

Diagnóstico

Motivação:

Em algumas análises, as estatísticas básicas podem mudar muito quando um elemento amostral é retirado. Este ponto será denominado “influyente”.

Técnicas de diagnóstico:

Formas de detectar pontos influentes.

1- Matriz “Hat”

$$Y = X\beta + \varepsilon$$

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

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

$$H = X(X'X)^{-1}X'Var(\hat{Y}) = H\sigma^2IH = H\sigma^2$$

$$\hat{y}_1 = h_{11}y_1 + h_{12}y_2 + \dots + h_{1n}y_n$$

$h_{ij} \rightarrow$ influência exercida por y_j em $\hat{y}_i$.

$h_{ii} \rightarrow$ influência exercida por y_i em $\hat{y}_i$.

H – simétrica e idempotente ($H^2 = H$) e $\sum_{i=1}^n h_{ii} = k + 1$ (var. indep intercepto, ou k – modelo sem intercepto).

$$h_{ii} = \sum_{j=1}^n h_{ij}^2 = h_{ii}^2 + \sum_{j \neq i} h_{ij}^2, (0 \leq h_{ii} \leq 1)$$

“Valor médio” de $h_{ii} = \frac{k+1}{n}$.

Análise os elementos da diagonal de H (h_{ii}) e dê especial atenção a pontos X_i


tais que $h_{ii} > \frac{2(k+1)}{n}$.

$$h_{ii} = 0 \text{ ou } h_{ii} = 1 \rightarrow h_{ij} = 0, \forall i \neq j$$

a) $h_{ii} = 0$ $h_{ij} = 0 \rightarrow \hat{y}_i = 0 \forall Y$ ($\hat{y}_i$ não é afetado por Y)

b) $h_{ii} = 1$ $h_{ij} = 0 \rightarrow \hat{y}_i = y_i$

H independe de Y. Uma checada em H pode revelar pontos sensíveis, nos quais um valor discrepante em y terá um grande impacto no ajuste.



Exemplo:

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

$$X = \begin{bmatrix} 1 & \dots & 1 \\ x_1 & \dots & x_n \end{bmatrix},$$

$$h_{ij} = \frac{1}{n} + \frac{(x_i - \bar{x})(x_j - \bar{x})}{\sum (x_i - \bar{x})^2} \quad \text{Procure valores tais que } h_{ij} > \frac{4}{n}$$

$$h_{ii} = \frac{1}{n} + \frac{(x_i - \bar{x})^2}{\sum (x_i - \bar{x})^2} \rightarrow \text{Ponto influente: abscissa distante de } \bar{x}.$$

Obs:

-Para $k > 2$, é difícil visualizar graficamente pontos X_i distantes do grupo e a diagonal de H é uma importante fonte de informação.

-O efeito do i-ésimo caso na regressão é mais provável ser alto se h_{ii} é alto, mas sua importância é incerta dependendo dos y_j . Existem medidas que combinam h_{ii} e os y_j .

Obs: nem sempre o resíduo associado a um ponto “discrepante” em Y é alto.

Ex


X	1	2	3	4	5	8
y	2	4	4	5	5.5	12

$$r = 0,9428$$

$$\widehat{\beta}_0 = 1,7$$

$$\widehat{\beta}_1 = 0,8$$

$$\hat{y} = 1,7 + 0,8x$$



Acrescentando o ponto (8,12)

$$R = 0.9576 \quad SSR = 54.55$$

$$\widehat{\beta}_0 = 0.33 \quad SSE = 4.61$$

$$\widehat{\beta}_1 = 1.33 \quad \sigma^2 = 1.15$$

$$\hat{y} = 0.33 + 1.33x$$

x_i	$\hat{y}_i$	e_i	h_{ii}	r_i	t_i
1	1.66	0.34	0.425	0.42	0.36
2	3.00	1.00	0.274	1.09	1.10
3	4.32	-0.32	0.188	-0.33	-0.27
4	5.65	-0.65	0.166	-0.67	-0.57
5	6.98	-1.48	0.211	-1.55	-1.92
8	11.00	1.00	0.730	1.89	3.92

Soma dos $h_{ii} = 1.994 \sim 2 = k + 1$

$$h_{ii} = \frac{1}{6} + \frac{(x_i - \bar{x})^2}{\sum (x_i - \bar{x})^2}$$

$$\bar{x} = \frac{23}{6} = 3.83$$

$$\sum (x_i - \bar{x})^2 = 30.84$$

$$h_{ii} \geq 2 \frac{(k+1)}{n} = \frac{4}{6} = 0.666$$

$$r_1 = \frac{0.34}{1.07\sqrt{1-0.425}}$$

2- Outros tipos de resíduos

$$e_i = y_i - \hat{y}_i \rightarrow \text{resíduo usual}$$

$$z_i = \frac{e_i}{\hat{\sigma}} \rightarrow \text{resíduo padronizado}$$

→ ir para verso de 3

$$r_i = \frac{e_i}{\hat{\sigma}\sqrt{1-h_{ii}}} \rightarrow \text{resíduo "internamente studentizado" (internally studentized residual)}$$

Válidas as suposições do modelo

$$\frac{r_i^2}{n-k-1} \sim \text{Beta}\left(\frac{1}{2}, \frac{n-k-1}{2}\right)$$

$$t_i = \frac{y_i - \tilde{y}_i}{\hat{\sigma}_{(i)} \sqrt{1 + X_i' (X_{(i)}' X_{(i)})^{-1} X_i}}^{1/2}, \text{ com } \tilde{y}_i = r_i \sqrt{\frac{n-k-2}{n-k-r_i^2}}$$

h_i pequeno - t_i pode ser alto porque e_i é alto, mas o "impacto" no ajuste deve ser menor.

h_i grande - t_i pode ser pequeno porque y_i é consistente com o modelo.

3- Medidas de influência

Os métodos mais comuns de detectar influência eliminam um caso do conjunto de dados de cada vez.

$\hat{\beta}_{(i)}$ - estimados de β computado sem o caso i .


$X_{(i)}$ - matriz $(n-1) \times (K+1)$, obtida tirando-se a i -ésima linha de X .

$$\hat{\beta}_{(i)} = (X_{(i)}' X_{(i)})^{-1} X_{(i)}' Y_{(i)}$$

No exemplo

$$\hat{\beta} = \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{bmatrix} = \begin{bmatrix} 0.33 \\ 1.33 \end{bmatrix} \quad \hat{\beta}_{(6)} = \begin{bmatrix} 1.7 \\ 0.8 \end{bmatrix}$$

Análise gráfica:



Como medir a distância entre $\hat{\beta}$ e $\hat{\beta}_{(6)}$?

Distância de Cook (D de Cook)

$$D_i = \frac{(\widehat{\beta}_{(i)} - \widehat{\beta})'(X'X)(\widehat{\beta}_{(i)} - \widehat{\beta})}{(K+1)\widehat{\sigma}^2}$$

$$\begin{cases} X\widehat{\beta}_{(i)} = \widehat{Y}_{(i)} \\ X\widehat{\beta} = \widehat{Y} \end{cases} \rightarrow D_i = \frac{(\widehat{Y}_{(i)} - \widehat{Y})'(\widehat{Y}_{(i)} - \widehat{Y})}{(K+1)\widehat{\sigma}^2}$$

Sugestões:

- Analise o caso com o mais alto D_i .
- Analise valores de D_i próximos de 1 e maiores ou iguais a 1.

Verifica-se que

$$D_i = \frac{1}{k+1} r_i^2 \frac{h_{ii}}{1-h_{ii}}$$

D_i é crescente em r_i^2 e em h_{ii} .

r_i – reflete falta de ajuste do modelo no ponto i .

h_{ii} – reflete a posição de X_i com relação a $\bar{X}$.

D_i alto é devido a $|r_i|$ alto ou h_{ii} alto, ou ambos.

Não existe um ponto de corte para D . Alguns autores sugerem o quantil de ordem 0,5 da distribuição F com k e $n - k - 1$ gl. No entanto, isto não é completamente satisfatório porque sabe-se que D_i não tem distribuição F. Um ponto de corte comum é $D_i \geq 1$.

$$DFit = \frac{\widehat{Y}_i - \widehat{Y}_{(i)}}{\sqrt{\widehat{\sigma}_{(i)}^2 h_{ii}}} = \left(\frac{h_{ii}}{1-h_{ii}} \right)^{1/2} \frac{e_i}{\widehat{\sigma}_i (1-h_{ii})^{1/2}} = \left(\frac{h_{ii}}{1-h_{ii}} \right)^{1/2} t_i$$

Belsley, Kuh e Welsch [1980] sugerem como ponto de corte $|DFit| > 2 \sqrt{\frac{p}{n}}$, $p = k + 1$

ou k .

Des:

$\tilde{X}_i'$ - i -ésima linha de X

$$X'_{(i)} X_{(i)} = X'X - \tilde{X}_i \tilde{X}_i'$$

$$(X'X - \tilde{X}_i \tilde{X}_i')^{-1} = (X'X)^{-1} + \frac{(X'X)^{-1} \tilde{X}_i \tilde{X}_i' (X'X)^{-1}}{1 - \tilde{X}_i' (X'X)^{-1} \tilde{X}_i}$$

$$\Rightarrow [X'_{(i)} X_{(i)}]^{-1} = (X'X)^{-1} + \frac{(X'X)^{-1} \tilde{X}_i \tilde{X}_i' (X'X)^{-1}}{1 - h_{ii}}$$

$$\text{pq } h_{ii} = \tilde{X}_i' (X'X)^{-1} \tilde{X}_i$$

$$\Rightarrow \hat{\beta} - \hat{\beta}_{(i)} = \frac{(X'X)^{-1} \tilde{X}_i e_i}{1 - h_{ii}}$$

Referências

Hoaglin, D. C. and Welsch, R. E. (1978). The Hat Matrix in Regression and ANOVA. The American Statistician, 32, 17-32.

Belsley, D. A., E. Kuh and R. E. Welsch (1980). Regression Diagnostic: Identifying Influential Data and Sources of Collinearity, Wiley, New York

Cook, R. D. and Weisberg, S. (1982). Residuals and Influence in Regression, New York: Chapman and Hall