

PROGNÓZOZENÍ POMOCÍ EKONOMETRICKÝCH MODELŮ. ÚLOHA OČEKÁVÁNÍ V EKONOMII.

Tento text věnuje prognózození, tedy predikci hodnot vysvětlovaných proměnných. Typy kvantitativních prognostických postupů můžeme rozdělit na:

- jednorozměrné metody, které predikují budoucí hodnoty časové řady pouze na základě jejich minulých hodnot (například ARIMA modely, metody exponenciálního vyrovnávání, klouzavé průměry...);
- vícerozměrné metody, které využívají k predikci i vztahy mezi proměnnými jedné či více časových řad (sem patří například VAR modely či modely korekce chyby);
- ostatní metody (jako například neuronové sítě či genetické algoritmy).

ZÁKLADNÍ POJMY

extrapolace do budoucna	„klasická“ předpověď
extrapolace do minulosti	předpověď hodnot před intervalem pozorování, retrospektiva (retropolace)
bodová předpověď	odhad jedné budoucí hodnoty
intervalová předpověď	odhad intervalu, ve kterém se s požadovanou pravděpodobností vyskytuje skutečná hodnota predikované proměnné
předpověď ex post	známe hodnoty endogenních i predeterminovaných proměnných s jistotou, takže je můžeme porovnat s předpovídanými a určit chybu předpovědi (pseudopředpověď)
předpověď ex ante	hodnoty endogenních, a někdy ani predeterminovaných proměnných neznáme a musíme je odhadovat
nepodmíněná předpověď	známe s jistotou hodnoty všech vysvětlujících predeterminovaných proměnných
podmíněná předpověď	neznáme hodnoty všech vysvětlujících predeterminovaných proměnných

CHYBA PŘEDPOVĚDI

Chyba předpovědi označuje odchylku předpovídaných a skutečných hodnot endogenních proměnných. Má na ni vliv řada věcí, k nimž patří následující:

- stochastický charakter modelu (kvůli existenci náhodné složky se těžko přesně trefíme);
- náhodná standardní chyba odhadnutých parametrů (odhadnuté parametry jsou náhodnou veličinou, při nekonečně velkém výběru bychom se trefili do skutečného parametru, ale při malém výběru může být odhad parametru vzdálený od jeho skutečné hodnoty);
- náhodná chyba při odhadu vysvětlujících proměnných v případě podmíněné předpovědi;
- chybná specifikace modelu (model nemusí být v čase stabilní), chyby měření a kvalita dat;
- změny očekávání ekonomických subjektů či změny hospodářské politiky.

Z toho plyne, že předpovědi mají stochastický charakter, a my se snažíme získat takové předpovědi, jejichž chyba má minimální rozptyl. Při použití LRM nebo rekurzivních MSR získáme nestranné a nevychýlené předpovědi.

PŘEDPOVĚDI POMOCÍ JEDNOROVNICOVÉHO LINEÁRNÍHO REGRESNÍHO MODELU

Mějme model $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$, kde \mathbf{X} je matice $T \times k$ vysvětlujících proměnných a \mathbf{y} je vektor vysvětlované proměnné. Musí platit, že model je v čase stabilní (jeho specifikace, rozdělení náhodné složky ani parametry se v čase nemění) a že splňuje GM předpoklady.

Nestranný odhad parametru $\boldsymbol{\beta}$ pomocí MNČ získáme ze vztahu : $\mathbf{b} = (\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{y})$.
 Kovarianční matici odhadové funkce $\mathbf{V}(\mathbf{b})$ získáme ze vztahu: $\mathbf{V}(\mathbf{b}) = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$
 Odhad kovarianční matice odhadové funkce $\mathbf{S}(\mathbf{b})$ získáme ze vztahu: $\mathbf{S}(\mathbf{b}) = s^2 (\mathbf{X}'\mathbf{X})^{-1}$

Budeme značit

→ Y_p skutečnou **individuální hodnotu** v období předpovědi a \widehat{Y}_p její odhad

→ \overline{Y}_p skutečnou **průměrnou** hodnotu v období předpovědi a $\widehat{\overline{Y}}_p$ její odhad

PŘEDPOVĚĎ PRŮMĚRNÉ HODNOTY

Bodovou ex-ante předpověď průměrné hodnoty Y v čase p lze stanovit jako:

$$E(Y_p) = \widehat{Y}_p = \mathbf{x}_p' \mathbf{b}$$

kde \mathbf{x}_p je vektor $1 \times k$ vysvětlujících proměnných (napozorovaných či odhadnutých hodnot: považujeme je za nestochastické hodnoty, buď je známe, a jsou tedy „správně,“ nebo je odhadneme, a pak bude \widehat{Y}_p podmíněnou předpovědí vzhledem k takto odhadnutým hodnotám). Pokud nakonec skutečná střední hodnota bude \overline{Y}_p , pak chyba předpovědi bude:

$$\widehat{e}_p = \widehat{Y}_p - \overline{Y}_p = \mathbf{x}_p' \mathbf{b} - \mathbf{x}_p' \boldsymbol{\beta} = \mathbf{x}_p' (\mathbf{b} - \boldsymbol{\beta}).$$

Neboli zdrojem chyby předpovědi **průměrné** Y je pouze variabilita odhadové funkce \mathbf{b} (náhodná složka není zdrojem chyby, protože jde o průměrnou hodnotu Y a průměr náhodné složky je 0). A protože odhadová funkce je při odhadu MNČ nestranná, je **střední hodnota chyby předpovědi rovna 0**. Předpověď střední hodnoty \overline{Y}_p je tedy nestranná a je nejlepší lineární nestrannou předpovědí.

Rozptyl chyby předpovědi má tvar $\widehat{\sigma}_p^2 = \mathbf{x}_p' \mathbf{V}(\mathbf{b}) \mathbf{x}_p$ a její odhad má tvar $\widehat{s}_p^2 = \mathbf{x}_p' \mathbf{S}(\mathbf{b}) \mathbf{x}_p$.¹ Odmocnina z odhadnutého rozptylu chyby předpovědi se nazývá **standardní chyba předpovědi průměrné hodnoty**

vysvětlované proměnné a spočítáme ji jako: $\widehat{s}_p = s \sqrt{\mathbf{x}_p' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_p}$.

Jestliže má náhodná složka LRM normální rozdělení, pak i \widehat{Y}_p a chyba předpovědi budou mít normální rozdělení, při neznalosti $\widehat{\sigma}_p^2$ ale používáme Studentovo rozdělení. Takže $\widehat{e}_p / \widehat{s}_p = \frac{\widehat{Y}_p - \overline{Y}_p}{s \sqrt{\mathbf{x}_p' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_p}}$ má

Studentovo rozdělení s $T-k$ stupni volnosti (T je počet pozorování, k je počet vysvětlujících proměnných). Intervalová předpověď průměrné hodnoty \overline{Y}_p má tvar $\widehat{\overline{Y}}_p \pm t^*_{\alpha/2} \widehat{s}_p$, kde $t^*_{\alpha/2}$ je kritická hodnota Studentova rozdělení s $T-k$ stupni volnosti.

¹ Minimální hodnotu má rozptyl předpovědi tehdy, pokud jsou předpokládáné hodnoty vysvětlujících proměnných v období předpovědi rovny jejich průměrným napozorovaným hodnotám v období odhadu modelu.

PŘEDPOVĚĚ KONKRÉTNÍ INDIVIDUÁLNÍ HODNOTY

Bodová předpověď má tvar

$$\widehat{Y}_p = \mathbf{x}_p' \mathbf{b}$$

Protože skutečná hodnota $Y_p = \mathbf{x}_p' \boldsymbol{\beta} + u_p$, tak pro chybu předpovědi individuální hodnoty platí:

$$\widetilde{e}_p = \widehat{Y}_p - Y_p = \mathbf{x}_p' \mathbf{b} - \mathbf{x}_p' \boldsymbol{\beta} - u_p$$

Z téhle rovnice je vidět, že zdrojem chyby předpovědi je navíc i hodnota náhodné složky (neodhadujeme střední hodnotu, ale individuální hodnotu, jejíž součástí bude náhodná složka). Střední hodnota chyby předpovědi je ale také nulová a bodová předpověď individuální hodnoty je tudíž nestranná: $E(\widehat{Y}_p) = E(Y_p)$, ale $E(\widetilde{e}_p) \neq 0$.

Rozptyl chyby předpovědi individuální hodnoty má tvar $\widetilde{\sigma}_p^2 = \sigma^2 + \mathbf{x}_p' \mathbf{V}(\mathbf{b}) \mathbf{x}_p = \sigma^2 + \widehat{\sigma}_p^2$, nebol rozptyl chyby předpovědi individuální hodnoty je součtem rozptylu chyby předpovědi průměrné hodnoty a rozptylu náhodné složky v období předpovědi. Odmocnina odhadu rozptylu chyby předpovědi individuální hodnoty, tedy **standardní chyba předpovědi individuální hodnoty** vysvětlované proměnné, má tvar $\widetilde{s}_p = s \sqrt{1 + \mathbf{x}_p' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_p}$. Intervalová předpověď individuální hodnoty má tvar $\widehat{Y}_p \pm t^*_{\alpha/2} \widetilde{s}_p$, kde $t^*_{\alpha/2}$ je kritická hodnota Studentova rozdělení s T-k stupni volnosti.²

SHRNUTÍ

	předpověď průměrné hodnoty	předpověď individuální hodnoty
<i>bodová předpověď</i>	$\widehat{Y}_p = \mathbf{x}_p' \mathbf{b}$	$\widehat{Y}_p = \mathbf{x}_p' \mathbf{b}$
<i>intervalová předpověď</i>	$\widehat{Y}_p \pm t^*_{\alpha/2} \widehat{s}_p$	$\widehat{Y}_p \pm t^*_{\alpha/2} \widetilde{s}_p$
<i>chyba předpovědi</i>	$\widehat{e}_p = \mathbf{x}_p' \mathbf{b} - \mathbf{x}_p' \boldsymbol{\beta} = \mathbf{x}_p' (\mathbf{b} - \boldsymbol{\beta})$	$\widetilde{e}_p = \widehat{Y}_p - Y_p = \mathbf{x}_p' \mathbf{b} - \mathbf{x}_p' \boldsymbol{\beta} - u_p$
<i>střední hodnota chyby předpovědi</i>	0	0
<i>rozptyl chyby předpovědi</i>	$\widehat{\sigma}_p^2 = \mathbf{x}_p' \mathbf{V}(\mathbf{b}) \mathbf{x}_p$	$\widetilde{\sigma}_p^2 = \sigma^2 + \mathbf{x}_p' \mathbf{V}(\mathbf{b}) \mathbf{x}_p = \sigma^2 + \widehat{\sigma}_p^2$
<i>standardní chyba předpovědi</i>	$\widehat{s}_p = s \sqrt{\mathbf{x}_p' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_p}$	$\widetilde{s}_p = s \sqrt{1 + \mathbf{x}_p' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_p}$

² Minimální hodnotu má rozptyl předpovědi opět tehdy, pokud jsou předpokládané hodnoty vysvětlujících proměnných v období předpovědi rovny jejich průměrným napozorovaným hodnotám v období odhadu modelu. Při velkých výběrech konverguje rozptyl chyby předpovědi k rozptylu náhodné složky.

TESTOVÁNÍ VHODNOSTI MODELU K PREDIKCI


K testování se používají Chowovy testy:

CHOWŮV TEST ZMĚNY STRUKTURY MODELU V ČASE (CHOWŮV 1. TEST)

Testuje, zda jsou regresní koeficienty v čase stabilní. Zajímá nás tedy, jestli jsou parametry stejné v různých podmnožinách dat, protože pokud ano, dá se předpokládat, že i v budoucnosti by mohly být stejné.

Postupujeme takto:

1. Máme T pozorování a rozdělíme je na dvě skupiny (T_1 a T_2), nebo i více skupin, ale mělo by platit, že $T_1 > k$, $T_2 > k$, kde k je počet parametrů v regresním modelu. Můžeme testovat, že v období $T_1 + 1$ došlo ke zlomu (strukturální změně).
2. Nulová hypotéza je, že regresní koeficienty jsou v těchto podmnožinách shodné.
3. Odhadneme parametry ve skupinách T_1 a T_2 a uložíme si rezidua. Součet čtverců reziduí modelů odhadnutých z T_1 a T_2 označme e_1^2 a e_2^2 . Součet čtverců reziduí modelu odhadnutého ze všech pozorování označme e^2 . Pokud se rezidua významně liší, pak se regresní koeficienty asi v čase mění.
4. Spočítáme F-statistiku a porovnáme ji s kritickou hodnotou: $\frac{[e^2 - (e_1^2 + e_2^2)]/k}{(e_1^2 + e_2^2)/(T - 2k)} \sim F(k, T - 2k)$
5. Pokud je testová statistika větší než kritická hodnota, zamítneme nulovou hypotézu o stabilitě modelu v čase. Model tedy není vhodný k predikci.



CHOWŮV TEST PREDIKČNÍ NEVHODNOSTI MODELU (CHOWŮV 2. TEST)

Používá se tehdy, když máme málo pozorování (T_1 resp. $T_2 < k$). Takže nás zajímá, jestli dodatečná pozorování jsou generována stejně jako ta předchozí, nebo ne. Postupujeme takto:

1. Máme T pozorování: většina bude ve skupině T_1 , dodatečná pozorování označme T_2
2. Nulová hypotéza je, že dodatečná pozorování (např. v období předpovědi) jsou generována stejně jako v období odhadu původního modelu.
3. Odhadneme parametry z T_1 pozorování a pak znovu z výběru zvětšeného o T_2 dodatečných pozorování, kde $T_1 + T_2 = T$. Uložíme si rezidua. Součet čtverců reziduí modelu odhadnutého z podmnožiny T_1 označme e_1^2 . Součet čtverců reziduí modelu se všemi T pozorováními označme e^2 .
4. Spočítáme F-statistiku a porovnáme ji s kritickou hodnotou: $\frac{(e^2 - e_1^2)/T_2}{e_1^2/(T_1 - k)} \sim F(T_2, T_1 - k)$
5. Pokud je testová statistika větší než kritická hodnota, zamítneme nulovou hypotézu a dá se očekávat, že predikční schopnosti modelu je nevyhovující.

PROČ JE PREDIKČNÍ SCHOPNOSTI MODELU NĚKDY NEVYHOVUJÍCÍ?

- parametry nejsou stabilní (i model s přesně odhadnutými parametry je při předpovědi k ničemu, pokud se mění vztah mezi proměnnými například kvůli různým institucionálním změnám);
- předpokládané hodnoty vysvětlujících proměnných se liší od skutečných;
- změni se podmínky v období předpovědi (např. v případě transformace ekonomiky).

CO V TOM PŘÍPADĚ DĚLAT?

Nejjednodušší je zvětšit rozsah výběru, ale to není vždy možné. Nebo můžeme změnit specifikaci modelu:

- přejít k MSR, VAR či MKCH;
- rozšířit počet vysvětlujících proměnných;
- změny odhadnutých parametrů v důsledku jejich nestability zachytit nula-jednotkovými dummy proměnnými či hodnoty parametrů aktualizovat;
- v případě závislosti endogenní proměnné na čase dynamizovat model (zahrnutím proměnné čas do modelu, zahrnutím zpožděných hodnot, přechodem k prvním diferencím apod.)
- v případě změny analytického tvaru modifikujeme funkční tvar modelu (lineární → kvadratický apod.).

PŘEDPOVĚDI POMOCÍ MSR

- Pro účely předpovědi rozdělíme vysvětlující proměnné \mathbf{x}_t na exogenní (\mathbf{z}_t) a zpožděné endogenní (\mathbf{y}_{t-1}). K prognózaování se nepoužívá strukturní tvar, nýbrž **redukovaný a konečný tvar**. Strukturní tvar není vhodný k předpovědím kvůli existenci zpětných vazeb.

Strukturní tvar MSR lze maticově zapsat jako

$$\mathbf{B}\mathbf{y}_t + \Gamma_1\mathbf{y}_{t-1} + \Gamma_2\mathbf{z}_t = \mathbf{u}_t$$

Redukovaný tvar MSR je tvar, ve kterém jsou endogenní proměnné vyjádřeny pouze jako funkce všech predeterminovaných proměnných a náhodných složek.

Omezený redukovaný tvar získáme řešením podle **B**:

$$\mathbf{y}_t = -\mathbf{B}^{-1}\Gamma_1\mathbf{y}_{t-1} + (-\mathbf{B}^{-1}\Gamma_2\mathbf{z}_t) + \mathbf{B}^{-1}\mathbf{u}_t$$

Neomezený redukovaný tvar získáme z omezeného substitucí:

$$\mathbf{y}_t = \Pi_1\mathbf{y}_{t-1} + \Pi_2\mathbf{z}_t + \mathbf{v}_t$$

kde Π_1 je matice **dynamických multiplikátorů** a Π_2 je matice **běžných** multiplikátorů. Konzistentní odhady matice Π neomezeného redukovaného lze získat přímo MNČ. Odhady matic parametrů omezeného redukovaného tvaru se musí určit nepřímou dopočítáním z matic **B** a Γ . Pokud jsou některé rovnice MSR přeidentifikované, jsou nepřímé odhady vydatnější, a předpovědi tak budou přesnější. Pokud jsou rovnice MSR přesně identifikované, není mezi přímým a nepřímým odhadem rozdíl.

Konečný tvar vyjadřuje endogenní proměnné v běžném období jako funkci pouze běžných a zpožděných hodnot vektorů exogenních proměnných, hodnot endogenních proměnných ve výchozím období a náhodných složek. Lze jej odvodit pouze pro modely, v nichž je obsažena zpožděná hodnota vysvětlované endogenní proměnné. Obecně jej lze zapsat jako:

$$\mathbf{y}_t = \Pi_1^t\mathbf{y}_0 + \sum_{j=0}^{t-1}\Pi_1^j\Pi_2\mathbf{z}_{t-j} + \sum_{j=0}^{t-1}\Pi_1^j\mathbf{v}_{t-j}$$

Pokud pro $t \rightarrow \infty$ konverguje $\Pi_1^t \rightarrow 0$, pak první člen vypadne (tato matice by měla konvergovat k nule, pokud se má \mathbf{y} vracet ke svým rovnovážným hodnotám).

KRÁTKODOBÉ A DLOUHODOBÉ PŘEDPOVĚDI

Pro **krátkodobé předpovědi ex ante** vyjdeme z **redukovaného tvaru**. Vektor podmíněných simultánních předpovědí v čase $t+1$ vyjádříme jako funkci známých hodnot endogenních proměnných v běžném období a předpokládaných hodnot exogenních proměnných v čase $t+1$, které můžeme získat extrapolací, expertním odhadem, prognózou z jiného modelu apod.:

$$\hat{y}_{t+1} = \hat{\Pi}_1 y_t + \hat{\Pi}_2 \hat{z}_{t+1}.$$

Pro **střednědobé a dlouhodobé předpovědi ex ante** vyjdeme z **konečného tvaru**. Vektor podmíněných simultánních předpovědí v čase $t+h$ vyjádříme jako funkci známých hodnot endogenních proměnných v běžném období a předpokládaných hodnot exogenních proměnných za celé období $t+h$:

$$\hat{y}_{t+h} = \hat{\Pi}_1^h y_t + \sum_{j=0}^{h-1} \hat{\Pi}_1^j \hat{\Pi}_2 \hat{z}_{t+h-j}$$

Konečný tvar ale lze vyjádřit jen v případě MSR obsahujících zpožděné endogenní proměnné. Pokud jej tedy vyjádřit nemůžeme, postupujeme iterativně (opakujeme krátkodobou předpověď pro celý horizont – vždy odhadneme jen jednu hodnotu v následujícím roce).

Stejně bychom postupovali při předpovědích ex post s tím rozdílem, že hodnoty exogenních proměnných bychom nemuseli odhadovat, protože jsou již známé.

CHYBY PŘEDPOVĚDI

Vyjdeme-li z **omezeného redukovaného tvaru**, kde budeme nepřímé odhady získané z odhadnutých parametrů strukturního tvaru značit vlnovkou (přímé odhady neomezeného redukovaného tvaru získané přímo použitím MNČ pak hvězdičkou), můžeme chybu předpovědi zapsat jako:

$$\begin{aligned} \tilde{e}_{t+1} &= \tilde{y}_{t+1} - y_{t+1} \\ &= \tilde{\Pi}_1 y_t + \tilde{\Pi}_2 \tilde{z}_{t+1} - \Pi_1 y_t - \Pi_2 z_{t+1} - v_{t+1} \\ &= (\tilde{\Pi}_1 - \Pi_1) y_t + (\tilde{\Pi}_2 - \Pi_2) z_{t+1} + \tilde{\Pi}_2 (\tilde{z}_{t+1} - z_{t+1}) - v_{t+1} \end{aligned}$$

Tedy zdrojem chyby předpovědi jsou 1) chyba odhadu matice Π_1 , 2) chyba odhadu matice Π_2 , 3) chyba odhadu samotné budoucí hodnoty exogenních proměnných a 4) náhodná složka. Chyba předpovědi je náhodnou veličinou. Protože **matice $\tilde{\Pi}_1$ a $\tilde{\Pi}_2$ nejsou nestranné, nýbrž jen konzistentní** odhady, není střední hodnota chyby nulová. Pro velký výběr se však střední hodnota chyby blíží nule, takže funkce simultánních předpovědí je konzistentní.

Vyjdeme-li z neomezeného redukovaného tvaru, můžeme chybu předpovědi zapsat jako:

$$\begin{aligned} e^*_{t+1} &= y^*_{t+1} - y_{t+1} \\ &= \Pi^*_1 y_t + \Pi^*_2 \tilde{z}_{t+1} - \Pi_1 y_t - \Pi_2 z_{t+1} - v_{t+1} \end{aligned}$$

Zdrojem chyby jsou stejně jako v předchozím případě chyby odhadu matic, budoucích hodnot exogenních proměnných a náhodná složka. Ale při přímém odhadu jsou odhady matic Π^*_1 a Π^*_2 **nestranné**, takže střední hodnota predikované endogenní proměnné se rovná střední hodnotě skutečné budoucí endogenní proměnné tehdy, pokud jsou budoucí hodnoty exogenních proměnných odhadnuty přesně. Při přesném odhadu budoucích hodnot exogenních proměnných je funkce krátkodobé simultánní předpovědi endogenní proměnné z neomezeného redukovaného tvaru **nestranná**.

- Jak určit a přesnost předpovědi u MSR?

Můžeme postupovat stejně jako v případě LRM a odhadnout standardní chyby a určit intervaly spolehlivosti pro podmíněné bodové předpovědi **postupně pro jednotlivé rovnice** (jedna po druhé). Můžeme ale také stanovit přesnost vektoru bodových předpovědí a oblast spolehlivosti pro všechny proměnné **současně**. Přesnost pak posuzujeme podle kovarianční matice chyb simultánních předpovědí. Odmocniny z jejích diagonálních prvků jsou standardní chyby a používají se k určení intervalů spolehlivosti.

Kovarianční matice se liší pro omezený a neomezený redukovaný tvar.

- V případě omezeného redukovaného tvaru budou hodnoty asymptotických rozptylů minimální při použití některé z metod úplné informace (M3NČ). Pokud musíme predikovat i hodnoty vysvětlujících proměnných, bývá odhad kovarianční matice chyb předpovědí podhodnocený. Konkrétní tvar matice viz Hušek str. 278.
- V případě neomezeného redukovaného tvaru má kovarianční matice chyby předpovědi tvar: $V(e_p^*) = [1 + x_p'(X'X)^{-1}x_p']\Omega$, kde x_p značí vektor všech vysvětlujících proměnných (exogenních i zpožděných endogenních), Ω je kovarianční matice náhodných složek a X je matice všech vysvětlujících proměnných.
- Pomocí kovarianční matice chyby předpovědi lze pak určit **elipsoid koncentrace**, což je něco jako interval spolehlivosti pro celý vektor vysvětlovaných proměnných.
- Při predikci dáme přednost omezenému redukovanému tvaru, víme-li, že je model správně specifikován, jinak raději neomezenému redukovanému tvaru i za cenu menší asymptotické přesnosti.

PŘEDPOVĚDI POMOCÍ VAR

V případě VAR modelu děláme předpovědi **extrapolací**. Například, pokud vynecháme pro zjednodušení úrovnovou konstantu a uvažujeme VAR(1) model, získáme optimální předpověď \mathbf{y}_{t+1} , tedy **předpověď s minimální střední kvadratickou chybou**, jako:

$$\hat{\mathbf{y}}_{t+1|t} = E(\mathbf{y}_{t+1} | \mathbf{y}_t, \mathbf{y}_{t-1}, \dots) = \Pi_1 \mathbf{y}_t.$$

Pro \mathbf{y}_{t+2} by to bylo

$$\hat{\mathbf{y}}_{t+2|t} = E(\mathbf{y}_{t+2} | \mathbf{y}_t, \mathbf{y}_{t-1}, \dots) = \Pi_1 \mathbf{y}_{t+1} = \Pi_1^2 \mathbf{y}_t.$$

A tak dále. až pro \mathbf{y}_{t+h} bychom dostali

$$\hat{\mathbf{y}}_{t+h|t} = E(\mathbf{y}_{t+h} | \mathbf{y}_t, \mathbf{y}_{t-1}, \dots) = \Pi_1^h \mathbf{y}_t.$$

Tedy jde o podmíněné očekávání \mathbf{y}_{t+h} na konci období t .

Vektor chyb předpovědí vyjádříme jako $\mathbf{e}_h = \mathbf{y}_{t+h} - \hat{\mathbf{y}}_{t+h|t} = \mathbf{v}_{t+h} + \Pi_1 \mathbf{v}_{t+h-1} + \dots + \Pi_1^{h-1} \mathbf{v}_{t+1}$

Kovarianční matice chyb předpovědí má tvar $\Sigma(h) = \Omega + \Pi_1 \Omega \Pi_1' + \Pi_1^2 \Omega (\Pi_1')^2 + \dots + \Pi_1^{h-1} \Omega (\Pi_1')^{h-1}$, kde kovarianční matice $E(\mathbf{v}_t, \mathbf{v}_h') = \Omega$ pro $h = t$ a $\mathbf{0}$ pro $h \neq t$ je pozitivně definitní.

Obecně VAR modely dávají horší předpovědi než řada jiných technik.

KRITÉRIA HODNOCENÍ PŘEDPOVĚDÍ

Můžeme použít parametrická kritéria: ověřování hypotézy o nestrannosti či konzistenci předpovědí, Chowovy testy, testy významnosti bodových předpovědí apod. Nejsou ale moc vhodné pro porovnání více prognóz. Můžeme použít také neparametrická kritéria: grafické metody, různé míry přesnosti předpovědí, simulační prognózy apod. Jde většinou o míry přesnosti předpovědi **ex post**.

Střední kvadratická chyba ekonometrické předpovědi: $MSE = \frac{1}{h} \sum_{t=1}^h (P_t - A_t)^2$, kde P_t je predikovaná hodnota a A_t je skutečná hodnota endogenní proměnné v období t a h je délka horizontu předpovědi. Většinou porovnáváme odmocninu ze střední kvadratické chyby (**RMSE**) pro různé metody

předpovědi. Máme-li více proměnných, je vhodné posuzovat MSE relativně v procentech vzhledem k dané proměnné.

- **Theilův modifikovaný koeficient nesouladu:** $U^* = \sqrt{\frac{M}{\frac{1}{h} \sum_{t=1}^h A_t^2}}$. Pokud se $U^* = 0$, jde o perfektní předpověď. Pro $U^* > 1$ dává model horší výsledky než naivní předpověď. Theilovu statistiku lze rozložit na **dílčí koeficienty nesouladu**, abychom zjistili, co je zdrojem nepřesnosti předpovědi.

$$M = \text{zkreslení (nesoulad v důsledku systematické chyby, tzn. rozdílů v průměrech)} \\ + \text{rozptyl (nesoulad v důsledku systematického rozdílu mezi variabilitou P a A)} \\ + \text{kovariance chyby (nesystematická náhodná chyba způsobená nedostatečnou} \\ \text{korelací P a A, na rozdíl od předchozích dvou složek ji nelze redukovat)} \\ = (\bar{P} - \bar{A})^2 + (s_P - s_A)^2 + 2(1 - r_{PA})s_P s_A,$$

kde v první závorce jsou průměry predikovaných a skutečných hodnot, ve druhé jejich směrodatné odchylky a r_{PA} je kovariance P a A .

Každou ze závorek lze vyjádřit jako podíl na M , čímž dospějeme k proporcím nesouladu. Podíly $\frac{(\bar{P} - \bar{A})^2}{M}$ a $\frac{(s_P - s_A)^2}{M}$ by se měly blížit 0, jinak by se měl model modifikovat, podíl $2(1 - r_{PA})s_P s_A / M$ by se měl tedy blížit 1.

- **Diagram předpověď-realizace** se sestrojí tak, že se na vertikální osu zanesou skutečné hodnoty endogenní proměnné a na horizontální osu její predikované hodnoty a body by měly ležet v 1. a 3. kvadrantu, jinak není správně predikován směr změny („chyby bodu zvratu“). Body by měly ležet kolem linie 45° .

ÚLOHA OČEKÁVÁNÍ V EKONOMII

Očekávání znamená, jaký mají ekonomické subjekty pohled na budoucí hodnoty ekonomických veličin. Často mají tato očekávání vliv na skutečný budoucí vývoj. Příklady, kde mají vliv očekávání:


- spotřeba, investice (pozitivní očekávání př. investičních pobídek může zvýšit investice) → vliv na HDP
- nejčastěji se o vlivu očekávání mluví v souvislosti s inflací

ADAPTIVNÍ OČEKÁVÁNÍ (FRIEDMAN):

- Podle této hypotézy ekonomické subjekty berou v úvahu minulý vývoj a zkušenosti (učí se z minulých chyb), nikoli však všechny relevantní skutečnosti. Adaptivní očekávání mohou být mylná a nevylučují systematické chyby.
- Často se tato hypotéza používá v souvislosti s Friedmanovou spotřební funkcí, podle které spotřeba závisí na očekávaném, permanentním, nikoli na běžném důchodu: $C_t = \beta_1 + \beta_2 Y_t^P + u_t$. Tento očekávaný důchod je generovaný na základě minulých očekávání: $Y_t^P = gY_t + (1 - g)Y_{t-1}^P$, kde g je koeficient očekávání. Očekávání ohledně důchodu tedy závisí nejen na současném důchodu, ale i na očekávaních v minulosti. Stejný princip se uplatňuje v souvislosti s inflací: $\pi_t^e = g\pi_{t-1} + (1 - g)\pi_{t-1}^e$
- Dalším příkladem aplikace hypotézy adaptivních očekávání je rozšířená Phillipsova křivka:

$\pi_t = \pi_t^e - \varepsilon(u - u^*)$, kde π značí inflaci, u značí skutečnou nezaměstnanost, u^* přirozenou míru nezaměstnanosti. Z rovnice plyne, že skutečná inflace se rovná očekávané ($\pi_t = \pi_t^e$), jen pokud se skutečná míra nezaměstnanosti rovná přirozené: pak se také míra skutečné inflace nemění.

Pokud se vláda snaží snížit nezaměstnanost pod její přirozenou úroveň, způsobí to růst inflace, neboť krátkodobě sice existuje substituční vztah mezi inflací a nezaměstnaností, vyšší inflaci však lidé po čase zakomponují do svých očekávání. To povede k posunu krátkodobé Phillipsovy křivky. Nezaměstnanost se vrátí na svou přirozenou míru, avšak při vyšší inflaci. Chtějí-li tvůrci



ZDROJ: VYSOKÁ ŠKOLA FINANČNÍ A SPRÁVNÍ

hospodářské politiky udržet skutečnou míru nezaměstnanosti pod její přirozenou mírou, bude to mít za následek nepřetržité zvyšování míry inflace.

Krátkodobě existuje substituce mezi inflací a nezaměstnaností (krátkodobá Phillipsova křivka SPC)

Dlouhodobě neexistuje substituce mezi inflací a nezaměstnaností (dlouhodobá Phillipsova křivka LPC)

RACIONÁLNÍ OČEKÁVÁNÍ (LUCAS):

- Racionální očekávání představují širší koncept než adaptivní očekávání. Podle této hypotézy ekonomický subjekt bere při formování svých očekávání v úvahu všechny relevantní informace (minulý, současný i budoucí vývoj). Jde o nejlepší odhad za dané situace (z daných informací). Vylučuje systematické chyby.
- Spotřebitel při rozhodování pracuje i s očekáváními ohledně budoucího vývoje, jako například s očekávanými změnami ve vládní politice. Model spotřební funkce se specifikuje ve tvaru $C_t = \beta_1 + \beta_2 E_{t-1}(Y_t) + u_t$, kde $E_{t-1}(Y_t)$ je neměřitelná, pouze očekávaná výše důchodu v libovolném období t , v níž jsou zahrnuty veškeré informace dostupné spotřebiteli na konci předcházejícího období. V případě inflace nedochází k odchylce skutečné a přirozené nezaměstnanosti. Například při zvýšení peněžní zásoby subjekty hned přizpůsobí svá očekávání: vědí, že inflace vzroste, hned to promítnou do změn mezd a cen, a nezaměstnanost ani důchod se tedy nezmění. V tomto případě krátkodobá Phillipsova křivka neexistuje.

ZDROJE

Hušek, R: Ekonometrická analýza. Nakladatelství Oeconomica, Praha 2007.

Krkošková, Š., Ráčková, A., Zouhar, J.: Základy ekonometrie v příkladech. Nakladatelství Oeconomica, Praha 2010.

Mach: Ekonomie

http://is.vsfs.cz/el/6410/leto2006/BP_MaE/58048/wawuctextmakro8.pdf