Time^3)	2.055e-03	6.800e-04	3.022	0.00406 **
I(Time^4)	NA	NA	NA	NA
I(Time^5)	NA	NA	NA	NA
I(Time^6)	NA	NA	NA	NA

---

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

```
Residual standard error: 12.14 on 47 degrees of freedom
Multiple R-squared: 0.2108, Adjusted R-squared: 0.1604
F-statistic: 4.183 on 3 and 47 DF, p-value: 0.01050
```

Vidíme, že s polynomem tak vysokého stupně jsou spojeny numerické problémy. Proto provedeme centrování času a výpočet provedeme znovu.

```
> delta <- 0.5 * (start(NigerTS)[1] + end(NigerTS)[1])
> TimeC <- Time - delta
> fitModel6 <- lm(NigerTS ~ TimeC + I(TimeC^2) + I(TimeC^3) + I(TimeC^4) +
  I(TimeC^5) + I(TimeC^6))
> summary(fitModel6)
```

Call:

```
lm(formula = NigerTS ~ TimeC + I(TimeC^2) + I(TimeC^3) + I(TimeC^4) +
  I(TimeC^5) + I(TimeC^6))
```

Residuals:

Min	1Q	Median	3Q	Max
-19.3877	-5.4541	-0.9673	5.1213	21.0478

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	6.469e+01	2.872e+00	22.523	< 2e-16 ***
TimeC	-1.757e+00	3.909e-01	-4.494	5.02e-05 ***
I(TimeC^2)	-2.385e-01	5.367e-02	-4.444	5.90e-05 ***
I(TimeC^3)	1.045e-02	2.371e-03	4.408	6.63e-05 ***
I(TimeC^4)	8.809e-04	2.268e-04	3.884	0.000341 ***
I(TimeC^5)	-1.165e-05	3.209e-06	-3.631	0.000733 ***
I(TimeC^6)	-8.461e-07	2.526e-07	-3.350	0.001666 **

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

```
Residual standard error: 9.36 on 44 degrees of freedom
Multiple R-squared: 0.5608, Adjusted R-squared: 0.5009
F-statistic: 9.364 on 6 and 44 DF, p-value: 1.278e-06
```

```
> anova(fitModel6)
```

Analysis of Variance Table

Response: NigerTS

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
TimeC	1	487.7	487.68	5.5664	0.0228113 *
I(TimeC^2)	1	16.4	16.37	0.1869	0.6676180
I(TimeC^3)	1	1345.7	1345.72	15.3601	0.0003066 ***
I(TimeC^4)	1	934.1	934.08	10.6616	0.0021221 **
I(TimeC^5)	1	1155.0	1155.02	13.1834	0.0007329 ***
I(TimeC^6)	1	983.3	983.29	11.2233	0.0016656 **
Residuals	44	3854.9	87.61		

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

Oba dva lineární modely srovnáme pomocí příkazu `anova()`.

```
> anova(fitModel6, fitModel3)
```

Analysis of Variance Table

```
Model 1: NigerTS ~ TimeC + I(TimeC^2) + I(TimeC^3) + I(TimeC^4) + I(TimeC^5) +
  I(TimeC^6)
```

```
Model 2: NigerTS ~ Time + I(Time^2) + I(Time^3)
```

	Res.Df	RSS	Df	Sum of Sq	F	Pr(>F)
1	44	3854.9				
2	47	6927.3	-3	-3072.4	11.690	9.241e-06 ***


```
---
```

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

Protože p-hodnota srovnávacího testu označená jako  $\text{Pr}(>F)$  je menší než 0.05, je model s polynomem šestého stupně významně lepší než model s polynomem třetího řádu.

Výsledky opět zakreslíme do grafu.

```
> gridtC <- gridt - delta
> Pred6 <- predict(fitModel6, data.frame(TimeC = gridtC), se = T)
> alpha <- 0.05
> CV <- qt(1 - alpha/2, Pred6$df)
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(NigerTS, main = TXT, cex.main = 0.85)
> matlines(gridt, cbind(Pred6$fit, Pred6$fit - CV * Pred6$se.fit,
  Pred6$fit + CV * Pred6$se.fit), lty = c(1, 2, 2), col = c("red",
  "gray35", "gray35"))
```



Obrázek 4: Polynomický trend šestého řádu pro průměrné roční průtoky vody v řece Nigeru v Coulicouro (Mali).

## B. Odhady počtu regresních koeficientů:

Mějme **regresní model** plné hodnosti (např. polynomický regresní model):

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad \wedge \quad h(\mathbf{X}) = h(\mathbf{X}'\mathbf{X}) = p + 1 \quad \wedge \quad n > k = p + 1 \quad \wedge \quad \boldsymbol{\varepsilon} \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I}_n)$$

Odhad neznámých parametrů  $\boldsymbol{\beta}$  provedeme *metodou nejmenších čtverců*:

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

Pro odhad počtu regresních koeficientů se nabízejí dvě intuitivní metody

- **Od nejmenšího k nejvyššímu počtu regresorů:**

Začneme od  $k = 1$  a postupně zvyšujeme počet regresorů o jeden a testujeme hypotézu

$$\boxed{H_0 : \beta_k = 0 \text{ proti } H_1 : \beta_k \neq 0} \quad \text{pomocí statistiky} \quad T_k = \frac{\hat{\beta}_k - \beta_k}{\sqrt{s_k^2 v_{kk}}} \sim t(n - k),$$

kde  $(\mathbf{X}'\mathbf{X})^{-1} = (v_{ij})_{i,j=1,\dots,k}$  (viz. Anděl, 1993).

Jestliže  $H_0$  **zamítneme**  $\Rightarrow$  **zvyšujeme** počet regresorů.

- **Od maximálního počtu regresorů dolů:**

Nejprve zvolme  $k = k_{max}$ . Testujeme opět  $\boxed{H_0 : \beta_k = 0 \text{ proti } H_1 : \beta_k \neq 0}$  pomocí statistiky  $T_k$ .

Jestliže  $H_0$  **nezamítneme**  $\Rightarrow$  **snižujeme** počet regresorů.

I když těmto metodám byla věnována velká pozornost a byly propracovány do podrobností (viz. Anderson, 1971), žádných uspokojivých výsledků se pomocí nich nedosáhlo. Vyložme jiný přístup k tomuto problému, který byl nalezen poměrně nedávno.

### PENALIZAČNÍ METODA ODHADU POČTU REGRESNÍCH KOEFICIENTŮ

Předpokládejme, že  $\boxed{k_0}$  je skutečný počet regresních parametrů.

Lze ukázat, že platí  $\begin{matrix} \text{pro } k < k_0: & E(s_k^2) > \sigma^2 \\ \text{pro } k \geq k_0: & E(s_k^2) = \sigma^2. \end{matrix}$

Otázkou však zůstává, jak z grafu hodnot  $\boxed{s_k^2}$  určit právě tu hodnotu  $k_0$ , od níž počínaje již graf dostává vodorovný charakter.

Ukázalo se, že místo  $s_k^2$  je třeba uvažovat  $\boxed{A_k = s_k^2(1 + kw_n)}$ , kde  $w_n$  je tzv. *penalizační funkce* a udává jakousi relativní cenu, kterou je třeba zaplatit za přidání každého dalšího parametru.

Hodnota  $w_n$ 

- nesmí být příliš velká - aby nezkreslila klesající charakter  $s_k^2$  pro  $k < k_0$ ;
- nesmí být příliš malá - aby z hodnot  $s_k^2$  oscilujících kolem  $\sigma^2$  vytvořila pro  $k \geq 0$  rostoucí posloupnost;

Za odhad  $\hat{k}$  se bere hodnota  $k \in \{0, 1, \dots, k_{max}\}$ , pro kterou  $A_k$  **nabývá svého minima**, kde  $k_{max}$  je maximální počet parametrů, které jsme ochotni uvažovat a o němž jsme si jisti, že  $k_0 \leq k_{max}$ .

Za dosti obecných podmínek týkajících se rozumné volby hodnot  $x_{ij}$  lze ukázat (Geweke a Meese(1981), Anděl a kol.(1981)):

pro  $n \rightarrow \infty$  pokud  $w_n > 0 \wedge w_n \rightarrow 0 \wedge nw_n \rightarrow \infty \Rightarrow$

$$\hat{k} \rightarrow k_0 \quad \text{podle pravděpodobnosti.}$$

V praxi se osvědčilo volit  $w_n = \frac{1}{\sqrt[4]{n}}$ , tj.  $A_k = s_k^2(1 + \frac{k}{\sqrt[4]{n}})$ .

## DALŠÍ KRITÉRIA PRO URČENÍ POČTU REGRESNÍCH KOEFICIENTŮ

AKAIKEOVO informační kritérium	$AIC_k = \ln s_k^2 + \frac{2k}{n}$	nadhodnocuje $k_0$
SWARZ (1978) a RISSANEN (1978)	$SR_k = \ln s_k^2 + \frac{k \ln n}{n}$	
HANNAN a QUINN (1979)	$HQ_k = \ln s_k^2 + \frac{2kc \ln \ln n}{n}$	$c > 1$ , obvykle $c = 2$ nebo $3$

PŘÍKLAD 1 (POKRAČOVÁNÍ)

Nejprve vytvoříme funkci, která vypočítá jednotlivá kritéria a výsledky vynese do grafu.

```
> fndptr <- function(y, x = (1:length(y)) - 0.5 * (1 + length(y)),
  alpha = 0.05, maxdgr = 10, mindgr = 1) {
  x <- x - mean(x)
  vh <- NULL
  vsk <- NULL
  vak <- NULL
  vaick <- NULL
  vsrk <- NULL
  vhqk2 <- NULL
  vhqk3 <- NULL
  ny <- length(y)
  maxdgr <- min(maxdgr, ny - 2)
  mindgr <- max(mindgr, 1)
  for (k in mindgr:maxdgr) {
    if (k == 1)
      pomf <- as.formula("y~x")
    else pomf <- as.formula(paste("y~x", paste("+I(x^", 2:k,
      ")", sep = "", collapse = ""), sep = ""))
    m <- lm(pomf)
    CI <- confint(m)[k + 1, ]
    if ((0 >= CI[1]) & (0 <= CI[2]))
```

```

      hyp <- 0
    else hyp <- 1
    sk1 <- sum(m$residuals^2)/(ny - k - 1)
    vh <- c(vh, hyp)
    vsk <- c(vsk, sk1)
    vak <- c(vak, sk1 * (1 + k * (ny^(-0.25))))
    vaick <- c(vaick, log(sk1) + (2 * k/ny))
    vsrk <- c(vsrk, log(sk1) + k * log(ny)/ny)
    vhwk2 <- c(vhwk2, log(sk1) + 4 * k * log(log(ny))/ny)
    vhwk3 <- c(vhwk3, log(sk1) + 6 * k * log(log(ny))/ny)
  }
  vd <- mindgr:maxdgr
  L = vh > 0
  vysl <- data.frame(vd, vh, vsk, vak, vaick, vsrk, vhwk2,
                    vhwk3)
  names(vysl) <- c("dgr", "significant", "S_k", "A_k", "AIC_k",
                  "SR_k", "HQ_k(c=2)", "HQ_k(c=3)")
  TXT <- c("S_k (Mean Square Error)", "A_k", "AIC_k", "SR_k",
           "HQ_k(c=2)", "HQ_k(c=3)")
  par(mfrow = c(2, 3), mar = c(2, 2, 1, 0) + 0.5)
  for (kk in 1:6) {
    plot(vysl[, 1], vysl[, kk + 2], type = "o", main = TXT[kk],
         xlab = "k", ylab = "")
    if (kk == 1)
      text(vysl[L, 1], vysl[L, kk + 2], labels = vysl[L,
                                                       1], pos = 3)
    ind <- which.min(vysl[, kk + 2])
    abline(v = vysl[ind, 1], lty = 2, col = "red")
    points(vysl[ind, 1], vysl[ind, kk + 2], pch = 19, cex = 1.25)
    mtext(paste("opt =", vysl[ind, 1]), cex = 0.85, line = -1)
  }
  return(vysl)
}


```

Pro průměrné roční průtoky vody v řece Nigeru se budeme snažit pomocí funkce `fndptr` zjistit optimální počet regresorů, tj. optimální stupeň polynomu.

Implicitně funkce nastavuje minimální stupeň polynomu 1 a maximální stupeň polynomu 10.

```
> fndptr(NigerTS)
```

	dgr	significant	S_k	A_k	AIC_k	SR_k	HQ_k(c=2)	HQ_k(c=3)
1	1	0	169.17139	232.4759	5.170128	5.208007	5.238293	5.291983
2	2	0	172.35465	301.3460	5.227986	5.303743	5.364316	5.471696
3	3	1	147.38939	312.8501	5.110725	5.224362	5.315220	5.476291
4	4	1	130.28745	325.3034	5.026606	5.178122	5.299266	5.514027
5	5	1	107.51558	308.6789	4.873714	5.063109	5.214539	5.482991
6	6	1	87.61154	284.3186	4.708207	4.935480	5.117197	5.439339
7	7	1	78.92988	285.6805	4.643070	4.908222	5.120225	5.496057
8	8	0	80.77111	322.5695	4.705345	5.008376	5.250665	5.680188
9	9	0	81.85967	357.5490	4.757948	5.098858	5.371433	5.854646
10	10	0	83.57424	396.3117	4.817892	5.196681	5.499542	6.036446



Obrázek 5: Penalizační kritéria pro výběr vhodného stupně polynomu pro průměrné roční průtoky vody v řece Nigeru v Coulicouro (Mali).

Z výsledků je zřejmé, že bychom se měli rozhodnout mezi polynomem šestého či sedmého stupně.

Model s polynomem šestého stupně jsme již počítali, proto na závěr ještě vypočítáme model, ve kterém použijeme polynom stupně sedm.

```
> fitModel7 <- lm(NigerTS ~ TimeC + I(TimeC^2) + I(TimeC^3) + I(TimeC^4) +
+ I(TimeC^5) + I(TimeC^6) + I(TimeC^7))
> summary(fitModel7)
```

Call:

```
lm(formula = NigerTS ~ TimeC + I(TimeC^2) + I(TimeC^3) + I(TimeC^4) +
+ I(TimeC^5) + I(TimeC^6) + I(TimeC^7))
```

Residuals:

Min	1Q	Median	3Q	Max
-18.5824	-6.2406	-0.8423	6.3083	16.8680

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	6.469e+01	2.726e+00	23.730	< 2e-16 ***
TimeC	-2.765e+00	5.582e-01	-4.953	1.18e-05 ***
I(TimeC^2)	-2.385e-01	5.094e-02	-4.682	2.85e-05 ***
I(TimeC^3)	2.449e-02	6.231e-03	3.931	0.000303 ***
I(TimeC^4)	8.809e-04	2.152e-04	4.092	0.000184 ***
I(TimeC^5)	-5.944e-05	2.001e-05	-2.971	0.004848 **
I(TimeC^6)	-8.461e-07	2.397e-07	-3.530	0.001006 **

```
I(TimeC^7) 4.575e-08 1.893e-08 2.417 0.019986 *
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 8.884 on 43 degrees of freedom
Multiple R-squared: 0.6133, Adjusted R-squared: 0.5504
F-statistic: 9.743 on 7 and 43 DF, p-value: 3.327e-07
```

```
> anova(fitModel7)
```

```
Analysis of Variance Table
```

```
Response: NigerTS
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
TimeC	1	487.7	487.68	6.1787	0.0168955 *
I(TimeC^2)	1	16.4	16.37	0.2075	0.6510563
I(TimeC^3)	1	1345.7	1345.72	17.0496	0.0001644 ***
I(TimeC^4)	1	934.1	934.08	11.8343	0.0013049 **
I(TimeC^5)	1	1155.0	1155.02	14.6335	0.0004174 ***
I(TimeC^6)	1	983.3	983.29	12.4578	0.0010061 **
I(TimeC^7)	1	460.9	460.92	5.8397	0.0199862 *
Residuals	43	3394.0	78.93		

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

Oba dva lineární modely srovnáme pomocí příkazu `anova()`.

```
> anova(fitModel7, fitModel6)
```

```
Analysis of Variance Table
```

```
Model 1: NigerTS ~ TimeC + I(TimeC^2) + I(TimeC^3) + I(TimeC^4) + I(TimeC^5) +
  I(TimeC^6) + I(TimeC^7)
```

```
Model 2: NigerTS ~ TimeC + I(TimeC^2) + I(TimeC^3) + I(TimeC^4) + I(TimeC^5) +
  I(TimeC^6)
```


	Res.Df	RSS	Df	Sum of Sq	F	Pr(>F)
1	43	3394.0				
2	44	3854.9	-1	-460.92	5.8397	0.01999 *

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

Protože p-hodnota srovnávacího testu označená jako  $\text{Pr}(>F)$  je menší než 0.05, je model s polynomem sedmého stupně významně lepší než model s polynomem šestého řádu.

Výsledek opět zakreslíme do grafu.

```
> Pred7 <- predict(fitModel7, data.frame(TimeC = gridtC), se = T)
> alpha <- 0.05
> CV <- qt(1 - alpha/2, Pred7$df)
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(NigerTS, main = TXT, cex.main = 0.85)
> matlines(gridt, cbind(Pred7$fit, Pred7$fit - CV * Pred7$se.fit,
  Pred7$fit + CV * Pred7$se.fit), lty = c(1, 2, 2), col = c("red",
  "gray35", "gray35"))
```




Obrázek 6: Polynomický trend sedmého řádu pro průměrné roční průtoky vody v řece Nigeru v Coulicoure (Mali).

Kvalitu modelu lze posoudit pomocí analýzy reziduí, kterou provedeme pro oba modely, tj. pro polynomy stupně šest a sedm.


Pomocí příkazu `plot`, ve kterém bude argumentem odhadnutý model, můžeme vykreslit celou řadu grafů. Vybereme si první a druhý.

```
> par(mfrow = c(1, 2), mar = c(2, 2, 1, 0) + 0.5)
> plot(fitModel6, which = c(1, 2))
```



Obrázek 7: Vybrané grafy z analýzy reziduí pro polynomický trend šestého řádu pro průměrné roční průtoky vody v řece Nigeru v Coulicoure (Mali).


```
> par(mfrow = c(1, 2), mar = c(2, 2, 1, 0) + 0.5)
> plot(fitModel7, which = c(1, 2))
```



Obrázek 8: Vybrané grafy z analýzy reziduí pro polynomický trend sedmého řádu pro průměrné roční průtoky vody v řece Nigeru v Coulicouro (Mali).

Na závěr všechny odhadnuté trendy zakreslíme do jediného grafu.

```
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(NigerTS, main = TXT, cex.main = 0.85)
> matlines(gridt, cbind(Pred$fit, Pred3$fit, Pred6$fit, Pred7$fit),
  lty = c(1, 2, 1, 2), col = c("magenta", "red", "dodgerblue",
    "darkgreen"))
> legend("bottomright", legend = paste("dgr =", c(1, 3, 6, 7)),
  bty = "n", lty = c(1, 2, 1, 2), col = c("magenta", "red",
    "dodgerblue", "darkgreen"))
```



Obrázek 9: Polynomické trendy řádu jedna, tři, šest a sedm pro průměrné roční průtoky vody v řece Nigeru v Coulicouro (Mali).

## C. Úkol:

Pro časové řady, které jste si našli ve druhém praktiku, vytvořte, vykreslete a analyzujte vhodné modely polynomického trendu.