

Zobecněný lineární regresní model

Zobecněný lineární regresní (jednorovnicový) model je charakterizován následujícími vlastnostmi modelových veličin :

1. **Centrovanost náhodných složek** $E\varepsilon = 0$
2. **Obecnost kovarianční matice náhodných složek :** $Cov(\varepsilon, \varepsilon') = \Sigma$ (obecná, nestochastická matice)
 - 2a) **heteroskedasticita**
 - 2b) **autokorelovanost náhodných složek**
3. **Nekorelovanost náhodných složek s nezávisle proměnnými** $EX'\varepsilon = 0$.
4. **Plná hodnota matice vysvětlujících proměnných** $h(X) = k$

Odhadová funkce zobecněné metody nejmenších čtverců (GLS) v zobecněném lineárním regresním modelu

(tzv. Aitkenovo zobecnění MNČ/OLS)

poskytuje odhad ${}_{GLS}\hat{\beta}$ regresních koeficientů β ve tvaru

$${}_{GLS}\hat{\beta} = (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}y$$

a má v zobecněném lineárním regresním modelu následující vlastnosti :

A. Odhad ${}_{GLS}\hat{\beta}$ je nestranný pro libovolnou velikost vzorku T , protože :

$$\begin{aligned} E({}_{GLS}\hat{\beta}) &= E(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}y = E(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}(X\beta + \varepsilon) = \\ &= E(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}X\beta + E(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}\varepsilon \\ &= E\beta + (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}E\varepsilon = \beta + 0 = \beta \end{aligned}$$

B. Odhad ${}_{GLS}\hat{\beta}$ je lineární (vůči y), neboť je lineární formou pozorování závisle proměnné ${}_{GLS}\hat{\beta} = (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}y$ s maticí $C = (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}$ koeficientů příslušné lineární formy. Poznamenejme, že vždy platí $C'X = (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}X = I_k$, kde I_k je jednotková matice řádu k .

C. Kovarianční matice příslušná odhadové funkci **má tvar** :

$$\begin{aligned} Cov({}_{GLS}\hat{\beta}) &= E[(\hat{\beta} - E\hat{\beta})(\hat{\beta} - E\hat{\beta})'] = E[(\hat{\beta} - \beta)(\hat{\beta} - \beta)'] = \\ Cov({}_{GLS}\hat{\beta}) &= E\left[\left[(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}y - \beta\right]\left[(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}y - \beta\right]'\right] = \\ &= E\left[\left[(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}(X\beta + \varepsilon) - \beta\right]\left[(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}(X\beta + \varepsilon) - \beta\right]'\right] = \\ &= E\left[\beta + (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}\varepsilon - \beta\right]\left[\beta + (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}\varepsilon - \beta\right]' = \end{aligned}$$

$$\begin{aligned}
&= E\left[(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}\varepsilon\right]\left[(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}\varepsilon\right]' \\
&= (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}E[\varepsilon\varepsilon']\Sigma^{-1}X(X'\Sigma^{-1}X)^{-1} = \\
&= (X'\Sigma^{-1}X)^{-1}(X'\Sigma^{-1}\Sigma\Sigma^{-1}X)(X'\Sigma^{-1}X)^{-1} = (X'\Sigma^{-1}X)^{-1} \quad \square.
\end{aligned}$$

D. odhad ${}_{GLS}\hat{\beta}$ je nejlepší ve smyslu minimální kovarianční matice $Cov({}_{GLS}\hat{\beta})$, neboť pro kovarianční matici kterékoliv jiné (lineární) odhadové funkce $\tilde{\beta}$ platí :

$$Cov(\tilde{\beta}) - Cov({}_{GLS}\hat{\beta}) = \Omega$$

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

ověření: Bez újmy na obecnosti můžeme matici D libovolné jiné lineární odhadové funkce $\tilde{\beta}$ vyjádřit ve tvaru

$$D = (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1} + G'$$

Poznámka : Vzhledem k požadavku na nestrannost ${}_{GLS}\hat{\beta}$ musí s ohledem na platnost

$$D'X = (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}X + G'X = I_T, \quad \text{vždy platit } G'X = 0.$$

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

$$\begin{aligned}
Cov(\tilde{\beta}) &= E\left[(\tilde{\beta} - E\tilde{\beta}) \cdot (\tilde{\beta} - E\tilde{\beta})'\right] = E\left[(\tilde{\beta} - \beta) \cdot (\tilde{\beta} - \beta)'\right] = \\
&= E\left[\left((X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1} + G'\right)y - \beta\right] \cdot \left[\left((X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1} + G'\right)y' - \beta'\right]' \\
&= E\left[\left((X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1} + G'\right)(X\beta + \varepsilon) - \beta\right] \cdot \left[\left((X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1} + G'\right)(X\beta + \varepsilon) - \beta'\right]' \\
&= E\left[\left((X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}X\beta + G'X\beta + \varepsilon\right) + G'\varepsilon - \beta\right] \cdot \left[\left((X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}X\beta + G'X\beta + \varepsilon\right) - \beta'\right]' \\
&\dots\dots\dots \\
&= E\left[\left((X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}\varepsilon + G'\varepsilon\right) \cdot \left[\left((X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}\varepsilon + G'\varepsilon\right)'\right]\right] = \\
&= E\left[\left((X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}\varepsilon\varepsilon'\Sigma^{-1}X(X'\Sigma^{-1}X)^{-1} + G'\varepsilon\varepsilon'G + (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}\varepsilon\varepsilon'G + G'\varepsilon\varepsilon'\Sigma^{-1}X(X'\Sigma^{-1}X)^{-1}\right)\right] \\
&= (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}E\varepsilon\varepsilon'\Sigma^{-1}X(X'\Sigma^{-1}X)^{-1} + G'E\varepsilon\varepsilon'G + (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}E\varepsilon\varepsilon'G + G'E\varepsilon\varepsilon'\Sigma^{-1}X(X'\Sigma^{-1}X)^{-1} \\
&= (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}\Sigma\Sigma^{-1}X(X'\Sigma^{-1}X)^{-1} + G'\Sigma G + (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}\Sigma G + G'\Sigma\Sigma^{-1}X(X'\Sigma^{-1}X)^{-1} = \\
&= (X'\Sigma^{-1}X)^{-1} + G'\Sigma G + (X'\Sigma^{-1}X)^{-1}X'G + G'X(X'\Sigma^{-1}X)^{-1} \\
&= (X'\Sigma^{-1}X)^{-1} + G'\Sigma G = Cov({}_{GLS}\hat{\beta}) + G'\Sigma G,
\end{aligned}$$

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

Poznámka 1: Odhadová funkce zobecněné metody nejmenších čtverců ${}_{GLS}\hat{\beta}$ ve tvaru ${}_{GLS}\hat{\beta} = (X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1}y$ v situacích, kdy (což je pravidlem) neznáme přesný tvar kovarianční matice Σ není přímo použitelná. Proto je ji nutno zpravidla nahradit výrazem

$${}_{GLS}\hat{\beta} = (X'\hat{\Sigma}^{-1}X)^{-1}X'\hat{\Sigma}^{-1}y,$$

kde $\hat{\Sigma}$ je nějaký vhodný odhad matice Σ .

Poznámka 2: Odhadová funkce obyčejné metody nejmenších čtverců (OLS) $\tilde{\beta}_{OLS}$ má v zobecněném lineárním regresním modelu tyto vlastnosti :

- (A) odhad $\tilde{\beta}_{OLS}$ je nestranný
- (B) odhad $\tilde{\beta}_{OLS}$ je lineární
- (C) odhad $\tilde{\beta}_{OLS}$ není nejlepší

Odvození zobecněné metody nejmenších čtverců GLS

Uvažujme nejprve lineární regresní model ve tvaru

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

u kterého uvolníme předpoklad (2) a nahradíme ho předpokladem (2*)
Kovarianční matice náhodných složek má obecný tvar :

$$(2^*) \quad Cov(\varepsilon, \varepsilon') = \Sigma \text{ (obecná, nestochastická matice),}$$

což znamená **2a) heteroskedasticitu**

2b) autokorelovanost náhodných složek

Znormujeme-li matici Σ "průměrným rozptylem" σ^2 , můžeme ji vyjádřit ve tvaru

$$\Sigma = \sigma^2 \cdot V,$$

kde σ^2 je skalár a V je symetrická pozitivně definitní matice. Matice V je normována tak, aby její stopa byla rovna T (tj. $tr(V) = T$). Průměr diagonálních prvků Σ je pak roven σ^2 .

Formálně zapsáno

$$\Sigma = \sigma^2 \cdot V = \sigma^2 \cdot \begin{bmatrix} \frac{\sigma_1^2}{\sigma^2} & 0 & \dots & 0 \\ 0 & \frac{\sigma_2^2}{\sigma^2} & \dots & 0 \\ \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & \frac{\sigma_T^2}{\sigma^2} \end{bmatrix}$$

Pro $V = I_T$ model přechází ve standardní lineární regresní model.

Připomeňme, že libovolnou (symetrickou) pozitivně definitní matici lze vyjádřit ve tvaru součinu dvou regulárních vzájemně transponovaných matic. Zapišme tedy

$$(3) \quad V = R^{-1} \cdot R'^{-1} \quad \text{neboli} \quad V^{-1} = (R^{-1} \cdot R'^{-1})^{-1} = R' \cdot R$$

Přitom zřejmě platí $R \cdot V \cdot R' = I_T$.

Vynásobíme-li model (1) touto nesingulární maticí R (řádu i hodnosti T), dostaneme

$$(4a) \quad Ry = R.X.\beta + R.\varepsilon \quad \text{neboli}$$

$$(4) \quad y^* = X^* \beta + \varepsilon^*$$

kde píšeme $y^* = R.y, X^* = R.X, \varepsilon^* = R.\varepsilon$.

Určeme kovarianční matici náhodného vektoru transformovaných náhodných složek

$$(5) \quad E(\varepsilon^* . \varepsilon^{*'}) = E(R.\varepsilon.\varepsilon' R') = \sigma^2 R.V.R' = \sigma^2 .I_T$$

[Podotkněme, že matice R byla volena právě s cílem dosáhnout diagonální kovarianční matice náhodných složek].

Ukážeme, že transformovaný model (4) má vlastnosti **standardního lineárního regresního modelu**:

Náhodné složky ε^* jsou totiž

a) centrované : $E(\varepsilon^*) = E(R.\varepsilon) = 0$.

b) vzájemně nekorelované a

homoskedastické : $E(\varepsilon^* . \varepsilon^{*'}) = E(R.\varepsilon.\varepsilon' R') = \sigma^2 .R.V.R' = \sigma^2 .I_T$.

c) nekorelované s vysvětlujícími proměnnými:

$$E(X^{*'} . \varepsilon^*) = E(X' R' R \varepsilon) = (RX)' R (E\varepsilon) = 0$$

(předsunutí před střední hodnotu je možné vzhledem k nestochastičnosti matic X, R).

Protože matice V^{-1} je stejně jako V symetrická a pozitivně definitní, lze ji vyjádřit takto:

$$(6) \quad V^{-1} A = A.D \quad , \text{ kde}$$

- matice $A_{[T \times T]}$ je matice, jejíž sloupce tvoří charakteristické vektory matice V^{-1} . Vlastní vektory mohou být zapsány při vhodné normalizaci v ortonormálním tvaru, takže pro sloupce matice A lze psát $a_i . a_i = 1, a_i . a_j = 0$ pro $i \neq j$. Proto tedy platí $A.A' = I_T$.

- matice $D [T \times T]$ je diagonální matice s diagonálou tvořenou charakteristickými čísly $R^{-1} : \lambda^1, \lambda^2, \dots, \lambda^T$ Pro matici V^{-1} lze psát (při násobení (6) maticí A' zprava) :

$$(6a) \quad V^{-1} = A.D.A' = A.D^{1/2} . D^{1/2} . A' \quad ,$$

kde D je diagonální matice, na jejíž diagonále jsou nějak (vzestupně či sestupně) seřazeny charakteristické kořeny/čísla matice V^{-1} . Matici R definujeme vztahem

$$R = D^{1/2} . A'$$

Je zřejmé, že při této volbě matice R bude platit :

$$(7) \quad R' R = A.D^{1/2} . D^{1/2} A' = V^{-1}$$

Využijeme-li nyní odhadovou funkci obyčejné metody nejmenších čtverců OLS k odhadu parametrů modelu (4), dostaneme :

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

nebo rovnocenně

$$(8) \quad \beta_{OLS}^* = (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} y$$

Kovarianční matice příslušná této odhadové funkci má tvar

$$(9) \quad Cov(\beta^*) = \sigma^2 \cdot (X'^* X^*)^{-1} = \sigma^2 \cdot (X' V^{-1} X)^{-1} = (X' \Sigma^{-1} X)^{-1}$$

Vzhledem k tomu, že prvky matice V zpravidla neznáme, je nutno při praktickém uplatnění odhadové funkce GLS (zobecněné metody nejmenších čtverců) použít nějaký její odhad.

Nestranný odhad s^2 pro σ^2 získáme standardním způsobem

$$(10) \quad s^2 = \frac{e^{*'} e^*}{T - k} = \frac{[y^* - X^* b]' [y^* - X^* b]}{T - k} = \frac{[R \cdot y - R \cdot X b]' [R \cdot y - R X b]}{T - k} = \frac{[y - X b]' R' R [y - X b]}{T - k} = \frac{e' V e}{T - k}$$

Poznámka: pracujeme-li s centrovanými veličinami y^* , lze **rozptyl závisle proměnné** vyjádřit jako

$$\begin{aligned} y^{*'} y^* &= [X^* b + e^*]' [X^* b + e^*] = b' X' R' R X b + e' R' R e = \\ &= b' X' V^{-1} X b + e' V^{-1} e \end{aligned}$$

První člen představuje vysvětlený, druhý člen nevysvětlený (reziduální) rozptyl. Reziduální rozptyl je představován kvadratickou formou v proměnných e s maticí koeficientů V^{-1} .

Získat takový odhad není však pro obecný případ (obecná matice Σ) vůbec snadné, neboť narážíme na nedostatek vstupní modelové informace:

- matice Σ má až $(T+1) \cdot T/2$ různých prvků, zatímco modelová informace obsažená v matici X sestává pouze z $T \times k$ pozorovaných hodnot vysvětlujících proměnných. Při $T=20$ bychom potřebovali odhadnout až 210 různých prvků matice Σ . Z tohoto důvodu se v reálných situacích zpravidla uplatňují jednodušší verze obecné GLS-metody, hlavně

- vážená metoda nejmenších čtverců WLS, která operuje s maticí Σ , jež má nenulové prvky (rozptyly) pouze na hlavní diagonále*
- různé speciální tvary matice Σ , jejíž prvky závisí na (podstatně) menším počtu jiných parametrů, které jsou snáze odvoditelné z dostupných dat.*

Uvědomme si, že v případě:

- standardního lineárního regresního modelu (metodou OLS) můžeme využít k odhadu jediného parametru matice Σ (stejně velkého rozptylu náhodných složek) celkem T reziduálních hodnot e_t .**
- zobecněného lineárního regresního modelu postiženého toliko heteroskedasticitou (metodou WLS) můžeme použít k odhadu T - parametrů matice Σ právě stejný počet T reziduálních hodnot e_t .**
- zobecněného lineárního regresního modelu v plné jeho obecnosti (metodou GLS) můžeme použít k odhadu $T \times (T+1)/2$ parametrů matice Σ právě jen těch T reziduálních hodnot e_t . (což zřejmě bez další případné doprovodné informace nestačí).**

V případě metody WLS se problém řeší zpravidla využitím apriorního předpokladu o velikosti náhodných složek (obvykle se zde uplatní vztah velikosti rezidua a vysvětlované proměnné).¹

V případě metody GLS se zpravidla vysloví (problém zjednodušující) předpoklad o konkrétním tvaru závislosti náhodných složek navzájem (např. předpoklad o jejich vzájemné autokorelovanosti 1. řádu), čímž se výrazně sníží počet neznámých (odhadovaných) parametrů.²

Odhadová funkce vážené metody nejmenších čtverců (WLS)

Vážená metoda nejmenších čtverců je speciálním případem zobecněné metody nejmenších čtverců. Je použitelná v situacích, kdy náhodné složky regresní rovnice nevykazují vzájemnou korelovanost.

Poskytuje odhady vykazující příznivé vlastnosti v modelu, který se vyznačuje (pouze) heteroskedasticitou, nikoliv autokorelací náhodných složek. Z obou podmínek vztahujících se k tvaru kovarianční matice náhodných složek Σ platí tedy jen

2a) (čistá) heteroskedasticita: $Cov(\varepsilon, \varepsilon') = \Sigma$ (diagonální nestochastická matice)

$$(11) \quad \text{neboli } \Sigma = \begin{pmatrix} \sigma_1^2 & 0 & \dots & 0 \\ \dots & \sigma_2^2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \sigma_T^2 \end{pmatrix},$$

přičemž prvky hlavní diagonály jsou obecně různé.³

Pro váženou metodu nejmenších čtverců platí všechny vlastnosti zobecněné metody nejmenších čtverců. Odhadová funkce však bude mít jednodušší tvar, protože prvky diagonály inverzní matice Σ^{-1} značené σ^{ii} mají tvar

$$(12) \quad \sigma^{ii} = \frac{adj(\sigma_{ii})}{|\Sigma|} = \frac{\prod_{\substack{j=1 \\ j \neq i}}^T \sigma_{jj}}{\prod_{j=1}^T \sigma_{jj}} = \frac{1}{\sigma_{ii}}, \quad \sigma^{ij} = 0 \quad \text{pro } i \neq j$$

Matice Σ^{-1} je tedy také diagonální

Nyní zapíšeme tvar WLS-odhadové funkce ${}_{WLS} \hat{\beta} = (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} y$

ve „strukturním“ tvaru

¹ Způsoby řešení tohoto problému budou podrobněji vyloženy v oddíle *Heteroskedasticita*

² Způsoby řešení tohoto problému budou podrobněji vyloženy v oddíle *Autokorelace*.

³ Diagonální prvky matice Σ (rozptyly) se značí buď σ_t^2 nebo jen σ_{tt} (tj. bez druhé mocniny)

$$X' \Sigma^{-1} X = \begin{pmatrix} \sum_{t=1}^T \sigma_t^2 x_{1t} x_{1t} & \sum_{t=1}^T \sigma_t^2 x_{1t} x_{2t} & \dots & \sum_{t=1}^T \sigma_t^2 x_{1t} x_{Tt} \\ \sum_{t=1}^T \sigma_t^2 x_{2t} x_{1t} & \sum_{t=1}^T \sigma_t^2 x_{2t} x_{2t} & \dots & \sum_{t=1}^T \sigma_t^2 x_{2t} x_{Tt} \\ \dots & \dots & \dots & \dots \\ \sum_{t=1}^T \sigma_t^2 x_{Tt} x_{1t} & \sum_{t=1}^T \sigma_t^2 x_{Tt} x_{2t} & \dots & \sum_{t=1}^T \sigma_t^2 x_{Tt} x_{Tt} \end{pmatrix}, \quad X' \Sigma^{-1} y = \begin{pmatrix} \sum_{t=1}^T \sigma_t^2 x_{1t} y_t \\ \sum_{t=1}^T \sigma_t^2 x_{2t} y_t \\ \dots \\ \sum_{t=1}^T \sigma_t^2 x_{Tt} y_t \end{pmatrix}$$

Stejně jako v případě GLS je k praktickému nasazení odhadové metody WLS zapotřebí uplatnit nějakým způsobem odhadnutý tvar $\tilde{\Sigma}$ kovarianční matice Σ . Budeme tedy pracovat s odhadovou funkcí tvaru

$$(13) \quad \hat{\beta}_{WLS} = (X' \tilde{\Sigma}^{-1} X)^{-1} X' \tilde{\Sigma}^{-1} y.$$

$$X' \tilde{\Sigma}^{-1} X = \begin{pmatrix} \sum_{t=1}^T s_t^2 x_{1t} x_{1t} & \sum_{t=1}^T s_t^2 x_{1t} x_{2t} & \dots & \sum_{t=1}^T s_t^2 x_{1t} x_{Tt} \\ \sum_{t=1}^T s_t^2 x_{2t} x_{1t} & \sum_{t=1}^T s_t^2 x_{2t} x_{2t} & \dots & \sum_{t=1}^T s_t^2 x_{2t} x_{Tt} \\ \dots & \dots & \dots & \dots \\ \sum_{t=1}^T s_t^2 x_{Tt} x_{1t} & \sum_{t=1}^T s_t^2 x_{Tt} x_{2t} & \dots & \sum_{t=1}^T s_t^2 x_{Tt} x_{Tt} \end{pmatrix}, \quad X' \tilde{\Sigma}^{-1} y = \begin{pmatrix} \sum_{t=1}^T s_t^2 x_{1t} y_t \\ \sum_{t=1}^T s_t^2 x_{2t} y_t \\ \dots \\ \sum_{t=1}^T s_t^2 x_{Tt} y_t \end{pmatrix}$$

Váhy v případě vážené metody nejmenších čtverců WLS bychom ovšem mohli stanovit i zcela subjektivně tak, že bychom užili odhadovou funkci (13) s maticí $\tilde{\Sigma}^*$ s prvky

$$(14) \quad \text{neboli } \tilde{\Sigma}^* = \begin{pmatrix} w_1 & 0 & \dots & 0 \\ \dots & w_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & w_T \end{pmatrix},$$

Abychom získali příslušnou odhadovou funkci, stačí nyní všechny pozorované hodnoty ve vektoru y a v matici X dělit (po řádcích) odmocninami vah w_1, w_2, \dots, w_T neboli

$$y^* = \begin{pmatrix} y_1 / \sqrt{w_1} \\ y_2 / \sqrt{w_2} \\ \dots \\ y_T / \sqrt{w_T} \end{pmatrix}, \quad X^* = \begin{pmatrix} x_{11} / \sqrt{w_1} & x_{12} / \sqrt{w_1} & \dots & x_{1k} / \sqrt{w_1} \\ x_{21} / \sqrt{w_2} & x_{22} / \sqrt{w_2} & \dots & x_{2k} / \sqrt{w_2} \\ \dots & \dots & \dots & \dots \\ x_{T1} / \sqrt{w_T} & x_{T2} / \sqrt{w_T} & \dots & x_{Tk} / \sqrt{w_T} \end{pmatrix}$$

Poznámka: Přirozeně, na vhodnosti volby vah w_i závisí kvalita (jmenovitě vydatnost) pořízených odhadů parametrů. Budou-li váhy co nepřesněji aproximovat směrodatné odchylky náhodných složek, pak budou i odhady vydatné. Pokud bychom však vzali váhy nepatřičné (např. bychom pozorování směrodatnými odchylkami σ_t násobili (nikoliv dělili), mohli bychom dostat odhady parametrů ještě méně vydatné než při nasazení metody OLS.

