

M5VM05 Statistické modelování

5. Lineární regresní model

Jan Koláček (kolacek@math.muni.cz)

Ústav matematiky a statistiky, Přírodovědecká fakulta, Masarykova univerzita, Brno



Motivace

Často chceme prozkoumat vztah mezi dvěma veličinami, kde jedna z nich, tzv. „nezávisle proměnná“ X , má řídit druhou, tzv. „závisle proměnnou“ Y . Předpokládá se, že obě veličiny jsou spojité. Prvním krokem ve zkoumání by mělo být zakreslení dat do grafu. V řadě případů tento krok napoví mnohé o tom, co nás zajímá: Existuje vztah mezi oběma proměnnými (veličinami)? Pokud ano, pak rostou či klesají obě v jednom směru, nebo jedna klesá, když druhá roste? Je přímka vhodným modelem pro vyjádření vztahu mezi těmito dvěma veličinami? Chceme-li se dostat dále za tuto intuitivní úroveň analýzy, je lineární regrese často užitečným nástrojem. Tato metoda zahrnuje proložení přímky daty a analýzu statistických vlastností takovéto přímky.

Lineární regresní model

Předpokládejme, že mezi nějakými nenáhodnými veličinami y, x_1, \dots, x_k platí lineární vztah

$$y = \beta_1 x_1 + \dots + \beta_k x_k,$$

ve kterém β_1, \dots, β_k jsou neznámé parametry. Informace o neznámých parametrech budeme získávat pomocí experimentu, a to tak, že opakovaně budeme měřit hodnoty veličiny y při vybraných hodnotách proměnných x_1, \dots, x_k . Při měření však vznikají chyby, což lze modelovat takto

$$Y = \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon,$$

kde ε je náhodná chyba měření.

Opakované hodnoty sledovaných veličin budeme pro $i = 1, \dots, n$ značit $Y_i, x_{i1}, \dots, x_{ik}$, obdobně také náhodné chyby ε_i .

Lineární regresní model

Celkově jsme dostali model

$$\begin{aligned} Y_1 &= \beta_1 x_{11} + \cdots + \beta_k x_{1k} + \varepsilon_1 \\ &\vdots \\ Y_n &= \beta_1 x_{n1} + \cdots + \beta_k x_{nk} + \varepsilon_n \end{aligned} \quad \underbrace{\begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}}_{\mathbf{Y}} = \underbrace{\begin{pmatrix} x_{11} & \cdots & x_{1k} \\ \vdots & & \vdots \\ x_{n1} & \cdots & x_{nk} \end{pmatrix}}_{\mathbf{X} \text{ (matice plánu)}} \underbrace{\begin{pmatrix} \beta_1 \\ \vdots \\ \beta_k \end{pmatrix}}_{\boldsymbol{\beta}} + \underbrace{\begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}}_{\boldsymbol{\varepsilon}}$$

O náhodných chybách $\varepsilon_1, \dots, \varepsilon_n$ budeme předpokládat, že jsou

- **nesystematické**, což lze matematicky vyjádřit požadavkem, že $E\varepsilon_i = 0$,
 $i = 1, \dots, n$, tj. $E\varepsilon = \mathbf{0}$ a tedy $E\mathbf{Y} = \mathbf{X}\boldsymbol{\beta}$
- **homogenní v rozptylu**, tj. že $D\varepsilon_i = \sigma^2 > 0$ pro $i = 1, \dots, n$;
- jednotlivé náhodné chyby jsou **nekorelované**, tj. že $C(\varepsilon_i, \varepsilon_j) = 0$
pro $i \neq j, i, j = 1, \dots, n$, tj. $D\mathbf{Y} = D\varepsilon = \sigma^2 \mathbf{I}_n$, takže i měření jsou nekorelovaná.

Terminologie


Používá se následující **terminologie** a značení

- parametry β_1, \dots, β_k se nazývají **regresní koeficienty**;
- matice \mathbf{X} obsahuje nenáhodné prvky x_{ij} a nazývá se **regresní maticí** nebo **maticí plánu** (*Design Matrix*);
- popsaný model souhrnně zapíšeme jako $\mathbf{Y} \sim \mathcal{L}(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n)$.

Takto zavedený model budeme nazývat **linerární regresní model**. Dále budeme předpokládat, že $n > k$ a o hodnosti matice \mathbf{X} budeme předpokládat, že je rovna k , tj. $h(\mathbf{X}) = k$. Bude-li tento přepoklad splněn, budeme říkat, že jde **linerární regresní model plné hodnosti**. V tom případě jsou sloupce matice \mathbf{X} nezávislé. V opačném případě, by bylo možné daný sloupec matice \mathbf{X} napsat jako lineární kombinaci ostatních sloupců, což je možné interpretovat tak, že proměnná odpovídající danému sloupci je nadbytečná, protože ji lze vyjádřit jako lineární funkci ostatních proměnných.

Příklad

Regresní přímka v klasickém lineárním regresním modelu



Jednoduchá lineární regrese:

předpokládáme Y_i ($i = 1, \dots, n$) mají normální rozdělení

$$Y_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2),$$

kde x_i jsou dané konstanty, které nejsou všechny stejné.

$$\begin{aligned} Y_1 &= \beta_0 + \beta_1 x_1 + \varepsilon_1 \\ &\vdots \\ Y_n &= \beta_0 + \beta_1 x_n + \varepsilon_n \end{aligned}$$

V tomto případě

$$\mathbf{Y} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}, \quad \mathbf{X} = \begin{pmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix}, \quad \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix}, \quad \boldsymbol{\varepsilon} = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix} \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I}_n).$$

Odhady neznámých parametrů

Definice 1

Řekneme, že odhad $\hat{\beta} = \hat{\beta}(\mathbf{Y})$ je **lineárním odhadem** vektoru β , jestliže existuje matici reálných čísel $\mathbf{B}_{k \times n}$ taková, že $\hat{\beta} = \mathbf{B}\mathbf{Y}$.

Dále řekneme, že odhad $\hat{\beta} = \hat{\beta}(\mathbf{Y})$ je **nestranným odhadem** vektoru β , jestliže pro každé $\beta \in \mathbb{R}^k$ platí $E\hat{\beta} = \beta$.

Jestliže $\hat{\beta} = \hat{\beta}(\mathbf{Y})$ je takový lineární nestranný odhad vektoru parametrů β , že pro každý jiný lineární nestranný odhad $\tilde{\beta} = \tilde{\beta}(\mathbf{Y})$ je rozdíl variančních matic $D\tilde{\beta}(\mathbf{Y}) - D\hat{\beta}(\mathbf{Y})$ **pozitivně semidefinitní matici**, potom budeme říkat, že $\hat{\beta} = \hat{\beta}(\mathbf{Y})$ je **nejlepší nestranný lineární odhad** (*Best Linear Unbiased Estimator*) parametrů β , zkráceně *BLUE* odhad.

Metoda nejmenších čtverců

Definice 2

Řekneme, že odhad $\hat{\beta}_{OLS}$ je odhadem parametru β **metodou nejmenších čtverců**, jestliže

$$\hat{\beta}_{OLS} = \arg \min_{\beta \in \mathbb{R}^k} (\mathbf{Y} - \mathbf{X}\beta)'(\mathbf{Y} - \mathbf{X}\beta) = \arg \min_{\beta \in \mathbb{R}^k} \sum_{i=1}^n \left(Y_i - \sum_{j=1}^k x_{ij}\beta_j \right)^2$$

Věta 3

Odhad parametru β v modelu $\mathbf{Y} \sim \mathcal{L}(\mathbf{X}\beta, \sigma^2 \mathbf{I}_n)$ je tvaru

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

Důkaz

Důkaz Nejprve označme symbolem \mathbf{x}'_i i -tý řádek matice plánu \mathbf{X} a symbolem \mathbf{X}_j j -tý sloupec této matice, tj.

$$\mathbf{X} = \begin{pmatrix} x_{11} & \cdots & x_{1k} \\ \vdots & & \vdots \\ x_{n1} & \cdots & x_{nk} \end{pmatrix} = \begin{pmatrix} \mathbf{x}'_1 \\ \vdots \\ \mathbf{x}'_n \end{pmatrix} = (\mathbf{x}_1 \dots \mathbf{x}_k)$$

Nutnou podmínkou pro extrém je, aby parciální derivace byly nulové, tj. pro $s = 1, \dots, k$

$$0 = \frac{\partial}{\partial \beta_s} S(\boldsymbol{\beta}) = \frac{\partial}{\partial \beta_s} (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}) = \frac{\partial}{\partial \beta_s} \sum_{i=1}^n \left(Y_i - \sum_{j=1}^k x_{ij} \beta_j \right)^2.$$

Proto počítejme

$$\begin{aligned}\boxed{\frac{\partial}{\partial \beta_s} S(\boldsymbol{\beta})} &= \frac{\partial}{\partial \beta_s} \sum_{i=1}^n \left[Y_i^2 - 2Y_i \sum_{j=1}^k x_{ij} \beta_j + \left(\sum_{j=1}^k x_{ij} \beta_j \right)^2 \right] \\ &= -2 \sum_{i=1}^n Y_i x_{is} + 2 \sum_{i=1}^n \left(\sum_{j=1}^k x_{ij} \beta_j \right) x_{is} \\ &= -2 \sum_{i=1}^n Y_i x_{is} + 2 \sum_{i=1}^n \sum_{j=1}^k x_{ij} x_{is} \beta_j = \boxed{0}\end{aligned}$$

tj.

$$\boxed{\sum_{i=1}^n \sum_{j=1}^k x_{ij} x_{is} \beta_j = \sum_{i=1}^n Y_i x_{is}}.$$

Nyní se budeme snažit vyjádřit předchozí rovnost maticově. Upravujme postupně levou a pravou stranu:

$$\sum_{i=1}^n \sum_{j=1}^k x_{ij} x_{is} \beta_s = \sum_{i=1}^n x_{is} \underbrace{\sum_{j=1}^k x_{ij} \beta_j}_{=\mathbf{x}'_i \boldsymbol{\beta}} = \sum_{i=1}^n x_{is} \mathbf{x}'_i \boldsymbol{\beta} = \mathbf{X}'_s \underbrace{\begin{pmatrix} \mathbf{x}'_1 \boldsymbol{\beta} \\ \vdots \\ \mathbf{x}'_n \boldsymbol{\beta} \end{pmatrix}}_{=\mathbf{X} \boldsymbol{\beta}} = \mathbf{X}'_s \mathbf{X} \boldsymbol{\beta}$$

$$\sum_{i=1}^n Y_i x_{is} = \mathbf{X}'_s \mathbf{Y}$$

a celkově, zapíšeme-li k rovnic pod sebe a uvažujeme-li obě strany rovnosti, dostaneme

$$\underbrace{\begin{pmatrix} \mathbf{X}'_1 \\ \vdots \\ \mathbf{X}'_k \end{pmatrix}}_{=\mathbf{X}' \mathbf{X} \boldsymbol{\beta}} \underbrace{\begin{pmatrix} \mathbf{x}'_1 \\ \vdots \\ \mathbf{x}'_n \end{pmatrix}}_{=\mathbf{X}' \mathbf{Y}} \boldsymbol{\beta} = \underbrace{\begin{pmatrix} \mathbf{X}'_1 \\ \vdots \\ \mathbf{X}'_k \end{pmatrix}}_{=\mathbf{X}' \mathbf{Y}} \mathbf{Y} \quad \dots \quad \text{tzv. normální rovnice}$$

Vzhledem k předpokladu $h(\mathbf{X}) = h(\mathbf{X}' \mathbf{X}) = k$,

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

Nyní zbývá dokázat, že tento extrém je také minimem, tj. že matice druhých parciálních derivací je pozitivně semidefinitní matice. Proto počítejme (sh)-tý prvek matice druhých parciálních derivací

$$\begin{aligned}\frac{\partial^2}{\partial \beta_s \partial \beta_h} S(\boldsymbol{\beta}) &= \frac{\partial}{\partial \beta_h} \left[-2 \sum_{i=1}^n Y_i x_{is} + 2 \sum_{i=1}^n \sum_{j=1}^k x_{ij} x_{is} \beta_j \right] \\ &= 2 \sum_{i=1}^n x_{is} \underbrace{\frac{\partial}{\partial \beta_h} \left(\sum_{j=1}^k x_{ij} \beta_j \right)}_{=x_{ih}} = 2 \sum_{i=1}^n x_{is} x_{ih} = 2 \mathbf{x}'_s \mathbf{x}_h\end{aligned}$$

Takže matice druhých parciálních derivací je

$$\left(\frac{\partial^2 S(\boldsymbol{\beta})}{\partial \beta_s \partial \beta_h} \right)_{s,h=1}^k = \left(\sum_{i=1}^n x_{is} x_{ih} \right)_{s,h=1}^k = \mathbf{x}' \mathbf{x} > 0,$$

tj. jde o pozitivně definitní matici a tím je věta dokázaná.

Věty

Věta 4 (Gaussova-Markovova věta)

Odhad $\hat{\beta}_{OLS}$ v modelu $\mathbf{Y} \sim \mathcal{L}(\mathbf{X}\beta, \sigma^2\mathbf{I}_n)$ je BLUE-odhad (tj. je nejlepší nestranný lineární odhad) a jeho variační matice je rovna

$$D\hat{\beta}_{OLS} = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$$

Věta 5

Pro libovolný vektor $\mathbf{c} \in \mathbb{R}^k$ je $\mathbf{c}'\hat{\beta}_{OLS}$ BLUE-odhad parametrické funkce $\mathbf{c}'\beta$ a má rozptyl $\sigma^2\mathbf{c}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{c}$.

Věty

Věta 6

Platí

$$S_e = S(\hat{\beta}_{OLS}) = \mathbf{Y}'\mathbf{Y} - \hat{\beta}_{OLS}'\mathbf{X}'\mathbf{Y} = \mathbf{Y}'(\mathbf{I} - \mathbf{H})\mathbf{Y},$$

kde \mathbf{H} je tzv. „hat“ matici

$$\mathbf{H} = \mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'.$$

Věta 7

Odhad $s^2 = \frac{S_e}{n - k}$ je nestranným odhadem rozptylu σ^2 .

Příklad

Příklad 8

$$V LRM (\mathbf{Y}, \mathbf{X}, \boldsymbol{\beta}), \mathbf{X} = \begin{pmatrix} 1 & -1 & -3 \\ 1 & -1 & -2 \\ 1 & -1 & -1 \\ 1 & 1 & 1 \\ 1 & 1 & 2 \\ 1 & 1 & 3 \end{pmatrix}, \mathbf{Y} = \begin{pmatrix} 5 \\ 7 \\ 8 \\ 12 \\ 13 \\ 15 \end{pmatrix}$$

spočítejte MNČ-odhady

vektoru parametrů $\hat{\boldsymbol{\beta}}$, approximace $\hat{\mathbf{Y}}$, reziduální součty čtverců S_e a s^2 .

Řešení

Řešení Nejprve vypočteme matice

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} 6 & 0 & 0 \\ 0 & 6 & 12 \\ 0 & 12 & 28 \end{pmatrix}, (\mathbf{X}'\mathbf{X})^{-1} = \begin{pmatrix} 0,5 & 0 & -0,0714 \\ 0 & 0,0357 & 0 \\ -0,0714 & 0 & 0,0153 \end{pmatrix}.$$

Odtud pak

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y} = \begin{pmatrix} 10 \\ 1/3 \\ 3/2 \end{pmatrix} \text{ a } \hat{\mathbf{Y}} = \mathbf{X}\hat{\boldsymbol{\beta}} = \begin{pmatrix} 5,17 \\ 6,67 \\ 8,17 \\ 11,83 \\ 13,33 \\ 14,83 \end{pmatrix}.$$

Nakonec ještě

$$S_e = (\mathbf{Y} - \hat{\mathbf{Y}})'(\mathbf{Y} - \hat{\mathbf{Y}}) = 1/3, s^2 = \frac{S_e}{n-k} = \frac{1/3}{3} = 1/9.$$

Testování hypotéz v lineárním regresním modelu

Díky předchozím větám dokážeme v lineárním regresním modelu plné hodnosti vypočítat nejen OLS-odhady neznámých parametrů $\beta = (\beta_1, \dots, \beta_k)'$, ale také máme k dispozici odhad neznámého rozptylu σ^2 a známe vlastnosti těchto odhadů. V dalším se zaměříme na stanovení jejich rozdělení v případě, že náhodný vektor \mathbf{Y} má **vícerozměrné normální rozdělení**. Pak teprve budeme moci přejít k testování hypotéz o neznámých parametrech β_1, \dots, β_k . Jestliže náhodný vektor \mathbf{Y} se řídí lineárním regresním modelem plné hodnosti, což zapisujeme $\mathbf{Y} \sim \mathcal{L}(\mathbf{X}\beta, \sigma^2\mathbf{I}_n)$, a navíc má **vícerozměrné normální rozdělení**, budeme psát

$$\mathbf{Y} \sim N_n(\mathbf{X}\beta, \sigma^2\mathbf{I}_n).$$

Věta

Věta 9

Mějme lineární regresní model plné hodnosti, přičemž $\mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2\mathbf{I}_n)$. Pak platí

(a) OLS-odhad vektoru neznámých parametrů má normální rozdělení

$$\hat{\boldsymbol{\beta}}_{OLS} \sim N_k \left(\boldsymbol{\beta}, \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} \right)$$

(b) náhodná veličina

$$K = \frac{n-k}{\sigma^2} s^2 \sim \chi^2(n-k)$$

(c) náhodná veličina $K = \frac{n-k}{\sigma^2} s^2$ a OLS-odhad $\hat{\boldsymbol{\beta}}_{OLS}$ jsou nezávislé.

Test významnosti koeficientu β_j

Věta 10

V modelu $\mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2\mathbf{I}_n)$ plné hodnoty pro každé $\mathbf{c} \in \mathbb{R}^k$, $\mathbf{c} \neq \mathbf{0}$ platí

$$T = \frac{\mathbf{c}'\hat{\boldsymbol{\beta}}_{OLS} - \mathbf{c}'\boldsymbol{\beta}}{s\sqrt{\mathbf{c}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{c}}} \sim t(n-k).$$

Důsledek 11

V modelu $\mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2\mathbf{I}_n)$ plné hodnoty má $100(1 - \alpha)\%$ interval spolehlivosti pro parametrickou funkci $\mathbf{c}'\boldsymbol{\beta}$ (kde $\mathbf{c} \neq \mathbf{0}$) tvar

$$\left(\mathbf{c}'\hat{\boldsymbol{\beta}}_{OLS} - s\sqrt{\mathbf{c}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{c}} t_{1-\alpha/2}(n-k), \mathbf{c}'\hat{\boldsymbol{\beta}}_{OLS} + s\sqrt{\mathbf{c}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{c}} t_{1-\alpha/2}(n-k) \right).$$

Praktický test

Prakticky lze provést test hypotézy $H_0 : \mathbf{c}'\boldsymbol{\beta} = \gamma_0$ (γ_0 je dané reálné číslo) proti alternativě $H_1 : \mathbf{c}'\boldsymbol{\beta} \neq \gamma_0$ na hladině významnosti α tak, že hypotézu H_0 **zamítáme**, pokud platí

$$\frac{|\mathbf{c}'\hat{\boldsymbol{\beta}}_{OLS} - \gamma_0|}{s\sqrt{\mathbf{c}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{c}}} \geq t_{1-\alpha/2}(n-k)$$

Poznámka

V praktických situacích se nejčastěji volí vektor \mathbf{c} jako jednotkový s jedničkou na j -tém místě $\mathbf{c} = (0, \dots, 1, 0, \dots, 0)'$ a v tom případě $\boxed{\mathbf{c}'\boldsymbol{\beta} = \beta_j}$, takže

(a) $100(1 - \alpha)\%$ interval spolehlivosti má tvar (při značení $(\mathbf{X}'\mathbf{X})^{-1} = (v_{ij})_{i,j=1}^k$)

$$\left(\hat{\beta}_{OLS,j} - s\sqrt{v_{jj}} t_{1-\alpha/2}(n-k), \quad \hat{\beta}_{OLS,j} + s\sqrt{v_{jj}} t_{1-\alpha/2}(n-k) \right).$$

(b) Test hypotézy $H_0 : \beta_j = \gamma_0$ (γ_0 je dané reálné číslo) proti alternativě $H_1 : \beta_j \neq \gamma_0$ na hladině významnosti α se provede tak, že hypotézu H_0 **zamítáme**, pokud platí

$$\frac{|\hat{\beta}_{OLS,j} - \gamma_0|}{s\sqrt{v_{jj}}} \geq t_{1-\alpha/2}(n-k).$$

Test významnosti modelu

Zavedeme následující bloková značení:

$$\beta = (\underbrace{\beta_1, \dots, \beta_m}_{=\beta'_1}, \underbrace{\beta_{m+1}, \dots, \beta_k}_{=\beta'_2})'$$

obdobně

$$\hat{\beta}_{OLS} = (\hat{\beta}'_{OLS,1}, \hat{\beta}'_{OLS,2})'$$

a nakonec také pro matici

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} \mathbf{V}_{11} & \mathbf{V}_{12} \\ \mathbf{V}_{21} & \mathbf{V}_{22} \end{pmatrix},$$

kde matice \mathbf{V}_{11} je typu $m \times m$.

Věta 12

V modelu $\mathbf{Y} \sim N_n(\mathbf{X}\beta, \sigma^2 \mathbf{I}_n)$ plné hodnoty platí, že statistika

$$F = \frac{1}{s^2(k-m)} \left(\hat{\beta}_{OLS,2} - \beta_2 \right)' \mathbf{V}_{22}^{-1} \left(\hat{\beta}_{OLS,2} - \beta_2 \right) \sim F(k-m, n-k).$$

Poznámka

Díky předcházející větě můžeme testovat nulovou hypotézu

$$H_0 : \beta_2 = \beta_{2,0},$$

(kde $\beta_{2,0}$ je daný vektor reálných čísel, nejčastěji nulový vektor)

proti alternativě

$$H_1 : \beta_2 \neq \beta_{2,0}$$

na hladině významnosti α tak, že hypotézu H_0 **zamítáme**, pokud platí

$$F_0 = \frac{1}{s^2(k-m)} \left(\hat{\beta}_{OLS,2} - \beta_{2,0} \right)' \mathbf{V}_{22}^{-1} \left(\hat{\beta}_{OLS,2} - \beta_{2,0} \right) \geq F_{1-\alpha}(k-m, n-k).$$

Prakticky

Testujeme nulovou hypotézu

$$H_0 : (\beta_1, \dots, \beta_k) = (0, \dots, 0)$$

proti alternativě

$$H_1 : \exists i > 0; \beta_i \neq 0$$

na hladině významnosti α tak, že hypotézu H_0 **zamítáme**, pokud platí

$$F_0 = \frac{s_{\hat{Y}}^2}{s^2(k-1)} = \frac{ID}{1-ID} \frac{n-k}{k-1} \geq F_{1-\alpha}(k-1, n-k),$$

kde $s_{\hat{Y}}^2 = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$.

Příklad

Příklad 13

Pro data

x	-2	-1	0	1	2
Y	-2	1	-2	1	-1

spočítejte MNČ-odhady vektoru parametrů $\hat{\beta}$, approximace \hat{Y} , reziduální součty čtverců s^2 a index determinace ID v následujících modelech. Odhadnuté regresní funkce znázorněte také graficky.

- ① $y = \beta_0 + \beta_1 x$
- ② $y = \beta_1 x$
- ③ $y = \beta_0 + \beta_1 x + \beta_2 x^2$
- ④ $y = \beta_1 x + \beta_2 x^2$
- ⑤ $y = \beta_0 + \beta_1 x + \beta_2 e^x$

Testujte významnost koeficientů β_i , testujte významnost modelu pomocí statistiky F . Porovnejte vhodnost regresních modelů pomocí F , s^2 a ID.

Řešení

Řešení Pro jednotlivé modely počítejme postupně

① $y = \beta_0 + \beta_1 x$

$\hat{\beta} = (-0,6; 0,2)', \hat{Y} = (-1; -0,8; -0,6; -0,4; -0,2)', s^2 = 2,93,$
 $ID = 0,04348, F = 0,136, p\text{-hodnoty pro jednotlivé koeficienty: } (0,49; 0,73)$

② $y = \beta_1 x$

$\hat{\beta}_1 = 0,2, \hat{Y} = (-0,4; -0,2; 0; 0,2; 0,4)', s^2 = 2,65, ID = 0,0363,$
 $F = 0,15, p\text{-hodnoty pro jednotlivé koeficienty: } 0,717$

③ $y = \beta_0 + \beta_1 x + \beta_2 x^2$

$\hat{\beta} = (-0,0286; 0,2; -0,2857)',$
 $\hat{Y} = (-1,5714; -0,5143; -0,0286; -0,1143; -0,7714)', s^2 = 3,8286,$
 $ID = 0,1677, F = 0,2015, p\text{-hodnoty pro jednotlivé koeficienty: }$
 $(0,985; 0,777; 0,6396)$

④ $y = \beta_1 x + \beta_2 x^2$

$$\hat{\beta} = (0,2; -0,2941)', \hat{Y} = (-1,576; -0,4941; 0; -0,0941; -0,776)',$$

$s^2 = 2,55$, $ID = 0,3037$, $F = 0,654$, p -hodnoty pro jednotlivé koeficienty:
 $(0,718; 0,362)$

⑤ $y = \beta_0 + \beta_1 x + \beta_2 e^x$

$$\hat{\beta} = (0,291; 0,847; -0,384)',$$

$$\hat{Y} = (-1,4547; -0,6969; -0,0926; 0,0949; -0,851)', s^2 = 3,8283,$$

$ID = 0,1677$, $F = 0,2015$, p -hodnoty pro jednotlivé koeficienty:
 $(0,8894; 0,59; 0,639)$.

Speciální modely lineární regrese

MODEL I: **Regresní přímka** $Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$, $i = 1, \dots, n$; $n > 2$.

$$\text{Matice plánu } \mathbf{X} = \begin{pmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix}, \quad \mathbf{X}'\mathbf{X} = \begin{pmatrix} n & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{pmatrix}, \quad \mathbf{X}'\mathbf{Y} = \begin{pmatrix} \sum_{i=1}^n Y_i \\ \sum_{i=1}^n x_i Y_i \end{pmatrix}$$

Model bude plné hodnosti, pokud všechny hodnoty x_1, \dots, x_n nebudou stejné.

Normální rovnice jsou tvaru:

$$\begin{aligned} \beta_0 n + \beta_1 \sum_{i=1}^n x_i &= \sum_{i=1}^n Y_i \\ \beta_0 \sum_{i=1}^n x_i + \beta_1 \sum_{i=1}^n x_i^2 &= \sum_{i=1}^n x_i Y_i \end{aligned}$$

Speciální modely lineární regrese

MODEL II: Regrese procházející počátkem $Y_i = \beta x_i + \varepsilon_i, i = 1, \dots, n; n > 1.$

Matice plánu \mathbf{X} $= \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}, \quad \mathbf{X}'\mathbf{X} = \left(\sum_{i=1}^n x_i^2 \right), \quad \mathbf{X}'\mathbf{Y} = \left(\sum_{i=1}^n x_i Y_i \right)$

a model bude plné hodnosti, pokud alespoň jedna z hodnot x_1, \dots, x_n bude různá od nuly.

Normální rovnice:

$$\beta \sum_{i=1}^n x_i^2 = \sum_{i=1}^n x_i Y_i$$

Speciální modely lineární regrese

MODEL III: Kvadratická regrese $Y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \varepsilon_i$,
 $i = 1, \dots, n; n > 3.$

Matice plánu \mathbf{X} =
$$\begin{pmatrix} 1 & x_1 & x_1^2 \\ \vdots & \vdots & \vdots \\ 1 & x_n & x_n^2 \end{pmatrix}, \quad \mathbf{X}'\mathbf{X} = \begin{pmatrix} n & \sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \\ \sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 & \sum_{i=1}^n x_i^3 \\ \sum_{i=1}^n x_i^2 & \sum_{i=1}^n x_i^3 & \sum_{i=1}^n x_i^4 \end{pmatrix},$$

$\mathbf{X}'\mathbf{Y}$ =
$$\begin{pmatrix} \sum_{i=1}^n Y_i \\ \sum_{i=1}^n x_i Y_i \\ \sum_{i=1}^n x_i^2 Y_i \end{pmatrix}, \quad \text{Norm. rov.:} \quad \begin{aligned} \beta_0 n + \beta_1 \sum_{i=1}^n x_i + \beta_2 \sum_{i=1}^n x_i^2 &= \sum_{i=1}^n Y_i \\ \beta_0 \sum_{i=1}^n x_i + \beta_1 \sum_{i=1}^n x_i^2 + \beta_2 \sum_{i=1}^n x_i^3 &= \sum_{i=1}^n x_i Y_i \\ \beta_0 \sum_{i=1}^n x_i^2 + \beta_1 \sum_{i=1}^n x_i^3 + \beta_2 \sum_{i=1}^n x_i^4 &= \sum_{i=1}^n x_i^2 Y_i \end{aligned}$$

Speciální modely lineární regrese

MODEL IV: Polynomická regrese $Y_i = \beta_0 + \beta_1 x_i + \dots + \beta_m x_i^m + \varepsilon_i$,
 $i=1, \dots, n; n > m+1$.


$$\mathbf{X} = \begin{pmatrix} 1 & x_1 & \cdots & x_1^m \\ \vdots & \vdots & \cdots & \vdots \\ \vdots & \vdots & \cdots & \vdots \\ 1 & x_n & \cdots & x_n^m \end{pmatrix}, \quad \mathbf{X}'\mathbf{X} = \begin{pmatrix} n & \sum_{i=1}^n x_i & \cdots & \sum_{i=1}^n x_i^m \\ \sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 & \cdots & \sum_{i=1}^n x_i^{m+1} \\ \vdots & \vdots & \ddots & \vdots \\ \sum_{i=1}^n x_i^m & \sum_{i=1}^n x_i^{m+1} & \cdots & \sum_{i=1}^n x_i^{2m} \end{pmatrix},$$
$$\mathbf{X}'\mathbf{Y} = \begin{pmatrix} \sum_{i=1}^n Y_i \\ \sum_{i=1}^n x_i Y_i \\ \vdots \\ \sum_{i=1}^n x_i^m Y_i \end{pmatrix}$$

Příklad

Příklad 14


Analyzujte data o počtu pracovních hodin za měsíc Y spojených s provozováním anesteziologické služby v závislosti na velikosti spádové populace nemocnice X (v tisících). Údaje byly získány ve 12 nemocnicích ve Spojených státech.

i	Y	X
1	304,37	25,5
2	2616,32	294,3
3	1139,12	83,7
4	285,43	30,7
5	1413,77	129,8
6	1555,68	180,8
7	383,78	43,4
8	2174,27	165,2
9	845,30	74,3
10	1125,28	60,8
11	3462,60	319,2
12	3682,33	376,2



Řešení

Graf naznačuje lineární vztah mezi pracovní dobou a velikostí populace, a tak budeme pokračovat kvantifikací tohoto vztahu pomocí přímky $y = \beta_0 + \beta_1 x$.



Řešení

Parametr	Koeficient	SE koef.	t-statistika	p-hodnota
β_0	180,658	128,381	1,407	0,1896823
β_1	9,429	0,681	13,847	7,520972e-08

Z tabulky tedy dostáváme:


$$\text{pracovní doba} = 180,658 + 9,429 \cdot \text{velikost populace.}$$

Co je na tom divného?

Řešení


Oboustranný interval spolehlivosti pro
 β_0

$$180,6575 \pm 2,228 \cdot 128,3812 = 180,6575 \pm 286,051$$



Oboustranný interval spolehlivosti pro
 β_1

$$9,429 \pm 2,228 \cdot 0,681 = 9,429 \pm 1,517$$




Řešení

Uvažujeme **regresi procházející počátkem** (plná čára) a výsledek srovnáme s obecnou regresní přímkou (čárkovaná čára).


$$\hat{\beta}_1^* = 10,185 \quad \hat{s}_{\beta_1^*} = 0,4371,$$
$$t^* = 3,30157,$$
$$p^*\text{-hodnota} = 1,0318e-10$$

Oboustranný interval spolehlivosti pro
 $\hat{\beta}_1^*$

$$10,185 \pm 2,2 \cdot 0,4371 = 10,185 \pm 0,962$$



pracovní doba =
 $10,185 \cdot \text{velikost populace.}$



Speciální modely lineární regrese

MODEL VI: Dvě regresní přímky (se stejným rozptylem).

Mějme dva nezávislé náhodné výběry Y_{11}, \dots, Y_{1n_1} (resp. Y_{21}, \dots, Y_{2n_2}) a k tomu odpovídající hodnoty regresorů x_{11}, \dots, x_{1n_1} (resp. x_{21}, \dots, x_{2n_2}). Předpokládejme, že platí

$$Y_{1i} = a_1 + b_1 x_{1i} + \varepsilon_{1i}, \quad i = 1, \dots, n_1, \quad \varepsilon_{1i} \sim N(0, \sigma_1^2)$$

$$Y_{2i} = a_2 + b_2 x_{2i} + \varepsilon_{2i}, \quad i = 1, \dots, n_2, \quad \varepsilon_{2i} \sim N(0, \sigma_2^2)$$

Speciální modely lineární regrese

Vytvořme společný regresní model:

$$\begin{pmatrix} Y_{11} \\ \vdots \\ Y_{1n_1} \\ Y_{21} \\ \vdots \\ Y_{2n_2} \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{1n_1} & 0 & 0 \\ 0 & 0 & 1 & x_{21} \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 1 & x_{2n_2} \end{pmatrix} \begin{pmatrix} a_1 \\ b_1 \\ a_2 \\ b_2 \end{pmatrix} + \begin{pmatrix} \varepsilon_{11} \\ \vdots \\ \varepsilon_{1n_1} \\ \varepsilon_{21} \\ \vdots \\ \varepsilon_{2n_2} \end{pmatrix}.$$

Vyjádřeno blokově:

$$\begin{pmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \end{pmatrix} = \begin{pmatrix} \mathbf{x}_1 & \mathbf{0} \\ \mathbf{0} & \mathbf{x}_2 \end{pmatrix} \begin{pmatrix} \beta_1 \\ \beta_2 \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \end{pmatrix}$$

Speciální modely lineární regrese

Počítejme postupně

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} \mathbf{X}_1'\mathbf{X}_1 & \mathbf{0} \\ \mathbf{0} & \mathbf{X}_2'\mathbf{X}_2 \end{pmatrix}, \quad \mathbf{X}'\mathbf{Y} = \begin{pmatrix} \mathbf{X}_1'\mathbf{Y}_1 \\ \mathbf{X}_2'\mathbf{Y}_2 \end{pmatrix} \text{ a}$$
$$\hat{\boldsymbol{\beta}} = \begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} = \begin{pmatrix} (\mathbf{X}_1'\mathbf{X}_1)^{-1} \mathbf{X}_1'\mathbf{Y}_1 \\ (\mathbf{X}_2'\mathbf{X}_2)^{-1} \mathbf{X}_2'\mathbf{Y}_2 \end{pmatrix}.$$

Označme

$$\hat{\boldsymbol{\varepsilon}} = \mathbf{Y} - \hat{\mathbf{Y}} = \mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}} = \begin{pmatrix} \hat{\varepsilon}_1 \\ \hat{\varepsilon}_2 \end{pmatrix} = \begin{pmatrix} \mathbf{Y}_1 - \hat{\mathbf{Y}}_1 \\ \mathbf{Y}_2 - \hat{\mathbf{Y}}_2 \end{pmatrix} = \begin{pmatrix} \mathbf{Y}_1 - \mathbf{X}_1\hat{\beta}_1 \\ \mathbf{Y}_2 - \mathbf{X}_2\hat{\beta}_2 \end{pmatrix}$$

Pak

$$SSE = \hat{\boldsymbol{\varepsilon}}' \hat{\boldsymbol{\varepsilon}} = \hat{\varepsilon}_1' \hat{\varepsilon}_1 + \hat{\varepsilon}_2' \hat{\varepsilon}_2 = SSE_1 + SSE_2$$

a

$$\begin{aligned} s_1^2 &= \frac{SSE_1}{n_1-2} = \frac{\hat{\varepsilon}_1' \hat{\varepsilon}_1}{n_1-2} & \Rightarrow & \quad s^2 = \frac{SSE}{n_1+n_2-4} = \frac{(n_1-2)s_1^2 + (n_2-2)s_2^2}{n_1+n_2-4} \\ s_2^2 &= \frac{SSE_2}{n_2-2} = \frac{\hat{\varepsilon}_2' \hat{\varepsilon}_2}{n_2-2} \end{aligned}$$

Testování rovnoběžnosti dvou regresních přímek

Při testování hypotézy $H_0 : b_1 = b_2$ proti alternativě $H_1 : b_1 \neq b_2$ využijeme toho, že statistika

$$T = \frac{\mathbf{c}' \hat{\boldsymbol{\beta}} - \mathbf{c}' \boldsymbol{\beta}}{\sqrt{s^2 \mathbf{c}' (\mathbf{X}' \mathbf{X})^{-1} \mathbf{c}}} \sim t(n - k).$$

Položme

$$\mathbf{c} = (0, 1, 0, -1) \Rightarrow \mathbf{c}' (\mathbf{X}' \mathbf{X})^{-1} \mathbf{c} = v_{22} + v_{44}, (\mathbf{X}' \mathbf{X})^{-1} = \begin{pmatrix} v_{11} & v_{12} & v_{13} & v_{14} \\ v_{21} & v_{22} & v_{23} & v_{24} \\ v_{31} & v_{32} & v_{33} & v_{34} \\ v_{41} & v_{42} & v_{43} & v_{44} \end{pmatrix}$$

Za platnosti nulové hypotézy statistika

$$T_0 = \frac{\hat{b}_1 - \hat{b}_2}{s\sqrt{v_{22} + v_{44}}} \sim t(n_1 + n_2 - 4).$$

Nulovou hypotézu zamítáme na hladině významnosti α , pokud

$$|t_0| > t_{1-\frac{\alpha}{2}}(n_1 + n_2 - 4)$$

Testování shodnosti dvou regresních přímek

Budeme testovat hypotézu $H_0 : \beta_1 = \beta_2$ proti alternativě $H_1 : \beta_1 \neq \beta_2$.

Využijeme vlastnosti

$$\hat{\beta}_1 - \hat{\beta}_2 \sim N\left(\beta_1 - \beta_2, \sigma^2 \underbrace{\left((\mathbf{X}'_1 \mathbf{X}_1)^{-1} + (\mathbf{X}'_2 \mathbf{X}_2)^{-1}\right)}_W\right).$$

a

$$K_1 = \frac{1}{\sigma^2} (\hat{\beta}_1 - \hat{\beta}_2)' W^{-1} (\hat{\beta}_1 - \hat{\beta}_2) \sim \chi^2(2),$$

dále

$$K_2 = \frac{SSE}{\sigma^2} = \frac{(n_1 + n_2 - 4)s^2}{\sigma^2} \sim \chi^2(n_1 + n_2 - 4),$$

takže k testování nulové hypotézy použijeme statistiku

$$F_0 = \frac{K_1/2}{K_2/(n_1+n_2-4)} = \frac{1}{2s^2} (\hat{\beta}_1 - \hat{\beta}_2)' W^{-1} (\hat{\beta}_1 - \hat{\beta}_2) \sim F(2, n_1 + n_2 - 4)$$

a **nulovou hypotézu zamítáme** na hladině významnosti α , pokud

$$f_0 < F_{\frac{\alpha}{2}}(2, n_1 + n_2 - 4) \text{ nebo } f_0 > F_{1-\frac{\alpha}{2}}(2, n_1 + n_2 - 4)$$

Ověřování shodnosti rozptylů

Při testování hypotézy $H_0 : \sigma_1^2 = \sigma_2^2$ proti alternativě $H_1 : \sigma_1^2 \neq \sigma_2^2$ využijeme toho, že statistika

$$F_0 = \frac{\frac{SSE_1}{(n_1-2)\sigma^2}}{\frac{SSE_2}{(n_2-2)\sigma^2}} = \frac{s_1^2}{s_2^2} \sim F(n_1 - 2, n_2 - 2)$$

a **nulovou hypotézu zamítáme** na hladině významnosti α , pokud

$$f_0 < F_{\frac{\alpha}{2}}(n_1 - 2, n_2 - 2) \text{ nebo } f_0 > F_{1-\frac{\alpha}{2}}(n_1 - 2, n_2 - 2)$$

Příklad

Příklad 15

V souboru „teploty.Rdata“ jsou uvedeny průměrné roční teploty v Praze (proměnná Y_1) a ve Velkých Pavlovicích (proměnná Y_2) v letech 1978 – 1995 (proměnná x). Předpokládejme, že závislost teplot na čase lze popsat regresní přímkou. Na hladině významnosti $\alpha = 0,05$ testujte hypotézy:

- (a) H_0 : vzestup teplot byl stejný na obou stanovištích
- (b) H_0 : průběh teplot byl stejný na obou stanovištích
- (c) H_0 : rozptyl teplot byl stejný na obou stanovištích
- (d) Vykreslete graf obou regresních přímk

Řešení

(a) Vypočteme odhady parametrů $\hat{b}_1 = 0,091$, $\hat{b}_2 = 0,0885$ a také $s^2 = 0,4334$. V našem případě je $v_{22} = v_{44} = 0,002$ a můžeme vypočítat hodnotu testové statistiky

$$t_0 = \frac{\hat{b}_1 - \hat{b}_2}{s\sqrt{v_{22} + v_{44}}} = 0,0603,$$

kterou porovnáme s kvantilem Studentova rozdělení $t_{0,975}(32) = 2,037$.

Protože $|t_0| < t_{0,975}(32)$, hypotézu H_0 na dané hladině významnosti **nezamítáme**.

(b) Vypočteme odhady parametrů $\hat{\beta}_1 = (-170,44; 0,091)'$,

$\hat{\beta}_2 = (-166,31; 0,0885)'$ a také matici $W = \begin{pmatrix} 16289,82 & -8,2 \\ -8,2 & 0,0041 \end{pmatrix}$. Pak

tedy $K_1 = (\hat{\beta}_1 - \hat{\beta}_2)' W^{-1} (\hat{\beta}_1 - \hat{\beta}_2) = 7,9$ a $K_2 = s^2 = 0,4334$. Pro testování hypotézy použijeme statistiku

$$f_0 = \frac{K_1}{2K_2} = 9,122,$$

kterou porovnáme s kvantily Fisherova–Snedecorova rozdělení


$f_{0,025}(2,32) = 0,025$ a $f_{0,975}(2,32) = 4,149$. Protože $f_0 > f_{0,975}(2,32)$, hypotézu H_0 na dané hladině významnosti **zamítáme**.

Řešení

- (c) Vypočteme odhady parametrů $s_1^2 = 0,4308$ a $s_2^2 = 0,436$. Pro testování hypotézy použijeme statistiku

$$f_0 = \frac{s_1^2}{s_2^2} = 0,988,$$

kterou porovnáme s kvantily Fisherova–Snedecorova rozdělení $f_{0,025}(16, 16) = 0,3621$ a $f_{0,975}(16, 16) = 2,7614$. Protože f_0 je mezi oběma hodnotami, hypotézu H_0 na dané hladině významnosti **nezamítáme**.



Úlohy k procvičení

Příklad 1.1

$$V LRM (\mathbf{Y}, \mathbf{X}, \boldsymbol{\beta}), \mathbf{X} = \begin{pmatrix} 1 & -3 & 9 \\ 1 & -2 & 4 \\ 1 & -1 & 1 \\ 1 & 1 & 1 \\ 1 & 2 & 4 \\ 1 & 3 & 9 \end{pmatrix}, \mathbf{Y} = \begin{pmatrix} 7 \\ 4 \\ 2 \\ 2 \\ 5 \\ 8 \end{pmatrix}$$

spočítejte MNČ-odhady

vektoru parametrů $\hat{\boldsymbol{\beta}}$, approximace $\hat{\mathbf{Y}}$, reziduální součty čtverců S_e a s^2 .

$$[\hat{\boldsymbol{\beta}} = (1,5; 0,1786; 0,6786)', \hat{\mathbf{Y}} = (7,0714; 3,8571; 2; 2,3571; 4,5714; 8,1429)', S_e = 0,3571, s^2 = 0,119.]$$

Úlohy k procvičení

Příklad 1.2

Pro data

x	-2	-1	0	1	2
Y	0	2	3	3	1

spočítejte $MNČ$ -odhad vektoru parametrů $\hat{\beta}$, approximace \widehat{Y} , reziduální součty čtverců S_e a s^2 ve dvou modelech. Který model je vhodnější? (Proč?) Oba modely vykreslete.

(a) model s regresní funkcí $Y = \beta_0 + \beta_1 x + \beta_2 x^2$

$$\begin{pmatrix} 1 & 4 \\ 1 & 1 \\ 0 & 0 \\ 1 & 1 \\ 1 & 4 \end{pmatrix}$$

(b) model s maticí plánu $X =$

$[(a) \hat{\beta} = (3,09; 0,3; -0,64)', \widehat{Y} = (-0,086; 2,143; 3,086; 2,743; 1,114)', S_e = 0,114, s^2 = 0,057.$

$(b) \hat{\beta} = (3,17; -0,67)', \widehat{Y} = (0,5; 2,5; 0; 2,5; 0,5)', S_e = 10, s^2 = 3,33.]$

Úlohy k procvičení

Příklad 1.3

Pomocí regresní přímky procházející počátkem spočítejte MNČ-odhadu vektoru parametrů $\hat{\beta}$, approximace \hat{Y} , reziduální součty čtverců S_e a s^2 v LRM (Y, X, β) pro data

x	10	20	30	40	50	60
Y	0,18	0,35	0,48	0,65	0,84	0,97

Jedná se o měření teplotní délkové roztažnosti měděné trubky. Rozdíl teploty od referenční $20^\circ C$ je x , prodloužení tyče je měřená veličina Y .

$$[\hat{\beta} = 0,0164, \hat{Y} = (0,164; 0,328; 0,493; 0,657; 0,821; 0,985)', S_e = 0,0015, s^2 = 0,0003.]$$

Úlohy k procvičení

Příklad 1.4

U 126 podniků řepařské oblasti v České Republice byl sledován hektarový výnos cukrovky ve vztahu ke spotřebě průmyslových hnojiv.

Data jsou uložena v souboru „cukrovka.Rdata“ ve 4 sloupcích:

- ① dolní hranice spotřeby K_2O (kg/ha)
- ② horní hranice spotřeby K_2O (kg/ha)
- ③ četnosti
- ④ průměrné výnosy cukrovky (q/ha)

- a) odhadněte parametry regresní funkce tvaru

$$y = \beta_0 + \beta_1 x$$

$$y = \beta_0 + \beta_1 x + \beta_2 x^2$$

$$y = \beta_0 + \beta_1 x^{0,5}$$

Poznámka: Za hodnoty nezávisle proměnné volte střed intervalu.

- b) Porovnejte vhodnost tří použitých regresních modelů.

Úlohy k procvičení

Příklad 1.5

U 19 vzorků potravinářské pšenice byl zjištován obsah zinku v zrnu (proměnná Y), v kořenech (proměnná X_1), v otrubách (proměnná X_2) a ve stonku a listech (proměnná X_3). Data jsou uložena v souboru „*psenice.Rdata*“.

- a) Předpokládejte, že je vhodný regresní model

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3.$$

Odhadněte regresní koeficienty a rozptyl, vypočtěte vektor predikce a index determinace. Proveďte celkový F -test a dílčí t -testy. Hladinu významnosti volte 0,05. Normalitu reziduů posudte graficky pomocí funkce *qqnorm*.

- b) Z regresního modelu odstraňte ty proměnné, jejichž regresní koeficienty se ukázaly nevýznamné pro $\alpha = 0,05$. Sestavte nový regresní model a provedte v něm všechny úkoly z bodu a).