

## Stanovení chyby předpovědi

Uvažujme opět standardní normální lineární regresní model, u kterého jsme již předtím ověřili jeho způsobilost k prognózování minimálně ve smyslu ověření stability modelové struktury.

Budeme pracovat s modelem v zápisu ( pro predikované období o délce  $m$  )

$$(1) \quad y_p = X_p \cdot \beta + \varepsilon_p \quad , \text{ kde}$$

$y_p$  je [  $m$ -členný ] sloupcový vektor hodnot vysvětlované (endogenní) proměnné, kterých nabude v predikovaném období

$X_p$  je [  $m \times k$ - rozměrná ] matice hodnot vysvětlujících (exogenních)

proměnných realizovaných v predikovaném období

$\beta$  je [  $k$ -členný ] sloupcový vektor regresních parametrů ( hodnoty parametrů přejímáme beze změn z pozorovaného období)

$\varepsilon_p$  je [  $m$ -členný ] sloupcový vektor náhodných složek predikovaného období

**Předpokládáme přitom, že**

a)  $E(\varepsilon) = 0_T$  ,  $E(\varepsilon_p) = 0_m$ , tzn. že náhodné složky s nulovou střední hodnotou v pozorovaném období zůstanou centrované i v předpovídaném období.

b)  $Var(\varepsilon_p^{(j)}) = Var(\varepsilon^{(i)}) = \sigma^2$  ,  $i = 1, 2, \dots, T$ ;  $j = 1, 2, \dots, m$  ; tzn. že rozptyly náhodných složek pozorovaného i predikovaného období jsou shodné ( rovné  $\sigma^2$  ) .

c)  $E(\varepsilon_p^{(j)} \cdot \varepsilon^{(i)}) = 0$  ,  $i = 1, 2, \dots, T$ ;  $j = 1, 2, \dots, m$  ; tzn. že náhodné složky predikovaného období jsou nekorelované navzájem i s náhodnými složkami pozorovaného období. Souhrnná kovarianční matice  $\tilde{\Sigma}_{[T+m; T+m]}$  má tedy

tvar 
$$\tilde{\Sigma} = Cov \begin{pmatrix} \varepsilon \\ \varepsilon_p \end{pmatrix} = \begin{pmatrix} \sigma^2 I_T & 0 \\ 0 & \sigma^2 I_m \end{pmatrix}$$

d) Náhodné složky jsou nekorelované s vysvětlujícími proměnnými v pozorovaném i v predikovaném období, tj.  $E(X_j' \varepsilon) = 0$  pro  $j = 1, 2, \dots, T$

$$E(X_p' \varepsilon_p) = 0 \text{ pro } l = 1, 2, \dots, m .$$

Model můžeme přehledněji znázornit maticovým zápisem

$$\begin{pmatrix} y_1 \\ y_2 \\ \dots \\ y_T \\ y_{T+1} \\ \dots \\ y_{T+m} \end{pmatrix} = \begin{pmatrix} x_{11} & x_{12} & x_{13} & \dots & x_{1k} \\ x_{21} & x_{22} & x_{23} & \dots & x_{2k} \\ \dots & \dots & \dots & \dots & \dots \\ x_{T,1} & x_{T,2} & x_{T,3} & \dots & x_{T,k} \\ x_{T+1,1} & x_{T+1,2} & x_{T+1,3} & \dots & x_{T+1,k} \\ \dots & \dots & \dots & \dots & \dots \\ x_{T+m,1} & x_{T+m,2} & x_{T+m,3} & \dots & x_{T+m,k} \end{pmatrix} \begin{pmatrix} \beta_1 \\ \beta_2 \\ \dots \\ \beta_k \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \dots \\ \varepsilon_T \\ \varepsilon_{T+1} \\ \dots \\ \varepsilon_{T+m} \end{pmatrix} .$$

**Bodovou předpověď**  $m$ -členného vektoru závisle proměnné získáme pomocí **predikční funkce<sup>1</sup>** tvaru

$$(2) \quad y_p^* = X_p \cdot b = X_p \cdot (X'X)^{-1} X' y \quad , \quad \text{kde}$$

$X$  je  $[Tx \ k\text{-rozměrná}]$  matice pozorovaných hodnot  $k$  vysvětlujících proměnných  
**Predikční funkce (2), jež je zřejmě lineární funkcí  $y$ , je nestrannou funkcí vektoru předpovědi  $y_p$  v tom smyslu, že pro ni platí**

$$(3) \quad E(y_p^*) = E(X_p \cdot b) = X_p E(b) = X_p \cdot \beta = E(y_p) \quad .$$

[  $X_p$  je nestochastická ] [  $b$  je nestranný odhad  $\beta$  ]

**To znamená, že střední hodnota predikční funkce je rovna střední hodnotě  $y_p$ .**<sup>2</sup>

**Poznámka:** Neznačená to však, že  $E(y_p^*) = y_p$ .<sup>3</sup>

**Lze ukázat, že predikční funkce (2) má ze všech nestranných predikčních funkcí (lineárními v  $y$ ) nejmenší v maticovém smyslu kovarianční matici vektoru reziduí v období předpovědi, tj. následujícího vektoru  $e_p$  :**

**Vektor chyb  $d_p$  definujeme jako odchylku (chybu) předpovídané hodnoty  $y_p^*$  od skutečné  $y_p$  :**

$$(4) \quad d_p = y_p^* - y_p = X_p(b - \beta) - \varepsilon_p$$

**Všimněme si, že zdrojem chyb předpovědi vektoru skutečných hodnot  $y_p$  je jednak variabilita náhodné složky  $\varepsilon_p$ , jednak výběrová chyba odhadové funkce  $b$  zpravidla pořázené metodou nejmenších čtverců OLS :**

**Střední chyba vektoru chyb predikčního vektoru  $d_p$  v (4) je nulová, protože platí**

$$E(d_p) = E(y_p^* - y_p) = X_p E(b - \beta) - E\varepsilon_p = 0.$$

**Před odvozením kovarianční matice tohoto vektoru upravíme  $d_p$  do tvaru**

$$(5) \quad \begin{aligned} d_p &= X_p \cdot b - X_p \beta - \varepsilon_p = -\varepsilon_p - X_p \beta + X_p (X'X)^{-1} X' y = \\ &= -\varepsilon_p - X_p \beta + X_p (X'X)^{-1} X' (X\beta + \varepsilon) = \\ &= -\varepsilon_p - X_p \beta + X_p \beta + X_p (X'X)^{-1} X' \varepsilon = -\varepsilon_p + X_p (X'X)^{-1} X' \varepsilon \end{aligned}$$

**Vektor reziduí předpovídaných hodnot závisí tedy na náhodných složkách pozorovaného i náhodných složkách predikovaného období.**

<sup>1</sup> Predikční funkce je náhodný vektor o  $m$  složkách.

<sup>2</sup> Jde o totožnost středních hodnot stejnohlých složek příslušných náhodných vektorů.

<sup>3</sup> Podle (1) je  $y_p = X_p \cdot \beta + \varepsilon_p$  a náhodnost vektoru  $y_p$  pramení z náhodnosti  $\varepsilon_p$ , zatímco

v případě  $y_p^*$  vyplývá náhodnost tohoto vektoru z náhodnosti  $b$  (a tudíž z  $\varepsilon$ ).

**Za přijatých předpokladů a) – d) lze pro kovarianční matici náhodného predikčního vektoru (5) psát :**

$$\begin{aligned} \text{Cov}(d_p) &= E \left[ -\varepsilon_p + X_p (X'X)^{-1} X' \varepsilon \right] \left[ -\varepsilon_p + X_p (X'X)^{-1} X' \varepsilon \right]' =^4 \\ &\quad \text{[nekorelovanost } \varepsilon, \varepsilon_p] \\ &= E \left[ -\varepsilon_p \cdot \varepsilon_p' \right] + E \left[ X_p (X'X)^{-1} X' \varepsilon \varepsilon' X (X'X)^{-1} X_p' \right] = \\ &\quad [E \varepsilon_p \varepsilon_p' = \sigma^2 I_m] \quad [E \varepsilon \varepsilon' = \sigma^2 I_T] \\ &= \sigma^2 \cdot \left[ I_m + X_p (X'X)^{-1} X_p' \right] \end{aligned}$$

**Poznámka :** speciální případ jediné predikované hodnoty tzn. případ  $m = 1$

$$\text{Cov}(d_p) = \sigma^2 \cdot \left[ 1 + x_p (X'X)^{-1} x_p' \right] =$$

*V tomto případě jsou  $y_p$  a  $\varepsilon_p$  skalární hodnoty a matice  $X_p$  se redukuje na řádkový vektor  $x_p$  o  $k$  složkách.*

**Standardní chybu (směrodatnou odchylku) bodové předpovědi skutečné hodnoty vysvětlované proměnné dostaneme nahrazením rozptylu  $\sigma^2$  jeho nestranným odhadem  $s^2$  získaným například metodou OLS. Pak**

$$s_{d_p} =_{OLS} s \cdot \sqrt{\left[ 1 + X_p (X'X)^{-1} X_p' \right]}^5$$

**Lze ukázat, že vyhovuje-li model předpokladu normality, pak bodová predikční funkce založená na odhadu  $\beta$  metodou OLS má též normální rozdělení, konkrétně :**

$$(6) \quad y_p^* \approx N \left[ X_p \cdot \beta ; \sigma^2 X_p (X'X)^{-1} X_p' \right], \quad \text{protože zřejmě}$$

$$(3^*) \quad E[y_p^*] = E[X_p b] = X_p b = E[y_p] \quad . \quad \text{a dále}$$

$$\text{Cov}(y_p^*) = \text{Cov}(X_p \cdot b) = X_p \cdot \text{Cov}(b) \cdot X_p' = X_p \cdot \sigma^2 (X'X)^{-1} X_p' = \sigma^2 X_p \cdot (X'X)^{-1} X_p'$$

[Cov(b) =  $\sigma^2 \cdot (X'X)^{-1}$ ]                      [ $\sigma^2$  je skalár]

<sup>4</sup> Bereme v úvahu nekorelovanost  $\varepsilon$  a  $\varepsilon_p$  .

<sup>5</sup> Pokud  $m=1$ , pak  $X_p$  je vektor a veličina  $x_p (X'X)^{-1} x_p'$  je skalár , pokud  $m > 1$ , pak se vezme diagonální prvek matice  $X_p (X'X)^{-1} X_p'$  pořadím příslušný dané složce vektoru parametrů  $\beta$ .