

## Regrese

Dále se budeme zabývat vztahem funkce na výsledku hodnoty jedné veličiny na hodnoty druhé, tj. budeme hledat funkci  $f$  tak, aby po posouzení hodnoty  $y_1, \dots, y_m$  platila  $y_i = f(x_i) + e_i$ , kde  $x_1, \dots, x_n$  jsou hodnoty měřivé pomeřné, když mají hodnoty odchylky posouzených dat od ideální hodnoty.

Statistika bavíme neurčitým zákonem optimačního lvaře když (tj. když lze kdežto řešit, polynom, exponentiela, -), umí pouze k řešení neznámých obecnějších lvařů s důležitými optimálními parametry, závislosti čili jiného řešení než polynomu a posouzení, když je jeho kontinuita lvařka pro daná data lze již zjistit.

## Lineární regresní model

máme vektor pozorování  $\mathbb{Y} = (Y_1, \dots, Y_n)'$

matice daných čísel  $\mathbb{X}$  typu  $n \times k$  - bude mít pravděpodobnost, že  
bodové  $\mathbb{X}$  je k až  $n > k$

$\beta = (\beta_1, \dots, \beta_k)'$  vektor neznámých parametrů

$\varepsilon = (\varepsilon_1, \dots, \varepsilon_n)'$  vektor náhodných chyb, jenž leží plati  $E\varepsilon = 0$ ,  $\text{var } \varepsilon = \sigma^2 \mathbb{I}$   
( $y_i$  je pouze menší náhodná veličina,  $E\varepsilon_i = 0$ ,  $\text{var } \varepsilon_i = \sigma^2$ )

model  $\mathbb{Y} = \mathbb{X}\beta + \varepsilon$

platí  $E\mathbb{Y} = \mathbb{X}\beta$ ,  $\text{var } \mathbb{Y} = \sigma^2 \mathbb{I}$

"nápravný" pro  $f(x) = \beta_0 + \beta_1 x + \beta_2 x^2$  bude matice

$$\mathbb{X} = \begin{pmatrix} 1 & x_1 & x_1^2 \\ 1 & x_2 & x_2^2 \\ \vdots & \vdots & \vdots \\ 1 & x_m & x_m^2 \end{pmatrix} \quad \text{a } \beta = (\beta_0, \beta_1, \beta_2)'$$

pak opakuji  $y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \varepsilon_i$

budly byl možný chtět počítat křivku  $f(x) = \beta_0 + \beta_1 \log x$ ,

knokla bych

$$\mathbb{X} = \begin{pmatrix} 1 & \log x_1 \\ 1 & \log x_2 \\ \vdots & \vdots \\ 1 & \log x_m \end{pmatrix} \quad \text{a } \beta = (\beta_0, \beta_1)'$$

a obecný model by byl pak slyšit  $\mathbb{Y} = \mathbb{X}\beta + \varepsilon$

lineární regrese - pojmenování modelu lineárního rozložení mezi množinou parametrů, mezi hodnotami  $x_i$

a modelu je třeba odhadovat meziříčí parametry  $\beta$  a  $\sigma^2$   
odhaduje se množina nezávislých členů, aby byly

$$S_e = \mathbf{x}'\mathbf{e} = (\mathbf{y} - \mathbf{x}\boldsymbol{\beta})'(\mathbf{y} - \mathbf{x}\boldsymbol{\beta}) \text{ bylo minimální}$$

případně  $S_e = \mathbf{x}'\mathbf{e} = \sum_{i=1}^m e_i^2 = \sum_{i=1}^m (y_i - \sum_{j=1}^k x_{ij}\beta_j)^2$

používáme  $\frac{\partial S_e}{\partial \beta_1} = -2 \sum_{i=1}^m (y_i - \sum_{j=1}^k x_{ij}\beta_j) x_{i1} = 0$

⋮

$$\frac{\partial S_e}{\partial \beta_k} = -2 \sum_{i=1}^m (y_i - \sum_{j=1}^k x_{ij}\beta_j) x_{ik} = 0$$

dostaneme  $\sum_{i=1}^m y_i x_{i1} = \sum_{i=1}^m \sum_{j=1}^k x_{ij}\beta_j x_{i1}$

⋮

$$\sum_{i=1}^m y_i x_{ik} = \sum_{i=1}^m \sum_{j=1}^k x_{ij}\beta_j x_{ik}$$

to je matice  $\mathbf{X}'\mathbf{y} = \mathbf{X}'\mathbf{X}\boldsymbol{\beta}$  - lomen se říká soustava normálních rovnic

řešení je  $\boldsymbol{\beta} = \hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$  pokud  $\mathbf{X}'\mathbf{X}$  je regulární, a t. následně je, protože  $\mathbf{X}$  má plné hodnoty

$\hat{\mathbf{y}} = \mathbf{X}\boldsymbol{\beta}$  je odhad (aproximace) reálné  $\mathbf{y}$

platí  $E\hat{b} = \beta$ ,  $\text{var } b = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$ ,  $E\hat{Y} = E\mathbf{X}\hat{b} = \mathbf{X}\mathbf{E}\hat{b} = \mathbf{X}\beta = EY$

dále:  $E\hat{b} = E[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'Y] = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'EY = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}\beta = \beta$

$$\begin{aligned} \text{var } b &= \text{var}[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'Y] = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\text{var } Y\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} = \\ &= (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\sigma^2 I \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} \end{aligned}$$

předpokládáme matice, že  $Y \sim N(\mathbf{X}\beta, \sigma^2 I)$

pak  $b \sim N(\beta, \sigma^2 (\mathbf{X}'\mathbf{X})^{-1})$

veličina  $R = \hat{s}_e^2 = (Y - \mathbf{X}\hat{b})'(Y - \mathbf{X}\hat{b})$  se nazývá residualní matice etou

představuje odhad chyby, které se dopestují, když je zahrnut nesprávný parametr  $\beta$  mimoadime jeho odhadem  $\hat{b}$

da' se dokázat, že  $ER = (n-k)\sigma^2$

a tedy  $s^2 = \frac{R}{n-k}$  je nezávislý odhad rozptylu  $\sigma^2$

$$a \text{že } \frac{R}{\sigma^2} \sim \chi^2_{n-k}$$

a matice  $b$  a  $R$  jsou nezávislé

(dokázal to nebudem, je to lama práce, jár většinu teorie matice, kterou mách, to asi myslí)

veličina  $s^2$  se nazývá residualní rozptyl.

Dále se budeme věnovat jednotlivým odhadům  $b_i$  odhadu  $\hat{b}$ .

ježliž  $\hat{b} \sim N(\beta, \sigma^2 (\mathbf{X}'\mathbf{X})^{-1})$ , pak  $b_i \sim N(\beta_i, \sigma^2 \sigma_{ii})$

kde  $\sigma_{ii} = (\mathbf{X}'\mathbf{X})_{ii}^{-1}$  ... prvek matice

a tedy  $U_i = \frac{b_i - \beta_i}{\sigma \sqrt{n_{ii}}} \sim N(0, 1)$

$$\text{dalej } \chi^2 = \frac{(m-k)s^2}{\sigma^2} = \frac{R}{\sigma^2} \sim \chi^2_{m-k}$$

$$\text{proto } T_i = \frac{U_i}{\sqrt{\frac{\sigma^2}{m-k}}} \sim t_{m-k}$$

$$\text{dosadim: } T_i = \frac{\frac{b_i - \beta_i}{\sigma \sqrt{n_{ii}}}}{\sqrt{\frac{s^2}{\sigma^2}}} = \frac{b_i - \beta_i}{\sqrt{s^2 n_{ii}}}$$

na této věci se pak dají rozložit testy hypotéz o

parametru  $\beta_i$ , např.  $H: \beta_i = 0$  proti  $H: \beta_i \neq 0$

téža a půjčadej approximace polynomem  $f(x) = \beta_0 + \beta_1 x + \beta_2 x^2$

testem  $H: \beta_2 = 0$  systém, jestli je množství nul pěkné

$$f'(x) = \beta_0' + \beta_1' x$$

Příklady

a) posloužíme si my  $f(x) = \beta_0 + \beta_1 x$

$$\mathbf{x} = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_m \end{pmatrix} \quad \mathbf{x}' \mathbf{x} = \begin{pmatrix} m & \sum x_i \\ \sum x_i & \sum x_i^2 \end{pmatrix}$$

$$(\mathbf{x}' \mathbf{x})^{-1} = \frac{1}{m \sum x_i^2 - (\sum x_i)^2} \begin{pmatrix} \sum x_i^2 & -\sum x_i \\ -\sum x_i & m \end{pmatrix} \quad \mathbf{x}' \mathbf{y} = \begin{pmatrix} \sum y_i \\ \sum x_i y_i \end{pmatrix}$$

$$\text{odhad } \mathbf{B} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} = \frac{1}{m\sum x_i^2 - (\sum x_i)^2} \begin{pmatrix} \sum x_i^2 & -\sum x_i \\ -\sum x_i & m \end{pmatrix} \begin{pmatrix} \sum y_i \\ \sum x_i y_i \end{pmatrix} =$$

$$= \begin{pmatrix} \frac{\sum x_i^2 \sum y_i - \sum x_i \sum x_i y_i}{m \sum x_i^2 - (\sum x_i)^2} \\ \frac{m \sum x_i y_i - \sum x_i \sum y_i}{m \sum x_i^2 - (\sum x_i)^2} \end{pmatrix} = \begin{pmatrix} b_0 \\ b_1 \end{pmatrix}$$

po odhadu rozměru  $\beta^2 = \frac{R}{m-2}$  použijeme rovnici  $R = \mathbf{Y}'\mathbf{Y} - \mathbf{B}'\mathbf{X}'\mathbf{Y}$ ,

která se může dát i takto, a máme


$$\beta^2 = \frac{1}{m-2} \left( \sum y_i^2 - b_0 \sum y_i - b_1 \sum x_i y_i \right)$$

testovací kritérium pro  $H: \beta_1 = 0$  je-li  $B: \beta_1 \neq 0$

$$\frac{|b_1| \sqrt{\sum x_i^2 - m\bar{x}^2}}{\sqrt{\beta^2}} \Rightarrow t'_{m-2}(x) \dots \text{kritická hodnota}$$

dal by se taky udat interval spolehlivosti pro  $\beta_1$ , ale ten nás moc nezajímá

spisť by bylo zajímavé mít intervalový odhad pro  $\beta_0 + \beta_1 x$ ,  
když po hledání bod na půmice, čímž by se zjistil přesný prosah.



dokle nejde. by se  
se padat

navedu rektor  $\mathbf{e} = \begin{pmatrix} 1 \\ \mathbf{x} \end{pmatrix}$

pak  $\beta_0 + \beta_1 x = \mathbf{c}' \boldsymbol{\beta}$  a odhad  $b_0 + b_1 x = \mathbf{c}' \mathbf{b}$

platí:  $E\mathbf{c}' \mathbf{b} = \mathbf{c}' E \mathbf{b} = \mathbf{c}' \boldsymbol{\beta}$

$$\text{var } \mathbf{c}' \mathbf{b} = \mathbf{c}' (\text{var } \mathbf{b}) \mathbf{c} = \sigma^2 \mathbf{c}' (\mathbf{X}' \mathbf{X})^{-1} \mathbf{c}$$

$\mathbf{c}' \mathbf{b}$  má normální rozdělení

$\mathbf{c}' \mathbf{b}$  a  $s^2$  jsou nezávislé

$$\text{proto } \frac{\frac{\mathbf{c}' \mathbf{b} - \mathbf{c}' \boldsymbol{\beta}}{\sqrt{\sigma^2 \mathbf{c}' (\mathbf{X}' \mathbf{X})^{-1} \mathbf{c}}}}{\sqrt{\frac{s^2}{\sigma^2}}} = \frac{\mathbf{c}' \mathbf{b} - \mathbf{c}' \boldsymbol{\beta}}{\sqrt{s^2 \mathbf{c}' (\mathbf{X}' \mathbf{X})^{-1} \mathbf{c}}} \sim t_{m-n} \quad (\text{a můžeme pídat } t_{m-n})$$

intervalový odhad na hladině  $1-\alpha$  pro  $\mathbf{c}' \boldsymbol{\beta}$  lze tedy když obecně

$$(\mathbf{c}' \mathbf{b} - t'_{m-n}(\alpha) \sqrt{s^2 \mathbf{c}' (\mathbf{X}' \mathbf{X})^{-1} \mathbf{c}}, \mathbf{c}' \mathbf{b} + t'_{m-n}(\alpha) \sqrt{s^2 \mathbf{c}' (\mathbf{X}' \mathbf{X})^{-1} \mathbf{c}})$$

a následně pídat

$$b_0 + b_1 x \pm t'_{m-n}(\alpha) \sqrt{s^2 \left( \frac{1}{m} + \frac{(x - \bar{x})^2}{\sum x_i^2 - m\bar{x}^2} \right)}$$

b) polynomický polynom  $f(x) = \beta_0 + \beta_1 x + \dots + \beta_n x^n$

verejme se matice

$$\mathbf{X} = \begin{pmatrix} 1 & x_1 & \dots & x_1^n \\ 1 & x_2 & \dots & x_2^n \\ \vdots & \vdots & & \vdots \\ 1 & x_m & & x_m^n \end{pmatrix}$$

a tím je to teoreticky dokázáno, prakticky ovšem nastavujejí potřebují

$\beta$  horizontem stupněm polynomu řečíme tř. matice  $X'X$  spoluž  
podminěnou (mať řečeno můžeme determinantu, blíží se singulární  
matice)

opysat:  $(X'X)^{-1}$  lze mít tř. řečené následující %  
místa písni inverse se degraduje reálnou vlastností možnámožnosti:

norme  $X'X\beta = X'X$  pouze numerickými metodami, mít se  
bez nich ucela objekt a řešit minimalizace se od řečeného numericky:  
ortogonalizace transformace

Gramm-Gibridova metoda.

Karushova metoda.

Givensova metoda

Newtonova singulární hodnota

dají se nazvat např. v Ralstonovi (Tabulky numerického matematiky)

nebo Antoch-Vorlicková. Výkonné metody statistiky analyzují dole  
jina inverse se upozorňuje asi od stupně polynomu 7

Problém určení optimálního stupně polynomu

možnosti: 1) řečí řečenému  $p=0$  a postupně do kryštalického  
písemka každý přidaný koeficient testovat, aby

je reálný ad můžete  
postat o obecnéku, když přidaný člen je statisticky  
možný

2) kritický od řečené - řečí řečenému možným je  
a postupně mítovat

% Tržby jsou právě posuvnými součty

$$a) 2x + 6y = 8$$

$$2x + 6,00001y = 8,00001$$

$$\text{řešení: } x = 1$$

$$y = 1$$

$$b) 2x + 6y = 8$$

$$2x + 5,99999y = 8,00002$$

$$\text{řešení: } x = 10$$

$$y = -2$$

Postraj odpadají levého kolence, přesto se řešení pracovně liší.

Je třeba počítat o maximální pěnovce, rešením vlastně násobkem kladných hodnot množství mýdla.

v písmadlo a) má malice postraj A determinant

$$\det A = 2 \cdot 6,00001 - 2 \cdot 6 = 0,00002$$

inverzní matice je

$$A^{-1} = \frac{1}{\det A} \begin{pmatrix} 6,00001 & -6 \\ -2 & 2 \end{pmatrix} = \begin{pmatrix} 300\,000,5 & -300\,000 \\ -100\,000 & 100\,000 \end{pmatrix}$$

řešení:

$$\begin{pmatrix} x \\ y \end{pmatrix} = A^{-1} \begin{pmatrix} 8 \\ 8,00001 \end{pmatrix} = \begin{pmatrix} 2\,400\,004 - 2\,400\,003 \\ -800\,000 + 800\,001 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$

když jich máme násobkem 8,00001 na 8:

$$\begin{pmatrix} x \\ y \end{pmatrix} = A^{-1} \begin{pmatrix} 8 \\ 8 \end{pmatrix} = \begin{pmatrix} 2\,400\,004 - 2\,400\,000 \\ -800\,000 + 800\,000 \end{pmatrix} = \begin{pmatrix} 4 \\ 0 \end{pmatrix} \quad \begin{matrix} \text{xnačná} \\ \text{elipsa} \end{matrix}$$

## stupně polynomu

1. Odhad je da' napi. xáoxit na hodnotach  $S_k^2$  počítaných postupně v modelu

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \dots + \beta_k X^k$$

pro  $k = 1, 2, \dots$

Té způsobem získaném modeluje  $S^2$  nešpatnější odhadem  $\sigma^2$ .

Zpravidla se upřednostňuje stupň polynomu  $k_0$  se určitou laby, aby platilo  $ES_k^2 > \sigma^2$  pro  $k < k_0$  a  $ES_k^2 = \sigma^2$  pro  $k \geq k_0$ .

Kruha se da' počítat z grafu hodnot  $S_k^2$ , blíž od  $k_0$  racína bývá konstantní.

Není všeobecně možné upřednostnit nějaký stupň, mohou je být, pokud se lím do modelu máš jistě mnoho neznámých parametrů, a to mohou být mnohem méně známých. Neznámé  $y_i$  mohou být doporučena sítovou, takže my je vlastně ani nechceme upřednostnit absolutně jistější, pokud se lím týdom ten závisí vlastně na budování daného modelu.

Jaký název bude mít použití lehkoj řeči pědofunkce na výsledky?

Předlohy bude použitelný jenom odhad parametru  $\beta$ , tj.

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}, \text{ a budeme mít, že je nezávislý.}$$

Ale sam se rádne' další' předpoklady upraví.

Oblastní výsledky (odhad rozptylu, testy hypotéz...) mohou být  
ukresleny.

(V případě analýzy složitosti algoritmu bude myčastěji použit  
předpoklad o konstantním rozptylu, pokud rozptyl je dobrý  
výsledek s rozsahem rozsahu výsledků obvykle málo růst.)

Gilvaldo, K. Tvaria: Regressn' analýza

Academia, Praha 1989


Při použití předpokladu normality chyb - existuje robustní metoda odhadu.

Ty se používají i v případech, kdy se v pozorování objevují výjimečné,  
vysoké hodnoty, označka' pozorování.

Při nekonstantním rozptylu se dá' někdy použít metoda načerpávky  
myšlených členů, kde  $\text{var } e = G/\mathbf{K} (= G^2/\mathbf{I})$ . Umoží-li matice  $\mathbf{K}$   
nejake odhadnout, pak minimalizujeme  $(\mathbf{Y} - \mathbf{X}\beta)' \mathbf{K}^{-1} (\mathbf{Y} - \mathbf{X}\beta)$   
a řešení bude mít formu  $\hat{\beta} = (\mathbf{X}'\mathbf{K}^{-1}\mathbf{X})^{-1}\mathbf{X}'\mathbf{K}^{-1}\mathbf{Y}$ .

Není-li matice  $\mathbf{K}$  diagonální, myslí se k tomu náročně i použití  
předpokladu meramostní pozorování.

O kvalitě řezené dalekohledají závratná' residua, která' by teoreticky měla odpovídat chybám  $\epsilon_i$ , o kterých se říkalo výše, až jenže to nazajem neexistuje náhodné relace s rozdílením  $N(0, \sigma^2)$ . To se da' bud' statistickým testem, nebo alegorii rozdílnosti posoudit a grafem residuum. Jen může vypadat např. takto:



Co se na lhotu da' počítat? Života to, že aby mají schůzce mezi všemi střední hodnotou, ale rozptyl mení konstantně, roste. Další podomítky věci by mohly být třeba:

oddělení (extremum) hodnoty

nějaký typ rozdílosti mezi horizontálními

převáha bladřík (metr různých) hodnot, spolu s rozdíly  
nějaká málo významná významná

## Další pomocné k regrese:

Zatím jsme jeho měřila kvality regresního modelu měly rozdílné součet čtvrtce  $\sum_i (y_i - \hat{y}_i)^2$ , čím je menší, tím je model lepší. Jak se ale pojme, jestli je RSS dost malý?

Jevou mimo kvality je koeficient determinace

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2},$$

Když by měl být napravě blíž 1

Vysvětlení:  $\sum_i (y_i - \bar{y})^2$  je celková variabilita vektoru  $\mathbf{Y}$

$\sum_i (y_i - \hat{y}_i)^2$  je část variability způsobené chybou regrese  
zbylé je variabilita objasněna regresním modelem

podíl  $\frac{\text{RSS}}{\sum_i (y_i - \bar{y})^2}$  když říká, jaký del% variabilitě je způsoben celkové  
chybou

$R^2$  udává, jaký del% celkové variabilitě je způsoben  
použitím regresním modelem

$R^2$  se obvykle vyjadřuje v procentech

Dalším měřítkem kvality modelu je tvar jeho prediktérniho počtu.

Data ne rozdělují na dvě poloviny  $(Y_1, \dots, Y_{m/2})$  a  $(Y_{m/2+1}, \dots, Y_m)$ .

Odhady se vypočítají k lepšímu polovině, pak se ukončuje, jestli vykrojuji i pro druhou polovinu. Např. podle brilemka

$$K = \frac{\text{RSS}}{\sum_{i \in M_1} (y_i - f(x_i, b(M_2)))^2 + \sum_{i \in M_2} (y_i - f(x_i, b(M_1)))^2}$$

hde  $f(x_i, b(M_j))$  je hodnota regresní funkce v bodě  $x_i$  pro parametry odhadnutými k části  $M_j$ .

Kodina  $K$  by se o soudržném půjčení měla blížit 1.

Konečné brilemum je i shoda s publicijně pořadovaný, např.

aby doba výpočtu nebyla mimořádně dlouhá.

## Dlelece vlivyjí porování v lineární regrese



Jak poznat mru daly oscilační hodnoty?

Jak vychodit, kda mohou významné ovlivnit statistickou analýzu a jakým způsobem?


Nevzorného hr. adélka porování - to jsou oscilační hodnoty ve souboru Y

nfocující body - oscilační body ve souboru X  
(někdy může jít o da typy nášvěr).

Jejich výsledek mohou neovlnit analýzu dat, protože "regadají" do modelu", např.



někdy ji veline' podstaví, např.



V tomto případě je nazýváno olymjicí body.

### Dělkou oddálky do průměru

a) vizuálně  $\approx$  grafu nebo  $\approx$  grafu residuum

b) statistickými testy, např.

nechť  $r_i$  jsou residua,  $s^2 = \frac{Se}{n-p}$  (resp.  $s^2 = Y - \hat{Y}$ )

( $Se$  je residuální soudí členec,  $p$  je počet merných parametrů)

$h_{ii}$  je jedna matice  $H = X(X'X)^{-1}X'$  (projektionní matice)

$t_i = \frac{r_i}{s\sqrt{1-h_{ii}}}$  je to tzv. standardizovaná resida

$$t_i^* = \frac{r_i}{s_{(i)}\sqrt{1-h_{ii}}}, \text{ kde } s_{(i)} = \frac{\|Y_{(i)}(I-X_{(i)}(X'_{(i)}X_{(i)})^{-1}X'_{(i)})\|}{n-p-1}$$

je to tzv. studentizovaná resida

$(\hat{X}_{(i)})$  je matice  $X$  po vyjmutí  $i$ -tého řádku,  $\hat{Y}_{(i)}$  je vektor  $Y$  po vyjmutí  $i$ -tého proudu

Plati:  $t_i^*$  máji t-vzdešení s  $m-p-1$  sl. volnosti.

Nechť hypotéza  $H_0$ : i-té pozorování odpovídá řadě modelu jeho ostatní

$H_0$  se namítá, když  $|t_i^*| > t_{m-p-1}(\alpha)$ .

Mixi  $t_i^*$  a  $t_i$  plati' mlah

$$t_i^* = t_i \sqrt{\frac{m-p-1}{m-p-t_i^2}}$$

### Dležce vybocujících bodů

je rozložena na hodnotách  $h_{ii}$ , po které platí  $0 \leq h_{ii} \leq 1$ .

Ví se, že jednotky mají jednotkové pozorování  $y_i$  působit hodnotu stejnoumiň, měla by být  $h_{ii} = \frac{1}{n}$ .

Koefficie  $h_{ii}$  blíže k 1 znamenala odpovídají vybocujícím bodům.

### Dležce vlnujících bodů

Jednou z používaných měří je Cochova vzdálenost

$$\begin{aligned} d_i &= \frac{(\hat{Y} - \hat{Y}_{(i)})'(\hat{Y} - \hat{Y}_{(i)})}{p\beta^2} = \frac{(\hat{\beta} - \hat{\beta}_{(i)})'X'X(\hat{\beta}' - \hat{\beta}_{(i)})}{p\beta^2} = \\ &= \frac{t_i^2}{p} \cdot \frac{h_{ii}}{1-h_{ii}} \end{aligned}$$

Velké hodnoty  $D_i$  ukazují významný vliv i-tého porovnaní na odhad  $\hat{\beta}$ .

V praxi se měří hodnoty  $D_i$  srovnává s kritickými hodnotami rozdělení

$F_{p, m-p}$ , i když to není výplň písma.

Kolečením po měření vlivu išic porovnaní na odhad  $\hat{\beta}$ :

$$D_{i_1, \dots, i_k} = \frac{(\hat{\beta} - \hat{\beta}_{(i_1, \dots, i_k)})' X' X (\hat{\beta} - \hat{\beta}_{(i_1, \dots, i_k)})}{p \sigma^2}$$

hde  $\hat{\beta}_{(i_1, \dots, i_k)}$  je odhad  $\beta$  metodou nejméně čtverců po výjmutí porovnaní  $i_1, \dots, i_k$ .

Hodnoty se opět porovnávají s kritickými hodnotami  $F_{p, m-p}$ .

Robustní Cookova vzdáenosť - ne může pro  $D_i$  se  $s^2$  mnohadi

mnohadi' významnou robustním odbadem vypočítat  $\sigma^2$ .

Welschova - Kubova vzdáenosť

$$DFITS_i = \frac{|x_i' (\hat{\beta} - \hat{\beta}_{(i)})|}{\hat{\beta}_{(i)} \sqrt{h_{ii}}} = |t_i^*| \sqrt{\frac{h_{ii}}{1-h_{ii}}}$$

hde  $x_i'$  je i-ty řádek matice  $X$

Velké hodnoty (řetězově  $\sqrt{\frac{4n}{m}}$ ) mohou ovlivnit následujícím způsobem

i-tého porovnaní.

Také měla od rána vlnu i-kde posouvaní myši na odklad β, ale i na odklad γ?

Existují další melody, které měla vlnu na jednoduché složky reblom β apod.

Po delce "pochvály" hodnot se maximálně rozběhnout co srdci, když je vložen (mohou to být dny) nebo je vloženo do modulu (v tom případě je dobré použít nějaké robustní melodie) nebo se jen ulevit radostí (mohou ukončit na velmi deprimové písni).