

## M5201 – 2. CVIČENÍ: Regresní analýza v R

### 1 Úvod do regresní analýzy

Regresní analýza je jednou z nejčastěji používaných statistických technik. Zabýváme se při ní vztahy mezi několika veličinami. Snažíme se zjistit, jak hodnoty jedné veličiny (*vysvětlované proměnné, odeszvy*) závisí na hodnotách ostatních veličin (*vysvětlujících veličin, regresorů, kovariátu*).

Vycházíme z předpokladu, že vysvětlovaná veličina je funkcí vysvětlujících proměnných a náhodné složky, což je náhodná veličina s nulovou střední hodnotou, která reprezentuje náhodné odchylky, chyby v měření apod.

$$Y = f(x_1, x_2, \dots, x_m, \varepsilon),$$

kde	$Y$	je vysvětlovaná proměnná
	$x_1, \dots, x_m$	jsou vysvětlující proměnné (kovariáty, regresory)
	$\varepsilon$	je náhodná složka

Funkce  $f$  patří do předem zvolené třídy funkcí a závisí na jednom či více parametrech. Ty jsou neznámé a odhadují se na základě zjištěných dat.

Obvykle máme k dispozici  $n$  pozorování vysvětlované proměnné

$$Y_1, Y_2, \dots, Y_n$$

a jim odpovídající hodnoty vysvětlujících proměnných

$$x_{11}, x_{12}, \dots, x_{1n}, x_{21}, x_{22}, \dots, x_{2n}, \dots, x_{m1}, \dots, x_{mn}$$

a pomocí regresního modelu můžeme popsat jednotlivá pozorování

$$Y_i = f(x_{i1}, x_{i2}, \dots, x_{im}, \varepsilon_i), \quad i = 1, \dots, n$$

Nejjednodušším případem regresního modelu je klasický lineární regresní model. Je charakteristický tím, že vysvětlovanou proměnnou se v něm snažíme popsat pomocí lineární kombinace známých funkcí vysvětlujících proměnných s neznámými regresními koeficienty. Pomocí rovnice můžeme lineární regresní model zapsat takto

$$Y_i = \beta_0 + \beta_1 f_1(x_{i1}, x_{i2}, \dots, x_{im}) + \beta_2 f_2(x_{i1}, x_{i2}, \dots, x_{im}) + \dots + \beta_k f_k(x_{i1}, x_{i2}, \dots, x_{im}) + \varepsilon_i,$$

kde pro  $i = 1, \dots, n$

$Y_i$	jsou vysvětlované proměnné
$x_{i1}, \dots, x_{im}$	jsou vysvětlující proměnné (kovariáty, regresory)
$f_1, f_2, \dots, f_k$	jsou známé (předem zvolené) funkce vysvětlujících proměnných
$\beta_0, \beta_1, \dots, \beta_k$	jsou neznámé regresní koeficienty
$\varepsilon_i$	jsou nekorelované náhodné veličiny s nulovou střední hodnotou a konstantním rozptylem

V lineárním regresním modelu tedy vysvětlovanou proměnnou modelujeme jako součet *systematické složky* (což je funkce, která je lineární v neznámých regresních koeficientech) a *náhodné složky*.

V lineárním regresním modelu se dále předpokládá, že pro různé realizace  $Y_i, i = 1, \dots, n$  vysvětlované proměnné jsou odpovídající náhodné veličiny  $\varepsilon_i$  navzájem nezávislé a mají stejné rozdělení s nulovou střední hodnotou a konstatním rozptylem, což značíme  $\varepsilon_i \sim IID(0, \sigma^2)$ . Pro testování hypotéz je třeba přidat předpoklad, že rozdělení chybové složky je normální.

Pro odhad neznámých parametrů regresních modelů existuje více metod. Pro lineární regresní modely se obvykle používá *metoda nejmenších čtverců*. Odhad parametrů se obvykle označují stříškou, např.  $\hat{\beta}_0, \hat{\beta}_1, \dots$ . Hodnoty vysvětlované proměnné  $\hat{Y}_i$ , které získáme po dosazení odhadnutých parametrů do regresní rovnice

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 f_1(x_{i1}, x_{i2}, \dots, x_{im}) + \hat{\beta}_2 f_2(x_{i1}, x_{i2}, \dots, x_{im}) + \dots + \hat{\beta}_k f_k(x_{i1}, x_{i2}, \dots, x_{im})$$

se nazývají *vyrovnané hodnoty*. Rozdíly mezi skutečnými a vyrovnanými hodnotami vysvětlované proměnné  $\hat{\varepsilon}_i = Y_i - \hat{Y}_i$  se nazývají *rezidua*.

Veličiny v modelu mohou být jak spojité, tak kategorické (sem patří nominální, ordinální a diskrétní veličiny). Kategorické proměnné se také nazývají faktory a jejich hodnoty se nazývají úrovně.

### Poznámka

Při maticovém popisu regresního modelu obvykle provedeme určité přeznačení

#### systematická složka

$$Y_i = \underbrace{\beta_0 + \beta_1 f_1(z_{i1}, z_{i2}, \dots, z_{ip})}_{\text{označíme } x_{i1}} + \underbrace{\beta_2 f_2(z_{i1}, z_{i2}, \dots, z_{ip})}_{\text{označíme } x_{i2}} + \dots + \underbrace{\beta_m f_m(z_{i1}, z_{i2}, \dots, z_{im})}_{\text{označíme } x_{im}} + \varepsilon_i,$$

takže pracujeme s modelem

$$\begin{aligned} Y_1 &= \beta_0 + \beta_1 x_{11} + \dots + \beta_m x_{1k} + \varepsilon_1 \\ &\vdots \\ Y_n &= \beta_0 + \beta_1 x_{n1} + \dots + \beta_m x_{nm} + \varepsilon_n \end{aligned} \quad \begin{matrix} \text{maticově} \\ \text{t.j.} \end{matrix} \quad \underbrace{\begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}}_{\mathbf{Y}} = \underbrace{\begin{pmatrix} 1 & x_{11} & \dots & x_{1m} \\ \vdots & \vdots & & \vdots \\ 1 & x_{n1} & \dots & x_{nm} \end{pmatrix}}_{\mathbf{X}(\text{matice plánu})} \underbrace{\begin{pmatrix} \beta_0 \\ \vdots \\ \beta_m \end{pmatrix}}_{\boldsymbol{\beta}} + \underbrace{\begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}}_{\boldsymbol{\varepsilon}}$$

Uvažujme **klasický regresní model** plné hodnosti, kde chyba má normální rozdělení:

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

Odhad neznámých parametrů  $\boldsymbol{\beta}$  provedený *metodou nejmenších čtverců* je řešením normálních rovnic

$$\mathbf{X}'\mathbf{X}\boldsymbol{\beta} = \mathbf{X}'\mathbf{Y}$$

a platí

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

### Označme

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

$$\hat{\boldsymbol{\varepsilon}} = \mathbf{Y} - \hat{\mathbf{Y}} = (\underbrace{\mathbf{I} - \mathbf{H}}_{\mathbf{M}})\mathbf{Y} = \mathbf{MY} = \mathbf{M}(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}) = \underbrace{\mathbf{MX}}_{=0} \boldsymbol{\beta} + \mathbf{M}\boldsymbol{\varepsilon} = (\mathbf{I} - \mathbf{H})\boldsymbol{\varepsilon}$$

$$s^2 = \frac{S_e}{n-p-1} = \frac{1}{n-m-1} (\mathbf{Y} - \hat{\mathbf{Y}})'(\mathbf{Y} - \hat{\mathbf{Y}}) = \frac{1}{n-m-1} \hat{\boldsymbol{\varepsilon}}'\hat{\boldsymbol{\varepsilon}} = \frac{1}{n-m-1} \hat{\mathbf{Y}}'(\mathbf{I} - \mathbf{H})\hat{\mathbf{Y}} = \frac{1}{n-m-1} \boldsymbol{\varepsilon}'(\mathbf{I} - \mathbf{H})\boldsymbol{\varepsilon}$$

Pak připomeňme následující vlastnosti klasického regresního modelu (plné hodnosti)

- $E\hat{\beta} = \beta$  (nestrannost odhadu)
  - $Es^2 = \frac{E(S_e)}{n-m-1} = \sigma^2$ , tj.  $s^2$  je nestranným odhadem rozptylu
  - $D\hat{\beta} = \sigma^2(\mathbf{X}'\mathbf{X})^{-1}$
  - $\mathbf{Y} \sim N_n(\mathbf{X}\beta, \sigma^2 I_n)$
  - $\hat{\varepsilon} \sim N_n(\mathbf{0}, \sigma^2(\mathbf{I} - \mathbf{H}))$
  - $\hat{\beta} \sim N_{m+1}(\beta, \sigma^2(\mathbf{X}'\mathbf{X})^{-1})$
  - $\frac{S_e}{\sigma^2} \sim \chi^2(n-m-1)$
  - $\hat{\beta}$  a  $s^2$  jsou stochasticky nezávislé
  - $T_j = \frac{\hat{\beta}_j - \beta_j}{\sqrt{s^2 v_{jj}}} \sim t(n-m-1)$ , kde  $(\mathbf{X}'\mathbf{X})^{-1} = (v_{ij})_{i,j=0,\dots,m}$
  - $F = \frac{1}{qs^2}(\hat{\beta}_2 - \beta_2)' \mathbf{W}^{-1}(\hat{\beta}_2 - \beta_2) \sim F(q, n-m-1)$ ,
- kde  $(\mathbf{X}'\mathbf{X})^{-1} = \begin{pmatrix} \mathbf{V} & \mathbf{U} \\ \mathbf{U}' & \mathbf{W} \end{pmatrix}$ ,  $\beta = \begin{pmatrix} \beta_1 \\ \beta_2 \end{pmatrix}$   $\hat{\beta} = \begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix}$  a  $h(\mathbf{W}) = q$
- $T = \frac{\mathbf{c}'\hat{\beta} - \mathbf{c}'\beta}{\sqrt{s^2 \mathbf{c}'(\mathbf{X}'\mathbf{X})^{-1} \mathbf{c}}} \sim t(n-m-1)$ , kde  $\mathbf{c} = (c_0, c_1, \dots, c_m)'$  a  $E(\mathbf{c}'\hat{\beta}) = \mathbf{c}'\beta$
  - $Y_i = \mathbf{x}'_i \beta + \varepsilon_i \sim N(\mathbf{x}'_i \beta, \sigma^2)$   
 $\hat{Y}_i = \mathbf{x}'_i \hat{\beta} \sim N(\mathbf{x}'_i \beta, \sigma^2 \mathbf{x}'_i (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_i) \Rightarrow Y_i - \hat{Y}_i \sim N(0, \sigma^2(1 + \mathbf{x}'_i (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_i))$
- kde  $\mathbf{x}'_i = (x_{i0}, \dots, x_{im})$  je  $i$ -tý řádek matice plánu  $\mathbf{X}$

Na základě předchozích vlastností lze odvodit následující intervaly spolehlivosti

INTERVALY SPOLEHLIVOSTI	
pro parametry $\beta_j$ $j = 0, \dots, p$	$(\beta_j - t_{1-\frac{\alpha}{2}}(n-p-1)s\sqrt{v_{jj}}, \beta_j + t_{1-\frac{\alpha}{2}}(n-p-1)s\sqrt{v_{jj}})$
pro střední hodnotu predikce $E\hat{Y}_i = E\mathbf{x}'_i\hat{\beta} = \mathbf{x}'_i\beta$	$(\mathbf{x}'_i\hat{\beta} - t_{1-\frac{\alpha}{2}}(n-m-1)s\sqrt{\mathbf{x}'_i(\mathbf{X}'\mathbf{X})^{-1}\mathbf{x}_i}, \mathbf{x}'_i\hat{\beta} + t_{1-\frac{\alpha}{2}}(n-m-1)s\sqrt{\mathbf{x}'_i(\mathbf{X}'\mathbf{X})^{-1}\mathbf{x}_i})$
pro predikci $\hat{Y}_i = \mathbf{x}'_i\hat{\beta}$ $i = 1, \dots, n$	$(\mathbf{x}'_i\hat{\beta} - t_{1-\frac{\alpha}{2}}(n-m-1)s\sqrt{1+\mathbf{x}'_i(\mathbf{X}'\mathbf{X})^{-1}\mathbf{x}_i}, \mathbf{x}'_i\hat{\beta} + t_{1-\frac{\alpha}{2}}(n-m-1)s\sqrt{1+\mathbf{x}'_i(\mathbf{X}'\mathbf{X})^{-1}\mathbf{x}_i})$

kde  $t_{1-\frac{\alpha}{2}}(n-m-1)$  je  $1 - \frac{\alpha}{2}$  kvantil Studentova rozdělení o  $n-m-1$  stupních volnosti

## 2 Použití funkce `lm()`

K odhadu parametrů lineárního regresního modelu je v systému R k dispozici funkce `lm`. Tato funkce má následující argumenty

```
lm(formula, data, subset, weights, na.action,
  method = "qr", model = TRUE, x = FALSE, y = FALSE, qr = TRUE,
  singular.ok = TRUE, contrasts = NULL, offset, ...)
```

Nejdůležitější je argument `formula`, kterým se zadává, jakou podobu má mít rovnice popisující model. Modelový vztah mezi proměnnými se obecně zadává ve tvaru

*vysvětlovaná proměnná*  $\sim$  *systematická složka*

Zatímco na levé straně můžeme normálně používat obvyklé matematické funkce jako logaritmus nebo matematické operátory  $+$ ,  $-$  apod., na pravé straně mají matematické operátory poněkud odlišný význam. Konkrétně:

- + přidat vysvětlující proměnnou
- odstranit vysvětlující proměnnou
- : interakce mezi veličinami
- \* všechny komponenty
- 1 absolutní člen
- 1 odebrat absolutní člen

Pokud potřebujeme při specifikaci modelu použít matematické operátory v obvyklém smyslu, musíme výraz s těmito operátory napsat jako argument funkce `I()`. Rozdíl můžeme ukázat na příkladu.

`y ~ x1 + x2` definuje model  $Y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \varepsilon_i$ ,

zatímco

`y ~ I(x1 + x2)` definuje model  $Y_i = \beta_0 + \beta_1(x_{1i} + x_{2i}) + \varepsilon_i$ .

Konkrétní příklady zadávání modelů v systému R jsou ukázány v následující tabulce.

<b>Formální zápis</b>	<b>Syntaxe v R</b>	<b>Popis</b>
$Y_i = \mu + \varepsilon_i$	$y \sim 1$	Model pouze s absolutním členem
$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$	$y \sim x$	Lineární model se spojitou vyšvětlující proměnnou $x$ (regresní přímka)
$Y_i = \beta_1 x_i + \varepsilon_i$	$y \sim x - 1$	Lineární model se spojitou vyšvětlující $x$ bez absolutního člena
$\log(Y_i) = \beta_0 + \beta_1 x_i + \varepsilon_i$	$\log(y) \sim x$	Lineární model se spojitou vyšvětlující $x$ a s logaritmicky transformovanou vyšvětlovanou proměnnou
$Y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \varepsilon_i$	$y \sim x + I(x^2),$ $y \sim poly(x, 2)$	Kvadratický model se spojitou vyšvětlující proměnnou $x$ (regresní parabola)
$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \varepsilon_i$	$y \sim x1+x2$	Model se dvěma spojitými vyšvětlujícími proměnnými $x_1$ a $x_2$ , v každé z nich je lineární (víceňasobná regrese)
$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \varepsilon_i$	$y \sim x1*x2,$ $y \sim x1+x2+I(x1*x2)$	Model se dvěma spojitými vyšvětlujícími proměnnými $x_1$ a $x_2$ s křízovým členem
$Y_{ij} = \mu + \alpha_i + \varepsilon_{ij}$	$y \sim A$	Model s jedním faktorem (jednofaktorová analýza rozptylu, ANOVA)
$Y_{ijk} = \mu + \alpha_i + \beta_j + \varepsilon_{ijk}$	$y \sim A + B$	Model se dvěma faktory bez interakce (dvoufaktorová analýza rozptylu)
$Y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk}$	$y \sim A + B + A:B, \quad y \sim A * B$	Model se dvěma faktory s interakcí (dvoufaktorová analýza rozptylu)
$Y_{ijkl} = \mu + \alpha_i + \beta_j + \gamma_k + \varepsilon_{ijkl}$	$y \sim A + B + C$	Model se třemi faktory bez interakcí (třífaktorová analýza rozptylu)
$Y_{ijkl} = \mu + \alpha_i + \beta_j + \gamma_k + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + (\alpha\beta\gamma)_{ijk} + \varepsilon_{ijkl}$	$y \sim A+B+C+A:B+A:C+B:C+A:B:C$ $y \sim A*B*C$	Model se třemi faktory s interakcemi (třífaktorová analýza rozptylu)
$Y_{ijkl} = \mu + \alpha_i + \beta_j + \gamma_k + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + \varepsilon_{ijkl}$	$y \sim A+B+C+A:B+A:C+B:C$ $y \sim (A+B+C)^2$	Model se třemi faktory obsahující kromě hlavních efektů maximálně dvojně interakce (třífaktorová analýza rozptylu)
$Y_{ij} = \mu + \alpha_j + \beta x_{ij} + \varepsilon_{ij}$	$y \sim x+A$	Model se spojitou proměnnou $x$ a faktorem $A$ bez interakce interakce (ANCOVA)
$Y_{ij} = \mu + \alpha_j + \beta x_{ij} + \delta_j x_{ij} + \varepsilon_{ij}$	$y \sim x*A$	Model se spojitou proměnnou $x$ a faktorem $A$ s interakcí (ANCOVA)

Tabulka 1: Přehled zápisu základních modelů (spojeté veličiny značíme písmeny z konce abecedy:  $x, Y, \dots$ , faktory písmeny ze začátku abecedy:  $A, B, \dots$ )

### 3 Příklady

#### PŘÍKLAD 1: REGRESNÍ PŘÍMKA

Máme k dispozici údaje o počtu australských domácností připojených v letech 1998–2008 na internet:


Rok	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008
Počet domácností	1098	1538	2340	3114	3445	4039	4393	4730	5138	5492	5878

Data nejprve načteme, a to tak, že údaje o počtech domácností zkopírujeme do schránky a použijeme funkci `scan()`.

```
> domacnosti <- scan("clipboard", sep = " ")
> time <- 1998:2008
```

Načtená data vykreslíme do grafu.

```
> TxtX <- "Rok"
> TxtY <- "Pocet domacnosti"
> plot(time, domacnosti, type = "p", xlab = TxtX, ylab = TxtY)
```



Obrázek 1: Počet domácností s připojením na internet v letech 1998–2008

Budeme uvažovat regresní model, ve kterém počet domácností s připojením na internet závisí lineárně na čase. Model můžeme popsat regresní rovnicí

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, \dots, 11$$

kde

$Y_i$	je počet domácností s připojením na internet v $i$ -tém roce
$x_i$	je rok odpovídající $i$ -tému pozorování
$\beta_0, \beta_1$	jsou neznámé regresní koeficienty, které budeme odhadovat
$\varepsilon_i$	je náhodná odchylka příslušející $i$ -tému pozorování

Parametry tohoto modelu odhadneme v systému R pomocí funkce `lm()` a k zobrazení výsledků použijeme funkci `summary()`.

```
> model1 <- lm(domacnosti ~ time)
> summary(model1)
```

```
Call:
lm(formula = domacnosti ~ time)

Residuals:
    Min      1Q  Median      3Q     Max 
-306.45 -200.05   20.18  173.09  318.82 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) -948407.45   45085.31 -21.04 5.81e-09 ***
time         475.36      22.51   21.12 5.61e-09 ***  
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 236.1 on 9 degrees of freedom
Multiple R-squared:  0.9802,    Adjusted R-squared:  0.978 
F-statistic:  446 on 1 and 9 DF,  p-value: 5.615e-09
```


Ve výpisu výsledků odhadu modelu vidíme nejprve zadaný tvar modelu. Dále jsou zde uvedeny informace o reziduích (minimální a maximální reziduum, horní a dolní kvartil a medián). V další tabulce jsou shrnutý odhadnuté parametry

$$\beta_0 = -948407.45 \text{ (Intercept)} \quad \beta_1 = 475.36 \text{ (time)}$$

a v dalších sloupcích jsou směrodatné odchyly odhadnutých parametrů a testové statistiky pro testování některých hypotéz týkajících se parametrů modelu. V závěru jsou uvedeny souhrnné statistiky týkající se celého modelu.

Na závěr zobrazíme data proložená odhadnutou regresní přímkou. Do grafu navíc dokreslíme interval spolehlivosti kolem střední hodnoty a predikční interval spolehlivosti (který je širší a měl by obsahovat cca 95% dat).


```
> n <- length(time)
> gridt <- seq(time[1], time[n], length.out = 500)
> ci.conf <- predict(model1, newdata = data.frame(time = gridt), interval = "confidence")
> ci.pred <- predict(model1, newdata = data.frame(time = gridt), interval = "prediction")
> yrangle <- range(c(domacnosti, ci.conf[, 2], ci.pred[, 3]))
> plot(time[c(1, n)], yrangle, type = "n", xlab = TxtX, ylab = TxtY)
> matlines(gridt, ci.conf[, 1], lty = 1, lwd = 2, col = "red2")
> matlines(gridt, ci.conf[, 2:3], lty = 2, lwd = 1.5, col = "dodgerblue")
> matlines(gridt, ci.pred[, 2:3], lty = 3, lwd = 1.5, col = "darkgreen")
> points(time, domacnosti, pch = 21, cex = 0.85, bg = "red1")
```



Obrázek 2: Grafické vyjádření regresní přímky pro data *Počet domácností s připojením na internet v letech 1998–2008* spolu s intervaly spolehlivosti kolem střední hodnoty a s predikčním intervalom

Pro zajímavost totéž provedeme v trochu jiné grafické úpravě.

```
> plot(time[c(1, n)], yrangle, type = "n", xlab = TxtX, ylab = TxtY)
> xx <- c(gridt, rev(gridt))
> yy <- c(ci.conf[, 2], rev(ci.conf[, 3]))
> polygon(xx, yy, col = "gray75", border = "gray75")
> yy <- c(ci.conf[, 2], rev(ci.pred[, 2]))
> polygon(xx, yy, col = "gray85", border = "gray85")
> yy <- c(ci.conf[, 3], rev(ci.pred[, 3]))
> polygon(xx, yy, col = "gray85", border = "gray85")
> matlines(gridt, ci.conf[, 1], lty = 1, lwd = 2, col = "red2")
> points(time, domacnosti, pch = 21, cex = 0.85, bg = "yellowgreen")
```



Obrázek 3: Grafické vyjádření regresní přímky pro data *Počet domácností s připojením na internet v letech 1998–2008* spolu s intervaly spolehlivosti kolem střední hodnoty a s predikčním intervalem – s využitím ploch

#### PŘÍKLAD 2: POLYNOMICKÁ REGRESE

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 jednotkách  $\text{cfs} \cdot 10^{-3}$ .

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.

```
> fileDat <- paste(data.library, "DataNiger.dat", 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 za pomoci funkce `read.table()` s argumentem `skip=2`, který způsobí vynechání prvních dvou řádků. Ve vzniklém datovém rámci pojmenujeme proměnné, vypíšeme jeho strukturu a prvních šest řádků. Nakonec data vykreslíme.

```
> dataNiger <- read.table(fileDat, header = F, skip = 2)  
> names(dataNiger) <- c("Rok", "Prutok")  
> str(dataNiger)
```

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

```
> head(dataNiger)
```


	Rok	Prutok
1	1907	39.793
2	1908	42.892
3	1909	69.070
4	1910	43.653
5	1911	56.700
6	1912	45.990

Příkazem `attach()` zpřístupníme proměnné v datovém rámci `dataNiger` a data vykreslíme.

```
> attach(dataNiger)
```

```
> plot(Rok, Prutok, main = "TXT", cex.main = 0.85, type = "l")
```

Prumerne roční průtoky vody v řece Nigeru v Coulicoure (Mali) v letech 1907 az 1957



Obrázek 4: Průměrně roční průtoky v řece Niger v Coulicoure (Mali).

Z grafu je patrné, že závislost průtoku na čase bude složitější a proložit grafem regresní přímku by mohlo být příliš zjednodušující. Proto zkusíme daty proložit polynomem vyššího stupně. Nejprve zkusíme polynom třetího stupně, kdy budeme předpokládat, že jednotlivá pozorování můžeme popsat vztahem

$$Y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \varepsilon_i,$$

kde  $Y_i$  označuje průtok vody a  $x_i$  označuje rok odpovídající danému údaji.

Neznámé parametry tohoto modelu nyní odhadneme.

```
> model3 <- lm(Prutok ~ Rok + I(Rok^2) + I(Rok^3))
> summary(model3)
```

```
Call:
lm(formula = Prutok ~ Rok + I(Rok^2) + I(Rok^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 ***
Rok          2.302e+04 7.614e+03  3.023 0.00404 ***
I(Rok^2)     -1.191e+01 3.941e+00 -3.022 0.00405 ***
I(Rok^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: 0.0105
```

Výsledky modelu s polynomem řádu tří zakreslíme do grafu. Odhadnutou regresní křivku zobrazíme do grafu tak, že nejprve vytvoříme vektor `gridt` obsahující 500 hodnot v rozmezí 1907 a 1957. Pak použijeme funkci `predict()`, pomocí níž pro všechny prvky `gridt` spočítáme na základě odhadnutých parametrů modelu vyrovnané hodnoty jednak odhadnuté hodnoty, kromě toho také intervaly spolehlivosti kolem střední hodnoty a predikční intervaly.


```
> n <- length(Rok)
> gridt <- seq(Rok[1], Rok[n], length.out = 500)
> ci.conf <- predict(model3, newdata = data.frame(Rok = gridt), interval = "confidence")
> ci.pred <- predict(model3, newdata = data.frame(Rok = gridt), interval = "prediction")
> yrange <- range(c(Prutok, ci.pred[, 2], ci.pred[, 3]))
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(Rok[c(1, n)], yrange, type = "n", main = TXT, cex.main = 0.85)
> matlines(gridt, ci.conf[, 1], lty = 1, lwd = 2, col = "red2")
> matlines(gridt, ci.conf[, 2:3], lty = 2, lwd = 1.5, col = "dodgerblue")
> matlines(gridt, ci.pred[, 2:3], lty = 3, lwd = 1.5, col = "darkgreen")
> points(Rok, Prutok, type = "o", pch = 21, cex = 0.85, bg = "red1")
```



Obrázek 5: Grafické znázornění polynomické regrese 3. stupně pro data *Průměrné roční průtoky vody v řece Niger v Coulicoure (Mali)* spolu s intervaly spolehlivosti

Opět intervaly spolehlivost zdůrazníme pomocí ploch.

```
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(Rok[c(1, n)], yrange, type = "n", main = TXT, cex.main = 0.85)
> xx <- c(gridt, rev(gridt))
> yy <- c(ci.conf[, 2], rev(ci.conf[, 3]))
> polygon(xx, yy, col = "gray75", border = "gray75")
> yy <- c(ci.conf[, 2], rev(ci.pred[, 2]))
> polygon(xx, yy, col = "gray85", border = "gray85")
> yy <- c(ci.conf[, 3], rev(ci.pred[, 3]))
> polygon(xx, yy, col = "gray85", border = "gray85")
> matlines(gridt, ci.conf[, 1], lty = 1, lwd = 2, col = "red2")
> points(Rok, Prutok, type = "o", pch = 21, cex = 0.85, bg = "yellowgreen")
```



Obrázek 6: Grafické znázornění polynomické regrese 3. stupně pro data *Průměrné roční průtoky vody v řece Niger v Coulicoure (Mali)* spolu s intervaly spolehlivosti – pomocí ploch

Zkusíme odhadnout jiný model s polynomem šestého stupně, budeme tudíž předpokládat, že jednotlivá pozorování lze popsat vztahem

$$Y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \beta_4 x_i^4 + \beta_5 x_i^5 + \beta_6 x_i^6 + \varepsilon_i.$$

Odhadneme parametry nového modelu.

```
> model6 <- lm(Prutok ~ Rok + I(Rok^2) + I(Rok^3) + I(Rok^4) + I(Rok^5) +
+ I(Rok^6))
> summary(model6)
```

```
Call:
lm(formula = Prutok ~ Rok + I(Rok^2) + I(Rok^3) + I(Rok^4) +
I(Rok^5) + I(Rok^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 **
Rok	2.302e+04	7.614e+03	3.023	0.00404 **
I(Rok^2)	-1.191e+01	3.941e+00	-3.022	0.00405 **
I(Rok^3)	2.055e-03	6.800e-04	3.022	0.00406 **
I(Rok^4)	NA	NA	NA	NA
I(Rok^5)	NA	NA	NA	NA

```
I(Rok^6)           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: 0.0105
```

Vidíme, že odhad modelu s vysokým stupněm polynomu je numericky problematický, protože se koeficienty od čtvrtého stupně výše nepodařilo spočítat. V takových případech se doporučuje proměnnou `Rok` centrovat a odhadnout parametry pro model s touto centrovanou proměnnou. Centrování znamená, že od každé hodnoty proměnné `Rok` odečteme průměr všech hodnot. Model se tak změní do podoby

$$Y_i = \beta_0 + \beta_1 z_i + \beta_2 z_i^2 + \beta_3 z_i^3 + \beta_4 z_i^4 + \beta_5 z_i^5 + \beta_6 z_i^6 + \varepsilon_i,$$

kde  $z_i = x_i - \bar{x}$ .

Provedeme nový odhad modelu s centrovanou proměnnou.

```
> delta <- mean(Rok)
> RokC <- Rok - delta
> model6C <- lm(Prutok ~ RokC + I(RokC^2) + I(RokC^3) + I(RokC^4) + I(RokC^5) +
  I(RokC^6))
> summary(model6C)
```

```
Call:
lm(formula = Prutok ~ RokC + I(RokC^2) + I(RokC^3) + I(RokC^4) +
  I(RokC^5) + I(RokC^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 ***
RokC	-1.757e+00	3.909e-01	-4.494	5.02e-05 ***
I(RokC^2)	-2.385e-01	5.367e-02	-4.444	5.90e-05 ***
I(RokC^3)	1.045e-02	2.371e-03	4.408	6.63e-05 ***
I(RokC^4)	8.809e-04	2.268e-04	3.884	0.000341 ***
I(RokC^5)	-1.165e-05	3.209e-06	-3.631	0.000733 ***
I(RokC^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
```

Výsledky opět znázorníme graficky.

```
> n <- length(RokC)
> gridt <- seq(Rok[1], Rok[n], length.out = 500)
> ci.conf <- predict(model6C, newdata = data.frame(RokC = gridt - delta),
  interval = "confidence")
```


```
> ci.pred <- predict(model6C, newdata = data.frame(RokC = gridt - delta),
  interval = "prediction")
> yrangle <- range(c(Prutok, ci.pred[, 2], ci.pred[, 3]))
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(Rok[c(1, n)], yrangle, type = "n", main = TXT, cex.main = 0.85)
> matlines(gridt, ci.conf[, 1], lty = 1, lwd = 2, col = "red2")
> matlines(gridt, ci.conf[, 2:3], lty = 2, lwd = 1.5, col = "dodgerblue")
> matlines(gridt, ci.pred[, 2:3], lty = 3, lwd = 1.5, col = "darkgreen")
> points(Rok, Prutok, type = "o", pch = 21, cex = 0.85, bg = "red1")
```

Prumerne ročni prutoky vody v rece Nigeru v Coulicoure (Mali) v letech 1907 az 1957

Obrázek 7: Grafické znázornění polynomické regrese 6. stupně pro data *Průměrné roční průtoky vody v řece Niger v Coulicoure (Mali)* spolu s intervaly spolehlivosti

Opět intervaly spolehlivost zdůrazníme pomocí ploch.

```
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(Rok[c(1, n)], yrangle, type = "n", main = TXT, cex.main = 0.85)
> xx <- c(gridt, rev(gridt))
> yy <- c(ci.conf[, 2], rev(ci.conf[, 3]))
> polygon(xx, yy, col = "gray75", border = "gray75")
> yy <- c(ci.conf[, 2], rev(ci.pred[, 2]))
> polygon(xx, yy, col = "gray85", border = "gray85")
> yy <- c(ci.conf[, 3], rev(ci.pred[, 3]))
> polygon(xx, yy, col = "gray85", border = "gray85")
> matlines(gridt, ci.conf[, 1], lty = 1, lwd = 2, col = "red2")
> points(Rok, Prutok, type = "o", pch = 21, cex = 0.85, bg = "yellowgreen")
```



Obrázek 8: Grafické znázornění polynomické regrese 6. stupně pro data *Průměrné roční průtoky vody v řece Niger v Coulicoure (Mali)* spolu s intervaly spolehlivosti – pomocí ploch

Na závěr příkladu nesníme zapomenout zrušit zpřístupnění jména proměnných v datovém rámci

```
> detach(dataNiger)
```

## 4 Úkoly

1. Načtěte datový soubor `japanese-vehicle.txt` obsahující údaje o množství motorových vozidel vyrobených v Japonsku v letech 1947–1989.

- Data vykreslete do grafu.
- Odhadněte parametry následujících čtyř modelů:

$$\text{Model 1: } Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$$

$$\text{Model 2: } Y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \varepsilon_i$$

$$\text{Model 3: } Y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \varepsilon_i$$

$$\text{Model 4: } Y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \beta_4 x_i^4 + \varepsilon_i,$$

kde  $Y_i$  je počet vyrobených vozidel a  $x_i$  je čas. Pokud to bude vhodné, pracujte s centrovaným časem.

- Pro každý model do grafu vykreslete data, odhadnutou regresní křivku, interval spolehlivosti kolem střední hodnoty a predikční interval spolehlivosti.

- Na závěr vykreslete grafy pro všechny modely do jednoho obrázku.
2. Do datového souboru **US\_population.txt** byly zaznamenány údaje o počtu obyvatel v USA v desetiletých intervalech v rozmezí let 1790–1980.
- Data načtěte.
  - Do grafu vykreslete
    - (a) původní hodnoty časové řady
    - (b) časovou řadu, v níž jsou počty obyvatel zlogaritmovány.
  - Odhadněte parametry v modelech:

$$\begin{aligned} \text{Model 1:} \quad Y_i &= \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \varepsilon_i \\ \text{Model 2:} \quad \ln Y_i &= \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \varepsilon_i, \end{aligned}$$

kde  $Y_i$  je počet obyvatel a  $x_i$  je rok.

- Pro každý model do grafu vykreslete data, odhadnutou regresní křivku, interval spolehlivosti kolem střední hodnoty a predikční interval spolehlivosti. U modelu s logaritmem vykreslete jak graf se zlogaritmovanými hodnotami, tak s hodnotami na původní škále.
- Na závěr vykreslete grafy pro oba modely do jednoho obrázku (v původním měřítku bez logaritmování).