

## 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, sdružená hustota *T-rozměrného normovaného normálního rozdělení* má v případě nezávislých náhodných veličin 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  $\frac{(T-k)s^2}{\sigma^2}$ ) má  $\chi^2$ -rozdělení o  $(T-k)$  stupních volnosti. Počet stupňů volnosti je určen rozdílem mezi počtem pozorování  $T$  a počtem vysvětlujících proměnných  $k$ .

**(2C)** Náhodné veličiny  $\frac{(T-k)s^2}{\sigma^2}$  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

$$(X'X)^{-1} X' y = (X'X)^{-1} X'(X\beta + \varepsilon) = \beta + (X'X)^{-1} X' \varepsilon, \text{ kde}$$

na pravé straně je nestochastické povahy pouze vektor náhodných složek  $\varepsilon$ . Odhadová funkce  $_{OLS}b$  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 *sdrúženým* normálním rozdělením má též *sdrúžené* normální rozdělení. Zbývá určit střední hodnotu a kovarianční matici tohoto vektoru. Zřejmě platí :

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

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

$$\begin{aligned} Cov(_{OLS}b) &= E[(b - \beta) \cdot (b - \beta)'] = E[(X'X)^{-1} X' \varepsilon \varepsilon' X (X'X)^{-1}] = (X'X)^{-1} X' E\varepsilon \varepsilon' X (X'X)^{-1} \\ &= (X'X)^{-1} X' \sigma_{\varepsilon}^2 I_T X \cdot (X'X)^{-1} = \sigma_{\varepsilon}^2 (X'X)^{-1}. \quad \square. \end{aligned}$$

**Poznámka** Kovarianční matice  $Cov(_{OLS}b)$  není na rozdíl od kovarianční matice náhodných odchylek diagonální, složky vektoru  $_{OLS}b$  tedy zpravidla budou vzájemně zkorelovány. Rozptyl každé této složky je dán součinem  $\sigma_{\varepsilon}^2$  a prvku ležícího na  $j$ -tém místě hlavní diagonály matice  $(X'X)^{-1}$  - tento prvek označíme v dalším textu jako  $V^{jj}$ .

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

**Důkaz tvrzení (2B)**

a) Víme, že skalární součin  $\varepsilon' \varepsilon$  tvoří 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

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

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 stopou 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  $\varepsilon' M \varepsilon$ . ( Rozptylem  $\sigma^2$  dělíme proto, abychom získali součet  $T$  nezávislých náhodných veličin s rozdělením  $N(0,1)$ ).

Zřejmě přitom platí

$$\text{Cov}(\varepsilon' M \varepsilon / \sigma^2) = I_T.$$

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  $OLS b - \beta$  jsou vzájemně nezávislé.

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

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

**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  $M \cdot N = 0$ .

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

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

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

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

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

Dále, protože podle předpokladu je  $X'X$  (jako momentová matice) pozitivně definitní (a symetrická) matice, existuje **regulární** matice  $P$  rozměru  $[k, k]$  taková, že platí  $X'X = P.P'$ . Proto lze psát

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

Odtud plyne, že vektor  $P'(b - \beta)$  a tedy též vektor  $(b - \beta)$  - protože matice  $P$  je nestochastická - nezávislý na skaláru  $s^2(T - k)$  a též na  $s^2$  (o matici  $P$  totiž předpokládáme, že to je 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

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

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

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

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  $\sigma^2$ ):

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

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):

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

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):

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

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

**Poznámka** Při derivování podle rozptylu  $\sigma^2$  zacházíme s touto veličinou jako s jediným (nedělitelným) symbolem. Proto např.  $(\sigma^{-2})' = -\sigma^{-4}$  nikoliv  $-2\sigma^{-3}$

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>1</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:

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

Odhad reziduálního rozptylu získaný metodou maximální věrohodnosti má tedy tvar

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

<sup>1</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  $\sigma^2$ , zatímco následný odhad  ${}_{ML}\hat{\sigma}^2$  byl již vázán na předtím pořízený odhad  ${}_{ML}\beta$  (při jinak odhadnutém  $\beta$  bychom mohli získat obecně jiný odhad pro  $\sigma^2$ ).

Měli bychom ještě ukázat, že získaný výraz pro  ${}_{ML}\beta$  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 hodnotu  $k$ ) vždy pozitivně definitní.

K získání **Fisherovy informační matice** (čtvercové symetrické matice řádu  $k+1$ ) potřebujeme vypočítat derivace věrohodnostní funkce podle hledaných neznámých parametrů, tj. všech složek vektoru  $\beta$  a skaláru  $\sigma^2$ . Vyjdeme-li ze vztahů

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

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

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

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

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

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

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

Matice  $P$  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  $P$  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  $P$ .

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

$\theta$  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

$$\text{Cov}V = -[T \cdot P(\theta)]^{-1}, \quad \text{kde } P(\theta) = E\left[\frac{\partial^2 \ln f(Z_t, \theta)}{\partial\theta\partial\theta'}\right]$$

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  $y_t, X_t^2$

<sup>2</sup> V našem případě jde o k+1 složkový náhodný vektor.

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

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

Odtud je vidět, že dolní hranice velikosti asymptotické kovarianční matice vektoru  $\beta$  libovolného estimátoru je dána výrazem  $Cov(\hat{\beta}) = \sigma^2 \cdot \lim \left( \frac{X'X}{T} \right)^{-1}$

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

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

**Poznámka** Mezi odhady reziduálního rozptylu pořízenými *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).