

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, odezvy*) závisí na hodnotách ostatních veličin (*vysvětlujících veličin, regresorů, kovariát*).

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
$\varepsilon$	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 modelu můžeme popsat jednotlivá pozorování

$$Y_i = f(x_{1i}, X_{2i}, \dots, x_{mi}, \varepsilon_i), \quad i = 1, \dots, n$$

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

$$Y_i = \beta_0 + \beta_1 f_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \beta_2 f_2(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + \beta_k f_k(x_{1i}, x_{2i}, \dots, x_{mi}) + \varepsilon_i,$$

kde

$Y$	je vysvětlovaná proměnná
$x_1, \dots, x_m$	jsou vysvětlující proměnné
$f_1, f_2, \dots, f_k$	jsou známé (předem zvolené) funkce vysvětlujících proměnných
$\beta_0, \beta_1, \dots, \beta_k$	jsou neznámé regresní koeficienty
$\varepsilon$	je náhodná veličina 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 konstantním rozptylem, což značíme  $\varepsilon_i \sim IID(0, \sigma^2)$ .

Pro odhad neznámých parametrů regresních modelů existuje více metod. Pro lineární regresní modely se obvykle používá *metoda nejmenších čtverců*. Odhady parametrů se obvykle

označují stríškou, např.  $\hat{\beta}_0, \hat{\beta}_1, \dots$ . Hodnoty vysvětlované proměnné  $\hat{Y}_i$ , které získáme po dosazení odhadnutých parametrů do regresní rovnice

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 f_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \hat{\beta}_2 f_2(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + \hat{\beta}_k f_k(x_{1i}, x_{2i}, \dots, x_{mi})$$

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.

### Značení:

Spojité veličiny budeme značit písmeny z konce abecedy:  $x, Y, \dots$

Faktory budeme značit písmeny ze začátku abecedy:  $A, B, \dots$

## 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  $+, -, \cdot, /$  apod., na pravé straně mají matematické operátory poněkud odlišný význam. Konkrétně:

- + přidat vysvětlující proměnnou
- odstranit vysvětlující proměnnou
- :
- \* 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.

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

zatímco

$y \sim I(x1 + x2)$  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 vysvětlující proměnnou $x$ (regresní přímka)
$Y_i = \beta_1 x_i + \varepsilon_i$	$y \sim x - 1$	Lineární model se spojitou vysvětlující $x$ bez absolutního člena
$\log(Y_i) = \beta_0 + \beta_1 x_i + \varepsilon_i$	$\log(y) \sim x$	Lineární model se spojitou vysvětlující $x$ a s logaritmicky transformovanou vysvětlovanou 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 vysvětlující proměnnou $x$ (regresní parabola)
$Y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \varepsilon_i$	$y \sim x1+x2$	Model se dvěma spojitými vysvětlujícími proměnnými $x_1$ a $x_2$ , v každé z nich je lineární (vícenásobná regrese)
$Y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \beta_3 x_{1i}x_{2i} + \varepsilon_i$	$y \sim x1*x2,$ $y \sim x1+x2+I(x1*x2)$	Model se dvěma spojitými vysvětlujícími 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)
$Y_{ijk} = \mu + \alpha_i + \beta_j + \gamma_k + \varepsilon_{ijk}$	$y \sim A + B + A:B,$ $y \sim A * B$	Model se dvěma faktory s interakcí (dvoufaktorová analýza rozptylu)
$Y_{ijkl} = \mu + \alpha_i + \beta_j + \gamma_k + \gamma_l + \varepsilon_{ijkl}$	$y \sim A + B + C$	Model se třemi faktory bez interakcí (třífaktorová analýza rozptylu)
$Y_{ijkl} = \mu + \alpha_i + \beta_j + \gamma_k + \gamma_l + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + (\beta\gamma)_{kl} + (\alpha\beta\gamma)_{ijk} + \varepsilon_{ijkl}$	$y \sim A+B+C+A:B+A:C+B:C+A:B:C$ $y \sim A*B*C$	Model se třemi faktory s interakcemi (třífaktorová analýza rozptylu)
$Y_{ijkl} = \mu + \alpha_i + \beta_j + \gamma_k + \gamma_l + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + \varepsilon_{ijkl}$	$y \sim A+B+C+A:B+A:C+B:C$ $y \sim (A+B+C)^2$	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

### 3 Příklady

#### PŘÍKLAD 1: REGRESNÍ PŘÍMKA

Máme k dispozici údaje o tom, jaký počet australských domácností měl v letech 1998–2008 připojení 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 <- "Počet domácností"
> 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, v němž bude počet domácností majících připojení na internet záviset lineárně na čase. Model můžeme popsat 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.

```
> plot(time, domacnosti, type = "p", xlab = "TxtX", ylab = "TxtY")
> abline(lm(domacnosti ~ time), col = "blue", lty = 1)
```



Obrázek 2: Počet domácností s připojením na internet v letech 1998–2008

### 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 cfs. $10^{-3}$ .

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")
```



Obrázek 3: 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 vyrovnané hodnoty na základě odhadnutých parametrů modelu a uložíme je do objektu `Pred3`. Výslednou křivku zobrazíme pomocí funkce `matlines`, kde jako argumenty zadáme `gridt` a `Pred3`.

```
> n <- length(Rok)
> gridt <- seq(Rok[1], Rok[n], length.out = 500)
> Pred3 <- predict(model3, data.frame(Rok = gridt))
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(Rok, Prutok, type = "l", main = "Průměrné roční průtoky vody v řece Nigeru v Coulicoure (Mali) v letech 1907 az 1957", cex.main = 0.85)
> matlines(gridt, Pred3, col = "red")
```



Obrázek 4: Průměrné roční průtoky vody v řece Niger v Coulicoure (Mali) proložené polynomem třetího stupně.

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         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.

```
> gridtC <- gridt - delta
> Pred6 <- predict(model6C, data.frame(RokC = gridtC))
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(Rok, Prutok, type = "l", main = TXT, cex.main = 0.85)
> matlines(gridt, Pred6, col = "red")
```



Obrázek 5: Průměrné roční průtoky vody v řece Niger v Coulicoure (Mali) proložené polynomem šestého stupně.

### PŘÍKLAD 3: TRIGONOMETRICKÁ REGRESE

Máme k dispozici údaje o průměrných měsíčních teplotách v New Yorku. Zjištěné teploty ve stupních Celsia za období leden 1949 – prosinec 1959 jsou uloženy v souboru `nytemps.dat`.

Soubor obsahuje jediný sloupec se zjištěnými teplotami a není v něm uvedena hlavička. Data načteme obvyklým způsobem pomocí funkce `read.table`, zobrazíme strukturu vytvořeného datového rámce a vypíšeme začátek datového souboru. Proměnnou v datovém rámci pojmenujeme a zpřístupníme pomocí příkazu `attach`.

```
> fileDat <- paste(data.library, "nytemps.dat", sep = "")
> data <- read.table(fileDat)
> str(data)
```

```
'data.frame':      168 obs. of  1 variable:
 $ V1: num  11.5 11 14.4 14.4 16.5 ...
```


```
> head(data)
```

	V1
1	11.506
2	11.022
3	14.405
4	14.442
5	16.524
6	17.918

```
> names(data) <- "teploty"
> attach(data)
```

Vývoj teplot v čase znázorníme graficky.

```
> TXT <- "Prumerne mesicni teploty v~New Yorku"
> n <- length(teploty)
> Time <- 1:n
> plot(1946 + (Time - 1)/12, teploty, type = "l", xlab = "Cas", ylab = "Teplota")
```



Obrázek 6: Průměrné měsíční teploty v New Yorku v letech 1946–1959.

Z grafu je patrné, že vývoj teplot v čase je periodický. Z povahy věci můžeme předpokládat, že perioda má délku 12 měsíců. Proto jako regresní funkci použijeme takovou funkci, která je periodická s periodou 12. K tomu jsou nevhodnější funkce sinus a cosinus. Jednotlivá pozorování popíšeme rovnicí

$$Y_i = \beta_0 + \beta_1 \sin\left(\frac{2\pi}{12}x_i\right) + \cos\left(\frac{2\pi}{12}x_i\right) + \varepsilon_i,$$

kde  $Y_i$  označuje teplotu odpovídající  $i$ -tému pozorování a  $x_i$  je odpovídající čas.

K odhadu parametrů modelu opět použijeme funkci `lm`.

```
> modelPeriod <- lm(teploty ~ 1 + I(sin(2 * pi/12 * Time)) + I(cos(2 *
  pi/12 * Time)))
> summary(modelPeriod)
```

```
Call:
lm(formula = teploty ~ 1 + I(sin(2 * pi/12 * Time)) + I(cos(2 *
  pi/12 * Time)))
```

Residuals:

Min	1Q	Median	3Q	Max
-1.6248	-0.4007	0.0111	0.3264	5.4562

Coefficients:


	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	15.33289	0.05203	294.70	<2e-16 ***
I(sin(2 * pi/12 * Time))	-2.53766	0.07358	-34.49	<2e-16 ***
I(cos(2 * pi/12 * Time))	-2.92704	0.07358	-39.78	<2e-16 ***
---				

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

```
Residual standard error: 0.6744 on 165 degrees of freedom
Multiple R-squared: 0.9438,          Adjusted R-squared: 0.9431
F-statistic: 1386 on 2 and 165 DF, p-value: < 2.2e-16
```

Nakonec zobrazíme data spolu s odhadnutou regresní křivkou.

```
> n <- length(data$teploty)
> gridt <- seq(Time[1], Time[n], length.out = 500)
> PredPeriod <- predict(modelPeriod, data.frame(Time = gridt))
> par(mar = c(2, 2, 1, 0) + 0.5)
> plot(1946 + (Time - 1)/12, data$teploty, type = "l", main = TXT, cex.main = 0.85)
> matlines(1946 + (gridt - 1)/12, PredPeriod, col = "darkgreen")
```



Obrázek 7: Průměrné měsíční teploty v New Yorku s trigonometrickou regresní funkcí.

#### PŘÍKLAD 4: JEDNOFAKTOROVÁ ANOVA

Byl proveden experiment, v němž se do pastí odchytával jistý druh můry. Pasti obsahovaly vždy jeden ze tří různých typů návnady a byly umístěny v různých výškách stromů. Data z experimentu jsou uložena v souboru `moths.csv` a informace o datovém souboru jsou k dispozici v souboru `moths_info.txt`.

Nejprve pomocí funkce `readLines` načteme soubor `moths_info.txt`.

```
> fileTxt <- paste(data.library, "moths_info.txt", sep = "")
> con <- file(fileTxt)
> (popis <- readLines(con))

[1] "Spruce Moth Trap"
[2] ""
[3] "Response: number of spruce moths found in trap after 48 hours"
[4] "Factor 1: Location of trap in tree (top branches, middle branches, lower branches, ground)"
[5] "Factor 2: Type of lure in trap (scent, sugar, chemical) "
[6] ""
[7] ""

> close(con)
```

V souboru `moths.csv` jsou data uložená ve třech proměnných, jejichž názvy jsou uvedeny na prvním řádku a jsou odděleny středníkem. Proto použijeme funkci `read.table` s argumenty `sep=";"` a `header=TRUE`.

```
> fileDat <- paste(data.library, "moths.csv", sep = "")  
> data <- read.table(fileDat, header = TRUE, , sep = ";")  
> str(data)

'data.frame':      60 obs. of  3 variables:  
 $ Location: Factor w/ 4 levels "Ground","Lower",...: 4 4 4 4 4 4 4 4 4 ...  
 $ Lure    : Factor w/ 3 levels "Chemical","Scent",...: 2 2 2 2 2 3 3 3 3 ...  
 $ Number   : int  28 19 32 15 13 35 22 33 21 17 ...
```

Zajímá nás, jaký vliv na počet můr chycených do pasti má umístění pasti. Úrovně této proměnné typu faktor zjistíme příkazem `levels`.


```
> levels(data$Location)
```

```
[1] "Ground" "Lower"  "Middle" "Top"
```

Umístění pasti je v našem případě kategoriální proměnná se čtyřmi úrovněmi *Ground*, *Lower*, *Middle* a *Top*.

Přibližnou představu o rozdílech mezi zjištěnými údaji pro různá umístění pastí můžeme získat z krabicového grafu.

```
> plot(data$Location, data$Number, ylab = "Number")
```



Obrázek 8: Počet chycených můr v závislosti na umístění pasti.

Budem předpokládat, že střední hodnota počtu odchycených můr se liší v závislosti na tom, v jaké výšce byla past umístěna, což můžeme zapsat

$$\begin{aligned} E(Y_{ground}) &= \mu + \alpha_{ground} \\ E(Y_{lower}) &= \mu + \alpha_{lower} \\ E(Y_{middle}) &= \mu + \alpha_{middle} \\ E(Y_{top}) &= \mu + \alpha_{top} \end{aligned}$$

kde proměnná  $Y$  označuje počet odchycených můr a index označuje umístění pasti.

Tomu odpovídá model, v němž jednotlivá pozorování popíšeme rovnicí

$$Y_{jk} = \mu + \alpha_j + \varepsilon_{jk}, \quad (1)$$

kde index  $j = 1, 2, 3, 4$  označuje umístění pasti odpovídající danému údaji a index  $k$  označuje pořadí pozorování mezi pozorováním se stejným umístěním pasti. Tento model se nazývá *analýza rozptylu jednoduchého třídění*, zkráceně *jednofaktorová ANOVA*.

K odhadu koeficientů  $\mu$  a  $\alpha_j$  použijeme opět funkci `lm`.

```
> anova1 <- lm(Number ~ Location, data)
> summary(anova1)

Call:
lm(formula = Number ~ Location, data = data)

Residuals:
    Min      1Q  Median      3Q     Max 
-19.000 -4.517 -1.200  5.950 13.000 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 19.067     1.970   9.676 1.49e-13 ***
LocationLower 14.267     2.787   5.120 3.90e-06 ***
LocationMiddle 11.933     2.787   4.282 7.32e-05 ***
LocationTop    4.267     2.787   1.531    0.131  
---
Signif. codes:  0 `***' 0.001 `**' 0.01 `*' 0.05 `.' 0.1 ` ' 1

Residual standard error: 7.632 on 56 degrees of freedom
Multiple R-squared:  0.3779,    Adjusted R-squared:  0.3446 
F-statistic: 11.34 on 3 and 56 DF,  p-value: 6.459e-06
```

Systém R ale pracuje s jinou parametrizací, než jaká je uvedena v rovnici (1). První skupina pozorování je zvolena jako referenční (zde jsou to pozorování, u nichž má proměnná `Location` úroveň `Ground`) a je zavedena následující omezující podminka

$$\alpha_1 = \alpha_{ground} = 0.$$

Odhadnuté parametry pak mají tento význam:

$\hat{\mu}$  vyjadřuje střední hodnotu  $Y$  pro první (referenční) úroveň kategoriální proměnné,  $\hat{\alpha}_j$  vyjadřuje rozdíl ve střední hodnotě  $Y$  mezi první a  $j$ -tou úrovní kategoriální proměnné.

Z výpisu informací o modelu `anova1` zjistíme tyto údaje:

$$\begin{aligned} (\text{Intercept}) &= \hat{E}(Y_{ground}) = 19.067 \\ \text{LocationLower} &= \hat{E}(Y_{lower}) - \hat{E}(Y_{ground}) = 14.267 \\ \text{LocationMiddle} &= \hat{E}(Y_{middle}) - \hat{E}(Y_{ground}) = 11.933 \\ \text{LocationTop} &= \hat{E}(Y_{top}) - \hat{E}(Y_{ground}) = 4.267 \end{aligned}$$

A odtud můžeme dopočítat střední hodnoty pro jednotlivé úrovně Location:


$$\begin{aligned}\hat{E}(Y_{ground,k}) &= (\text{Intercept}) = 19.067 \\ \hat{E}(Y_{lower,k}) &= (\text{Intercept}) + \text{LocationLower} = 19.067 + 14.267 = 33.334 \\ \hat{E}(Y_{middle,k}) &= (\text{Intercept}) + \text{LocationMiddle} = 19.067 + 11.933 = 31 \\ \hat{E}(Y_{top,k}) &= (\text{Intercept}) + \text{LocationTop} = 19.067 + 4.267 = 23.334\end{aligned}$$

#### PŘÍKLAD 5: DVOUFAKTOROVÁ ANOVA

Pro stejná data týkající se odchycených můr zkusíme odhadnout model, v němž bychom zohlednili jak vliv umístění pasti, tak vliv zvolené návnady na počet můr, které se podařilo lapit do pasti.

Abychom si udělali představu, jak počet chycených můr ovlivňuje návnada, vykreslíme krabicové graf pro zjištěná dat zvlášť pro jednotlivé typy návnady.

```
> plot(data$Lure, data$Number, ylab = "Number")
```



Obrázek 9: Počet chycených můr v závislosti na typu návnady.

Situaci se pokusíme popsat modelem, do něhož zahrneme vliv obou kategorických proměnných. Nejprve zkusíme odhadnout jednodušší model

$$Y_{jkl} = \mu + \alpha_j + \beta_k + \varepsilon_{jkl}, \quad \begin{array}{ll} j = 1, 2, 3, 4 \\ \text{kde } k = 1, 2, 3 \\ l = 1, \dots, n_{jk} \end{array}$$

kde  $\alpha_j$  zachycuje vliv umístění pasti a  $\beta_k$  zachycuje vliv  $k$ -tého typu návnady a pro počty pozorování platí  $\sum_{j=1}^4 \sum_{k=1}^3 n_{jk} = n = 60$ .

```
> anova2 <- lm(Number ~ Lure + Location, data)
> summary(anova2)
```

```

Call:
lm(formula = Number ~ Lure + Location, data = data)

Residuals:
    Min      1Q  Median      3Q     Max 
-17.4500 -5.1208 -0.5167  6.0625 12.9333 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 19.883     2.415   8.234 4.14e-11 ***
LureScent   -2.750     2.415  -1.139   0.260    
LureSugar    0.300     2.415   0.124   0.902    
LocationLower 14.267     2.788   5.117 4.23e-06 ***
LocationMiddle 11.933     2.788   4.280 7.70e-05 ***
LocationTop   4.267     2.788   1.530   0.132    
---
Signif. codes:  0 `***' 0.001 `**' 0.01 `*' 0.05 `.' 0.1 ` ' 1

Residual standard error: 7.636 on 54 degrees of freedom
Multiple R-squared:  0.3995,    Adjusted R-squared:  0.3439 
F-statistic: 7.184 on 5 and 54 DF,  p-value: 3.236e-05


```

Systém R opět zvolil první úrovně faktorů jako referenční. Proto koeficient označený v tabulce jako `(Intercept)` představuje odhadnutou střední hodnotu chycených můr pro `Location = Ground` a `Lure = Chemical`. Zbylé koeficienty představují odchylky středních hodnot od referenční v případě, že se změní úroveň jedné z proměnných.

V modelu `anova2` jsme mlčky předpokládali, že vliv proměnných `Location` a `Lure` se sčítá, nebrali jsme v úvahu možnost, že by mohlo docházet ke složitějším interakcím mezi nimi.

Jak se mění průměrné hodnoty chycených můr pro různé kombinace úrovní obou vysvětlujících proměnných si můžeme prohlédnout v následujícím grafu.

```
> interaction.plot(data$Location, data$Lure, data$Number, xlab = "Location",
  ylab = "Number", trace.label = "Lure")
```



Obrázek 10: Porovnání průměrného počtu chycených můr v závislosti na umístění pasti a typu návnady.

Nyní odhadneme složitější model, který bude mít tvar

$$Y_{jkl} = \mu + \alpha_j + \beta_k + (\alpha\beta)_{jk} + \varepsilon_{jkl}, \quad \begin{aligned} j &= 1, 2, 3, 4 \\ k &= 1, 2, 3 \\ l &= 1, \dots, n_{jk} \end{aligned}$$

kde  $\alpha_j$  zachycuje vliv umístění pasti,  $\beta_k$  zachycuje vliv  $k$ -tého typu návnady a  $(\alpha\beta)_{jk}$  zachycuje vliv interakce mezi  $j$ -tou úrovní proměnné Location a  $k$ -tou úrovní proměnné Lure.

```
> anova3 <- lm(Number ~ Lure * Location, data)
> summary(anova3)
```

```
Call:
lm(formula = Number ~ Lure * Location, data = data)

Residuals:
    Min      1Q  Median      3Q     Max 
-15.80   -5.00   -0.90    5.85   14.20 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 19.200     3.555   5.400 2.04e-06 ***
LureScent   -2.200     5.028  -0.438  0.66367    
LureSugar    1.800     5.028   0.358  0.72191    
LocationLower 16.800     5.028   3.341  0.00162 **  
LocationMiddle 12.600     5.028   2.506  0.01565 *   
LocationTop   3.800     5.028   0.756  0.45347    
LureScent:LocationLower -1.000     7.111  -0.141  0.88875    
LureSugar:LocationLower -6.600     7.111  -0.928  0.35795    
LureScent:LocationMiddle -1.800     7.111  -0.253  0.80124    
LureSugar:LocationMiddle -0.200     7.111  -0.028  0.97768    
LureScent:LocationTop    0.600     7.111   0.084  0.93310    
LureSugar:LocationTop    0.800     7.111   0.113  0.91089    
---
Signif. codes:  0 `***' 0.001 `**' 0.01 `*' 0.05 `.' 0.1 ` ' 1

Residual standard error: 7.95 on 48 degrees of freedom
Multiple R-squared:  0.4214,    Adjusted R-squared:  0.2888 
F-statistic: 3.178 on 11 and 48 DF,  p-value: 0.002653
```

### PŘÍKLAD 6: ANCOVA

Při experimentu byla zkoumána závislost rychlosti růstu populace studenokrevných organismů na teplotě prostředí. V laboratoři byla sledována rychlosť populačního růstu (proměnná **rate**) u dvou druhů roztočů (kategoriální proměnná **genus** se dvěma úrovněmi **genA** a **genB**) při různých teplotách (proměnná **temp**).

Data jsou obsahem souboru **mite.txt**, v němž je na prvním řádku uvedena hlavička a hodnoty pro jednotlivé proměnné jsou odděleny tabelátorem. Proto k načtení použijeme funkci **read.table** s argumentem **sep = "\t"**.

```
> fileDat <- paste(data.library, "mite.txt", sep = "") 
> roztoci <- read.table(fileDat, sep = "\t", header = TRUE)
> str(roztoci)
```


```
'data.frame':      22 obs. of  3 variables:
 $ temp : num  10 12.5 15 18 20 22.5 25 27.5 30 32.5 ...
 $ rate : num  0.01 0.0759 0.1083 0.1505 0.1774 ...
 $ genus: Factor w/ 2 levels "genA","genB": 1 1 1 1 1 1 1 1 1 1 ...
```

> attach(roztoci)

Načtená data znázorníme graficky. Abychom si udělali představu o tom, jak se výsledky liší pro různé druhy roztočů, znázorníme jinou barvou údaje získané pro roztoče druhu A (bílá barva) a pro roztoče druhu B (černá barva).

Toho dosáhneme tak, že nejprve nakreslíme „prázdný“ graf a pak do něj zvlášť vykreslíme body reprezentující data pro druh A a pro druh B.

```
> plot(temp, rate, type = "n")
> points(temp[genus == "genA"], rate[genus == "genA"])
> points(temp[genus == "genB"], rate[genus == "genB"], pch = 16)
> legend("topleft", legend = c("genA", "genB"), pch = c(1, 16), bty = "n")
```



Obrázek 11: Závislost rychlosti růstu na teplotě pro dva druhy roztočů: "genA" (bílé), "genB" (černé).

Podle obrázku bychom mohli usoudit, že závislost rychlosti růstu populace na teplotě není lineární a navíc pro druh A je většinou o něco vyšší. To nás vede k tomu, že model popisující vztah proměnných, by mohl mít následující podobu

$$Y_{jk} = \mu + \alpha_j + \beta x_{jk} + \gamma x_{jk}^2 + \varepsilon_{jk},$$

kde  $Y$  označuje rychlosť růstu populace,  $x$  je teplota,  $j$  je index označující druh roztoče a  $k$  označuje konkrétní pozorování v rámci daného druhu.

Modely, v nichž figuruje alespoň jedna spojitá a alespoň jedna kategoriální proměnná, se nazývají *analýza kovariance* (ANCOVA).

```
> ancova <- lm(rate ~ temp + I(temp^2) + genus)
> summary(ancova)
```

```

Call:
lm(formula = rate ~ temp + I(temp^2) + genus)

Residuals:
    Min      1Q  Median      3Q     Max 
-0.013530 -0.006213 -0.002241  0.003962  0.017629 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) -3.111e-01  1.779e-02 -17.489 9.63e-13 ***
temp         4.060e-02  1.694e-03  23.966 4.15e-15 ***
I(temp^2)   -8.154e-04  3.719e-05 -21.927 1.96e-14 ***
genusgenB   -1.224e-02  4.128e-03 -2.966  0.00828 **  
---
Signif. codes:  0 `***' 0.001 `**' 0.01 `*' 0.05 `.' 0.1 ` ' 1

Residual standard error: 0.009682 on 18 degrees of freedom
Multiple R-squared:  0.9753,    Adjusted R-squared:  0.9712 
F-statistic: 237.1 on 3 and 18 DF,  p-value: 1.186e-14

```


Podobně jako v předchozích příkladech byl druh A vybrán jako referenční, a proto odhadnutý parametr `genusgenB` vyjadřuje odchylku druhu B od druhu A.

Výsledky odhadu modelu zobrazíme do grafu.

```

> grid <- seq(from = min(temp), to = max(temp), length.out = 300)
> predA <- predict(ancova, data.frame(temp = grid, genus = rep("genA",
+ 300)))
> predB <- predict(ancova, data.frame(temp = grid, genus = rep("genB",
+ 300)))
> plot(temp, rate, type = "n")
> points(temp[genus == "genA"], rate[genus == "genA"])
> points(temp[genus == "genB"], rate[genus == "genB"], pch = 16)
> matlines(grid, predA, col = "navy")
> matlines(grid, predB, col = "darkgreen")
> legend(x = 10.5, y = 0.2, legend = c("genA", "genB"), pch = c(1, 16),
+ col = c("navy", "darkgreen"), bty = "n")
> legend(x = 9, y = 0.18, legend = c("genA", "genB"), lty = 1, col = c("navy",
+ "darkgreen"), bty = "n")

```



Obrázek 12: Závislost rychlosti růstu na teplotě pro dva druhy roztočů: "genA" (bílé body, modrá čára), "genB" (černé body, zelená čára).