

MA012 Statistika II

7. Regresní diagnostika

Ondřej Pokora (pokora@math.muni.cz)

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

(podzim 2015)




V praxi se sestkáváme s jevem, že v souboru dat se vyskytnou některé hodnoty výrazně se lišící od hodnot ostatních. V literatuře se rozvinuly dva směry, které se snaží s existencí takových hodnot vyrovnat:

- metody robustní statistiky,
- metody regresní diagnostiky.


Robustní diagnostika používá odlišné modely, testy, apod., které jsou navrženy tak, aby se v nich pokud možno eliminoval vliv výrazně odlišných hodnot v datovém souboru.

Regresní diagnostika, kterou budeme využívat, se snaží detekovat podezřelá data a pomocí vhodných statistických indikátorů dává statistikovi možnost rozhodnout se, jak s takovými hodnotami dále naloží.


Data set 1




Data set 2



Data set 1



Data set 2



Regresní diagnostika

V rámci regresní diagnostiky se zabýváme dvěma základními úlohami:

- detekcí neočekávaných hodnot v datovém souboru,
- rozhodnutím, zda takové hodnoty mohou významně ovlivnit statistickou analýzu datového souboru.

Definice 1 (Neočekávané hodnoty)

- **odlehlá pozorování (outliers)** – neočekávané hodnoty vysvětlované proměnné,
- **vybočující body (leverage points)** – neočekávané hodnoty vysvětlujících proměnných,
- data, která lze zařadit do obou výše uvedených skupin.

Neočekávané hodnoty v datovém souboru

Výskyt odlehlých pozorování či vybočujících bodů nemusí nutně významně ovlivnit analýzu datového souboru, neboť i taková měření mohou být v souladu s předpokládaným matematicko-statistickým modelem. Většinou však odlehlá či vybočující pozorování významně ovlivňují výsledky analýzy a proto je vhodné se v regresní diagnostice zabývat.

Významný vliv na výsledky však mohou mít i jiné body, než jen odlehlá či vybočující pozorování.

Definice 2 (Vlivný bod)

Jako **vlivné body** se označují všechny hodnoty datového souboru, které nějakým způsobem podstatně ovlivňují analýzu datového souboru, tj. některou z charakteristik spojených s odhadem vektoru parametrů v lineárním regresním modelu či s testováním hypotéz o parametrech.

Základním nástrojem regresní diagnostiky jsou rezidua.

Lineární regresní model

Pozorujeme dvojice (x_i, Y_i) , $i = 1, \dots, n$.

Předpokládáme

$$Y_i = m(x_i) + \varepsilon_i$$

x_i ... body pevného plánu,

Y_i ... naměřené hodnoty

ε_i ... chyby měření, $E(\varepsilon_i) = 0$, $D(\varepsilon_i) = \sigma^2$, $C(\varepsilon_i, \varepsilon_j) = 0$ pro $i \neq j$.

Hledáme **odhad** regresní funkce m .

Lineární regresní model

Celkově jsme dostali model

$$\begin{array}{l} Y_1 = \beta_1 x_{11} + \dots + \beta_k x_{1k} + \varepsilon_1 \\ \vdots \\ Y_n = \beta_1 x_{n1} + \dots + \beta_k x_{nk} + \varepsilon_n \end{array} \quad \underbrace{\begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}}_Y = \underbrace{\begin{pmatrix} x_{11} & \dots & x_{1k} \\ \vdots & & \vdots \\ x_{n1} & \dots & x_{nk} \end{pmatrix}}_{X(\text{matice plánu})} \underbrace{\begin{pmatrix} \beta_1 \\ \vdots \\ \beta_k \end{pmatrix}}_{\beta} + \underbrace{\begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}}_{\varepsilon}$$

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 $EY = X\beta$
- **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. $DY = D\varepsilon = \sigma^2 I_n$, takže i měření jsou nekorelovaná.

Terminologie

Používá se následující **terminologie** a značení

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

Takto zavedený model budeme nazývat **lineární regresní model**. Dále budeme předpokládat, že $n > k$ a o hodnotě matice \mathbf{X} budeme předpokládat, že je rovna k , tj. $h(\mathbf{X}) = k$. Bude-li tento předpoklad splněn, budeme říkat, že jde **lineární 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.

Metoda nejmenších čtverců

Definice 3

Řekneme, že odhad $\hat{\beta}$ je odhadem parametru β **metodou nejmenších čtverců** (**Least Squares method**), jestliže

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

Věta 4

V lineárním regresním modelu $\mathbf{Y} \sim \mathcal{L}(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n)$ platí:

$$E\mathbf{Y} = \mathbf{X}\boldsymbol{\beta}, \quad D\mathbf{Y} = \sigma^2 \mathbf{I}_n,$$

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

$$E\hat{\boldsymbol{\beta}} = \boldsymbol{\beta}, \quad D\hat{\boldsymbol{\beta}} = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1},$$

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

$$s^2 = \frac{S_e}{n - k} \text{ je nestranným odhadem rozptylu } \sigma^2,$$

přičemž

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

Definice 5 (Projekční matice)

Matice $H = X(X'X)^{-1}X'$ se nazývá **projekční matice (hat matrix)**.

Věta 6

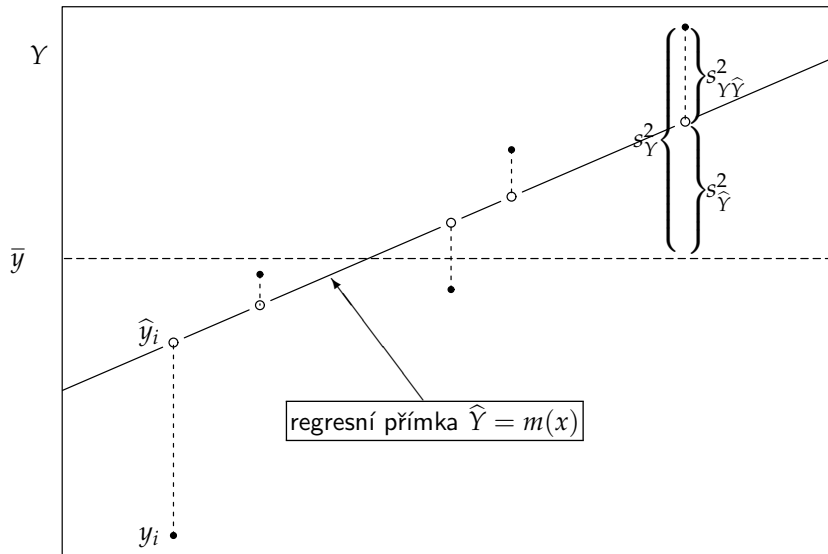
Pro odhady \hat{Y} platí

$$\hat{Y} = HY.$$

Důkaz:

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

Graficky



Vlastnosti projekční matice

Věta 7

Projekční matice $\mathbf{H} = \mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'$:

- je symetrická řádu n , tj. $\mathbf{H}' = \mathbf{H}$,
- je **idempotentní**, tj. $\mathbf{H}\mathbf{H} = \mathbf{H}$,
- má na hlavní diagonále hodnoty $h_{ii} \in [0; 1]$, ($i = 1, \dots, n$),
- má **stopu (Trace)** rovnou počtu parametrů, $\text{Tr } \mathbf{H} = \sum_{i=1}^n h_{ii} = k$.

Definice 8

Jednotlivé sloupce projekční matice \mathbf{H} se nazývají **vlivové vektory**.

Číslo h_{ii} se nazývá **vliv** pozorování Y_i , $i = 1, \dots, n$.

Věta 9

Průměrný vliv pozorování Y_1, \dots, Y_n je rovný $\bar{h} = \frac{k}{n}$.

Rezidua a jejich vlastnosti

Definice 10 (Rezidua)

Vektor **reziduí (residuals)** je vektor rozdílů skutečných hodnot a odhadů,

$$\mathbf{r} = (r_1, \dots, r_n)' = \mathbf{Y} - \hat{\mathbf{Y}} = (Y_1 - \hat{Y}_1, \dots, Y_n - \hat{Y}_n)'.$$

Věta 11

Pro vektor reziduí \mathbf{r} a pro odhady $\hat{\mathbf{Y}}$ platí:

$$\mathbf{r} = (\mathbf{I}_n - \mathbf{H})\mathbf{Y} = (\mathbf{I}_n - \mathbf{H})\boldsymbol{\varepsilon},$$

$$\text{D}\mathbf{r} = \sigma^2(\mathbf{I}_n - \mathbf{H}),$$

$$\text{D}\hat{\mathbf{Y}} = \sigma^2\mathbf{H}.$$

Důkaz:

$$\mathbf{r} = \mathbf{Y} - \hat{\mathbf{Y}} = \mathbf{Y} - \mathbf{H}\mathbf{Y} = (\mathbf{I}_n - \mathbf{H})\mathbf{Y} = \underbrace{(\mathbf{I}_n - \mathbf{H})\mathbf{X}\boldsymbol{\beta}}_0 + (\mathbf{I}_n - \mathbf{H})\boldsymbol{\varepsilon} = (\mathbf{I}_n - \mathbf{H})\boldsymbol{\varepsilon}.$$

Využití reziduí v regresní diagnostice

První tvrzení předchozí věty tedy říká, že rezidua \mathbf{r} souvisí s náhodnými odchylkami ε od regresního modelu. Chybu ε_i měření Y_i bychom tedy mohli detekovat pomocí rezidua r_i .

Avšak v případě, že $h_{ii} \approx 1$, je odpovídající hodnota na hlavní diagonále matice $\mathbf{I}_n - \mathbf{H}$ rovna $1 - h_{ii} \approx 0$. To znamená, že v případě velkého vlivu pozorování Y_i se chyba tohoto pozorování nemusí projevit v reziduu r_i . Rezidua ostatních měření však ovlivnit může, pokud projekční matice \mathbf{H} není diagonální.

V regresní diagnostice se proto zavádí a používají další typy reziduí.

Další typy reziduí

Definice 12

Normované reziduum (normalized/scaled) je

$$r_{Ni} = \frac{r_i}{s}.$$

Modifikované normované reziduum je

$$r_{Mi} = \frac{r_{Ni}}{\sqrt{n-k}} = \frac{r_i}{s\sqrt{n-k}}.$$

Standardizované reziduum je

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

Další typy reziduí

Definice 13

Predikované reziduum (predicted/crossvalidated) je reziduum v modelu bez i -tého pozorování, tzn.

$$r_{P(i)} = Y_i - \hat{Y}_{(i)},$$

kde $\hat{Y}_{(i)} = \mathbf{X}\hat{\boldsymbol{\beta}}_{(i)}$, a vektor parametrů $\hat{\boldsymbol{\beta}}_{(i)}$ odhadneme v LRM bez i -tého pozorování.

Studentizované reziduum (jackknife residual) je

$$r_{J(i)} = r_{P(i)} \frac{\sqrt{1 - h_{ii}}}{s_{(i)}},$$

kde $s_{(i)}^2$ je odhad rozptylu náhodných chyb v modelu bez i -tého pozorování (tzn. s $n - k - 1$ stupni volnosti).

DFFIT reziduum je

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

Další typy reziduí

Definice 14

Vektor **Parciálních reziduí** $\mathbf{r}_{[j]} = (r_{1[j]}, \dots, r_{n[j]})'$ je tvořen rezidi v modelu bez j -tého parametru β_j , tzn.

$$r_{i[j]} = Y_i - \hat{Y}_{i[j]},$$

kde $\hat{Y}_{i[j]} = \mathbf{X}_{[j]} \hat{\boldsymbol{\beta}}_{[j]}$ je odhad v modelu, v němž ve vektoru parametrů $\hat{\boldsymbol{\beta}}_{[j]}$ chybí parametr β_j a v matici plánu $\mathbf{X}_{[j]}$ chybí odpovídající sloupec.

Vlastnosti reziduí

Následující tvrzení ukazuje, že jednotlivá rezidua je možno počítat

Věta 15

$$r_{Pi} = \frac{r_i}{1 - h_{ii}},$$
$$r_{J(i)} = \frac{r_i}{s_{(i)} \sqrt{1 - h_{ii}}}, \quad s_{(i)}^2 = s^2 - \frac{r_i^2}{(n - k)(1 - h_{ii})},$$
$$d_i = r_{J(i)} \sqrt{\frac{h_{ii}}{1 - h_{ii}}}.$$

Pokud mají veličiny Y_1, \dots, Y_n normální rozdělení pravděpodobnosti, potom

$$\mathbf{r} \sim N_n \left(\mathbf{0}, \sigma^2 (\mathbf{I}_n - \mathbf{H}) \right),$$

$$r_{J(i)} \sim t(n - k).$$

Odlehlá pozorování

Definice 16

Pozorování Y_i je **odlehlé**, jestliže $E\varepsilon_i \neq 0$.

Věta 17

Hypotézu $H_0 : E\varepsilon_i = 0$ proti $H_1 : E\varepsilon_i \neq 0$ zamítneme na hladině významnosti α , tzn. pozorování Y_i je odlehlé, pokud

$$|r_{J(i)}| \geq t_{1-\alpha/2}(n-k).$$

Pro $n - k > 30$ lze použít aproximaci podmínky ve tvaru $|r_{J(i)}| \geq 2$.

Lze využít také DFFIT reziduí.

Pro $n - k > 30$ detekujeme jako odlehlá ta pozorování, pro něž platí

$$|d_i| > 2\sqrt{\frac{k}{n}}.$$

Vliv pozorování – Cookova vzdálenost

Definice 18 (Cookova vzdálenost)

Pro měření vlivu i -tého pozorování na hodnotu odhadu $\hat{\beta}$ se používá tzv. **Cookova vzdálenost**

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

Cookova vzdálenost je euklidovská vzdálenost mezi vektory predikce \hat{Y} ze všech pozorování a predikce $\hat{Y}_{(i)}$ při vynechání i -tého pozorování, a souvisí s konfidenčním elipsoidem odhadů. Vyjadřuje vliv i -tého bodu pouze na odhady $\hat{\beta}$, nikoliv na odhad rozptylu σ^2 náhodných chyb.

Věta 19

V praxi se obvykle za vlivný bod označuje takový, pro nějž je $D_i > 1$.

Vliv pozorování – další možnosti

Definice 20 (Welschova-Kuhova vzdálenost)

Pro měření vlivu i -tého pozorování simultánně na hodnotu odhadu $\hat{\beta}$ i na odhad rozptylu σ^2 náhodných chyb se používá statistika

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

Definice 21 (Parciální vliv)

Pro měření vlivu i -tého pozorování na hodnotu j -té složky $\hat{\beta}_j$ odhadu $\hat{\beta}$ je navržena statistika

$$DFBETAS_{ij} = \frac{\hat{\beta}_j - \hat{\beta}_{j(i)}}{\sqrt{D\hat{\beta}_j}}.$$

Věta 22

Obvykle se parciální vliv považuje za prokázaný, pokud $DFBETAS_{ij} > 2 \sqrt{\frac{k}{n}}$.

Vliv pozorování – variační poměr

Definice 23 (Variační poměr)

Pro měření vlivu i -tého pozorování na kovariační matici $D\hat{\beta}$ (spec. na rozptyly) vektoru odhadů $\hat{\beta}$ je navržena statistika

$$\text{COVRATIO}_i = \left(\frac{s_{(i)}^2}{s^2} \right)^k \frac{1}{1 - h_{ii}}.$$

Věta 24

Jako pozorování mající vliv na kovariační matici $D\hat{\beta}$ odhadů $\hat{\beta}$ se doporučuje považovat ta, pro něž je $|\text{COVRATIO}_i - 1| > 3\frac{k}{n}$.

Graf predikovaných reziduí:

- osa x : predikovaná rezidua $r_P(i)$
- osa y : rezidua r_i
- vybočující body jsou identifikovány polohou výrazně mimo přímku $y = x$
- odlehlá pozorování sice leží na přímce $y = x$ či v její blízkosti, ale jsou výrazně vzdálená od ostatních pozorování

Williamsův graf:

- osa x : vlivy h_{ii}
- osa y : jackknife rezidua $r_J(i)$
- mezní linie pro odlehlá pozorování: $y = t_{1-\alpha/2}(n-k)$
- mezní linie pro vybočující body: $x = 2\frac{k}{n}$
- bublinkový graf: obsah bublinek reprezentujících jednotlivá data je úměrný Cookově vzdálenosti D_i

Pregibonův graf:

- osa x : vlivy h_{ii}
- osa y : kvadráty $r_{M(i)}^2$ modifikovaných normovaných reziduí
- hraniční linie: $y = -x + 2\frac{k}{n}$ a $y = -x + 3\frac{k}{n}$
- pozorování zobrazená mezi oběma přímkami jsou vlivná, pozorování zobrazená nad horní přímkou jsou silně vlivná

Graf:

- osa x : vlivy h_{ii}
- osa y : Cookova vzdálenost D_i

Q-Q plot:

- osa x : teoretické kvantily standardizovaného normálního rozdělení $N(0;1)$
- osa y : standardizovaná rezidua r_{Si}

Grafické nástroje

Indexové grafy:

- osa x : index i pozorování
- osa y : jednotlivé typy reziduí nebo vlivy h_{ii} nebo odhady $\beta_{(i)}$ nebo vzdálenosti (např. Cookova D_i)

Graf:

- osa x : odhady \hat{Y}_i
- osa y : rezidua r_i


Graf:

- osa x : odhady \hat{Y}_i
- osa y : odmocniny absolutních hodnot standardizovaných reziduí, $\sqrt{|r_{Si}|}$


Scatter-plot:

- osa x : nezávisle proměnná
- osa y : závisle proměnná


Data set 1




Data set 2




Data set 1




Data set 2




Data set 1



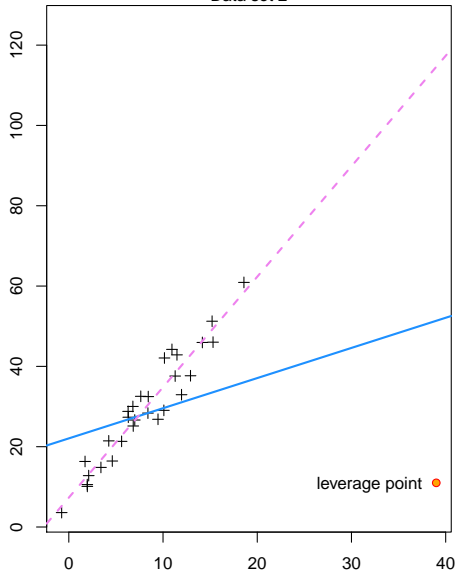
Data set 2



Data set 1



Data set 2



LRM pro Dataset 1

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

Residuals:

Min	1Q	Median	3Q	Max
-8.2031	-1.6710	0.0737	3.1437	6.3020

Coefficients:

	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	***

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

LRM pro Dataset 1

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



Residuals:



Min	1Q	Median	3Q	Max
-40.357	-6.517	0.260	6.759	24.885

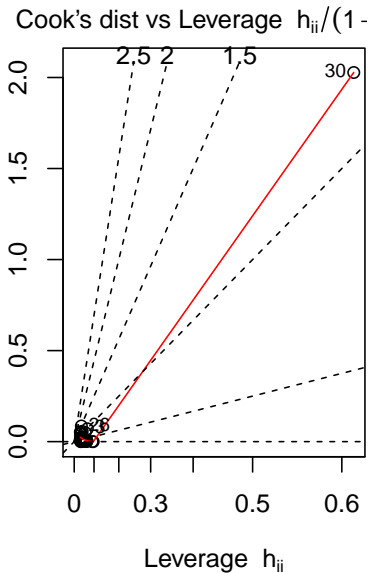
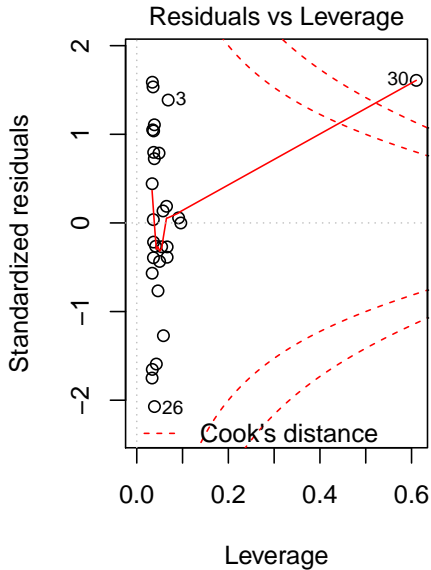
Coefficients:



	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	*



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


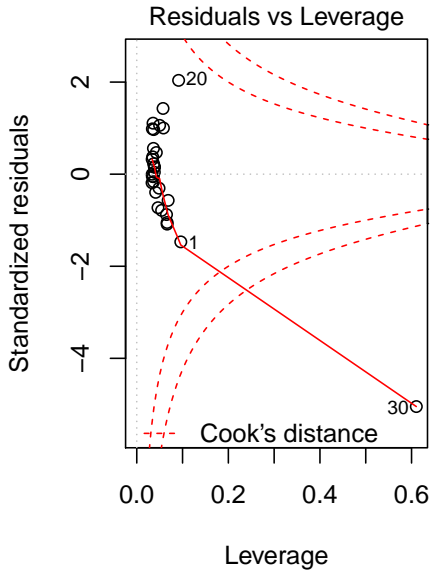


















Podezřelá pozorování pro Dataset 1

meze pro h_{ii} : $2*k/n=0.1333$ $3*k/n=0.2$

	[,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


Podezřelá pozorování pro Dataset 2

meze pro h_{ii} : $2*k/n=0.1333$ $3*k/n=0.2$


	[,1]	[,2]	[,3]	[,4]	[,5]	[,6]
20	20	18.58604	60.91134	2.16843	0.09137258	0.2088146
30	30	39.00000	11.00000	-16.50284	0.61041902	19.9574746

Struktura tabuky: $i \mid x_i \mid Y_i \mid r_{J(i)} \mid h_{ii} \mid D_i$

Diagnostic Plots



Diagnostic Plots



Test nulovosti středních hodnot reziduí Dataset 1




No Studentized residuals with Bonferonni $p < 0.05$




Largest |rstudent|:

	rstudent	unadjusted p-value	Bonferonni p
26	-2.210719	0.035713	NA

Test nulovosti středních hodnot reziduí Dataset 1

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





Podezřelá pozorování pro Dataset 1


```
index  x   y   dfb.x1
1      30 39 125 2.01818
```

Podezřelá pozorování pro Dataset 1


```
index      x      y      dfb.x2
30      30      39      11 -20.08538
20      20      18.58604 60.91134 0.5480413
1        1 -0.7576732 3.591746 0.3962400
```

```
index  x   y      dffit
1      30 39 11 -20.65732
```


Data set 1



Data set 2



Regresní diagnostika v R

```
library (car)
model <-lm (... ~..., ...)
plot (model, which=...)
influence.measures (model)
rstandard (model)
rstudent (model)
dffits (model)
dfbetas (model)
covratio (model)
hatvalues (model)
cooks.distance (model)
influencePlot (model)
infIndexPlot (model, ...)
outlierTest (model)
```

diagnostické grafy
vlivy a příbuzné statistiky
standardizovaná rezidua
jackknife rezidua
statistika DFFITS
statistika DFBETAS
variační poměr COVRATIO
vlivy
Cookova vzdálenost
diagnostické grafy pro vlivy
indexové grafy
simultánní test odlehlých pozorování