

9. Nieliniowa Metoda Najmniejszych Kwadratów

9.1. Regresja nieliniowa

Modele liniowe są w ekonomii często niewystarczające jako przybliżenie prawdziwych zależności między zmiennymi. Uogólniając model liniowy możemy estymować parametry równania

$$y_i = h(\mathbf{x}_i, \boldsymbol{\beta}) + \varepsilon_i$$

gdzie $h(\bullet, \bullet)$ jest pewną funkcją, \mathbf{x}_i jest wektorem zmiennych egzogenicznych, $\boldsymbol{\beta}$ wektorem parametrów estymowanych, zaś ε_i błędem losowym. Taka forma równania regresji, choć ogólniejsza od regresji liniowej nie wyczerpuje jednak wszystkich możliwości, na przykład zależności $y_i = \frac{\alpha}{\beta x_i + \varepsilon_i}$ nie da zapisać w ten sposób. Podobnie jak w przypadku *MNK* także w przypadku nieliniowej regresji za estymator parametru $\boldsymbol{\beta}$ przyjmujemy takie \mathbf{b} , które zapewnia najlepsze dopasowanie $\hat{y}_i = h(\mathbf{x}_i, \mathbf{b})$ do y_i . Za kryterium dopasowania przyjmujemy tak jak w przypadku *MNK* sumę kwadratów reszt.

$$S(\mathbf{b}) = \frac{1}{2} \sum_{i=1}^n [y_i - h(\mathbf{x}_i, \mathbf{b})]^2 = \frac{1}{2} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \frac{1}{2} \sum_{i=1}^n \varepsilon_i^2$$

Warunki pierwszego rzędu dla problemu

$$\min_{\mathbf{b}} S(\mathbf{b})$$

mają postać układu równań nieliniowych:

$$\frac{\partial S(\mathbf{b})}{\partial \mathbf{b}} = - \sum_{i=1}^n [y_i - h(\mathbf{x}_i, \mathbf{b})] \frac{\partial h(\mathbf{x}_i, \mathbf{b})}{\partial \mathbf{b}}$$

Układ ten z reguły nie ma analitycznego analitycznego rozwiązania. W związku z tym pojawiają się dwa problemy. Po pierwsze jak przeanalizować własności estymatora *NMNK* nie znając jego analitycznej formy a po drugie w jaki sposób można znaleźć wartość tego estymatora.

9.2. Zlinearyzowana regresja

Własności estymatora *NMNLK* zbadamy posługując się zlinearyzowaną wersją nieliniowej regresji. Zamiast rozważać własności nieliniowej funkcji

$$y_i = h(\mathbf{x}_i, \boldsymbol{\beta}^0) + \varepsilon_i$$

skorzystamy z rozwinięcia Taylora, uzyskując liniowej aproksymację tej funkcji. Dla pewnego z góry ustalonego $\boldsymbol{\beta}^0$, mamy

$$\begin{aligned} h(\mathbf{x}_i, \boldsymbol{\beta}) &\approx h(\mathbf{x}_i, \boldsymbol{\beta}^0) + \frac{\partial h(\mathbf{x}_i, \boldsymbol{\beta}^0)}{\partial \boldsymbol{\beta}^0} (\boldsymbol{\beta} - \boldsymbol{\beta}^0) \\ &= h(\mathbf{x}_i, \boldsymbol{\beta}^0) - \frac{\partial h(\mathbf{x}_i, \boldsymbol{\beta}^0)}{\partial \boldsymbol{\beta}^0} \boldsymbol{\beta}^0 + \frac{\partial h(\mathbf{x}_i, \boldsymbol{\beta}^0)}{\partial \boldsymbol{\beta}^0} \boldsymbol{\beta} \end{aligned}$$

Dla niewielkich wartości $\boldsymbol{\beta} - \boldsymbol{\beta}^0$ taka liniowa funkcja będzie dobrym przybliżeniem prawdziwej wartości $h(\mathbf{x}_i, \boldsymbol{\beta})$. Oznaczmy jako $\mathbf{x}_i^0 = \frac{\partial h(\mathbf{x}_i, \boldsymbol{\beta}^0)}{\partial \boldsymbol{\beta}^0}$, a wtedy

$$y_i \approx h(\mathbf{x}_i, \boldsymbol{\beta}^0) - \mathbf{x}_i^0 \boldsymbol{\beta}^0 + \mathbf{x}_i^0 \boldsymbol{\beta} + \varepsilon_i$$

Jednak tak zdefiniowana funkcja nie ma jeszcze postaci regresji liniowej, ponieważ po prawej stronie znajdują się nie związane z nieznanymi parametrami elementy $h(\mathbf{x}_i, \boldsymbol{\beta}^0)$, $\mathbf{x}_i^0 \boldsymbol{\beta}^0$. Można je jednak przenieść na lewą stronę i definiując $y_i^0 = y_i - h(\mathbf{x}_i, \boldsymbol{\beta}^0) + \mathbf{x}_i^0 \boldsymbol{\beta}^0$ otrzymujemy

$$y_i^0 \approx \mathbf{x}_i^0 \boldsymbol{\beta} + \varepsilon_i$$

które to równanie ma już postać klasycznego równania regresji. Tak zwanym pseudoregresorami w tym równaniu są elementy wektora $\mathbf{x}_i^0 = \frac{\partial h(\mathbf{x}_i, \boldsymbol{\beta}^0)}{\partial \boldsymbol{\beta}^0}$, a więc pierwsze pochodne $h(\mathbf{x}_i, \boldsymbol{\beta}^0)$ wzglę-

dem elementów wektora β^0 . Regresję tę można zapisać w postaci macierzowej

$$\mathbf{y}^0 = \mathbf{X}^0 \beta + \varepsilon \quad (9.1)$$

gdzie $\mathbf{y}^0 = \begin{bmatrix} y_1^0 \\ \vdots \\ y_n^0 \end{bmatrix}$, $\mathbf{X}^0 = \begin{bmatrix} \mathbf{x}_1^0 \\ \vdots \\ \mathbf{x}_n^0 \end{bmatrix}$.

Odpowiednikiem tej regresji będzie wyestymowane równanie postaci

$$\mathbf{y}^0 = \mathbf{X}^0 \mathbf{b} + \mathbf{e}.$$

Estymator *NMNK* minimalizuje sumę kwadratów reszt

$$S(\mathbf{b}) = \frac{1}{2} \sum_{i=1}^n [y_i - h(\mathbf{x}_i, \mathbf{b})]^2 = \frac{1}{2} \sum_{i=1}^n e_i^2$$

Warunki pierwszego rzędu dla tego estymatora można zapisać jako

$$\frac{\partial S(\mathbf{b})}{\partial \mathbf{b}} = - \sum_{i=1}^n [y_i - h(\mathbf{x}_i, \mathbf{b})] \frac{\partial h(\mathbf{x}_i, \mathbf{b})}{\partial \mathbf{b}} \approx - \sum_{i=1}^n (\mathbf{y}^0 - \mathbf{X}^0 \mathbf{b}) \frac{\partial h(\mathbf{x}_i, \beta^0)}{\partial \beta^0} = -\mathbf{X}^{0r} \mathbf{e} = \mathbf{0}$$

Warunek ortogonalności wynikającego z tego układu równań jest identyczny do tego, który pojawia się w kontekście *MNK*. Korzystając z (9.1) otrzymujemy układ równań liniowych

$$-\mathbf{X}^{0r} \mathbf{e}^0 = -\mathbf{X}^{0r} (\mathbf{y}^0 - \mathbf{X}^0 \mathbf{b}) = \mathbf{0}$$

który po rozwiązaniu daje nam estymator dla regresji zlinearyzowanej $\mathbf{b} = (\mathbf{X}^{0r} \mathbf{X}^0)^{-1} \mathbf{X}^0 \mathbf{y}^0$.

Estymator ten jest *bliski* estymatorowi *NMNK* parametru β pod warunkiem, że \mathbf{y}^0 i \mathbf{X}^0 zostały policzone dla β^0 *bliskiego* β , który uzyskalibyśmy znajdując minimum dla $S(\beta)$. Oczywiście w praktyce takie β^0 trzeba jakoś znaleźć i w związku z tym estymator zlinearyzowany będzie służył nam głównie do rozważań teoretycznych.

9.3. Asymptotyczne własności nieliniowego estymatora metody najmniejszych kwadratów

Warunki zbieżności i normalności wynikają z własności regresji zlinearyzowanej, przy czym wyrażone są poprzez własności macierzy pseudoregresorów \mathbf{X}^0 policzonych dla prawdziwej wielkości parametru β . W związku z tym warunki na zbieżność estymatora są identyczne jak analogiczne dla MNK .

Dla zbieżności estymatora koniecznym warunkiem jest, by

$$\text{plim} \left(\frac{\mathbf{X}^{0'} \mathbf{X}^0}{n} \right) = \text{plim} n^{-1} \sum_{i=1}^n \left(\frac{\partial h(\mathbf{x}_i, \beta)}{\partial \beta} \right) \left(\frac{\partial h(\mathbf{x}_i, \beta)}{\partial \beta'} \right) = \mathbf{Q}_0 \quad (9.2)$$

gdzie \mathbf{Q}_0 jest macierzą skończoną oraz asymptotyczny brak skorelowania między \mathbf{X}^0 i ε :

$$\text{plim} \left(\frac{\mathbf{X}^{0'} \varepsilon}{n} \right) = \text{plim} n^{-1} \sum_{i=1}^n \mathbf{x}_i^0 \varepsilon_i = 0 \quad (9.3)$$

Asymptotyczny rozkład normalny estymator $NMNK$ posiada, gdy dodatkowo

$$\frac{1}{\sqrt{n}} \mathbf{X}^{0'} \varepsilon = \frac{1}{\sqrt{n}} \sum_{i=1}^n \mathbf{x}_i^0 \varepsilon_i \xrightarrow{D} N(0, \sigma^2 \mathbf{Q}_0) \quad (9.4)$$

Podobnie jak w przypadku MNK zgodnym estymatorem wariancji błędu losowego będzie

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n [y_i - h(\mathbf{x}_i, \mathbf{b})]^2}{n} = \frac{\mathbf{e}' \mathbf{e}}{n}$$

przy czym jest to estymator zgodny. Zaleca się stosowanie poprawki na ilość stopni swobody, choć w małych próbach estymator ten jest i tak obciążony. W wersji z poprawką estymator ten ma postać

$$\tilde{\sigma}^2 = \frac{\mathbf{e}' \mathbf{e}}{n - k}$$

Twierdzenie 9.1 Dla pseudoregresorów spełniający założenia 9.2, 9.3, 9.4 estymator asymptotyczny rozkład estymatora Nieliniowej Metody Najmniejszych Kwadratów ma postać

$$\sqrt{n}(\mathbf{b} - \boldsymbol{\beta}) \xrightarrow{D} N[0, \sigma^2 \mathbf{Q}_0^{-1}],$$

gdzie $\mathbf{Q}_0 = \text{plim} \left(\frac{\mathbf{X}^{0'} \mathbf{X}^0}{n} \right)$. Zbieżnym estymatorem asymptotycznej wariancji estymatora \mathbf{b} jest

$$\widehat{\boldsymbol{\Sigma}}_{bb} = \widehat{\sigma}^2 (\mathbf{X}^{0'} \mathbf{X}^0)^{-1}$$

Dowód. Podobnie jak w przypadku MNK.

$$\begin{aligned} \sqrt{n}(\mathbf{b} - \boldsymbol{\beta}) &= \sqrt{n} \left[(\mathbf{X}^{0'} \mathbf{X}^0)^{-1} \mathbf{X}^0 \mathbf{y}^0 - \boldsymbol{\beta} \right] \\ &= \sqrt{n} \left[(\mathbf{X}^{0'} \mathbf{X}^0)^{-1} \mathbf{X}^{0'} (\mathbf{X}^0 \boldsymbol{\beta} + \boldsymbol{\varepsilon}) - \boldsymbol{\beta} \right] \\ &= \sqrt{n} \left[(\mathbf{X}^{0'} \mathbf{X}^0)^{-1} \mathbf{X}^{0'} \boldsymbol{\varepsilon} \right] \\ &= \left(\frac{\mathbf{X}^{0'} \mathbf{X}^0}{n} \right)^{-1} \frac{1}{\sqrt{n}} \mathbf{X}^{0'} \boldsymbol{\varepsilon} \xrightarrow{D} N[0, \sigma^2 \mathbf{Q}_0^{-1}] \end{aligned}$$

■

9.4. Testowanie hipotez w modelu nieliniowym

Rozpatrzmy ogólną hipotezę nieliniową postaci

$$H_0 : \mathbf{H}(\boldsymbol{\beta}) = \mathbf{h},$$

która ma postać układu g równań nieliniowych. Oznaczmy pochodną funkcji wektorowej $\mathbf{H}(\boldsymbol{\beta})$, jako

$$\mathbf{C}(\boldsymbol{\beta}) = \frac{\partial \mathbf{H}(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}'}$$

i zauważmy, że rozwinięcie Taylora $\mathbf{H}(\boldsymbol{\beta})$ wokół \mathbf{b} ma postać

$$\mathbf{H}(\mathbf{b}) \approx \mathbf{H}(\boldsymbol{\beta}) + \frac{\partial \mathbf{H}(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}'} (\mathbf{b} - \boldsymbol{\beta})$$

a więc

$$\mathbf{H}(\mathbf{b}) - \mathbf{H}(\boldsymbol{\beta}) \approx \frac{\partial \mathbf{H}(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}'} (\mathbf{b} - \boldsymbol{\beta})$$

i w konsekwencji przy założeniu prawdziwości H_0 otrzymujemy, że

$$\mathbf{H}(\mathbf{b}) - \mathbf{h} \approx \frac{\partial \mathbf{H}(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}'} (\mathbf{b} - \boldsymbol{\beta}) = \mathbf{C}(\boldsymbol{\beta}) (\mathbf{b} - \boldsymbol{\beta})$$

Wariancja $\mathbf{H}(\mathbf{b}) - \mathbf{h}$ będzie więc wynosić

$$\text{Var}[\mathbf{H}(\mathbf{b}) - \mathbf{h}] = \mathbf{C}(\boldsymbol{\beta}) \text{Var}(\mathbf{b} - \boldsymbol{\beta}) \mathbf{C}'(\boldsymbol{\beta})$$

Jeśli estymator \mathbf{b} jest zbieżny według prawdopodobieństwa i ma asymptotyczny rozkład normalny, to

$$\mathbf{H}(\mathbf{b}) - \mathbf{h} \xrightarrow{D} N(0, \mathbf{C}(\boldsymbol{\beta}) \text{Var}(\mathbf{b}) \mathbf{C}'(\boldsymbol{\beta}))$$

a

$$[\mathbf{H}(\mathbf{b}) - \mathbf{h}]' [\mathbf{C}(\boldsymbol{\beta}) \text{Var}(\mathbf{b}) \mathbf{C}'(\boldsymbol{\beta})]^{-1} [\mathbf{H}(\mathbf{b}) - \mathbf{h}] \xrightarrow{D} \chi_g$$

Zwykle $\mathbf{C}(\boldsymbol{\beta})$ i $\text{Var}(\mathbf{b})$ są nieznane jednak można je zastąpić w powyższej formie kwadratowej zbieżnymi estymatorami $\mathbf{C}(\mathbf{b})$ i $\widehat{\Sigma}$, otrzymując ostateczną formę statystyki

$$W = [\mathbf{H}(\mathbf{b}) - \mathbf{h}]' [\mathbf{C}(\mathbf{b}) \widehat{\Sigma} \mathbf{C}'(\boldsymbol{\beta})]^{-1} [\mathbf{H}(\mathbf{b}) - \mathbf{h}] \xrightarrow{D} \chi_g$$

Statystyka o tej formie nazywana jest statystyką Walda.