

## Zobecněný lineární regresní model

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

- A) **Centrovanost náhodných složek**  $E\varepsilon = 0$
- B) **Obecnost kovarianční matice náhodných složek:**  $Cov(\varepsilon, \varepsilon') = \Sigma$  (obecná, nestochastická matice )
- 1b) **heteroskedasticita**
- 2b) **autokorelovanost** náhodných složek
- C) **Nekorelovanost náhodných složek s nezávisle proměnnými**  $EX'\varepsilon = 0$
- D) **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  $\beta$  ve tvaru

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

a má v zobecněném lineárním regresním modelu následující vlastnosti :

**1. odhad  ${}_{GLS}\hat{\beta}$  je nestranný** (pro libovolnou velikost vzorku  $T$ )

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

**2. 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  $k$ .

**3. kovarianční matice** příslušná odhadové funkci má tvar

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

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

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

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

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

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

**Poznámka** Vzhledem k požadavku na nestrannost  ${}_{GLS} \hat{\beta}$  musí s ohledem na platnost  $\mathbf{D}' \mathbf{X} = (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} X + \mathbf{G}' X = \mathbf{I}_T$ , vždy platit  $\mathbf{G}' X = 0$ .

Pr\*o libovolnou jinou (lineární, nestrannou) odhadovou funkci tedy musí platit

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

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

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

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

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

kde  $\hat{\Sigma}$  je nějaký vhodný odhad matice  $\Sigma$ .<sup>1</sup>

**Poznámka:** Všimněme-si, že zobecněná metoda nejmenších čtverců přechází v případě, že kovarianční matici náhodných složek je diagonální se stejnými prvky v obyčejnou metodu nejmenších čtverců:

${}_{GLS} \hat{\beta} = \left( X' \Sigma^{*-1} X \right)^{-1} X' \Sigma^{*-1} y$ , kde  $\Sigma^* = \sigma^2 I_T$ , pak zřejmě platí

$$\begin{aligned}
{}_{GLS} \hat{\beta} &= \left( X' (\sigma^2 \cdot I_T)^{-1} X \right)^{-1} X' (\sigma^2 \cdot I_T)^{-1} y = \left( X' \sigma^{-2} X \right)^{-1} \left( X' \sigma^{-2} y \right) =_2 \\
&= \sigma^2 \left( X' X \right)^{-1} \sigma^{-2} X' y = \left( X' X \right)^{-1} X' y = {}_{OLS} \hat{\beta}
\end{aligned}$$

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

- 1) odhad  ${}_{OLS} \tilde{\beta}$  je nestranný
- 2) odhad  ${}_{OLS} \tilde{\beta}$  je lineární
- 3) odhad  ${}_{OLS} \tilde{\beta}$  není nejlepší

<sup>1</sup> Získat odhad kovarianční matice  $\Sigma$  použitelné pro GLS estimátor je ovšem daleko problematičtější než odhad jediného prvku- rozptylu o OLS, kde lze snadno užít výrazy. Uvědomme si, že k odhadu obecně  $T(T+1)/2$  máme jen  $Tx(k+1)$  pozorovaných hodnot. Těch bude zpravidla méně než neznámých parametrů – prvků matice  $\Sigma$ .

<sup>2</sup> Z odvozování je patrné, že by totéž platilo i pro kovarianční matici obou těchto estimátorů.

## Odvození zobecněné metody nejmenších čtverců GLS

Uvažujme nejprve lineární regresní model ve tvaru

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

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

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

což znamená **B1\*) heteroskedasticita**

**B2\*) autokorelovanost náhodných složek**

Znormujeme-li matici  $\Sigma$  "průměrným rozptylem"  $\sigma^2$ , můžeme ji vyjádřit ve tvaru

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

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

Formálně zapsáno

$$\Sigma = \sigma^2 \cdot V = \sigma^2 \cdot \begin{bmatrix} \frac{\sigma_1^2}{\sigma^2} & \frac{\sigma_{12}}{\sigma^2} & \dots & \frac{\sigma_{1T}}{\sigma^2} \\ \frac{\sigma_{12}}{\sigma^2} & \frac{\sigma_2^2}{\sigma^2} & \dots & \frac{\sigma_{2T}}{\sigma^2} \\ \dots & \dots & \dots & \dots \\ \frac{\sigma_{1T}}{\sigma^2} & \frac{\sigma_{2T}}{\sigma^2} & \dots & \frac{\sigma_T^2}{\sigma^2} \end{bmatrix}$$

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

$$(2) \quad V = R^{-1} \cdot R'^{-1} \quad \text{neboli} \quad V^{-1} = (R^{-1} \cdot R'^{-1})^{-1} = R' \cdot R$$

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

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

$$(3a) \quad Ry = R \cdot X \cdot \beta + R \cdot \varepsilon \quad \text{neboli}$$

$$(3) \quad y^* = X^* \beta + \varepsilon^*$$

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

Určeme kovarianční matici náhodného vektoru transformovaných náhodných složek

$$(4) \quad E(\varepsilon^* \cdot \varepsilon^{*'}) = E(R \cdot \varepsilon \cdot \varepsilon' \cdot R') = R \cdot E(\varepsilon \cdot \varepsilon') \cdot R' = \sigma^2 R \cdot V \cdot R' = \sigma^2 \cdot I_T$$

(Podotkneme, že matice  $R$  byla volena právě s cílem dosáhnout diagonální kovarianční matice náhodných složek)

Ukážeme, že transformovaný model 3) má vlastnosti **standardního lineárního regresního modelu**. Náhodné složky  $\varepsilon^*$  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

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

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

Nyní ukážeme, jak lze takovou matici R sestavit:

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

$$(5) \quad V^{-1} A = A D$$

- matice  $A_{[TxT]}$  je matice, jejíž sloupce tvoří vlastní (charakteristické) vektory matice  $V^{-1}$ . Vlastní vektory mohou být zapsány při vhodné normalizaci v ortonormálním tvaru, takže pro sloupce matice  $A$  lze psát  $a_i \cdot a_j = 1$ ,  $a_i \cdot a_j = 0$  pro  $i \neq j$ . Proto tedy platí  $A A' = I_T$ .

- matice  $D$  rozměrů  $[TxT]$  je diagonální matice s diagonálou tvořenou vlastními (charakteristickými) čísly  $R^{-1}: \lambda^1, \lambda^2, \dots, \lambda^T$ . Pro matici  $V^{-1}$  lze psát (při násobení 5) maticí  $A'$  zprava):

$$(5a) \quad V^{-1} = A D A' = A D^{1/2} \cdot D^{1/2} \cdot A'$$

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

$$R = D^{1/2} \cdot A' \quad \square .$$

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

$$(6) \quad R' R = A D^{1/2} \cdot D^{1/2} A' = V^{-1}$$

Využijeme-li nyní odhadovou funkci *obyčejné metody nejmenších čtverců OLS* k odhadu parametrů modelu 3), 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

$$(7) \quad {}_{OLS} \beta^* = (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} y$$

Kovarianční matice příslušná této odhadové funkci má tvar

$$(8) \quad Cov(\beta^*) = \sigma^2 \cdot (X^{*'} X^*)^{-1} = \sigma^2 \cdot (X' V^{-1} X)^{-1} = (X' \Sigma^{-1} X)^{-1}$$

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  $\sigma^2$  získáme standardním způsobem:

$$(9) \quad s^2 = \frac{e^{*'}e^*}{T-k} = \frac{[y^* - X^*b] \cdot [y^* - X^*b]}{T-k} =$$

$$= \frac{[R \cdot y - R \cdot Xb] \cdot [R \cdot y - R \cdot Xb]}{T-k} = \frac{[y - Xb] \cdot R' R [y - Xb]}{T-k} = \frac{e' V^{-1} e}{T-k}$$

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

$$y^{*'}y^* = [X^*b + e^*]' [X^*b + e^*] = b' X' R' R Xb + e' R' R e = b' X' V^{-1} Xb + e' V^{-1} e$$

První člen představuje **vysvětlený**, druhý člen **nevysvětlený (též 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  $\Sigma$ ) vůbec snadné, neboť narážíme na nedostatek vstupní modelové informace. Matice  $\Sigma$  má až  $(T+1) \cdot T/2$  různých prvků, zatímco modelová informace obsažená v matici  $X$  sestává pouze z  $T \cdot k$  pozorovaných hodnot vysvětlujících proměnných. Při  $T=20$  bychom potřebovali odhadnout až 210 různých prvků matice  $\Sigma$ . Z tohoto důvodu se v reálných situacích zpravidla uplatňují jednodušší verze obecné GLS-metody, hlavně

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

Uvědomme si, že v případě:

- a) **standardního lineárního regresního modelu** (metodou OLS) můžeme využít k odhadu jediného parametru matice  $\Sigma$  (stejně velkého rozptylu náhodných složek) celkem  $T$  reziduálních hodnot  $e_t$ .
- b) **zobecněného lineárního regresního modelu postiženého toliko heteroskedasticitou** (metodou WLS) můžeme použít k odhadu  $T$  - parametrů matice  $\Sigma$  právě stejný počet  $T$  reziduálních hodnot  $e_t$ .
- c) **zobecněného lineárního regresního modelu v plné jeho obecnosti** (metodou GLS) můžeme použít k odhadu  $(T+1) \cdot T/2$  parametrů matice  $\Sigma$  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 vůči velikosti vysvětlované proměnné).<sup>1</sup>

**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.<sup>2</sup>

<sup>1</sup> Způsoby řešení tohoto problému budou podrobněji vyloženy v oddíle *Heteroskedasticita*

<sup>2</sup> Způsoby řešení tohoto problému budou podrobněji vyloženy v oddíle *Autokorelace*.

## 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  $\Sigma$  platí tedy jen

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

$$(10) \quad \Sigma = \begin{pmatrix} \sigma_1^2 & 0 & \dots & 0 \\ \dots & \sigma_2^2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \sigma_T^2 \end{pmatrix}$$

přičemž prvky hlavní diagonály matice  $\Sigma$  jsou obecně různé.<sup>1</sup>

Pro váženou metodu nejmenších čtverců platí v modelu zatíženém pouze heteroskedasticitou všechny vlastnosti zobecněné metody nejmenších čtverců. Odhadová funkce však bude mít jednodušší tvar, protože **prvky diagonály inverzní matice  $\Sigma^{-1}$  značené  $\sigma^{ii}$  mají tvar**

$$(11) \quad \sigma^{ii} = \frac{adj(\sigma_{ii})}{|\Sigma|} = \frac{\prod_{j=1, j \neq i}^T \sigma_{jj}}{\prod_{j=1}^T \sigma_{jj}} = \frac{1}{\sigma_{ii}}, \quad \sigma^{ij} = 0 \text{ pro } i \neq j$$

Matice  $\Sigma^{-1}$  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

$$X' \Sigma^{-1} X = \begin{pmatrix} \sum_{t=1}^T \sigma^{tt} x_{t1}^2 & \sum_{t=1}^T \sigma^{tt} x_{t1} x_{t2} & \dots & \sum_{t=1}^T \sigma^{tt} x_{t1} x_{tk} \\ \sum_{t=1}^T \sigma^{tt} x_{t2} x_{t1} & \sum_{t=1}^T \sigma^{tt} x_{t2}^2 & \dots & \sum_{t=1}^T \sigma^{tt} x_{t2} x_{tk} \\ \dots & \dots & \dots & \dots \\ \sum_{t=1}^T \sigma^{tt} x_{tk} x_{t1} & \sum_{t=1}^T \sigma^{tt} x_{tk} x_{t2} & \dots & \sum_{t=1}^T \sigma^{tt} x_{tk}^2 \end{pmatrix} \quad X' \Sigma^{-1} y = \begin{pmatrix} \sum_{t=1}^T \sigma^{tt} x_{t1} y_t \\ \sum_{t=1}^T \sigma^{tt} x_{t2} y_t \\ \dots \\ \sum_{t=1}^T \sigma^{tt} x_{tk} y_t \end{pmatrix}$$

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

$$(12) \quad {}_{WLS} \hat{\beta} = (X' \tilde{\Sigma}^{-1} X)^{-1} X' \tilde{\Sigma}^{-1} y.$$

<sup>1</sup> Diagonální prvky matice  $\Sigma$  (rozptyly) se značí buď  $\sigma_t^2$  nebo jen  $\sigma_{tt}$  (tj. bez druhé mocniny)

$$X' \tilde{\Sigma}^{-1} X = \begin{pmatrix} \sum_{t=1}^T s^{tt} x_{t1}^2 & \sum_{t=1}^T s^{tt} x_{t1} x_{t2} & \dots & \sum_{t=1}^T s^{tt} x_{t1} x_{tT} \\ \sum_{t=1}^T s^{tt} x_{t2} x_{t1} & \sum_{t=1}^T s^{tt} x_{t2}^2 & \dots & \sum_{t=1}^T s^{tt} x_{t2} x_{tT} \\ \dots & \dots & \dots & \dots \\ \sum_{t=1}^T s^{tt} x_{tT} x_{t1} & \sum_{t=1}^T s^{tt} x_{tT} x_{t2} & \dots & \sum_{t=1}^T s^{tt} x_{tT}^2 \end{pmatrix}, \quad X' \tilde{\Sigma}^{-1} y = \begin{pmatrix} \sum_{t=1}^T s^{tt} x_{t1} y_t \\ \sum_{t=1}^T s^{tt} x_{t2} y_t \\ \dots \\ \sum_{t=1}^T s^{tt} x_{tT} y_t \end{pmatrix}$$

Váhy v případě vážené metody nejmenších čtverců WLS bychom ovšem mohli stanovit i zcela subjektivně tak, že bychom užíli odhadovou funkci (12) s maticí  $\tilde{\Sigma}^*$  s prvky

$$(13) \quad \tilde{\Sigma}^* = \begin{pmatrix} w_1 & 0 & \dots & 0 \\ 0 & w_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & w_r \end{pmatrix}$$

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

$$(14) \quad y^* = \begin{pmatrix} y_1 / \sqrt{w_1} \\ y_2 / \sqrt{w_2} \\ \dots \\ y_T / \sqrt{w_T} \end{pmatrix}, \quad X^* = \begin{pmatrix} x_{11} / \sqrt{w_1} & x_{12} / \sqrt{w_1} & \dots & x_{1k} / \sqrt{w_1} \\ x_{21} / \sqrt{w_2} & x_{22} / \sqrt{w_2} & \dots & x_{2k} / \sqrt{w_2} \\ \dots & \dots & \dots & \dots \\ x_{T1} / \sqrt{w_T} & x_{T2} / \sqrt{w_T} & \dots & x_{Tk} / \sqrt{w_T} \end{pmatrix}$$

**Poznámka 1:** Měli bychom rozlišovat metodu WLS ze dvou hledisek. Jednak jde o matematický (technický postup, které podle příslušného algoritmu (12) umožňuje provedení výpočtu regresních koeficientů zobecněného lineárního modelu zatíženého jen heteroskedasticitou.

**Poznámka 2:** Avšak statistické vlastnosti metody WLS (konkrétně **vydatnost**) silně závisí na volbě vah. Čím blíže jsou váhy  $w_t$  blíže skutečným hodnotám směrodatných odchylek náhodných složek, tím bud odhad vydatnější. To na druhé straně znamená, že pokud bychom vzali váhy nepatřičné (např. bychom pozorování ve (14) směrodatnými odchylkami  $\sigma_t$  násobili (nikoliv dělili), mohli bychom dostat odhady parametrů ještě méně vydatné než při nasazení metody OLS.



## Pomocná tvrzení:

### Tvrzení 1. Převod symetrické matice na diagonální

Nechť  $A$  je symetrická matice. Potom existuje nesingulární matice  $B$  taková, že  $BAB'$  je diagonální matice, tj. matici  $A$  lze vyjádřit jako součin  $C \cdot \Delta \cdot C'$ , kde  $C$  je nesingulární matice a  $\Delta$  je diagonální matice.

#### Postup a důkaz tvrzení:

Uvažujme první diagonální prvek matice  $A$ . Je-li nenulový, uijeme ho jako pivotálního prvku a anulujeme všechny ostatní prvky prvního řádku a stejně tak i prvky prvního sloupce. Postup je ekvivalentní postupnému násobení matice  $A$  zprava a zleva elementárními maticemi; přitom matice, kterými se násobí zprava jsou transponované matice k těm, kterými se násobí zleva, protože  $A$  symetrická. Výsledná matice je také symetrická.

Stejně tak se postupuje s druhým diagonálním prvkem, první řádek a první sloupec upravené matice se v této další fázi nezmění. V postupu se pokračuje, dokud se při některém kroku nenarazí na nulový diagonální prvek. Jestliže jsou v příslušném řádku a sloupci samé nulové prvky, přejdeme k dalšímu diagonálnímu prvkem a postupujeme shodně jako dříve.

Jestliže řádek nebo sloupec s nulovým prvkem na diagonále obsahuje nenulové prvky, pak můžeme dosáhnout toho, že na diagonále bude nenulový prvek a pak se pokračuje jako dříve. I tento obrat je symetrickou operací, kterou lze vyjádřit jako násobení elementárními maticemi.

Na závěr důkazu položíme  $B$  rovno součinu elementárních matic, kterými jsme násobili matici  $A$  zleva a  $C = B^{-1}$ .

□ .