

## Normální standardní lineární regresní model

K dříve vysloveným předpokladům o veličinách standardního lineárního regresního modelu připojíme další předpoklad :

### 5. Normalita náhodných složek

*T-rozměrný vektor* náhodných složek  $\varepsilon = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_T)'$  má *T-rozměrné normální rozdělení* s nulovým vektorem středních hodnot a s diagonální kovarianční maticí, tzn.

$$\Sigma = \sigma^2 I_T, \quad \text{stručněji zapsáno} \quad \varepsilon \approx N(0; \sigma^2 I_T)$$

Jak známo, **sružená hustota *T-rozměrného normovaného normálního rozdělení*** má v případě nezávislých náhodných veličin  $\varepsilon = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_T)'$  tvar:

$$f(\varepsilon) = \frac{1}{(2\pi)^{T/2} \sigma^T} \exp\left(-\frac{\varepsilon' \varepsilon}{2\sigma^2}\right)$$

### Věta 2 (pro standardní normální lineární regresní model)

Za podmínek Věty 1 (**Gauss-Markovovy**) a dále za dodatečného předpokladu o *T-rozměrném rozdělení vektoru náhodných složek*  $\varepsilon \approx N(0; \sigma^2 I_T)$  lze ukázat, že :

**(2A) Odhadová funkce**  $OLS b = (X'X)^{-1} X'y$  **je také normálně rozdělena** s vektorem středních hodnot (rovným skut. parametrům)  $\beta$  a s kovarianční maticí  $\sigma^2 (X'X)^{-1}$ .

**(2B) Náhodná veličina**  $\frac{e'e}{\sigma^2}$  resp. (jinak zapsaná jako  $\frac{(n-k)s^2}{\sigma^2}$ ) **má  $\chi^2$ -rozdělení o  $(n-k)$  stupních volnosti.** Počet stupňů volnosti je určen rozdílem mezi počtem pozorování  $T$  a počtem vysvětlujících proměnných  $k$ .

**(2C) Náhodné veličiny**  $\frac{e'e}{\sigma^2}$  a  $OLS b - \beta$  **jsou vzájemně nezávislé.**

**(2D) Odhady vektoru parametrů  $\beta$  získané metodou nejmenších čtverců**  $OLS b$  **a metodou maximální věrohodnosti**  $ML b$  **jsou identické**, tj. platí  $OLS b = ML b$ .

Výše uvedená tvrzení postupně dokážeme:

**Tvrzení (2A) Odhadová funkce**  $OLS b = (X'X)^{-1} X'y$  **je normálně rozdělena s vektorem středních hodnot** (rovným skut. parametrům)  $\beta$  **a s kovarianční maticí**  $\sigma^2 (X'X)^{-1}$ .  $OLS b = (X'X)^{-1} X'y$

**Důkaz tvrzení (2A)** Odhadovou funkci  $b_{OLS}$  lze zřejmě vyjádřit ve tvaru

$$X' y = X' X \beta + \varepsilon' = \beta + X' \varepsilon, \text{ kde}$$

na pravé straně je nestochastické povahy pouze vektor náhodných složek  $\varepsilon$ . Odhadová funkce  $b_{OLS}$  je tedy lineární kombinací složek náhodného vektoru  $\varepsilon$ , přičemž tato lineární kombinace má nestochastické prvky (a je k ní přičten nestochastický vektor  $\beta$ ). Jak známo ze statistické teorie, **lineární kombinace složek náhodného vektoru se sdruženým normálním rozdělením má též sdružené normální rozdělení**. Zbývá určit střední hodnotu a kovarianční matici tohoto vektoru. Zřejmě platí:

$$E(b_{OLS}) = E(X' y) = E(\beta + X' \varepsilon) = \beta + E(X' \varepsilon) = \beta + X' E\varepsilon = \beta$$

neboť dle předpokladu (a)  $E\varepsilon = 0$ . Podobně

$$\begin{aligned} Cov(b_{OLS}) &= E[(b_{OLS} - \beta)(b_{OLS} - \beta)'] = E[X' \varepsilon \varepsilon' X] = X' E\varepsilon \varepsilon' X \\ &= X' \sigma_\varepsilon^2 I_T X = \sigma_\varepsilon^2 X' X. \quad \square \end{aligned}$$

**Poznámka** Kovarianční matice  $Cov(b_{OLS})$  není na rozdíl od kovarianční matice náhodných odchylek diagonální, složky vektoru  $b_{OLS}$  tedy zpravidla budou vzájemně z Korelovány. Rozptyl každé této složky je dán součinem  $\sigma_\varepsilon^2$  a prvku ležícího na  $j$ -tém místě hlavní diagonály matice  $X' X$  - tento prvek označíme v dalším textu jako  $V^{jj}$ .

**Tvrzení (2B) Náhodná veličina  $\frac{e'e}{\sigma^2}$  resp. (jinak zapsaná jako  $\frac{(y - \hat{y})^2}{\sigma^2}$ ) má  $\chi^2$ -rozdělení o  $(T - k)$  stupních volnosti. Počet stupňů volnosti je dán rozdílem mezi počtem pozorování  $T$  a počtem vysvětlujících proměnných  $k$ .**

**Důkaz tvrzení (2B)**

a) Víme, že skalární součin  $\varepsilon' \varepsilon$  představuje součet druhých mocnin  $T$  vzájemně nezávislých (tj. zde nekorelovaných a normálně rozdělených) náhodných veličin (jmenovitě náhodných složek regresní rovnice).

b) Dále víme, že analogický výraz  $e'e$  pro rezidua lze vyjádřit zápisem

$$e'e = M' M \varepsilon, \text{ kde } M = I_T - X(X' X)^{-1} X', \text{ neboť } e = M \cdot \varepsilon$$

c) Matice  $M$  je symetrická a idempotentní, neboť pro ni platí

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

Tedy  $e'e$  je kvadratická forma s hodnotami danou hodnotami matice  $M$ . Hodnota idempotentní matice je rovna její stopě. Stopa matice  $M$  je přitom rovna  $(T - k)$ .

Počet stupňů volnosti  $\chi^2$ -rozdělení veličiny  $e'e$  je určen velikostí stopy matice  $M$  (je tedy roven  $T - k$ ). Podle **Cochranovy věty** má výraz  $\varepsilon'M\varepsilon/\sigma^2$   $\chi^2$ -rozdělení s tolika stupni volnosti, jaká je hodnota matice  $M$  v kvadratické formě  $\varepsilon'M\varepsilon$ .

**(Poznámka:** Rozptylem  $\sigma^2$  dělíme proto, abychom získali součet  $T$  nezávislých náhodných veličin s rozdělením  $N(0,1)$ ). Samotné  $\varepsilon$  mají rozdělení  $N(0, \sigma^2)$ .

Zřejmě přitom platí

$$\text{Cov}(\varepsilon'M\varepsilon/\sigma^2) = T - k.$$

d) Konečně je snadné ukázat, že platí

$$\frac{e'e}{\sigma^2} = \frac{(T - k) s^2}{\sigma^2}$$

Výraz  $e'e$  představuje součet čtverců reziduí (obvykle značen  $SSE$ ).  $s^2$  je tzv. **reziduální rozptyl** (mj. nestranný odhad rozptylu náhodných složek), jehož tvar je právě

$$\frac{e'e}{T - k} = s^2 \quad \square.$$

**Tvrzení (2C) Náhodné veličiny**  $\frac{(T - k) s^2}{\sigma^2}$  a  $b_{OLS}$  jsou vzájemně nezávislé<sup>1</sup>.

**Důkaz tvrzení (2C)** Součet čtverců náhodných odchylek  $\varepsilon'e$  rozložíme následovně :

$$\varepsilon'e = \varepsilon'[I_T - X(X'X)^{-1}X']\varepsilon + \varepsilon'[X(X'X)^{-1}X']\varepsilon = \varepsilon'M\varepsilon + \varepsilon'N\varepsilon$$

**Poznámka** Matice  $M$  i  $N$  jsou idempotentní, s hodnotami  $h(M) = T - k$  a  $h(N) = k$ .

Podle **Cochranovy věty** mají náhodné veličiny – kvadratické formy  $P(\varepsilon), Q(\varepsilon)$  obsahující matice  $M$  i  $N$  tato rozdělení:

- kvadratická forma  $P(\varepsilon) = \varepsilon'M\varepsilon/\sigma^2$  má rozdělení  $\chi^2$  o  $T - k$  stupních volnosti
- kvadratická forma  $Q(\varepsilon) = \varepsilon'N\varepsilon/\sigma^2$  má rozdělení  $\chi^2$  o  $k$  stupních volnosti

Obě tyto náhodné veličiny jsou vzájemně nezávislé, neboť platí  $MN = 0$ .

(stochastická nezávislost je zde „posuzována“ algebraickou ortogonalitou matic  $M, N$ )

Dále, výrazy  $\varepsilon'M\varepsilon$  a  $\varepsilon'N\varepsilon$  lze rozepsat následovně :

$$\varepsilon'M\varepsilon = \varepsilon'[I_T - X(X'X)^{-1}X']\varepsilon = \varepsilon'M\varepsilon = \varepsilon'MM\varepsilon = \varepsilon'e = (T - k)s^2, \text{ kde } s^2 = \frac{e'e}{T - k}.$$

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

$$\text{neboť } b = \beta + (X'X)^{-1}X'\varepsilon, \text{ tzn. } b - \beta = (X'X)^{-1}X'\varepsilon$$

<sup>1</sup> Mějme na paměti, že  $\sigma^2 = \frac{e'e}{T - k}$  je nestochastická veličina, zatímco  $S^2 = \frac{e'e}{T - k}$  je náhodná veličina.

Dále, protože podle předpokladu je  $X'X$  (jako momentová matice) pozitivně definitní (a symetrická) matice, existuje **regulární** matice  $P$  rozměru  $[T, k]$  taková, že platí  $X'X = P'P$ . Proto lze psát

$$\varepsilon'N\varepsilon = (b - \beta)' X'X(b - \beta) = (b - \beta)' P'P(b - \beta) = [P(b - \beta)]'[P(b - \beta)]$$

Odtud plyne, že vektor  $P(b - \beta)$  a tedy též vektor  $(b - \beta)$  - protože matice  $P$  je nestochastická - nezávislý na skaláru  $s^2(T - 1)$  a též na  $s^2$  (je-li matice  $X$ , jak se předpokládá, nestochastická, pak je  $P$  rovněž nestochastická matice).  $\square$ .

**Tvrzení (2D)** Odhady vektoru parametrů  $\beta$  pořízené metodou nejmenších čtverců a metodou maximální věrohodnosti jsou identické.

**Důkaz tvrzení (2D)** Již jsme ukázali, že odhad  $\hat{\beta}$  pořízený metodou OLS má tvar

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

Zbývá tedy ukázat, že **odhad pořízený metodou maximální věrohodnosti má stejný tvar**. Při tomto ověření vyjdeme ze sdružené hustoty vektoru náhodných složek, která má tvar

$$f(\beta) = \frac{1}{(2\pi)^{T/2} \sigma^T} \exp\left(-\frac{\varepsilon'\varepsilon}{2\sigma^2}\right) \text{ pro } \varepsilon \approx N(0; \sigma^2 I_T)$$

Tato **sdružená hustota** je současně tzv. **věrohodnostní funkcí**, v jejímž zápisu se projevuje rozdíl v chápání pozic (odhadovaných) parametrů a pozorovaných veličin. Píšeme tedy

$$f(y, X; \beta, \sigma^2) = L(\beta, \sigma^2; y, X)$$

**Zápis sdružené hustoty**  $f(y, X; \beta, \sigma^2)$  (kde se pozorované hodnoty  $y, X$  uvádí před středníkem, zatímco parametry  $\beta, \sigma^2$  za ním) pohlíží na tvar (zde *normálního*) rozdělení jako na rozdělení náhodného vektoru s pevně danými (známými) určenými parametry  $\beta$  a  $\sigma^2$ . Na hodnoty  $y$  zde pohlížíme, jakoby byly „generovány mechanismem“, který se řídí rozdělením náhodných složek  $\varepsilon$  (při dané matici vysvětlujících proměnných  $X$ ).

**V zápise věrohodnostní funkce**  $L(\beta, \sigma^2; y, X)$  (kde oba tyto parametry uvádíme v zápise před středníkem) se naopak na hledané parametry pohlíží jako na neznámé, které odhadujeme ze známých pozorovaných veličin regresní rovnice (těmi jsou vektor  $y$  a matice  $X$ ).

Věrohodnostní funkci, jejíž maximum hledáme, zapíšeme ve tvaru, do něhož zahrneme pozorované veličiny (a přirozeně též vektor  $\beta$  a skalár  $\sigma$ ):

$$L(\beta, \sigma^2; y, X) = \frac{1}{(2\pi)^{T/2} \sigma^T} \exp\left(-\frac{(y - X\beta)'(y - X\beta)}{2\sigma^2}\right)$$

Maximalizaci této (nelineární) věrohodnostní funkce si zjednodušíme tak, že budeme (ekvivalentně uvažovat maximalizaci jejího logaritmu). Tato cesta nevede k žádnému zkreslení původní úlohy: logaritmus je spojitá rostoucí funkce, takže poloha původního maxima – ze statistického hlediska jde o **modus** – se po této transformaci nezmění):

$$\tilde{L}(\beta, \sigma^2; y, X) = nL(\beta, \sigma^2; y, X) = -\frac{T}{2} \cdot \ln(2\pi) - \frac{T}{2} \cdot \ln \sigma^2 - \frac{1}{2\sigma^2} (y - X\beta)'(y - X\beta)$$

Úkolem je maximalizovat  $\tilde{L}(\beta, \sigma^2; y, X)$  vzhledem k  $\beta$  a  $\sigma^2$ . Rovnocenným cílem je ale minimalizace kladně vzatého výrazu  $L^*(\beta, \sigma^2; y, X) = -\tilde{L}(\beta, \sigma^2; y, X)$  (neboť  $\sigma^T = \sigma^2)^{T/2}$ )

$$\text{Min}_{\sigma^2, \beta} \left[ \frac{T}{2} \cdot \ln(2\pi) + \frac{T}{2} \cdot \ln \sigma^2 + \frac{1}{2\sigma^2} (y - X\beta)'(y - X\beta) \right]$$

Při této minimalizaci postupně dostáváme (položením parc. derivací rovných 0):

$$(A1) \quad \frac{\partial L^*}{\partial \beta} = \frac{1}{2\sigma^2} \cdot (-X'y + X'X\beta) = 0$$

$$(B1) \quad \frac{\partial L^*}{\partial \sigma^2} = \frac{T}{2\sigma^2} - \frac{1}{2\sigma^4} (y - X\beta)'(y - X\beta) = 0$$

**Poznámka** Při derivování podle rozptylu  $\sigma$  zacházíme s touto veličinou jako s jediným (nedělitelným) symbolem. Proto např.  $(\sigma^{-1})' = -\sigma^{-2}$  nikoliv  $-\sigma^{-1}$

Řešením vztahu (A1) zřejmě dostaneme vektor odhadnutých parametrů ve tvaru

$${}_{ML}b = (X'X)^{-1} X'y$$

Následně nyní dosazením tohoto odhadu za  $\beta$  do vztahu (B1) obdržíme <sup>2</sup>

$$(B1^*) \quad \frac{\partial L^*}{\partial \sigma^2} = \frac{T}{2\sigma^2} - \frac{1}{2\sigma^4} (y - X(X'X)^{-1}X'y)'(y - X(X'X)^{-1}X'y) = 0$$

Po vynásobení dvojnásobkem rozptylu ( $2\sigma^2$ ) dostaneme zjednodušení:

$$T - \frac{1}{\sigma^2} e'e = 0, \text{ odkud plyne } e'e = \sigma^2 \cdot T \text{ a následně } {}_{ML}\hat{\sigma}^2 = \frac{e'e}{T}.$$

Odhad reziduálního rozptylu získaný metodou maximální věrohodnosti má tedy tvar

$${}_{ML}\hat{\sigma}^2 = \frac{e'e}{T} = \frac{SSE}{T}$$

<sup>2</sup> Tvaru, kdy po určení některého parametru (zde  $\beta$ ) dosadíme získanou hodnotu do původní věrohodnostní funkce, abychom mohli určit další parametry (zde  $\sigma^2$ ) se někdy říká *koncentrovaná věrohodnostní funkce*.

**Poznámka** Všimněme si, že k odhadu koeficientů  $_{ML} \beta$  jsme nepotřebovali operovat se  $\sigma$ , zatímco následný odhad  $_{ML} \hat{\sigma}^2$  byl již vázán na předtím pořízený odhad  $_{ML} \hat{\beta}$  (při jinak odhadnutém  $\beta$  bychom mohli získat obecně jiný odhad pro  $\sigma$ ).

Měli bychom ještě ukázat, že získaný výraz pro  $_{ML} \hat{\beta}$  dává skutečně minimum (nikoliv maximum nebo sedlový bod). To dokážeme, pokud druhý diferenciál vztahu pro  $L^*$  vede k matici, která je pozitivně definitní. Skutečně lze snadno ověřit, že

$$(B2) \quad \frac{\partial^2 L^*}{\partial \beta^2} = \frac{X'X}{\sigma^2} > 0$$

protože momentová matice  $X'X$  je sama (za přijatého předpokladu, že  $X$  má plnou hodnost  $k$ ) vždy pozitivně definitní.

K získání **Fisherovy informační matice** (čtvercové symetrické matice řádu  $k+1$ )<sup>3</sup> potřebujeme vypočítat derivace věrohodnostní funkce podle hledaných neznámých parametrů, tj. všech složek vektoru  $\beta$  a skaláru  $\sigma$ . Vyjdeme-li ze vztahů

$$(A1) \quad \frac{\partial L^*}{\partial \beta} = \frac{1}{2\sigma^2} \cdot (-X'y + X'X\beta) = 0$$

$$(B1) \quad \frac{\partial L^*}{\partial \sigma^2} = \frac{T}{2\sigma^2} - \frac{1}{2\sigma^4} \cdot (y - X\beta)'(y - X\beta) = 0$$

určíme potřebné druhé partiální derivace pro dosazení do matice

$$P = \begin{pmatrix} \frac{\partial^2 L^*(\beta, \sigma^2)}{\partial \beta \partial \beta} & \frac{\partial^2 L^*(\beta, \sigma^2)}{\partial \beta \partial \sigma^2} \\ \frac{\partial^2 L^*(\beta, \sigma^2)}{\partial \beta \partial \sigma^2} & \frac{\partial^2 L^*(\beta, \sigma^2)}{\partial \sigma^2 \partial \sigma^2} \end{pmatrix} = \begin{pmatrix} \frac{\partial^2 \tilde{L}(\beta, \sigma^2)}{\partial \beta \partial \beta} & \frac{\partial^2 \tilde{L}(\beta, \sigma^2)}{\partial \beta \partial \sigma^2} \\ \frac{\partial^2 \tilde{L}(\beta, \sigma^2)}{\partial \beta \partial \sigma^2} & \frac{\partial^2 \tilde{L}(\beta, \sigma^2)}{\partial \sigma^2 \partial \sigma^2} \end{pmatrix}$$

Výpočtem jednotlivých derivací dostáváme

$$(A2) \quad \frac{\partial L^*}{\partial \beta \partial \beta} = \frac{X'X}{\sigma^2}$$

$$(B2) \quad \frac{\partial^2 L^*}{\partial \sigma^2 \partial \sigma^2} = -\frac{T}{2\sigma^4} + \frac{2}{2\sigma^6} (y - X\beta)'(y - X\beta) = \frac{1}{\sigma^6} \varepsilon' \varepsilon - \frac{T}{2\sigma^4}$$

$$(AB2) \quad \frac{\partial^2 L^*}{\partial \beta \partial \sigma^2} = \frac{-X'X\beta - X'y}{\sigma^4} = \frac{X'\varepsilon}{\sigma^4} \quad (\text{a pro kontrolu})$$

$$(BA2) \quad \frac{\partial^2 L^*}{\partial \sigma^2 \partial \beta} = \frac{-X'X\beta - X'y}{2\sigma^4} = \frac{X'\varepsilon}{\sigma^4}$$

<sup>3</sup> Matice má takový řád, kolik je neznámých modelových parametrů, těch je právě  $k+1$ :  $k$  prvků vektoru  $\beta$  a jeden rozptyl  $\sigma^2$ .

Matrice  $P$  tedy nabude tvaru

$$P = \begin{pmatrix} \frac{X'X}{\sigma^2} & \frac{X'\varepsilon}{\sigma^4} \\ \frac{X'\varepsilon}{\sigma^4} & \frac{1}{\sigma^6} \varepsilon'\varepsilon - \frac{T}{2\sigma^4} \end{pmatrix} = \frac{1}{\sigma^2} \begin{pmatrix} X'X & \frac{X'\varepsilon}{\sigma^2} \\ \frac{X'\varepsilon}{\sigma^2} & \frac{1}{\sigma^2} \varepsilon'\varepsilon - \frac{T}{2\sigma^2} \end{pmatrix}$$

Uplatněním střední hodnoty na matici  $P$  dostaneme

$$EP = \begin{pmatrix} X'X & E \frac{X'\varepsilon}{\sigma^2} \\ E \frac{X'\varepsilon}{\sigma^2} & E \left( \frac{1}{\sigma^4} \varepsilon'\varepsilon - \frac{T}{2\sigma^2} \right) \end{pmatrix} = \frac{1}{\sigma^2} \begin{pmatrix} X'X & 0 \\ 0 & \frac{T}{2\sigma^2} \end{pmatrix}$$

protože  $E \frac{X'\varepsilon}{\sigma^2} = \frac{X'}{\sigma^2} E\varepsilon = 0$  s ohledem na nestochastičnost  $X'$  a centrovanost  $\varepsilon$  a

$$E \left( \frac{1}{\sigma^4} \varepsilon'\varepsilon - \frac{T}{2\sigma^2} \right) = \frac{E\varepsilon'\varepsilon}{\sigma^4} - \frac{T}{2\sigma^2} = \frac{T}{2\sigma^2}, \text{ protože } E\varepsilon'\varepsilon = T \cdot \sigma^2$$

Všimněme si, že tato matice je – s ohledem na pozitivní definitnost momentové matice  $X'X$  – rovněž *pozitivně definitní*. Tím jsme dokázali, že jde skutečně o minimum (námi záporně vzaté) resp. o maximum (původní) věrohodnostní funkce.

Nyní se můžeme přesvědčit, zda jde skutečně o nejlepší odhady, což zjistíme vyčíslením **Fisherovy informační matice**, jež je inverzní k matici  $P$ .

$$\begin{pmatrix} \frac{\partial L^{**}(\theta)}{\partial \theta'} \end{pmatrix} = \begin{pmatrix} \frac{X'X}{\sigma^2} & 0 \\ 0 & \frac{T}{2\sigma^4} \end{pmatrix}^{-1} = \begin{pmatrix} X'X & 0 \\ 0 & \frac{T}{2\sigma^2} \end{pmatrix}^{-1}$$

$\theta$  je užito z důvodu úsporného značení, v našem případě  $\theta = (\beta_1, \beta_2, \dots, \beta_k, \sigma^2)$ .

**Poznámka** (a současně definice)

Odhadová funkce  $\hat{\theta}$  se nazývá **MVB [minimum variance bound] estimátor**, jestliže je nestranná a jestliže její kovarianční matice má velikost danou jako

$$\text{Cov}V = - [P(\theta)]^{-1}, \quad \text{kde } P(\theta) = E \left[ \frac{\partial^2 \ln f(Z_t, \theta)}{\partial \theta \partial \theta'} \right]$$

kde  $f(Z_t, \theta)$  je sdružená hustota (resp. věrohodnostní funkce  $L(\theta, Z_t)$ ) rozdělení náhodného vektoru  $Z_t$  sdružujícího (v našem případě) pozorované hodnoty  $y_t, X_t$ <sup>4</sup>

<sup>4</sup> V našem případě jde o  $k+1$  složkový náhodný vektor.

Odtud můžeme určit kovarianční matici odhadové funkce  $\hat{\theta}$ .

$$\text{Cov}V = - [P(\theta)]^{-1} = - \left[ \frac{\partial \tilde{L}(\theta)}{\partial \theta'} \right]^{-1} = \begin{pmatrix} \frac{X'X}{\sigma^2} & 0 \\ 0 & \frac{T}{2\sigma^4} \end{pmatrix} = \begin{pmatrix} \frac{X'X}{T} & 0 \\ 0 & \frac{1}{2\sigma^2} \end{pmatrix}$$

Odtud je vidět, že dolní hranice velikosti asymptotické kovarianční matice vektoru  $\beta$

libovolného estimátoru je dána výrazem  $\text{Cov}(\hat{\beta}) \geq \sigma^2 \cdot \lim \left( \frac{X'X}{T} \right)$

To však přesně odpovídá tvaru asymptotické kovarianční matice  $\sqrt{T}(\hat{\beta} - \beta)$ .

Současně je vidět, že dolní hranice pro rozptyl  $\hat{\sigma}^2$  (získaná libovolným estimátorem) je dána jako

$$\text{var} \hat{\sigma}^2 = \sigma^4$$

**Poznámka** Mezi odhady reziduálního rozptylu pořizenými *metodou nejmenších čtverců a metodou maximální věrohodnosti* platí vztah :

$${}_{ML} \hat{\sigma}^2 = \frac{T - k}{T} {}_{OLS} \hat{\sigma}^2$$

**Poznámka** Z předchozího je vidět, že *odhad reziduálního rozptylu metodou maximální věrohodnosti není nestranný* (zůstává však – stejně jako odhad prostou metodou nemenších čtverců OLS – *konzistentní a asymptoticky nestranný*)

Obecněji, ne však zcela univerzálně lze říci, že zatímco *OLS-metody* inklinují z hlediska svých vlastností k *nestranným* odhadům (které jsou vydatné jen za velmi vzácných okolností), pak *ML-techniky* poskytují odhady *vydatné* (obvykle na samé mezi možností daných **Cramér-Raovou dolní hranicí**), avšak *nestrannost* je vlastností, kterou od nich obvykle nelze očekávat. Ve víceroznicových regresních modelech ovšem ani simultánní OLS-odhadové techniky neposkytují nestranné odhady (opět nepočítaje výjimky), takže tam dvěma aspoň požadovanými statistickými vlastnostmi zůstává jen *konzistence a asymptotická normalita*).