

## UOGÓLNIONA MIARA DOPASOWANIA W MODELU LINIOWYM

**Wojciech Zieliński**

Katedra Ekonometrii i Statystyki, SGGW  
Nowoursynowska 159, PL-02-767 Warszawa  
[wojtek.zielinski@statystyka.info](mailto:wojtek.zielinski@statystyka.info)

**Streszczenie:** W modelu regresji liniowej stosowane są dwie miary wpływu zmiennych niezależnych na zmienną zależną: współczynnik determinacji oraz współczynnik korelacji cząstkowej. W pracy zaproponowane jest uogólnienie tych miar i skonstruowana jest miara wpływu grupy zmiennych niezależnych z wyłączeniem wpływu pozostałych zmiennych niezależnych.

**Słowa kluczowe:** miara dopasowania, współczynnik determinacji, korelacja cząstkowa, analiza regresji

Założymy, że obserwacje  $Y_i$  pewnej zmiennej losowej możemy przedstawić w postaci

$$Y_i = \beta_1 x_{1i} + \dots + \beta_p x_{pi} + \varepsilon_i, \quad i = 1, \dots, n \quad (*)$$

gdzie  $x_{ki}$ ,  $k = 1, \dots, p$ ,  $i = 1, \dots, n$ , są znane,  $\beta_1, \dots, \beta_p$  są nieznanymi współczynnikami regresji, natomiast  $\varepsilon_i$ ,  $i = 1, \dots, n$ , są zmiennymi losowymi o rozkładach normalnych o zerowej wartości oczekiwanej i wariancji  $\sigma^2$ .

Jednym z pytań stawianych w analizie modeli (\*) jest pytanie o wpływ zmiennych niezależnych na cechę  $Y$ . W zastosowaniach wykorzystuje się w zasadzie dwie miary: miarę łącznego wpływu wszystkich zmiennych niezależnych oraz miarę wpływu pojedynczych zmiennych (z eliminacją wpływu pozostałych). Jest to powszechnie znany współczynnik determinacji oraz współczynnik korelacji cząstkowej. Ścisłe określenia tych pojęć można znaleźć w bardzo bogatej literaturze poświęconej analizie regresji (w spisie literatury podanych znaleźć kilka takich książek). Podane miary niestety nie udzielają odpowiedzi na pytania o wpływ grup wybranych zmiennych niezależnych na zmienną zależną, np. jak zmierzyć wpływ zmiennej  $x_1$  oraz  $x_2$  z wyłączeniem pozostałych zmiennych? W dalszym ciągu zaproponowana jest taka miara. Pokazano również, że współczynnik determinacji

oraz współczynnik korelacji cząstkowej są szczególnymi przypadkami tej ogólniejszej miary.

W dalszych rozważaniach znacznie wygodniej jest się posługiwać zapisami macierzowymi. Model liniowy (\*) w zapisie macierzowym ma postać

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

gdzie  $\mathbf{Y}' = [Y_1, \dots, Y_n]$  jest wektorem obserwacji,  $\boldsymbol{\beta}' = [\beta_1, \dots, \beta_p]$  jest wektorem nieznanych parametrów,  $\boldsymbol{\varepsilon}' = [\varepsilon_1, \dots, \varepsilon_n]$  jest wektorem błędów losowych oraz

$$\mathbf{X} = \begin{bmatrix} x_{11} & \cdots & x_{p1} \\ x_{12} & \cdots & x_{p2} \\ \vdots & \cdots & \vdots \\ x_{1n} & \cdots & x_{pn} \end{bmatrix}$$

jest macierzą eksperymentu. Zgodnie z poczynionymi założeniami wektor losowy  $\mathbf{Y}$  ma  $n$ -wymiarowy rozkład normalny:

$$\mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n)$$

Niech teraz  $\mathbf{X} = [\mathbf{X}_1 : \mathbf{X}_2]$ , gdzie macierze  $\mathbf{X}_1$  oraz  $\mathbf{X}_2$  są macierzami o wymiarach odpowiednio  $n \times (p - q)$  i  $n \times q$ . Niech wektor parametrów  $\boldsymbol{\beta}$  będzie podzielony odpowiednio na dwa podwektory  $\boldsymbol{\beta}_1$  i  $\boldsymbol{\beta}_2$  zgodnie z podziałem macierzy  $\mathbf{X}$ . Interesuje nas zmierzenie wpływu na zmienną zależną zmiennych zawartych w macierzy  $\mathbf{X}_2$ . Niech  $\widehat{\boldsymbol{\beta}}$  oznacza estymator wektora  $\boldsymbol{\beta}$  w modelu z macierzą  $\mathbf{X}$

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

natomast niech  $\widehat{\boldsymbol{\beta}}_1$  będzie estymatorem najmniejszych kwadratów wektora  $\boldsymbol{\beta}$  w modelu z ograniczeniami  $\boldsymbol{\beta}_2 = \mathbf{0}$  (Zieliński 2007):

$$\widehat{\boldsymbol{\beta}}_1 = \widehat{\boldsymbol{\beta}} - (\mathbf{X}'\mathbf{X})^{-1}\mathbf{A}[\mathbf{A}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{A}]^{-1}\mathbf{A}\widehat{\boldsymbol{\beta}}$$

Tutaj  $\mathbf{A} = [\mathbf{0}_{n \times (p-q)} : \mathbf{I}_q]$  jest macierzą ograniczeń, tzn.  $\boldsymbol{\beta}_2 = \mathbf{0}$  jest równoważne temu, że  $\mathbf{A}\boldsymbol{\beta} = \mathbf{0}$  ( $\mathbf{0}$  oznacza, w zależności od kontekstu, wektor lub macierz zerową,  $\mathbf{I}_q$  oznacza macierz jednostkową wymiaru  $q$ ).

Wektor obserwacji  $\mathbf{Y}$  możemy zapisać jako

$$\mathbf{Y} - \mathbf{X}\widehat{\boldsymbol{\beta}}_1 = (\mathbf{X}\widehat{\boldsymbol{\beta}} - \mathbf{X}\widehat{\boldsymbol{\beta}}_1) + (\mathbf{Y} - \mathbf{X}\widehat{\boldsymbol{\beta}} + \mathbf{X}\widehat{\boldsymbol{\beta}}_1)$$

Zauważmy, że wektory  $\mathbf{X}\widehat{\boldsymbol{\beta}} - \mathbf{X}\widehat{\boldsymbol{\beta}}_1$  i  $\mathbf{Y} - \mathbf{X}\widehat{\boldsymbol{\beta}} + \mathbf{X}\widehat{\boldsymbol{\beta}}_1$  są ortogonalne. A zatem

$$\|Y - X\hat{\beta}_1\|^2 = \|X\hat{\beta} - X\hat{\beta}_1\|^2 + \|Y - X\hat{\beta} + X\hat{\beta}_1\|^2$$

gdzie  $\|\cdot\|^2$  oznacza kwadrat długości wektora (w normie euklidesowej).

Jako miarę wpływu zmiennych zawartych w macierzy  $X_2$  przyjmujemy

$$\mathfrak{R}^2(X_2) = \frac{\|X\hat{\beta} - X\hat{\beta}_1\|^2}{\|Y - X\hat{\beta}_1\|^2}$$

*Twierdzenie.* Zmienna losowa

$$\frac{\mathfrak{R}^2(X_2)}{1 - \mathfrak{R}^2(X_2)} \cdot \frac{n - q}{q}$$

ma niecentralny rozkład  $F$  z  $(q, n - q)$  stopniami swobody i parametrem niecentralności  $\boldsymbol{\beta}'\mathbf{A}[\mathbf{A}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{A}]^{-1}\mathbf{A}\boldsymbol{\beta}$ , gdzie  $\mathbf{A} = [\mathbf{0}_{n \times (p-q)} : \mathbf{I}_q]$ .

*Dowód.* W dowodzie korzystamy z dobrze znanych faktów dotyczących rozkładów prawdopodobieństwa form liniowych i kwadratowych wektorów losowych o wielowymiarowym rozkładzie normalnym.

Łatwo sprawdzić, że

$$\frac{\mathfrak{R}^2(X_2)}{1 - \mathfrak{R}^2(X_2)} = \frac{\|X\hat{\beta} - X\hat{\beta}_1\|^2}{\|Y - (X\hat{\beta} - X\hat{\beta}_1)\|^2} = \frac{\hat{\boldsymbol{\beta}}'\mathbf{A}'[\mathbf{A}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{A}']\mathbf{A}\hat{\boldsymbol{\beta}}}{\mathbf{Y}'(\mathbf{I}_n - \mathbf{A}'[\mathbf{A}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{A}']\mathbf{A})\mathbf{Y}}$$

Macierz  $\mathbf{I}_n - \mathbf{A}'[\mathbf{A}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{A}']\mathbf{A}$  jest idempotentna, więc w mianowniku mamy zmienną losową o centralnym rozkładzie chi-kwadrat z  $(n - q)$  stopniami swobody. Ponieważ wektor losowy  $\hat{\boldsymbol{\beta}}$  ma rozkład  $N_p(\boldsymbol{\beta}, \sigma^2(\mathbf{X}'\mathbf{X})^{-1})$ , więc w liczniku mamy zmienną losową o niecentralnym rozkładzie chi-kwadrat z  $q$  stopniami swobody i parametrem niecentralności  $\hat{\boldsymbol{\beta}}'\mathbf{A}'[\mathbf{A}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{A}']\mathbf{A}\hat{\boldsymbol{\beta}}$ . Licznik i Mianownik są niezależnymi zmiennymi losowymi i stąd wynika teza twierdzenia.

Pokażemy teraz, że współczynnik determinacji oraz współczynnik korelacji cząstkowej są szczególnym przypadkiem miary  $\mathfrak{R}^2(X_2)$ .

*Współczynnik determinacji* jest miarą wpływu wszystkich zmiennych niezależnych  $x_1, \dots, x_m$  na zmienną  $Y$  w modelu

$$Y_i = \beta_0 + \beta_1 x_{1i} + \dots + \beta_m x_{mi} + \varepsilon_i, \quad i = 1, \dots, n.$$

W zapisie macierzowym

$$\mathbf{X} = \begin{bmatrix} 1 & x_{11} & \cdots & x_{m1} \\ 1 & x_{12} & \cdots & x_{m2} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{1n} & \cdots & x_{mn} \end{bmatrix}, \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_m \end{bmatrix}.$$

Macierz  $\mathbf{X}$  i wektor parametrów można podzielić na  $\mathbf{X}_1 = \mathbf{1}_n$ ,

$$\mathbf{X}_2 = \begin{bmatrix} x_{11} & \cdots & x_{m1} \\ x_{12} & \cdots & x_{m2} \\ \vdots & \ddots & \vdots \\ x_{1n} & \cdots & x_{mn} \end{bmatrix}, \quad \boldsymbol{\beta}_1 = [\beta_0], \quad \boldsymbol{\beta}_2 = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_m \end{bmatrix}.$$

W tym modelu mamy  $p = m + 1$ ,  $q = m$  oraz

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} n & \mathbf{1}'_n \mathbf{X}_2 \\ \mathbf{1}_n \mathbf{X}'_2 & \mathbf{X}'_2 \mathbf{X}_2 \end{bmatrix}, \quad (\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} M & \mathbf{k}' \\ \mathbf{k} & \mathbf{L} \end{bmatrix}$$

gdzie  $\mathbf{L}^{-1} = \mathbf{X}'_2 \mathbf{X}_2 - \frac{1}{n} \mathbf{X}'_2 \mathbf{1}_n \mathbf{1}'_n \mathbf{X}_2$ ,  $\mathbf{k}' = -\frac{1}{n} \mathbf{1}'_n \mathbf{X}_2 \mathbf{L}$  oraz  $M = \frac{1}{n} + \mathbf{k}' \mathbf{L} \mathbf{k}$  (ogólny wzór na odwrotność blokowej macierzy  $2 \times 2$  można znaleźć w np. Rao 1982, Zieliński 2007). Estymator najmniejszych kwadratów wektora  $\boldsymbol{\beta}$  w pełnym modelu ma postać

$$\hat{\boldsymbol{\beta}} = \begin{bmatrix} M & \mathbf{k}' \\ \mathbf{k} & \mathbf{L} \end{bmatrix} \begin{bmatrix} \mathbf{1}'_n \\ \mathbf{X}'_2 \end{bmatrix} \mathbf{Y} = \begin{bmatrix} M \mathbf{1}'_n + \mathbf{k}' \mathbf{X}'_2 \\ \mathbf{k} \mathbf{1}'_n + \mathbf{L} \mathbf{X}'_2 \end{bmatrix} \mathbf{Y}$$

tzn.

$$\hat{b}_0 = (M \mathbf{1}'_n + \mathbf{k}' \mathbf{X}'_2) \mathbf{Y}, \quad \hat{\boldsymbol{\beta}}_2 = (\mathbf{k} \mathbf{1}'_n + \mathbf{L} \mathbf{X}'_2) \mathbf{Y}$$

Estymator wektora  $\boldsymbol{\beta}_1$  w modelu z ograniczeniami określonymi macierzą  $\mathbf{A} = [\mathbf{0}_m : \mathbf{I}_m]$  wyraża się wzorem

$$\begin{aligned} \hat{\boldsymbol{\beta}}_1 &= \left( \mathbf{I}_{m+1} - \begin{bmatrix} M & \mathbf{k}' \\ \mathbf{k} & \mathbf{L} \end{bmatrix} \begin{bmatrix} \mathbf{0}'_m \\ \mathbf{I}_m \end{bmatrix} \left( \begin{bmatrix} \mathbf{0}_m & \mathbf{I}_m \end{bmatrix} \begin{bmatrix} M & \mathbf{k}' \\ \mathbf{k} & \mathbf{L} \end{bmatrix} \begin{bmatrix} \mathbf{0}'_m \\ \mathbf{I}_m \end{bmatrix} \right)^{-1} \begin{bmatrix} \mathbf{0}_m & \mathbf{I}_m \end{bmatrix} \right) \hat{\boldsymbol{\beta}} \\ &= \begin{bmatrix} 1 & -\mathbf{k}' \mathbf{L}^{-1} \\ \mathbf{0}_m & \mathbf{0}_{m \times m} \end{bmatrix} \hat{\boldsymbol{\beta}} = \begin{bmatrix} \hat{b}_0 - \mathbf{k}' \mathbf{L}^{-1} \hat{\boldsymbol{\beta}}_2 \\ \mathbf{0}_m \end{bmatrix} = \begin{bmatrix} \frac{1}{n} \mathbf{1}'_n \mathbf{Y} \\ \mathbf{0}_m \end{bmatrix} = \begin{bmatrix} \bar{Y} \\ \mathbf{0}_m \end{bmatrix} \end{aligned}$$

gdzie  $\bar{Y} = \frac{1}{n} \sum Y_i$ . Ponieważ  $\mathbf{X} \hat{\boldsymbol{\beta}}_1 = Y \mathbf{1}_n$ , więc  $(\hat{\mathbf{Y}} = \mathbf{X} \hat{\boldsymbol{\beta}})$

$$\|\mathbf{X} \hat{\boldsymbol{\beta}} - \mathbf{X} \hat{\boldsymbol{\beta}}_1\|^2 = (\hat{\mathbf{Y}} - Y \mathbf{1}_n)'(\hat{\mathbf{Y}} - Y \mathbf{1}_n) = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2$$

oraz

$$\|\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}_1\|^2 = (\mathbf{Y} - \bar{Y}\mathbf{1}_n)'(\mathbf{Y} - \bar{Y}\mathbf{1}_n) = \sum_{i=1}^n (Y_i - \bar{Y})^2$$

Współczynnik determinacji, wyrażany zwyczajowo w procentach, określony jest więc w następujący sposób

$$D = R^2(\mathbf{X}_2) \cdot 100\% = \frac{\Sigma(\hat{Y}_i - \bar{Y})^2}{\Sigma(Y_i - \bar{Y})^2}$$

Z twierdzenia otrzymujemy

*Wniosek.* Zmienna losowa

$$\frac{D}{100-D} \cdot \frac{n-m}{m}$$

ma niecentralny rozkład  $F$  z  $(m, n-m)$  stopniami swobody i parametrem niecentralności  $\boldsymbol{\beta}'_2 \mathbf{X}'_2 (\mathbf{I}_n - \mathbf{1}_n \mathbf{1}'_n) \mathbf{X}_2 \boldsymbol{\beta}_2$ .

*Współczynnik korelacji cząstkowej* jest miarą wpływu jednej ze zmiennych niezależnych na zmienną  $Y$  w modelu

$$Y_i = \beta_0 + \beta_1 x_{1i} + \cdots + \beta_m x_{mi} + \varepsilon_i, \quad i = 1, \dots, n.$$

Wyprowadzimy odpowiedni wzór dla zmiennej  $x_1$ . Dla uproszczenia zapisu model zapisujemy w postaci

$$Y_i = \beta_0 + \beta_2 x_{2i} + \cdots + \beta_m x_{mi} + \beta_1 x_{1i} + \varepsilon_i, \quad i = 1, \dots, n.$$

W zapisie macierzowym

$$\mathbf{X} = \begin{bmatrix} 1 & x_{21} & \cdots & x_{m1} & x_{11} \\ 1 & x_{22} & \cdots & x_{m2} & x_{12} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 1 & x_{2n} & \cdots & x_{mn} & x_{1n} \end{bmatrix}, \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \beta_2 \\ \vdots \\ \beta_m \\ \beta_1 \end{bmatrix}.$$

Macierz  $\mathbf{X}$  i wektor parametrów można podzielić na

$$\mathbf{X}_1 = \begin{bmatrix} 1 & x_{21} & \cdots & x_{m1} \\ 1 & x_{22} & \cdots & x_{m2} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{2n} & \cdots & x_{mn} \end{bmatrix} \quad \mathbf{x}_2 = \begin{bmatrix} x_{11} \\ x_{12} \\ \vdots \\ x_{1n} \end{bmatrix} \quad \boldsymbol{\beta}_1 = \begin{bmatrix} \beta_0 \\ \beta_2 \\ \vdots \\ \beta_m \end{bmatrix} \quad \boldsymbol{\beta} = [\beta_1]$$

W tym modelu

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} \mathbf{X}'_1 \mathbf{X}_1 & \mathbf{X}'_1 \mathbf{x}_2 \\ \mathbf{x}'_2 \mathbf{X}_1 & \mathbf{x}'_2 \mathbf{x}_2 \end{bmatrix} \quad (\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} \mathbf{M} & \mathbf{k} \\ \mathbf{k}' & L \end{bmatrix}$$

gdzie

$$L = \frac{1}{\mathbf{x}'_2 \mathbf{x}_2 - \mathbf{x}'_2 \mathbf{X}_1 (\mathbf{X}'_1 \mathbf{X}_1)^{-1} \mathbf{X}'_1 \mathbf{x}_2},$$

$$\mathbf{k}' = -L(\mathbf{X}'_1 \mathbf{X}_1)^{-1} \mathbf{X}'_1 \mathbf{x}_2 \mathbf{X}_1, \quad \mathbf{M} = (\mathbf{X}'_1 \mathbf{X}_1)^{-1} - L \mathbf{k} \mathbf{k}'.$$

Ograniczenia opisane są za pomocą wektora  $[\mathbf{0}'_m : 1]$ . Po wykonaniu odpowiednich obliczeń otrzymujemy, że miarą wpływu zmiennej  $x_1$  na  $Y$  jest

$$\mathfrak{R}^2(x_2) = \frac{(\mathbf{x}'_2 (\mathbf{I}_n - \mathbf{X}_1 (\mathbf{X}'_1 \mathbf{X}_1)^{-1} \mathbf{X}'_1) \mathbf{Y})^2}{(\mathbf{Y}' (\mathbf{I}_n - \mathbf{X}_1 (\mathbf{X}'_1 \mathbf{X}_1)^{-1} \mathbf{X}'_1) \mathbf{Y})(\mathbf{x}'_2 (\mathbf{I}_n - \mathbf{X}_1 (\mathbf{X}'_1 \mathbf{X}_1)^{-1} \mathbf{X}'_1) \mathbf{x}_2)}$$

Współczynnik korelacji cząstkowej między  $Y$  a  $x_1$  określony jest jako  $\sqrt{\mathfrak{R}^2(x_2)}$  i oznaczany  $R_{Y(x_1)(x_2, \dots, x_m)}$ . Znak tego współczynnika jest oczywiście zgodny ze znakiem  $\mathbf{x}'_2 (\mathbf{I}_n - \mathbf{X}_1 (\mathbf{X}'_1 \mathbf{X}_1)^{-1} \mathbf{X}'_1) \mathbf{Y}$ . Z twierdzenia otrzymujemy następujący wniosek

*Wniosek.* Zmienna losowa

$$\frac{R_{Y(x_1)(x_2, \dots, x_m)}^2}{1 - R_{Y(x_1)(x_2, \dots, x_m)}^2} \cdot (n - m - 1)$$

ma niecentralny rozkład  $F$  z  $(1, n - m - 1)$  stopniami swobody i parametrem niecentralności  $\beta_2^2 \mathbf{x}'_2 (\mathbf{I}_n - \mathbf{X}_1 (\mathbf{X}'_1 \mathbf{X}_1)^{-1} \mathbf{X}'_1) \mathbf{x}_2$ .

*Dodatkowa zmienna.* Niech  $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$ . Przypuśćmy, że do modelu włączamy jeszcze jedną zmienną niezależną, tzn.  $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{z}\gamma + \boldsymbol{\eta} = \mathbf{W}\boldsymbol{\delta} + \boldsymbol{\eta}$ , gdzie  $\mathbf{W} = [\mathbf{X} : \mathbf{z}]$ ,  $\boldsymbol{\delta} = [\boldsymbol{\beta} : \gamma]'$  oraz  $\boldsymbol{\eta}$  jest wektorem błędów losowych. Tutaj  $\mathbf{z}$  jest wektorem  $n$ -wymiarowym reprezentującym włączaną zmienną, natomiast  $\gamma$  jest nieznanym współczynnikiem regresji. Wyznaczmy współczynnik  $\mathfrak{R}^2(\mathbf{W})$  i porównamy go z  $\mathfrak{R}^2(\mathbf{X})$ .

Estymatorem najmniejszych kwadratów wektora  $\boldsymbol{\delta}$  jest oczywiście  $\hat{\boldsymbol{\delta}} = (\mathbf{W}'\mathbf{W})^{-1}\mathbf{W}'\mathbf{Y}$ . Mamy

$$\mathbf{W}'\mathbf{W} = \begin{bmatrix} \mathbf{X}'\mathbf{X} & \mathbf{X}'\mathbf{z} \\ \mathbf{z}'\mathbf{X} & \mathbf{z}'\mathbf{z} \end{bmatrix}$$

oraz

$$(\mathbf{W}'\mathbf{W})^{-1} = \frac{1}{c} \begin{bmatrix} c(\mathbf{X}'\mathbf{X})^{-1} + \mathbf{a}\mathbf{a}' & -\mathbf{a} \\ -\mathbf{a}' & 1 \end{bmatrix}$$

gdzie  $\mathbf{a} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}\mathbf{z}$  oraz  $c = \mathbf{z}'(\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{z}$ . Zatem

$$\mathbf{d} = \begin{bmatrix} \mathbf{b} - \frac{\mathbf{z}'(\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{Y}}{\mathbf{z}'(\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{z}}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{z} \\ \frac{\mathbf{z}'(\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{Y}}{\mathbf{z}'(\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{z}} \end{bmatrix}$$

Ponieważ

$$\mathbf{Wd} = \mathbf{Xb} + \frac{\mathbf{z}'(\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{Y}}{\mathbf{z}'(\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{z}}(\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{z}$$

więc

$$\|\mathbf{Wd}\|^2 = \|\mathbf{Xb}\|^2 + \frac{(\mathbf{z}'(\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{Y})^2}{\mathbf{z}'(\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{z}}$$

Zatem  $\mathfrak{R}^2(\mathbf{W}) \geq \mathfrak{R}^2(\mathbf{X})$ , tzn. model z dodatkową zmienną nie gorzej odtwarza zmienną zależną niż model bez niej.

## LITERATURA

- Borkowski B., Dudek H., Szczesny W. 2003: Ekonometria, wybrane zagadnienia, PWN, Warszawa.  
 Draper N. R., Smith H. 1973: Analiza regresji stosowana, PWN, Warszawa.  
 Rao C. R. 1982: Modele liniowe statystyki matematycznej, PWN, Warszawa.  
 Seber G. A. F. 1977: Linear Regression Analysis, Wiley, New York.  
 Zieliński W. 2007: Teoretyczne podstawy ekonometrycznych jednorównaniowych modeli liniowych, Wydawnictwo SGGW, Warszawa.

## Generalized measure of fit in a linear model

**Abstract:** In a model of linear regression two measures of fit are used: coefficient of determination and coefficient of partial correlation. A generalization of those measures is proposed and a measure of influence of a group of independent variables excluding an influence of remaining variables is constructed.

**Keywords:** measure of fit, determination coefficient, partial correlation, linear regression