

Prognostické metody

Vymezení prognostiky

Prognostika je v širším slova smyslu část teorie poznání vztahující se k budoucnosti

Ekonomické procesy mají objektivní charakter

Prognóza x predikce x hypotéza

Klasifikace prognóz

Dle délky prognostického horizontu

Dle předmětu prognózování

Dle typu prognóz:

Event outcome forecasts

Event timing forecasts

Time series forecasts

Event outcome forecasts

Narodí se chlapec či dívka?

Kdo vyhraje volby?

Jakou známku dostanu z prognostických metod? ... Dostanu ji?

...

Event timing forecasts

Kdy budou v ČR volby?

Kdy nastane zlomový bod v ekonomice? (leading indicator)

Kdy ČNB změní sazby?

....

Time series forecasts

Časová řada je sekvence hodnot dané proměnné, jež je zaznamenávána (obvykle) v pravidelných intervalech.

Proměnná – x_t , kde $t=1, \dots, n$

Jaké bude nabývat hodnoty v čase $n+h$?

h reprezentuje počet period (období) prognostického horizontu.

x_t je sekvence náhodných proměnných, stejně tak i x_{n+h}

Proměnná x_t může být popsána pravděpodobnostními charakteristikami

Distribuční funkce; funkce hustoty pravděpodobnosti;

Průměr a rozptyl

Rozdělení pravděpodobnosti podmíněně na disponibilních informacích v čase n .

Intervalová prognóza x bodová prognóza

Trace forecast

Informační (datová) základna

Informační základna (I_n):

$$I_n: x_{n-j}, j \geq 0$$

$$I_n: x_{n-j}, y_{n-j}, z_{n-j}, \text{ etc.}, j \geq 0$$

Misspecification

Under-parameterisation

Over-parameterisation

Informační základna:

Vhodná – minulá a současná data

Nevhodná – suboptimální (podmíněná) prognóza

Informační základna:

Numerická data

Informace nenumerického charakteru

Nákladová funkce prognóz

Kritérium výběru nejlepší prognózy

$$C(e) = Ae^2$$

Kritérium = $\min C(e)$

Členění prognostických metod

Prognostické metody

Orientačně, podle míry subjektivity, lze klasifikovat prognostické metody na subjektivní, objektivní a systémové modely. Charakteristika prognostických metod v tomto pojetí ale neznamená předurčení prognóz sestavených převážně na základě subjektivních metod na prognózy méně kvalitní ve srovnání s prognózami, které využívají ve větší míře objektivní metody. Jak objektivní tak subjektivní metody mají své přednosti a nedostatky a jde spíše o využívání předností obou prognostických směrů. Určitou syntézu subjektivních a objektivních metod představují systémové modely.

Subjektivní metody

Metoda srovnávací (analogických úsudků) spočívá v nalezení analogie ve vývoji systémů obdobných jak z hlediska obsahové struktury, tak časových a místních podmínek. V ekonomických prognózách se používá zejména historické analogie, která při dodržení podmínky odpovídající srovnatelnosti může poskytnout v krátké době a s nízkými náklady na jednotku informace požadované prognostické poznatky.

Analýza dokumentů se vztahuje jak k textovým, tak k elementárním statistickým podkladům, které poskytují informace o objektu prognózy. Pokud jsou informace úplné, metoda umožňuje získat komplexní přehled o daném problému. Plnému využití této metody brání mnohdy značná nesourodost podkladových materiálů s vysokými nároky na stanovení skutečných vývojových tendencí.

Při normativní metodě se využívá prognóz sestavených pro hlavní výrobky. Na základě příslušných normativů se odvozuje prognóza pro výrobky, které jsou v závislosti na hlavním výrobku – buď jako výrobky sdružené, nebo které tvoří doplněk, příslušenství nebo náhradní díl výrobku hlavního. Přesnost takto odvozených prognóz zcela závisí na kvalitě působení prognózy. Normativní metoda je obdobou analogické metody.

Podstatou metody dotazování je zjištění názoru odborníků na vývoj předmětu prognózy. Dotazy jsou kladeny ústní nebo písemnou formou. Předností písemných dotazů je menší časová náročnost na shromáždění příslušných informací a stejný systém kladení otázek, který není při ústním dotazování zcela zaručen.

Způsob organizace a zpracování dotazování je podrobně popsáno v tzv. delfské metodě. Jedná se o etapové zjištění názoru odborníků, při němž se dotazy formulují nejdříve obecně, pak se postupně zpřesňují a konkretizují směrem od obecného ke zvláštnímu. Dotazy jsou formulovány tak, aby bylo možné statistické zpracování ve formě zjištění mediánů a kvartilů, zmenšení kvartilových intervalů a korelace mezi hodnotami časových horizontů objevu při dvou pravděpodobnostech 0,5 a 0,9, mezi nimiž se předpokládá psychologická souvislost. Předností metody je dosažení konkrétního závěru ještě v etapě dotazování.

Obdobou delfské metody je tzv. brainstorming - burza nápadů, při němž jsou dotazy kladeny ústní formou kolektivu odborníků různých profesí, případně neoborníků, mezi nimiž nejsou žádné zábrany pro vyjádření jakýchkoliv námětů a idejí. Nenucená a otevřená forma diskuse je podmínkou úspěchu této metody. Na rozdíl od delfské metody diskuse nemusí vyústit v konkrétní závěr. Zhodnocení utříděných námětů vzešlých z diskuse, která se zaznamenává, představuje závěrečnou etapu brainstormingové metody.

Charakteristickým rysem metody dotazování v jejích různých variantách je přenesení řešení prognostického úkolu z větší části na dotazované - není to jistě jediný důvod značného rozšíření těchto metod. Soubor dotazovaných pak vlastně představuje prognostický tým a na jeho složení do značné míry závisí kvalita prognózy.

Objektivní metody

Objektivní metody používané v prognostické činnosti vycházejí z poznatků statistiky a aplikované matematiky, nebo jsou jejich kombinací. Ze statistických metod se jedná zejména o zkoumání založené na analýze trendových funkcí, modelů časových řad a regresních modelů.

Analýzu trendových funkcí lze rozdělit do dvou navazujících etap. První etapou je stanovení trendové funkce. V ekonomických prognózách se jedná zpravidla o neperiodické časové řady s náhodným kolísáním. K jejich vyrovnání se používá řady funkcí, z nichž největšího rozšíření doznaly funkce lineární, mocinná (dvojlogaritmická), semilogaritmická, exponenciální, kvadratická, hyperbolická a logistická (tzv. S-funkce).

Modely časových řad – ARIMA modely

Mezi objektivní metody patří dále prognostické postupy, které využívají poznatků aplikované matematiky. Jedná se zejména o strukturální analýzu, matematické programování a síťovou analýzu.

Značného rozšíření v prognostických pracích doznala zejména strukturální analýza, která vychází z klasického Leontěvova modelu. Input-output analysis of the Economy of USA. Umožňuje vyčíslit výslednou spotřebu při požadované hrubé produkci, úroveň hrubé produkce při požadované spotřebě, nebo řešení smíšeného úkolu. Kromě těchto základních propočtů lze vyjádřit vliv ekonomických nástrojů řízení, včetně cenových, na reprodukční proces a jeho výsledky.

Strukturální analýza patří k metodám, které v prognostické činnosti respektují normativně cílový postup formulace prognóz. Obdobně je tomu v případě modelů matematického programování. Bilanční modely lze v kombinaci se simplexovými modely považovat za další obohacení prognostických nástrojů.

Ve srovnání s ostatními prognostickými metodami předností modelů matematického programování je možnost formulace účelové funkce.

Ostatní metody operační analýzy ve větším měřítku nebyly pro sestavení prognóz využívány. Za zmínku stojí metody síťové analýzy, které lze využít k prognóze časových úseků, v nichž vývoj předmětu prognózy dosáhne předem definovaného stadia nebo požadovaného stavu.

Systémové modely

Mezi nejslibnější metody prognostické činnosti patří systémové modely. Prognostické systémové modely využívají jak objektivních, tak subjektivních metod pro vyjádření budoucnosti jako struktury, v níž jsou všechny dílčí prvky ve vzájemných souvislostech a interakcích. Systémový přístup je způsob chápání reality, který nemění základní metodologické nástroje prognózování. Systémový přístup při sestavování prognóz představuje účinný pořádací princip, který přispívá k dosažení souladu prognózy a skutečného vývoje.

Vlastnosti časových řad, modely časových řad

Časová řada – věcně a prostorově srovnatelná pozorování (dat), která jsou jednoznačně uspořádána z hlediska času ve směru minulost – přítomnost.

Analýza časových řad – soubor metod, které slouží k popisu těchto řad a případně k předpovídání jejich budoucího chování.

Elementární charakteristiky časových řad

Obvykle prvním úkolem při analýze časové řady je získat rychlou a orientační představu o charakteru procesu, který tato řada reprezentuje.

Vizuální analýza

Grafy

Elementární char. (diference různého řádu, tempa a prům. tempa růstu, prům. čas. řady aj.)

Přístupy k modelování časových řad

Výchozím principem je jednorozměrný model:

$$Y_t = f(t; u)$$

k němuž se v zásadě přistupuje trojím způsobem

A) Klasický (formální) model

Dekompozice časové řady na 4 složky

$$Y = T + S + C + u$$

B) Box-Jenkinsova metodologie

Tento přístup považuje za základní prvek časové řady náhodnou složku a snaží se ji modelovat. Těžiště postupu se klade na korelační analýzu více či méně závislých pozorování, uspořádaných do tvaru časové řady.

C) Spektrální analýza

V tomto přístupu se časová řada považuje za „směs“ sinusovek a kosinusovek o rozličných amplitudách a frekvencích. Tato koncepce umožňuje provést explicitní popis periodického chování časové řady a především vystopovat ty významné složky periodicity, které se podílejí na věcných vlastnostech zkoumaného procesu. V tomto přístupu tedy není stěžejním faktorem časová proměnná, ale právě faktor frekvenční.

Vlastnosti stochastických časových řad

Stochastický proces lze označit jako nekonečnou posloupnost náhodných veličin uspořádaných v čase.

Možnost realizace každého pozorování je dána funkcí rozdělení pravděpodobnosti $f(Y_t)$.

Modelování konkrétního stochastického procesu proto vyžaduje, co nejpřesněji popsat povahu náhodnosti.

Skutečná povaha zpravidla neznámá.

Aproximativně pomocí zjednodušeného modelu časové řady.

Čím přesněji popisuje stochastický model časové řady charakteristiky skutečného rozdělení pravděpodobnosti, tím lepší je jeho schopnost predikce.

Stacionarita a nestacionarita časových řad

Popis stochastického procesu – společné (simultánní) rozdělení pravděpodobnosti hodnot náhodné veličiny Y_t , tj. $(Y_{R+1}, Y_{R+2}, \dots, Y_{R+T})$.

Komplikované

Používá se 1. a 2. moment realizovaných hodnot

Stacionarita

Definice: časová řada y_t je stacionární, jestliže její rozdělení pravděpodobnosti je v čase neměnné, tj. společné (rozdělení) pravděpodobnosti ($y_{R+1}, y_{R+2}, \dots, y_{R+T}$) není závislé na R .

Striktní stacionarita

Slabě stacionární proces (2. řádu) – průměr a rozptyl je konstantní, přičemž kovariance libovolných dvou pozorování časové řada závisejí pouze na velikosti zpoždění, tj. na délce časového posunu mezi nimi, nikoliv na hodnotě R .

Nestacionární časové řady

- Trend
- Sezónnost
- Strukturální šoky v ekonomice

Zjišťování nestacionarity

- ACF
- Testy jednotkového kořene

Modely časových řad

ARIMA modely

Použití ke krátkodobé predikci a to v situaci, kdy nejsou k dispozici adekvátní data vysvětlujících proměnných, resp. když při odhadu a verifikaci LRM nebo MSR dospějeme k závěru, že odhadnuté parametry jsou z hlediska ekonomických, statistických i ekonometrických kritérií nepoužitelné. Nebo má-li model špatné prognostické vlastnosti.

Modely náhodných procházek

Jednoduchý stochastický proces

Proces je nestacionární, neboť průměr a rozptyl nejsou konstantní

$I(1)$

Použije-li se proces tohoto typu k popisu dynamického chování, např. cen akcií nebo spotřebitelských cen, jde o nestacionární model časových řad.

Avšak časové řady cenových změn jsou již generovány stacionárním ryze náhodným procesem, nazývaným také jako bílý šum.

Pro krátkodobou předpověď na základě modelu náhodné procházky platí

$$y_{t+1} = y_t + E(u_{t+1}) = y_t$$

Modely klouzavých průměrů (MA)

Jedna z možností modelování dynamiky stacionárních časových řad

Např. analýza vývoje změn cen akcií, kdy tato posloupnost změn cen s nulovým průměrem a konstantním rozptylem lze zapsat:

$$Y_t = u_t$$

u_t jsou identicky rozdělené náhodné složky, sériově nezkorelované. Odrážejí působení neočekávaných vlivů na cenu akcií např. informace o finanční situaci podniku.

Lze předpokládat, že všechny nové informace nejsou trhem absorbovány během 1 dne, proto změnu pro příští den lze vyjádřit jako:

$$y_{t+1} = u_{t+1} + a u_t$$

Přičemž u_{t+1} reprezentuje vliv nové informace (inovace), která vešla ve známost v průběhu dne $t+1$, zatímco výraz $a u_t$ odráží doznívající působení informace z předešlého dne.

Vzhledem k tomu, že procesem MA(1) generovaná pozorování y_t jsou zkorelována pouze se sousedními pozorováními, tj. y_{t-1} a y_{t+1} , říkáme, že proces MA(1) má paměť pouze jedno období, tj. zapomíná vše, co se událo se zpožděním větším než jedno období.

Autoregresní modely (AR)

Jiný přístup k modelování časové struktury stacionárních časových řad.

Vyjádření y_t jako funkce několika předcházejících pozorování.

Autoregresní modely klouzavých průměrů - ARMA

V praxi při modelování čas. řad se setkáváme s případy, kdy stacionární náhodný proces, generující jejich jednotlivá pozorování, nevyhovují zcela předpokladům MA, resp. AR, modelů. V této situaci je adekvátní taková specifikace modelu časové řady, jejíž složky vycházejí z principu kombinace AR a MA procesů.

Smíšený model čas. řady, se nazývá ARMA (p,q) model, přičemž p výrazů je autoregresního typu a q reprezentuje zpožděné klouzavé průměry.

Autoregresní integrované modely klouzavých průměrů - ARIMA

Kromě stacionárních stochastických procesů se používají při specifikaci modelů časových i nestacionární procesy.

I(d)

Nejsou-li stacionární časové řady smíšeného typu, takže jejich pozorování jsou generována pouze buď AR, resp. MA, procesem, pak Y_t mají charakter integrovaného autoregresního procesu řádu (p,d), značeného jako ARI (p,d,0) nebo integrovaného procesu klouzavých průměrů řádu (d,q), který se značí IMA (0,d,q).

Zvláštním případem procesu ARIMA, kterým lze generovat časové řady vykazující trend, je proces SARIMA, používaný k modelování čas. řad multiplikativně sezónního typu, tj. zatížených stochastickou sezónností (opět možné modifikace na SAR, SMA, resp. SARMA).

Specifikace Modelu ARIMA (p,d,q)

1. fáze – linearizace časové řady
2. fáze – určení řádu integrace (homogenity) časové řady
Stacionární časová řada = integrovaná řádu 0
Nestacionární č. ř. = integrovaná řádu d
3. fáze – nalezení hodnot p a q, tj. délky zpoždění AR a MA
4. fáze – odhad modelu
5. fáze – verifikace modelu
6. fáze – aplikace - prognózy

2. fáze - Autokorelační funkce (ACF)

Autokorelační funkce k-tého řádu

$$\rho_k = \gamma_k / \gamma_0$$

$$\gamma_k = \text{cov}(y_t, y_{t+k})$$

$$\gamma_0 = \sigma_{y_t} \sigma_{y_{t+k}} = \sigma_y^2$$

V praktické aplikaci neznáme teoretickou ACF, odhadujeme pomocí výběrové ACF k-tého řádu

Grafickým znázorněním pro různé hodnoty k je tzv. výběrový korelogram.

Korelogram

Stacionární čas. řada – s rostoucím k hodnota ACF klesá

Nestacionární čas. řada – s rostoucím k hodnota ACF neklesá

3. fáze – nalezení hodnot p a q

ACF; AIC, SIC; Korigované R^2

4. fáze – odhad modelu

AR – pomocí BMNČ

MA – speciální techniky (interativního charakteru)

5. fáze – verifikace modelu

Aplikace různých kritérií za účelem ověření správnosti zvolené specifikace modelu

Nejlépe provést verifikaci shody s předpověďmi ex post.

Testování autokorelace reziduí

Výběrový korelogram reziduí

6. fáze – odvození prognózy

Předpověď s modelem MA(1)

Předpověď s modelem AR(1)

Předpověď s modelem ARMA(1,1)

Metody s nízkými náklady

Celý proces analýzy časových řad je někdy příliš zdlouhavý a nákladný.

Proto byly některé části modelování z automatizovány.

Identifikace modelu, tj. nalezení hodnot p a q, je zpravidla ponechána na analytikovi.

Jednou z metod, která ulehčuje proces volby správného tvaru modelu, je stepwise AR model.

EWMA – exponentially weighted moving average methods

Prognóza s nízkými náklady

Metoda je založena na odlišném přístupu ve srovnání s metodami předchozími. Tento přístup pokládá za nejdůležitější aspekt časové řady její průměr.

Prognóza je pak založena na odhadu průměru časové řady.

EWMA

$$\bar{x}_t = \alpha x_t + (1 - \alpha) \bar{x}_{t-1} \quad f_{t,h} = \bar{x}_t$$

Vylepšení EWMA

$$\bar{x}_t = \alpha (x_t - S_{t-12}) + (1 - \alpha) (\bar{x}_{t-1} + T_{t-1}) \quad f_{t,h} = \bar{x}_t + hT_t + S_{t+h-12}$$

$$T_t = \beta (\bar{x}_t - x_{t-1}) + (1 - \beta) T_{t-1}$$

$$S_t = \gamma (x_t - \bar{x}_t) + (1 - \gamma) S_{t-12}$$

Kterou z metod použít

ARIMA; Stepwise AR model; EWMA model

Rozhodnutí záleží na:

Času; Penězích; Disponibilních datech

Vlastnosti optimální prognózy

Chyby prognózy $e_{t,h}$ na h období prognostického horizontu by měly mít podobu MA($h-1$) modelu.

Zvláště pak chyba prognózy na jedno období dopředu $e_{t,1}$ by měla mít charakter bílého šumu.

Rozptyl $e_{t,h}$ je rostoucí s rostoucím h . S dostatečně velkým h by se měl blížit rozptylu x_t .

General to specific modelování

General to specific modelování zahrnuje formulaci neomezeného dynamického modelu (proto general), který je následně testován, transformován a redukován ve velikosti pomocí řady různých statistických testů.

Tento specifický model ve své povaze odpovídá obecnému modelu, jelikož je z něho odvozen, avšak obsahuje pouze podstatné (signifikantní) vztahy mezi proměnnými modelovaného vztahu.

ADL model

Neomezený dynamický model (jednorovnicový) je zpravidla formulován, resp. definován ve formě ADL (autoregressive distributed lag) modelu.

ADL (Autoregressive distributed lag) model je model, který obsahuje n zpožděných hodnot závisle proměnné (proto označení „autoregressive“) a p zpožděných hodnot nezávisle proměnné (proto „distributed lag“).

ADL (n,p) model

$$y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \dots + \beta_n y_{t-n} + \gamma_0 x_t + \gamma_1 x_{t-1} + \dots + \gamma_p x_{t-p} + u_t$$

kde β_0, \dots, β_n a $\gamma_0, \dots, \gamma_p$ jsou neznámé parametry pro n zpožděných hodnot endogenní proměnné a p zpoždění exogenní proměnné a u_t je náhodná složka s nulovým podmíněným průměrem, tj. $E(u_t | y_{t-1}, \dots, y_{t-n}, x_t, x_{t-1}, \dots, x_{t-p}) = 0$.

ADL (n,p) model s k proměnnými

$$y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \dots + \beta_n y_{t-n} + \gamma_0 x_t + \gamma_1 x_{t-1} + \dots + \gamma_p x_{t-p} + \dots + \gamma_{k0} x_{kt} + \gamma_{k1} x_{kt-1} + \dots + \gamma_{kp} x_{kt-p} + u_t$$

kde β_0, \dots, β_n a $\gamma_{10}, \dots, \gamma_{1p}, \gamma_{k0}, \dots, \gamma_{kp}$ jsou neznámé parametry pro n zpožděných hodnot endogenní proměnné a p zpoždění k exogenních proměnných a u_t je náhodná složka s nulovým podmíněným průměrem, tj. $E(u_t | y_{t-1}, \dots, y_{t-n}, x_t, x_{t-1}, \dots, x_{t-p}) = 0$.

DL model a význam jeho parametrů

Dílčí multiplikátory řádu i (Partial multipliers of order i) – vyjadřují mezní efekt proměnné x_{t-i} na y_t . Jinými slovy lze říci, že tyto multiplikátory ukazují vliv jednotkové změny proměnné X_t v období $t-i$, tj. i období před běžným obdobím (obdobím t), na $E(y_t)$ (ceteris paribus).

Krátkodobý multiplikátor (Short-run, or impact multiplier) – je dílčí multiplikátor řádu $i = 0$, tj. je roven γ_0 . Tento multiplikátor ukazuje, jaký má vliv jednotkový růst v x_t na $E(y_t)$ v běžném období (ve stejném období).

Střednědobé multiplikátory řádu i (Interim, or intermediate, multipliers of order i) – představují sumu prvních i dílčích multiplikátorů, tzn., že jsou rovny součtu $\gamma_0 + \gamma_1 + \gamma_2 + \dots + \gamma_i$. Tyto multiplikátory ukazují vliv jednotkové změny v x_t na $E(y_t)$ za i období vzhledem k období t , tj. za i období předcházející období t .

Dlouhodobý (celkový, rovnovážný) multiplikátor – je sumou všech dílčích multiplikátorů DL modelu. Tento multiplikátor vyjadřuje vliv jednotkové změny v x_t na $E(y_t)$ za všechna období.

ADL model a význam jeho parametrů

Dílčí multiplikátory řádu i – nabývají stejného významu jako v případě DL modelu.

Krátkodobý multiplikátor (Short-run, or impact multiplier) – je opět shodný s krátkodobým multiplikátorem u DL modelu, tj. je roven γ_0 .

Střednědobé multiplikátory řádu I – jsou multiplikátory, které ukazují vliv jednotkové změny v x_t na $E(y_t)$ za I období vzhledem k období t , tj. za I období předcházející období t . Vzhledem k tomu, že na pravé straně rovnice se vyskytují zpožděné hodnoty závisle proměnné, je nutné zohlednit jejich vliv.

Střednědobý multiplikátor řádu I

$$\Delta \hat{y}_t = \gamma_0 \Delta x_t$$

$$\Delta y_{t+1} = \beta_1 \Delta y_t + \gamma_1 \Delta x_t$$

$$\Delta \hat{y}_{t+2} = \beta_2 \Delta \hat{y}_t + \beta_1 \Delta \hat{y}_{t+1} + \gamma_2 \Delta x_t$$

$$\Delta \hat{y}_{t+2} = \beta_2 \Delta \hat{y}_t + \beta_1 (\beta_1 \Delta \hat{y}_t + \gamma_1 \Delta x_t) + \gamma_2 \Delta x_t$$

$$\Delta \hat{y}_{t+2} = [\beta_2 \gamma_0 + \beta_1 (\beta_1 \gamma_0 + \gamma_1) + \gamma_2] \Delta x_t$$

$$\Delta \hat{y}_{t+2} = w_2 = \beta_2 \gamma_0 + (\beta_1 \beta_1 \gamma_0 + \gamma_1) + \gamma_2$$

Dlouhodobý multiplikátor ADL modelu

Dlouhodobý (celkový, rovnovážný) multiplikátor – je multiplikátor, který vyjadřuje vliv jednotkové změny v x_t na $E(y_t)$ za všechna období a je totožný se střednědobým multiplikátorem za předpokladu, že $I=(p=n)$.

ADL model a kointegrační analýza

$$Y^* = \frac{\alpha}{(1 - \beta_1 - \dots - \beta_n)} + \frac{\gamma_0 + \gamma_1 + \dots + \gamma_p}{(1 - \beta_1 - \dots - \beta_n)} X^* = \frac{\alpha}{1 - \sum_{j=1}^n \beta_j} + \frac{\sum_{i=0}^p \gamma_i}{1 - \sum_{j=1}^n \beta_j} X^* = \alpha^* + \gamma^* X^*$$

Model ADL(1,1)

Existuje nejméně deset ekonomicky smysluplných specifických modelů, které mohou být odvozeny z výše uvedeného obecného modelu při uvalení restrikcí na parametry β_1 , γ_0 a γ_1 .

$\beta_1 = \gamma_1 = 0$ Při uvalení nulových restrikcí na parametry β_1 a γ_1 se model zjednoduší na statickou regresi.

$\gamma_0 = \gamma_1 = 0$ Za předpokladu nulových parametrů γ je specifický model autoregresním modelem prvního řádu AR(1).

$\beta_1 = \gamma_0 = 0$ Specifický model se zpožděnou exogenní proměnnou se nazývá modelem předbíhajícího indikátoru.

$\beta_1 = 1, \gamma_0 = -\gamma_1$ Při takovýchto hodnotách parametrů se jedná o rovnici v prvních diferencích.

$\beta_1 = 0$ Model bez zpožděné endogenní proměnné se nazývá konečný distributed lag model prvního řádu, tj. DL(1)

$\gamma_1 = 0$ Za předpokladu nulové restrikce na parametr γ_1 je model nazýván modelem částečného přizpůsobení.

$\gamma_0 = 0$ V situaci uvalení nulové restrikce na parametr γ_0 se jedná o tzv. „dead-start“ model se zpožděnou informací.

$\gamma_1 = -\beta_1$ Model, ve kterém parametr $\gamma_1 = -\beta_1$ je označován jako model proporcionalní odezvy a vysvětlujícími proměnnými jsou x_t a $(y_{t-1} - x_{t-1})$.

$\beta_1 - 1 = -(\gamma_0 + \gamma_1)$ Příklad 9, tj. model, kde $\beta_1 - 1 = -(\gamma_0 + \gamma_1)$, je poněkud složitější v odvození. Pro získání jeho tvaru je nutné vyjádřit model ADL(1,1) v prvních diferencích s kointegračním vektorem, tj. s error-correction mechanismem. Je tudíž třeba od obou stran rovnice ADL(1,1) odečíst y_{t-1} a přičíst a odečíst $\gamma_0 x_{t-1}$ k pravé straně rovnice.

$\gamma_1 = -\beta_1 \gamma_0$ Restrikce 10 je nazývána common factor nebo též COMFAC restrikce.

Předpoklady modelu ADL

- $E(u_t | y_{t-1}, \dots, y_{t-n}, x_{1t}, x_{1t-1}, \dots, x_{1t-p}, \dots, x_{kt}, x_{kt-1}, \dots, x_{kt-p}) = 0$;
- (a) náhodné proměnné $(y_t, x_{1t}, \dots, x_{kt})$ jsou stacionární;
- (b) $(y_t, x_{1t}, \dots, x_{kt})$ a $(y_{t-j}, x_{1t-j}, \dots, x_{kt-j})$ jsou nezávislé s dostatečně velkým j ;
- x_{1t}, \dots, x_{kt} a y_t mají nenulové a konečné první čtyři momenty;
- nepřítomnost perfektní multikolinearity.

Volba délky zpoždění ADL (n,p) modelu

- F-test
- Maximalizace korigovaného R^2
- Minimalizace Akaikeho informačního kritéria
- Minimalizace Bayesova (nebo také Schwarzova) informačního kritéria

$$\bar{R}^2 = 1 - \frac{n-1}{n-q}(1-R^2) \quad AIC = \ln\left(\frac{SSR}{n}\right) + \frac{2q}{n} \quad BIC = \ln\left(\frac{SSR}{n}\right) + \frac{q}{n} \ln(n)$$

Ačkoliv jsou informační kritéria založena na stejném principu, tj. ohodnocení efektů a nákladů zahrnutí dodatečných zpožděných proměnných, mohou poskytovat vzhledem k různému ocenění těchto efektů či nákladů různé výsledky. Volba správné délky zpoždění pak závisí na postojích a preferencích autora modelu.

Přechod od obecného modelu ke specifickému

Testování významnosti i-tého zpoždění

- F-test
- Grangerova kauzalita
 - Test Grangerovy kauzality
 - Statistika Grangerovy kauzality – F-test

Odvození prognózy z ADL (n,p) modelu

Krátkodobá prognóza

$$f_{n,1} \text{ nebo } \hat{y}_{t+1} = b_0 + b_1 y_t + c_1 x_t$$

$$f_{n,1} \text{ nebo } \hat{y}_{t+1} = b_0 + b_1 y_t + b_2 y_{t-1} + \dots + b_n y_{t-n+1} + c_1 x_t + \dots + c_p x_{t-p+1} + \dots + c_k x_{kt} + \dots + c_{kp} x_{kt-p+1}$$

Situace je o něco složitější obsahuje-li ADL (n,p) model vysvětlující proměnnou x , resp. proměnné x_1, \dots, x_k v běžném období t .

Odvození prognózy z ADL (n,p) modelu

Střednědobá a dlouhodobá prognóza

$$f_{n,2} \text{ nebo } \hat{y}_{t+2} = b_0 + b_1 \hat{y}_{t+1} + b_2 y_t + \dots + b_n y_{t-n+2} + c_1 x'_{1t+2} + c_1 x'_{1t+1} + \dots + c_p x'_{1t-p+2} + \dots + c_k x'_{kt+2} + c_k x'_{kt+1} + \dots + c_{kp} x'_{kt-p+2}$$

$$f_{n,h} \text{ nebo } \hat{y}_{t+h} = b_0 + b_1 \hat{y}_{t+h-1} + b_2 y_{t+h-2} + \dots + b_n y_{t-n+h} + c_1 x'_{1t+h} + c_1 x'_{1t+h-1} + \dots + c_p x'_{1t-p+h} + \dots + c_k x'_{kt+h} + c_k x'_{kt+h-1} + \dots + c_{kp} x'_{kt-p+h}$$

Chyba prognózy

Chyba prognózy se skládá ze dvou komponentů. Prvním je nejistota plynoucí z odhadu regresních koeficientů, jež má pravděpodobnostní charakter, a to i přesto, že je při splnění všech předpokladů nejlepším (lineárním), konzistentním a neštranným odhadem. Druhým komponentem je nejistota spojená s budoucí neznámou hodnotou náhodné složky – u_t .

Velikost typické chyby vzniklé použitím prognostického modelu lze vyjádřit pomocí RMSFE (Root Mean Squared Forecast). RMSFE je vypočtena jako odmocnina průměru čtverce chyby prognózy.

RMSFE

$$y_{t+1} - \hat{y}_{t+1} = u_{t+1} - [(b_0 - \beta_0) + (b_1 - \beta_1)y_t + (c_1 - \gamma_1)x_t]$$

$$MSFE = E[(y_{t+1} - \hat{y}_{t+1})^2] = \sigma_u^2 + \text{var}[(b_0 - \beta_0) + (b_1 - \beta_1)y_t + (c_1 - \gamma_1)x_t]$$

Interval prognózy

Za předpokladu normálního rozdělení náhodné složky je interval spolehlivosti prognózy dán vztahem:

$$\hat{y}_{t+1} \pm t_{\alpha} \text{ tabulkove} * SE(y_{t+1} - \hat{y}_{t+1})$$

Ex-post prognóza

Ex-post prognóza je využívána k ověření prognostických vlastností modelu, k odhadu RMSFE a k porovnání prognostických modelů mezi sebou.

VAR model

modelovaný vztah cenové transmise s použitím ADL modelu opomíjí jeden důležitý ekonomický aspekt vztahů v zemědělsko-potravinářské vertikále, a to že tyto vztahy zřejmě mají simultánní povahu. V případě, že simultánní vztahy ve vertikále existují, což lze předpokládat (viz následující hypotéza), jejich opomenutím se dopouštíme chyby specifikace, která v lepším případě má za důsledek, že ztrácíme důležitou informaci o modelovaném vztahu.

Rozšíření ekonomického modelu

$$\pi_i = P_p(Q_p) \cdot Q_{pi} - P_A(Q_A) \cdot Q_{Ai} - C_i$$

$$Q_{pi} = \frac{Q_{Ai}}{k}$$

$$\pi_i(P_p, P_A) = \max P_p(Q_p) \cdot Q_{pi} - P_A(Q_A) \cdot Q_{Ai} - C_i$$

$$\frac{\partial \pi_i(P_p, P_A)}{\partial Q_{pi}} = 0$$

$$P_p + Q_{pi} \cdot \frac{\partial P_p}{\partial Q_p} \cdot \frac{\partial Q_p}{\partial Q_{pi}} - kP_A - kQ_{Ai} \cdot \frac{\partial P_A}{\partial Q_A} \cdot \frac{\partial Q_A}{\partial Q_{Ai}} = 0$$

$$P_p + Q_{pi} \cdot \frac{\partial P_p}{\partial Q_p} \cdot \frac{\partial Q_p}{\partial Q_{pi}} = kP_A + kQ_{Ai} \cdot \frac{\partial P_A}{\partial Q_A} \cdot \frac{\partial Q_A}{\partial Q_{Ai}}$$

$$P_p \cdot (1 + \frac{\lambda_i}{e_{pp}}) = kP_A \cdot (1 + \frac{\delta_i}{e_{pA}})$$

$$P_p \cdot (1 + \frac{\lambda}{e_{pp}}) = kP_A \cdot (1 + \frac{\delta}{e_{pA}})$$

Charakteristika VAR modelování

Vektorové autoregresní modely vycházejí z myšlenky, že všechny proměnné využitě pro analýzu zvolené závislosti jsou náhodné a simultánně závislé. To znamená, že modelová struktura obsahuje pouze endogenní proměnné, přičemž jejich maximální délka zpoždění je stejná.

Další charakteristikou je, že VAR model (jeho obecná forma) nevychází striktně z ekonomické teorie.

VAR model

VAR(p) modely jsou zobecněním AR modelů na časové řady více proměnných a jejich předností je relativně jednoduchý odhad parametrů metodou nejmenších čtverců. Konstrukce modelů VAR se zpravidla rozpadá do následujících kroků:

- transformace dat na stacionární časové řady (testy jednotkových kořenů),
- volba proměnných modelu a maximální délky zpoždění,
- zjednodušení modelu redukcí maximálního zpoždění a
- ortogonalizace reziduí.

VAR model

Model VAR(p) lze zapsat ve formě, přičemž se předpokládá, že $C_s = 0$ pro $s > p$:

$$X_t = \eta + \sum_{s=1}^p C_s X_{t-s} + U_t \quad \text{kde } X_t \text{ reprezentuje k proměnných modelu,}$$

tj. v případě dvou proměnných je $X_t = \begin{bmatrix} x_{1t} \\ x_{2t} \end{bmatrix}$

Volba počtu proměnných a délky zpoždění ve VAR modelu, tj. počet k a velikost p , je v praxi často spojena s nutností uvalení nulových restrikcí, a to v závislosti na délce disponibilních časových řad. Například při zahrnutí tří proměnných do VAR modelu a při délce zpoždění 5 období je v každé rovnici odhadováno nejméně 15 parametrů (tj. v případě, že model neobsahuje deterministickou složku).

Volbu délky zpoždění ve VAR modelu lze založit stejně jako u ADL modelu na informačních kritériích (viz AIC, SIC, aj.).

Velmi důležitým, ale též často přehlíženým rysem VAR modelu je, že náhodné složky výše uvedeného vztahu mají nenulové kovariance. Tento významný rys umožňuje odvození „strukturální“ alternativy ke klasickým ekonometrickým modelům, která je konzistentní s danou ekonomickou teorií a umožňuje aplikaci modelu v ekonomické analýze.

Ortogonalizace reziduí

Odvození „strukturální“ alternativy spočívá v transformaci VAR modelu do formy mající „ortogonální inovace“ (ortogonální rezidua). Jinak řečeno model je transformován tak, aby neobsahoval korelované náhodné složky.

Postup ortogonalizace reziduí lze názorně demonstrovat na příkladu jednoduchého VAR modelu obsahujícího dvě proměnné x_t a y_t a majícího dvě zpoždění ve VAR prostoru.

$$\begin{bmatrix} x_t \\ y_t \end{bmatrix} = \begin{bmatrix} a_1 & b_1 \\ c_1 & d_1 \end{bmatrix} \begin{bmatrix} x_{t-1} \\ y_{t-1} \end{bmatrix} + \begin{bmatrix} a_2 & b_2 \\ c_2 & d_2 \end{bmatrix} \begin{bmatrix} x_{t-2} \\ y_{t-2} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix}$$

kde náhodné složky jsou souběžně korelovány, tj:

$$E(u_{1t}) = E(u_{2t}) = 0; \quad E(u_{1t}^2) = \sigma_{11}; \quad E(u_{2t}^2) = \sigma_{22}; \quad E(u_{1t} \cdot u_{2t}) = \sigma_{12}$$

Pro získání modelu, ve kterém nebudou náhodné složky souběžně korelovány, lze první řádek vztahu vynásobit

$$\delta = \frac{\sigma_{12}}{\sigma_{11}} \quad \text{a výsledek odečíst od druhého řádku.}$$

$$\begin{bmatrix} x_t \\ y_t - \delta x_t \end{bmatrix} = \begin{bmatrix} a_1 & b_1 \\ c_1^* & d_1^* \end{bmatrix} \begin{bmatrix} x_{t-1} \\ y_{t-1} \end{bmatrix} + \begin{bmatrix} a_2 & b_2 \\ c_2^* & d_2^* \end{bmatrix} \begin{bmatrix} x_{t-2} \\ y_{t-2} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t}^* \end{bmatrix}$$

kde

$$c_s^* = (c_s - \delta a_s); \quad d_s^* = (d_s - \delta b_s); \quad u_{2t}^* = (u_{2t} - \delta u_{1t})$$

Hodnoty σ_{ij} jsou zpravidla neznámé a musí být odhadnuty. Myšlenka ortogonalizace reziduí spočívá v možnosti využití jednotlivých rovnic VAR modelu odděleně v ekonomické analýze. V tomto smyslu lze ekonomickou analýzu chápat jako analýzu, která se zabývá vlivem známého šoku nebo též „ortogonální inovace“ na zkoumaný systém (vztah)

Impulse-response analýza

Výše uvedený proces ortogonalizace reziduí lze využít v dynamické simulaci, ve které zkoumáme reakce proměnných na jednotlivé exogenní šoky (inovace) v čase t . Jinými slovy se zajímáme o to, jak se bude měnit proměnná y při jednotkové změně x . V případě dvourovnicového VAR(1) modelu lze takovou změnu zkoumat tak, že se o jednotku bude měnit náhodná složka u_{1t} rovnice x , která bude determinovat y . Výsledný efekt je stejný jako, když by se měnila o jednotku proměnná x .

Impulse-response funkce

$$\begin{bmatrix} x_t \\ y_t \end{bmatrix} = \sum_{i=0}^{\infty} \begin{bmatrix} a_1 & b_1 \\ c_1 & d_1 \end{bmatrix}^i \begin{bmatrix} 1 & 0 \\ \delta & 1 \end{bmatrix} \begin{bmatrix} u_{1t-i} \\ u_{2t-i}^* \end{bmatrix}$$

kde

$$u_{2t}^* = (u_{2t} - \delta u_{1t}) \quad a \quad \delta = \sigma_{12} / \sigma_{11}$$

$$\begin{bmatrix} x_t \\ y_t \end{bmatrix} = \sum_{i=0}^{\infty} \begin{bmatrix} \phi_{11}^{(i)} & \phi_{12}^{(i)} \\ \phi_{21}^{(i)} & \phi_{22}^{(i)} \end{bmatrix} \begin{bmatrix} u_{1t-i} \\ u_{2t-i}^* \end{bmatrix}$$

Význam elementů v I-R funkci

Význam pro jednotlivá i lze vymežit následovně:

ϕ_{21}^0 reprezentuje očekávaný okamžitý vliv jednotkové změny v u_{1t} na y_t .

ϕ_{21}^1 je očekávaná reakce v prvním období na jednotkovou změnu v u_{1t} na y_t .

Odvození prognózy z VAR modelu

VAR modely poskytují dvě velké výhody při jejich aplikaci v prognostické činnosti. Jednak nemusíme věnovat takovou pozornost ekonomické teorii při specifikaci modelu, a to vzhledem k tomu, že zde nerozlišujeme mezi endogenními a exogenními proměnnými a dále zde nejsou uvalovány žádné nulové restrikce. Druhou a důležitější výhodou je, že se nemusí přijímat žádné předpoklady o hodnotách exogenních proměnných v prognostickém horizontu ve srovnání se standardními ekonometrickými prognózami, které jsou podmíněné na znalostech hodnot exogenních proměnných.

Je-li abstrahováno od korelace mezi rezidui jednotlivých rovnic, lze prognózu z VAR modelu odvodit mechanicky. V prvním období je způsob analogický odvození prognózy z ADL modelu, tj. dosazením známých hodnot zahrnutých proměnných v modelovaném vztahu. Pro další období prognostického horizontu se prognóza odvodí rekurzivně podmíněně na prognózách v obdobích, pro které skutečné hodnoty nejsou známy. To lze přehledně zapsat následovně:

$$f_{n,1} \text{ nebo } \hat{X}_{kT+h} = \eta + \sum_{s=1}^p C_s \hat{X}_{kT-s+h} \quad \hat{X}_{kT-s+h} = \begin{cases} \hat{X}_{kT-s+h} & \text{pro } h > s \\ X_{kT-s+h} & \text{pro } h \leq s \end{cases}$$

Kointegrační analýza

Transformací, tzn. převodem nestacionárních časových řad na stacionární (např. diferencováním u řad majících stochastický trend) ztrácí časové řady z ekonomického hlediska velmi důležitou informaci o jejich dlouhodobých vztazích.

Kointegrační analýza umožňuje řešit rozpor vzniklý mezi statistickými požadavky a ekonomickými potřebami.

Předpokládejme, že proměnné Y_t a X_t jsou integrované stejného řádu a vyjádříme jejich vztah v jednoduchém statickém modelu:

$$Y_t = \gamma X_t + u_t$$

Nyní mohou nastat 3 situace:

- proces u_t má charakter bílého šumu, tj. je typu $I(0)$,
- proces u_t je stacionární a autokorelovaný a je rovněž typu $I(0)$,
- proces u_t je typu $I(1)$, tj. je integrován řádem jedna.

V prvním případě jsou proměnné kointegrované, tzn. je mezi nimi dlouhodobý vztah (směřují k rovnovážnému stavu). Dlouhodobým multiplikátorem je regresní parametr γ .

V druhém případě jsou proměnné také kointegrované. V této situaci lze psát $u_t = \beta u_{t-1} + \varepsilon_t$, kde ε_t je proces bílého šumu, pak model lze přepsat do tvaru ADL (1,1), tj.:

$$Y_t = \beta Y_{t-1} + \gamma X_t - \beta \gamma X_{t-1} + \varepsilon_t$$

Dlouhodobý multiplikátor (δ) vyjadřující dlouhodobý vztah má v tomto případě podobu:

$$\delta = \gamma (1+\beta)/(1-\beta)$$

Poslední případ neobsahuje kointegrované časové řady a tudíž neobsahuje dlouhodobý multiplikátor.

Myšlenka kointegrační analýzy

Myšlenka kointegrační analýzy je založena na vztahu, který mají ekonomické proměnné mezi sebou v dlouhém období. Takovýto vztah může být konvergující k rovnovážnému stavu v dlouhém období nebo naopak divergující. Jestliže ekonomické proměnné od sebe v krátkém období divergují a tato divergence nemá hranice, pak mezi proměnnými rovnovážný stav není. Je-li ovšem divergence od rovnovážného vztahu v určitých mezích, resp. stochastická, a po určitém čase se vytrácí, pak lze proměnné označit za kointegrované, jelikož v dlouhém období směřují k rovnovážnému vztahu.

Definice kointegrace

Engle a Granger (1987) definují kointegraci mezi dvěma proměnnými následovně:

Definice: časové řady x_t a y_t jsou kointegrované řádu d , b , kde $d \geq b \geq 0$, v zápisu jako $x_t, y_t \sim CI(d,b)$,

jestliže: obě časové řady jsou integrovány řádu d ,

existuje lin. kombinace těchto čas. řad (proměnných), tj. $\alpha_1 x_t + \alpha_2 y_t$, která je integrována řádu $d - b$.

Vektor $[\alpha_1, \alpha_2]$ se nazývá kointegrační vektor.

V praktické aplikaci je nejzajímavější případ, kdy se časové řady při použití kointegračního vektoru stávají stacionárními, tj. kde $d = b$. V takovém případě obsahuje kointegrační vektor parametry dlouhodobého vztahu mezi proměnnými.

Ekonomické časové řady jsou zpravidla integrovány řádu 1. Máme-li proměnné integrovány řádu 1 potom, aby byly kointegrované musí splňovat:

$$x'_t \cdot \alpha \sim CI(1, 1).$$

Důležitost kointegrační analýzy

Důležitost kointegrační analýzy v modelování nestacionárních časových řad lze vymezit dle Banerjee A., et al. (2003) v následujících třech bodech:

- Jestliže existuje rovnovážný vztah mezi proměnnými, tj. je-li lineární kombinace proměnných stacionární, pak lze počítat s tím, že tato lineární kombinace se vrací ke svému průměru (zpravidla nulovému).
- Ekonometrický model, který obsahuje nestacionární proměnné má smysl tehdy a jen tehdy, jsou-li proměnné kointegrované. V opačném případě se jedná o tzv. zdánlivou regresi (spurious regression).
- Jestliže jsou proměnné kointegrované, lze sestavit error-correction model, který obsahuje jak dlouhodobý vztah mezi proměnnými (tj. kointegrační vektor), tak odchylku proměnných od rovnovážného vztahu.

VECM

VECM lze formálně zapsat ve formě:

$$\Delta X_t = \eta + \Pi X_{t-1} + \sum_{s=1}^p C_s \Delta X_{t-s} + u_t$$

kde $C_s = 0$ pro $s > p$, X_t je $k \times 1$ vektor proměnných integrovaných řádu 1, tj. $I(1)$, u_1, \dots, u_t jsou iid $(0, \Sigma)$ a Π je matice dlouhodobého vztahu.

Konstrukce modelů VECM

Konstrukce modelů VECM se podobně jako konstrukce VAR modelu skládá z následujících kroků: testy jednotkových kořenů, určení (odhad) kointegračního vektoru, volba proměnných modelu a maximální délky zpoždění, odhad modelu, zjednodušení modelu redukcí maximálního zpoždění a ortogonalizace reziduí.

Specific to general modeling

Specific-General přístup je ekonometrickým přístupem, který reprezentuje tradiční ekonometrické modelování. Toto modelování je založeno na přesně definovaném vztahu (rovnici), který vychází z ekonomické teorie. Model je vystaven na předpokladu nulového průměru náhodné složky, nepřítomnosti autokorelace a heteroskedasticity náhodné složky, specifikačních předpokladech a neexistenci perfektní multikolinearity. Z toho plyne, že za předpokladu stability prostředí nejčastěji používaná metoda nejmenších čtverců poskytuje nejlepší a nezkreslené lineární odhady.

Nevýhody tradičního přístupu

Testy statistických a ekonometrických vlastností modelu nemají stanovené pořadí. Vzhledem k neomezenému počtu diagnostických testů není zřejmé, zda-li byl odhadnut nejlepší model. Podmíněný charakter testů rovněž neumožňuje určit skutečnou hladinu významnosti aplikovaných testů, jelikož není známo skutečné rozdělení pravděpodobnosti.

Fáze ekonometrického modelování

- Ekonomická teorie – studium dokumentu
- Tvorba ekonomického modelu
- Tvorba ekonometrického modelu
- Sběr, zpracování a analýza vstupních dat
- Odhad parametrů ekonometrického modelu
- Ekonomické ověření modelu – interpretovatelnost
- Statistické a ekonometrické ověření
- Aplikace ekonometrického modelu nebo jeho zamítnutí, které vrací postup k bodu (1)

„Základem každé vědy je soubor jistých znalostí. To, co z těchto izolovaných poznatků dělá skutečnou vědu je, že tyto poznatky logicky uspořádáme, vytvoříme z nich systém. A k tomu slouží logika. Pomocí logického myšlení, logickým odvozováním získáváme z daných faktů nová fakta nebo hypotézy (poslední opět konfrontujeme s experimentem, neboť by se mohlo stát, že výchozí poznatky nezobrazují skutečnost správně)...“ (Kopáček, 2004).

Při odvození ekonomického modelu je třeba respektovat některé důležité aspekty tohoto kroku. Tinbergen (1951; in Charemza et al. (2003)) v této souvislosti říká, že: „první věcí, kterou je třeba udělat v důkladné aplikaci, je rozhodnout o správné ekonomické analýze zkoumaných vztahů ... Dvou věcí si musíme být neustále vědomi: i) je nezbytné vědět, o jaký vztah se přesně zajímáme, a ii) znát faktory vstupující do tohoto vztahu“.

Znalost daného vztahu a faktorů, které ho determinují, je nezbytná pro odvození ekonomického modelu. Jinými slovy ekonomický model musí splňovat specifikační předpoklady. V této souvislosti se jedná o předpoklad zahrnutí podstatných proměnných do modelu, volby správné funkční formy, stability parametrů a předpoklad neexistence simultánního vztahu mezi endogenní proměnnou a exogenní, resp. exogenními proměnnými.

Předpoklady EM

- *Specifikační předpoklady ekonometrického modelu*
 - Neopomenutí podstatné vysvětlující proměnné;
 - Vyuštění irelevantních vysvětlujících proměnných;
 - Volba správné funkční formy modelu;
 - Stabilní odhadnuté parametry, časová invariančnost;
 - Respektování simultánnosti vztahů mezi proměnnými;
- *Předpoklad nulového průměru*
- *Předpoklad homoskedasticity*
- *Předpoklad nepřítomnosti autokorelace reziduí*
- *Nezávisle proměnné jsou nenáhodné a fixní v opakujících se souborech*
- *Neexistence perfektní multikolinearity*
- *Normální rozdělení náhodné složky*

Důsledky nedodržení předpokladů EM

Při výskytu autokorelace reziduí získané odhady běžnou metodou nejmenších čtverců jsou nezkreslené, ale nejsou nejlepší. Existují tedy jiné metody odhadu, které poskytují lepší výsledky, jako např. GLS (Generalized Least Squares). Při výskytu autokorelace metoda nejmenších čtverců podhodnocuje standardní chyby odhadu. To znamená, že t-hodnoty, R² a F-testy jsou vysoce nespolehlivé.

Přítomnost heteroskedasticity způsobuje, že odhadnuté parametry ekonometrického modelu jsou nezkreslené, ale nejsou nejlepší. Parametry mají velké chyby odhadu. Lepších odhadů může být dosaženo opět při použití GLS. Chyby parametrů získané BMNC jsou zkreslené. Směr zkreslení závisí na vztahu mezi rozptylem náhodné složky a hodnotou nezávisle proměnné, která heteroskedasticitu způsobuje.

Při výskytu vysoké multikolinearity není možné separovat vlivy jednotlivých vysvětlujících proměnných na vysvětlovanou proměnnou, jelikož proměnné se v čase pohybují obdobně, a to v závislosti na výši multikolinearity. Důsledkem vysoké multikolinearity je získání velkých chyb parametrů.

Dodržení předpokladu normálního rozdělení náhodné složky je důležité z toho důvodu, aby odhady parametrů pomocí běžné metody nejmenších čtverců měly taktéž normální rozdělení a testy statistických předpokladů měly t, F a χ^2 rozdělení, tj. nebyly zavádějící.