

Lineární regresní model

Specifikace lineárního jednorovnicového modelu

$$(1) \quad y = X\beta + \varepsilon$$

definice vyrovnaných hodnot závisle proměnné

$$(2A) \quad \hat{y} = Xb$$

definice reziduí

$$(2B) \quad \hat{\varepsilon} = y - Xb \text{ neboli } \hat{\varepsilon} = y - \hat{y}$$

odtud vyplývá možnost zápisu závisle proměnné

$$(3) \quad y = Xb + \hat{\varepsilon}$$

z porovnání (1) a (3) obdržíme vztah mezi ε a $\hat{\varepsilon}$:

$$(4) \quad X\beta + \varepsilon = Xb + \hat{\varepsilon}$$

(pokud použijeme odhad OLS, pak pravá strana = $X(X'X)^{-1} X'y + \hat{\varepsilon}$),
z čehož dále plyne

$$(5) \quad \hat{\varepsilon} = y - Xb = y - X(X'X)^{-1} X'y = \left[I_T - X(X'X)^{-1} X' \right] y = My$$

neboli platí $\hat{\varepsilon} = My$

(6)

$$\begin{aligned} \hat{\varepsilon} = y - Xb &= X\beta + \varepsilon - Xb = X\beta + \varepsilon - X(X'X)^{-1} X'y = X\beta + \varepsilon - X(X'X)^{-1} X'[X\beta + \varepsilon] = \\ &= X\beta + \varepsilon - X\beta - \left[X(X'X)^{-1} X' \right] \varepsilon = \left[I - X(X'X)^{-1} X' \right] \varepsilon = M\varepsilon \end{aligned}$$

neboli platí $\hat{\varepsilon} = M\varepsilon$

Varovná poznámka :

Ze vztahů $\hat{\varepsilon} = My$ a $\hat{\varepsilon} = M\varepsilon$ nelze usuzovat, že platí $y = \varepsilon$, neboť M je vždy singulární matice. Nelze proto nikdy psát $y = M^{-1}\varepsilon$ a $\varepsilon = M^{-1}y$.

Hodnost matice $M = I_T - X(X'X)^{-1} X' = T - k < T$

protože $h(I_T) = T$ $h\left(X(X'X)^{-1} X'\right) = h\left(X'X (X'X)^{-1}\right) = k$

Metoda nejmenších čtverců

Minimalizačním kritériem je zde součet čtverců reziduí (odhadnutých náhodných složek neboli rozdílů mezi pozorovanými a vyrovnanými hodnotami) :

$$\text{Min } e'e = \text{Min}(y - Xb)'(y - Xb) \text{ neboli v pozorovaných hodnotách}$$

$$\text{Min} \sum_{t=1}^T e_t^2 = \text{Min} \sum_{t=1}^T \left(y_t - \sum_{j=1}^K x_{tj} b_j \right) \left(y_t - \sum_{k=1}^K x_{tk} b_k \right)$$

Polohu minima (tj. bodu, ve kterém je minimalizovaný výraz nejmenší) nalezneme řešením soustavy tzv. normálních rovnic.

$$\frac{\partial e'e}{\partial b} = \frac{\partial (y - Xb)'(y - Xb)}{\partial b} = -2X'y + 2X'Xb = 0 \quad (\text{vektorově})$$

tuto soustavu řešíme úpravami (vydělením 2, přesunem členů) na tvar $X'Xb = X'y$, která má řešení pro b ve tvaru $b = (X'X)^{-1} X'y$, ← řešení je jednoznačné, neboť vzhledem k předpokladům $h(X) = k$, existuje (jediná) inverzní matice k matici $X'X$.

Vyjádření minimalizace v pozorovaných hodnotách :

$$H(y, X, b) = \sum_{t=1}^T \left(y_t - \sum_{i=1}^K x_{ti} b_i \right) \left(y_t - \sum_{j=1}^K x_{tj} b_j \right) = \sum_{t=1}^T y_t^2 - \sum_{t=1}^T y_t \left(\sum_{j=1}^K x_{tj} b_j \right) - \sum_{t=1}^T y_t \sum_{i=1}^K x_{ti} b_i + \sum_{t=1}^T \left(\sum_{i=1}^K x_{ti} b_i \right) \left(\sum_{j=1}^K x_{tj} b_j \right)$$

$$\frac{\partial H(y, X, b)}{\partial b_j} = 0 - 2 \sum_{t=1}^T X_{tj} y_t + 2 \sum_{t=1}^T x_{tj} \sum_{j=1}^k x_{tj} b_j = 0 \quad \text{pro } j = 1, 2, \dots, k$$
$$- 2X'y \quad + 2X'Xb$$

Prostá metoda nejmenších čtverců není jedinou používanou odhadovou metodou v prostředí standardního lineárního regresního modelu. K dalším technikám patří :

Metoda maximální věrohodnosti (Maximum Likelihood) je založena na maximalizaci sdružené hustoty (tzv. věrohodnostní funkce) rozdělení náhodných složek. Lokalizuje se tedy poloha modusu pro β a σ^2 , v němž tato funkce nabývá maxima.

Metoda nejmenších absolutních odchylek LAD (Least Absolute Deviations) je založena na minimalizačním kritériu tvaru

$$\sum_{t=1}^T \left| y_t - \sum_{j=1}^k x_{tj} \beta_j \right|$$

Odhady pořízené metodou LAD nelze vyjádřit v explicitním tvaru, ale je nutno použít iterační postup (např. algoritmy R.L.Faira)