

## M6120 – 8. CVIČENÍ : M6120cv08 (Metody regresní diagnostiky)

### A. Míry influence v regresní diagnostice

V praxi se často můžeme setkat s jevem, že v souboru dat se vyskytují některé hodnoty výrazně se liší od hodnot ostatních. V literatuře se v průběhu minulých let rozvinuly dva směry, které se svým způsobem snaží s jejich existencí vyrovnat.

- metody robustní statistiky
- metody regresní diagnostiky

Regresní diagnostika jde cestou detekovat více či méně ojedinělá data a dát původci dat možnost rozhodnout se, jak s nimi v případě výskytu dále naložit, tj. zda je v souboru ponechat či vyloučit, věnovat jím menší váhu při zpracování, popřípadě je vhodně transformovat apod. V rámci regresní diagnostiky se budeme zabývat dvěma základními úlohami

- jak detektovat mezi daty neočekávané hodnoty
- jak rozhodnout, zda mohou významně ovlivnit statistickou analýzu, případně jakým způsobem.

Pokud se zabýváme detekcí neočekávaných hodnot v datech, v zásadě může jít o

- neočekávané hodnoty vysvětlované proměnné, tzv. **odlehlá pozorování** (*outliers*);
- neočekávané hodnoty vektoru vysvětlujících proměnných, tzv. **vybočující body** (*leverage points*);
- v některých případech může jít dokonce o data, jež lze zařadit do obou skupin.

Jejich výskyt nemusí nutně významně ovlivnit analýzu dat, nebot' takováto měření mohou být plně ve shodě s předpokládaným modelem.

Většinou je tomu však naopak a odlehlá pozorování i vybočující body hrají významnou roli pro výsledky regresní analýzy.

Na druhé straně i některé další body mohou mít významný vliv at' již na  $\hat{\beta}$ ,  $\hat{\beta}_i$ ,  $D\beta$ ,  $\hat{Y}$  apod.

Všechny body, jež nějakým způsobem ovlivňují podstatně analýzu dat, tj. některou z charakteristik spojených s odhadem vektoru parametrů v lineárním modelu a testováním hypotéz o nich, nazveme **vlivnými body**.

Základním diagnostickým nástrojem v regresní analýze jsou **rezidua**.

Připomeňme definici a vlastnosti regresního modelu a zaved'me celou škálu diagnostických měr influnce.

**Regresní model** 
$$\boxed{\mathbf{Y} = \mathbf{X}\beta + \epsilon \wedge E\epsilon = 0 \wedge var\epsilon = \sigma^2 \mathbf{I}_n \wedge h(\mathbf{X}) = k = p + 1}.$$

Odhady metodou nejmenších čtverců:

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

**Projekční matice**  $\boxed{\mathbf{H}} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$  je idempotentní  $\mathbf{H}^2 = \mathbf{H}$   
symetrická  $\mathbf{H}' = \mathbf{H}$

Označme matici  $\mathbf{H} = \begin{pmatrix} h_{11} & \cdots & h_{1n} \\ \vdots & \ddots & \vdots \\ h_{n1} & \cdots & h_{nn} \end{pmatrix} = (\mathbf{H}_1, \dots, \mathbf{H}_n)$ . Pak  $\widehat{\mathbf{Y}} = \mathbf{HY}$ .

Protože  $Y_i = \mathbf{H}'_i \mathbf{Y} = \sum_{j=1}^n h_{ij} Y_j$ , vidíme, jak pozorování  $Y_j$  ovlivňuje  $i$ -tou odhadovanou hodnotu  $\widehat{Y}_i$ .

**Definice 1:** Sloupce matice  $\mathbf{H}$  se nazývají **vlivové vektory** a  $\|\mathbf{H}_j\|^2$  se nazývá **vliv j-tého pozorování** na odhad  $\widehat{\mathbf{Y}}$ , stručně **j-tý vliv**.

**Věta 1:**  $\boxed{\|\mathbf{H}_j\|^2 = h_{jj}}$ .

Důkaz:  $\|\mathbf{H}_j\|^2 = \mathbf{H}'_j \mathbf{H}_j = \sum_{i=1}^n h_{ij} h_{ij} \wedge \mathbf{H}^2 = \mathbf{H} \Rightarrow h_{jj} = \mathbf{H}'_j \mathbf{H}_j$

**Věta 2:**  $\boxed{\bigvee_{i=1}^n 0 \leq h_{ii} \leq 1}$ .

Důkaz:  $\mathbf{H}^2 = \mathbf{H} \Rightarrow h_{ii} > 0$ ;  $h_{ii} = \sum_{j=1}^n h_{ij} h_{ij} = h_{ii}^2 + \sum_{i \neq j} h_{ij}^2 \Rightarrow h_{ii} > h_{ii}^2 \Rightarrow h_{ii} < 1$

**Věta 3:**  $\boxed{tr \mathbf{H} = k}$

Důkaz:  $\mathbf{H}^2 = \mathbf{H}$  je idempotentní  $\Rightarrow tr \mathbf{H} = h(\mathbf{H})$ . Užitím věty o součinu matic lze odvodit, že  $h(\mathbf{H}) = h(\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}') = k$ .

**Věta 4:** Průměrný vliv pozorování  $Y_1, \dots, Y_n$  je roven  $\boxed{\frac{k}{n}}$ .

Důkaz:  $\sum_{i=1}^n h_{ii} = k \Rightarrow \bar{h} = \frac{1}{n}(\|\mathbf{H}_1\|^2 + \dots + \|\mathbf{H}_n\|^2) = \frac{1}{n} \sum_{i=1}^n h_{ii} = \frac{k}{n}$ .

**Definice 2:** Definujme vektor reziduů:  $\boxed{\mathbf{r} = \mathbf{Y} - \widehat{\mathbf{Y}}}$ .

**Věta 5:**  $\boxed{\mathbf{r} = (\mathbf{I} - \mathbf{H})\boldsymbol{\varepsilon}}$

Důkaz:  $\mathbf{r} = \mathbf{Y} - \mathbf{HY} = (\mathbf{I} - \mathbf{H})\mathbf{Y} = (\mathbf{I} - \mathbf{H})(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}) = \underbrace{(\mathbf{I} - \mathbf{H})\mathbf{X}\boldsymbol{\beta}}_{=0} + (\mathbf{I} - \mathbf{H})\boldsymbol{\varepsilon} = (\mathbf{I} - \mathbf{H})\boldsymbol{\varepsilon}$

Pak maticově  $\begin{pmatrix} r_1 \\ \vdots \\ r_n \end{pmatrix} = \begin{pmatrix} 1 - h_{11} & -h_{12} & \dots & h_{1n} \\ -h_{21} & 1 - h_{22} & \dots & h_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ -h_{n1} & \dots & \dots & 1 - h_{nn} \end{pmatrix} \begin{pmatrix} \boldsymbol{\varepsilon}_1 \\ \vdots \\ \boldsymbol{\varepsilon}_n \end{pmatrix}$

$$r_i = \boldsymbol{\varepsilon}_i - \sum_{j=1}^n h_{ij} \boldsymbol{\varepsilon}_j = \boldsymbol{\varepsilon}_i(1 - h_{ii}) - \sum_{j \neq i} h_{ij} \boldsymbol{\varepsilon}_j.$$

**Poznámka 1:** Pokud jsou prvky  $h_{ii} \approx 1$  (blízké k 1)  $\Rightarrow 1 - h_{ii} \approx 0$ . Pak neočekávaně velká chyba pozorování  $Y_i$  (velká chyba  $\boldsymbol{\varepsilon}_i$ ) se nemusí odrážet v  $r_i$ . Na ostatní rezidua však vliv mít může.

**Věta 6:**  $\boxed{D\widehat{\mathbf{Y}} = \sigma^2 \mathbf{H}}$ ;  $\boxed{D\mathbf{r} = \sigma^2(\mathbf{I} - \mathbf{H})}$ .

Důkaz:  $D\widehat{\mathbf{Y}} = D(\mathbf{HY}) = \mathbf{H}D\mathbf{Y}\mathbf{H}' = \sigma^2 \mathbf{H}\mathbf{H}' = \sigma^2 \mathbf{H}^2 = \sigma^2 \mathbf{H}$ ;  
 $D\mathbf{r} = D(\mathbf{I} - \mathbf{H})\boldsymbol{\varepsilon} = (\mathbf{I} - \mathbf{H})D\boldsymbol{\varepsilon}(\mathbf{I} - \mathbf{H})' = \sigma^2(\mathbf{I} - \mathbf{H})(\mathbf{I} - \mathbf{H})' = \sigma^2(\mathbf{I} - \mathbf{H})^2 = \sigma^2(\mathbf{I} - \mathbf{H})$

**Poznámka 2:** Pokud matice  $\mathbf{H}$  není diagonální maticí, pak rezidua  $r_i$  jsou korelovaná. Z předchozího je vidět, že rezidua  $r_i$  v některých situacích nemusí dobře identifikovat odlehlá pozorování. Proto se v literatuře zavádějí a používají další typy reziduí.

**Značení:** Symbol  $(i)$  bude znamenat vynechání  $i$ -tého řádku, symbol  $[j]$  vynechání  $j$ -tého sloupce.

**Definice 3:** Definujme:

■ **normovaná rezidua** (*normalized or scaled residuals*)  $r_{Ni} = \frac{r_i}{s}$ , kde

$$s^2 = \frac{(\mathbf{Y} - \hat{\mathbf{Y}})'(\mathbf{Y} - \hat{\mathbf{Y}})}{n-k} = \frac{SSE}{n-k}.$$

■ **standardizovaná rezidua** (*standardized or internally studentized residuals*)

$$r_{Si} = \frac{r_i}{s\sqrt{1-h_{ii}}}$$

■ **predikovaná rezidua** (*predicted or crossvalidated residuals*)  $r_{P(i)} = Y_i - \hat{Y}_{(i)}$ ,

kde v lineárním modelu vynecháme  $i$ -té pozorování a značíme matici plánu  $\mathbf{X}_{(i)}$ , vektor  $\mathbf{Y}_{(i)}$ , odhad metodou nejmenších čtverců  $\hat{\beta}_{(i)} = (\mathbf{X}'_{(i)} \mathbf{X}_{(i)})^{-1} \mathbf{X}_{(i)} \mathbf{Y}_{(i)}$  a  $i$ -té pozorování odhadneme pomocí  $\hat{\beta}_{(i)}$  takto  $\hat{Y}_{(i)} = \mathbf{x}_i \hat{\beta}_{(i)}$ , kde  $\mathbf{x}_i$  je  $i$ -tý řádek původní matice plánu.

■ **studentizovaná rezidua** (*jackknife or externally studentized residuals*)

$$r_{J(i)} = \frac{r_{P(i)}\sqrt{1-h_{ii}}}{s_{(i)}}, \text{ kde } s_{(i)}^2 = \frac{(\mathbf{Y}_{(i)} - \hat{\mathbf{Y}}_{(i)})'(\mathbf{Y}_{(i)} - \hat{\mathbf{Y}}_{(i)})}{n-k-1}.$$

■  **$i$ -té DFFIT reziduum**  $d_i = \frac{\hat{Y}_i - \hat{Y}_{(i)}}{\sqrt{h_{ii}s_{(i)}}}$ .

■  **$i$ -té parciální reziduum**  $r_{i[j]} = Y_i - \hat{Y}_{i[j]}$  kde v lineárním modelu vynecháme  $j$ -tý regresor, odpovídající matici plánu označíme  $\mathbf{X}_{[j]}$ , odhad metodou nejmenších čtverců  $\hat{\beta}_{[j]} = (\mathbf{X}'_{[j]} \mathbf{X}_{[j]})^{-1} \mathbf{X}_{[j]} \mathbf{Y}$  a  $i$ -té pozorování odhadneme pomocí  $\hat{\beta}_{[j]}$  takto  $\hat{Y}_{i[j]} = \mathbf{x}_{i[j]} \hat{\beta}_{[j]}$ , kde  $\mathbf{x}_{i[j]}$  je  $i$ -tý řádek matice plánu  $\mathbf{X}_{[j]}$ .

**Věta 7:** Necht'  $\varepsilon \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I}_n) \Rightarrow [\mathbf{r} \sim N_n(\mathbf{0}, \sigma^2(\mathbf{I} - \mathbf{H}))]$ . Důkaz: viz. Anděl(1978).

**Poznámka 3:** Protože  $s^2(1 - h_{ii})$  je odhad rozptylu  $Dr_i = \sigma^2(1 - h_{ii})$ , pak standardizovaná rezidua mají rozptyl přibližně roven 1. Pokud nastane situace, že chyba je příliš velká oproti modelu, pak pomocí příslušného standardizovaného rezidua je lze snadněji identifikovat.

**Věta 8:**  $r_{P(i)} = \frac{r_i}{1-h_{ii}}$ ;  $Dr_{P(i)} = \frac{\sigma^2}{1-h_{ii}}$

**Věta 9:**  $(n - k)s_{(i)}^2 = (n - k)s^2 - \frac{r_i^2}{1-h_{ii}}$ ;

**Věta 10:**  $r_{J(i)} = \frac{r_i}{\sqrt{1-h_{ii}s_{(i)}}}$  Důkaz: viz. Staudte, Sheather(1990).

**Poznámka 4:** Předchozí vzorce umožňují vypočítat statistiky  $r_{P(i)}$ ,  $s_{(i)}^2$  a  $r_{J(i)}$  pouze z hodnot známých z celého regresního modelu.

**Věta 11:** Necht'  $\varepsilon \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I}_n) \Rightarrow [r_{J(i)} \sim t(n - k)]$ . Důkaz: viz. Staudte, Sheather(1990).

**Definice 4:** Řekneme, že  $i$ -té pozorování  $Y_i$  je **odlehlé**, jestliže  $E\varepsilon_i \neq 0$ .

**Poznámka 5:** Z věty 11 plyne, že pomocí  $i$ -tého studentizovaného rezidua  $r_{J(i)}$  lze testovat nulovou hypotézu  $H_0 : E\varepsilon_i = 0$ , že  $i$ -té pozorování není odlehlé proti alternativě  $H_1 : E\varepsilon_i \neq 0$ , tj. že je odlehlé. Pokud  $|r_{J(i)}| \geq t_{1-\alpha/2}(n-k)$ , pak na hladině významnosti  $\alpha$  zamítáme hypotézu  $H_0$  a tedy  $i$ -té pozorování na hladině významnosti  $\alpha$  je odlehlé.

**Věta 12:** DFFITS rezidua  $d_i$  pro  $i = 1, \dots, n$  lze vyjádřit vztahem 
$$d_i = \left( \frac{h_{ii}}{1-h_{ii}} \right)^{\frac{1}{2}} r_{J(i)}.$$

Důkaz: viz. Staudte, Sheather(1990).

**Poznámka 6:** Je-li  $n-k > 30$ , je na hladině významnosti  $\alpha = 0.05$  kvantil Studentova  $t$  rozdělení přibližně roven 2 a lze tedy v praktických situacích na základě věty 11 po-važovat  $i$ -té pozorování za odlehlé na hladině významnosti  $\alpha = 0.05$ , když  $|r_{J(i)}| \geq 2$ .

Toto odpovídá také empirických zkoušenostem (viz. Staudte, Sheather(1990)).

Posuzujeme-li odlehlé pozorování pomocí  $i$ -tého DFFITS rezidiua, můžeme vyu-žít vztah z věty 12 a navíc uplatnit vliv  $i$ -tého pozorování  $h_{ii}$  a jeho průměrnou hodnotu. Pak platí

$$|d_i| = \left( \frac{h_{ii}}{1-h_{ii}} \right)^{\frac{1}{2}} |r_{J(i)}| > 2 \left( \frac{h_{ii}}{1-h_{ii}} \right)^{\frac{1}{2}}.$$

Uvážíme-li, že průměrný vliv je  $\frac{k}{n}$  a dosadíme-li jej za  $h_{ii}$ , dostaneme

$$|d_i| = 2 \left( \frac{\frac{k}{n}}{1 - \frac{k}{n}} \right)^{\frac{1}{2}} = 2 \left( \frac{k}{n-k} \right)^{\frac{1}{2}} > 2 \left( \frac{k}{n} \right)^{\frac{1}{2}}.$$

Posledně uvedená nerovnost se v praxi užívá pro posouzení, zda  $i$ -té pozorování je odlehlé na základě DFFIT rezidiu.

**Cookova vzdálenost.** Pro měření **vlivu  $i$ -tého pozorování na hodnotu odhadu vektoru  $\beta$**  navrhl Cook použít statistiku

$$D_i = \frac{(\hat{\mathbf{Y}} - \hat{\mathbf{Y}}_{(i)})'(\hat{\mathbf{Y}} - \hat{\mathbf{Y}}_{(i)})}{ks^2} = \frac{r_{J(i)}^2}{k} \frac{h_{ii}}{1-h_{ii}}.$$

Cookova vzdálenost souvisí s konfidenčním elipsoidem odhadů, což umožňuje její porovnání s kvantily F-rozdělení s  $k$  a  $n-k$  stupni volnosti. Jde zde však o posun odhadů, který vznikl vynecháním  $i$ -tého bodu. Orientačně platí, že pro  $D_i > 1$  posun přesahuje 50% konfidenční oblast a daný bod je proto **vlivný**.

Další možné vysvětlení Cookovy vzdálenosti vychází z toho, že jde o eukleidovskou vzdálenost mezi vektorem predikce  $\hat{\mathbf{Y}}$  z metody nejmenších čtverců a vektorem predikce  $\hat{\mathbf{Y}}_{(i)}$ , který odpovídá odhadům stanoveným metodou nejmenších čtverců při vynechání  $i$ -tého bodu.

Cookova vzdálenost vyjadřuje vliv  $i$ -tého bodu pouze na odhady parametrů  $\beta$ . Pokud proto  $i$ -tý bod neovlivní odhady regresních parametrů  $\beta$  výrazně, bude hodnota Cookovy vzdálenosti malá.

Takový bod však může silně ovlivnit *odhad reziduálního rozptylu*  $\sigma^2$ , kde  $D\boldsymbol{\varepsilon} = \sigma^2 \mathbf{I}_n$ .

**Welschova-Kuhova vzdálenost.** Pro měření **vlivu  $i$ -tého pozorování simultánně jak na odhad  $\beta$ , tak na odhad  $\sigma^2$** , zvolili Welsch a Kuh statistiku

$$DFFITS_i = d_i = \frac{\hat{Y}_i - \hat{Y}_{(i)}}{\sqrt{h_{ii}} s_{(i)}}$$

(viz. def. 3, věta 12 a pozn. 6).

**Parciální vliv.** Pro měření vlivu  $i$ -tého pozorování na  $j$ -tou složku vektoru  $\hat{\beta}$

navrhli Belsley, Kuh a Welsch statistiku  $DFBETAS_{ij} = \frac{\hat{\beta}_i - \hat{\beta}_{j(i)}}{\sqrt{D\hat{\beta}_j}}$  (doporučená hranice  $2\sqrt{k/n}$ )

**Variační poměr.** Pro stanovení míry vlivu  $i$ -tého pozorování na matici  $D\hat{\beta}$  je navržena statistika

$$COVRATIO_i = \frac{(s_{(i)}^2 / s^2)^k}{1 - h_{ii}}.$$

Velké hodnoty statistiky signalizují vlivné body (vzhledem k  $D\hat{\beta}$ ).

V literatuře se za vlivná pozorování doporučuje považovat ta, pro něž

$$|COVRATIO_i - 1| > 3\frac{k}{n}.$$

### MÍRY INFLUENCE V PROSTŘEDÍ R:

K dispozici je především funkce `influence.measures()`, kterou lze použít pouze na objekt třídy `lm`. Výsledkem je objekt třídy `infl`, který je tvořen ze tří prvků: `infmat`, `is.inf` a `call`.

**Matice infmat :**

- každý řádek odpovídá jednomu pozorování ( $Y_i, \mathbf{x}_i$ )
- prvních  $k$  sloupců tvoří matici statistik DFBETAS, sloupce jsou označeny `dbf`. a za tečkou následuje většinou přiměřeně zkrácený název příslušného regresoru
- následuje sloupec statistik DFFITS označený `dffit`.
- další sloupce nazvané `cov.r`, `cook.d` a `hat` obsahují statistiky COVRATIO,  $D_i$  a diagonální prvky matice  $\mathbf{H}$ .

Samostatně lze jednotlivá rezidua a další statistiky získat z objektu typu `lm` pomocí funkcí

<code>rstandard()</code>	<code>dffits()</code>	<code>dfbetas()</code>	<code>covratio()</code>
<code>rstudent()</code>	<code>cooks.distance()</code>	<code>hatvalues()</code>	

**Parciální rezidua** v prostředí R získáme například tímto postupem

1. Nejprve vytvoříme pomocnou matici, která je typu  $n \times (k-1)$  (pokud model obsahuje konstantní člen vždy značený jako `(Intercept)`). Matice parciálních reziduí obsahuje kolik sloupců, kolik je regresorů, které lze vynechat.

```
pom.parc.rez <- residuals(model.lm, type = "partial")
```

2. Protože tato rezidua jsou modifikována tak, aby každý sloupec měl nulový průměr, je třeba přičíst jistou konstantu, kterou prostředí R spolu s modifikovanými parciálními rezidui nabízí.

```
parc.rez <- pom.parc.rez + attr(pom.parc.rez, "constant")
```

## B. STRATEGIE REGRESNÍ DIAGNOSTIKY

Jednotlivé míry regresní diagnostiky poskytují cenné informace o výskytu vlivných pozorování. V žádném případě však nemá smysl používat je automaticky na všechna data, protože bychom byli brzy zavaleni horou výsledků, z převážné většiny naprosto zbytečných.

Mnohem praktičejší je naopak držet se některé strategie regresní diagnostiky. Ta musí být dostatečně pružná, abychom mohli v každém kroku rozhodnout, zda některá pozorování přidat či vyloučit, aplikovat vhodnou transformaci a vrátit se o několik kroků zpět nebo naopak některý krok přeskočit apod. Je zřejmé, že k tomu musíme mít k dispozici vhodné programové vybavení s interaktivním přístupem.

**GRAFY IDENTIFIKACE VLIVNÝCH BODŮ** - existuje velké množství různých grafů, jako příklad uved'me:

**Graf predikovaných reziduů:**

- osa  $x$ : predikovaná rezida  $r_{P(i)}$
- osa  $y$ : rezida  $r_i$

Vybočující body (*leverage points*) jsou snadno identifikovány svou polohou, neboť leží mimo přímku  $y = x$ .

Odlehlá pozorování (*outliers*) leží sice na přímce  $y = x$  nebo v její blízkosti, jsou však dostatečně vzdáleny od ostatních bodů.

**Williamsův graf:**

- osa  $x$ : vlivy  $h_{ii}$
- osa  $y$ : Jackknife rezida  $r_{J(i)}$

Do grafu lze zakreslit mezní linie pro odlehlá pozorování (*outliers*):  $y = t_{1-\alpha}(n-k)$  a jednak mezní linie pro vybočující body (*leverage points*):  $x = 2\frac{k}{n}$ .

**Pregibonův graf:**

- osa  $x$ : vlivy  $h_{ii}$
- osa  $y$ : kvadráty modifikovaných normovaných reziduů  $r_{Mi}^2 = \frac{r_i^2}{SSE} = \frac{r_i^2}{(n-k)s^2}$

Protože platí, že  $E(h_{ii} + r_{Mi}^2) = \frac{k}{n}$ , lze do grafu zakreslit dvě hraniční přímky:  $y = -x + 2\frac{k}{n}$  a  $y = -x + 3\frac{k}{n}$ .

K rozlišení mezi body platí tato pravidla:

- (a) bod je silně vlivný, leží-li nad horní přímkou
- (b) bod je pouze vlivný, leží-li mezi oběma přímkami

Může jít jak o vybočující body (*leverage points*), tak i o odlehlá pozorování (*outliers*).

**Indexové grafy:**

- osa  $x$ : index  $i$
- osa  $y$ : jednotlivé typy reziduů, vlivy  $h_{ii}$ ,  $\beta_{(i)}$

**Rankitové Q-Q grafy:**

- osa  $x$ : kvantily standardizovaného normálního rozložení
- osa  $y$ : pořádkové statistiky (vzestupně setříděné hodnoty reziduů)

**POSTUP PŘI REGRESNÍ DIAGNOSTICE:** lze jich navrhnut celou řadu

- (a) Spočteme základní charakteristiky jednotlivých proměnných  $Y, X_1, \dots, X_k$ , tj. průměr, směrodatnou odchylku, šíkmost atd. a vykreslíme pro ně histogram, krabicový graf, případně indexový graf apod. Odtud získáme představu o možných odlehlých pozorování v jednotlivých proměnných, tvaru dat apod.
- (b) Vykreslíme rozptylové grafy (*scatter plots*) dvojic vektorů  $(Y, X_i)$ , resp. dvojic vektorů  $(X_i, X_j)$ .
- (c) Zkontrolujeme, zda se v datech nevyskytují vybočující body v prostoru regresorů (*leverage points*), např. pomocí diagonálních prvků projekční matici  $H$ . Tyto body v žádném případě automaticky nevylučujeme, nebot' nemusí jít nutně o vlivné body. Při další analýze jim však věnujeme zvýšenou pozornost.
- (d) Provedeme pečlivou analýzu reziduí. Používáme přitom jak grafické zobrazení reziduí (např. proti indexu), tak u „podezřelých“ hodnot užijeme k ověření významnosti vlivu některou z dříve uvedených statistik. Získáme tak představu o odlehlých pozorováních.
- (e) Po této všeobecné analýze dále postupujeme dle toho, co nás především zajímá. Je-li to vliv jednotlivých pozorování na hodnotu  $\hat{\beta}$ , užijeme např. Cookovu vzdálenost. Je-li to vliv jednotlivých pozorování na varianční matici  $\hat{\beta}$ , užijeme statistiku  $COVRATIO_i$  apod. V maximální možné míře přitom též využíváme grafická znázornění, jež nám podstatně urychlují orientaci ve výsledcích.

Výše uvedené kroky představují pouze jednu možnou základní strategii regresní diagnostiky. Při jejím užití vzniká v praxi potřeba dalších kroků a analýz. Patří mezi ně různé transformace, změna modelu, vylučování pozorování apod.

## LITERATURA:

- Anděl, J.(1978): *Matematická statistika*, Praha, SNTL.  
 Antoch, J., Vorlíčková, D. (1992): *Vybrané metody statistické analýzy dat*, Academia Praha  
 Staudte, R.G.,Sheather, S.J.(1990): *Robust Estimation and Testing*, New York, Wiley

PŘÍKLAD 1: Simulovaná data


Nejprve na simulovaných datech ukážeme příklad dat, ve kterých se nacházejí pozorování

- **odlehlá** (*outliers*) –  $y$ -ové hodnoty
- **vybočující** (*leverage points*) –  $x$ -ové hodnoty
- **vlivná**, jejichž odstraněním se radikálně změní výsledek

```
> k <- 15
> n <- 2 * k - 1
> sigma1 <- 3.5
> xx <- seq(1, k, by = 0.5) + sigma1 * rnorm(n)
> a <- 5
> b <- 3
> sigma2 <- 3.5
> yy <- a + b * xx + sigma2 * rnorm(n)
> x1 <- c(xx, 39)
> y1 <- c(yy, 125)
> x2 <- x1
> y2 <- c(yy, 11)
```

Simulovaná data graficky znázorníme. Doplníme vždy odhadnuté regresní přímky se všemi body (plná čára) a bez posledního bodu (čárkováně).

```
> xlim <- range(c(x1, x2))
> ylim <- range(c(y1, y2))
> par(mfrow = c(1, 2), mar = c(2, 2, 2, 0.5) + 0.05)
> plot(x1[1:n], y1[1:n], pch = 3, xlim = xlim, ylim = ylim)
> points(x1[n + 1], y1[n + 1], pch = 21, col = "red", bg = "orange")
> abline(lm(y1 ~ x1), col = "dodgerblue", lwd = 2)
> abline(lm(y1[-(n + 1)] ~ x1[-(n + 1)]), col = "violet",
  lwd = 2, lty = 2)
> text(x1[n + 1], y1[n + 1], "leverage point and outlier   ",
  adj = c(1, 0.5))
> mtext("Data set 1")
> plot(x2[1:n], y2[1:n], pch = 3, xlim = xlim, ylim = ylim)
> points(x2[n + 1], y2[n + 1], pch = 21, col = "red", bg = "orange")
> abline(lm(y2 ~ x2), col = "dodgerblue", lwd = 2)
> abline(lm(y2[-(n + 1)] ~ x2[-(n + 1)]), col = "violet",
  lwd = 2, lty = 2)
> text(x2[n + 1], y2[n + 1], "leverage point   ", adj = c(1,
  0.5))
> mtext("Data set 2")
```



Obrázek 1: Grafické znázornění odlehlych, vybočujících a vlivných bodů na simulovaných datech.

Z druhého panelu grafu je patrné, že doplněný bod v druhé sérii simulovaných dat je vlivným bodem.

Grafické zobrazení regresních přímek doplníme také explicitním výpočtem pomocí funkce `lm()` pro oboje simulovaná data. Výsledky zobrazíme pomocí funkce `summary()`.

```
> m1 <- lm(y1 ~ x1)
> summary(m1)

Call:
lm(formula = y1 ~ x1)

Residuals:
    Min      1Q  Median      3Q     Max 
-8.20309 -1.67102  0.07375  3.14365  6.30204 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept)  0.07375   0.14365   0.514   0.605    
x1          0.14365   0.01436  10.000   0.000 *** 
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
```

```

      Estimate Std. Error t value Pr(>|t|)
(Intercept)  5.8296     1.1903   4.897 3.67e-05 ***
x1          2.9517     0.1026  28.762 < 2e-16 ***
---
Signif. codes:  0 ,***, 0.001 **, 0.01 *, 0.05 ., 0.1 , , 1

Residual standard error: 4.039 on 28 degrees of freedom
Multiple R-squared: 0.9673, Adjusted R-squared: 0.9661
F-statistic: 827.2 on 1 and 28 DF, p-value: < 2.2e-16

```

```

> m2 <- lm(y2 ~ x2)
> summary(m2)

```

```

Call:
lm(formula = y2 ~ x2)

Residuals:
    Min      1Q  Median      3Q      Max
-40.3571 -6.5171  0.2596  6.7593 24.8853

Coefficients:
      Estimate Std. Error t value Pr(>|t|)
(Intercept) 22.0678     3.7758   5.845 2.78e-06 ***
x2          0.7510     0.3255   2.307  0.0287 *
---
Signif. codes:  0 ,***, 0.001 **, 0.01 *, 0.05 ., 0.1 , , 1

Residual standard error: 12.81 on 28 degrees of freedom
Multiple R-squared: 0.1597, Adjusted R-squared: 0.1297
F-statistic: 5.322 on 1 and 28 DF, p-value: 0.02867

```

Porovnáme-li oba dva regresní modely, vidíme, že i když se výchozí data liší pouze v jediném bodě, dostali jsme diametrálně odlišné výsledky.

- |          |                     |                                  |      |
|----------|---------------------|----------------------------------|------|
| 1. model | $y = 5.83 + 2.95x$  | upravený koeficient determinace: | 0.97 |
| 2. model | $y = 22.07 + 0.75x$ |                                  | 0.16 |

První model vysvětluje téměř 97% variability dat, kdežto druhý pouhých 16%.


Tyto skutečnosti by se měly projevit také v analýze reziduí.

Podíváme se nejprve, jaké typy diagnostických grafů nabízí funkce `plot.lm()` (ale stačí psát `plot()`) pro simulovaná data 1 a 2.

```

> par(mfrow = c(3, 2), mar = c(5, 5, 1.5, 0) + 0.05)
> plot(m1, which = 1:6)


```



Obrázek 2: `plot.lm(.,which=1:6)` pro simulovaná data 1.

```
> par(mfrow = c(3, 2), mar = c(5, 5, 1.5, 0) + 0.05)
```

```
> plot(m2, which = 1:6)
```



Obrázek 3: `plot.lm(.,which=1:6)` pro simulovaná data 2.

Prohlédneme-li si pozorně jednotlivé grafy, vidíme, že v těch grafech, ve kterých figuruje Cookova vzdálenost, se nejlépe odhalí oba dva doplněné koncové body.

Velmi užitečným je také bublinkový graf vytvořený pomocí funkce `influencePlot()`, který nabízí knihovna `car`.

Na ose  $x$  jsou vyneseny hodnoty vlivů  $h_{ii}$ , na ose  $y$  hodnoty studentizovaných reziduí  $r_{J(i)}$ . Každý bod  $(h_{ii}, r_{J(i)})$  reprezentuje kruh, jehož obsah je úměrný velikosti Cookovy vzdálenosti  $D_i$ .

Kromě toho jsou do grafu zaneseny dvě vertikální referenční čáry pro vlivy (konkrétně hodnoty  $2\frac{k}{n}$  a  $3\frac{k}{n}$ ) a tři horizontální referenční čáry pro hodnoty  $-2, 0, 2$ .

Body ležící mezi oběma vertikálními přímkami jsou **vlivné**, ty body, které leží napravo od druhé vertikální přímky jsou pak již **silně vlivné**.


Body, které leží nad horizontální přímkou v bodě 2 nebo pod horizontální přímkou v bodě  $-2$  jsou **odlehlé**.

Pokud přidáme do funkce `influencePlot()` argument `id.method="identify"`, můžeme interaktivně provádět identifikaci podezřelých bodů.

Identifikaci podezřelých hodnot neprovědeme interaktivně, ale ještě před vykreslením grafu je sami nalezneme. Po vykreslení grafu pomocí funkce `influencePlot()` pak s využitím příkazu `text()` doplníme číslo indexu, tj. pořadí pozorování.

Vytvořme bublinkové grafy pro oba simulované datové soubory, doplňme identifikaci podezřelých bodů a vypišme je.

```
> library(car)
> k <- length(coef(m1))
> n <- length(x1)
> sr <- rstudent(m1)
> Lr2 <- abs(sr) > 2
> hii <- hatvalues(m1)
> Lh2 <- hii > 2 * k/n
> L <- Lr2 | Lh2
> par(mfrow = c(1, 1), mar = c(5, 5, 1.5, 0) + 0.05)
> influencePlot(m1)
> text(hii[L], sr[L], as.character((1:n)[L]), adj = c(0.5,
  0.5), col = "blue", cex = 0.75)
```



Obrázek 4: Graf `influencePlot()` z knihovny `car` pro simulovaná data 1.

Vypíšeme podezřelá pozorování spolu s hodnotami studentizovaných reziduí  $r_{J(i)}$ , vlivy  $h_{ii}$  a Cookovou vzdáleností  $D_i$ .


```
> Di <- cooks.distance(m1)
> cat(paste("meze pro hii: 2*k/n=", round(2 * k/n, 4),
  "3*k/n=", round(3 * k/n, 4), "\n", sep = ""))
meze pro hii: 2*k/n=0.1333 3*k/n=0.2

> cbind((1:n)[L], x1[L], y1[L], sr[L], hii[L], Di[L])

 [,1]      [,2]      [,3]      [,4]      [,5]      [,6]
26   26 11.96542 32.94453 -2.210719 0.03861484 0.08618558
30   30 39.00000 125.00000  1.658210 0.61041902 2.02747514

> library(car)
> k <- length(coef(m2))
> n <- length(x2)
> sr <- rstudent(m2)
> Lr2 <- abs(sr) > 2
> hii <- hatvalues(m2)
> Lh2 <- hii > 2 * k/n
```

```
> L <- Lr2 / Lh2
> par(mfrow = c(1, 1), mar = c(5, 5, 1.5, 0) + 0.05)
> influencePlot(m2)
> text(hii[L], sr[L], as.character((1:n)[L]), adj = c(0.5,
0.5), col = "blue", cex = 0.75)
```



Obrázek 5: Graf `influencePlot()` z knihovny `car` pro simulovaná data 2.

Vypíšeme podezřelá pozorování spolu s hodnotami studentizovaných reziduí  $r_{J(i)}$ , vlivy  $h_{ii}$  a Cookovou vzdáleností  $D_i$ .

```
> Di <- cooks.distance(m2)
> cat(paste("meze pro hii: 2*k/n=", round(2 * k/n, 4),
" 3*k/n=", round(3 * k/n, 4), "\n", sep = ""))
meze pro hii: 2*k/n=0.1333 3*k/n=0.2

> cbind((1:n)[L], x2[L], y2[L], sr[L], hii[L], Di[L])

 [,1]      [,2]      [,3]      [,4]      [,5]      [,6]
20  20 18.58604 60.91134  2.168430 0.09137258 0.2088146
30  30 39.00000 11.00000 -16.502845 0.61041902 19.9574746
```

Oba dva bublinkové grafy dobře odhalily jako podezřelé uměle doplněné body s indexem 30.

Provedeme-li srovnání obou uměle doplněných bodů, dostaneme

kritérium	bod 30 – 1. sada dat	bod 30 – 2. sada dat
$r_{J(i)}$	1.6582	-16.5028 < -2
$h_{ii}$	0.6104 > $3\frac{k}{n}$	0.6104 > $3\frac{k}{n}$
$D_i$	2.0275 > 1	19.9575 > 1

Z hodnot vyplývá, že oba dva body zřetelně vybočují v  $x$ -vých hodnotách (identifikuje  $h_{ii}$ ). Bod 30 v první sadě dat je v souladu s předpokládaným regresním modelem (regresní přímkou), proto hodnota studentizovaného rezidua  $r_{J(i)}$  nevybočuje. Signifikantní je samozřejmě Cookova vzdálenost  $D_i$ . Naproti tomu bod 30 ve druhé sadě dat jasně nevyhovuje předpokládanému regresnímu modelu (vysoká hodnota  $r_{J(i)}$  a závratná hodnota  $D_i$ ).

V případě bodů 26 v první sadě dat a bodu 20 ve druhé sadě dat máme hodnoty

kritérium	bod 26 – 1. sada dat	bod 20 – 2. sada dat
$r_{J(i)}$	-2.2107 < -2	2.1684 > 2
$h_{ii}$	0.0386	0.0913
$D_i$	0.0862	0.2088

Je vidět, že tyto dva body byly vybrány pouze díky těsně vyšším hodnotám studentizovaných reziduí.

Jako zástupce **indexových grafů** si uvedeme graf `infIndexPlot()`, který je dostupný opět v knihovně `car`.

Tato funkce nabízí pro jednotlivá pozorování ( $i = 1, \dots, n$ ) samostatně hodnoty

- Cookovy vzdálenosti  $D_i$ ,
- studentizovaná rezidua  $r_{J(i)}$
- vlivů  $h_{ii}$ ,
- simultánní hladiny významnosti (na základě Bonferroniho nerovnosti) pro testování hypotézy  $H_0 : E\varepsilon_i = 0$  proti alternativě  $H_1 : E\varepsilon_i \neq 0$ .

Poznámka (Bonferroniho nerovnost).

Mějme  $n$  intervalů spolehlivosti  $CI_1, \dots, CI_n$ , pro které platí  $P(\gamma(\theta_i) \in CI_i) = 1 - \alpha_i$  pro  $\alpha_i \in (0, 1)$ . Pak platí


$$P\left(\bigcap_{i=1}^n \{\gamma(\theta_i) \in CI_i\}\right) \geq 1 - (\alpha_1 + \dots + \alpha_n)$$

Pokud zvolíme  $\alpha_i = \frac{\alpha}{n}$ , pak bude zaručeno, že

$$P\left(\bigcap_{i=1}^n \{\gamma(\theta_i) \in CI_i\}\right) \geq 1 - \alpha.$$


Pro oba dva regresní modely použijeme funkci `infIndexPlot()` z knihovny `car`. Přidáme požadavek na označení 5 bodů  $(x_i, y_i)$ , které mají největší Mahalanobisovu vzdálenost od výběrových průměrů  $(\bar{x}, \bar{y})$ .

```
> library(car)
> infIndexPlot(m1, id.method = "mahal", id.n = 5)
```



Obrázek 6: Graf `infIndexPlot()` z knihovny `car` pro simulovaná data 1.

```
> library(car)
> infIndexPlot(m2, id.method = "mahal", id.n = 5)
```

Obrázek 7: Graf `infIndexPlot()` z knihovny `car` pro simulovaná data 2.

Nejdůležitější informací předchozích dvou grafů jsou simultánní hladiny významnosti (na základě Bonferronoho nerovnosti) pro testování hypotézy  $H_0 : E\varepsilon_i = 0$  proti alternativě  $H_1 : E\varepsilon_i \neq 0$ . Z grafu však nezjistíme explicitní p-hodnoty. Tuto informaci získáme díky funkci `outlierTest()` z knihovny `car`.

```
> outlierTest(m1)
```

```
No Studentized residuals with Bonferonni p < 0.05
Largest |rstudent|:
      rstudent unadjusted p-value Bonferonni p
26 -2.210719           0.035713        NA
```

```
> outlierTest(m2)
```

```

rstudent unadjusted p-value Bonferonni p
30 -16.50284      1.2485e-15   3.7456e-14

```

V prvním modelu byl nalezen jako významný bod 26, ve druhém modelu bod 30.


Dosud jsme nezkoumali  $DFFIT$  rezidua,  $DFBETAS_{ij}$  a  $COVRATIO_i$  ( $i = 1, \dots, n$ ,  $j = 1, \dots, k$ ), která odhalují simultánní vliv pozorování na odhadu neznámých parametrů  $\beta$  a  $\sigma^2$ . Vytvoříme indexové grafy a provedeme identifikaci podezřelých pozorování.

```

> X <- x1
> M <- m1
> Y <- y1
> IM <- influence.measures(M)
> IDs <- 2:4
> txtY <- c("DFBETAS_2", "DFFIT", "COVRATIO")
> shift <- c(0, 0, 1)
> CutOff <- c(2/sqrt(length(X)), 2 * sqrt(length(coef(M)/length(X))),
  3 * length(coef(M)/length(X)))
> par(mfrow = c(1, 3), mar = c(5, 5, 0.5, 0.5) + 0.05)
> for (id in 1:3) {
  ID <- IDs[id]
  plot(IM$infmat[, ID], type = "p", xlab = "index",
    ylab = txtY[id])
  L <- abs(IM$infmat[, ID] - shift[id]) > CutOff[id]
  abline(h = shift[id])
  abline(h = c(shift[id] - CutOff[id], shift[id] +
    CutOff[id]), lty = 2)
  if (sum(L) > 0) {
    text(as.numeric(rownames(IM$infmat)[L]), IM$infmat[L,
      ID], labels = rownames(IM$infmat)[L], cex = 0.75,
      pos = 2)
    pom <- data.frame(cbind(rownames(IM$infmat)[L],
      X[L], Y[L], IM$infmat[L, ID]))
    names(pom) <- c("index", "x", "y", colnames(IM$infmat)[ID])
    o <- order(-abs(IM$infmat[L, ID]))
    print(pom[o, ], digits = 4)
  }
}

```

	index	x	y	dfb.x1
1	30	39	125	2.01818459863541




Obrázek 8: Indexové grafy pro vybrané influenční míry pro simulovaná data 1.

```

> X <- x2
> M <- m2
> Y <- y2
> IM <- influence.measures(M)
> IDs <- 2:4
> txtY <- c("DFBETAS_2", "DFFIT", "COVRATIO")
> shift <- c(0, 0, 1)
> CutOff <- c(2/sqrt(length(X)), 2 * sqrt(length(coef(M)/length(X))),
  3 * length(coef(M)/length(X)))
> par(mfrow = c(1, 3), mar = c(5, 5, 0.5, 0.5) + 0.05)
> for (id in 1:3) {
  ID <- IDs[id]
  plot(IM$infmat[, ID], type = "p", xlab = "index",
    ylab = txtY[id])
  L <- abs(IM$infmat[, ID] - shift[id]) > CutOff[id]
  abline(h = shift[id])
  abline(h = c(shift[id] - CutOff[id], shift[id] +
    CutOff[id]), lty = 2)
  if (sum(L) > 0) {
    text(as.numeric(rownames(IM$infmat)[L]), IM$infmat[L,
      ID], labels = rownames(IM$infmat)[L], cex = 0.75,
      pos = 2)
    pom <- data.frame(cbind(rownames(IM$infmat)[L],
      X[L], Y[L], IM$infmat[L, ID]))
    names(pom) <- c("index", "x", "y", colnames(IM$infmat)[ID])
    o <- order(-abs(IM$infmat[L, ID]))
    print(pom[o, ], digits = 4)
  }
}

```

	index	x	y	dfb.x2
30	30	39	11	-20.0853820508696
20	20	18.5860388797267	60.9113433759351	0.548041322583496
1	1	-0.757673226860099	3.59174629397058	0.396240079235418
	index	x	y	dffit
1	30	39	11	-20.6573198640163



Obrázek 9: Indexové grafy pro vybrané influenční míry pro simulovaná data 2.

V prvním modelu má vliv na odhadu neznámých parametrů  $\beta_1$  a  $\sigma^2$  bod 30 a v druhém modelu jsou to body 1, 20 a 30.

PŘÍKLAD 2: Obsah těžkých kovů v řece Moravě v průběhu let 1997 až 2009

Načteme datový soubor `sedimenty.csv` pomocí příkazu `read.csv2()` a vytvoříme proměnnou `data` typu `data.frame`.

```
> fileDat <- paste(data.library, "sedimenty.csv", sep = "")  
> data <- read.csv2(fileDat)  
> str(data)
```

```
,data.frame,: 144 obs. of 6 variables:  
$ lokalita: int 1 1 1 1 1 1 1 1 1 ...  
$ rok : int 1997 1997 1998 1998 1999 1999 2000 2000 2001 2001 ...  
$ Pb : num 24.9 34.1 38 40.3 33.2 33.7 45.9 82.5 68.9 64.1 ...  
$ Cd : num 0.69 1.22 0.842 0.894 0.548 0.609 1.13 0.78 0.64 0.86 ...  
$ Ni : num 29.8 36.6 40.3 35.4 21.6 24.1 NA NA 60.2 54.6 ...  
$ Hg : num 0.056 0.144 0.187 0.086 0.078 0.071 0.22 NA 0.15 0.2 ...
```

Všimněme si, že pro některé těžké kovy jsou v souboru chybějící pozorování. Budeme muset pak být velmi obezřetní při identifikaci podezřelých pozorování podle jejich pořadových čísel.


```
> Lna <- apply(is.na(data), 1, any)  
> print(data[Lna, ])
```

	lokalita	rok	Pb	Cd	Ni	Hg
7		1 2000	45.9	1.13	NA	0.220
8		1 2000	82.5	0.78	NA	NA
13		1 2003	NA	NA	NA	0.183
14		1 2003	45.9	1.36	NA	0.225
15		1 2004	263.0	0.43	NA	0.040
16		1 2004	10.4	0.21	NA	0.030
17		1 2005	13.1	0.27	NA	0.320
18		1 2005	10.0	0.29	NA	0.030
29		2 2000	60.1	1.52	NA	0.830
30		2 2000	34.5	0.69	NA	NA
35		2 2003	NA	NA	NA	0.285
36		2 2004	52.7	0.58	NA	0.160
37		2 2004	21.8	0.37	NA	0.120
38		2 2005	26.9	0.44	NA	0.230
39		2 2005	27.5	0.90	NA	0.220
48		3 2000	41.1	1.10	NA	0.290
49		3 2000	57.7	1.32	NA	NA
54		3 2003	17.5	0.35	NA	0.138
55		3 2003	43.4	0.91	NA	0.449
56		3 2004	309.0	0.81	NA	0.280
57		3 2004	35.6	0.54	NA	0.190
58		3 2005	33.2	0.80	NA	0.340
59		3 2005	29.5	0.81	NA	0.450
70		4 2000	38.3	0.95	NA	0.280
71		4 2000	31.7	0.73	NA	NA
76		4 2003	29.7	0.48	NA	0.196
77		4 2004	76.2	0.50	NA	0.160
78		4 2004	34.3	0.58	NA	0.200
79		4 2004	20.5	0.44	NA	0.110
80		4 2005	43.3	0.88	NA	0.300

81	4	2005	29.0	0.64	NA	0.290
92	5	2000	65.0	1.78	NA	0.440
93	5	2000	35.8	1.87	NA	NA
100	5	2004	81.9	0.97	NA	0.180
101	5	2004	25.9	1.00	NA	0.230
102	5	2005	185.0	0.81	NA	0.230
103	5	2005	31.5	0.75	NA	0.240
114	6	2000	20.5	0.46	NA	0.130
115	6	2000	29.0	0.59	NA	NA
120	6	2003	36.5	0.99	NA	0.266
121	6	2003	94.2	0.71	NA	0.237
122	6	2004	31.6	0.68	NA	0.180
123	6	2004	17.6	0.38	NA	0.140
124	6	2005	54.1	0.89	NA	0.240
125	6	2005	26.8	0.75	NA	0.230
126	6	2005	7.8	0.05	NA	0.040
132	7	2001	NA	NA	NA	NA
135	7	2002	NA	NA	NA	NA
140	7	2006	NA	NA	NA	NA
141	7	2006	NA	NA	NA	NA

Data vykreslíme


```
> par(mfrow = c(2, 2), mar = c(2, 5, 0.5, 0.5) + 0.05)
> for (id in 3:6) plot(data[, id] ~ data[, 2], ylab = paste(names(data)[id],
+ "[mg/kg]"))
```



Obrázek 10: Obsah těžkých kovů v řece Moravě v průběhu let 1997 až 2009 (v mg/kg).

Vzhledem k tomu, že jako závisle proměnné budeme brát **logaritmy** obsahů těžkých kovů v mg/kg, vykresleme ještě zlogaritmovaná data. Do grafů pro názornost dokreslíme regresní přímky.

```
> LogNames <- c(names(data)[1:2], paste("log(", names(data)[3:6],
  ") [mg/kg]", sep = ""))
> par(mfrow = c(2, 2), mar = c(2, 5, 0.5, 0.5) + 0.05)
> for (id in 3:6) {
  plot(log(data[, id]) ~ data[, 2], ylab = LogNames[id])
  abline(lm(log(data[, id]) ~ data[, 2]), col = "red")
}
```



Obrázek 11: Logaritmy obsahu těžkých kovů v řece Moravě v průběhu let 1997 až 2009 (v mg/kg).

Pro další analýzu vybereme jeden z těžkých kovů, například kadmium a provedeme regresní analýzu pro logaritmy obsahu těžkých kovů. Protože nezávisle proměnnou jsou roky, které nabývají vysokých hodnot, doporučuje se vždy čas centrovat.

```
> id <- 4
> y <- log(data[, id])
> xshift <- mean(range(data[, 2]))
> x <- data[, 2] - xshift
> ytxt <- LogNames[id]
> Data <- data.frame(x = x, y = y)
> m <- lm(y ~ x)
> summary(m)
```

```

Call:
lm(formula = y ~ x)

Residuals:
    Min      1Q  Median      3Q     Max 
-2.622863 -0.272384  0.005871  0.255382  1.603285 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) -0.32587   0.04521 -7.208 3.55e-11 ***  
x             -0.02350   0.01232 -1.907  0.0586 .    
---
Signif. codes:  0 ,***, 0.001 ,**, 0.01 ,*, 0.05 ., 0.1 ., 1 

Residual standard error: 0.5206 on 136 degrees of freedom
(6 observations deleted due to missingness)
Multiple R-squared: 0.02606, Adjusted R-squared: 0.01889 
F-statistic: 3.638 on 1 and 136 DF, p-value: 0.05857

```

Dalším krokem bude grafické zázornění výsledků spolu s intervaly spolehlivosti kolem regresní přímky a také s predikčními intervaly spolehlivosti.

```

> xrange <- range(x)
> xx <- seq(xrange[1], xrange[2], length.out = 100)
> conf.i <- predict(m, newdata = data.frame(x = xx), interval = "confidence")
> str(conf.i)


num [1:100, 1:3] -0.185 -0.188 -0.191 -0.193 -0.196 ...
- attr(*, "dimnames")=List of 2
..$ : chr [1:100] "1" "2" "3" "4" ...
..$ : chr [1:3] "fit" "lwr" "upr"

> pred.i <- predict(m, newdata = data.frame(x = xx), interval = "prediction")
> str(pred.i)

num [1:100, 1:3] -0.185 -0.188 -0.191 -0.193 -0.196 ...
- attr(*, "dimnames")=List of 2
..$ : chr [1:100] "1" "2" "3" "4" ...
..$ : chr [1:3] "fit" "lwr" "upr"

> ylim <- range(c(y, pred.i[, 2:3]), na.rm = TRUE)
> par(mfrow = c(1, 1), mar = c(2, 5, 1, 0) + 0.5)
> xt <- x + xshift
> xxt <- xx + xshift
> plot(y ~ xt, ylab = ytxt, ylim = ylim)
> matlines(xxt, cbind(conf.i, pred.i[, -1]), lty = c(1,
  2, 2, 3, 3), lwd = c(2, 1, 1, 1, 1), col = c("dodgerblue",
  "blue", "blue", "darkgreen", "darkgreen"))
> znam <- ifelse(coef(m)[2] < 0, "", "+")
> txtmodel <- paste("y=", round(coef(m)[1], 2), znam, round(coef(m)[2],
  3), "x", sep = "")
> mtext(txtmodel)
> mtext(paste("n=", length(m$residuals)), sep = ""), side = 1)


```



Obrázek 12: Logaritmy obsahu těžkých kovů v řece Moravě v průběhu let 1997 až 2009 ( $Cd$  v mg/kg).


Pro regresní model provedeme analýzu reziduí – využijeme funkci `plot()`.

```
> par(mfrow = c(2, 2), mar = c(5, 5, 1.5, 0) + 0.05)
> plot(m, which = 1:4)
```



Obrázek 13: `plot.lm(., which=1:4)` pro Logaritmy obsahu těžkých kovů v řece Moravě v průběhu let 1997 až 2009 ( $Cd$  v mg/kg).

```
> par(mfrow = c(1, 2), mar = c(5, 5, 1.5, 0) + 0.05)
> plot(m, which = 5:6)
```



Obrázek 14: `plot.lm(.,which=5:6)` pro *Logaritmy obsahu těžkých kovů v řece Moravě v průběhu let 1997 až 2009 (Cd v mg/kg)*.

V dalším kroku využijeme funkci `influencePlot()` pro vykreslení bublinkového grafu. Na ose

- $x$  jsou vyneseny hodnoty vlivů  $h_{ii}$ ,
- na ose  $y$  hodnoty studentizovaných reziduí  $r_{J(i)}$ .

Každý bod  $(h_{ii}, r_{J(i)})$  reprezentuje kruh, jehož obsah je úměrný velikosti Cookovy vzdálenosti  $D_i$ .

Kromě toho jsou do grafu zaneseny dvě vertikální referenční čáry pro vlivy (konkrétně hodnoty  $2\frac{k}{n}$  a  $3\frac{k}{n}$ ) a tři horizontální referenční čáry pro hodnoty  $-2, 0, 2$ .


```
> k <- length(coef(m))
> sr <- rstudent(m)
> n <- length(sr)
> str(sr)

Named num [1:138] -0.3607 0.7444 0.0703 0.186 -0.7134 ...
- attr(*, "names")= chr [1:138] "1" "2" "3" "4" ...

> Lr2 <- abs(sr) > 2
> hii <- hatvalues(m)
> str(hii)

Named num [1:138] 0.0228 0.0228 0.0175 0.0175 0.0133 ...
- attr(*, "names")= chr [1:138] "1" "2" "3" "4" ...

> Lh2 <- hii > 2 * k/n
> L <- Lr2 | Lh2
> par(mfrow = c(1, 1), mar = c(5, 5, 1.5, 0) + 0.05)
> influencePlot(m)
> text(hii[L], sr[L], names(hii)[L], adj = c(0.5, 0.5),
       col = "blue", cex = 0.75)
```



Obrázek 15: Graf `influencePlot()` z knihovny `car` pro Logaritmy obsahu těžkých kovů v řece Moravě v průběhu let 1997 až 2009 ( $Cd$  v mg/kg).

Dříve než začneme vypisovat podezřelá pozorování pomocí jejich pořadí, je třeba si všimnout, že pro kadmium místo vstupních 144 pozorování je pouze 138, tedy 6 je chybějících. Proto budeme muset být při výpisu velmi opatrní.

Vypíšeme tedy podezřelá pozorování spolu s hodnotami studentizovaných reziduí  $r_{J(i)}$ , vlivy  $h_{ii}$  a Cookovou vzdáleností  $D_i$ .

```

> LNA <- with(Data, is.na(y))
> Di <- cooks.distance(m)
> pom <- data.frame(data[!LNA, c(1:2, id)][L, ], y[!LNA][L],
+ x[!LNA][L], sr[L], hii[L], Di[L])
> names(pom) <- c(names(data)[c(1:2, id)], "y", "x", "student.res",
+ "h_ii", "D_i")
> print(pom, digits = 4)

```

lokalita	rok	Cd	y	x	student.res	h_ii	D_i
16		1	2004	0.21	-1.56065	1	-2.376692 0.008912 2.456e-02
21		1	2009	1.29	0.25464	6	1.414210 0.032573 3.342e-02
22		1	2009	1.70	0.53063	6	1.968491 0.032573 6.388e-02
42		2	2009	0.87	-0.13926	6	0.638394 0.032573 6.891e-03
43		2	2009	0.93	-0.07257	6	0.768871 0.032573 9.982e-03
62		3	2009	0.71	-0.34249	6	0.242065 0.032573 9.933e-04
63		3	2009	0.76	-0.27444	6	0.374618 0.032573 2.378e-03
84		4	2009	0.74	-0.30111	6	0.322660 0.032573 1.764e-03
85		4	2009	0.63	-0.46204	6	0.009414 0.032573 1.503e-06
88		5	1998	3.83	1.34286	-5	3.099694 0.017483 8.040e-02
95		5	2001	3.76	1.32442	-2	3.195242 0.008157 3.932e-02

```

106      5 2009 2.58  0.94779  6   2.833149 0.032573 1.285e-01
107      5 2009 2.35  0.85442  6   2.636163 0.032573 1.121e-01
126      6 2005 0.05 -2.99573  2   -5.605079 0.011404 1.481e-01
143      7 2009 0.76 -0.27444  6   0.374618 0.032573 2.378e-03
144      7 2009 0.89 -0.11653  6   0.682831 0.032573 7.880e-03

```

```
> cat(paste("meze pro hii: 2*k/n=", round(2 * k/n, 4),
           " 3*k/n=", round(3 * k/n, 4), "\n", sep = ""))
```

```
meze pro hii: 2*k/n=0.029  3*k/n=0.0435
```

Vzhledem k tomu, že nezávisle proměnnou je čas (tj. jednotlivé roky), jejich odlehlost nemá cenu zkoumat.

Body, které je třeba prověřit se tak stávají body, které jsou vybrány na základě hodnot studentizovaných reziduí  $r_{J(i)}$ . Jde o body, jejich indexy (pořadí) je 126, 106, 107, 88, 95 a 16.

Uvidíme, jak dopadne testování hypotézy  $H_0 : E\varepsilon_i = 0$  proti alternativě  $H_1 : E\varepsilon_i \neq 0$  pomocí simultánních hladin významnosti získaných na základě Bonferroniho nerovnosti.

```
> outlierTest(m)
```

```

rstudent unadjusted p-value Bonferonni p
126 -5.605079      1.1272e-07    1.5555e-05

```

Jako odlehlé pozorování bylo určeno pozorování s indexem 126.

Na závěr ještě prozkoumejme  $DFFIT$  rezidua,  $DFBETAS_{ij}$  a  $COVRATIO_i$  ( $i = 1, \dots, n$ ,  $j = 1, \dots, k$ ), která odhalují simultánní vliv pozorování na odhadu neznámých parametrů  $\beta$  a  $\sigma^2$ . Vytvoříme proto indexové grafy a provedeme identifikaci podezřelých pozorování. Jejich pořadí setřídíme podle velikosti vlivu.

```

> X <- x
> M <- m
> Y <- y
> IM <- influence.measures(M)
> IDs <- 2:4
> txtY <- c("DFBETAS_2", "DFFIT", "COVRATIO")
> shift <- c(0, 0, 1)
> CutOff <- c(2/sqrt(length(X)), 2 * sqrt(length(coef(M)/length(X))),
            3 * length(coef(M)/length(X)))
> par(mfrow = c(1, 3), mar = c(5, 5, 0.5, 0.5) + 0.05)
> for (id in 1:3) {
  ID <- IDs[id]
  plot(IM$infmat[, ID], type = "p", xlab = "index",
       ylab = txtY[id])
  L <- abs(IM$infmat[, ID] - shift[id]) > CutOff[id]
  abline(h = shift[id])
  abline(h = c(shift[id] - CutOff[id], shift[id] +
               CutOff[id]), lty = 2)
  if (sum(L) > 0) {


```

```

text(as.numeric(rownames(IM$infmat)[L]), IM$infmat[L,
  ID], labels = rownames(IM$infmat)[L], cex = 0.75,
  pos = 2)
pom <- data.frame(cbind(rownames(IM$infmat)[L],
  X[L], Y[L], IM$infmat[L, ID]))
names(pom) <- c("index", "x", "y", colnames(IM$infmat)[ID])
o <- order(-abs(IM$infmat[L, ID]))
print(pom[o, ], digits = 4)
}
}

```

	index	x	y	dfb.x
106	106	3	-0.755022584278033	0.458400139122709
107	107	5	-0.653926467406664	0.426528105228927
126	126	2	-0.116533816255952	-0.363493603762246
22	22	6	0.254642218373581	0.318499569715897
88	88	-6	-0.281037529733112	-0.316400707045973
21	21	5	-0.579818495252942	0.228817552516062
87	87	6	-0.462035459596559	-0.20275156658593
83	83	2	-0.446287102628419	-0.178120421517005



Obrázek 16: Indexové grafy pro vybrané influenční míry pro *Logaritmy obsahu těžkých kovů v řece Moravě v průběhu let 1997 až 2009 (Cd v mg/kg)*.

Identifikovaná pozorování bude třeba prověřit v tom smyslu, zda nedošlo k nějaké chybě například při přepisu. Rozhodně to neznamená okamžitě je vypustit ze zpracování.

### C. Úkol:

Na základě grafu predikovaných reziduí, Williamsova grafu a Pregibonova grafu provedte identifikaci odlehlých a vlivných pozorování pro obsah olova v řece Moravě v letech 1997 až 2009.