

Twierdzenie Frischa-Waugha

Marcin Pawlik

16 marca 2006 roku

Spis treści

1 Rzutowanie	2
2 Twierdzenie Frischa-Waugha	3
3 Przykład liczbowy	4

1 Rzutowanie

Wektor reszt empirycznych dany jest wzorem:

$$\mathbf{e} = \mathbf{y} - \mathbf{X}\hat{\beta} \quad (1)$$

podstawiając $\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}$ otrzymujemy:

$$\mathbf{e} = \mathbf{y} - (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} = (\mathbf{I} - (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}') \mathbf{y} = \mathbf{M}\mathbf{y} \quad (2)$$

Macierz $\mathbf{M}_{n \times n}$ jest symetryczna:

$$\begin{aligned} \mathbf{M}' &= (\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}')' = \\ &= \mathbf{I}' - (\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}')' = \\ &= \mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' = \mathbf{M} \end{aligned} \quad (3)$$

oraz idempotentna (tzn. pomnożona przez samą siebie daje w wyniku samą siebie):

$$\begin{aligned} \mathbf{M}\mathbf{M} &= (\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}') (\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}') = \\ &= \mathbf{I} - 2\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' + \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' = \\ &= \mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' = \mathbf{M} \end{aligned} \quad (4)$$

Macierz \mathbf{M} można traktować jako macierz, która przez wektor \mathbf{y} daje wektor reszt empirycznych z regresji \mathbf{y} względem \mathbf{X} . Ponadto zachodzi następująca zależność:

$$\mathbf{M}\mathbf{X} = \mathbf{0} \quad (5)$$

Jedną z interpretacji tego wyniku jest fakt, że regresja \mathbf{X} względem \mathbf{X} da zerowy wektor reszt. Wartości otrzymane w wyniku regresji można zdekomponować na wartości obserwowane oraz reszty empiryczne:

$$\hat{\mathbf{y}} = \mathbf{y} - \mathbf{e} = \mathbf{y} - \mathbf{M}\mathbf{y} = (\mathbf{I} - \mathbf{M})\mathbf{y} = \mathbf{P}\mathbf{y} \quad (6)$$

gdzie:

$$\mathbf{P} = \mathbf{I} - \mathbf{M} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \quad (7)$$

Macierz \mathbf{P} jest macierzą projekcji (inaczej rzutowania) wektora \mathbf{y} na podprzestrzeń rozpiętą przez \mathbf{X} . \mathbf{P} jest macierzą skonstruowaną z macierzy \mathbf{X} taką, że po przemnożeniu przez \mathbf{y} daje w wyniku wartości regresji \mathbf{y} względem \mathbf{X} . Podobnie jak $\mathbf{M}\mathbf{P}$ jest symetryczna i idempotentna:

$$\begin{aligned} \mathbf{P}' &= (\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}')' = \\ &= (\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}') = \mathbf{P} \end{aligned} \quad (8)$$

$$\begin{aligned} \mathbf{P}\mathbf{P} &= \left(\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' \right) \left(\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' \right) = \\ &= \left(\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' \right) = \mathbf{P} \end{aligned} \quad (9)$$

Macierze \mathbf{M} i \mathbf{P} są ortogonalne:

$$\mathbf{P}\mathbf{M} = \mathbf{M}\mathbf{P} = \mathbf{0} \quad (10)$$

$$\mathbf{P}\mathbf{M} = \mathbf{P}(\mathbf{I} - \mathbf{P}) = \mathbf{P} - \mathbf{P}^2 = \mathbf{P} - \mathbf{P} = \mathbf{0} \quad (11)$$

$$\mathbf{M}\mathbf{P} = \mathbf{M}(\mathbf{I} - \mathbf{M}) = \mathbf{M} - \mathbf{M}^2 = \mathbf{M} - \mathbf{M} = \mathbf{0} \quad (12)$$

Ponadto:

$$\mathbf{P}\mathbf{X} = \mathbf{X}, \quad (13)$$

co tłumaczy się tym, że rzut \mathbf{X} na podprzestrzeń rozpiętą przez \mathbf{X} daje \mathbf{X} .

Naturalną konsekwencją (2) i (7) jest stwierdzenie, że MNK dzieli \mathbf{y} na dwie ortogonalne części:

$$\mathbf{y} = \mathbf{P}\mathbf{y} + \mathbf{M}\mathbf{y} = \text{rzut} + \text{reszty} \quad (14)$$

2 Twierdzenie Frischa-Waughy

Załóżmy, że dokonujemy regresji \mathbf{y} względem dwóch zbiorów zmiennych — \mathbf{X}_1 i \mathbf{X}_2 :

$$\mathbf{y} = \mathbf{X}\beta + \varepsilon = \mathbf{X}_1\beta_1 + \mathbf{X}_2\beta_2 + \varepsilon. \quad (15)$$

Jaka jest algebraiczna postać estymatora $\hat{\beta}_2$ parametru β_2 ? Równania normalne dla (15) można zapisać w następujący sposób:

$$\begin{aligned} \text{i} & \begin{bmatrix} X_1'X_1 & X_1'X_2 \\ X_2'X_1 & X_2'X_2 \end{bmatrix} \begin{bmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix} = \begin{bmatrix} X_1'y \\ X_2'y \end{bmatrix} \\ \text{ii} & \end{bmatrix} \end{aligned} \quad (16)$$

$$\begin{aligned} \mathbf{X}_1'\mathbf{X}_1\hat{\beta}_1 + \mathbf{X}_1'\mathbf{X}_2\hat{\beta}_2 &= \mathbf{X}_1'\mathbf{y} \\ \mathbf{X}_1'\mathbf{X}_1\hat{\beta}_1 &= \mathbf{X}_1'\mathbf{y} - \mathbf{X}_1'\mathbf{X}_2\hat{\beta}_2 \\ \hat{\beta}_1 &= (\mathbf{X}_1'\mathbf{X}_1)^{-1}\mathbf{X}_1'(\mathbf{y} - \mathbf{X}_2\hat{\beta}_2) \end{aligned} \quad (17)$$

Wynik ten pokazuje, że $\hat{\beta}_1$ można otrzymać dokonując regresji reszt z regresji y względem X_2 względem X_1 . Warto zwrócić uwagę na pewien ciekawy fakt. Jeśli $X_1'X_2 = 0$ (czyli X_1 i X_2 są ortogonalne), wtedy $\hat{\beta}_1$ się redukuje do:

$$\hat{\beta}_1 = (\mathbf{X}_1'\mathbf{X}_1)^{-1}\mathbf{X}_1'\mathbf{y} \quad (18)$$

W takim przypadku $\hat{\beta}_1$ jest wektorem parametrów regresji y względem X_1 . Prowadzi to do następującego twierdzenia:

Twierdzenie 2.1 (*Orthogonal Partitioned Regression*) W regresji wielorakiej \mathbf{y} względem dwóch zbiorów zmiennych — \mathbf{X}_1 i \mathbf{X}_2 , jeśli te dwa zbiory są ortogonalne, to „osobne” wektory współczynników można otrzymać w wyniku „osobnych” regresji \mathbf{y} względem \mathbf{X}_1 i \mathbf{y} względem \mathbf{X}_2 .

Podstawienie (17) do (15) daje następujący wynik:

$$\begin{aligned} (\mathbf{X}'_2 \mathbf{X}_1) (\mathbf{X}'_1 \mathbf{X}_1)^{-1} \mathbf{X}'_1 (\mathbf{y} - \mathbf{X}_2 \hat{\beta}_2) + \mathbf{X}'_2 \mathbf{X}'_2 \hat{\beta}_2 &= \mathbf{X}'_2 \mathbf{y} \\ \mathbf{X}'_2 [\mathbf{I} - \mathbf{X}_1 (\mathbf{X}'_1 \mathbf{X}_1)^{-1} \mathbf{X}'_1] \mathbf{X}_2 \hat{\beta}_2 &= \mathbf{X}'_2 [\mathbf{I} - \mathbf{X}_1 (\mathbf{X}'_1 \mathbf{X}_1)^{-1} \mathbf{X}'_1] \mathbf{y} \\ \mathbf{X}'_2 \mathbf{M}_1 \mathbf{X}_2 \hat{\beta}_2 &= \mathbf{X}'_2 \mathbf{M}_1 \mathbf{y} \\ \hat{\beta}_2 &= (\mathbf{X}'_2 \mathbf{M}_1 \mathbf{X}_2)^{-1} \mathbf{X}'_2 \mathbf{M}_1 \mathbf{y} \end{aligned} \quad (19)$$

Korzystając z faktu, że \mathbf{M}_1 jest idempotentna i symetryczna oraz podstawiając $\mathbf{X}_2^* = \mathbf{M}_1 \mathbf{X}_2$ i $\mathbf{y}^* = \mathbf{M}_1 \mathbf{y}$ otrzymujemy:

$$\hat{\beta}_2 = (\mathbf{X}_2^{*'} \mathbf{X}_2^*)^{-1} \mathbf{X}_2^* \mathbf{y}^* \quad (20)$$

Wynik ten ma zasadnicze znaczenie w analizie regresji.

Twierdzenie 2.2 (*Frisch-Waugh [1933]*) W regresji MNK wektora \mathbf{y} względem dwóch zbiorów zmiennych \mathbf{X}_1 i \mathbf{X}_2 podwektor $\hat{\beta}_2$ jest zbiorem współczynników otrzymanych z regresji reszt z regresji \mathbf{y} względem \mathbf{X}_1 względem zbioru reszt pochodzących z regresji każdej kolumny \mathbf{X}_2 względem \mathbf{X}_1 .

3 Przykład liczbowy

Poniżej przykład liczbowy pokazujący, że powyższe twierdzenie naprawdę „działa”.

W przykładzie wykorzystano dane z podręcznika Ramathana dołączone do pakietu Gretl¹ dotyczące kosztów naprawy pojazdów w serwisach Toyoty.

Regresja zmiennej *cost* względem pozostałych daje następujące wyniki:

$$\begin{aligned} \widehat{\text{cost}} &= 26,1888 + 28,0163 \text{ age} - \mathbf{154,635} \text{ miles} \\ &\quad (0,229) \quad (10,094) \quad (-7,475) \\ T &= 57 \quad \bar{R}^2 = 0,9492 \quad F(2, 54) = 523,8 \quad \hat{\sigma} = 259,55 \\ &\quad (\text{statystyka } t \text{ w nawiasach}) \end{aligned}$$

Następnie oszacujemy parametr przy zmiennej *miles* (wytluszczony) zgodnie z metodą z twierdzenia Frischa-Waugh. Pierwszy krok polega na oszacowaniu równania regresji *cost* względem stałej i zmiennej *age*. Wynik obliczeń

¹GNU Regression, Econometrics and Time Series Library

przedstawia się następująco:

$$\widehat{\text{cost}} = -625,935 + 7,34348 \text{ age}$$

(-6,010) (22,281)

$$T = 57 \quad \bar{R}^2 = 0,8985 \quad F(1, 55) = 496,46 \quad \hat{\sigma} = 366,85$$

(statystyka t w nawiasach)

Reszty z tego równania zapisujemy jako zmienną $uhat2$.

W kolejnym kroku szacujemy regresję zmiennej $miles$ względem stałej i zmiennej age :

$$\widehat{\text{miles}} = 4,21719 + 0,133688 \text{ age}$$

(8,781) (87,961)

$$T = 57 \quad \bar{R}^2 = 0,9928 \quad F(1, 55) = 7737,2 \quad \hat{\sigma} = 1,6917$$

(statystyka t w nawiasach)

Reszty z tego równania zapisujemy jako zmienną $uhat3$.

Ostatnim etapem tego ćwiczenia jest oszacowanie równania regresji $uhat3$ względem $uhat2$:

$$\widehat{uhat2} = -154,635 \text{ uhat3}$$

(-7,612)

$$T = 57 \quad \bar{R}^2 = 0,5085 \quad F(1, 56) = 57,938 \quad \hat{\sigma} = 254,88$$

(statystyka t w nawiasach)

Na zakończenie cieszymy się, że nam wyszło. Wyróżniona wartość współczynnika jest równa tej z pierwszego modelu.

Ponizej zapis sesji Gretla:

```
open /usr/local/share/gretl/data/data3-7.gdt
ols cost const age miles
ols cost const age
(* commands pertaining to model 2 *)
genr uhat2 = $uhat
ols miles const age
(* commands pertaining to model 3 *)
genr uhat3 = $uhat
ols uhat2 uhat3
```

Literatura

- [1] W.H. Greene: *Econometric Analysis*, Prentice Hall, Englewood Cliffs 2000.