

Standardní lineární regresní model

Standardní (také klasický) lineární regresní (jednorovnicový) model je charakterizován těmito předpoklady o vlastnostech modelových veličin :

1. **Centrovanost náhodných složek** $E \varepsilon = 0$
2. **Diagonalita kovarianční matice náhodných složek :** $Cov(\varepsilon, \varepsilon') = \sigma^2 \cdot I_T$
 - 2a) **homoskedasticita** (diagonální matice se stopou $T\sigma^2$.)
 - 2b) **neautokorelovanost náhodných složek** $E(\varepsilon_t \cdot \varepsilon_s) = \delta_{ts} \cdot \sigma^2$
3. **Nekorelovanost náhodných složek s nezávisle proměnnými** $E(X'\varepsilon) = 0$.
4. **Plná hodnota matice vysvětlujících proměnných** $h(X) = k$.

Odhadová funkce obyčejné (prosté) metody nejmenších čtverců MNČ (OLS) v klasickém lineárním regresním modelu

poskytuje odhad $OLS\beta^*$ regresních koeficientů β ve tvaru

$$OLS\beta^* = (X'X)^{-1} X'y$$

Věta 1 (Gauss-Markovova) . Odhad regresních koeficientů $OLS\beta^*$ pořízený obyčejnou (prostou) metodou nejmenších čtverců je nejlepším nestranným lineárním odhadem vektoru parametrů β

Důkaz: rozdělíme na několik částí

A. odhad $OLS\beta^*$ je nestranný (pro libovolnou velikost vzorku T) .

ověření nestrannosti :

$$\begin{aligned} E(\beta^*) &= E(X'X)^{-1} X'y = E(X'X)^{-1} X'(X\beta + \varepsilon) = E(X'X)^{-1} X'X\beta + E(X'X)^{-1} X'\varepsilon = \\ &= (X'X)^{-1} X'X E\beta + (X'X)^{-1} X' E\varepsilon = E\beta + E\varepsilon = \beta \quad \square . \end{aligned}$$

Důsledek 1 : Nestranná odhadová funkce je vždy asymptoticky nestranná.

Platí-li totiž $E({}^{(T)}\beta^*) = \beta$ pro každé konečné T , platí tentýž vztah i pro $T \rightarrow \infty$.

B. odhad β^*_{OLS} je konzistentní , tj. platí : $\lim_{T \rightarrow \infty} \beta^* = \beta$

Vlastnost platí i pro případ, že matice X je stochastická matice.

ověření konzistence : lze vyvodit z následujícího tvrzení :

Tvrzení 1 : Jestliže odhadová funkce je asymptoticky nestranná a kovarianční matice této odhadové funkce konverguje při $T \rightarrow \infty$ k nulové matici, pak je tato odhadová funkce konzistentní.

Důkaz vlastnosti B:

- a) asymptotická nestrannost OLS-odhadové funkce vyplývá z důsledku 1.
- b) konvergenci kovarianční matice OLS-odhadové funkce (její tvar viz dále ad D) k nulové matici ukážeme následovně :

Dále ukážeme, že $\text{Cov}(\beta^*) = \sigma_\varepsilon^2 (X'X)^{-1}$. Definujme matici $P = (X'X)/T$ a její ij -tý prvek označíme jako p_{ij} . Pro tento prvek platí

$$|p_{ij}| = \left| \frac{1}{T} \cdot \sum_{t=1}^T x_{ti} \cdot x_{tj} \right| \leq \xi_{ij}^2, \text{ přičemž tato rovnost platí pro všechna } T.$$

Všechny prvky této matice jsou tedy (v absolutní hodnotě) shora omezeny hodnotou $\xi^2 = \max \xi_{ij}^2$. Tedy, pro všechna T má matice P konečně velké prvky a je nesingulární. Zřejmě dále platí

$$(X'X)^{-1} = P^{-1} / T \quad (\text{neboť platí } X'X = T \cdot P)$$

a navíc matice P^{-1} má konečně velké prvky (π_{ij}) pro všechna T . Platí tedy

$$\lim_{T \rightarrow \infty} \text{Cov}(\text{OLS}\beta^*) = \lim_{T \rightarrow \infty} \sigma_\varepsilon^2 (X'X)^{-1} = \sigma_\varepsilon^2 \lim_{T \rightarrow \infty} P^{-1} / T = 0_K, \text{ kde}$$

0_K je symetrická matice složená ze samých nul.

C. odhad β^*_{OLS} je lineární (vzhledem k vysvětlované proměnné y),

neboť je definován jako lineární forma pozorování závisle proměnné y :

ověření linearity: lze psát $\beta^* = (X'X)^{-1} X'y = C'y$, kde matice $C' = (X'X)^{-1} X'$

představuje koeficienty lineární formy, jejíž proměnné tvoří složky vektoru y .

Poznamenejme, že vždy platí $C'X = (X'X)^{-1} X'X = I_k$, kde I_k je jednotková matice řádu k .

D. kovarianční matice příslušná odhadové funkci $\beta^* = (X'X)^{-1} X'y$ má následující tvar :

$$\text{Cov}(\beta^*) = \sigma_\varepsilon^2 (X'X)^{-1}.$$

(nestrannost β^*)

$$\text{ověření: } \text{Cov}(\beta^*) = E \{ [\beta^* - E(\beta^*)] [\beta^* - E(\beta^*)]' \} = \dots = E \{ [\beta^* - \beta] [\beta^* - \beta]' \} =$$

(dosazení za y)

$$E \{ [(X'X)^{-1} X'y - \beta] [(X'X)^{-1} X'y - \beta]' \} = E \{ [(X'X)^{-1} X'(X\beta + \varepsilon) - \beta] [(X'X)^{-1} X'(X\beta + \varepsilon) - \beta]' \}$$

$(X'X)^{-1} X'X = I_T$

(vyrůšení β)

$$= E \{ [\beta + (X'X)^{-1} X'\varepsilon - \beta] [\beta + (X'X)^{-1} X'\varepsilon - \beta]' \} = E \{ [(X'X)^{-1} X'\varepsilon] [(X'X)^{-1} X'\varepsilon]' \} =$$

(transpozice)

(vytknutí nestoch. členů před E)

$E\varepsilon\varepsilon' = \sigma_\varepsilon^2 I_T$

$$= E \{ [(X'X)^{-1} X'\varepsilon \varepsilon' X (X'X)^{-1}] \} = \dots = (X'X)^{-1} X' E\varepsilon\varepsilon' X (X'X)^{-1} = \dots =$$

(vytknutí skaláru σ_ε^2)

$(X'X)^{-1} X'X = I_T$

$$(X'X)^{-1} X' \sigma_\varepsilon^2 I_T X (X'X)^{-1} = \dots = \sigma_\varepsilon^2 (X'X)^{-1} X'X (X'X)^{-1} = \sigma_\varepsilon^2 (X'X)^{-1} \quad \square.$$

Odtud plyne důsledek :

D1 směrodatné odchylky odhadnutých **regresních parametrů** s_{β^*} získáme jako

$$\sigma_{\beta_j} = \sigma_\varepsilon \sqrt{\xi_{jj}^2}, \text{ kde}$$

ξ_{jj}^2 je j -tý diagonální prvek inverzní momentové matice $(X'X)^{-1}$

σ_ε je směrodatná odchylka náhodných složek (stejná u všech ε_t).

E. **odhad β^* je nejlepší** ve smyslu minimální kovarianční matice $Cov(\beta^*)$, neboť pro kovarianční matici kterékoliv jiné (lineární) odhadové funkce β^{**} platí :

$$Cov(\tilde{\beta}) - Cov(\beta^*) = \Omega ,$$

kde Ω je nějaká **symetrická pozitivně semidefinitní matice řádu k** (rozměrů $k \times k$).

ověření : Bez újmy na obecnosti můžeme matici D' jiné **lineární odhadové funkce**

$$\varepsilon \quad \text{vyjádřit ve tvaru} \quad D' = (X'X)^{-1}X' + G'$$

Poznámka : Vzhledem k požadavku na nestrannost β^{**} musí s ohledem na platnost vztahu $D'X = (X'X)^{-1}X'X + G'X = I_k$, vždy platit $G'X = 0$.

ověření vydatnosti:

$$\beta = E(\tilde{\beta}) = E(D'y) = E[D'(X\beta + \varepsilon)] = ED'X\beta + ED'\varepsilon = D'X\beta + 0 = D'X\beta$$

[matice D, X jsou nestochastické]

z čehož přímo plyne $D'X = I_k$

Pro libovolnou jinou (lineární, nestrannou) odhadovou funkci tedy musí platit

$$\begin{aligned} Cov(\tilde{\beta}) &= E\{[\tilde{\beta} - E\tilde{\beta}][\tilde{\beta} - E\tilde{\beta}]'\} = E\{[D'y - \beta][D'y - \beta]'\} = \\ &= E\{[(X'X)^{-1}X' + G']y - \beta\} \cdot \{[(X'X)^{-1}X' + G']y - \beta\}' = \\ &= E\{[(X'X)^{-1}X' + G'](X\beta + \varepsilon) - \beta\} \cdot \{[(X'X)^{-1}X' + G'](X\beta + \varepsilon) - \beta\}' = \\ &= E\{[(X'X)^{-1}X'X\beta + (X'X)^{-1}X'\varepsilon + G'\varepsilon - \beta] \cdot [(X'X)^{-1}X'X\beta + (X'X)^{-1}X'\varepsilon + G'\varepsilon - \beta]'\} = \\ &\quad \text{[protože } G'X = 0 \text{]} \quad \text{[protože } G'X = 0 \text{]} \\ &= E\{[\beta + (X'X)^{-1}X'\varepsilon + G'\varepsilon - \beta] \cdot [\beta + (X'X)^{-1}X'\varepsilon + G'\varepsilon - \beta]'\} = \\ &= E\{[(X'X)^{-1}X'\varepsilon + G'\varepsilon] \cdot [(X'X)^{-1}X'\varepsilon + G'\varepsilon]'\} = \\ &= E\{(X'X)^{-1}X'\varepsilon\varepsilon'X(X'X)^{-1} + G'\varepsilon\varepsilon'G + (X'X)^{-1}X'\varepsilon\varepsilon'G + G'\varepsilon\varepsilon'X(X'X)^{-1}\} = \\ &= (X'X)^{-1}X'E\varepsilon\varepsilon'X(X'X)^{-1} + G'E\varepsilon\varepsilon'G + (X'X)^{-1}X'E\varepsilon\varepsilon'G + G'E\varepsilon\varepsilon'X(X'X)^{-1} = \\ &\quad \text{[protože } X \text{ i } G \text{ jsou nestochastické matice]} \\ &= (X'X)^{-1}X'\sigma^2I_TX(X'X)^{-1} + G'\sigma^2I_TG + (X'X)^{-1}X'\sigma^2I_TG + G'\sigma^2I_TX(X'X)^{-1} = \\ &= \sigma^2(X'X)^{-1} + \sigma^2G'G + \sigma^2(X'X)^{-1}X'G + \sigma^2G'X(X'X)^{-1} = \\ &\quad \text{[protože } \sigma^2 \text{ je skalární hodnota]} \\ &= \sigma^2(X'X)^{-1} + \sigma^2G'G = Cov(\beta^*) + \sigma^2G'G, \\ &\quad \text{[protože } G'X = 0 \text{ a stejně } X'G = 0 \text{]} \end{aligned}$$

kde $G'G$ je zřejmě pozitivně semidefinitní matice. □.

F. **Pro odhad rozptylu reziduí dostaneme :**

$$\begin{aligned} E(e'e) &= E(\varepsilon'M\varepsilon) = E(\varepsilon'M\varepsilon) = E\text{tr}(\varepsilon'M\varepsilon) = E\text{tr}(M\varepsilon\varepsilon') = \\ &\quad \text{(M je idempotentní matice)} \quad \text{(skalár je současně svou stopou)} \quad \text{(tr A.B = tr B.A)} \\ &= \text{tr} E(M\varepsilon\varepsilon') = \text{tr}(ME\varepsilon\varepsilon') = \text{tr}(M\sigma_\varepsilon^2I_T) = \sigma_\varepsilon^2 \text{tr}(M) = \sigma_\varepsilon^2(T-k) \\ &\quad \text{(záměna stopy a střední hodnoty)} \quad \text{(M je nestochastická)} \quad \text{(\sigma^2 je skalární hodnota)} \end{aligned}$$

protože $\text{tr}(M) = \text{tr}(I_T - X(X'X)^{-1}X') = \text{tr}(I_T - X'X(X'X)^{-1}) = \text{tr}(I_T - I_k) = T - k$.
 (definice M) (platí tr A.B = tr B.A) (stopa jednotkové matice je rovna její dimenzi)

G. Z tvrzení F plyne, že **nestranným odhadem rozptylu náhodných složek** σ_ε^2

je výraz $\hat{\sigma}_\varepsilon^2 = \frac{e'e}{T-k}$, neboť zřejmě platí $E \left[\frac{\sum e_t^2}{T-k} \right] = \sigma_\varepsilon^2$.