

[wg Jobson, 227]

Niech $y = X\beta + u$, $Eu = 0, Vu = \sigma^2 I$, $X \in M(n, p + 1)$. Uwaga! W macierzy planu X pierwsza kolumna składa się z samych jedynek, a $p + 1$ jest liczbą współczynników regresji dla p zmiennych. Warunek najmniejszych kwadratów $\|y - X\beta\|^2$ daje estymator b parametru β postaci

$$b = (X^T X)^{-1} X^T y$$

Wtedy

$$\hat{y} = Xb = X (X^T X)^{-1} X^T y$$

Oznaczmy $H = X (X^T X)^{-1} X^T$, a przez $e = y - \hat{y}$ wektor reszt z regresji próbkowej. Wtedy

$$\begin{aligned} y &= X\beta + u, \\ y &= Xb + e \\ \hat{y} &= Hy, e = (I - H)y \end{aligned}$$

Własność 1

$$\begin{aligned} HX &= X, \quad H1_n = 1_n, \quad (I - H)X = 0 \\ H &= H^T, \quad H^2 = H, \quad (I - H)^2 = I - H \end{aligned}$$

Dowód

$$\begin{aligned} H^T &= \left(X (X^T X)^{-1} X^T \right)^T = X (X^T X)^{-1} X^T = H, \\ H^2 &= X (X^T X)^{-1} (X^T X) (X^T X)^{-1} X^T = X (X^T X)^{-1} X^T = H, \\ (I - H)^2 &= I - H - H + H^2 = I - H \end{aligned}$$

H jest więc operatorem rzutu prostopadłego na płaszczyznę regresji próbkowej, $I - H$ operatorem rzutu prostopadłego na płaszczyznę błędu próbkowego.

Własność 2

Reszty u od regresji populacji są niezależne ($Vu = \sigma^2 I$), natomiast reszty e od regresji próbkowej są zależne, $Ve = \sigma^2 (I - H)$.

Dowód

$$\begin{aligned} Ee &= E(I - H)y = (I - H)Ey = (I - H)X\beta \\ (I - H)X &= 0 \Rightarrow Ee = 0 \end{aligned}$$

$$\begin{aligned} Ve &= Eee^T = E(I - H)yy^T(I - H) = (I - H)Eyy^T(I - H), \\ Eyy^T &= E(X\beta + u)(X\beta + u)^T = X\beta\beta^T X^T + Euu^T = X\beta\beta^T X^T + \sigma^2 I, \\ (I - H)Eyy^T &= ((I - H)X)\beta\beta^T X^T + \sigma^2(I - H) = \sigma^2(I - H), \\ Ve &= \sigma^2(I - H)(I - H) = \sigma^2(I - H) \end{aligned}$$

Będzie dowód, że $\frac{1}{n} \leq h_{ii} \leq 1$. Gdy $h_{ii} = 1$ to $Ve_i = 0$ a więc z prawdopodobieństwem 1 reszta $e_i = 0$.

Definicja

Resztą standaryzowaną nazywamy wielkość

$$r_i = \frac{e_i}{s\sqrt{1 - h_{ii}}},$$

gdzie s jest estymatorem σ .

Z faktu, że $HX = X$ wynika, że $H1_n = 1_n$.

Wtedy

$$\bar{y} = \frac{1}{n}1_n^T y = \frac{1}{n}1_n^T H y = \frac{1}{n}1_n^T \hat{y} = \bar{\hat{y}}$$

i trójkąt o bokach $y, \hat{y}, \bar{y}1_n$ jest trójkątem prostokątnym.

Stąd dla każdego y zachodzą nierówności

$$0 \leq \|\hat{y} - \bar{y}1_n\|^2 \leq \|y - \bar{y}1_n\|^2$$

Mamy

$$\begin{aligned} \|\hat{y} - \bar{y}1_n\|^2 &= \|\hat{y}\|^2 - 2\bar{y}1_n^T \hat{y} + \|\bar{y}1_n\|^2 \\ &= \|Hy\|^2 - 2n\bar{y}\bar{y} + n(\bar{y})^2 \\ &= y^T H y - n(\bar{y})^2 \end{aligned}$$

$$\begin{aligned} \|y - \bar{y}1_n\|^2 &= \|y\|^2 - 2\bar{y}1_n^T y + \|\bar{y}1_n\|^2 \\ &= \|y\|^2 - n(\bar{y})^2 \end{aligned}$$

A więc, dla każdego y zachodzą nierówności

$$\|y\|^2 \geq y^T H y \geq n (\bar{y})^2$$

Kładąc $y^T = [0, 0, \dots, 0, 1, 0, \dots, 0]$ z jedynką na i -tym miejscu otrzymamy

$$\begin{aligned} \frac{1}{n} &\leq h_{ii} \leq 1, \\ \sum_i h_{ii} &= \text{Tr}(H) = \text{Tr}\left(X(X^T X)^{-1} X^T\right) \\ &= \text{Tr}\left((X^T X)^{-1} X^T X\right) = \text{Tr}(I) \\ &= p + 1 \end{aligned}$$

Współczynnik h_{ii} opisuje wpływ i -tej obserwacji na regresję, gdyż

$$\hat{y}_i = \sum_j h_{ij} y_j = h_{ii} y_i + \sum_{j \neq i} h_{ij} y_j$$

$$\begin{aligned} \sum_{j=1}^n h_{ij}^2 &= (H H^T)_{ii} = (H^2)_{ii} = h_{ii} \\ \sum_{j \neq i} h_{ij}^2 &= h_{ii} (1 - h_{ii}), \\ \sum_{j \neq i} h_{ij}^2 &\leq \frac{1}{4} \end{aligned}$$

Dla $h_{ii} \geq \frac{1}{2}$ duże wartości h_{ii} oznaczają małe wartości h_{ij}
Przyjmujemy, że wartość h_{ii} jest duża, gdy

$$h_{ii} > 2 \frac{1}{n} \sum_i h_{ii} = \frac{2(p+1)}{n}$$

Ocenimy teraz jakie modyfikacje w oszacowaniu równania regresji spowoduje usunięcie jednej, i -tej obserwacji.

Oznaczmy przez $X_{(i)}$ macierz X po usunięciu i -tego wiersza ($X_{(i)} \in M(n-1, p+1)$), zaś przez $y_{(i)}$ $n-1$ - wymiarowy wektor y po usunięciu i -tego wiersza.

Niech $b_{(i)}$ oznacza $p+1$ - wymiarowy wektor estymatorów współczynników regresji, zaś $\widehat{y}_{(i)}$ oznacza n - wymiarowy wektor wartości regresji, gdy z danych usunięto i -tą obserwację.

Wtedy

$$\begin{aligned}\widehat{y}_{(i)} &= Xb_{(i)}, \\ b_{(i)} &= (X_{(i)}^T X_{(i)})^{-1} X_{(i)}^T y_{(i)}\end{aligned}$$

Zauważmy, że $X_{(i)}^T y_{(i)} = X^T y - X_i^T y_i$, gdzie X_i jest i -tym wierszem macierzy X .

$$b_{(i)} = (X_{(i)}^T X_{(i)})^{-1} X_{(i)}^T y_{(i)} = (X_{(i)}^T X_{(i)})^{-1} (X^T y - X_i^T y_i)$$

Skorzystamy ze wzoru [Madansky, 140]

$$(X_{(i)}^T X_{(i)})^{-1} = (X^T X)^{-1} + \frac{(X^T X)^{-1} X_i^T X_i (X^T X)^{-1}}{1 - h_{ii}}$$

$$\begin{aligned}(X_{(i)}^T X_{(i)})^{-1} X^T y &= (X^T X)^{-1} X^T y + \frac{(X^T X)^{-1} X_i^T X_i (X^T X)^{-1} X^T y}{1 - h_{ii}} = \\ &= b + \frac{(X^T X)^{-1} X_i^T \widehat{y}_i}{1 - h_{ii}}\end{aligned}$$

gdź $\widehat{y}_i = X_i (X^T X)^{-1} X^T y$

$$\begin{aligned}(X_{(i)}^T X_{(i)})^{-1} X_i^T y_i &= (X^T X)^{-1} X_i^T y_i + \frac{(X^T X)^{-1} X_i^T X_i (X^T X)^{-1} X_i^T y_i}{1 - h_{ii}} = \\ &= (X^T X)^{-1} X_i^T y_i + \frac{(X^T X)^{-1} X_i^T h_{ii} y_i}{1 - h_{ii}} = \\ &= (X^T X)^{-1} X_i^T y_i \left(1 + \frac{h_{ii}}{1 - h_{ii}}\right) = \frac{(X^T X)^{-1} X_i^T y_i}{1 - h_{ii}}\end{aligned}$$

gdź $h_{ii} = X_i (X^T X)^{-1} X_i^T$

Stąd

$$\begin{aligned}b_{(i)} &= b + \frac{(X^T X)^{-1} X_i^T \widehat{y}_i}{1 - h_{ii}} - \frac{(X^T X)^{-1} X_i^T y_i}{1 - h_{ii}} = \\ &= b - \frac{e_i (X^T X)^{-1} X_i^T}{1 - h_{ii}}\end{aligned}$$

$$\begin{aligned}\widehat{y}_{(i)} &= Xb_{(i)} = X \left(b - \frac{e_i (X^T X)^{-1} X_i^T}{1 - h_{ii}} \right) = \\ &= \widehat{y} - \frac{e_i X (X^T X)^{-1} X_i^T}{1 - h_{ii}} = \widehat{y} - \frac{sr_i X (X^T X)^{-1} X_i^T}{\sqrt{1 - h_{ii}}}\end{aligned}$$

Odległością Cooka nazywamy liczbę

$$D_i = \frac{\|\widehat{y} - \widehat{y}_{(i)}\|^2}{s^2 (p + 1)}$$

Odległość Cooka ocenia skutki usunięcia i-tej obserwacji. Jest standaryzowaną średnią odległością pomiędzy wartościami regresji przed i po usunięciu i-tej obserwacji.

$$\begin{aligned}D_i &= \frac{\|\widehat{y} - \widehat{y}_{(i)}\|^2}{s^2 (p + 1)} = \frac{\left\| \frac{sr_i X (X^T X)^{-1} X_i^T}{\sqrt{1 - h_{ii}}} \right\|^2}{s^2 (p + 1)} = \frac{s^2 r_i^2 \left\| X (X^T X)^{-1} X_i^T \right\|^2}{s^2 (p + 1) (1 - h_{ii})}, \\ \left\| X (X^T X)^{-1} X_i^T \right\|^2 &= X_i (X^T X)^{-1} X^T X (X^T X)^{-1} X_i^T = X_i (X^T X)^{-1} X_i^T = h_{ii}, \\ D_i &= \frac{s^2 r_i^2 h_{ii}}{s^2 (p + 1) (1 - h_{ii})} = r_i^2 \frac{h_{ii}}{(p + 1) (1 - h_{ii})}\end{aligned}$$

Pierwszy składnik iloczynu odpowiada za odchylenia od regresji, zaś drugi - za wielkość wpływu