

## 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 také 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 navíc obsahuje nestochastický vektor  $\beta$ ). Jak známo ze statistické teorie, lineární kombinace složek náhodného vektoru s normálním rozdělením má též normální rozdělení. Zbývá určit střední hodnotu a kovarianční matici tohoto vektoru. Zřejmě platí:

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

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  $e'e$  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

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

**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 (též značen  $SSE$ ) .  $s^2$  je 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  $h(N) = k$ .

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

$P(\varepsilon) = \varepsilon'M\varepsilon/\sigma^2$  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  $M.N = 0$  ( stochastická nezávislost je takto „posuzována“ ortogonalitou matic  $M, N$  )

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

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

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  $X'X = P.P'$ . Pak 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  $P$  totiž předpokládáme, že je nestochastická matice).  $\square$ .

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

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

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

Zbývá tedy ukázat, že odhad pořizený 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  $X$ ).

Věřohodnostní funkci, jejíž maximum hledáme, zapíšeme ve tvaru, do něhož zahrneme pozorované veličiny (a přirozeně též vektor  $\beta$  a skalár  $\sigma^2$ ):

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

Přímá maximalizace této (nelineární) věrohodnostní funkce je komplikovaná. Proto ji ekvivalentně maximalizujeme v logaritmovaném tvaru (logaritmus je spojitá rostoucí funkce, takže poloha původního maxima – ze statistického hlediska jde o modus – se po této transformaci nezmění):

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

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

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

Při této minimalizaci postupně dostáváme :

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

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

**Poznámka** Při derivování podle rozptylu  $\sigma^2$  zacházíme s touto veličinou jako s jediným (nedělitelným) symbolem

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

<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*.

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

**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 hodnot  $k$ ) 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  $\sigma^2$ . Vydeme-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 parciální 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

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

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  $y_t, X_t^2$

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

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

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

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

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

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

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