

## Standardní (též klasický) lineární regresní model

**Specifikace=formulace (jednorovnicového) lineárního regresního modelu**

$$(1) \quad y = X\beta + \varepsilon \quad \text{resp.} \quad y_t = \sum_{j=1}^k X_{tj}\beta_j + \varepsilon_t \quad , \text{ kde}$$

$y$  je T-členný (sloupcový) vektor pozorování závisle (vysvětlující) proměnné (*regresandu*)

$X$  je [ T x k ] matice pozorování k nezávisle proměnných (*regresorů*) – tzv. *matice plánu*

$\beta$  je k-členný (sloupcový) vektor neznámých regresních koeficientů

$\varepsilon$  je T-členný (sloupcový) vektor nepozorovatelných náhodných složek (*disturbancí*)

**Ve strukturním vektorově- maticovém vyjádření**

$$(1A) \quad \begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ \dots \\ y_T \end{pmatrix} = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1k} \\ x_{21} & x_{22} & \dots & x_{2k} \\ x_{31} & x_{32} & \dots & \dots \\ \dots & \dots & \dots & \dots \\ x_{T1} & x_{T2} & \dots & x_{Tk} \end{pmatrix} \cdot \begin{pmatrix} \beta_1 \\ \beta_2 \\ \dots \\ \beta_k \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \dots \\ \varepsilon_T \end{pmatrix}$$

**Poznámka:** Pokud je v rovnici zastoupena úroňová konstanta  $\beta_1$ , pak k ní příslušný jedničkový vektor  $l = (1, 1, \dots, 1)'$  bude obvykle obsažen v prvním sloupci matice  $X$ , tzn. že bude platit  $x_{t1} = 1$  pro všechna  $t = 1, 2, \dots, T$ .

Předpokládáme, že **počet vysvětlujících proměnných je menší** (v krajním případě roven) **než počet pozorování**, tedy, že platí nerovnost  $k < T$

**Odhady parametrů** nějakou vhodnou odhadovou metodou (např. **metodou nejmenších čtverců**)

$$(2) \quad b = \hat{\beta}(y, X) \quad \text{např.} \quad \hat{\beta} = (X'X)^{-1}(X'y)$$

**Definice vyrovnaných hodnot závisle proměnné**

$$(3) \quad \hat{y} = Xb \quad y_t = \sum_{j=1}^k X_{tj}b_j$$

**Definice reziduí** (odhadnutých náhodných složek)

$$(4) \quad e = \hat{\varepsilon} = y - \hat{y} \quad \text{neboli} \quad y = \hat{y} + e$$

odtud vyplývá možnost **alternativního zápisu závisle proměnné** (s odhady parametrů a s reziduy)

$$(5) \quad y = Xb + e$$

## Některé další vztahy mezi veličinami lineárního regresního modelu

Z porovnání (1) a (5) obdržíme vztah mezi  $\varepsilon$  a  $e = \hat{\varepsilon}$ :

$$(6) \quad X\beta + \varepsilon = Xb + e^1$$

(pokud použijeme odhad OLS, pak pravá strana  $= X(X'X)^{-1} X'y + e$ ),  
z čehož dále plyne

$$(7) \quad e = y - Xb = y - X(X'X)^{-1} X'y = [I_T - X(X'X)^{-1} X']y = My$$

$$(8) \quad \text{neboli platí } \hat{\varepsilon} = My$$

(9)

$$\begin{aligned} e = y - Xb &= X\beta + \varepsilon - Xb = X\beta + \varepsilon - X(X'X)^{-1} X'y = X\beta + \varepsilon - X(X'X)^{-1} X'[X\beta + \varepsilon] = \\ &= X\beta + \varepsilon - X\beta - [X(X'X)^{-1} X']\varepsilon = [I - X(X'X)^{-1} X']\varepsilon = M\varepsilon^2 \end{aligned}$$

$$(10) \quad \text{neboli platí } e = M\varepsilon$$

### Varovná poznámka:

Ze vztahů  $e = My$  a  $e = M\varepsilon$  nelze usuzovat, že platí  $y = \varepsilon$ , neboť  $M$  je vždy singulární matice. Nelze proto psát  $y = M^{-1} \varepsilon$ , resp.  $e = M^{-1} \varepsilon$ , protože matice  $M^{-1}$  neexistuje.

Hodnost matice  $M = I_T - X(X'X)^{-1} X'$  je  $T - k < T$

$$\text{protože} \quad h(I_T) = T \quad h\left(X(X'X)^{-1} X'\right) = h\left(X'X (X'X)^{-1}\right) = k$$

Na výše uvedené zjištění můžeme pohlížet také z toho hlediska, že k určení vektoru reziduí  $e$  je skrze matici  $M$  „vytahována“ stejná informace jako z vektoru závisle proměnné. Matice  $M$  jakoby „odfiltruje“ „přebytečnou“ informaci (potřebnou pro určení  $e$ ) nacházející se v  $y$ , ale nikoliv v  $\varepsilon$ .

### Poznámka:

Centrování náhodných složek se přenáší na rezidua, která mají rovněž nulovou střední hodnotu, neboť

$$(11) \quad E(e) = E(M\varepsilon) = E\left(I_T - X(X'X)^{-1} X'\right)\varepsilon = \left(I_T - X(X'X)^{-1} X'\right)E(\varepsilon) = 0.$$

dle (10) nestochastičnost M centrování  $\varepsilon$

<sup>1</sup> Na levé straně (6) máme dvě nepozorovatelné veličiny:  $\beta, \varepsilon$ , zatímco na pravé straně jsou jak odhadnuté parametry  $b$ , tak rezidua  $e$ , obojí určené z pozorovaných proměnných: Je ovšem třeba dodat, že výpočet  $b$  (a následně i  $e$ ) obecně závisí na užitých odhadových metodách. U standardního lineárního modelu regresního i jiné odhadové metody vedou k témuž výrazu, avšak u složitějších modelů tomu ale tak nemusí být.

<sup>2</sup> Poznamenejme, že vzorce (7) a (9) platí pouze tehdy, odhadujeme-li parametry modelu metodou OLS.

## Vlastnosti proměnných lineárního regresního modelu

### 1. Centrovanost náhodných složek

$$(12) \quad E \varepsilon = 0 \quad \text{neboli} \quad E \varepsilon_t = 0 \quad \text{pro všechna } t = 1, 2, \dots, T$$

**nebude-li splněno, pak** střední hodnota náhodných složek (ani reziduí) nebude nulová a regresní přímka nepovede „středem“ oblasti pozorovaných hodnot, ale nad či pod ní (nepůjde o regresní přímku ve vlastním slova smyslu). Odchytky nebudou „nestranné“ a součet reziduí nebude roven 0.

### 2. Diagonalita kovarianční matice náhodných složek

$$(13) \quad \text{Var}(\varepsilon) = \text{Cov}(\varepsilon, \varepsilon') = \sigma^2 \cdot I_T \quad (\text{diagonální matice se stopou } T \cdot \sigma^2)$$

což v sobě obsahuje dvě vlastnosti, jimiž jsou

#### 2a) homoskedasticita náhodných složek

$$(13A) \quad \text{var } \varepsilon_t = \sigma^2 \quad (\text{rozptyl nezávislý na indexu pozorování})$$

**nebude-li splněno, pak** budou mít náhodné složky v různých pozorováních různý rozptyl a metoda OLS ztratí svou vydatnost (byť odhady zůstanou nestranné). Nejde však o fatální problém a parametry modelu budou odhadnutelné. Různost rozptylů náhodných složek v různých pozorováních se nazývá *heteroskedasticita*. Ta je odstranitelná nebo zmírnitelná některými speciálními postupy, např. použitím vážené metody nejmenších čtverců WLS.

#### 2b) nekorelovanost náhodných složek

$$(13B) \quad \text{Cov}(\varepsilon_s, \varepsilon_t) = E(\varepsilon_s \cdot \varepsilon_t) = \delta_{st} \cdot \sigma^2, \quad \text{kde } \delta_{st} = 1 \quad \text{pro } s = t \quad \text{a také } \delta_{st} = 0 \quad \text{pro } s \neq t$$

**nebude-li splněno, pak** budou náhodné složky v různých pozorováních vzájemně korelované a odhady parametrů nebudou vydatné (byť zůstanou nestranné). K zajištění optimálních vlastností bude nutno uplatnit *zobecněnou metodu nejmenších čtverců GLS* (pokud budou dodatečné informace o modelu) nebo problém zmírnit některou speciální technikou připouštějící autokorelaci náhodných složek.

### 3. Nekorelovanost náhodných složek s nezávisle proměnnými

$$(14) \quad E(X' \cdot \varepsilon) = 0 \quad \text{neboli} \quad E(x_{tj} \cdot \varepsilon_t) = 0 \quad \text{pro všechna } j = 1, 2, \dots, k$$

**nebude-li splněno, pak** to znamená, že informace obsažená v náhodných složkách má něco společného s informací obsaženou v některé vysvětlované proměnné a že „náhodná složka“ má v sobě kousek (nebo víc) systematické, nenáhodné informace. To je v rozporu s přijatým charakterem *náhodné* složky. Odhad parametrů nebude možno takto nijak statisticky získat (ani jinou metodou než OLS)

### 4. Plná hodnost matice vysvětlujících proměnných

$$(15) \quad h(X) = k$$

**nebude-li splněno, pak** bude mít matice  $X$  hodnost menší než  $k$ , což bude znamenat, že některé její sloupce budou lineárně závislé. Jinými slovy: informace obsažená v některých sloupcích matice  $X$  je „redundantní“ a některý z nich by mohl být beztržně vynechán. Z algebraického hlediska to má za následek to, že matice  $X'X$  bude singularní (její determinant bude nulový) a nebude k ní existovat (jednoznačně určená) inverzní matice. Odhad parametrů (metodou OLS) takto nebude možné určit, resp. při užití pseudoinverze nebude odhad určen jednoznačně. Požadavek znamená, aby každá z vysvětlujících proměnných nesla v sobě „aspoň kousek“ informace neobsažené v jiných vysvětlujících proměnných.

**Poznámka:** Tento požadavek nezaměňujeme s daleko přísnější podmínkou tzv. **ortogonalita** vysvětlujících proměnných vyjádřené zápisem  $x_{ti} \cdot x_{tj} = 0, i, j = 1, 2, \dots, k$ , která by znamenala navíc to, že kterákoliv z vysvětlujících proměnných nemá v sobě „ani kousek“ informace obsažené v jiné vysvětlující proměnné.

### (prostá, obyčejná) Metoda nejmenších čtverců (MNČ, OLS)

[ Ordinary least squares method ]

**Minimalizačním kritériem je zde součet čtverců reziduí (odhadnutých náhodných složek neboli rozdílů mezi pozorovanými a vyrovnanými hodnotami) :**

$$(16) \quad \text{Min } e'e = \text{Min}(y - Xb)'(y - Xb) \text{ neboli v pozorovaných hodnotách}$$

$$\text{Min } \sum_{t=1}^T e_t^2 = \text{Min} \sum_{t=1}^T (y_t - \hat{y}_t)^2 = \text{Min} \sum_{t=1}^T \left( y_t - \sum_{j=1}^K x_{tj} b_j \right) \left( y_t - \sum_{k=1}^K x_{tk} b_k \right)$$

**Polohu minima** (tj. k-rozměrného bodu=odhadnutého vektoru parametrů  $b$ ), ve kterém je minimalizovaný výraz nejmenší) **nalezneme řešením soustavy tzv. normálních rovnic**

$$\frac{\partial e'e}{\partial b} = \frac{\partial (y - Xb)'(y - Xb)}{\partial b} = -2X'y + 2X'Xb = 0 \quad (\text{vektorově}).$$

tuto soustavu řešíme úpravami (vydělením 2, přeskupením členů) **na tvar**  $X'Xb = X'y$ , která má řešení pro  $b$  ve tvaru

$$(17) \quad b = (X'X)^{-1} X'y, \leftarrow \text{řešení je jednoznačné, neboť vzhledem k předpokladů } h(X) = k, \text{ existuje (jediná) inverzní matice k matici } X'X.$$

**Poznámka** Vyjádření minimalizace v pozorovaných hodnotách:

$$H(y, X, b) = \sum_{t=1}^T \left( y_t - \sum_{i=1}^k x_{ti} b_i \right) \left( y_t - \sum_{i=1}^k x_{ti} b_i \right) = \sum_{t=1}^T y_t^2 - \sum_{t=1}^T y_t \left( \sum_{i=1}^k x_{ti} b_i \right) - \sum_{t=1}^T y_t \left( \sum_{i=1}^k x_{ti} b_i \right) + \sum_{t=1}^T \left( \sum_{i=1}^k x_{ti} b_i \right) \left( \sum_{i=1}^k x_{ti} b_i \right)$$

Derivací podle (kterékoliv) pevně zvolené složky vektoru parametrů  $b_j$  dostaneme<sup>3</sup>

$$(18) \quad \frac{\partial H(y, X, b)}{\partial b_j} = 0 - 2 \sum_{t=1}^T x_{tj} y_t + 2 \sum_{t=1}^T \sum_{j=1}^k x_{ti} x_{tj} b_j = 0 \text{ pro } j, i = 1, 2, \dots, k$$

$$- 2X'y \quad + 2X'Xb$$

a odtud

$$(19) \quad \sum_{t=1}^T \sum_{i=1}^k x_{ti} x_{tj} b_j = \sum_{t=1}^T x_{tj} y_t \text{ neboli } b_j = \left( \sum_{t=1}^T \sum_{i=1}^k x_{ti} x_{tj} \right)^{-1} \sum_{t=1}^T x_{tj} y_t, \quad j = 1, 2, \dots, k$$

V případě konečných sumací můžeme přeskupovat členy v součtech

---

<sup>3</sup> Zřejmě  $\frac{\partial \left( \sum_{i=1}^k x_{ti} b_i \right)}{\partial b_j} = x_{tj}$  a podobně  $\frac{\partial \sum_{t=1}^T \left( \sum_{i=1}^k x_{ti} b_i \right) \left( \sum_{i=1}^k x_{ti} b_i \right)}{\partial b_j} = 2 \sum_{t=1}^T \sum_{i=1}^k x_{ti} x_{tj} b_j$

**Příklad: Lineární regrese s jedinou vysvětlující proměnnou (+úrovňovou konstantou) ( $x_{t1} = 1$ )**

$$\begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} = \begin{pmatrix} T & \sum x_{t2} \\ \sum x_{t2} & \sum x_{t2}^2 \end{pmatrix}^{-1} \begin{pmatrix} \sum y_t \\ \sum x_{t2} y_t \end{pmatrix} = \frac{1}{D} \begin{pmatrix} \sum x_{t2}^2 & -\sum x_{t2} \\ -\sum x_{t2} & T \end{pmatrix} \begin{pmatrix} \sum y_t \\ \sum x_{t2} y_t \end{pmatrix}, \text{ kde}$$

$$D = \begin{vmatrix} T & \sum x_{t2} \\ \sum x_{t2} & \sum x_{t2}^2 \end{vmatrix} = T \cdot \sum x_{t2}^2 - (\sum x_{t2})^2. \text{ Odtud máme}$$

$$(20) \quad \hat{\beta}_1 = \frac{(\sum x_{t2}^2)(\sum y_t) - (\sum x_{t2})(\sum x_{t2} y_t)}{T \cdot \sum x_{t2}^2 - (\sum x_{t2})^2} \quad \hat{\beta}_2 = \frac{T \cdot (\sum x_{t2} y_t) - (\sum x_{t2})(\sum y_t)}{T \cdot \sum x_{t2}^2 - (\sum x_{t2})^2}$$

hodnota úrovnňové konstanty hodnota parametru sklonu regresní přímky

### Vlastnosti obyčejné (prosté) metody nejmenších čtverců MNČ (OLS) v klasickém lineárním regresním modelu

poskytuje odhad  $_{OLS} \hat{\beta}$  regresních koeficientů  $\beta$  ve tvaru  $_{OLS} \hat{\beta} = (X'X)^{-1} X'y$

**Věta 1 (Gauss-Markovova)** Odhad regresních koeficientů  $_{OLS} \hat{\beta}$  pořízený obyčejnou (prostou) metodou nejmenších čtverců je nejlepším nestranným lineárním odhadem vektoru parametrů  $\beta$ .

**Důkaz** rozdělíme jej na několik částí.

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

**Ověření nestrannosti:**

$$\begin{aligned} E(\hat{\beta}) &= E(X'X)^{-1} X'y = E(X'X)^{-1} X'(X\beta + \varepsilon) = E(X'X)^{-1} X'X\beta + E(X'X)^{-1} X'\varepsilon = \\ &\quad \text{vyjádření } y=X\beta+\varepsilon \\ &= (X'X)^{-1} X'XE\beta + (X'X)^{-1} X'E\varepsilon = E\beta + (X'X)^{-1} X'0 = \beta + 0 = \beta \quad \square. \\ &\quad \text{nestochastičnost } X \quad E\varepsilon=0 \quad E\beta=\beta \text{ ( } \beta \text{ nestochastický vektor )} \end{aligned}$$

**Důsledek A** Nestranná odhadová funkce je vždy asymptoticky nestranná.

Platí-li totiž  $E({}_{(T)} \hat{\beta}) = \beta$ <sup>4</sup> pro každé konečné  $T$ , platí tentýž vztah i pro  $T \rightarrow \infty$ .

**B. odhad  $_{OLS} \hat{\beta}$  je konzistentní**, tj. platí  $\underset{T \rightarrow \infty}{plim} \hat{\beta} = \beta$

Vlastnost platí i pro případ, že matice  $X$  je stochastická.

**Ověření konzistence:** lze vyvodit z následujícího tvrzení

**Tvrzení** Jestliže je odhadová funkce asymptoticky nestranná a kovarianční matice této odhadové funkce konverguje při  $T \rightarrow \infty$  k nulové matici, pak je tato odhadová funkce konzistentní.

**Důkaz** a) asymptotická nestrannost OLS-odhadové funkce vyplývá z *důsledku A*.

b) konvergenci kovarianční matice OLS-odhadové funkce (její tvar viz ad D) k nulové matici ukážeme následovně

<sup>4</sup> Symbolem nalevo rozumíme střední hodnotu odhadnutého vektoru parametrů  $\beta$  spočteného na základě  $T$  pozorování.

Dále ukážeme, že  $Cov(\hat{\beta}) = \sigma_\varepsilon^2 (X'X)^{-1}$ . Definujme matici  $P = (X'X)/T$  a její  $ij$ -tý prvek označíme jako  $P_{ij}$ .<sup>5</sup> Pro tento prvek platí

$$|P_{ij}| = \left| \frac{1}{T} \cdot \sum_{t=1}^T x_{ti} \cdot x_{tj} \right| \leq \xi_{ij}^2, \text{ přičemž tato rovnost platí pro všechna konečná } T.$$

Všechny prvky této matice jsou tedy (v absolutní hodnotě) shora omezeny hodnotou  $\xi^2 = \max \xi_{ij}^2$ . Tedy, pro všechna  $T$  má matice  $P$  konečně velké prvky a je nesingulární. Zřejmě dále platí

$$(X'X)^{-1} = P^{-1} / T \quad (\text{neboť platí } X'X = T \cdot P)$$

a navíc matice  $P^{-1}$  má konečně velké prvky ( $\pi_{ij}$ ) pro všechna  $T$ . Platí tedy

$$p \lim_{T \rightarrow \infty} Cov(OLS\hat{\beta}) = p \lim_{T \rightarrow \infty} \sigma_\varepsilon^2 (X'X)^{-1} = \sigma_\varepsilon^2 p \lim_{T \rightarrow \infty} P^{-1} / T = 0_k,$$

kde  $0_k$  je (čtvercová) matice řádu  $k$  složená ze samých nul.

**C. odhad  $OLS\hat{\beta}$  je lineární** (vzhledem k vysvětlované proměnné  $y$ ), neboť je definován jako lineární forma pozorování závisle proměnné  $y$ .

**Ověření linearity** Lze psát  $\hat{\beta} = (X'X)^{-1} X'y = C'y$ , kde matice  $C' = (X'X)^{-1} X'$  představuje koeficienty lineární formy, jejíž proměnné tvoří složky vektoru  $y$ .

Poznamenejme, že vždy platí  $C'X = (X'X)^{-1} X'X = I_k$ , kde  $I_k$  je jednotková matice řádu  $k$ .

**D. kovarianční matice** příslušná odhadové funkci  $\hat{\beta} = (X'X)^{-1} X'y$  má následující tvar

$$Cov(\hat{\beta}) = \sigma_\varepsilon^2 \cdot (X'X)^{-1}$$

**Ověření**  $Cov(\hat{\beta}) = E\left\{ \hat{\beta} - E(\hat{\beta}) \right\} \left\{ \hat{\beta} - E(\hat{\beta}) \right\}' = E\left\{ \hat{\beta} - \beta \right\} \left\{ \hat{\beta} - \beta \right\}' =$

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

$$= E\left\{ (X'X)^{-1} X'y - \beta \right\} \left\{ (X'X)^{-1} X'y - \beta \right\}' = E\left\{ (X'X)^{-1} X'(X\beta + \varepsilon) - \beta \right\} \left\{ (X'X)^{-1} X'(X\beta + \varepsilon) - \beta \right\}' =$$

$$E\left\{ \beta + (X'X)^{-1} X'\varepsilon - \beta \right\} \left\{ \beta + (X'X)^{-1} X'\varepsilon - \beta \right\}' = E\left\{ (X'X)^{-1} X'\varepsilon \right\} \left\{ (X'X)^{-1} X'\varepsilon \right\}' =$$

$$= E\left[ (X'X)^{-1} X' \varepsilon \varepsilon' X \cdot (X'X)^{-1} \right] = (X'X)^{-1} X' E\varepsilon \varepsilon' X \cdot (X'X)^{-1} =$$

$$= (X'X)^{-1} X' \sigma_\varepsilon^2 I_T X \cdot (X'X)^{-1} = \sigma_\varepsilon^2 (X'X)^{-1} X'X \cdot (X'X)^{-1} = \sigma_\varepsilon^2 (X'X)^{-1} \quad \square.$$

Odtud plyne **důsledek D1**.

<sup>5</sup> Účelem je ukázat, že matice  $P$  má prvky o konečné velikosti.

Směrodatné odchytky odhadnutých regresních parametrů  $\sigma_{\hat{\beta}}$  získáme jako

$$\sigma_{\hat{\beta}_j} = \sigma_{\varepsilon} \cdot \sqrt{\xi_{jj}}, \text{ kde}$$

$\xi_{jj}$  je j-tý diagonální prvek inverzní momentové matice  $(X'X)^{-1}$

$\sigma_{\varepsilon}$  je směrodatná odchytky náhodných složek (stejná u všech  $\varepsilon_t$ ).

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

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

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

**Ověření** Bez újmy na obecnosti můžeme matici  $D'$  jiné lineární odhadové funkce

$$\tilde{\beta} = D'y \text{ vyjádřit ve tvaru } D' = (X'X)^{-1}X' + G'$$

**Poznámka** Vzhledem k požadavku na nestrannost  $\tilde{\beta}$  musí s ohledem na platnost vztahu  $D'X = (X'X)^{-1}X'X + G'X = I_k$ , vždy platit  $G'X = 0$ .

**Ověření vydatnosti**

$$\beta = E(\tilde{\beta}) = E(D'y) = E[D'(X\beta + \varepsilon)] = ED'X\beta + ED'\varepsilon = D'X\beta + 0 = D'X\beta$$

[ matice D, X jsou nestochastické ]

z čehož přímo plyne  $D'X = I_k$

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

$$\begin{aligned} Cov(\tilde{\beta}) &= E\left\{[\tilde{\beta} - E\tilde{\beta}][\tilde{\beta} - E\tilde{\beta}]'\right\} = E\left\{[D'y - \beta][D'y - \beta]'\right\} = \\ &= E\left\{[(X'X)^{-1}X' + G']y - \beta\right\}[(X'X)^{-1}X' + G']y - \beta\left\} = \\ &= E\left\{[(X'X)^{-1}X' + G'](X\beta + \varepsilon) - \beta\right\}[(X'X)^{-1}X' + G'](X\beta + \varepsilon) - \beta\left\} = \\ &\quad \text{[ protože } G'X = 0 \text{ ]} \qquad \qquad \qquad \text{[ protože } G'X = 0 \text{ ]} \\ &= E\left\{[(X'X)^{-1}X'X\beta + (X'X)^{-1}X'\varepsilon + G'\varepsilon - \beta][(X'X)^{-1}X'X\beta + (X'X)^{-1}X'\varepsilon + G'\varepsilon - \beta]\right\} = \\ &\quad \text{[ protože } (X'X)^{-1}X'X = I \text{ ]} \qquad \qquad \qquad \text{[ protože } (X'X)^{-1}X'X = I \text{ ]} \\ &= E\left\{[\beta + (X'X)^{-1}X'\varepsilon + G'\varepsilon - \beta][\beta + (X'X)^{-1}X'\varepsilon + G'\varepsilon - \beta]\right\} = \\ &= E\left\{[(X'X)^{-1}X'\varepsilon + G'\varepsilon][(X'X)^{-1}X'\varepsilon + G'\varepsilon]\right\} = \end{aligned}$$

$$\begin{aligned}
&= E\left\{ (X'X)^{-1} X'\varepsilon\varepsilon'X(X'X)^{-1} + G'\varepsilon\varepsilon'G + (X'X)^{-1} X'\varepsilon\varepsilon'G + G'\varepsilon\varepsilon'X(X'X)^{-1} \right\} = \\
&\quad \text{[ po uplatnění operátoru střední hodnoty a protože X i G jsou nestochastické matice ]} \\
&= (X'X)^{-1} X'E\varepsilon\varepsilon'X(X'X)^{-1} + G'E\varepsilon\varepsilon'G + (X'X)^{-1} X'E\varepsilon\varepsilon'G + G'E\varepsilon\varepsilon'X(X'X)^{-1} = \\
&\quad \text{[ protože } E\varepsilon'\varepsilon = \sigma^2 I_T \text{ ]} \\
&= (X'X)^{-1} X'\sigma^2 I_T X(X'X)^{-1} + G'\sigma^2 I_T G + (X'X)^{-1} X'\sigma^2 I_T G + G'\sigma^2 I_T X(X'X)^{-1} = \\
&\quad \text{[ protože } \sigma^2 \text{ je skalární hodnota ]} \\
&= \sigma^2 (X'X)^{-1} + \sigma^2 G'G + \sigma^2 (X'X)^{-1} X'G + \sigma^2 G'X(X'X)^{-1} = \\
&\quad \text{[ protože } G'X = 0 \text{ a stejně } X'G = 0 \text{ ]} \\
&= \sigma^2 (X'X)^{-1} + \sigma^2 G'G = \text{Cov}(\hat{\beta}) + \sigma^2 G'G
\end{aligned}$$

kde  $G'G$  je zřejmě pozitivně semidefinitní matice<sup>6</sup> a  $\sigma^2 > 0$  □

## F. pro odhad rozptylu reziduí dostaneme

$$\begin{aligned}
E(e'e) &= E(\varepsilon' M . M \varepsilon) = E(\varepsilon' M . \varepsilon) = E \text{tr}(\varepsilon' M . \varepsilon) = E \text{tr}(M \varepsilon \varepsilon') = \\
&\quad \text{(M je idempotentní matice)} \quad \text{(skalár je současně svou stopou)} \quad \text{(tr A.B = tr B.A)}
\end{aligned}$$

$$\begin{aligned}
&= \text{tr} E(M \varepsilon \varepsilon') = \text{tr}(M E \varepsilon \varepsilon') = \text{tr}(M \sigma_\varepsilon^2 I_T) = \sigma_\varepsilon^2 \text{tr}(M) = \sigma_\varepsilon^2 (T - k) \\
&\quad \text{(záměna stopy a střední hodnoty)} \quad \text{(M je nestochastická)} \quad \text{(\sigma^2 je skalární hodnota)}
\end{aligned}$$

protože

$$\begin{aligned}
\text{tr}(M) &= \text{tr}(I_T - X(X'X)^{-1} X') = \text{tr}(I_T - X'X(X'X)^{-1}) = \text{tr}(I_T - I_K) = T - k \\
&\quad \text{(definice M)} \quad \text{(platí tr A.B = tr B.A)} \quad \text{(stopa jednotkové matice je rovna její dimenzi)}
\end{aligned}$$

## G. z tvrzení F plyne, že nestranným odhadem rozptylu náhodných složek $\sigma_\varepsilon^2$

$$\text{je výraz } \hat{\sigma}_\varepsilon^2 = \frac{e'e}{T - k}, \text{ neboť zřejmě platí } E\left[\frac{\sum e_t^2}{T - k}\right] = \sigma_\varepsilon^2.$$

Z důsledku D1 je patrné, že

odhady směrodatných odchylek odhadnutých regresních parametrů  $s_{\hat{\beta}}$  získáme jako

$$s_{\hat{\beta}_j} = s_e \cdot \sqrt{\xi_{jj}}, \text{ kde}$$

$\xi_{jj}$  je j-tý diagonální prvek inverzní momentové matice  $(X'X)^{-1}$

$s_e$  je směrodatná odchylka reziduí (stejná pro všechna  $j = 1, 2, \dots, k$ )

**Tvrzení 1** Platí vztah  $X'e = 0$ , tj. rezidua jsou nekorelovaná s kteroukoliv z vysvětlujících proměnných.

**Ověření:** zřejmě platí  $X'e = X'y - X'\hat{y} = X'y - X'Xb = X'y - X'X(X'X)^{-1}X'y = 0$

<sup>6</sup> Matice  $P = G'G$  (stejně jako kterákoliv jiná symetrická nenulová matice  $H'H$ ) je pozitivně definitní, protože pro ni platí  $x'Px = x'G'Gx = z'z > 0$  (skalární součin je nulový jen pro identicky nulový vektor).



**Důsledek:** Platí  $\sum_{i=1}^T \mathbf{e}_t = \mathbf{0}$ , tzn. součet všech reziduí je nulový, tj. regresní přímka/nadrovina prochází středem pozorovaných hodnot.

**Ověření:** protože platí  $\mathbf{X}'\mathbf{e} = \mathbf{0}$ , stačí v matici  $\mathbf{X}$  uvažovat jeden z jejich sloupců jako jedničkový vektor (nemusí to být nutně ten první). Pak máme

$$\mathbf{X}'\mathbf{e} = \begin{pmatrix} \mathbf{x}_{11} & \mathbf{x}_{21} & \dots & \mathbf{x}_{T1} \\ 1 & 1 & \dots & 1 \\ \dots & \dots & \dots & \dots \\ \mathbf{x}_{1k} & \mathbf{x}_{2k} & \dots & \mathbf{x}_{Tk} \end{pmatrix} \cdot \begin{pmatrix} \mathbf{e}_1 \\ \mathbf{e}_2 \\ \dots \\ \mathbf{e}_T \end{pmatrix} = \mathbf{0}$$

a je zřejmě vidět (z druhého řádku), že platí  $\sum_{t=1}^T \mathbf{e}_t = \mathbf{0}$

**Poznámka:** Prostá metoda nejmenších čtverců není jedinou používanou odhadovou metodou v prostředí standardního lineárního regresního modelu. K dalším technikám patří:

**Metoda maximální věrohodnosti ML (Maximum Likelihood)** je založena na maximalizaci sdružené hustoty (tzv. věrohodnostní funkce) rozdělení náhodných složek. Lokalizuje se tedy poloha modusu pro  $\beta$  a  $\sigma^2$ , v němž tato funkce nabývá maxima.

**Metoda nejmenších absolutních odchylek LAD (Least Absolute Deviations)** je založena na minimalizačním kritériu tvaru

$$\sum_{t=1}^T \left| y_t - \sum_{j=1}^k x_{tj} \beta_j \right|$$

Odhady pořízené metodou LAD nelze vyjádřit v explicitním tvaru, ale je nutno použít iterační postup (např. algoritmy R.L.Faira)

**Zobecněná momentová metoda GMM (Generalized moment method).**