

**EKONOMICKÁ UNIVERZITA V BRATISLAVE
FAKULTA HOSPODÁRSKEJ INFORMATIKY**

Evidenčné číslo: 17200/D/2010/0004604822

**MODELOVANIE IMPORTU TOVAROV A SLUŽIEB DO
SLOVENSKEJ REPUBLIKY**

Dizertačná práca

2010

Ing. Peter Ďurka

**EKONOMICKÁ UNIVERZITA V BRATISLAVE
FAKULTA HOSPODÁRSKEJ INFORMATIKY**

**MODELOVANIE IMPORTU TOVAROV A SLUŽIEB DO
SLOVENSKEJ REPUBLIKY**

Dizertačná práca

Študijný program: Ekonometria a operačný výskum

Študijný odbor: 3.3.25 Ekonometria a operačný výskum

Školiace pracovisko: Katedra operačného výskumu a ekonometrie

Školiteľ: doc. RNDr. Eva Rublíková, PhD.

Bratislava 2010

Ing. Peter Ďurka

ZADANIE ZÁVEREČNEJ PRÁCE

Meno a priezvisko študenta: Ing. Peter Ďurka

Študijný program: Ekonometria a operačný výskum (Jednoodborové štúdium, doktorandské III. st., denná forma)

Študijný odbor: 3.3.25 Ekonometria a operačný výskum

Typ záverečnej práce: Dizertačná záverečná práca

Jazyk záverečnej práce: slovenský

Názov: Modelovanie importu tovarov a služieb do Slovenskej republiky

Cieľ: Navrhnuť vhodný prognostický model dovozu tovarov a služieb do SR prostredníctvom aktuálnych prístupov k modelovaniu makroekonomických časových radov a určiť prognózu dovozu na rok 2010.

Anotácia: ARIMA modely a ich vlastnosti, vektorovo autoregresné procesy časových radov, modely s korekčným členom, stacionarita makroekonomických časových radov, dovoz tovarov a služieb, prognóza

Odporúčaná literatúra:

ARLT, J. 1999. *Moderní metody modelování ekonomických časových řad*. Praha : Grada Publishing, 1999. 307 s. ISBN 80-7169-539-4.

GREENE, W., H. 2003. *Econometric analysis*. Upper Saddle River, N. J. : Prentice Hall, 2003. 1026 s. ISBN 0-13-066189-9.

LÜTKEPOHL, H. 2005. *New introduction to multiple time series analysis*. Berlin : Springer, 2005. 764 s. ISBN 3-540-26239-3.

RUBLIKOVÁ, E. – PRÍHODOVÁ, I. 2008. *Analýza vybraných časových radov – ARIMA modely*. Bratislava : Vydavateľstvo EKONÓM, 2008. 214 s. ISBN 978-80-225-2540-4.

Školiteľ: doc. RNDr. Eva Rublíková, PhD.

Katedra: Katedra operačného výskumu a ekonometrie

Vedúci katedry: Mgr. Juraj Pekár, PhD.

Dátum zadania:

Dátum schválenia:

***Dizertačná práca bola spracovaná v rámci riešenia grantu VEGA číslo
1/0181/10 Hybridné modely prognózovania časových radov***

Čestné vyhlásenie

Čestne vyhlasujem, že záverečnú prácu som vypracoval samostatne a že som uviedol všetku použitú literatúru.

Dátum:

.....
(podpis študenta)

Pod'akovanie

Ďakujem mojej školiteľke, doc. RNDr. Eve Rublíkovej, PhD. za cenné rady, čas, pripomienky a odborný dohľad počas celého obdobia vypracovávania dizertačnej práce.

ABSTRAKT

ĎURKA, Peter: *Modelovanie importu tovarov a služieb do Slovenskej republiky*. – Ekonomická univerzita v Bratislave. Fakulta hospodárskej informatiky; Katedra operačného výskumu a ekonometrie. – doc. RNDr. Eva Rublíková, PhD. – Bratislava: FHI EU, 2010, počet strán 127. Práca je rozdelená do 4 kapitol, obsahuje 32 obrázkov, 24 tabuliek a 31 príloh.

Dovoz tovarov a služieb odráža úroveň kúpyschopného obyvateľstva a jeho rast naznačuje vyššiu spotrebu obyvateľstva (vyšší dopyt po tovaroch a službách zo zahraničia). V tak malej a otvorenej ekonomike akou je slovenská, predstavuje dovoz dôležitý makroekonomický ukazovateľ, ktorý by sa mal veľmi starostlivo sledovať a poznanie jeho ďalšieho vývoja je dôležité pre zvolenie správnych opatrení štátu na podporu a rast domácej ekonomiky. Z týchto dôvodov považujeme za dôležité analyzovať determinanty vývoja dovozu tovarov a služieb, aby tvorcovia hospodárskej politiky mali k dispozícii aj kvantitatívny nástroj pri politickom rozhodovaní.

Cieľom dizertačnej práce je navrhnúť vhodný prognostický model dovozu tovarov a služieb do SR prostredníctvom aktuálnych prístupov k modelovaniu makroekonomických časových radov – ARIMA modely, vektorovo autoregresné modely (VAR) a modely s členom korigujúcim chyby (ECM) a prognózovať vývoj dovozu tovarov a služieb na rok 2010.

Kľúčové slová: stacionárnosť, integrovanosť, ARIMA, VAR, ECM, ADF, prognóza, dovoz tovarov a služieb

ABSTRACT

DURKA, Peter: *Modeling the import of goods and services of the Slovak Republic*. – University of Economics in Bratislava. Faculty of Economic Informatics; Department of Operations Research and Econometrics. – doc. RNDr. Eva Rublikova, PhD. – Bratislava: FEI UE, 2010, no. of pages 127. Thesis is divided into 4 chapters, includes 32 figures, 24 tables and 31 annexes.

Import of goods and services reflects the level of purchasable inhabitants and its increase indicates higher consumption of inhabitants (higher demand for foreign goods and services). In so small and open economy as Slovak economy is, import presents important macroeconomic indicator which should be watched very carefully and the knowing of its further development is important in order to choose correct actions by the state for support and growth of domestic economy. For these reasons we consider to be important to analyze the determinants of the development of import. The architects of economic policies could use the results of that analyses as quantitative instruments for making their decisions.

The aim of doctoral thesis is to design prognostic model of import of goods and services of the Slovak republic using actually used model approaches for modeling macroeconomic time series – ARIMA models, vector autoregression models (VAR) and error-correction models (ECM) and to forecast the development of import of goods and services in 2010.

Key words: stationarity, integration, ARIMA, VAR, ECM, ADF, forecast, import of goods and services

OBSAH

Úvod	10
1 Súčasný stav riešenej problematiky doma a v zahraničí	12
1.1 Makroekonomické modely dovozu na Slovensku	12
1.1.1 Modely Slovenskej akadémie vied	13
1.1.2 Modely INFOSTATu	18
1.1.3 Model Ministerstva financií SR	24
1.2 Makroekonomické modely dovozu v zahraničí	25
1.2.1 Model poľskej ekonomiky NECMOD	25
1.2.2 Model dovozu Českej republiky	27
1.2.3 Model dovozu Grécka	28
2 Ciele práce	31
3 Metodika práce a metódy skúmania	34
3.1 Boxova-Jenkinsova metodológia ARIMA modelov časových radov	34
3.1.1 Modely stacionárnych časových radov	34
3.1.2 Modely homogénne nestacionárnych časových radov	43
3.1.3 Modely sezónnych stochastických časových radov	51
3.2 Vektorovo autoregresné (VAR) procesy časových radov	53
3.3 Modely viacrozmerných nestacionárnych časových radov - Modely s korekčným členom (ECM)	61
4 Výsledky práce	68
4.1 Dovoz tovarov a služieb do Slovenskej republiky	68
4.1.1 Analýza vývoja dovozu tovarov a služieb do SR v rokoch 1995 až 2008	70
4.2 ARIMA model dovozu tovarov a služieb do SR	80
4.2.1 Identifikácia modelu	80
4.2.2 Odhad parametrov modelu a overenie rezíduí	84

4.2.3. Prognóza dovozu tovarov a služieb do SR modelom ARIMA na rok 2010	91
4.3 VAR model dovozu tovarov a služieb do SR	93
4.3.1 Analýza stacionarity uvažovaných premenných	93
4.3.2 Odhad VAR modelu dovozu tovarov a služieb do SR	97
4.3.3 Diagnostická kontrola modelu VAR	99
4.3.4 Prognóza dovozu tovarov a služieb do SR modelom VAR(2) na rok 2010	103
4.3.5 Analýza reakcie na impulz modelu VAR(2)	104
4.4 ECM model dovozu tovarov a služieb do SR	106
4.4.1 Analýza stacionarity uvažovaných premenných	106
4.4.2 Odhad ECM dovozu tovarov a služieb do SR	107
4.4.3 Prognóza dovozu tovarov a služieb do SR ECM na rok 2010	111
4.5 Porovnanie modelov dovozu tovarov a služieb do SR	115
Záver	118
Literatúra	122
Prílohy	126

ÚVOD

Analýza ekonomických časových radov sa v posledných rokoch stala veľmi dynamicky sa rozvíjajúcou disciplínou. V mnohých jej oblastiach bol dosiahnutý významný pokrok. Vzniklo množstvo efektívnych postupov a metód modelovania časových radov. S rastúcou dostupnosťou výkonnej výpočtovej techniky sa sofistikované metódy začali vo väčšej miere presadzovať v ekonomickej praxi. V súčasnosti sa dostávame do obdobia, kedy vo vyspelých krajinách nie je možné robiť dôležité ekonomické rozhodnutia bez dôkladnej analýzy vývoja základných ukazovateľov. Stále väčší dôraz sa kladie na konštrukciu štatisticko-ekonometrických modelov charakterizujúcich základné rysy vývoja celého národného hospodárstva. Existuje množstvo oblastí národohospodárskej praxe, kde je nevyhnutné využívať moderné metódy analýzy časových radov.

Na Slovensku (najmä v súčasnosti, kedy časové rady ukazovateľov hospodárskeho vývoja už začínajú mať istú informačnú schopnosť) sa kladie postupne väčší dôraz na analýzu časových radov pomocou najnovších metód. Táto skutočnosť je vyvolaná vzrastajúcou reálnou potrebou kvantitatívnych informácií, ktoré sú nevyhnutné pre uskutočňovanie konkrétnej rozhodovacej činnosti. Rastúca dĺžka časových radov bude prirodzene vytvárať stále lepšie podmienky pre analytickú a modelovaciú činnosť a preto sa treba touto činnosťou zaoberať intenzívnejšie. Správna aplikácia súčasných metód analýzy ekonomických časových radov môže viesť k informáciám, ktoré uľahčia rozhodovaciú činnosť na rôznych úrovniach národohospodárskeho riadenia. Pri riešení konkrétnych úloh modelovania vývoja ekonomických procesov je dôležitá spolupráca štatistikov-ekonometrov s ekonómami.

Cieľom dizertačnej práce je pomocou aktuálnych prístupov k modelovaniu časových radov analyzovať a prognózovať vývoj dovozu tovarov a služieb do Slovenskej republiky ako jedného zo základných makroekonomických ukazovateľov, ktorý by sa mal starostlivo sledovať, pretože poznať jeho minulý, súčasný a budúci vývoj môže pomôcť tvorcom hospodárskej politiky zvoliť správne opatrenia na podporu a rast domácej ekonomiky.

Predkladaná dizertačná práca je rozdelená do štyroch kapitol. V prvej kapitole sú stručne popísané makroekonomické modely Slovenskej republiky od starších až po jedny z novších. Väčšia pozornosť sa venuje regresným rovniciam dovozu tovarov a služieb. Makroekonomickým modelovaním sa na Slovensku v súčasnosti zaoberá najmä Ústav slovenskej a svetovej ekonomiky SAV, INFOSTAT a Inštitút finančnej politiky Ministerstva financií SR. Ďalej je v tejto časti spracovaná problematika makroekonomického modelovania dovozu tovarov a služieb vo svete. Konkrétne spomenieme regresné rovnice dovozu krajín Poľska, Českej republiky a Grécka. Tieto krajiny sme si vybrali pre ich podobné zameranie a závislosť ekonomiky na dovoze, aké má aj Slovenská republika.

V druhej kapitole je uvedený cieľ a čiastkové ciele dizertačnej práce.

Obsahom tretej kapitoly je teoretické spracovanie aktuálnych metód a prístupov modelovania ekonomických časových radov od jednoduchších, zaoberajúcich sa jednorozmerným časovým radom až po komplexnejšie modely viacrozmerných časových radov – Boxova a Jenkinsova metodológia modelov „autoregresných integrovaných kľzavých priemerov“ (ARIMA), vektorovo autoregresné modely (VAR) a modely s členom korigujúcim chyby (ECM). Vysvetlené sú pojmy a teoretické základy, ktoré je nutné poznať a ovládať pre správne použitie jednotlivých metód, ako napr. pojem stacionarity, autokorelačná a parciálna autokorelačná funkcia, autoregresný proces a proces kľzavých priemerov a ich viacrozmerné rozšírenie, určenie stupňa diferencovania, analýza reakcie na impulz, kointegrácia a iné.

Štvrtá kapitola obsahuje aplikáciu teoretických poznatkov z tretej kapitoly na analýzu a prognózu vývoja dovozu tovarov a služieb do Slovenskej republiky. Na vytvorenie ARIMA modelu použijeme štvrťročné údaje o dovoze za roky 1997 až 2009 v mld. EUR, stálych cien roku 2000. Odhad modelu uskutočníme pomocou softwaru Statgraphics Centurion XV. Na vytvorenie VAR modelu a modelu s korekčným členom použijeme hodnoty dovozu za rovnaké obdobie, ale sezónne očistené spolu aj s vysvetľujúcimi premennými kvôli lepšiemu vystihnútiu trendu. Na vytvorenie bázy dát, ako aj na kvantifikáciu regresných rovníc, bude využitý programový systém EViews 5.0. Zdrojom všetkých údajov je Štatistický úrad databáza SLOVSTAT.

1 Súčasný stav riešenej problematiky doma a v zahraničí

1.1 Makroekonomické modely dovozu na Slovensku

Bývalé Československo, ako aj ostatné socialistické krajiny zaznamenali v porovnaní s ostatnými krajinami oneskorenie vývoja systému prognózovania a teda aj ekonometrie ako takej. Bolo to zapríčinené najmä tým, že základom riadenia socialistickej ekonomiky bol plán. Prognostické prístupy sa začali využívať až potom, čo sa socialistická ekonomika dostávala do ťažkostí, skutočné údaje sa značne odlišovali od plánovaných. Preto sa na zlepšenie systému plánovania začali využívať rôzne ekonometricko - prognostické prístupy.

Čo sa týka charakteru ekonometrických a prognostických modelov, tak s prechodom na trhovu orientovanú ekonomiku a s existenciou údajov o kapitále, nevyhnutných pre produkčné funkcie, začali v ekonometrickom modelovaní dominovať dopytovo orientované modely, ktoré predpokladajú uspokojenie dostatočnou ponukou. Roky 1993 – 1996 možno v oblasti ekonometrického modelovania na Slovensku charakterizovať ako obdobie enormného rozvoja kvality a kvantity údajov, ako aj postupného rastu a rozvoja samotných ekonometrických modelov. Konštrukcia čiastkových i komplexných ekonometrických modelov slovenskej ekonomiky však nemá v súčasnosti z objektívnych dôvodov ešte príliš bohatú vlastnú históriu. Príčinou nedostatku modelov je relatívne krátka história samostatnej existencie slovenskej ekonomiky (a aj nedostupnosť dát z obdobia do roku 1989), v dôsledku čoho sú krátke aj časové rady, ktoré odzrkadľujú jej doterajší vývoj. Markantne sa to prejavuje najmä na dĺžke ročných časových radov. Relatívne najlepšiu údajovú základňu konštrukcie ekonometrických modelov slovenskej ekonomiky preto predstavujú štvrt'ročné časové rady makroekonomických ukazovateľov. No ani dnešný disponibilný počet pozorovaní v štvrt'ročných časových radoch nie je ešte spravidla zárukou, aby bolo možné v našich podmienkach efektívne verifikovať novšie poznatky ekonometrie.

Medzi pracoviská, ktoré sa problematikou modelovania slovenskej ekonomiky zaoberajú najdlhšie, patrí Ústav slovenskej a svetovej ekonomiky SAV, INFOSTAT

a Inštitút finančnej politiky Ministerstva financií SR. Ďalej popíšeme niektoré významné makroekonomické modely týchto inštitúcií so zameraním na dovoz tovarov a služieb do SR. Všetky opísané modely majú dopytový charakter, ktorý je vyjadrený dopytovou špecifikáciou regresných rovníc. Za hlavnú vysvetľujúcu premennú dovozu je použitý vo väčšine modelov hrubý domáci produkt, resp. jeho zložky, ktoré vyjadrujú domáci dopyt. Ako cenový faktor ovplyvňujúci dovoz je v rovniciach použitý väčšinou cenový index (deflátor dovozu). Ďalšie vysvetľujúce premenné sú napr. vývoz, hrubý fixný kapitál, súkromná spotreba, relatívne ceny, pomer indexov cien dovozu a priemyselných cien a iné. Všetky modely, okrem najstaršieho makromodelu ISWE97q3, sú v tvare s členom korigujúcim chyby a vplyv použitých vysvetľujúcich faktorov sa prejavuje v krátkom i dlhom období.

1.1.1 Modely Slovenskej akadémie vied

Jedným z prvým väčších ekonometrických modelov slovenskej ekonomiky bol model *ISWE97q3* skonštruovaný na pracovisku Ústavu slovenskej a svetovej ekonomiky SAV (ÚSSE; dnes Ekonomický ústav SAV) v roku 1997. Model *ISWE97q3* bol konštruovaný na základe postkeynesovských prístupov ako príjmový - spotrebný model slovenskej ekonomiky. Ide o makroekonomický interdependentný ekonometrický model, pri konštrukcii ktorého bolo použitých 240 časových radov a 118 rovníc. Bohužiaľ, pre nás dôležitému bloku zahraničného obchodu a konkrétne dovozu tovarov a služieb do Slovenskej republiky sa tento model venuje veľmi okrajovo a bez vysvetlenia podrobnejších vzťahov v regresnej rovnici dovozu. ÚSSE svoj model ISWE (Institute of Slovak and World Economy) pravidelne aktualizuje, a tak vzniklo doteraz niekoľko ďalších modelov, konkrétne model *ECM-ISWE04q1* z roku 2004, v ktorom je na odhad behaviorálnych rovníc použitá metóda modelu s členom korigujúcim chybu (error-correction model - ECM). Základňou pre tento model bola databáza *ISWE03q4*, ktorá obsahuje viac ako 300 premenných v štvrtročných pozorovaniach od prvého štvrtroku 1993 po koniec roku 2003.

V súčasnosti sa SAV venuje modelom HERMIN a CGE, ktoré slúžia na vyhodnotenia čerpania štrukturálnych fondov Európskej únie.

1.1.1.1 Makroekonomický model ISWE97q3 (z roku 1998)

Makroekonomický model ISWE97q3¹ bol skonštruovaný na pracovisku Ústavu Slovenskej a Svetovej Ekonomiky SAV v roku 1997. Model ISWE97q3 bol konštruovaný na základe postkeynesovských prístupov ako príjmový - spotrebný model slovenskej ekonomiky. Ide o makroekonomický interdependentný ekonometrický model, pri konštrukcii ktorého bolo použitých 240 časových radov a 118 rovníc. Z obsahového hľadiska sa skladá zo šiestich blokov - blok obyvateľstva, blok cien a produktivity práce, blok zahraničného obchodu, monetárny blok, blok štátneho rozpočtu a blok HDP.

Premenné, ktoré majú v jednotlivých blokoch exogénny charakter, vstupujú do nich vo viacerých prípadoch z iných blokov. Z interpretačnej i konštrukčnej roviny je potrebné chápať model ako jeden celok a rozdelenie do blokov má svoj pôvod skôr v obsahovo-názornej rovine. Časové rady z obdobia existencie Slovenskej republiky, napriek svojej relatívne malej dĺžke, ale na druhej strane, vďaka svojej konzistentnosti, umožnili odhady regresných rovníc s dobrými matematicko-štatistickými parametrami.

Autori pri konštrukcii a verifikácii makroekonomického modelu ISWE97q3 urobili nasledujúci záver:

V dôsledku postupnej zmeny v ponukovej časti slovenskej ekonomiky a zníženia tarifných a netarifných nástrojov obmedzujúcich import došlo k zhoršeniu platobnej bilancie a tým aj k spomaleniu tvorby HDP. Súčasný stav ekonomiky nie je schopný tento vývoj zvrátiť. Preto sa vytvorili alternatívne predpovede na:

- redukciu importu pomocou zmeny výmenného kurzu,
- regulovanie súkromnej spotreby,
- regulovanie verejných výdavkov a silnú kontrolu menového agregátu M2.

Zahraničný obchod – regresná rovnica dovozu tovarov a služieb (v stálych cenách)

Pri konštrukcii bloku zahraničného obchodu sa do značnej miery vychádzalo z verzie ekonometrického modelu z roku 1996. Vzhľadom na to, že sa zvýšil význam Európskej únie v zahraničnom obchode Slovenskej republiky, nebola Česká republika

¹ Páleník V. – Bors L. – Kvetan V. – Vokoun J. 1998. Construction and Verification of macroeconomic model ISWE97q3. In *Ekonomický časopis*. 1998, roč. 46, č. 3, s.428 - 466

vydelená ako samostatné teritórium, ale z časových radov zahraničného obchodu s ČR, EÚ a zvyšku sveta boli vytvárané ich integrálne ukazovatele, konštruované ako vážené priemery.

Tomuto bloku nie je v práci venovaná veľká pozornosť. Jednotlivé regresné rovnice dovozu aj vývozu sú udávané bez bližšieho popisu a interpretovania a bez odôvodnenia použitých premenných. Pri rovniciach nie je uvedený ani koeficient determinácie ani iné charakteristiky.

Zoznam premenných v regresnej rovnici dovozu tovarov a služieb:

<i>Symbol</i>	<i>Definícia</i>
M	Dovoz tovarov do SR, mld. SK, stále ceny
X	Hrubý obrat (HDP + medziprodukt), stále ceny
PM1	Cenový index dovozu, stále ceny; PM1 = MP/M
PX	Cenový index vývozu, stále ceny
DMS	Dovozná prirážka (štrukturálna premenná na dovoz)
DKF	Tvorba hrubého fixného kapitálu, mld. SK, stále ceny
AM2	Štrukturálna adaptácia dovozu SR (umelá premenná)
U9293	Umelá premenná
DM2	Mimoriadny vplyv na dovoz SR (umelá premenná)
MP	Dovoz tovarov do SR, bežné ceny

Regresná rovnica dovozu má nasledovný tvar (v stálych cenách):

$$\ln M = -3,073 + 1,25 \cdot \ln X_{(t-1)} - 1,21 \cdot (\ln PM1_{(t-1)} - \ln PX_{(t-1)}) - 0,907 \cdot DMS_{(t-1)} + 0,0483 \cdot \ln DKF + 1,74 \cdot AM2 + 0,201 \cdot D9293 + 0,155 \cdot DM2 + 0,0501 \cdot Q2 + 0,117 \cdot Q4$$

Z rovnice dovozu vidieť, že naň pôsobia najmä cenový diferenciál, hrubý obrat (X) a tvorba hrubého fixného kapitálu (DKF). Hrubý obrat v tomto prípade vyjadruje dopyt slovenskej ekonomiky po dovážaných tovaroch. Tvorba hrubého fixného kapitálu, čo sú vlastne investície, v počiatočnom období tiež pôsobí na zvýšenie dovozu.

1.1.1.2 Model ECM-ISWE04q1 (z roku 2004)

Štruktúra modelu ECM-ISWE04q1² vychádza z predošlých prác vykonaných na Ústave slovenskej a svetovej ekonomiky SAV. Celkovo sa tento model dá charakterizovať ako malý dopytovo orientovaný model reálnej ekonomiky SR. Z dôvodu nestacionarity väčšiny použitých ekonomických časových radov bol na odhad behaviorálnych rovníc použitý modelový prístup ECM. Základňou pre tento model bola databáza ISWE03q4, ktorá obsahuje viac ako 300 premenných v štvrťročných pozorovaniach od prvého štvrťroku 1993 po koniec roku 2003.

Oproti prepracovanejším verziám úplného ekonometrického modelu typu ISWE neobsahuje blok štátneho rozpočtu ani menový blok. Tiež niektoré vzťahy vo vnútri jednotlivých blokov sú konštruované jednoduchšie. Nevyhnutné relevantné vzťahy však ostali nezmenené a tak vypovedacia a prognostická schopnosť v oblasti štandardných scenárov sa zásadne nezhoršila.

Model je rozdelený do štyroch základných blokov – blok cien a deflátorov, blok obyvateľstva, blok zahraničného obchodu, blok HDP.

Podľa autorov je ťažiskom konštrukcie modelu diskusia a interpretácia jednotlivých behaviorálnych rovníc. Všetky diskutované rovnice majú dobré štatistické parametre, majú oporu v príslušnej ekonomickej teórii a sú v súlade s ekonomickou intuíciou. Z tohto pohľadu možno považovať model ECM-ISWE04q1 za verifikovaný s možnosťou využitia pri kvantifikácii štandardných prognóz. V rámci svojej vypovedacej schopnosti je vhodný aj na vytváranie alternatívnych scenárov budúceho vývoja, charakterizovanými zmenami vo vývoji exogénnych premenných alebo vo výške relevantných elasticít.

Zahraničný obchod – regresná rovnica dovozu tovarov a služieb (v stálych cenách)

V bloku zahraničného obchodu sa napočítavajú ako deflátoary pre dovoz a vývoz tak i objemy a saldo medzinárodnej výmeny tovarov a služieb.

Zoznam premenných v regresnej rovnici dovozu tovarov a služieb:

<i>Symbol</i>	<i>Definícia</i>
EGSR	Vývoz

² Páleník, V. – Ďuraš, J. – Kvetan, V. – Ondko, P. 2004. Konštrukcia modelu ECM – ISWE04q1. In *Zborník príspevkov - Ekomstat 2004*. Trenčianske Teplice 2004

HC1+G1+DK	Domáci dopyt
MGSR	Dovoz
PMGSR	Deflátor dovozu (ceny dovozu)
PXI95	Ceny priemyselných výrobcov
SEAS	Sezónna premenná
UMGSR4	Umelá premenná dovozu

Regresná rovnica dovozu tovarov a služieb (v stálych cenách) má nasledovný tvar:

$$\begin{aligned} \Delta_4 \ln \text{MGSR}_t = & -2,0062 - 0,6049 * [\ln \text{MGSR}_{t-4} - 0,9862 * \ln(\text{HC1}_{t-4} + \text{G1}_{t-4} + \text{DK}_{t-4})] - \\ & - 0,6219 * \ln \text{EGSR}_{t-4} + 0,4280 * \ln(\text{PMGSR}_{t-4} / \text{PXI95}_{t-4}) + 1,2647 * \Delta_4 \ln(\text{HC1}_t + \text{G1}_t + \text{DK}_t) + \\ & + 0,8556 * \Delta_4 \ln \text{EGSR}_t + 0,0436 * \text{SEAS1} + 0,0390 * \text{SEAS4} + 0,0261 * \text{UMGSR4} \\ R^2 = & 0,98 \quad \quad \quad \text{DW} = 2,28 \end{aligned}$$

Objem dovozu tovarov a služieb je počítaný na základe veličín vytvárajúcich dopyt po dovoze. Rovnica importu ukazuje v EC člene dlhodobý vzťah medzi importom MGSR a domácim dopytom (HC1 + G1 + DK). Podľa neho nárast domáceho dopytu o 1 % spôsobí nárast reálneho dovozu o 0,98 %. Z dlhodobého hľadiska na reálny import vplýva aj reálny vývoz EGSR, pomer indexov cien dovozu a priemyselných cien. Všetky tieto premenné vystupujú aj pri vysvetlení krátkodobých zmien.

1.1.1.3 SAV – súčasnosť

Ekonomický ústav SAV sa v súčasnosti stal ex-ante hodnotiteľom návrhu národného strategického referenčného rámca (NSRR) pre Slovenskú republiku. Na vyhodnotenie makroekonomických dopadov NSRR pre roky 2007 – 2013 sú použité dva rozdielne štruktúrne modely – model HERMIN, ktorý bol vyvinutý konkrétne na vyhodnocovanie dopadov pri alokácii poskytnutých fondov Európskej únie a model všeobecnej ekonomickej rovnováhy (CGE), ktorý zachytáva jednotlivé nominálne toky, čím umožňuje skúmať štruktúru celej ekonomiky ako celku a zároveň umožňuje analyzovať dopad rôznych nemarginálnych zmien na ekonomiku. CGE modely sa

najčastejšie používajú na analýzu zmien v daňovej, sociálnej, zahranično-obchodnej a environmentálnej politike.³

1.1.2 Modely INFOSTATu

V roku 1996 uverejnil INFOSTAT svoj model EMSE 1.0. V roku 1999 uverejnil jeho aktualizovanú verziu, model *EMSE 2.0* (vyvinutý v roku 1996). Jednotlivé verzie modelu sa odlišujú nielen dĺžkou časových radov ich bázy dát, ale aj počtom regresných rovníc a identít, ktoré v nich vystupujú. Model EMSE 2.0 nie je len aktualizovanou verziou modelu EMSE 1.0, ale obsahuje aj niektoré nové vzťahy a väzby (9 regresných rovníc a 12 identít), ktorých kvantifikáciu umožnilo predĺženie časového horizontu bázy dát. Túto verziu ekonometrického modelu slovenskej ekonomiky tvorí simultánny systém 82 dynamických, lineárnych a nelineárnych rovníc a identít (25 regresných rovníc a 57 identít), ktoré vyjadrujú vzťahy medzi 113 premennými.

INFOSTAT vytvoril aj štvrťročný ekonometrický model *QEM-ECM-1.0* (publikovaný v roku 2001), taktiež založený na metodológii ECM. Model tvorí simultánny systém 80 dynamických, lineárnych a nelineárnych rovníc a identít (z toho 26 regresných), ktoré vyjadrujú vzťahy medzi 135 premennými.

V súčasnosti INFOSTAT v súlade s požiadavkami Eurostatu konštruuje tzv. *rýchle odhady* (flash estimates) vývoja základných makroekonomických ukazovateľov, pri príprave ktorých využíva dva druhy modelových nástrojov – ARIMA modely a modely s členom korigujúcim chyby (ECM).

1.1.2.1 Ekonometrický model EMSE 2.0 (z roku 1999)

Ekonometrický model slovenskej ekonomiky v období transformácie EMSE 2.0⁴ predstavuje druhú verziu pôvodného experimentálneho variantu vyvinutého v roku 1996 na INFOSTATE Bratislava, ktorý sa postupne zdokonaľuje a aktualizuje. Jednotlivé verzie modelu sa odlišujú nielen dĺžkou časových radov ich bázy dát, ale aj počtom regresných rovníc a identít, ktoré v nich vystupujú.

³ PÁLENÍK, V. – RADVANSKÝ, M. 2006. Aplikácie modelov HERMIN a CGE na hodnotenie finančných alokácií NSSR. In *Forum Statisticum Slovaca*. 2006, roč. 2, č. 2, s. 208 - 216.

⁴ Olexa, M. – Haluška, J. – Klein, T. - Orságová J. 1999. Econometric model for transforming Slovakia - EMSE 2.0. In *Ekonomický časopis*. 1999, roč. 47, č. 3, s. 351-373

Dominujúcou črtou modelu je podľa autorov takmer výlučne dopytový charakter, ktorý je vyjadrený dopytovou špecifikáciou regresných rovníc, zobrazujúcich vývoj hlavných makroekonomických ukazovateľov. Limitujúcim faktorom je krátka história trhových vzťahov v slovenskej ekonomike.

Model EMSE 2.0 tvorí simultánny systém 82 dynamických, lineárnych a nelineárnych rovníc a identít (25 regresných rovníc a 57 identít), ktoré vyjadrujú vzťahy medzi 113 premennými. Sústavu regresných rovníc a identít modelu autori z hľadiska ich ekonomického obsahu rozdelili do nasledujúcich blokov – spotreba a investície; zahraničný obchod v porovnateľných cenách; zahraničný obchod v bežných cenách; HDP; cenové indexy a deflátoary; zamestnanosť, nezamestnanosť a produktivita práce; mzdy a príjmy obyvateľstva; štátny rozpočet; ponuka peňazí, úrokové miery a kurz meny.

Kompletná báza dát ekonometrického modelu obsahuje celkovo 113 časových radov modelových premenných (82 endogénnych a 31 exogénnych premenných). Časový horizont údajovej základne zahŕňa obdobie od roku 1985 až do roku 1996. Hoci daný ekonometrický model chce opisovať hlavne obdobie transformácie ekonomiky na Slovensku (t. j. od roku 1990), ako vyplýva z časového horizontu bázy dát, obsahuje aj informácie o období pred jej začiatkom. Zahrnutie tohto obdobia do časových radov bolo však nevyhnutné z toho dôvodu, aby bol dlhší časový horizont na kvantifikáciu parametrov regresných rovníc.

Parametre jednotlivých regresných rovníc modelu boli odhadnuté pomocou metódy najmenších štvorcov. Vypovedacia schopnosť modelu bola overená na základe statickej a dynamickej ex-post simulácie využitím programového systému SORITEC 6.4. Priemerná odchýlka vypočítaných a skutočných hodnôt bola pri statickej simulácii 8,39 % a pri dynamickej simulácii 8,54 %. Rozdiel medzi statickou a dynamickou simuláciou je, napriek značnému počtu dynamických väzieb obsiahnutých v modeli, veľmi malý. Autori hodnotia výsledky ex-post simulácií ako veľmi dobré. Model EMSE 2.0 podľa nich uspokojivo reprodukuje správanie ekonomiky Slovenska v rokoch 1986-1996 a je možné ho použiť aj pri simulačných a prognostických aplikáciach na ďalšie roky.

Regresná rovnica dovozu tovarov a služieb (v stálych cenách)

V modeli EMSE 2.0 je dovoz tovarov a služieb skúmaný v štyroch agregovaných skupinách rozdelených podľa tried SITC (Standard International Trade Classification) na potraviny (triedy 0 a 1), materiály (triedy 2 a 4), palivá (trieda 3), spotrebný tovar (triedy 5 až 9).

Rovnice vyjadrujúce dovoz tovarov sú dopytovo orientované a hlavnými vysvetľujúcimi faktormi sú relatívne ceny (podielu cien dovozu do SR a domácich cien). V prípade skupiny potraviny (triedy 0 a 1) je hlavným dopytovým faktorom súkromná spotreba (C93) a cenovým faktorom je relatívny cenový index dovozu (PM) (vyjadrený relatívne k deflátoru súkromnej spotreby PC). V ostatných skupinách je dopytovým faktorom hrubý domáci produkt (GDP93) a relatívne cenové indexy dovozu (PM) sú podelené deflátorom HDP (PY). V prípade modelovania dovozu (M59_93) vidíme, že jednou z vysvetľujúcich premenných je modelovaná premenná posunutá o jedno obdobie dozadu. Týmto je vyjadrená určitá zotrvačnosť dovozu tovarov tried 5 až 9 podľa delenia SITC.

Zoznam premenných v regresnej rovnici dovozu tovarov a služieb:

<i>Skratka</i>	<i>Definícia</i>
C93	Konečná spotreba domácností, mld. Sk, s. c. 1993
GDP93	Hrubý domáci produkt, mld. Sk, s. c. 1993
M01_93	Dovoz tovarov podľa tried SITC 0 a 1, mld. Sk, s. c. 1993
M24_93	Dovoz tovarov podľa tried SITC 2 a 4, mld. Sk, s. c. 1993
M3_93	Dovoz tovarov podľa triedy SITC 3, mld. Sk, s. c. 1993
M59_93	Dovoz tovarov podľa tried SITC 5 až 9, mld. Sk, s. c. 1993
MG93	Dovoz tovarov (celkový), mld. Sk, s. c. 1993
MGS93	Dovoz tovarov a služieb, mld. Sk, s. c. 1993
MS93	Dovoz služieb, mld. Sk, s. c. 1993
PC	Deflátor konečnej spotreby domácností, 1993=1
PM	Deflátor dovozu, 1993=1
PY	Deflátor HDP, 1993=1
T85	Sezónna premenná, rok 1985=1
U+premenná	Umelá premenná

Regresné rovnice dovozu tovarov podľa tried SITC majú tvar:

$$\ln M01_{93} = 0,43165 \cdot \ln C93 - 1,03064 \cdot \ln (PM/PC) + 0,04933 \cdot T85 + 0,33026 \cdot UM01_{93}$$

$$R^2 = 0,9396 \quad DW = 2,45$$

$$\ln M24_{93} = 0,25181 \cdot \ln GDP93 - 1,32480 \cdot \ln (PM/PY) + 0,08543 \cdot T85 + 0,32409 \cdot UM24_{93}$$

$$R^2 = 0,9401 \quad DW = 1,73$$

$$\ln M3_{93} = 0,51208 \cdot \ln GDP93 - 0,76532 \cdot \ln (PM/PY) + 0,05468 \cdot T85 + 0,30622 \cdot UM3_{93}$$

$$R^2 = 0,9163 \quad DW = 1,98$$

$$\ln M59_{93} = 0,29794 \cdot \ln GDP93 - 1,05653 \cdot \ln (PM/PY) + 0,53854 \cdot \ln M59_{93,t-1} + 0,05193 \cdot T85 + 0,36699 \cdot UM59_{93}$$

$$R^2 = 0,9742 \quad DW = 2,13 \quad \text{Durbin } h = -0,270$$

Ďalšia regresná rovnica popisuje dovoz služieb, ktorý je ovplyvnený HDP v stálych cenách (GDP93) a podielom relatívneho cenového indexu (PM) a deflátoru HDP (PY). Štatisticky významný vplyv má aj dovoz služieb z predchádzajúceho obdobia ($MS93_{t-1}$).

$$\ln MS93 = 0,24025 \cdot \ln GDP93 - 0,37920 \cdot \ln (PM/PY) + 0,58126 \cdot \ln MS93_{t-1} + 0,05930 \cdot \ln T85 + 0,44593 \cdot UMS93$$

$$R^2 = 0,9280 \quad DW = 2,27 \quad \text{Durbin } h = -0,478$$

Potom rovnica dovozu tovarov a služieb (v stálych cenách) bude:

$$MGS93 = MG93 + MS93$$

$$\text{kde} \quad MG93 = M01_{93} + M24_{93} + M3_{93} + M59_{93}$$

1.1.2.2 Ekonometrický model QEM-ECM-1.0 (z roku 2001)

Štvrtročný ekonometrický model QEM-ECM-1.0⁵ predstavuje experimentálnu verziu nového modelu slovenskej ekonomiky, ktorý je založený na metodológii ECM (model obsahuje 26 regresných rovníc, z ktorých 25 je odhadnutých na základe

⁵ Haluška, J. – Olexa, M. – Orságová J. 2001. Štvrtročný ekonometrický model slovenskej ekonomiky QEM-ECM-1.0. In *Ekonomický časopis*. 2001, roč. 49, č.5, s. 847-867

metodológie ECM a jedna má klasický ekonometrický tvar). Model bol vyvinutý v priebehu roku 2000 a z hľadiska ekonomického obsahu nadväzuje na ekonometrické modely slovenskej ekonomiky, ktoré vyvinul INFOSTAT Bratislava v predchádzajúcom období.

V súlade s princípmi trhovej ekonomiky je dominujúcou črtou tohto modelu dopytový charakter, ktorý je vyjadrený dopytovou špecifikáciou regresných rovníc, zobrazujúcich prevažne vývoj hlavných makroekonomických ukazovateľov reálnej ekonomiky. Limitujúcim faktorom v tomto smere je krátka história trhových vzťahov v slovenskej ekonomike, ktorá ovplyvnila aj špecifikáciu výsledných tvarov regresných rovníc modelu.

Experimentálnu verziu ekonometrického modelu slovenskej republiky QEM-ECM-1.0 tvorí simultánny systém 80 dynamických, lineárnych a nelineárnych rovníc a identít (z toho 26 regresných), ktoré vyjadrujú vzťahy medzi 135 premennými. Prostredníctvom jednotlivých rovníc modelu je zobrazený vývoj hlavných makroekonomických agregátov slovenskej ekonomiky z oblasti jej reálneho, finančného a bankového sektora.

Sústavu regresných rovníc a identít modelu autori rozdelili z hľadiska ich ekonomického obsahu do nasledujúcich blokov – spotreba a investície, zahraničný obchod (v stálych a bežných cenách); HDP a jeho zložky (v stálych a bežných cenách); cenové indexy a deflátoary; zamestnanosť, nezamestnanosť a produktivita práce; mzdy, príjmy a výdavky obyvateľstva; štátny rozpočet (príjmy daňové a nedaňové, výdavky); menový blok (ponuka peňazí, úrokové miery, úvery, priame zahraničné investície a kurz meny).

Pracovná báza dát modelu obsahuje viac ako 150 štvrt'ročných časových radov reálnych, odvodených a pomocných premenných. Časový horizont údajovej základne zahŕňa obdobie od 1. štvrt'roku 1993 po 2. štvrt'rok 2000 (t. j. 30 štvrt'ročných pozorovaní). Na odhad parametrov regresných rovníc modelu sa použili skutočné hodnoty časových radov príslušných premenných v kombinácii so sezónnymi filtrami. Všetky regresné rovnice modelu boli kvantifikované pomocou metódy najmenších štvorcov, pričom východiskovým rokom odhadu bol spravidla rok 1994. Na vytvorenie bázy dát, ako aj na kvantifikáciu regresných rovníc, bol využitý programový systém EViews 2.0.

Regresná rovnica dovozu tovarov a služieb (v stálych cenách)

Regresná rovnica dovozu tovarov a služieb je dopytovou funkciou, ktorá vyjadruje závislosť vývoja celkového dovozu (MGS95) v stálych cenách. Hlavným dopytovým faktorom pre celkový dovoz je agregátny efektívny dopyt. Vplyv hlavného dopytového faktora je modifikovaný vplyvom príslušného cenového indexu, t.j. relatívneho cenového indexu celkového dovozu. Vplyv uvedených vysvetľujúcich faktorov sa prejavuje v krátkom i dlhom období, pričom v dlhodobých vzťahoch má cenový faktor jednotkovú elasticitu a dopytový faktor elasticitu väčšiu ako 1 (konkrétne 1,5041). Autori vysvetľujú vyššiu ako jednotkovú dlhodobú elasticitu celkového dovozu na dopytový faktor známou skutočnosťou o vysokej dovoznej náročnosti slovenskej ekonomiky, ktorá sa prejavuje v rastúcom podiele dovozu na krytí rastu domáceho i agregátneho dopytu. Celkový dovoz sa vyznačuje len veľmi malou intenzitou zotrvačnosti vývoja.

Zoznam premenných v regresnej rovnici dovozu tovarov a služieb:

<i>Symbol</i>	<i>Definícia</i>
C95	Konečná spotreba domácností, mld. Sk, s. c. 1995
G95	Konečná spotreba štátnej správy, mld. Sk, s. c. 1995
I95	Tvorba hrubého fixného kapitálu, mld. Sk, s. c. 1995
EGS95	Vývoz tovarov a služieb, mld. Sk, s. c. 1995; $MG95_t = MGS95_t \cdot QMG_t$
MGS95	Dovoz tovarov a služieb, mld. Sk, s. c. 1995
MG95	Dovoz tovarov, mld. Sk, s. c. 1995
MS95	Dovoz služieb, mld. Sk, s. c. 1995; $MS95_t = MGS95_t - MG95_t$
PMGS	Deflátor dovozu tovarov a služieb, 1995=1
PAED	Deflátor agregátneho efektívneho dopytu, 1995=1
QMG	Podiel dovozu tovarov na dovoze tovarov a služieb
SDi	Sezónny filter pre štvrt'rok i , $i = 1, 2, 3, 4$
UMGS95	Umelá premenná

Regresná rovnica dovozu tovarov a služieb (stále ceny) má tvar:

$$\Delta_4 \ln MGS95_t = -3,2750 + 1,7203 \Delta_4 \ln (C95 + G95 + I95 + EGS95)_t - 0,4655 \Delta_4 \ln (PMGS/PAED)_t - 0,8788 [\ln MGS95_{t-4} - 1,5041 \ln (C95 + G95 + I95 + EGS95)_t + \ln (PMGS/PAED)_{t-4}] + 0,0708 SD1 - 0,0602 SD4 + 0,0648 UMGS95$$

1.1.2.3 INFOSTAT – súčasnosť

V súčasnosti sa INFOSTAT nezaoberá súhrnnými modelmi celého hospodárstva, ale v súlade s požiadavkami Eurostatu konštruuje tzv. *rýchle odhady* (flash estimates) vývoja základných makroekonomických ukazovateľov. INFOSTAT pri príprave rýchlych odhadov využíva dva druhy modelových nástrojov: ARIMA modely a modely s členom korigujúcim chyby (ECM). Podľa požiadaviek Eurostatu sú v súčasnosti členské štáty EÚ povinné zverejňovať rýchle odhady vývoja HDP a celkovej zamestnanosti do 45 dní po skončení referenčného štvrťroku (v čase T+45). Čas prípravy rýchlych odhadov sa však má skrátiť na T+38 dní a neskôr až na T+30 dní po skončení referenčného štvrťroku.⁶

1.1.3 Model Ministerstva financií SR

Štvrťročný ekonometrický model Slovenskej republiky⁷ bol vytvorený pod dohľadom konzultanta (autora) zo Svetovej banky a je navrhnutý tak, aby napomáhal analytikom Ministerstva financií vytvárať krátkodobé aj dlhodobé prognózy vývoja ekonomiky, analyzovať riziká a uskutočňovať simulačné analýzy. Model popisuje správanie sa strany ponuky (potenciálny output, vládne investície, zamestnanosť, nezamestnanosť...) ako aj stranu dopytu (súkromná spotreba, vládna spotreba, dovoz, vývoz...), ceny a náklady (CPI, PPI, mzdy, dovozné ceny, vývozné ceny...), monetárny sektor (kurz dolára, úrokové miery...) a fiskálny sektor (vládny dlh, dane...). Tento vyvinutý model používa Inštitút finančnej politiky Ministerstva financií SR ako rozhodujúci nástroj pri ekonomických analýzach a expertných odhadoch. Hlavné behaviorálne rovnice sú odhadnuté metódou najmenších štvorcov v tvare modelu s korekčným členom. Údajovú základňu tvoria sezónne očistené dáta za obdobie 1994Q1 až 2002Q4.

Hlavný dopytový faktor, použitý v rovnici dovozu tovarov a služieb sú celkové finálne výdavky (total final expenditure), ktoré predstavujú súčet súkromnej spotreby, vládnej spotreby, investícií a vývozu.

⁶ JURIOVÁ, J. 2009. Využívanie modelových prístupov ARIMA a ECM pri odhade priemyselnej produkcie. In *Slovenská štatistika a demografia*. 2009, č. 1-2. str. 3-29

⁷ LIVERMORE, S. 2004. *An econometric model of the Slovak Republic*. Financial Policy Institute, Ministry of Finance of the SR. May 2004, p. 57

Zoznam premenných v regresnej rovnici dovozu tovarov a služieb:

M – dovoz tovarov a služieb do SR

TFE – celkové finálne výdavky

WCR – jednotkové náklady práce

TT – časový trend

U – umelá premenná

$$\Delta \ln M_t = -0,54 + 1,75 \Delta \ln TFE_t - 0,29 (\ln M_{t-1} - \ln TFE_{t-1} - 0,15 \ln WCR_{t-1}) + 0,003 TT + U$$

1.2 Makroekonomické modely dovozu v zahraničí

Zo zahraničných modelov dovozu tovarov a služieb spomenieme modely krajín, ktoré sú zameraním ekonomiky (krajina závislá na dovoze) podobné so Slovenskou republikou, a to Poľsko, Česká republika a Grécko.

Použité vysvetľujúce premenné sú veľmi podobné ako v slovenských modeloch (hlavný vysvetľujúci faktor je hrubý domáci produkt, resp. iba niektoré jeho zložky a deflátor dovozu ako cenový index). Na rozdiel od slovenských modelov, ktoré sú dopytovo orientované, zahraničné modely kladú dôraz na modelovanie ponuky.

1.2.1 Model poľskej ekonomiky NECMOD

Aktualizovanú verziu modelu NECMOD⁸ z roku 2009 v súčasnosti používa Národná banka Poľska (NBP) na prognostické účely, ako aj na cvičné simulácie vývoja národnej ekonomiky. Model NECMOD je zlúčením strednodobého a čiastočne výhľadového štvrt'ročného makroekonomického modelu so základom v ekonomickej teórii. Dôraz kladie na modelovanie strany ponuky a na mechanizmy, ktoré vznikajú po ekonomických šokoch. Modelovanie strany ponuky bolo motivované dynamickým rozvojom pracovného trhu počas transformácie a po vstupe do Európskej únie, ako aj potrebou zaznamenať vplyv prítoku prostriedkov z rôznych štrukturálnych fondov na ekonomiku krajiny. Okrem hlavného zamerania na stranu ponuky (potenciálny output) sa

⁸ Katarzyna, B. et. al. 2009. *An update of the macroeconomic model of the Polish economy NECMOD*. National Bank of Poland, 2009.

model NECMOD venuje aj agregovanému dopytu, domácnostiam (spotreba, príjem), pracovnému trhu (pracovná sila, zamestnanosť, mzdy), zahraničiu (dovoz, vývoz, ceny), fiškálnemu sektoru (príjmy a výdavky vlády) a monetárnemu sektoru a úrokovým mieram.

V súčasnej verzii modelu sa používajú štvrťročné údaje od roku 1995 do 2008, ktoré sú sezónne očistené a zdrojom údajov sú národné účty. Všetky behaviorálne rovnice modelu sú odhadnuté metódou najmenších štvorcov a vyjadrené v tvare ECM.

Zoznam premenných v regresnej rovnici dovozu tovarov a služieb:

gdp_imp – objem dovozu

gdp – hrubý domáci produkt

pimp – deflátor dovozu

GR_TAR_TR – pomer dovozných ciel

pva – deflátor pridanej hodnoty

GFCF – hrubý fixný kapitál

CONP – spotreba domácností

CONGOV – nominálna spotreba vlády

GDP_EXP – objem vývozu

TFP_TREND - total factor productivity

gdp_ext_pot – potenciálny output zahraničia

Regresná rovnica dovozu podľa NBP má tvar:

$$\Delta gdp_imp_t = gdp_t - 0,13(gdp_imp_{t-1} - gdp_imp^*_{t-1}) - 0,55\Delta(pimp_t + GR_TAR_TR_t - pva_t) + 2,16\Delta\log((0,4GFCF_t + 0,2CONP_t + 0,5CONGOV_t + 0,4GDP_EXP_t)/TFP_TREND^{0,67}_t)$$

kde

$$gdp_imp^*_{t-1} = gdp_t - 12,2 + 1,51gdp_ext_pot_t - 1,52(pimp_t + GR_TAR_TR_t - pva_t) + 0,04D04Q3$$

1.2.2 Model dovozu Českej republiky

V práci⁹ publikovanej v roku 2003 autori skúmali, ktoré faktory ovplyvňujú hodnotu a štruktúru dovážaných komodít podľa tried SITC. Dovozy do Českej republiky považujú za funkciu agregovaného dopytu, reprezentovaného hrubým domácim produktom. Potom táto premenná odráža potenciál nákupnej absorpcie agregovaného domáceho dopytu. Autori skúmali zvlášť dovoz z krajín Európskej únie a dovoz zo zvyšku sveta (krajiny mimo EÚ). Rovnice dovozu sú založené na ekonomickej teórii a jednotlivé parametre sú odhadnuté metódou najmenších štvorcov v logaritmickom tvare. Použité časové rady premenných sú za obdobie rokov 1993 až 1999.

Regresná rovnica dovozu do Českej republiky z krajín Európskej únie:

$$\ln(M_t) = 3,557 + 0,359\ln(PM_t) + 0,362\ln(S_t/VA_t) + 0,381\ln(FDI_t) + 1,178\ln(GDP_{cz,t}) - 2,119\ln(RER_t)$$

M – dovoz z krajín EÚ

PM – ceny dovozu

S – dotácie

VA – pridaná hodnota

FDI – priame zahraničné investície

GDP_{cz} – nominálny hrubý domáci produkt

RER – reálny výmenný kurz

Za jedno z najviac prekvapujúcich zistení považujú autori to, že dovoz z krajín EÚ sa nesústreďuje na kapitálovo náročné produkty. Ako cenovú premennú autori použili premennú ceny dovozu, ktorej elasticita je +0,359. Autori nepovažujú domáce ceny za konkurenčnú hrozbu pre krajiny EÚ a myslia si, že výrobky z EÚ sú pre českých spotrebiteľov exkluzívnymi tovarmi a uprednostňujú kvalitné výrobky pred lacnejšími. Priame zahraničné investície reprezentujú ľudský kapitál, ktorého elasticita je kladná a pomerne nízka (0,381). Za ďalšie dôležité zistenie autori považujú hodnotu príjmovej elasticity českého dopytu po dovoze, ktorá je o 18 % vyššia ako jednotková elasticita. To znamená, že s rastom HDP (so silnejúcou českou ekonomikou) nastáva viacej ako

⁹ Benáček, V. – Víšek, J. Á. *Determining Factors of Trade Specialization and Growth of a Small Economy in Transition: Impacts of the EU Opening-up on Czech Exports and Imports*. International Institute for Applied Systems Analysis, Austria, 2003.

proporcionálny rast dovozu tovarov a služieb z EÚ. Významný vplyv reálneho výmenného kurzu naznačuje, že zhodnotenie meny (apreciácia) zvyšuje dovoz. Elasticita je vyššia ako jedna a je zjavné, že znehodnotenie meny (depreciácia) by mohol byť dôležitý nástroj na obnovenie rovnováhy obchodnej bilancie. Na druhej strane, apreciácia môže vážne zasiahnuť domáci vývoz.

Regresná rovnica dovozu do Českej republiky zo zvyšku sveta:

$$\ln(M_t) = 0,448 + 0,095\ln(PM_t) + 0,261\ln(K/L_t) + 0,143\ln(FDI_t) - 0,424\ln(TAR_{czt}) + 0,815\ln(GDP_{czt})$$

K – kapitál (stále ceny r. 1997)

L – práca

TAR – clá a tarify

Evidentný rozdiel oproti predchádzajúcej rovnici je v hodnote parametrov a v dvoch iných premenných – podiel kapitálu a práce, čím chcú autori charakterizovať domáce technológie a clá. Príjmová elasticita dovozu zo zvyšku sveta je dominantnou premennou v tejto regresii. Jej hodnota je menšia ako jedna (0,815), čo znamená, že podiel dovozu z týchto krajín na celkovom dovoze sa časom zníži. Tento dopad sa čiastočne vynahradí vyšším dovozom z krajín EU. Cenový index v tejto rovnici je takmer rovný nule, čo autori vysvetľujú absolútnou neschopnosťou domácich výrobkov konkurovať v nízkej cene výrobkom z rozvojových krajín. V tejto rovnici sa štatisticky významne prejavil aj vplyv ciel a taríf na dovezené výrobky, čo sa nepodarilo zahrnúť do rovnice dovozu z krajín EÚ. Potvrďuje to fakt, že české colné opatrenia sú efektívnym nástrojom na podporu domácej produkcie.

1.2.3 Model dovozu Grécka

Štvrtročný model Gréckej ekonomiky GR-MCM¹⁰ (Multi-Country Model) bol vyvinutý ako súčasť projektu v rámci Európskeho systému centrálnych bánk (ESCB). Model kombinuje krátkodobú dynamiku determinovanú dopytom s neoklasickým

¹⁰ Sideris, D. - Zonzilos, N. *The Greek model of the European system of central bank multi-country model*. Bank of Greece, 2005.

ustáleným (dlhodobým) stavom, riadeným ponukovými faktormi. Odhadnuté dlhodobé vzťahy sú založené na ekonomickej teórii, zatiaľ čo krátkodobé dynamické vzťahy sú špecifikované s ohľadom na štatistickú významnosť. Podľa autorov model poskytuje užitočné a zaujímavé implikácie fungovania Gréckej ekonomiky a ukázal sa byť veľmi vhodný na konštrukciu simulačných cvičení. Model GR-MCM analyzuje vývoj Gréckej ekonomiky počas obdobia rôznych monetárnych a fiskálnych režimov ako aj významných štrukturálnych zmien a sociálnej transformácie. Model odhadnutý s dátami za takéto obdobie môže odhaliť základné sily a mechanizmy, ktoré viedli Grécko ku vstupu do Európskej únie (EMU) a tým by, podľa autorov, mohol poskytnúť užitočné informácie aj pre nových a perspektívnych členov únie.

Model GR-MCM obsahuje 80 rovníc (čo je podľa autorov relatívne málo), z ktorých je 14 dynamických. Bázu dát tvoria štvrťročné časové rady premenných za roky 1980 až 2000 získané z národných účtov zisťovaných podľa metodiky ESA95. Rovnovážne vzťahy sú odhadované kointegračnou analýzou, zatiaľ čo dynamické rovnice sú špecifikované v tvare modelu korigujúcom chyby (ECM). Model sa zameriava na stranu ponuky (zamestnanosť, kapitál), stranu dopytu (spotreba domácností, investície), ceny a mzdy, sektor zahraničného obchodu (vývoz, dovoz) a na sektor vlády a úrokové miery.

Zoznam premenných v regresnej rovnici dovozu tovarov a služieb:

MTR – dovoz tovarov a služieb

TFER – dopytový indikátor (demand indicator)

MTR/MTRSTAR – člen korigujúci chyby

MTD – deflátor dovozu

YED – deflátor HDP

PCR – domáci dopyt

ITR – hrubý fixný kapitál

XTR – vývoz tovarov a služieb

Rovnica dovozu tovarov a služieb do Grécka má tvar:

$$\Delta \log(MTR)_t = -0,002 + 1,922 \Delta \log(TFER)_t - 0,323 \Delta \log(TFER)_{t-1} - 0,182 \log(MTR/MTRSTAR)_{t-2} - 0,313 \Delta \log(MTD/YED)_t$$

kde $TFER = 0,25PCR + 0,5ITR + 0,4XTR$

Dynamická rovnica dovozu je vyjadrená v štandardnom tvare ECM. Hlavnými vysvetľujúcimi premennými sú dopytový indikátor (demand indicator) v čase t aj $t-1$ a relatívne ceny (MTD/YED). Autori upozorňujú na relatívne vysokú elasticitu pri premennej $TFER$ (1,922).

2 Ciele práce

Hlavným cieľom dizertačnej práce je navrhnúť prognostický model dovozu tovarov a služieb do SR.

Dovoz v malej a otvorenej slovenskej ekonomike predstavuje dôležitý makroekonomický ukazovateľ, ktorého budúci vývoj treba vhodne regulovať pre podporu rastu domácej ekonomiky.

Okrem toho je dôležité analyzovať aj determinanty vývoja dovozu tovarov a služieb, ako sú napr. tvorba kapitálu alebo domáci dopyt, aby tvorcovia hospodárskej politiky mali k dispozícii okrem prognóz aj kvantitatívny nástroj politického rozhodovania.

Takúto úlohu možno riešiť rôznymi metodologickými postupmi od jednoduchých prognostických modelov založených na analýze iba jedného časového radu, cez viacnásobnú regresiu časových radov, klasickú ekonometrickú analýzu alebo dynamické modelovanie.

V našom prípade sme zvolili štatistický prístup založený na najnovších vedeckých poznatkoch dynamického modelovania časových radov s cieľom poukázať na fakt, že moderné štatisticko-ekonometrické metódy môžu poskytovať práve tak dobré výsledky prognóz makroekonomických ukazovateľov, ako zložité viacrovnícové ekonometrické modely. Z tohto zámeru vyplývajú nasledujúce čiastkové ciele.

Čiastkové ciele dizertačnej práce sú nasledovné:

- Analyzovať historický vývoj dovozu tovarov a služieb do Slovenskej republiky v rokoch 1995 až 2008 na základe štvrťročného časového radu Q1/1995 – Q4/2008.

Slovensko je charakteristické svojou výrazne otvorenou ekonomikou. Ekonomický rast je často dosahovaný práve z dôvodu vývoja v zahraničnom obchode. V minulosti vláda ovplyvňovala dovoz častými zmenami výšky dovoznej prirážky a zmenami objemu kvót. Nepriaznivý vývoj zahraničného obchodu si vyžiadal až zmenu kurzového režimu slovenskej koruny z fixného na plávajúci v októbri 1998. So silnejúcou slovenskou ekonomikou a vstupom do rôznych ekonomických zoskupení sa menil objem a aj teritoriálna a tovarová štruktúra dovozu tovarov a služieb do SR. Preto je dôležité poznať jeho historický vývoj.

- Popísať metodológiu troch zvolených moderných štatistických a ekonometrických metód a to: SARIMA modely, vektorovo-autoregresný model (VAR) a model s členom korigujúcim chybu (ECM).

Prístup SARIMA modelov skúma jednorozmerný časový rad so sezónnou zložkou. Túto metodológiu „autoregresne integrovaných kľzavých priemerov“ vyvinuli autori Box a Jenkins v 70-tych rokoch. Pomocou tohto prístupu sa dá rýchlo a s dnešnou výpočtovou technikou aj pomerne ľahko modelovať minulý vývoj časového radu a tiež určiť dostatočne presnú krátkodobú prognózu na najbližšie obdobie.

VAR model predstavuje viacrozmerné zovšeobecnenie autoregresných modelov jednorozmerných časových radov, v ktorom sa môžu vyskytovať premenné ovplyvňujúce dovoz do SR. VAR modely veľmi nezohľadňujú ekonomickú teóriu, pretože ako vysvetľujúce premenné sa v každej rovnici vektorovo-autoregresného modelu objavujú oneskorené hodnoty všetkých endogénnych premenných. Výhodou VAR modelov je, že prognóza skonštruovaná na ich základe, môže byť presnejšia, ako predpoveď založená na modeli iba jedného časového radu.

Model ECM je síce jednorovnicovým modelom, ale umožňuje rozlišovať dlhodobý vzťah medzi premennými a na rozdiel od klasických ekonometrických modelov dokáže vyjadriť aj krátkodobý vplyv vysvetľujúcich premenných na vývoj skúmanej premennej. Predpoveď pomocou ECM však závisí od presnosti prognózy vysvetľujúcich premenných.

- Analyzovať stacionárnosť, integrovanosť a kointegráciu časových radov vstupujúcich do modelu dovozu tovarov a služieb.

Všetky použité metódy (SARIMA, VAR, ECM) vyžadujú stacionárne časové rady (premenné). Časový rad je slabo stacionárny, keď má konštantný priemer a rozptyl a kovariancia medzi pozorovaniami závisí iba od posunu (lagu) medzi nimi, a nie od konkrétneho času. Je všeobecne známe, že časové rady makroekonomických ukazovateľov sú nestacionárne. Preto prvým krokom konštrukcie modelu je analýza stupňa (rádu) integrácie premenných, teda počtu diferencií potrebných na ich stacionarizovanie. Metóda ECM vyžaduje okrem stacionárnosti aj kointegrovanosť uvažovaných premenných. Ak premenné nie sú kointegrované, každá má iný smer vývoja a pri skúmaní vzťahov medzi takýmito premennými pomocou regresnej analýzy vzniká stav tzv. zdanlivej (falošnej)

regresie. Naopak, ak sú rady kointegrované, majú dlhodobu spoločný smer, ktorý možno modelovať.

- Odhadnúť, verifikovať jednotlivé modely a porovnať presnosť zvolených modelov dovozu tovarov a služieb do SR pomocou ex-post analýzy.

Dôkladné overenie kvality a presnosti odhadu vývoja skúmanej premennej modelom je dôležité pre určenie správnej prognózy v ďalšom kroku. Ak model nevystihuje dobre historický vývoj skúmanej premennej, obyčajne nie je ani vhodný na prognostické účely, a v takom prípade treba zvoliť inú metódu odhadu alebo iné vysvetľujúce premenné.

- Určiť krátkodobú prognózu vývoja dovozu tovarov a služieb do SR na jednotlivé štvrťroky roka 2010 pomocou zvolených a verifikovaných modelov. Porovnať získané prognózy medzi sebou a tiež s prognózou vývoja dovozu stanovenou Výborom pre makroekonomické prognózy Ministerstva financií SR.

Každým zvoleným metodologickým prístupom určíme krátkodobú prognózu dovozu tovarov a služieb na štvrťroky roka 2010. V dnešnej dobe sú ekonomiky štátov a celý finančný trh dosť nestabilné a kríza, menšia či väčšia, môže nastať kedykoľvek a bez varovania, takže sa podstatne môže zmeniť vývoj makroekonomických ukazovateľov. Toto je dôvod, že prognózu dovozu tovarov a služieb do SR budeme určovať iba na obdobie do jedného roku. Ak sa model osvedčí, nie je problém horizont prognózy predĺžiť alebo ju aktualizovať.

- Zdôrazniť rozdielnosť metodologických postupov a ich vplyv na určenie prognózy.

Zvolené prístup majú svoje výhody aj nevýhody. Ak chceme zistiť iba prognózu premennej na najbližšie obdobie, vhodným prístupom je model SARIMA, ktorý umožňuje jednoducho a rýchlo odhadnúť a prognózovať vývoj časového radu. VAR modely umožňujú zase použitím analýzy reakcie na impulz skúmať akú reakciu v jednom časovom rade vyvolá impulz v inom časovom rade v rámci systému, ktorý obsahuje ešte ďalšie časové rady, a tým sa dá zistiť stabilita celého systému. Prístup ECM umožňuje používateľovi zistiť krátkodobý aj dlhodobý vplyv vysvetľujúcich premenných na závislú premennú. Vyžaduje si však zvládnutie väčších teoretických vedomostí.

3 Metodika práce a metódy skúmania

3.1 Boxova-Jenkinsova metodológia ARIMA modelov časových radov

Boxova-Jenkinsonova metodológia stochastickej koncepcie tvorby modelov je východiskom pre modelovanie nestacionárnych časových radov, sezónnych časových radov, ale tiež stacionárnych a nestacionárnych viacrozmerných časových radov. Pri analýze jednorozmerných časových radov môžeme sledovať dva základné ciele - nájsť čo najlepší model vhodný pre konštrukciu predpovedí budúceho vývoja časového radu a získať informácie o vlastnostiach jednotlivých časových radov, ktoré sú nevyhnutné pre skúmanie ich vzťahov. Analýza jednorozmerných časových radov má tiež didaktický význam, pretože pochopenie základných pojmov tejto disciplíny je predpokladom pre pochopenie zložitejších disciplín modelovania viacrozmerných časových radov.

3.1.1 Modely stacionárnych časových radov

Stochastický proces je v čase usporiadaná postupnosť náhodných veličín $\{y(s,t), s \in S, t \in T\}$, kde S nazývame výberový priestor a T je indexová množina. Pre každé $s \in S$ je $y(s, \cdot)$ realizácia stochastického procesu definovaná na indexovej množine T , t.j. usporiadaná postupnosť čísel – časový rad.

Stacionarita

Ekonomické časové rady majú takú vlastnosť, že ich hodnoty nemajú tendenciu vracaať sa k nejakej konštante. Táto vlastnosť sa označuje ako *nestacionarita* a je typická pre viaceré makroekonomické premenné.

Proces je *striktne stacionárny* ak jeho pravdepodobnostné rozdelenie je v čase stabilné, t.j. jeho správanie je nezávislé (invariantné) od času, teda stredná hodnota i rozptyl časového radu sú konštantné, platí¹¹:

- stredná hodnota $\mu = E(y_t)$
- rozptyl $\sigma^2 = D(y_t) = E(y_t - \mu)^2$

¹¹ CHATFIELD, Ch. 1995. *The analysis of time series*. London : Chapman and Hall/CRC. 1995. s. 28-29

- autokovariančná funkcia medzi y_{t-k} a y_t , kde $k = 1, 2, \dots, n$

$$\gamma(k) = E[(y_{t-k} - \mu)(y_t - \mu)]$$

- korelačná funkcia y_{t-k} a y_t , kde $k = 1, 2, \dots, n$ $\rho(k) = \frac{\gamma(k)}{\gamma(0)}$ (3.1.1)

Ak priemer a rozptyl sú konštantné v čase a kovariancia medzi hodnotami z dvoch rôznych pozorovaní závisí iba od dĺžky časového intervalu, ktorý medzi nimi uplynul, a nie od konkrétneho času, ku ktorému prislúchajú, takýto proces nazývame *slabo (kovariančne) stacionárny*¹² ak neuvažujeme jeho pravdepodobnostné rozdelenie, t.j. pre všetky t platí, že $\mu_t = \mu$, $\sigma_t^2 = \sigma^2$:

$$\gamma(t-k, t) = \gamma(t, t+k) = \gamma_k$$

$$\rho(t-k, t) = \rho(t, t+k) = \rho_k \quad (3.1.2)$$

Striktne stacionárny proces, ktorý má prvé dva všeobecné momenty (priemerná hodnota a rozptyl) konečné, je tiež slabo stacionárny proces. V praktickej analýze časových radov sa uvažuje najčastejšie podmienka slabej stacionarity, pretože je relatívne ľahké odhadovať prvé dva momenty. V prípade, že budeme ďalej hovoriť o stacionarite, budeme mať na mysli práve slabú stacionaritu.

Ak náhodné veličiny stochastického procesu majú normálne rozdelenie, potom ide o normálny (gaussovský) stochastický proces.¹³

Autokorelačná a výberová autokorelačná funkcia

Autokorelačná funkcia (*autocorrelation function*; ACF) medzi veličinami y_t a y_{t-k} možno v prípade stacionárneho stochastického procesu y_t vyjadriť ako¹⁴:

$$\rho_k = \frac{\text{cov}(y_t, y_{t-k})}{\sqrt{D(y_t)}\sqrt{D(y_{t-k})}} = \frac{\gamma_k}{\gamma_0} \quad (3.1.3)$$

kde γ_0 je autokovariančná funkcia definovaná takto:

$$\gamma_k = \text{cov}(y_t, y_{t-k}) = E(y_t - \mu)(y_{t-k} - \mu) \quad (3.1.4)$$

a vzhľadom na stacionaritu procesu platí $D(y_t) = D(y_{t-k}) = \gamma_0$.

¹² LUKÁČIKOVÁ, A. – LUKÁČIK, M. 2008. *Ekonomické modelovanie s aplikáciami*. Bratislava : Vydavateľstvo EKONÓM, 2008. s. 185

¹³ ARLT, J - ARLTOVÁ, M. 2007. *Ekonomické časové rady*. Praha : Grada Publishing, 2007. s. 25

¹⁴ RUBLÍKOVÁ, E - PRÍHODOVÁ, I. 2008. *Analýza vybraných časových radov - ARIMA modely*. Bratislava : Vydavateľstvo EKONÓM, 2008, s. 20

Pre stacionárny stochastický proces má autokorelačná funkcia tieto vlastnosti:

- $\rho_0 = 1$
- $|\gamma_k| \leq \gamma_0$ a $|\rho_k| \leq 1$
- $\gamma_k = \gamma_{-k}$ a $\rho_k = \rho_{-k}$ pre všetky k , autokovariančná a autokorelačná funkcia sú teda symetrické okolo $k = 0$, pretože časová vzdialenosť medzi dvojicami premenných y_t, y_{t-k} a y_{t-k}, y_t je rovnaká.

Autokorelačná funkcia ρ_k pre $k = 1, 2, \dots$ hodnotí silu lineárnej zvislosti medzi časovými radmi y_t a y_{t-k} . Sledovaná závislosť môže byť spôsobená koreláciou týchto dvoch radov s tretím radom, napr. y_{t-1} . Veľká časť korelácie medzi radmi y_t a y_{t-k} môže byť zapríčinená aj koreláciou s ďalšími radmi $y_{t-2}, \dots, y_{t-k+1}$.

Obvykle parametre μ , γ_0 ani ρ_k nepoznáme. Za predpokladu stacionarity môžeme strednú hodnotu procesu μ odhadnúť pomocou výberového priemeru:

$$\bar{y} = \frac{1}{T} \sum_{t=1}^T y_t \quad (3.1.5)$$

kde T je počet hodnôt (pozorovaní) časového radu a y_t sú hodnoty týchto pozorovaní.

Rozptyl procesu odhadujeme výberovým rozptylom:

$$s^2 = \frac{1}{T-1} \sum_{t=1}^T (y_t - \bar{y})^2 \quad (3.1.6)$$

Potom odhadom ρ_k je koeficient r_k výberovej autokorelačnej funkcie¹⁵:

$$r_k = \frac{\sum_{t=k+1}^T (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2} \text{ pre } k = 0, 1, 2, \dots, \text{ kde} \quad (3.1.7)$$

r_k je koeficient korelácie v k -tom oneskorení,

y_t je hodnota pozorovania časového radu v okamihu t ,

$\bar{y}$ je priemer hodnôt časového radu,

T je počet pozorovaní.

Výberová autokorelačná funkcia (VACF) je teda autokorelačná funkcia určená z hodnôt časového radu y_t . Analýzou grafu VACF (korelogramu) dokážeme posúdiť štatistickú významnosť jednotlivých koeficientov autokorelácie na zvolenej hladine

¹⁵ RUBLÍKOVÁ, E - PRÍHODOVÁ, I. 2008. *Analýza vybraných časových radov - ARIMA modely*. Bratislava : Vydavateľstvo EKONÓM, 2008, s. 23

významnosti, čo je dôležité nielen pre testovanie stacionarity radu, ale hlavne pre identifikáciu typu modelu a počtu jeho parametrov. Časový rad je nestacionárny, VACF má tvar lineárneho trendu, teda ak koeficienty autokorelácie s posunom oneskorenia k klesajú veľmi pomaly. Ak máme štvrťročné časové rady, potom o nestacionarite radu rozhodujeme na základe významnosti koeficientov autokorelácie maximálne do posunu $k = 3$; pre mesačné časové rady maximálne do posunu $k = 4$ (alebo 5).

Parciálna a výberová parciálna autokorelačná funkcia

Parciálna autokorelačná funkcia (*partial autocorrelation function*; PACF) na rozdiel od autokorelačnej funkcie informuje o korelácii medzi časovými radmi y_t a y_{t-k} očistenej o vplyv radov ležiacich medzi nimi.

Výberovú parciálnu autokorelačnú funkciu f_{kk} získame nahradením ρ_k jeho odhadom r_k . Durbin na výpočet koeficientov autokorelácie vo výberovej parciálnej autokorelačnej funkcii navrhol rekurentný vzťah¹⁶:

$$f_{kk} = \frac{r_k - \sum_{j=1}^{k-1} f_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} f_{k-1,j} r_j} \quad (3.1.8)$$

$$f_{kk} = f_{k-1,j} - f_{kk} f_{k-1,k-j} \text{ pre } j = 1, 2, \dots, k-1$$

Prvý výberový parciálny koeficient autokorelácie je rovnaký ako prvý výberový koeficient autokorelácie.

Korelogram

Korelogram je graf autokorelačnej alebo parciálnej autokorelačnej funkcie. Tieto grafy nachádzajú uplatnenie pri modelovaní časových radov a pri ich dekompozícii. Jednotlivé stĺpce autokorelačnej funkcie zobrazujú autokorelačné koeficienty, ktoré vyjadrujú silu lineárnej závislosti medzi hodnotami časového radu. Prvý stĺpec vyjadruje intenzitu lineárnej závislosti medzi časovým radom y_t a časovým radom y_{t-1} pre $t = 2, 3, 4, \dots, T$, druhý stĺpec medzi radom y_t a y_{t-2} , pre $t = 3, 4, \dots, T$ atď.

¹⁶ RUBLÍKOVÁ, E - PRÍHODOVÁ, I. 2008. *Analýza vybraných časových radov - ARIMA modely*. Bratislava : Vydavateľstvo EKONÓM, 2008, s. 24

Prvý stĺpec parciálnej autokorelačnej funkcie je totožný s prvým stĺpcom autokorelačnej funkcie. Druhý stĺpec vyjadruje intenzitu lineárnej závislosti medzi časovým radom y_t a y_{t-2} pre $t = 3, 4, \dots, T$, nezohľadňuje pri tom ale vplyv radu y_{t-1} atď.

Biely šum

Stochastický proces y_t , ktorý je radom nekorelovaných náhodných veličín s rovnakým rozdelením pravdepodobnosti a s vlastnosťami:

- $E(y_t) = 0$
- $D(y_t) = \sigma^2$, konštantný rozptyl pre všetky t ,
- $cov(y_t; y_{t-k}) = \gamma_k = 0$, nulovou kovarianciou medzi časovým radom v čase t a časovým radom posunutým o k oneskorení pre všetky $k \neq 0$, nazývame *proces bieleho šumu*.

Proces bieleho šumu je stacionárny. Základnou vlastnosťou procesu bieleho šumu je, že jeho ACF a PACF sú nulové. Tento proces sa prakticky nevyskytuje, je však základným stavebným prvkom pri verifikácii modelov časových radov.

Autoregresný proces p -teho stupňa AR(p)

Autoregresný proces predstavuje modelovanie vývoja hodnôt časového radu na základe časovo oneskorených hodnôt toho istého časového radu, teda závislosť časového radu od jeho vlastných oneskorených hodnôt. Autoregresný proces umožňujúci modelovať lineárnu závislosť hodnôt časového radu y_t od viacerých (p) oneskorených hodnôt sa nazýva autoregresný proces p -teho stupňa (*autoregressive process of order p [AR(p)]*).

V prípade, že $E(y_t) = \mu \neq 0$, má model AR(p) tvar¹⁷:

$$y_t = \phi_0 + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + a_t \quad (3.1.09)$$

kde $\phi_0 = (\mu - \phi_1 \mu - \dots - \phi_p \mu) = \mu(1 - \sum_{j=1}^p \phi_j)$

Ak $E(y_t) = 0$, model sa zjednoduší na tvar:

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + a_t \quad (3.1.10)$$

¹⁷ ARLT, J - ARLTOVÁ, M. 2007. *Ekonomické časové řady*. Praha : Grada Publishing, 2007, s. 31

Tento proces možno pomocou spätného operátora B^{18} zapísať:

$$(1 - \phi_1 B - \dots - \phi_p B^p)y_t = a_t \quad (3.1.11)$$

Nevyhnutnou podmienkou použitia AR modelu je *stacionarita*. Proces $AR(p)$ je stacionárny, ak ho možno transformovať do tvaru lineárneho procesu, t.j. ak korene polynomickej rovnice $(1 - \phi_1 B - \dots - \phi_p B^p) = 0$ ležia mimo jednotkového kruhu, resp. ak platí $\phi_1 + \phi_2 + \dots + \phi_p < 1$.

Rozptyl procesu $AR(p)$ možno pomocou σ_a^2 , ϕ_1 , ..., ϕ_p pri známych hodnotách ρ_1 , ..., ρ_p vyjadriť ako:

$$\gamma_0 = \frac{\sigma_a^2}{1 - \phi_1 \rho_1 - \dots - \phi_p \rho_p} \quad (3.1.12)$$

Hodnoty teoretickej autokorelačnej funkcie získame zo vzťahu:

$$\rho_k = \phi_1 \rho_{k-1} + \dots + \phi_p \rho_{k-p}, \text{ pre } k = 1, 2, \dots \quad (3.1.13)$$

Ak sú korene rovnice $\phi_p(B) = 0$ reálne, ACF exponenciálne klesá k nule, ak sú korene rovnice komplexné, ACF exponenciálne klesá k nule v sínusových vlnách.

Hodnoty PACF sú pre oneskorenie $k = 1, 2, \dots, p$ rôzne od nuly, pre ďalšie oneskorenia sa rovnajú nule. Počet štatisticky významných koeficientov v grafe PACF určuje stupeň $AR(p)$ modelu.

Proces kľzavých priemerov q -teho stupňa $MA(q)$

Namiesto vysokého stupňa AR procesu je vhodné použiť model procesu kľzavých priemerov q -teho stupňa (*moving average process of order q* [$MA(q)$]). Termín „kľzavý priemer“ sa používa z toho dôvodu, že premenná y_t vzniká ako vážená suma z hodnôt rezíduí sledovaného časového radu a je podobná priemeru. Podstata procesov kľzavých priemerov sa zakladá na myšlienke opísať vývoj hodnôt časového radu y_t prostredníctvom časového radu náhodných šokov a_t .

Všeobecný zápis procesu kľzavých priemerov vyjadruje, že hodnoty časového radu y_t lineárne závisia od q oneskorených hodnôt náhodných šokov a_t .

¹⁸ Spätný operátor (backshift operator) predstavuje oneskorenie o jedno obdobie, tzn. že $By_t = y_{t-1}$ a všeobecne potom $B^p y_t = y_{t-p}$. V prípade konštanty platí $B^p \mu = \mu$. Operátor B umožňuje najmä modely s viacerými oneskoreniami zapísať stručnejším spôsobom. [Arlt, 1999, s. 23]

Proces kľzavých priemerov môžeme zapísať v tvare (ak $E(y_t) = \mu \neq 0$)¹⁹:

$$y_t = \phi_0 + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (3.1.14)$$

kde $\phi_0 = \mu$.

Ak $E(y_t) = \mu = 0$, potom model môžeme zapísať v tvare:

$$y_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (3.1.15)$$

Spätný operátor umožňuje tento zápis modelu MA(q):

$$y_t = \theta_q(B)a_t \quad (3.1.16)$$

Model MA je konečnou formou lineárneho procesu, z čoho vyplýva, že všetky modely MA sú stacionárne. Aby bolo možné jednoznačne interpretovať jeho výsledky, musí byť proces MA *invertibilný*. Proces MA je invertibilný, ak sa dá vyjadriť vo forme reprezentácie AR(∞), ktorá konverguje. Táto podmienka je splnená, ak korene polynomickej rovnice $(1 - \theta_1 B - \dots - \theta_q B^q) = 0$ ležia mimo jednotkového kruhu, t.j. ak platí $\theta_1 + \theta_2 + \dots + \theta_q < 1$. Je zrejmé, že nie každý stacionárny proces je proces invertibilný. A rovnako každý invertibilný proces nemusí byť procesom stacionárnym. Podmienka invertibility má význam predovšetkým pre konštrukciu predpovedí.

ACF procesu MA(q) má tvar²⁰:

$$\rho_k = \frac{-\theta_k + \theta_1 \theta_{k+1} + \dots + \theta_{q-k} \theta_q}{1 + \theta_1^2 + \dots + \theta_q^2} \text{ pre } k = 1, 2, \dots, q \quad (3.1.17)$$

a $\rho_k = 0$ pre $k > q$. Hodnoty ACF sú pri oneskorení $k = 1, 2, \dots, q$ rôzne od nuly, pre ďalšie oneskorenia sa nule rovnajú. ACF hovorí o tom, aký stupeň MA procesu je potrebný zaradiť do modelu na odstránenie autokorelácie zo stacionarizovaného časového radu. PACF v prípade reálnych koreňov rovnice $\theta_q(B) = 0$ exponenciálne klesá. V prípade komplexných koreňov tejto rovnice PACF klesá exponenciálne v sínusových vlnách.

Zmiešaný proces ARMA (p, q)

Tento proces možno vyjadriť, ak $E(y_t) = 0$, takto²¹:

$$\phi_p(B)y_t = \theta_q(B)a_t \quad (3.1.18)$$

¹⁹ ARLT, J - ARLTOVÁ, M. 2007. *Ekonomické časové rady*. Praha : Grada Publishing, 2007. s. 34

²⁰ RUBLÍKOVÁ, E - PRÍHODOVÁ, I. 2008. *Analýza vybraných časových radov - ARIMA modely*. Bratislava : Vydavateľstvo EKONÓM, 2008, s. 41

²¹ ARLT, J - ARLTOVÁ, M. 2007. *Ekonomické časové rady*. Praha : Grada Publishing, 2007. s. 36

V prípade, ak $E(y_t) \neq 0$, zmiešaný proces môžeme vyjadriť nasledovne:

$$\phi_p(B)y_t = \phi_0 + \theta_q(B)a_t \quad (3.1.19)$$

$$\text{kde } \phi_0 = (\mu - \phi_1\mu - \dots - \phi_p\mu) = \mu(1 - \sum_{j=1}^p \phi_j)$$

Boxova a Jenkinsova metodológia vyžaduje, aby model, ktorý opisuje minulý vývoj a má slúžiť na prognózovanie, spĺňal podmienky stacionarity a invertibility. Aby bol tento proces stacionárny, musia korene rovnice $\phi_p(B) = 0$ ležať mimo jednotkového kruhu, t.j. absolútny súčet parametrov procesu $AR(p)$ musí byť menší ako jeden. Na to, aby bol proces invertibilný, musia korene rovnice $\theta_q(B) = 0$ ležať mimo jednotkového kruhu, teda absolútny súčet parametrov procesu $MA(q)$ musí byť menší ako jeden. V prípade zmiešaného procesu $ARMA(p, q)$ musia byť splnené obe podmienky súčasne.

Skúmať podmienky stacionarity a invertibility je dôležité najmä preto, že odhad parametrov modelov sa robí iteratívnymi technikami, ktoré požadujú začiatkové odhady navrhnutých modelov spĺňajúce podmienky stacionarity aj invertibility. Je preto zrejmé, že i konečné odhady parametrov modelov získané iteračnou metódou musia spĺňať podmienky stacionarity a invertibility. Ak tieto podmienky nie sú splnené, konkrétny odhadnutý model nie je adekvátny. Potom treba hľadať iný, vhodnejší model.

Teoretickú autokovarianciu a autokoreláciu získame z rovníc:

$$\gamma_k - \phi_1\gamma_{k-1} - \dots - \phi_p\gamma_{k-p} = 0 \text{ pre } k > q \quad (3.1.20)$$

$$\rho_k - \phi_1\rho_{k-1} - \dots - \phi_p\rho_{k-p} = 0 \text{ pre } k > q \quad (3.1.21)$$

Z týchto rovníc vyplýva, že proces $ARMA(p, q)$ bude mať podobný tvar ako proces $AR(p)$. ACF bude exponenciálne klesať, resp. exponenciálne klesať v sínusových vlnách. Tento tvar však bude nasledovať až po prvých $q-p$ hodnotách, ak $q > p$. Hodnoty $\rho_0, \rho_1, \dots, \rho_{q-p}$ tento tvar mať nebudú.

V prípade procesu $ARMA(p, q)$ sa PACF pre $k > p-q$, ak $p > q$ bude správať ako pri procese $MA(q)$. Pre $k \leq p-q$ je tvar PACF úplne odlišný.

Vo výberových ACF a PACF sa môže vyskytnúť situácia, že obe funkcie klesajú k nule rýchlo, t.j. žiadna z nich nemá charakter exponenciálneho klesania s rastúcim posunom k . V takomto prípade treba sledovať, ktorá z funkcií klesá k nule rýchlejšie, t.j. má menší počet štatisticky významných koeficientov. Ak VACF klesá rýchlejšie, potom

volíme model $MA(q)$. Naopak, ak VPACF klesá rýchlejšie, potom volíme model $AR(p)$. Ak obe funkcie klesajú k nule rovnako rýchlo, potom odhadneme oba modely a na základe verifikácie oboch odhadnutých modelov rozhodneme, ktorý model je vhodnejší.

Metóda odhadu parametrov

Na odhady parametrov modelov časových radov možno použiť *jednoduchú metódu najmenších štvorcov* (ordinary least squares; OLS) iba vtedy, ak nie sú veličiny nesystematickej zložky autokorelované, t.j. vtedy ak v stacionárnom modeli $ARMA(p, q)$ platí, že $q = 0$. Pokiaľ táto podmienka nie je splnená, vzniká problém, pretože odhady parametrov časti AR sú vychýlené a nie sú konzistentné²².

Pre odhad parametrov všeobecného modelu $ARMA(p, q)$ sa používa nelineárna metóda najmenších štvorcov. Táto metóda vychádza z prvotných odhadov parametrov, ktoré sa iteratívne inovujú. Iterácie pokračujú tak dlho, pokiaľ nie sú dosiahnuté dopredu špecifikované kritéria konverencie. Na dosiahnutie úplnej a rýchlej konverencie bolo vyvinutých množstvo algoritmov.

Iteračné metódy odhadov parametrov umožňujú získať aj odhady smerodajných odchýlok odhadov parametrov a tak konštruovať t -testy na testovanie jednotlivých parametrov zvoleného modelu. Avšak vypovedacia schopnosť týchto testov je v niektorých prípadoch nesprávna práve kvôli iteračným spôsobom získania odhadov smerodajných odchýlok²³.

Prognózovanie na základe modelov stacionárnych časových radov (s nenulovou strednou hodnotou)²⁴

Jednou zo základných úloh analýzy ekonomických časových radov je tvorba predpovedí.

²² ARLT, J. 1999. *Moderní metody modelování ekonomických časových řad*. Praha : Grada, 1999. s 67

²³ ARLT, J. 1999. *Moderní metody modelování ekonomických časových řad*. Praha : Grada, 1999. s 66

²⁴ RUBLÍKOVÁ, E - PRÍHODOVÁ, I. 2008. *Analýza vybraných časových radov - ARIMA modely*. Bratislava : Vydavateľstvo EKONÓM, 2008, s. 57 - 64

Prognózovanie autoregresných procesov AR(p)

Prognózu procesu AR(p) na h období dopredu pre $j = 1, 2, \dots, h$ vyjadríme nasledovne:

$$(y_{t+j}^* | t - \mu) = \phi_1(y_{t+j-1}^* | t - \mu) + \phi_2(y_{t+j-2}^* | t - \mu) + \dots + \phi_p(y_{t+j-p}^* | t - \mu) \quad (3.1.22)$$

kde $y_{\tau|t} = y_{\tau}$ pre $\tau \leq t$.

Prognózovanie procesov kĺzavých priemerov MA(q)

Pre horizont prognózy $h = 1, 2, \dots, q$ je prognóza procesov MA(q) definovaná ako:

$$y_{t+h}^* | t = \mu + (\theta_h + \theta_{h+1}B + \dots + \theta_q B^{q-h})a_t \quad (3.1.23)$$

kde $a_t = (y_t - \mu) - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$

Prognózovanie zmiešaných procesov ARMA(p, q)

Prognóza zmiešaného procesu ARMA(p, q) na h období dopredu má tvar:

$$(y_{t+h}^* | t - \mu) = \phi_1(y_{t+h-1} | t - \mu) + \phi_2(y_{t+h-2} | t - \mu) + \dots + \phi_p(y_{t+h-p} | t - \mu) + \theta_h a_t + \theta_{h+1} a_{t-1} + \dots + \theta_q a_{t+h-q} \text{ pre } h = 1, 2, \dots, q \quad (3.1.24)$$

A pre $h = q+1, q+2, \dots$, má tvar:

$$(y_{t+h}^* | t - \mu) = \phi_1(y_{t+h-1} | t - \mu) + \phi_2(y_{t+h-2} | t - \mu) + \dots + \phi_p(y_{t+h-p} | t - \mu) \quad (3.1.25)$$

Takže pre horizont prognózy dlhší ako stupeň q procesu kĺzavých priemerov sa prognóza určuje len autoregresným procesom p -teho stupňa.

Smerodajná odchýlka chýb prognóz

Táto miera sa používa pri rozhodovaní o výbere vhodného modelu na prognózovanie z viacerých modelov. Vyberá sa model s najnižšou hodnotou tejto charakteristiky.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (3.1.26)$$

3.1.2 Modely homogénne nestacionárnych časových radov

Stacionárne časové rady sú často označované ako časové rady s krátkou pamäťou, nestacionárne časové rady ako rady s dlhou pamäťou. V časových radoch s krátkou pamäťou sa vplyv šoku z minulého obdobia postupne vytráca, v radoch s dlhou pamäťou sa ale prejavuje neustále. Odlišnosti týchto časových radov sú dané predovšetkým

zásadnými rozdielmi v ich generujúcich procesoch. Nestacionarita časových radov je typická pre časové rady makroekonomických ukazovateľov. Nestacionarita procesu môže byť spôsobená v čase sa meniacou strednou hodnotou procesu alebo v čase sa meniacim rozptylom procesu alebo oboje.

Homogénne nestacionárne časové rady sú rady, ktoré majú stochastické trendy typu polynómu (najčastejšie prvého a druhého stupňa). Takéto časové rady sa dajú stacionarizovať nesezónnymi diferenciami.

Proces náhodnej prechádzky (Random walk process)

Špeciálnym prípadom nestacionárneho časového radu je náhodná prechádzka. Je to náhodný proces, ktorý sa dá opísať modelom AR(1), v ktorom $\phi_1 = 1$. Je definovaný ako proces, v ktorom súčasná hodnota premennej pozostáva z minulej hodnoty tejto premennej a náhodného šoku. Môžeme ho zapísať v tvare:

$$y_t = 1 \cdot y_{t-1} + a_t \quad (3.1.27)$$

Pomocou spätného operátora B ho môžeme zapísať v tvare:

$$(1 - B)y_t = a_t \quad (3.1.28)$$

Vzhľadom k tomu, že:

$$(1 - B)^{-1} = (1 + B + B^2 + \dots) \quad (3.1.29)$$

môžeme proces (3.1.28) prepísať do formy

$$y_t = (1 + B + B^2 + \dots)a_t = a_t + a_{t-1} + a_{t-2} + \dots^{25}. \quad (3.1.30)$$

Je teda zrejmé, že proces náhodnej prechádzky je tvorený kumulovaním náhodných veličín tvoriacich proces bieleho šumu. Proces náhodnej prechádzky je tiež nazývaný integrovaný proces stupňa jeden $I(1)$.

²⁵ ARLT, J. 1999. *Moderní metody modelování ekonomických časových řad*. Praha : Grada, 1999. s 48

Náhodná prechádzka má tieto vlastnosti:

- $E(y_t) = y_0$ – nepodmienená stredná hodnota je konštantná a nezávislá od času,
- $D(y_t) = t\sigma_a^2$ – nepodmienený rozptyl závisí na čase,
- $E(y_t - y_0)(y_{t-k} - y_0) = (t-k)\sigma_a^2$ – nepodmienený rozptyl od času $(t-k)$ je:
 $D(y_{t-k}) = (t-k)\sigma_a^2$,
- korelačný koeficient $\rho_k = \frac{t-k}{\sqrt{(t-k)t}} = \frac{\sqrt{t-k}}{\sqrt{t}} = \sqrt{1-\frac{k}{t}}$,

závisí od času t a pri $t \rightarrow \infty$ pri danom posune k konverguje k jednej.

Z týchto vlastností vyplýva, že náhodná prechádzka je *nestacionárny proces*. Zdrojom nestacionarity je stochastický trend $\sum_{j=1}^t a_j$.

Procesy ARIMA(p, d, q)

Nestacionaritu procesov, ktorých výsledkom sú ekonomické časové rady, spôsobuje najmä prítomnosť trendu. Na stacionarizovanie časového radu nestacionárneho v strednej hodnote môžeme použiť diferenciáciu d -teho stupňa. Potom výsledný proces môžeme často vyjadriť vo forme stacionárneho a invertibilného modelu ARMA(p, d). Stacionárne procesy sa označujú ako integrované procesy nultého stupňa $I(0)$.

Pôvodný nestacionárny proces so strednou hodnotou $E(y_t) = \mu = 0$ zapíšeme v tvare²⁶:

$$\phi_p(B)(1-B)^d y_t = \theta_q(B)a_t \quad (3.1.31)$$

resp.

$$\phi_p(B)z_t = \theta_q(B)a_t \quad (3.1.32)$$

kde $z_t = (1-B)^d y_t$

a nazývame autoregresným integrovaným procesom kľzavých priemerov ARIMA(p, d, q).

Ak $E(y_t) = \mu \neq 0$, potom môžeme proces ARIMA zapísať v tvare²⁷:

$$\phi_p(B)(1-B)^d y_t = \phi_0 + \theta_q(B)a_t \quad (3.1.33)$$

kde $\phi_0 = (\mu - \phi_1\mu - \dots - \phi_p\mu)$.

²⁶ RUBLÍKOVÁ, E - PRÍHODOVÁ, I. 2008. *Analýza vybraných časových radov - ARIMA modely*. Bratislava : Vydavateľstvo EKONÓM, 2008, s. 66

²⁷ CRYER, J. D. – CHAN, K-S. 2008. *Time Series Analysis: With Applications in R*. New York : Springer. 2008. s. 97

Niekedy sa procesy $ARIMA(p, d, q)$ nazývajú zjednodušené len integrované procesy stupňa d a označujú sa $I(d)$. V praxi sa obvykle stretávame s procesmi $I(1)$ ²⁸ a $I(2)$. Časové rady generované integrovanými procesmi sa často nazývajú radmi s jednotkovými koreňmi. [Arlt, 1999, 51]

Procesy $AR(p)$ a $MA(q)$ môžu v $ARIMA(p, d, q)$ modeli vzájomne rušiť svoje účinky, i keď oba môžu byť v modeli štatisticky významné, ale vnútri modelu môžu pracovať proti sebe. O takomto modeli hovoríme, že je preparametrizovaný. Výsledné odhady parametrov môžu byť nejednoznačné a proces môže potrebovať veľmi veľa iterácií na to, aby konvergoval. Vhodným spôsobom ako predísť tomuto problému, je snažiť sa odhadnúť model s o jeden stupeň nižším AR , resp. MA procesom a porovnať ich.

Z tohto dôvodu sa na identifikáciu modelov $ARIMA(p, d, q)$ používa *metóda postupného zaradovania* (forward selection) jednotlivých typov procesov do modelu, indikovaných tvarom grafov $VACF$ a $VPACF$. Ak je časový rad výrazne pod- alebo prediferencovaný, t.j. ak je potrebné zvýšiť alebo znížiť diferenciu o celý stupeň, signalizuje to jednotkový koreň v $AR(p)$, resp. $MA(q)$ procese. V $AR(p)$ procesoch vyššieho stupňa sa jednotkový koreň vyskytuje, ak suma koeficientov $AR(p)$ procesov sa rovná jednej. Časový rad s jednotkovým koreňom z koeficientov $AR(p)$ procesov je nestacionárny – potrebuje vyšší stupeň diferencovania²⁹.

Pri analýze ekonomických časových radov je najdôležitejšou (a zároveň najťažšou fázou) identifikácia modelu časového radu. Prvou operáciou s časovým radom je jeho stabilizácia a stacionarizácia. Potom sa pomocou tvaru výberovej autokorelačnej a parciálnej autokorelačnej funkcie hľadá jeho vhodný model. Po odhadnutí parametrov takto zvoleného modelu je ešte potrebné overiť jeho vlastnosti. Identifikácia modelov najmä pre ekonomické časové rady nie je triviálnou záležitosťou a vo väčšine prípadov hrá kľúčový význam skúsenosť a intuícia analytika. Ak sa hľadá model iba za účelom konštrukcie predpovedí, potom v niektorých prípadoch hrá intuícia dokonca rozhodujúcu úlohu.

²⁸ Integrovaný proces prvého stupňa $I(1)$ je aj proces náhodnej prechádzky, pretože jeho prvá diferencia je proces bieleho šumu. [Arlt, 1999, s. 48]

²⁹ RUBLÍKOVÁ, E - PRÍHODOVÁ, I. 2008. *Analýza vybraných časových radov - ARIMA modely*. Bratislava : Vydavateľstvo EKONÓM, 2008, s. 67

Určenie stupňa diferencovania

Pri výstavbe modelov triedy $ARIMA(p, d, q)$ je dôležité určenie stupňa (rádu) diferencovania (integrovania) d . V praktickej analýze ekonomických časových radov sa stretávame obvykle s nestacionárnymi časovými radmi. Tieto časové rady sa najčastejšie stacionarizujú diferenciami prvého alebo druhého stupňa.

Je viacero spôsobov ako určiť stupeň diferencie. Veľmi jednoduchou metódou je posúdenie grafu časového radu. Ak z grafu vidíme, že časový rad má stochastický lineárny trend, tak na jeho odstránenie použijeme prvú diferenciu, na odstránenie stochastického kvadratického trendu použijeme zase druhú diferenciu. Obvykle sa porovnáva variabilita hodnôt grafu nediferencovaného časového radu s variabilitou hodnôt grafu radu po prvej, resp. druhej diferencii. Aj keď má táto metóda subjektívny charakter, je vo väčšine prípadov veľmi efektívna (najmä keď má analytik, ktorý robí túto operáciu isté empirické skúsenosti).

Veľmi jednoduchou metódou je tiež posúdenie tvaru výberovej autokorelačnej funkcie (VACF) a výberovej parciálnej autokorelačnej funkcie (VPACF). Ak má VACF prvú hodnotu veľmi blízku jednej a ostatné hodnoty klesajú pomaly, približne lineárnym tempom a VPACF má tiež prvú hodnotu veľmi blízku jednej a ostatné hodnoty klesajú exponenciálne (aj v sínusových vlnách) k nule, jedná sa o situáciu kedy je vhodné urobiť diferencovanie, pretože daný časový rad je nestacionárny. Ak je pôvodný časový rad nestacionárny, analyzujú sa jeho prvé diferencie. Ak rad prvých diferencií je nestacionárny, analyzuje sa rad druhých diferencií. Optimálny stupeň diferencovania je obvykle ten, pri ktorom je smerodajná odchýlka diferencovaných radov najnižšia.

Mierne poddiferencovanie časového radu môže byť vyvážené zaradením AR procesu a mierne prediferencovanie zase zaradením MA procesu do modelu.

Testy jednotkového koreňa

Predchádzajúce metódy určovania stupňa diferencovania majú však subjektívny charakter. Preto bolo postupne vytvorených niekoľko testov, ktoré sa začali označovať ako *testy jednotkového koreňa*. Najpoužívanejším je test, ktorý navrhli Dickey a Fuller.

Dickeyov-Fullerov (DF) test

V DF teste overujeme hypotézu, či odhad parametra ϕ_1 z rovnice autoregresného procesu prvého stupňa AR(1)

$$y_t = \phi_1 y_{t-1} + a_t \quad (3.1.34)$$

sa rovná jednej, a teda jednotkový koreň existuje. Test je založený na odhade parametrov regresnej rovnice

$$\Delta y_t = (\phi_1 - 1)y_{t-1} + a_t = \delta y_{t-1} + a_t \quad (3.1.35)$$

Podstata DF testu spočíva v testovaní zápornosti parametra δ . Testujeme nulovú hypotézu, že parameter δ sa rovná nule, oproti jednostrannej alternatíve, že je menší ako nula, z čoho vyplýva, že parameter ϕ_1 je menší ako jedna. Prijatie alternatívnej hypotézy znamená, že proces nemá jednotkový koreň a nie je potrebné ho stacionarizovať. Problémom je, že v prípade nevýznamnosti parametra δ , teda v prípade nestacionarity, sa nedá použiť klasický t -test, a teda t -štatistika pre δ nemá Studentovo rozdelenie.

Dickey a Fuller preto tabelovali kritické hodnoty pre t -štatistiku a nazvali ju τ -štatistika. DF test po odhade parametra δ z rovnice (3.1.35) a výpočte štatistiky t_δ porovnáva túto hodnotu s tabelovanou τ hodnotou. Nižšia hodnota štatistiky t_δ znamená zamietnutie nulovej hypotézy, a teda stacionaritu radu.

Pri nezamietnutí nulovej hypotézy o nestacionarite sa môže proces testovania opakovať s modelmi vyšších diferencií, až kým nie je nulová hypotéza zamietnutá. Podľa stupňa diferencovania sa potom určí stupeň integrácie časového radu.³⁰

Nedostatkom DF testu je predpoklad, že náhodná zložka a_t má charakter bieleho šumu a nezohľadňuje možnosť autokorelácie v a_t .

Rozšírený Dickeyov-Fullerov test

V prípade, ak je náhodná zložka a_t autokorelovaný proces, klasický DF test zlyháva. Preto autori navrhli rozšíriť pôvodný autoregresný model prvého stupňa AR(1) na všeobecný autoregresný proces p -teho stupňa AR(p), ktorý eliminuje problém autokorelácie práve pridanými autoregresnými členmi.

³⁰ LUKÁČIK, M. 2007. *Prognóza na základe modelov s korekčným členom*. In: Vincúr, P. – Zajac, Š. a kolektív: *Úvod do prognostiky*. Bratislava : Sprint v.fra, 2007. s. 236

Rozšírený skúmaný model má potom tvar:

$$\Delta y_t = \delta y_{t-1} + \sum_{j=2}^p \phi_{j-1} \Delta y_{t-j+1} + a_t, \quad (3.1.36)$$

rozšírený model obsahujúci absolútny člen:

$$\Delta y_t = \mu + \delta y_{t-1} + \sum_{j=2}^p \phi_{j-1} \Delta y_{t-j+1} + a_t, \quad (3.1.37)$$

a rozšírený model s absolútnym členom a lineárnym časovým trendom:

$$\Delta y_t = \mu + \alpha_1 t + \delta y_{t-1} + \sum_{j=2}^p \phi_{j-1} \Delta y_{t-j+1} + a_t. \quad (3.1.38)$$

Testovanie s modelmi sa nazýva *rozšírený Dickeyov-Fullerov test* (augmented Dickey-Fuller tests; ADF test). Pôvodné tabelované hodnoty platia aj pre rozšírené typy modelov. Rozhodnutie o veľkosti použitého autoregresného stupňa p , ktorý najlepšie reprezentuje autokoreláciu, sa odporúča vykonať podľa Akaikeho alebo Schwarzovho informačného kritéria³¹.

Postup ADF testu ako kroková schéma je nasledovný³²:

1. Testovacia procedúra začína odhadom metódy najmenších štvorcov najvšeobecnejšieho modelu v tvare (3.1.38).
2. Pre testovanie prítomnosti trendu sa v modeli (3.1.38) využíva podmienená hypotéza $\alpha_1=0$, ak $\delta=0$ alebo združená hypotéza $\alpha_1 = \delta = 0$. Prijatie hypotézy o nulovom parametri α_1 znamená, že v rade nie je deterministický trend a pokračuje sa krokom 4.
3. Po zamietnutí hypotézy o nulovom parametri α_1 sa vykoná test o nulovom parametri δ . Jeho nevýznamnosť znamená, že rad je proces *náhodnej prechádzky s trendom*. V rámci tohto záveru sa dá dodatočne zistiť prítomnosť posunu a využije sa podmienená hypotéza $\mu = \alpha_1 = \delta = 0$.
4. Prejdeme k testovaniu modelu v tvare (3.1.37).
5. Pre testovanie prítomnosti posunu sa v modeli (3.1.37) využíva podmienená hypotéza $\mu=0$, ak $\delta=0$ alebo združená hypotéza $\mu = \delta = 0$. Prijatie hypotézy

³¹ Bližšie pozri napr. LUKÁČIKOVÁ, A. – LUKÁČIK, M. 2008. *Ekonometrické modelovanie s aplikáciami*. Bratislava : Vydavateľstvo EKONÓM, 2008. s. 226

³² LUKÁČIK, M. 2007. *Prognóza na základe modelov s korekčným členom*. In: Vincúr, P. – Zajac, Š. a kolektív: *Úvod do prognostiky*. Bratislava: Sprint vfra, 2007. s. 238

- o nulovom parametri ϕ_0 znamená, že rad je proces *náhodnej prechádzky* (bez posunu a trendu).
6. Po zamietnutí hypotézy o nulovom parametri μ sa vykoná test o nulovom parametri δ . Jeho nevýznamnosť znamená, že rad je proces *náhodnej prechádzky s posunom*.
 7. Prijatie hypotézy o významnosti parametra δ znamená v testovacom kroku 3 alebo 6 zastavenie procedúry s konštatovaním, že *rad je stacionárny*. Po zistení stacionarity sa klasickým t -testom overí, či rad obsahuje posun alebo deterministický trend.

Pre spojené hypotézy zaviedli Dickey a Fuller Φ rozdelenia podobné Fisherovmu rozdeleniu, kde sa testovaná hodnota vypočíta ako klasické F a pre podmienené hypotézy iné t_c rozdelenia, ktoré sú odlišné od DF testu, ale sú rovnako podobné Studentovmu rozdeleniu.

Určenie stupňa polynómov $\phi_p(B)$ a $\theta_q(B)$

Po určení stupňa diferencovania je potrebné určiť stupeň autoregresného polynómu $\phi_p(B)$, t.j. číslo p , a stupeň polynómu procesu kľzavých priemerov $\theta_q(B)$, t.j. číslo q . Jedna z najčastejšie používaných metód spočíva v hľadaní podobnosti medzi tvarom výberovej ACF a PACF s ich teoretickými tvarmi zodpovedajúcich modelov.

Niekedy je veľmi ťažké určiť typ modelu na základe ACF a PACF. V situáciách veľkej neistoty je vhodné sústrediť sa predovšetkým na základné rysy výberovej ACF a PACF a detaily v ich vývoji je treba zanedbať. Vylepšenie modelu sa potom obvykle urobí až po diagnostickom posúdení primárne zvoleného modelu.

Transformácia stabilizujúca rozptyl procesov

Pri analýze ekonomických časových radov sa môžeme stretnúť s prípadmi, v ktorých je zjavné, že generujúce procesy sú nestacionárne z hľadiska rozptylu jednotlivých ich náhodných veličín. Stacionarizácia sa pritom nedá dosiahnuť diferencovaním. V týchto prípadoch je treba počítať s tým, že generujúce procesy majú nelineárny charakter a nie je teda možné pracovať s lineárnymi modelmi typu ARIMA. Problém nelinearity, ktorý vedie k nestacionarite z hľadiska rozptylu možno riešiť v niektorých prípadoch pomocou linearizujúcich transformácií. Tieto transformácie je

potrebné vykonávať pred vlastnou analýzou časových radov a teda i pred ich diferencovaním.

Ekonomické časové rady majú tú vlastnosť, že s rastúcim trendom sa zväčšujú aj sezónne výkyvy. Takýto časový rad je (často) vhodné linearizovať logaritmickou transformáciou ($\log(y_t)$). Táto transformácia zabezpečí, že náhodné zmeny stredných hodnôt majú charakter bieleho šumu, s konštantným rozptylom a s normálnym rozdelením.³³

3.1.3 Modely sezónnych stochastických časových radov

3.1.3.1 Sezónne stacionárne procesy

Ak je v časovom rade štatisticky významná sezónnosť, potom existuje štatisticky významná lineárna závislosť medzi radom y_t a radom posunutým o s sezón, t.j. radom y_{t-s} . Sezónnosť preto zisťujeme pomocou výberovej ACF alebo výberovej PACF v posunoch s , $2s$, $3s$, Vplyvom náhodnej zložky sa však sezónnosť nemusí objaviť priamo v daných posunoch, ale v niektorom z posunov $s \pm k$, $2s \pm k$, $3s \pm k$, ..., pre $k = 1, 2, \dots, s-1$.

Sezónny autoregresný proces P -teho stupňa $SAR(P)_s$

Proces $SAR(P)_s$ môžeme zapísať:

$$y_t = \Phi_1 y_{t-s} + \Phi_2 y_{t-2s} + \dots + \Phi_P y_{t-Ps} + a_t \quad (3.1.39)$$

Spätný operátor umožňuje nasledujúci zápis procesu:

$$(1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_P B^{Ps}) y_t = a_t \quad (3.1.40)$$

resp.

$$\Phi_P(B^s) y_t = a_t \quad (3.1.41)$$

Proces je stabilný, ak korene rovnice $\Phi_P(B^s) = 0$, ležia mimo jednotkového kruhu. Tento proces je stacionárny, ak ho možno prepísať do tvaru sezónneho lineárneho procesu:

$$Y_t = \Psi(B^s) a_t \quad (3.1.42)$$

³³ RUBLÍKOVÁ, E - PRÍHODOVÁ, I. 2008. *Analýza vybraných časových radov - ARIMA modely*. Bratislava : Vydavateľstvo EKONÓM, 2008, s. 71

Sezónny proces kľzavých priemerov Q -teho stupňa $SMA(Q)_s$

Proces $SMA(Q)_s$ môžeme definovať nasledovne:

$$y_t = a_t - \Theta_1 a_{t-s} - \Theta_2 a_{t-2s} - \dots - \Theta_Q a_{t-Qs} \quad (3.1.43)$$

Pomocou spätného operátora ho môžeme zapísať v tvare:

$$y_t = (1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS}) a_t = \Theta_Q(B^S) a_t \quad (3.1.44)$$

Proces $SMA(Q)$ je vždy stacionárny a autokorelačná funkcia bude nadobúdať nenulové hodnoty len v sezónnych posunoch $s, 2s, 3s, \dots, Qs$. Proces je invertibilný, ak korene rovnice $\Theta_Q(B^S) = 0$ ležia mimo jednotkového kruhu.

Zmiešaný proces $SARMA(p, q)(P, Q)_s$

Zápis tohto procesu pomocou spätného operátora je takýto:

$$\phi_p(B) \Phi_P(B^S) y_t = \theta_q(B) \Theta_Q(B^S) a_t, \quad (3.1.45)$$

kde $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$ – nesezónny operátor procesu $AR(p)$

$\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$ – nesezónny operátor procesu $MA(q)$

$\Phi_P(B^S) = (1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS})$ – sezónny operátor procesu $AR(P)$

$\Theta_Q(B^S) = (1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS})$ – sezónny operátor procesu $MA(Q)$

Autoregresný proces charakterizujú polynómy $\phi_p(B) \Phi_P(B^S)$ a proces kľzavých priemerov polynómy $\theta_q(B) \Theta_Q(B^S)$.

Proces $SARMA(p, q)(P, Q)_s$ je stacionárny, ak korene rovnice $\phi_p(B) \Phi_P(B^S) = 0$ ležia mimo jednotkového kruhu, a invertibilný, ak korene rovnice $\theta_q(B) \Theta_Q(B^S) = 0$ ležia mimo jednotkového kruhu.

3.1.3.2 Sezónne homogénne nestacionárne procesy

Pre sezónny časový rad platí, že musí byť stacionárny aj zo sezónneho hľadiska. Ak je časový rad stacionárny v celkovej variabilite, je stacionárny aj v sezónnej variabilite. Problém predstavuje iba stacionarizácia sezónnej úrovne, keďže časový rad stacionárny v celkovej úrovni ešte nemusí byť stacionárny aj v sezónnej úrovni.

Sezónnu diferenciu s periódou dĺžky s časového radu y_t môžeme vyjadriť:

$$\nabla^s y_t = y_t - y_{t-s} = (1 - B^s)y_t \quad (3.1.46)$$

Sezónne integrované procesy SARIMA(p, d, q)(P, D, Q) $_s$

Model SARIMA(p, d, q)(P, D, Q) $_s$ s konštantou môžeme napísať v tvare³⁴:

$$\phi_p(B)\Phi_P(B^s)\nabla^d\nabla_s^D y_t = \theta_q(B)\Theta_Q(B^s)a_t \quad (3.1.47)$$

Pri sezónnych časových radoch je v prvom rade dôležité identifikovať, či je potrebné časový rad stacionarizovať sezónnou diferenciou, resp. či bude následne potrebné použiť aj diferenciu nesezónnu. Obvykle sa nepoužíva vyššia ako prvá sezónna diferencia a viac ako dve diferencie spolu (sezónna i nesezónna). Ak koeficienty autokorelácie so sezónnym oneskorením s postupne klesajú, časový rad je nestacionárny v sezónnej úrovni a je potrebné vykonať príslušnú sezónnu diferenciu $\nabla^s y_t$. Po sezónnych diferenciách stupňa D sa počet pozorovaní radu skracuje o $D.s$ hodnôt. Ak sa určia aj nesezónne diferencie, potom sa z radu stráca $d + D.s$ hodnôt.

Neodporúča sa kombinovať SAR(P) a SMA(Q) procesy v jednom modeli. Najčastejšie sú postačujúce SAR(P) i SMA(Q) procesy prvého stupňa. Záporná autokorelácia v sezónnej perióde indikuje použitie SMA(Q) procesu, kladná autokorelácia v sezónnej perióde indikuje zase použitie SAR(P) procesu.

Vylučovanie sezónnej zložky z radu má ten význam, že časový rad očistený od sezónnosti možno modelovať nesezónnym ARIMA(p, d, q) modelom alebo sezónnym ARIMA(p, d, q)(P, D, Q) $_s$ modelom s menším počtom parametrov.

Sezónne integrované procesy SARIMA možno chápať ako špeciálne tvary modelov ARIMA, ale aj ako rozšírenie týchto modelov. Vzhľadom na to, sú postupy na identifikáciu modelov, odhadovanie parametrov, diagnostickú kontrolu a predpovedanie budúceho vývoja u týchto dvoch skupín analogické.

³⁴ RUBLÍKOVÁ, E - PRÍHODOVÁ, I. 2008. *Analýza vybraných časových radov - ARIMA modely*. Bratislava : Vydavateľstvo EKONÓM, 2008, s. 82

3.2 Vektorovo autoregresné (VAR) procesy časových radov

Modely viacrozmerných časových radov môžeme na jednej strane chápať ako viacrozmerné zovšeobecnenie modelov jednorozmerných časových radov, na druhej strane sú však tieto modely základom pre vznik a riešenie otázok, s ktorými sa v jednorozmernom prípade nemôžeme stretnúť. Predpovede konštruované na základe modelov charakterizujúcich vzťahy medzi viacerými časovými radmi môžu byť presnejšie ako predpovede založené na modeli jedného časového radu.

Stacionarita vektorového stochastického procesu

Predpokladajme l -rozmerný stochastický proces $\{\mathbf{Y}_t\} = \{(Y_{1t}, Y_{2t}, \dots, Y_{lt})^T\}$. Proces $\{\mathbf{Y}_t\}$ je slabo stacionárny, keď:

- $E(\mathbf{Y}_t) = \boldsymbol{\mu} < \infty$ pre všetky t , $\boldsymbol{\mu}$ je l -rozmerný vektor stredných hodnôt
- $E[(\mathbf{Y}_t - \boldsymbol{\mu})(\mathbf{Y}_t - \boldsymbol{\mu})^T] = \boldsymbol{\Sigma} < \infty$, pre všetky t , $\boldsymbol{\Sigma}$ je kovariančná matica rozmeru $(l \times l)$, na jej diagonále sú rozptyly (variance), mimo diagonálu sú kovariancie náhodných veličín stochastických procesov,
- $E[(\mathbf{Y}_t - \boldsymbol{\mu})(\mathbf{Y}_{t-k} - \boldsymbol{\mu})^T] = \boldsymbol{\Gamma}_k$ pre všetky t a $k = 0, 1, \dots$, $\boldsymbol{\Gamma}_k$ je autokovariančná maticová funkcia rozmeru $(l \times l)$. Na diagonále tejto matice sú autokovariancie náhodných veličín v čase t a oneskorení k (kovariancie jednotlivých náhodných veličín v čase t a $t-k$), mimo diagonálu sú kovariancie náhodných veličín, jedna je vždy v čase t a druhá v čase $t-k$.

Prvá podmienka znamená, že stredné hodnoty náhodných veličín všetkých skalárnych stochastických procesov obsiahnutých vo vektorovom stochastickom procese sú v čase nemenné. Druhá podmienka vyjadruje, že rozptyly náhodných veličín a kovariancie medzi dvojicami náhodných veličín rôznych skalárnych stochastických procesov sú v čase nemenné. Tretia podmienka znamená, že jednotlivé autokovariancie a kovariancie medzi dvojicami náhodných veličín rôznych skalárnych stochastických procesov sú iba funkcie oneskorenia k , bez ohľadu na čas t .

Viacrozmerný proces bieleho šumu

Vektorový l -rozmerný stochastický proces $\{a_t\}$ s nulovým vektorom stredných hodnôt a s autokovariančnou maticou funkcií

$$\Gamma_k = E(a_t a'_{t-k}) = \Sigma_a, \text{ ak } k = 0 \text{ a} \quad (3.2.1)$$

$$\Gamma_k = E(a_t a'_{t-k}) = 0_{l \times l}, \text{ ak } k \neq 0, \quad (3.2.2)$$

Kde Σ_a je symetrická pozitívne definitná matica rozmeru $l \times l$, sa označuje ako l -rozmerný proces bieleho šumu. Prvky procesu $\{a_t\}$ nie sú v rôznych časoch korelované, môžu však byť korelované v rovnakom čase.

Vektorovo autoregresný proces prvého stupňa VAR(1)

Model VAR(1) môžeme zapísať v tvare:

$$Y_t = \phi_1 Y_{t-1} + a_t \quad (3.2.3)$$

Pomocou spätného operátora B môžeme model VAR(1) vyjadriť v tvare:

$$(I_l - \phi_1 B) Y_t = a_t \quad (3.2.4)$$

Model môžeme zapísať tiež ako:

$$Y_t = (I_l - \phi_1 B)^{-1} a_t = (I_l + \phi_1 B + \phi_1^2 B^2 + \dots) a_t = a_t + \phi_1 a_{t-1} + \phi_1^2 a_{t-2} + \dots^{35}. \quad (3.2.5)$$

Ak ležia charakteristické hodnoty matice ϕ_1 mimo jednotkového kruhu, t.j. $|\lambda_i| < 1$ pre $i = 1, 2, \dots, l$, potom je rad ϕ_1^k , $k = 1, 2, \dots$ absolútne spočítateľný, t.j. $\sum_{k=0}^{\infty} |\phi_{1ij,k}| < \infty$ pre $i, j = 1, 2, \dots, l$. Platí taktiež podmienka $\sum_{k=0}^{\infty} \phi_{1ij,k}^2 < \infty$ pre $i, j = 1, 2, \dots, l$, z čoho plynie, že proces VAR(1) je stacionárny.

Charakteristické hodnoty matice ϕ_1 sú korene rovnice:

$$|\lambda I_l - \phi_1| = 0, \quad (3.2.6)$$

ak $\lambda = B^{-1}$, potom dostaneme:

$$|I_l - \phi_1 B| = 0. \quad (3.2.7)$$

Je teda zrejmé, že VAR(1) proces je stacionárny, ak ležia korene rovnice (3.2.7) mimo jednotkového kruhu.

³⁵ ARLT, J - ARLTOVÁ, M. 2007. Ekonomické časové řady. Praha : Grada Publishing, 2007. s. 169

Vektorovo autoregresný proces p -teho stupňa VAR(p)

Model VAR(p) môžeme zapísať v tvare³⁶:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t \quad (3.2.8)$$

V prípade, že $E(Y_t) = \mu \neq 0_l$, má model VAR(p) tvar:

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t \quad (3.2.9)$$

kde $c = (\mu - \phi_1 \mu - \dots - \phi_p \mu) = \mu(I_l - \sum_{j=1}^p \phi_j)$.

Pomocou spätného operátora B môžeme model vyjadriť v tvare:

$$\phi_p(B)Y_t = a_t \quad (3.2.10)$$

kde $\phi_p(B) = (I_l - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$ je polynomiálna matica. Tento proces je stacionárny, ak ležia korene rovnice $|I_l - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p| = 0$ mimo jednotkového kruhu. Potom

$$Y_t = [\phi_p(B)]^{-1} a_t = \sum_{k=0}^{\infty} \psi_k a_{t-k} \quad (3.2.11)$$

kde pre koeficienty matice ψ_k platí $\sum_{k=0}^{\infty} \psi_{ij,k}^2 < \infty$ pre $i = 1, 2, \dots, l$ a $j = 1, 2, \dots, l$.

Určenie stupňa modelu VAR

Prvou úlohou pri modelovaní časových radov pomocou vektorovo autoregresného modelu je určenie jeho stupňa (dĺžky oneskorenia) p .

Model VAR je stupňa p , ak parametrická matica ϕ_p je nenulová, tzn. nenulový je aspoň jeden jej prvok a matice ϕ_i , $i = p+1, p+2, \dots$ sú nulové. Zvyčajne sú vtedy nenulové aj parametrické matice ϕ_i , $i = 1, 2, \dots, p-1$. Nie je však vylúčené, že niektorá z týchto matíc je tiež nulová.

Najčastejší spôsob určenia dĺžky oneskorenia p vektorovo autoregresného modelu je pomocou kritérií Akaikeho a Schwartz. Tieto charakteristiky sú založené na porovnávaní rezíduí jednotlivých modelov VAR líšiacich sa počtom oneskorení. Volí sa taký stupeň p modelu VAR, ktorý tieto kritéria minimalizuje.

Akaikeho kritérium AIC pre model VAR(p) s konštantou možno vyjadriť v tvare³⁷:

$$AIC(p) = \ln|\hat{\Sigma}_a| + 2l(pl + 1)/T \quad (3.2.12)$$

³⁶ ARLT, J - ARLTOVÁ, M. 2007. *Ekonomické časové řady*. Praha : Grada Publishing, 2007. s. 170

³⁷ ARLT, J - ARLTOVÁ, M. 2007. *Ekonomické časové řady*. Praha : Grada Publishing, 2007. s. 205

kde $|\hat{\Sigma}_a|$ je determinant rezíduálnej kovariančnej matice modelu VAR(p), l je počet rovníc, p dĺžka oneskorenia skúmaného modelu a T je dĺžka časového radu.

Schwartzovo kritérium SC pre model VAR(p) s konštantou možno zapísať v tvare³⁸:

$$SC(p) = \ln|\hat{\Sigma}_a| + \ln T[l(pl + 1)]/T \quad (3.2.13)$$

Odhady parametrov modelu VAR³⁹

Keďže vektorovo autoregresný model obsahuje iba časovo oneskorené endogénne premenné a o náhodných zložkách predpokladáme, že nie sú autokorelované a majú konštantný rozptyl, jeho parametre, v prípade použitia stacionárnych časových radov, môžeme odhadnúť metódou najmenších štvorcov.

Uvažujme vektorovo autoregresný model VAR(p) s konštantou v tvare (3.2.9):

$$\mathbf{Y}_t = \mathbf{c} + \phi_1 \mathbf{Y}_{t-1} + \phi_2 \mathbf{Y}_{t-2} + \dots + \phi_p \mathbf{Y}_{t-p} + \mathbf{a}_t$$

Ďalej definujeme:

$\mathbf{Y} = (\mathbf{Y}_1, \dots, \mathbf{Y}_T)$ rozmeru $(l \times T)$,

$\mathbf{B} = (\mathbf{c}, \phi_1, \dots, \phi_p)$ $(l \times (lp + 1))$

$$\mathbf{Z}_t = \begin{bmatrix} 1 \\ \mathbf{Y}_t \\ \vdots \\ \mathbf{Y}_{t-p+1} \end{bmatrix} \quad ((lp + 1) \times 1)$$

$$\mathbf{Z} = (\mathbf{Z}_0, \dots, \mathbf{Z}_{T-1}) \quad ((lp + 1) \times T) \quad (3.2.14)$$

$\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_T)$ $(l \times T)$

$\mathbf{y} = \text{vec}(\mathbf{Y})$ $(lT \times 1)$

$\boldsymbol{\beta} = \text{vec}(\mathbf{B})$ $((l^2 p + l) \times 1)$

$\mathbf{b} = \text{vec}(\mathbf{B}')$ $((l^2 p + l) \times 1)$

$\mathbf{a} = \text{vec}(\mathbf{A})$ $(lT \times 1)$

³⁸ ARLT, J - ARLTOVÁ, M. 2007. *Ekonomické časové řady*. Praha : Grada Publishing, 2007. s. 206

³⁹ LÜTKEPOHL, H. 2005. *New introduction to multiple time series analysis*. Berlin : Springer, 2005. s.70-72

Použitím tohto zápisu môžeme vektorovo autoregresný model z (3.2.9) zapísať kompaktnejšie:

$$Y = BZ + U \quad (3.2.15)$$

alebo

$$\text{vec}(Y) = \text{vec}(BZ) + \text{vec}(U) = (Z' \otimes I_l) \text{vec}(B) + \text{vec}(U) \quad (3.2.16)$$

alebo

$$y = (Z' \otimes I_l) \beta + u \quad (3.2.17)$$

Potom môžeme neznáme parametre β modelu VAR(p) odhadnúť metódou najmenších štvorcov a dostaneme estimátor v tvare:

$$\hat{\beta} = ((ZZ')^{-1} \otimes \Sigma_u)(Z \otimes \Sigma_u^{-1})y = ((ZZ')^{-1} Z \otimes I_l)y \quad (3.2.18)$$

Ak sú regresory vo všetkých rovniciach modelu VAR(p) rovnaké, estimátor zovšeobecnenej metódy najmenších štvorcov sa rovná estimátoru získaného pomocou bežnej metódy najmenších štvorcov.

Diagnostická kontrola modelu VAR

Po stanovení stupňa modelu a odhade jeho parametrov, podobne ako v jednorozmernom prípade, je treba uskutočniť diagnostickú kontrolu zvoleného modelu, t.j. overiť či nesystematická zložka je typu viacrozmerného bieleho šumu, príp. viacrozmerného gaussovského bieleho šumu.

Autokorelácia nesystematickej zložky

Pri posudzovaní, či nesystematická zložka modelu má charakter bieleho šumu vychádzame z rezíduí, získaných na základe modelu VAR(p), t.j.

$$\hat{a}_t = Y_t - \hat{c} - \hat{\phi}_1 Y_{t-1} - \dots - \hat{\phi}_p Y_{t-p}, \quad t = 1, 2, \dots, T. \quad (3.2.19)$$

Je možné použiť výberovú autokorelačnú maticovú funkciu

$$r_{ak} = \hat{D}^{-1/2} C_k \hat{D}^{1/2}, \quad k = 1, 2, \dots \quad (3.2.20)$$

kde

$$C_k = \hat{\Gamma}_{ak} = (1/T) \sum_{t=k+1}^T \hat{a}_t \hat{a}_{t-k}', \quad k = 1, 2, \dots \quad (3.2.21)$$

je výberová autokovariančná maticová funkcia a $\hat{D}$ je diagonálna matica rozmeru $l \times l$, v ktorej i -ty diagonálny prvok je i -tým diagonálnym prvkom matice $C_0 = (1/T) \sum_{t=1}^T \hat{a}_t \hat{a}_t'$.

Pri testovaní, či má nesystematická zložka charakter bieleho šumu sa v praxi často vychádza z Bartlettovej aproximácie odhadu smerodajnej chyby jednotlivých výberových autokorelácií a vzájomných autokorelácií, t.j. jednotlivých koeficientov výberovej autokorelačnej maticovej funkcie r_{ak} , $k = 1, 2, \dots$, ktorá je v prípade procesu bieleho šumu pre dlhé časové rady rovná hodnote $1/\sqrt{T}$. Vzhľadom k asymptotickej normalite r_{ak} je možné stanoviť 95 % interval spoľahlivosti pre jednotlivé koeficienty výberovej autokorelačnej maticovej funkcie ako $\pm 2/\sqrt{T}$. V prípade nesystematickej zložky typu bieleho šumu by mali byť jednotlivé koeficienty (alebo aspoň väčšina z nich) v intervale $(-2/\sqrt{T}, 2/\sqrt{T})$.

Uvedený test je iba asymptotický. Pri testovaní vychádzame z predpokladu, že parametre modelu VAR(p) sú známe a nesystematickú zložku tvorí proces bieleho šumu. V skutočnosti však parametre modelu VAR(p) sú odhadované. Z týchto dôvodov je treba výsledky testu chápať iba ako predbežné a preto sa táto grafická analýza dopĺňa často tzv. *Portmanteauovým testom*⁴⁰, ktorý testuje nulovú hypotézu $H_0: \rho_{a1} = \rho_{a2} = \dots = \rho_{aK} = 0_{l \times l}$ oproti alternatívnej hypotéze $H_1: \text{non } H_0$. Testovacia charakteristika, ktorá má asymptotické χ^2 rozdelenie pravdepodobnosti s počtom stupňov voľnosti $[l^2(K-p)]$ má potom tvar:

$$Q_l = T \sum_{k=1}^K \text{tr}(C_k' C_0^{-1} C_k C_0^{-1}) \quad (3.2.22)$$

Normalita nesystematickej zložky

Úlohou je pomocou testu zistiť, či proces $\{a_t\}$ je gaussovského typu, tzn. veličiny a_t majú l -rozmerné normálne rozdelenie. Uvažujme rezíduá modelu VAR(p), t.j.:

$$\hat{a}_t = Y_t - \hat{c} - \hat{\phi}_1 Y_{t-1} - \dots - \hat{\phi}_p Y_{t-p} \quad t = 1, 2, \dots, T. \quad (3.2.23)$$

Odhad autokovariančnej matice nesystematickej zložky možno získať ako:

$$\hat{\Sigma}_a^* = \frac{T}{T - pl - 1} \sum_{t=1}^T \hat{a}_t \hat{a}_t' \quad (3.2.24)$$

⁴⁰ ARLT, J - ARLTOVÁ, M. 2007. *Ekonomické časové rady*. Praha : Grada Publishing, 2007. s. 203

Nech $\hat{P}$ je dolná triangulárna matica s kladnými diagonálnymi prvkami, pre ktorú platí $\hat{P}\hat{P}' = \hat{\Sigma}_a^*$. Definujme ďalej:

$$\hat{u}_t = (\hat{u}_{1t}, \dots, \hat{u}_{lt})' = \hat{P}^{-1} \hat{a}_t, \quad t = 1, 2, \dots, T. \quad (3.2.25)$$

$$\hat{m}_j = (\hat{m}_{1j}, \dots, \hat{m}_{lj})' \quad j = 3, 4, \quad (3.2.26)$$

kde

$$\hat{m}_{ij} = (1/T) \sum_{t=1}^T \hat{u}_{it}^j, \quad i = 1, 2, \dots, l, \quad j = 3, 4. \quad (3.2.27)$$

Dá sa dokázať, že štatistiky

$$MSK^2 = T\hat{m}_3'\hat{m}_3/6 \text{ a } MK^2 = T(\hat{m}_4 - 3_l)'(\hat{m}_4 - 3_l)/24, \quad (3.2.28)$$

kde 3_l je l -rozmerný vektor trojok, majú za predpokladu platnosti nulovej hypotézy, t.j. že nesystematická zložka modelu VAR(p) (v prípade nenulových stredných hodnôt model VAR(p) s konštantou) je gaussovského typu, asymptoticky rozdelenie $\chi^2(l)$. Štatistika MSK^2 je testovacie kritérium na testovanie šikmosti a štatistika MK^2 je testovacie kritérium na testovanie špicatosti. Združené testovacie kritérium na testovanie šikmosti a špicatosti je⁴¹:

$$MJB = (MSK^2 + MK^2). \quad (3.2.29)$$

Za predpokladu platnosti nulovej hypotézy má asymptoticky rozdelenie $\chi^2(2l)$.

Pre testovanie normality je teda možné použiť všetky tri testovacie kritéria. Vzhľadom k tomu, že testy založené na šikmosti a špicatosti v jednorozmernom prípade majú výberové rozdelenia, ktoré sa pri malých výberoch pomerne výrazne líšia od svojich asymptotických protikladov, musia byť výsledky uvedených testov interpretované opatrne. Je treba ich považovať skôr za veľmi približné prostriedky na overenie normality. V praxi sa niekedy používajú rôzne korekcie týchto testov pre malé výbery.

Analýza reakcie na impulz⁴²

V praxi je často zaujímavé skúmať akú *reakciu* (response) v jednom časovom rade vyvolá *impulz* (impulse) v inom časovom rade v rámci systému, ktorý obsahuje ešte ďalšie časové rady. Ide teda o skúmanie vzťahu medzi dvomi jednorozmernými časovými radmi vo viacrozmernom systéme. Reakcia na impulz v jednom rade znamená kauzálny vzťah v druhom rade.

⁴¹ ARLT, J - ARLTOVÁ, M. 2007. *Ekonomické časové rady*. Praha : Grada Publishing, 2007. s. 205

⁴² ARLT, J - ARLTOVÁ, M. 2007. *Ekonomické časové rady*. Praha : Grada Publishing, 2007. s.177-180

Po rozpísaní má l -rozmerný stacionárny model VAR(1)

$$\mathbf{Y}_t = \boldsymbol{\phi}_1 \mathbf{Y}_{t-1} + \mathbf{a}_t \quad (3.2.30)$$

formu

$$\begin{bmatrix} Y_{1t} \\ Y_{2t} \\ \vdots \\ Y_{lt} \end{bmatrix} = \begin{bmatrix} \phi_{1,11} & \phi_{1,12} & \cdots & \phi_{1,1l} \\ \phi_{1,21} & \phi_{1,22} & \cdots & \phi_{1,2l} \\ \vdots & \vdots & \vdots & \vdots \\ \phi_{1,l1} & \phi_{1,l2} & \cdots & \phi_{1,ll} \end{bmatrix} \begin{bmatrix} Y_{1t-1} \\ Y_{2t-1} \\ \vdots \\ Y_{lt-1} \end{bmatrix} + \begin{bmatrix} a_{1t} \\ a_{2t} \\ \vdots \\ a_{lt} \end{bmatrix} \quad (3.2.31)$$

kde l -rozmerný vektor konštánt $\boldsymbol{\phi}_0 = (\phi_{0,1}, \phi_{0,2}, \dots, \phi_{0,l})'$ je nulový a tiež vektor stredných hodnôt $\boldsymbol{\mu} = \boldsymbol{\phi}_0(\mathbf{I}_l + \boldsymbol{\phi}_1 + \boldsymbol{\phi}_1^2 + \dots)$ je nulový. Základným predpokladom je, že $\mathbf{a}_t$ pre $t < 0$ sú nulové vektory a $\mathbf{Y}_t = \mathbf{0}_l$ pre $t < 0$. Ďalším predpokladom je, že v čase $t = 0$ bude vektor $\mathbf{a}_t$ obsahovať jednu jednotku a inak samé nuly. Jednotka bude znamenať impulz v danom časovom rade. Pre $t > 0$ bude $\mathbf{a}_t = \mathbf{0}$.

Potom v čase $t = 0$ platí

$$\mathbf{Y}_0 = \begin{bmatrix} Y_{10} \\ Y_{20} \\ \vdots \\ Y_{l0} \end{bmatrix} = \begin{bmatrix} a_{10} \\ a_{20} \\ \vdots \\ a_{l0} \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \\ \vdots \\ 0 \end{bmatrix}, \quad (3.2.32)$$

$$\mathbf{Y}_1 = \boldsymbol{\phi}_1 \mathbf{Y}_0 = \begin{bmatrix} \phi_{1,11} & \phi_{1,12} & \cdots & \phi_{1,1l} \\ \phi_{1,21} & \phi_{1,22} & \cdots & \phi_{1,2l} \\ \vdots & \vdots & \vdots & \vdots \\ \phi_{1,l1} & \phi_{1,l2} & \cdots & \phi_{1,ll} \end{bmatrix} \begin{bmatrix} 0 \\ 1 \\ \vdots \\ 0 \end{bmatrix} = \begin{bmatrix} \phi_{1,12} \\ \phi_{1,22} \\ \vdots \\ \phi_{1,l2} \end{bmatrix}, \quad (3.2.33)$$

$$\mathbf{Y}_2 = \boldsymbol{\phi}_1 \mathbf{Y}_1 = \boldsymbol{\phi}_1^2 \mathbf{Y}_0 = \begin{bmatrix} \phi_{1,11}\phi_{1,12} & + \phi_{1,12}\phi_{1,22} & + \cdots & + \phi_{1,1l}\phi_{1,l2} \\ \phi_{1,21}\phi_{1,12} & + \phi_{1,22}\phi_{1,22} & + \cdots & + \phi_{1,2l}\phi_{1,l2} \\ \vdots & \vdots & \vdots & \vdots \\ \phi_{1,l1}\phi_{1,12} & \phi_{1,l2}\phi_{1,22} & + \cdots & + \phi_{1,ll}\phi_{1,l2} \end{bmatrix}, \quad (3.2.34)$$

$\vdots$

Reakciu na impulz vo všetkých procesoch v čase $t = 1$ udáva v druhom procese v čase $t = 0$ druhý stĺpec matice $\boldsymbol{\phi}_1$, reakciu na impulz vo všetkých procesoch v čase $t = 2$ udáva v druhom procese v čase $t = 0$ druhý stĺpec matice $\boldsymbol{\phi}_1^2$, reakciu na impulz vo všetkých procesoch v čase $t = i$ udáva v druhom procese v čase $t = 0$ druhý stĺpec matice $\boldsymbol{\phi}_1^i$.

Reakciu v procese j na jednotkový impulz v procese k možno vyjadriť graficky tak, že na horizontálnu os nanesieme čas t a na vertikálnu os nanesieme hodnoty odozvy j -teho procesu na impulz v k -tom procese.

3.3 Modely viacrozmerných nestacionárnych časových radov - Modely s korekčným členom (ECM)

Charakteristickou vlastnosťou mnohých makroekonomických časových radov je nestacionarita. Modelovanie viacrozmerných nestacionárnych časových radov zasluhuje zvláštnu pozornosť. Problémom je, že štandardné testy síce vo väčšine prípadov indikujú významné vzťahy medzi jednotlivými radmi. Tieto vzťahy však môžu byť iba zdanlivé. V tejto súvislosti sa objavila myšlienka kointegrácie časových radov, ktorá umožňuje daný problém riešiť.

Kointegrované procesy

Pri konštrukcii modelov ekonomických časových radov je logické vychádzať z predpokladu, že vývoj jednotlivých radov spojených teoreticky zdôvodneným ekonomickým vzťahom sa v dlhodobom časovom horizonte nerozchádza. Ak je odklon smeru vývoja časových radov krátkodobý, časom sa vytráca a existuje hranica, za ktorú nemôže ísť, potom hovoríme, že časové rady sú v ekvilibriu (v rovnováhe). Štatistické vyjadrenie tohto stavu sa označuje ako *kointegrácia časových radov*. Ak takáto hranica nie je, potom sa nedá povedať, že sú v ekvilibriu a zo štatistického hľadiska takéto časové rady kointegrované nie sú.

Ak dve alebo viac premenných je kointegrovaných, musia byť z dlhodobého hľadiska v rovnováhe, ale z krátkodobého hľadiska v rovnováhe nemusia byť.⁴³

Ak sú dva procesy $\{X_t\}$ a $\{Y_t\}$ integrované stupňa d ($I(d)$) a ak existuje lineárna kombinácia $\{aX_t + bY_t\} \sim I(d-c)$, kde $c > 0$, potom sa tieto procesy nazývajú *kointegrované stupňa d* , c a označujú sa ako $\{X_t\}, \{Y_t\} \sim CI(d, c)$. Vektor $(a, b)'$ sa nazýva *kointegračný vektor*. V prípade dvoch procesov môže existovať iba jeden kointegračný vektor.

⁴³ HATRÁK, M. 1998. Error correction models and cointegration analysis in applied econometrics. In CEJORE. 1998, vol. 6, no. 3-4, p. 189

Kointegráciu dvoch procesov možno zovšeobecniť na l integrovaných procesov nasledovne. Nech $\{X_t\}$ je l -rozmerný vektor obsahujúci procesy $\{X_{1t}\}$, $\{X_{2t}\}$, ..., $\{X_{lt}\}$. Ak je každý z nich typu $I(d)$ a ak existuje taký vektor α rozmeru $(l \times 1)$, že $\alpha' \{X_t\} \sim I(d, c)$, kde $c > 0$, potom sú tieto procesy kointegrované a možno písať $\{X_t\} \sim CI(d, c)$. Vektor α sa nazýva kointegračný vektor.

V empirickej ekonometrii časových radov je najzaujímavejší prípad, keď kointegračný vektor smeruje ku stacionárnej lineárnej kombinácii, t.j. keď $d = c$. Premenné možno v takomto prípade odhadovať bez diferencovania. Strednú hodnotu stacionárnej lineárnej kombinácie integrovaných časových radov je možné chápať ako ekvilibrium, ktoré spojuje uvažované časové rady.

Môže však existovať prípad viac než dvoch procesov, ktorý je komplikovanejší, než bolo uvedené v definícii kointegrovaných procesov. Tak napr. v prípade troch procesov $\{X_{1t}\}$, $\{X_{2t}\}$, $\{X_{3t}\}$, kedy $\{X_{1t}\} \sim I(1)$, $\{X_{2t}\} \sim I(2)$ a $\{X_{3t}\} \sim I(2)$, aby bola výsledná lineárna kombinácia $\{u_t\}$ typu $I(0)$, musí byť druhý a tretí proces kointegrovaný tak, že ich lineárna kombinácia je typu $I(1)$, musí teda platiť, že $\{X_{2t}\}$, $\{X_{3t}\} \sim CI(2, 1)$. Je teda zrejmé, že v prípade vektorov procesov, ktoré sú integrované rozdielneho stupňa, musí existovať viac než jeden proces vyššieho stupňa, aby mohlo dôjsť k dielčej kointegrácii, t.j. k lineárnej kombinácii s rovnakým stupňom integrácie ako majú ostatné procesy.

Pre prípad k premenných môže teda existovať až $k - 1$ lineárne nezávislých vektorov. V takom prípade môže byť nemožné bez apriórnej informácie identifikovanie vzťahu dlhodobej rovnováhy. Podľa počtu kointegrujúcich vektorov sa potom rozoznáva *hodnota kointegrácie*.

Analýza vzťahov medzi integrovanými časovými radmi má zmysel iba vtedy, ak sú tieto časové rady kointegrované, t.j. ak sú spojené spoločným stochastickým trendom. Ak tomu tak nie je, každý časový rad má iný smer vývoja. Pri skúmaní vzťahov medzi takýmito časovými radmi pomocou regresnej analýzy vzniká stav, ktorý sa označuje ako *zdanlivá (falošná) regresia* (spurious regression). Prejavuje sa tak, že metódou najmenších štvorcov získané štatisticky významné odhady parametrov danej regresnej funkcie, t.j. t -testy, F -test a koeficient determinácie budú indikovať vhodnosť modelu daných časových radov, aj keď tieto nebudú spolu vôbec súvisieť (ako jednoduché pravidlo diagnostiky sa

uvádza vzťah $R^2 > DW$). Test kointegrácie časových radov je teda súčasne metódou na odlíšenie medzi pravou regresiou a regresiou zdanlivou.

Model s korekčným členom

Skupinu kointegrovaných časových radov možno popísať *modelom korekcie chyby* (error-correction model – ECM). ECM patria v poslednom období medzi najviac používané modelové prístupy.

Prostredníctvom ECM je možné odlíšiť dlhodobé a krátkodobé vzťahy medzi časovými radmi. Tento model obsahuje parametre charakterizujúce mieru vychýlenia systému od dlhodobo sa presadzujúceho rovnovážneho stavu (ekvilibria). Môže byť prostriedkom na riešenie rozporu medzi štatistickým a ekonometrickým prístupom modelovania nestacionárnych ekonomických časových radov. Umožňuje spojiť prístup štatistický, spočívajúci v skúmaní vlastností diferencovaných časových radov (stacionarizovaných časových radov) a prístup ekonometrický, ktorý kladie dôraz na ekvilibrium medzi časovými radmi a preto sa zaujíma o nediferencované časové rady. Oba prístupy použité izolovane sú problematické. Štatistický v tom, že sa zbavuje dôležitých informácií obsiahnutých v pôvodných nestacionarizovaných časových radoch, ekonometrický potom v tendencii prehliadať problém zdanlivej regresie.

Predpokladajme l -rozmerný model VAR(p) typu I(1) v tvare:

$$Y_t = c + \Omega D_t + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + a_t \quad (3.3.1)$$

kde $\{a_t\}$ je l -rozmerný gaussovský proces bieleho šumu s kovariančnou maticou Σ_a , c sú konštanty, D_t vyjadruje deterministickú zložku. Model VAR možno potom vyjadriť v nasledujúcej forme:

$$\Delta Y_t = c + \Omega D_t + \Gamma_1 \Delta Y_{t-1} + \dots + \Gamma_{p-1} \Delta Y_{t-p+1} + \Pi Y_{t-p} + a_t \quad (3.3.2)$$

kde

$$\Gamma_i = -(I_l - \phi_1 - \dots - \phi_i) \text{ pre } i = 1, \dots, p-1, \Pi = -(I_l - \phi_1 - \dots - \phi_p). \quad (3.3.3)$$

Tento model sa nazýva *model korekcie chyby*. Obsahuje na jednej strane krátkodobé vzťahy medzi procesmi, čo sú vzťahy medzi diferencovanými (stacionarizovanými) procesmi. Na druhej strane obsahuje vzťahy dlhodobé, t.j. vzťahy medzi nediferencovanými procesmi. Informácie o týchto vzťahoch sú obsiahnuté v parametrickej matici Π . Konštrukcia ECM umožňuje oddeliť tieto dva druhy vzťahov a skúmať ich samostatne.

V tomto modeli môžu nastať tri situácie:⁴⁴

1. $h(\boldsymbol{\Pi}) = l$, t.j. matica $\boldsymbol{\Pi}$ má plnú hodnotu, čo znamená, že l -rozmerný časový rad je generovaný stacionárnym vektorovým procesom $\{\mathbf{Y}_t\}$. Ak je viacrozmerný časový rad stacionárny, sú stacionárne jednotlivé časové rady a nie je treba použiť diferencie na ich stacionarizovanie.
2. $h(\boldsymbol{\Pi}) = 0$, tzn. že matica $\boldsymbol{\Pi}$ je nulová a model (3.3.2) neobsahuje nediferencovaný člen, l -rozmerný časový rad je generovaný nestacionárnym vektorovým procesom $\{\mathbf{Y}_t\}$. Stacionarizáciu možno urobiť individuálnym diferencovaním jednotlivých časových radov. Diferencovaním nedochádza k strate informácií o dlhodobom vzťahu medzi časovými radmi, pretože žiadny vzťah neexistuje.
3. $0 < h(\boldsymbol{\Pi}) = r < l$, v tomto prípade nezmizne nediferencovaný člen modelu (3.3.2), ale súčasne nemožno vektorový proces $\{\mathbf{Y}_t\}$ považovať za stacionárny. Pretože matica $\boldsymbol{\Pi}$ je nenulová, možno nájsť medzi časovými radmi dlhodobý vzťah a stacionarizáciu individuálnym diferencovaním jednotlivých časových radov bez straty informácie nemožno uskutočniť (niektoré časové rady možno stacionarizovať ich diferencovaním, pretože nie sú obsiahnuté v žiadnom dlhodobom vzťahu s inými časovými radmi; niektoré časové rady však nemôžu byť stacionarizované diferencovaním, pretože ich lineárne kombinácie s inými časovými radmi už stacionárne sú, tieto rady sú kointegrované).

Častejšie sa modely s korekčným členom používajú v tvare odvodenom z modelov s autoregresne rozdelenými oneskoreniami – model ADL (Autoregressive Distributed Lags). Všeobecne sa tento model zapisuje $ADL(m, n, p)$, kde m je stupeň oneskorenia závisle premennej, n je stupeň oneskorenia v rámci nezávisle premenných a p je počet nezávislých premenných. Najjednoduchší typ modelu ADL je v prípade ak model obsahuje iba jednu nezávislú premennú a jeho zápis môžeme potom zredukovať na tvar $ADL(m, n)$. Model $ADL(1, 1)$, v ktorom sa predpokladá časové oneskorenie o jedno obdobie možno zapísať nasledovne:

$$y_t = a_0 + a_1 y_{t-1} + b_0 x_t + b_1 x_{t-1} + u_t \quad (3.3.4)$$

kde u_t splňa podmienky bieleho šumu.

⁴⁴ ARLT, J - ARLTOVÁ, M. 2007. *Ekonomické časové řady*. Praha : Grada Publishing, 2007. s. 238

Pomocou jednoduchšej transformácie možno rovnicu (3.3.4) upraviť do tvaru modelu s korekčným členom, ktorý vyjadruje krátkodobý aj dlhodobý vzťah medzi dvoma premennými nasledovne:

$$\Delta y_t = a_0 + b_0 \Delta x_t + (a_1 - 1)(y_{t-1} - \delta_1 x_{t-1}) + u_t \quad (3.3.5)$$

kde $\delta_1 = -(b_0 + b_1) / (a_1 - 1)$.

V tejto forme krátkodobú rovnováhu predstavuje vzťah $\Delta y_t = a_0 + b_0 \Delta x_t + u_t$ a chybu rovnováhy, teda samotný korekčný člen vyjadruje vzťah $(a_1 - 1)(y_{t-1} - \delta_1 x_{t-1})$.

Vzhľadom na to, že ide o modely založené na diferenciách, špeciálnu pozornosť treba venovať parametru a_1 , ktorý sa interpretuje ako *miera zotrvačnosti*. Čím väčšia zotrvačnosť existuje vo vývoji závisle premennej, tým menší je vplyv nerovnováhy, teda $(1 - a_1)$ sa približuje k nule zľava. Kvôli tomu, aby model (3.3.5) mal dlhodobé statické riešenie, musí nevyhnutne platiť, že $|a_1| < 1$. Narušenie dlhodobej stability modelu, ktoré nastáva v prípade, keď $a_1 > 1$ a vedie okamžite k narušeniu mechanizmu na korekciu chýb, čo sa prejaví tým, že parameter pri korekčnom člene je kladný. Hodnota koeficienta a_1 blízka 1 znamená rýchlu konvergenciu a hodnoty blízke 0 pomalú konvergenciu k rovnováhe.

Parameter b_0 sa nazýva *krátkodobý multiplikátor* a indikuje okrem porušenia vzťahov rovnováhy v minulosti aj vplyv krátkodobej závislosti medzi vysvetľovanou a vysvetľujúcou premennou, t.j. krátkodobú elasticitu. Parameter δ_1 sa nazýva *dlhodobý multiplikátor*. V modeloch typu log-log je tento parameter meradlom dlhodobej elasticity vysvetľovanej premennej vzhľadom na zmenu vysvetľujúcej premennej.

Koeficient krátkodobého prispôsobenia $\gamma = (a_1 - 1)$, ktorý modifikuje veľkosť korekčného člena, by mal byť záporný a meria rýchlosť prispôsobenia k rovnováhe. Nízka hodnota parametra γ signalizuje, že rýchlosť, ktorou sa vysvetľovaná premenná približuje k dlhodobej rovnováhe, je veľmi pomalá a hodnota blízka 1 znamená rýchlu konvergenciu k rovnováhe.

Model EC zahŕňa krátkodobé, ako aj dlhodobé vlastnosti, pretože obsahuje nielen zmeny premenných (Δy_t , Δx_t), ale aj úrovne premenných (y_{t-1} a x_{t-1}). V ARIMA modeloch

sú všetky premenné diferencované. To znamená, že modely časových radov využívajú iba krátkodobé informácie a zanedbávajú dlhodobé informácie z úrovňových premenných.⁴⁵

Dobrou vlastnosťou ECM je, že pri odhade jeho parametrov nevzniká problém falošnej regresie, pretože premenné Δy_t a Δx_t sú *stacionárne* a y_t a x_t sú *kointegrované* a potom ich lineárna kombinácia - výraz $(y_{t-1} - \delta_1 x_{t-1})$ je *stacionárny*. Na odhad parametrov modelu ECM môžeme použiť bežnú metódu najmenších štvorcov a pri hodnotení odhadov bežný t -test a F -test štatistickej významnosti.⁴⁶

Doteraz sme sa zaoberali modelmi, ktoré obsahovali jednu nezávislú premennú. Vyššie spomínané úvahy možno zovšeobecniť pre prípad vyššieho počtu p nezávisle premenných. Majme model ADL(1, 1, p)

$$Y_t = a_0 + a_1 Y_{t-1} + b_{01} X_{t1} + \dots + b_{0p} X_{tp} + b_{11} X_{t-1,1} + \dots + b_{1p} X_{t-1,p} + u_t \quad (3.3.6)$$

Úpravou dostaneme všeobecný model s korekčným členom v tvare:

$$\Delta Y_t = a_0 + b_{01} \Delta X_{t1} + \dots + b_{0p} \Delta X_{tp} - (1 - a_1)(Y_{t-1} - X_{t-1,1} - \dots - X_{t-1,p}) + (a_1 - 1 + b_{01} + b_{11})X_{t-1,1} + \dots + (a_1 - 1 + b_{0p} + b_{1p})X_{t-1,p} + u_t \quad (3.3.7)$$

Vzťah (3.3.7) vyjadruje mechanizmus prispôsobovania sa závisle premennej k dlhodobej rovnováhe prostredníctvom vplyvu všetkých vysvetľujúcich premenných použitých v pôvodnom modeli. Parameter $(1 - a_1)$ nie je citlivý na charakter dlhodobej závislosti medzi premennými a ani na počet vysvetľujúcich premenných.

Engle a Granger (1987) navrhli na kvantifikáciu ECM *dvojkrokový postup*. V prvom kroku sa pomocou bežnej metódy najmenších štvorcov odhadne rovnica dlhodobej rovnováhy (rovnica kointegrácie) medzi premennými v pôvodnom tvare, ktoré sú integrované rovnakého stupňa:

$$y_t = \beta_0 + \beta_1 x_{t1} + \beta_2 x_{t2} + \dots + \beta_k x_{tk} + u_t \quad (3.3.8)$$

Ak sú rezíduá kointegračnej rovnice *stacionárne*, ich oneskorené hodnoty sa použijú v druhom kroku na odhad najvhodnejšieho tvaru modelu s korekčným členom metódou najmenších štvorcov.

⁴⁵ HATRÁK, M. 1998. Error correction models and cointegration analysis in applied econometrics. In CEJORE. 1998, vol. 6, no. 3-4, p. 187

⁴⁶ HATRÁK, M. 2007. *Ekonometria*. Bratislava : Iura Edition, 2007. s. 283

4 Výsledky práce

4.1 Dovoz tovarov a služieb do Slovenskej republiky

V národnom účtovníctve a makroekonómii predstavuje celkový dovoz (import) objem statkov (tovarov alebo služieb), ktorý určité národné hospodárstvo (štát) získalo za určitý čas zo zahraničia kúpou alebo výmenou, určených na domácu spotrebu a tiež na spracovanie s následným spätným vývozom. Je to toková veličina a predstavuje tok tovaru do krajiny.

Dovoz je, podľa Štatistického úradu SR (ŠÚ SR), definovaný ako pohyb tovaru z tretích krajín (štáty, ktoré nie sú členmi Európskej únie) do členských štátov EÚ. ŠÚ SR ďalej definuje aj nepriamy dovoz a to ako transakciu, pri ktorej je tovar dovezený z nečlenského štátu do Slovenskej republiky, pričom dovozné colné formality sa uskutočnia v inom členskom štáte. V súlade s medzinárodne platnou metodikou vykazovania štatistických údajov o zahraničnom obchode sa údaje celkového dovozu publikujú podľa krajiny pôvodu. Údaje o dovoze tovarov a služieb publikované Štatistickým úradom SR sú zostavované podľa národného konceptu a sú zbierané z colnej štatistiky.

Hodnoty celkového dovozu sú zostavované buď ako hodnoty typu f.o.b. (free on board), t.j. zahŕňajú transakčnú hodnotu tovaru a hodnotu služieb (napr. doprava, poistenie, prekládka, skladovanie tovaru a pod.) vykonaných na dodanie tovaru na hranicu vyvážajúcej krajiny, alebo ako hodnoty typu c.i.f. (cost, insurance, freight), kde je k transakčnej hodnote tovaru pripočítaná hodnota služieb (napr. doprava, poistenie, prekládka, skladovanie tovaru a pod.) vykonaných na dodanie tovaru na hranicu Slovenskej republiky.

Do hodnoty dovozu nie sú zahrnuté hodnoty tovaru, ktorý je predmetom dočasných transakcií. Od 1.1.2005 sú zo štatistiky zahraničného obchodu vyňaté tiež hodnoty tovaru určeného na opravu a po oprave a s tým súvisiace náhradné diely.

Hodnoty tovaru, u ktorého bolo v Slovenskej republike uskutočnené len colné konanie (hodnoty nepriamych dovozov) nie sú od roku 2007 započítané do obchodu

s nečlenskými krajinami. Štatistiky publikované v cudzej mene sú prepočítané na slovenskú menu priemernými mesačnými výmennými kurzami.

Od 1. mája 2004 sa štatistika zahraničného obchodu skladá z údajov z EXTRASTAT a INTRASTAT systému. EXTRASTAT systém poskytuje informácie o výmene tovarov s nečlenskými krajinami Európskej únie na základe dokumentov predpísaných pre colné konanie, systém INTRASTAT obsahuje informácie o obchode s tovarom s členskými štátmi EÚ ako partnerskými krajinami, získané štatistickým zisťovaním.

INTRASTAT systém ako zdroj údajov pre štatistiku obchodovania s tovarom medzi členskými štátmi je implementovaný ako štatistické zisťovanie u odosielateľov a príjemcov tovaru. Zber, kontrolu a prvotné spracovanie štatistických hlásení vykonáva colná správa, ktorá následne údaje v elektronickej podobe odovzdáva Štatistickému úradu SR.

Colná správa vytvára databázu údajov o obchodovaní Slovenskej republiky s nečlenskými krajinami (EXTRASTAT) z dokladov získaných pri colnom konaní a kompletné údaje za sledovaný mesiac ako i aktualizované údaje za predchádzajúce mesiace sprístupní Štatistickému úradu SR.

V národnom hospodárstve je dovoz tovarov a služieb súčasťou vzťahu (identity) na vyjadrenie základného a najpoužívanejšieho makroekonomického ukazovateľa - hrubého domáceho produktu (HDP) výdavkovou (spotrebnou) metódou, teda ako súčet hodnoty finálnych tovarov a služieb, kde na ľavej strane (agregovaná ponuka) je HDP a na pravej strane (agregovaný dopyt) je súčet výdavkov domácností na osobnú spotrebu tovarov a služieb (konečná spotreba domácností), hrubých súkromných domácich investícií firiem (tvorba hrubého fixného kapitálu a stav zásob), výdavkov vlády na nákup tovarov a služieb (konečná spotreba štátnej správy) a rozdiel vývozu a dovozu tovarov a služieb, tzv. čistý (netto) export.

4.1.1 Analýza vývoja dovozu tovarov a služieb za roky 1995 až 2008

Slovenská ekonomika prešla od svojho vzniku mnohými zmenami. Nevyhol sa tomu ani zahraničný obchod s tovarmi a službami, ktorý pre malé ekonomiky, akou je slovenská, znamená kľúčovú úlohu. Hodnoty dovozu tovarov a služieb do Slovenskej republiky za roky 1995 až 2008 v mld. EUR v b.c. sú v tab. 4.1.1. Z obr. 4.1.1 vidieť, že dovoz tovarov a služieb rástol počas celého obdobia. Počas rokov 1995 až 2008 sa dovoz v priemere zvýšil každý rok o 3,5852 mld. EUR, každý rok dovoz rástol 1,1376 násobne, t.j. zvyšoval sa v priemere o 13,76 %.


Najvyšší prírastok (28,65 %) dosiahol dovoz tovarov a služieb v roku 1996. Od tohto obdobia sa striedal rýchlejší rast s pomalším, až dovoz dosiahol najnižší nárast v roku 1999 a to iba 0,1255 mld. EUR (0,69 %). Bolo to spôsobené tým, že Národná banka koncom roku 1998 prešla z fixného kurzového režimu na plávajúci, čo zapríčinilo devalváciu Slovenskej koruny a znovuzavedením dovoznej prirážky od 1. júna 1999, ktorá bola zrušená v predchádzajúcom roku. Po takmer žiadnom raste zaznamenáva dovoz jeden z najvyšších rastov hneď v nasledujúcom období. V rokoch 2000 a 2001 dosiahol rast 23,37 % a 20,26 %. Bolo to ovplyvnené otvorením rokovaní o vstupe SR do Európskej únie a postupným znižovaním dovoznej prirážky, čo zvyšovalo dovoz tovarov a služieb do Slovenskej republiky. V roku 2002 sa rast dovozu spomalil a dosiahol iba 5,41 % nárast oproti roku 2001. Avšak od tohto obdobia dovoz pomaly rastie, až zaznamená najvyšší absolútny medziročný prírastok v roku 2006 na úrovni 8,7848 mld. EUR, čo je spôsobené oneskorenejšou reakciou na vstup Slovenskej republiky do Európskej únie 1. mája 2004. V nasledujúcom roku zaznamená dovoz druhý najvyšší absolútny medziročný nárast o 5,3680 mld. EUR, ale v relatívnom vyjadrení je to nárast iba o 11%. V roku 2008 dosiahne dovoz najvyššiu hodnotu v sledovanom období, ale tretí najnižší medziročný nárast (iba o 6,13%).

Podiel dovozu tovarov a služieb na HDP hovorí o otvorenosti ekonomiky, čím je väčší, tým je ekonomika viac otvorená. V roku 1995 bol podiel dovozu na HDP 55,52 % a do roku 2008 sa postupne zvýšil až na 85,28 % a najvyšší podiel z HDP dosahoval dovoz v roku 2006, a to 88,38 %. Vidíme teda, že s časom sa slovenská ekonomika stáva stále viac a viac otvorená.

Tab. 4.1.1 Dovozy tovarov a služieb do SR v mld. EUR b.c., absolútna diferencia, koeficient rastu, tempo prírastku (v %), dovoz/HDP (v %), 1995 - 2008

Rok	Dovoz	Absolútna diferencia	Koeficient rastu	Tempo prírastku %	Dovoz/HDP v %
1995	10,7196	0,0000	0,000	0,00	55,52
1996	13,7905	3,0708	1,286	28,65	64,10
1997	15,7374	1,9470	1,141	14,12	65,98
1998	18,3049	2,5675	1,163	16,31	69,99
1999	18,4304	0,1255	1,007	0,69	65,62
2000	22,7384	4,3080	1,234	23,37	72,99
2001	27,3457	4,6072	1,203	20,26	80,77
2002	28,8258	1,4801	1,054	5,41	78,37
2003	31,5453	2,7195	1,094	9,43	77,73
2004	34,8832	3,3379	1,106	10,58	77,30
2005	39,8648	4,9816	1,143	14,28	80,89
2006	48,6495	8,7848	1,220	22,04	88,38
2007	54,0176	5,3680	1,110	11,03	87,77
2008	57,3274	3,3098	1,061	6,13	85,28

(Zdroj: Štatistická ročenka SR, 1997, 2000, 2003, 2006, 2008; Vlastné výpočty)


**Obr. 4.1.1** Dovozy tovarov a služieb v mld. EUR b.c. a absolútna diferencia za 1995-2008 (Zdroj: Vlastné výpočty)**Tab. 4.1.2** Dovozy tovarov a dovoz služieb do SR (mld. EUR, b.c.), podiel tovarov na celkovom dovoze (%), podiel služieb na celkovom dovoze (%), služby/tovary (%), 1995 - 2008

Rok	Dovoz tovarov mld. EUR b.c.	Dovoz služieb mld. EUR b.c.	Podiel tovarov na celkovom dovoze v %	Podiel služieb na celkovom dovoze v %	Služby/tovary v %
1995	8,9286	1,7910	83,29	16,71	20,06
1996	11,7592	2,0312	85,27	14,73	17,27
1997	13,4324	2,3050	85,35	14,65	17,16
1998	15,6833	2,6216	85,68	14,32	16,72
1999	15,9100	2,5204	86,32	13,68	15,84
2000	20,0419	2,6965	88,14	11,86	13,45
2001	24,1781	3,1676	88,42	11,58	13,10
2002	25,3877	3,4381	88,07	11,93	13,54
2003	27,9095	3,6358	88,47	11,53	13,03

2004	31,4717	3,4115	90,22	9,78	10,84
2005	35,7637	4,1011	89,71	10,29	11,47
2006	44,0934	4,5562	90,63	9,37	10,33
2007	48,6431	5,3745	90,05	9,95	11,05
2008	50,7484	6,5789	88,52	11,48	12,96

(Zdroj: Štatistická ročenka SR, 1997, 2000, 2003, 2006, 2008; Vlastné výpočty)

Z tab. 4.1.2 vidíme, že aj dovoz tovarov aj dovoz služieb sa v absolútnom vyjadrení zvyšovali počas celého sledovaného obdobia. Treba si však všimnúť, že podiel služieb na celkovom dovoze postupne klesá a teda podiel tovarov na celkovom dovoze rastie aj keď v roku 2008 sme zaznamenali opačný vývoj. Najväčší podiel dovozu tovarov na celkovom dovoze bol v roku 2006, kedy dovezené tovary tvorili 90,63 % celkového dovozu a najmenší podiel zaznamenal dovoz tovarov na celkovom dovoze v roku 1995, iba 83,29 %. Keďže dovoz služieb predstavuje doplnok do celkového dovozu, tak tieto zaznamenali opačné najvyššie a najnižšie hodnoty. Taktiež počas sledovaného obdobia postupne klesá aj podiel dovozu služieb na dovoze tovarov aj keď v roku 2008 zaznamenali služby zvýšenie podielu z dovozu tovarov oproti predchádzajúcemu roku.



Obr. 4.1.2 Podiel tovarov na celkovom dovoze (%), podiel služieb na celkovom dovoze (%), služby/tovary (%), 1995 - 2008

(Zdroj: Vlastné výpočty)


Ak skúmame štruktúru dovozu tovarov a služieb podľa tried SITC zistíme, že počas sledovaného obdobia rokov 1997 až 2008 najvyšší podiel predstavujú tovary triedy SITC 7 „Stroje a zariadenia“, ktoré tvoria v priemere 39,15 %. Podiel jednotlivých tried sa veľmi nemení a štruktúra dovozu tovarov a služieb zostáva takmer bez zmeny od začiatku obdobia okrem triedy SITC 0 „Potraviny“, SITC 3 „Nerastné palivá“ a SITC 5 „Chemikálie“, kde nastáva mierny pokles podielu týchto tovarov. A naopak,

v najpočetnejšej triede SITC 7 a v triede SITC 8 „Priemyselné výrobky“ nastáva nárast podielu na celkovom dovoze.

Tab. 4.1.3 Štruktúra dovozu tovarov a služieb do SR podľa tried SITC (v % celkového dovozu) a priemer, 1997 - 2008

Rok	SITC 0	SITC 1	SITC 2	SITC 3	SITC 4	SITC 5	SITC 6	SITC 7	SITC 8	SITC 9
1997	5,6	1	4,4	15,7	0,2	11,6	16,5	36	8,9	0
1998	5,3	0,9	3,8	10,9	0,2	10,6	18	40,3	9,9	0
1999	5,1	1,1	3,8	12,9	0,2	11,3	18,3	37,7	9,5	0
2000	4,5	0,8	3,9	17,5	0,2	11	17,7	35,7	8,8	0
2001	4,6	0,8	3,7	15,2	0,3	10,3	18,5	37,6	9	0
2002	4,3	0,8	3,6	13,4	0,2	10,7	19,1	38,2	9,7	0
2003	3,7	0,7	3,3	12	0,2	9,8	19	41,1	10,2	0
2004	4,1	0,7	3,7	12,5	0,2	9,8	19	39,5	10,4	0,1
2005	4,8	1	3,5	13,2	0,2	9,8	18	37,9	11	0,6
2006	4,3	0,6	3,1	13,5	0,2	8,9	16,9	38,9	13,4	0,2
2007	4,3	0,8	2,9	11	0,2	8,8	17,3	43,9	10,7	0,2
2008	4,6	0,6	3	12,9	0,3	8,6	16,7	43	10,1	0,2
PRIE MER	4,60	0,82	3,56	13,39	0,22	10,10	17,92	39,15	10,13	0,11

(Zdroj: Štatistická ročenka SR, 1999, 2002, 2005, 2008; Vlastné výpočty)



Obr. 4.1.3 Štruktúra dovozu tovarov a služieb podľa tried SITC (v % celkového dovozu) – priemer za roky 1997 - 2008

(Zdroj: Vlastné výpočty)


Tab. 4.1.4 Teritoriálna štruktúra dovozu tovarov a služieb do SR (v % celkového dovozu) za obdobie 1995 – 1998 a 2004 - 2008

	1995	1996	1997	1998	2004	2005	2006	2007	2008
OECD	71,4	74,6	77,1	80,7	66,2	69,7	70,3	66,1	64,3
EU	34,8	37,3	43,8	50,1	65,1	71,3	68	69,5	67,6
EURÓPA	89,4	88,3	89,6	89,5	72,0	77,1	77	69,8	69,1
ÁZIA	5,9	7,1	5,6	5,7	9,4	11,9	14,4	16,5	16,6
Nemecko	14,3	14,6	19,7	25,7	20,7	20,6	20,5	18,6	18,4
Česko	27,7	24,3	21,3	18,4	12,0	12,8	12,3	10,8	10,6
Rakúsko	5,1	4,8	5,0	4,7	3,5	3,9	3,4	3	2,7
Poľsko	2,8	2,4	2,5	2,5	3,5	4,1	4,4	4	3,6
Maďarsko	2,2	2,0	2,1	2,4	3,0	3,6	4,6	5,2	4,6
Rusko	16,6	17,4	13,9	10,4	8,2	10,7	11,3	9,3	10,8
Ukrajina	1,4	1,6	2,4	1,8	1,2	1,4	1,3	1	1,0
Čína	0,7	0,7	1,0	1,2	2,4	3,3	4	5	6,0
Kórea	-	-	-	-	1,6	2,6	3,9	5	6,0
USA	2,5	2,7	3,1	2,9	1,4	1,4	1,2	1	1,2

(Zdroj: Štatistická ročenka SR, 1997, 1998, 2006, 2008)

Pri pohľade na graf na obr. 4 vidieť na prvý pohľad veľký nárast dovozu tovarov a služieb z Ázie, najmä za posledné roky, kedy bol nárast dovozu v roku 2008 oproti roku 1995 o viac ako 10 p.b. a ešte aj oproti roku 2004 je nárast o 7 p.b. Pri ostatných sledovaných ekonomických zoskupeniach vidieť mierny pokles dovozu tovarov a služieb za sledované obdobie. Dovoz z európskych krajín klesol z 89,4 % v roku 1995 na 69,1 % v roku 2008 a dovoz z krajín OECD klesol z 71,4 % na 64,3 % v roku 2008 aj keď vidieť mierny nárast na začiatku sledovaného obdobia.


Z ekonomických zoskupení je najväčším a najdôležitejším obchodným partnerom Slovenskej republiky Európska únia, pretože najväčší obchodní partneri Slovenskej republiky sú členmi tohto zoskupenia. Porovnávať dovoz z krajín Európskej únie je však trochu komplikované, pretože EÚ sa za posledné obdobie niekoľkokrát rozširovala. Avšak posledné veľké rozširovanie bolo v roku 2004 (ak neberieme do úvahy rozširovanie v roku 2007, kedy do EÚ vstúpili Rumunsko a Bulharsko, z ktorých je však dovoz do Slovenskej republiky veľmi malý), kedy vstúpilo do EÚ až desať krajín. Aj tak vidieť obrovský nárast dovozu tovarov a služieb z krajín tohto ekonomického zoskupenia, kedy podiel dovozu stúpol z 34,8 % v roku 1995 až na 65,1 % v roku 2004. Od tohto obdobia je podiel dovozu približne 68 % a v roku 2008 dosiahol 67,6 %. Veľký nárast obchodu s krajinami EÚ počas skúmaného obdobia je spôsobený geografickou a kultúrnou blízkosťou s týmito krajinami.



Obr. 4.1.4 Dovoz tovarov a služieb do SR podľa ekonomických zoskupení a kontinentov (% podiel na celkovom dovoze tovarov a služieb do SR), 1995 - 2008
(Zdroj: Vlastné výpočty)

Podiel dovozu tovarov a služieb z vybraných krajín je v tab. 4.1.4. Za zmienku stojí vývoj dovozu z Nemecka, kde si môžeme všimnúť, že podiel postupne rástol zo 14,3 % v roku 1995 až na 25,7 % v roku 1998 a následne postupne klesal až na 18,4 % v roku 2008. Podiel dovozu z Českej republiky má jednoznačnejší klesajúci trend, kedy klesal z 27,7 % v roku 1995 až na 10,6 % v roku 2008. Podobný priebeh má aj podiel dovozu z Ruska, ktorý klesol zo 16,6 % (1995) postupne približne na 10 % v posledných rokoch.

Veľmi zaujímavý je vývoj podielu dovozu tovarov a služieb z Číny a Kórei. Podiel dovozu z Číny vzrástol z 0,7 % v rokoch 1995 a 1996 až na 6 % v roku 2008 a podiel dovozu z Kórei, ktorý sa v prvých rokoch sledovaného obdobia vôbec nenachádza v štatistických ročenkách, vzrástol z 1,6 % v roku 2004 až na 6 % v roku 2008.



Obr. 4.1.5 Dovoz tovarov a služieb do SR z vybraných krajín (% podiel na celkovom dovoze do SR), 1995 - 2008
(Zdroj: Vlastné výpočty)

Najviac dovážané tovary podľa skupín Klasifikácie produkcie⁴⁷ sú v tab. 4.1.5, podľa ktorej je najviac dovážaným tovarom do Slovenskej republiky ropa a zemný plyn, čo je dôsledkom vysokej energetickej závislosti SR. Vývoj podielu tohto tovaru na celkovom dovoze je veľmi nestály. V roku 1997 bol podiel dovozu ropy a zemného plynu na celkovom dovoze 11,08 %. V nasledujúcom roku klesol na minimum a dosiahol iba 7,47 %. V roku 1999 podiel vzrástol na 9,65 % a v nasledujúcom roku dosiahol svoje maximum 14,81 %. Od tohto obdobia podiel na dovoze postupne klesá až na 8,23 % v roku 2004, kedy v nasledujúcich dvoch rokoch opäť rastie až na 10,18 % v roku 2006. V nasledujúcom roku podiel ropy a zemného plynu na celkovom dovoze opäť klesá na 7,87 % a v roku 2008 podiel tohto tovaru dosiahol 9,29 %. Druhý najpočetnejší dovezený tovar boli televízory a rozhlasové prijímače, ktoré dosiahli 9,21 % v roku 2008, keď v roku 1997 tvorili iba 0,98 % dovozu. Od tohto obdobia ďalej ich podiel na celkovom dovoze rástol, ale ešte iba v roku 2006 tvorili len 3,78 % a v nasledujúcom roku dosiahli už 8,02 % celkového dovozu. Tretími najpočetnejšími dovezenými tovarmi sú „časti pre motorové vozidlá“, čo vyplýva zo zamerania slovenskej ekonomiky na výrobu osobných automobilov. Štvrtú skupinu s najväčším podielom na celkovom dovoze predstavujú „motorové vozidlá“. Aj keď je Slovensko krajina z jedných s najvyšším podielom vyrobených automobilov na jedného obyvateľa, tieto vozidlá sa takmer všetky vyvážajú do iných krajín a navyše sú to vozidlá nižších tried a do Slovenskej republiky sa preto dovážajú drahšie a luxusnejšie vozidlá, čo sa odráža aj na spomínanom vysokom podiele tohto tovaru na celkovom dovoze, ktorý sa zvýšil z 5,51 % v roku 1997 na 6,56 % v roku 2008 a svoje maximum dosiahol v roku 2003 s 7,25 %. Naopak, znížil sa podiel dovezených počítačov z 2,64 % (1997) postupne približne na 2 % v posledných rokoch sledovaného obdobia.

⁴⁷ Štatistická klasifikácia produkcie - KP 1. revízia je národná verzia klasifikácie produkcie podľa činností CPA 2002 (Statistical classification of products by activity in the European Economic Community), ktorú vydal Štatistický úrad Európskej únie EUROSTAT nariadením komisie (ES) č.204/2002. Tým nahradil Štatistickú klasifikáciu produkcie CPA (Statistical classification of products by activity in the European Economic Community) vydanú Nariadením rady (EEC) č.3696/93. Toto nariadenie je záväzné vo svojej celistvosti a je priamo uplatniteľné vo všetkých členských štátoch Európskej únie a nadobúda účinnosť 1.1.2003. Klasifikáciu vydal Štatistický úrad SR Vyhláškou č. 632/2002 v Z.z, ktorá nadobudla účinnosť 1. januára 2003

Tab. 4.1.5 Tovarová štruktúra dovozu do SR podľa skupín Klasifikácie produkcie v % (vybrané skupiny), 1997 - 2008

Rok	1110 Ropa a zemný plyn	3230 televízor, rozhlas. prijímače	3430 Časti pre motor. vozidlá	3410 Motorové vozidlá	2710 Železo, ocel', ferozliatiny	2442 Farmaceutické prípravky	2320 Rafinérské ropné produkty	3002 Počítače
1997	11,08	0,98	4,25	5,51	1,87	2,77	0,94	2,64
1998	7,47	1,17	5,62	5,89	1,97	2,42	0,89	2,62
1999	9,65	1,03	6,13	4,29	1,60	2,99	1,19	2,49
2000	14,81	1,06	6,85	3,89	1,61	2,69	0,81	2,14
2001	12,30	1,27	6,20	5,48	1,86	2,62	1,02	2,20
2002	10,46	1,40	6,52	6,51	2,12	2,83	1,27	2,11
2003	9,07	1,34	8,68	7,25	1,98	2,56	1,05	1,84
2004	8,23	1,45	7,78	7,06	2,57	2,82	1,55	1,94
2005	9,31	2,30	6,58	6,52	2,59	2,77	2,06	2,14
2006	10,18	3,78	7,10	6,48	2,78	2,42	1,94	1,99
2007	7,87	8,02	8,79	6,46	3,40	2,62	1,76	2,23
2008	9,29	9,21	7,34	6,56	3,46	2,38	1,99	1,94


(Zdroj: Štatistická ročenka SR, 1999, 2002, 2005, 2008)

Vývoj dovozu a vývozu tovarov a služieb – vývoj zahraničného obchodu

Vývoj dovozu tovarov a služieb treba posudzovať súčasne s vývozom tovarov a služieb. Dostaneme tak obraz nielen o obrate zahraničného obchodu, ale aj o jeho salde.

Kladné saldo dosiahol zahraničný obchod iba v roku 1995 a to na úrovni 0,4393 mld. EUR (obr. 4.1.6 a tab. 4.1.6). V ostatných rokoch bolo saldo záporné. V rokoch 1996 dosiahlo saldo hodnotu -2,3127 mld. EUR a v roku 1997 -2,2924 mld. EUR, čo bolo spôsobené opätovným prijatím dovoznej prirážky a stanovením dovozných kvót. V roku 1998 dovozná prirážka bola zrušená a nízka úroveň domácej ponuky spôsobili, že saldo zahraničného obchodu dosiahlo najvyššiu zápornú hodnotu v sledovanom období a to - 2,8204 mld. EUR. Tento nepriaznivý vývoj si vyžiadala zmenu kurzového režimu slovenskej koruny z fixného na plávajúci v októbri 1998, čo vlastne znamenalo devalváciu slovenskej koruny. S nástupom novej vlády s hlavným cieľom nastolenia makroekonomickej rovnováhy vidieť od roku 1999 výrazné zlepšenie zahraničného obchodu, kedy sa saldo zlepšilo o viac ako o 50 % oproti predchádzajúcemu roku na hodnotu -1,2380 mld. EUR. V dôsledku znovuzavedenia dovoznej prirážky od druhej polovice roku 1999 vo výške 7 %, sa deficit zahraničného obchodu v roku 2000 vyvíjal lepšie ako v predchádzajúcom roku a dosiahol iba -0,7746 mld. EUR. V roku 2000 sa znížila dovozná prirážka na 3%, čo spôsobilo vyšší nárast dovozu tovarov a služieb oproti vývozu a tým v roku 2001 druhú najvyššiu zápornú hodnotu salda na úrovni -2,7098 mld.

EUR. S koncom štvorročného vládneho obdobia v roku 2002 prichádzajú populárne opatrenia vlády, ktoré mali za následok zvýšenie domáceho dopytu a tým prehĺbenie salda zahraničného dovozu na jednu z najvyšších hodnôt v sledovanom období a to na -2,6494 mld. EUR. So začiatkom nového vládneho obdobia prichádzajú opäť opatrenia na stimuláciu domácej ekonomiky a saldo zahraničného obchodu v roku 2003 dosahuje jednu z najnižších záporných hodnôt a zníženie až o 72 % oproti predchádzajúcemu roku, na -0,7431 mld. EUR a v nasledujúcom roku 2004 iba mierne zvýšenie na -1,2179 mld. EUR. Ku koncu vládneho obdobia dosahuje saldo zahraničného obchodu opäť prudký negatívny nárast na jedny z najvyšších hodnôt za sledované obdobie, konkrétne -2,2617 mld. EUR v roku 2005 a -2,1789 mld. EUR v roku 2006. Tento nárast salda môže byť spôsobený aj vstupom Slovenska do Európskej únie 1. mája 2004 a zvýšením dovozu z krajín tohto integračného zoskupenia (pozri aj obr. 4.1.1 a obr. 4.1.4). V roku 2007 zaznamenáva saldo zahraničného obchodu s nástupom novej vlády opäť jedno z najvýraznejších znížení oproti predchádzajúcemu roku a to až o 70 % na úroveň -0,6448 mld. EUR. V roku 2008 sa záporné saldo zahraničného obchodu zvýšilo takmer dvojnásobne na hodnotu -1,5127 mld. EUR čo mohlo byť zapríčinené vstupom Slovenskej republiky do Schengenského priestoru 21. decembra 2007.



Obr. 4.1.6 Saldo zahraničného obchodu SR, mld. EUR, b.c., 1995 - 2008

(Zdroj: Vlastné výpočty)

Tab. 4.1.6 Vývoz, dovoz a saldo zahraničného obchodu SR, mld. EUR, 1995 - 2008

Rok	Vývoz	Dovoz	Saldo
1995	11,1589	10,7196	0,4393
1996	11,4777	13,7905	-2,3127
1997	13,4450	15,7374	-2,2924
1998	15,4845	18,3049	-2,8204
1999	17,1925	18,4304	-1,2380
2000	21,9638	22,7384	-0,7746
2001	24,6359	27,3457	-2,7098
2002	26,1764	28,8258	-2,6494
2003	30,8022	31,5453	-0,7431
2004	33,6653	34,8832	-1,2179
2005	37,6030	39,8648	-2,2617
2006	46,4707	48,6495	-2,1789
2007	53,3728	54,0176	-0,6448
2008	55,8147	57,3274	-1,5127

(Zdroj: Štatistická ročenka SR, 1997, 2000, 2003, 2006, 2008; Vlastné výpočty)

Od roku 1995 zahraničný obchod s tovarmi a službami Slovenskej republiky zaznamenal „divoký“ vývoj s mnohými zmenami a šokmi. Vysoký deficit v jednom roku striedalo aj viac ako polovičné zníženie hneď v nasledujúcom roku. Veľmi často sa meniaci výška dovozných prirážok a rôzne iné opatrenia nemali žiadne dlhodobé účinky. S nástupom nových vlád v rokoch 1999 (vláda Mikuláša Dzurindu), 2003 (staronová vláda Mikuláša Dzurindu) a 2007 (vláda Róberta Fica) saldo zahraničného obchodu zaznamenalo výrazné zníženie oproti predchádzajúcemu roku. Ešte aj v nasledujúcom roku je saldo nízke, ale ku koncu každého štvorročného vládneho obdobia (r. 2001 a 2005) končiaca vláda nastrojuje ekonomické opatrenia, ktoré veľmi výrazne (aj viacej ako dvojnásobne) zvyšujú saldo zahraničného obdobia.

Vzhľadom na malý vnútorný trh patrí Slovenská republika medzi krajiny, v ktorých zahraničný obchod zohráva dôležitú úlohu. Malé krajiny sú totiž vo väčšej miere nútené uspokojovať zvýšený domáci dopyt dovozom tovarov a služieb. Slovensko zostáva aj naďalej veľmi závislé na dodávkach strategických a nerastných surovín, predovšetkým ropy a zemného plynu najmä z Ruska a na druhej strane vyváža jednoduché výrobky s nízkou pridanou hodnotou. Transformácia slovenskej ekonomiky z centrálne plánovanej na trhovú začiatkom 90-tych rokov značne poznačila výrobu vo viacerých odvetviach národného hospodárstva. Štrukturálne zmeny sa najviac týkajú strojárnských podnikov, špeciálnej výroby atď. Práve v prípade týchto komodít došlo k značnému zvýšeniu dovozu.


4.2 ARIMA model dovozu tovarov a služieb do SR

Bázu dát pre ARIMA model tvorí časový rad dovozu tovarov a služieb za roky 1997 až 2009 v štvrtročnom vyjadrení, mld. EUR, stále ceny roku 2000 (sezónne neočistený). Zdrojom údajov je Štatistický úrad SR databáza SLOVSTAT.

4.2.1 Identifikácia modelu


Prvým krokom pri modelovaní časových radov metodológiou ARIMA modelov je indentifikácia modelu. Pri identifikácii treba určiť vhodnú kombináciu parametrov $(p, d, q)(P, D, Q)_s$ modelu, ktorá zodpovedá vývoju analyzovaného časového radu. Najprv sa musí zistiť, či časový rad, ktorý chceme modelovať a prognózovať, je stacionárny. Najjednoduchší spôsob zistenia stacionarity je graf časového radu y_t oproti času $t = 1, 2, \dots, T$. Časový rad považujeme za stacionárny, ak podľa grafu usúdime, že T hodnôt radu kolíše s konštantnou variabilitou (smerodajnou odchýlkou) okolo konštantnej strednej hodnoty (úrovne).

Pri pohľade na graf pôvodného časového radu dovozu tovarov a služieb na obrázku 4.2.1, vidíme stochastický rastúci trend z čoho usudzujeme, že daný časový rad je nestacionárny v strednej hodnote, pretože hodnoty dovozu nekolíšu okolo konštantného priemeru. Rast prebieha relatívne plynulo bez veľkých výkyvov až do roku 2005. Od tohto obdobia ďalej sa vývoj časového radu javí ako nestacionárny vo variabilite (rozptyl hodnôt okolo lokálnej úrovne sa s časom mení). Na grafe je veľmi dobre vidieť aj výkyvy vývoja dovozu, ktoré môžu byť spôsobené sezónnosťou po dopyte výrobkov a služieb zo zahraničia, teda môžeme predpokladať aj sezónnu zložku.



Obr. 4.2.1 Vývoj celkového dovozu do SR (v mld. EUR, s.c.), za Q1/97 až Q4/09
(Zdroj: Vlastné výpočty)


Z grafu výberovej autokorelačnej funkcie (VACF) na obrázku 4.2.2 vidíme, že prvé štyri koeficienty autokorelácie sú štatisticky významné na 5% hladine významnosti a prvé dva koeficienty sú približne rovné jednej (pozri aj príloha P.1.1). Štatistická významnosť štvrtého koeficienta autokorelácie môže naznačovať štvrťročnú sezónnosť v časovom rade. Koeficienty ACF s posunom oneskorenia k klesajú k nule lineárne a veľmi pomaly, čo svedčí o trende v časovom rade, t.j. časový rad je nestacionárny.



Obr. 4.2.2 Graf VACF celkového dovozu do SR
(Zdroj: Vlastné výpočty)

Na grafe výberovej parciálnej autokorelačnej funkcie (VPACF) na obrázku 4.2.3 vidíme, že štatisticky významný je prvý a druhý parciálny koeficient autokorelácie v nesezónnej časti a štvrtý, piaty a deviaty koeficient v sezónnej časti (pozri aj príloha


P.1.2). Prvý parciálny koeficient je približne rovný jednej a ostatné koeficienty pomaly klesajú v sínusových vlnách smerom k nule. Toto sú takmer ukážkové príklady priebehu teoretickej autokorelačnej a teoretickej parciálnej autokorelačnej funkcie nestacionárneho časového radu.



Obr. 4.2.3 Graf VPACF celkového dovozu do SR

(Zdroj: Vlastné výpočty)

Pôvodný časový rad dovozu výrobkov a služieb upravíme na stacionárny rad prostredníctvom logaritmickej transformácie, ktorá odstráni nestacionaritu vo variabilite. Sezónnosť z radu vylúčime pomocou sezónnej diferencie a pomocou absolútnej diferencie odstránime z radu nestacionaritu v strednej hodnote. Takto upravený časový rad je na obrázku 4.2.4. Časový rad dovozu sa v dôsledku vykonaných úprav skrátil o 5 prvých (najstarších) pozorovaní (4 vplyvom vykonanej sezónnej diferencie a 1 vplyvom absolútnej diferencie) oproti pôvodnému časovému radu.



Obr. 4.2.4 Časový rad dovozu po log. transformácii, sezónnej a absolútnej diferencii


(Zdroj: Vlastné výpočty)

Z obrázka 4.2.4 môžeme vidieť, že časový rad je stacionárny s konštantnou strednou hodnotou (hodnoty radu kolíšu okolo priemeru $\ln \mu = -0,00519522$) a s konštantným rozptylom hodnôt v čase. V prvom štvrtroku 1999 bol zaznamenaný veľký výkyv, považujeme ho však za náhodný. Pomocou spätného operátora B predstavujúceho oneskorenie o jedno obdobie, môžeme takto upravený rad zapísať všeobecne nasledovne:

$$z_t = (1-B)(1-B^4)\ln\text{Dovoz}_t \quad (4.2.1)$$


Na určenie stupňa procesu a typu procesu časového radu Dovoz preskúmame priebeh Výberovej autokorelačnej funkcie (VACF) a Výberovej parciálnej autokorelačnej funkcie (VPACF) po spomínaných transformáciách.

Pri pohľade na graf VACF na obrázku 4.2.5 vidíme, že v nesezónnej časti nie je štatisticky významný žiadny koeficient autokorelácie a v sezónnej časti je štatisticky významný koeficient na štvrtom mieste, teda prvý sezónny koeficient autokorelácie, na hladine významnosti 5 % (pozri aj príloha P.1.3). Graf VACF exponenciálne klesá v sínusových vlnách. Predbežne identifikujeme sezónny model kľavých priemerov prvého stupňa SMA(1).



Obr. 4.2.5 VACF radu $z_t = (1-B)(1-B^4)\ln\text{Dovoz}_t$
(Zdroj: Vlastné výpočty)

Z grafu VPACF radu $z_t = (1-B)(1-B^4)\ln\text{Dovoz}_t$, na obrázku 4.2.6 zistujeme, že štatisticky významný je iba prvý parciálny koeficient autokorelácie v sezónnej časti na hladine významnosti 5 % (pozri aj príloha P.1.4). Predbežne identifikujeme sezónny autoregresný operátor prvého stupňa SAR(1).



Obr. 4.2.6 VPACF radu $z_t = (1-B)(1-B^4)\ln\text{Dovoz}_t$
(Zdroj: Vlastné výpočty)

4.2.2 Odhad parametrov modelu a overenie rezíduí

V predchádzajúcej grafickej analýze výberovej autokorelačnej a parciálnej autokorelačnej funkcie sme predbežne identifikovali sezónny autoregresný operátor prvého stupňa SAR(1) a sezónny model kľzavých priemerov prvého stupňa SMA(1). Pre model vhodný na prognostické účely sa rozhodneme na základe porovnania štandardnej chyby uvažovaných modelov (RMSE).

Porovnaním štandardnej chyby (RMSE) uvažovaných modelov z výstupu programu Statgraphics v tab. 4.2.1 vidíme, že najnižšiu hodnotu dosahuje model (B) ARIMA(0,1,0)x(0,1,1)₄, teda model sezónnych kľzavých priemerov prvého stupňa. Model dosahuje najnižšie hodnoty aj pri ostatných charakteristikách a keďže spĺňa testy rezíduí, použijeme ho na prognózu vývoja dovozu tovarov a služieb na rok 2010.

Tab. 4.2.1 Porovnanie uvažovaných modelov ARIMA pre dovoz tovarov a služieb

Model Comparison						
Data variable: Dovož						
Number of observations = 52						
Start index = Q1/97						
Models						
(A) ARIMA(0,1,0)x(1,1,0) ₄						
Math adjustment: Natural log						
(B) ARIMA(0,1,0)x(0,1,1) ₄						
Math adjustment: Natural log						
(C) ARIMA(0,1,0)x(1,1,1) ₄						
Math adjustment: Natural log						
Estimation Period						
Model	RMSE	MAE	MAPE	ME	MPE	
(A)	0,528144	0,421706	5,25961	-0,0790218	-0,881749	
(B)	0,45848	0,3473	4,22007	-0,0469771	-0,525911	
(C)	0,483177	0,37264	4,50044	-0,055963	-0,710351	
Model	RMSE	RUNS	RUNM	AUTO	MEAN	VAR
(A)	0,528144	OK	OK	OK	OK	OK
(B)	0,45848	OK	OK	OK	OK	OK
(C)	0,483177	OK	OK	OK	OK	OK

(Zdroj: Vlastné výpočty)

Hodnota odhadnutého parametra identifikovaného modelu (B) ARIMA(0,1,0)x(0,1,1)₄ je vo výstupe programu Statgraphics v tab. 4.2.2. Odhad parametra SMA(1) je $\hat{\theta}_1 = 0,838073$. Podmienka invertibility je splnená, pretože $|\hat{\theta}_1| < 1$. Parameter je štatisticky významný na ľubovoľnej hladine významnosti. Model je bez konštanty, pretože stredná hodnota radu z_t nie je štatisticky významne rozdielna od nuly (pozri príloha P.1.5). Podľa priemerných charakteristík rezíduí sa použitím modelu ARIMA(0,1,0)x(0,1,1)₄ bez konštanty dopustíme v období odhadu v priemere 4,22 % chyby (MAPE) a hodnoty odhadu sa budú v priemere odchyľovať od skutočných hodnôt o cca $\pm 0,4585$ mld. EUR (RMSE). Model veľmi mierne systematicky nadhodnocuje skutočnosť (MPE < 0) a hodnoty odhadu sú nadhodnotené v priemere každý štvrtý rok o cca 0,53%, teda o 0,0469 mld. EUR. Pretože smerodajná odchýlka rezíduí RMSE nie je podstatne vyššia ako priemerná absolútna chyba rezíduí MAE, rad rezíduí neobsahuje veľmi vysoké hodnoty.

Tab. 4.2.2 Odhad modelu ARIMA(0,1,0)x(0,1,1)₄ bez konštanty

Number of observations = 52

Start index = Q1/97

Forecast Summary

Math adjustment: Natural log

Nonseasonal differencing of order: 1

Seasonal differencing of order: 1

	<i>Estimation</i>
<i>Statistic</i>	<i>Period</i>
RMSE	0,45848
MAE	0,3473
MAPE	4,22007
ME	-0,0469771
MPE	-0,525911

ARIMA Model Summary

<i>Parameter</i>	<i>Estimate</i>	<i>Std. Error</i>	<i>t</i>	<i>P-value</i>
SMA(1)	0,838073	0,0543597	15,4172	0,000000

Backforecasting: yes

Estimated white noise variance = 0,0034803 with 46 degrees of freedom

Estimated white noise standard deviation = 0,0589941

Number of iterations: 7


(Zdroj: Vlastné výpočty)

4.2.2.1 Overenie predpokladov o náhodnej zložke modelu


Aj keď model spĺňa podmienku invertibility, má štatisticky významný koeficient a nízku štandardnú chybu, nemôžeme si byť istí, že daný odhad modelu ako celku je adekvátny a vhodný na prognózovanie. Veľmi dôležitou podmienkou vhodnosti modelu ako celku je analýza rezíduí modelu s cieľom overiť podmienky bieleho šumu pre náhodné zložky.

Test nezávislosti náhodných zložiek

Či sú rezíduá modelu štatisticky nezávislé (neautokorelované) môžeme zistiť z grafov autokorelačnej a parciálnej autokorelačnej funkcie rezíduí na obr. 4.2.7 a 4.2.8. Môžeme vidieť, že ani jeden koeficient autokorelácie nepresahuje 95 % hranice spoľahlivosti, t.j. koeficienty autokorelácie sa štatisticky významne nelíšia od nuly na 5 % hladine významnosti a môžeme prijať záver o neautokorelovanosti rezíduí skúmaného modelu.



Obr. 4.2.7 ACF rezíduí modelu $ARIMA(0,1,0) \times (0,1,1)_4$ bez konštanty
(Zdroj: Vlastné výpočty)



Obr. 4.2.8 PACF rezíduí modelu $ARIMA(0,1,0) \times (0,1,1)_4$ bez konštanty
(Zdroj: Vlastné výpočty)

Grafická analýza je niekedy dosť subjektívna a závisí na posúdení samotným autorom, preto použijeme na zistenie autokorelácie rezíduí aj objektívne testy štatistickej významnosti.

Na posúdenie nezávislosti rezíduí použijeme Znamienkový test sekvencií nad alebo pod mediánom (runs above and below median), Test náhodnosti založený na bodoch obratu (runs up and down)⁴⁸ a Boxov-Piercov test⁴⁹, ktoré štandardne ponúka program Statgraphics Plus. Výsledky testov sú v tab. 4.2.3. Vidieť, že pri všetkých testoch je hodnota *p-value* dostatočne vysoká na prijatie nulovej hypotézy o rovnosti koeficientov

⁴⁸ Bližšie k testom pozri napr. RUBLÍKOVÁ, E. 2007. *Analýza časových radov*. Bratislava : Iura Edition, 2007, str. 46 - 49

⁴⁹ Bližšie pozri napr. RUBLÍKOVÁ, E. 2007. *Analýza časových radov*. Bratislava : Iura Edition, 2007, str. 55

autokorelácie nule na ľubovoľnej hladine významnosti a rezíduá modelu sú vzájomne lineárne nezávislé.


Tab. 4.2.3 Testy nezávislosti pre rezíduá modelu ARIMA(0,1,0)x(0,1,1)₄ bez konštanty

- | |
|---|
| <p>(1) Runs above and below median
 Median = -0,00312603
 Number of runs above and below median = 27
 Expected number of runs = 24,0
 Large sample test statistic $z = 0,74554$
 P-value = 0,455943</p> <p>(2) Runs up and down
 Number of runs up and down = 32
 Expected number of runs = 31,0
 Large sample test statistic $z = 0,17641$
 P-value = 0,859967</p> <p>(3) Box-Pierce Test
 Test based on first 15 autocorrelations
 Large sample test statistic = 3,5531
 P-value = 0,997609</p> |
|---|

(Zdroj: Vlastné výpočty)

Test heteroskedasticity náhodných zložiek

V časových radoch so sezónnou zložkou je častá heteroskedasticita pozorovaní, t.j. rastúca variabilita pozorovaní v čase. Opakom je konštantnosť rozptylu - homoskedasticita. Posúdiť homoskedasticitu rezíduí v čase možno na základe grafu *rezíduá verzus čas*. Pre graf homoskedastických rezíduí je typické, že sa podobá grafu náhodných (nezávislých) rezíduí, t.j. rezíduá kolíšu okolo nuly v určitom konštantnom pásme s hranicami $\pm$ smerodajná odchýlka rezíduí. Graf rezíduá verzus čas je na obrázku 4.2.9. Pri pohľade na graf by sme mohli prijať tvrdenie o homoskedasticite rezíduí, pretože tieto nevykazujú systematický priebeh opísateľný matematickou funkciou a väčšina hodnôt sa nachádza v rozpätí ohraničeného smerodajnou odchýlkou rezíduí.



Obr. 4.2.9 Graf rezíduá modelu ARIMA(0,1,0)x(0,1,1)₄ bez konštanty vz. čas
(Zdroj: Vlastné výpočty)

Rozhodnutie na základe grafického zobrazenia rezíduá verzus čas je taktiež subjektívne a nemusí byť vždy správne. Otázkou tiež je, či pozorovaná heteroskedasticita rezíduí je aj štatisticky významná. Popri grafickom posúdení sa preto používajú aj testy zhody rozptylov. Najpoužívannejšie nešpecifické testy homoskedasticity sú *Bartlettov test*, *Cochranov test* a *Leveneov test*⁵⁰. Vo všetkých testoch sa testuje platnosť nulovej hypotézy o rovnosti rozptylov (t.j. náhodná zložka je homoskedastická) oproti alternatívnej hypotéze, že aspoň niektoré rozptyly sa nerovnajú (t.j. náhodná zložka je heteroskedastická) s danou pravdepodobnosťou. Výsledky jednotlivých testov sú v tab. 4.2.4 kde vidíme, že hodnoty testovacích charakteristík sú veľmi nízke a preto hodnoty *p-value* sú takmer rovné jednej, z čoho môžeme zamietnuť alternatívnu hypotézu o heteroskedasticite rezíduí na ľubovoľnej hladine významnosti.

Tab. 4.2.4 Testy homoskedasticity rezíduí modelu ARIMA(0,1,0)x(0,1,1)₄ bez konštanty

	Test	P-Value
Bartlett's	1,00004	0,968556
Cochran's C	0,504581	0,968561
Levene's	0,004695	0,945729


(Zdroj: Vlastné výpočty)

⁵⁰ Bližšie k testom pozri napr. ŠOLTÉS, E. 2008. *Regresná a korelačná analýza s aplikáciami*. Bratislava : Iura Edition, 2008. s. 147-152.

Testovanie normálneho rozdelenia náhodných zložiek

Predpoklad o normálnom rozdelení náhodných zložiek umožňuje konštruovať intervaly spoľahlivosti skutočných hodnôt radu, ale aj jeho krátkodobých prognóz. Testy normality robíme opäť buď graficky (histogramom) alebo na základe ďalších testov.

Na obr. 4.2.10 je histogram rezíduí odhadovaného modelu, z ktorého nevieme jednoznačne potvrdiť normalitu rezíduí.



Obr. 10 Histogram rezíduí modelu $ARIMA(0,1,0) \times (0,1,1)_4$ bez konštanty
(Zdroj: Vlastné výpočty)

Najpoužívannejšie testy normality sú *Chí-kvadrát test dobrej zhody*, *Shapiro-Wilkov test* a *Kolmogorovov-Smirnovov test*⁵¹. Testuje sa nulová hypotéza o zhode rezíduí s teoretickým normálnym rozdelením na stanovenej hladine významnosti. Výsledky jednotlivých testov sú v tab. 4.2.5. Vidíme, že hodnoty *p-value* sú dostatočne vysoké, aby sme mohli prijať nulovú hypotézu o normalite rezíduí odhadovaného modelu $ARIMA(0,1,0) \times (0,1,1)_4$ bez konštanty.

⁵¹ Bližšie k testom pozri napr. ŠOLTÉS, E. 2008. *Regresná a korelačná analýza s aplikáciami*. Bratislava : Iura Edition, 2008. s. 170-172.

Tab. 4.2.5 Testy normality rezíduí modelu $ARIMA(0,1,0) \times (0,1,1)_4$ bez konštanty

Test	Statistic	P-Value
Chi-Squared	10,0638	0,815706
Shapiro-Wilk W	0,97908	0,712671

Kolmogorov-Smirnov Test	
	<i>Normal</i>
DPLUS	0,0431284
DMINUS	0,0708757
DN	0,0708757
P-Value	0,972255

(Zdroj: Vlastné výpočty)

4.2.3. Prognóza dovozu tovarov a služieb do SR modelom $ARIMA$

Po doterajšej analýze modelu $ARIMA (0,1,0) \times (0,1,1)_4$ bez konštanty môžeme konštatovať, že parameter $\hat{\theta}_1 = 0,838073$ je štatisticky významný, model spĺňa predpoklad invertibility a rezíduá vyhovujú podmienkam bieleho šumu. Model môžeme zapísať nasledovne:

$$z_t = (1 - B)(1 - B^4) \ln Dovozy_t = \Theta_1(B^4)a_t \quad (4.2.2)$$

$$\text{alebo} \quad (1 - B - B^4 + B^5) \ln Dovozy_t = [1 - \Theta_{1,4}(B^4)]a_t \quad \text{pre } t = 6, 7, \dots, 52 \quad (4.2.3)$$

kde a_t sú rezíduá (náhodný šok; biely šum)

Potom po roznásobení:

$$\ln Dovozy_t - \ln Dovozy_{t-1} - \ln Dovozy_{t-4} + \ln Dovozy_{t-5} = a_t - \Theta_{1,4}a_{t-4} \quad (4.2.4a)$$

$$\ln Dovozy_t = (a_t - \Theta_{1,4}a_{t-4}) + \ln Dovozy_{t-1} + \ln Dovozy_{t-4} + \ln \frac{1}{Dovozy_{t-5}} \quad (4.2.4b)$$

Po úprave a dosadení hodnoty parametra $\hat{\theta}_1$ dostaneme výsledný tvar:

$$Dovozy_t = \exp(a_t - 0,838073a_{t-4}) * \frac{Dovozy_{t-1} * Dovozy_{t-4}}{Dovozy_{t-5}} \quad (4.2.5)$$

Simulácia ex-post

Kvalitu modelu a presnosť prognózy overíme na základe *simulácie ex-post* za posledných 12 období. Výsledné údaje sú v tabuľke 4.2.6, kde môžeme vidieť, že hodnoty ex-post prognózy nami zvoleným modelom $ARIMA (0,1,0) \times (0,1,1)_4$ bez konštanty sú takmer totožné so skutočnými hodnotami dovozu a služieb do Slovenskej republiky.

Tab 4.2.6. Skutočné hodnoty dovozu tovarov a služieb do SR, ex-post prognóza dovozu modelom ARIMA (0,1,0)x(0,1,1)₄ bez konštanty a chyba prognózy (mld. EUR, s.c.), 2007Q1 – 2009Q4

Obdobie	Skutočnosť	Prognóza ex-post	Chyba prognózy
2007Q1	10,4812	10,2814	0,1998
2007Q2	11,0623	11,6871	-0,6248
2007Q3	10,9296	10,9411	-0,0115
2007Q4	12,8458	12,2337	0,6121
2008Q1	11,5881	11,3569	0,2312
2008Q2	11,9475	12,8284	-0,8809
2008Q3	11,3283	11,8150	-0,4867
2008Q4	11,8425	12,7615	-0,9190
2009Q1	9,0078	10,4976	-1,4898
2009Q2	9,2896	9,87917	-0,5896
2009Q3	9,5624	9,13593	0,4265
2009Q4	10,6277	10,6670	-0,0393

(Zdroj: Vlastné výpočty)

Ak vyhodnotíme chyby prognóz simulácie ex-post, zistíme že prognózované hodnoty sa od skutočných hodnôt odchyľujú v priemere o 5,13 %, teda o ±0,6749 mld. EUR a model veľmi mierne systematicky nadhodnocuje skutočnosť. Hodnoty odhadu sú nadhodnotené v priemere každý štvrt'rok o 2,94 %, teda o 0,2977 mld. EUR.

Predchádzajúcou analýzou sme potvrdili veľmi dobrú vypovedaciu schopnosť modelu ARIMA (0,1,0)x(0,1,1)₄ bez konštanty.


Prognóza ex-ante

Prognóza ex-ante dovozu tovarov a služieb do SR na rok 2010 spolu aj s hornou a dolnou hranicou 95 % intervalu spoľahlivosti sú v tabuľke 4.2.7. Grafické zobrazenie prognózy aj so skutočnými hodnotami dovozu je na obr. 4.2.11.

Tab. 4.2.7 Prognóza ex-ante dovozu tovarov a služieb do SR modelom ARIMA (0,1,0)x(0,1,1)₄ bez konštanty, spodná a horná 95% hranica (v mld. EUR, s.c.), 2010Q1 – 2010Q4

Obdobie	Prognóza	Spodná 95,0% hranica	Horná 95,0% hranica
2010Q1	9,2097	8,1785	10,3709
2010Q2	9,9923	8,4475	11,8195
2010Q3	9,9039	8,0628	12,1656
2010Q4	11,0362	8,7031	13,9947

(Zdroj: Vlastné výpočty)



Obr. 4.2.11 Skutočné hodnoty dovozu tovarov a služieb do SR za Q1/97 - Q4/10, vyrovnané hodnoty a prognóza na rok 2010 modelom ARIMA $(0,1,0) \times (0,1,1)_4$ bez konštanty (mld. EUR, s.c.)

(Zdroj: Vlastné výpočty)

4.3 VAR model dovozu tovarov a služieb do SR

Na vytvorenie VAR modelu použijeme časové rady premenných dovoz tovarov a služieb (M), konečná spotreba spolu⁵² (KSS) a tvorba hrubého kapitálu (THK). Bázu tvoria údaje za obdobie 1997Q1 až 2009Q4 v mld. EUR stálych cien. Zdrojom údajov je Štatistický úrad databáza SLOVSTAT. Na lepšie vystihnúť trendu použijeme časové rady sezónne očistené.

4.3.1 Analýza stacionarity uvažovaných premenných


Prvým krokom pri vytváraní VAR modelu je analýza stacionarity, respektíve určenie stupňa (rádu) diferencovania (integrácie) použitých premenných. Pri analýze ekonomických časových radov sa prakticky stretávame s integrovanými časovými radmi

⁵² Použijeme údaje o celkovej konečnej spotrebe, ktorú ŠÚ SR udáva ako súčet konečnej spotreby domácností, štátu a neziskových inštitúcií slúžiacich domácnostiam.

maximálne rádu dva, t.j. rády typu $I(2)$. Najčastejšie sa však môžeme stretnúť s rádmí $I(1)$. Časové rady sa teda stacionarizujú väčšinou prostredníctvom prvej či druhej diferenciencie.

Najjednoduchším spôsobom určenia stupňa diferencovania premennej je posúdenie grafu časového radu. Ak z grafu vidíme, že časový rad má lineárny trend, tak na jeho odstránenie použijeme prvú diferencienciu, na odstránenie kvadratického trendu použijeme zase druhú diferencienciu. Veľmi jednoduchou metódou je tiež posúdenie tvaru výberovej autokorelačnej funkcie (VACF) a výberovej parciálnej autokorelačnej funkcie (VPACF). Ak je pôvodný časový rad nestacionárny, analyzujú sa jeho prvé diferenciencie. Ak rad prvých diferenciencií je nestacionárny, analyzuje sa rad druhých diferenciencií.

Pri pohľade na graf pôvodného časového radu dovozu tovarov a služieb na obr. 4.3.1 vidíme, že tento má stochastický rastúci trend, až do obdobia začiatku roku 2008 kedy vidieť pokles hodnoty dovozu čo je dané vtedy vznikajúcou celosvetovou hospodárskou krízou. Na odstránenie tohto trendu a tým stacionarizovanie časového radu dovozu by mohla stačiť prvá absolútna diferenciencia.



Obr. 4.3.1 Dovoz tovarov a služieb do SR (mld. EUR, s.c. sezónne očistený), Q1/97 až Q4/09

(Zdroj: Vlastné výpočty)

Vhodnosť použitia prvej diferencie potvrdzujú aj grafy VACF a VPACF na obr. 4.3.2, na ktorom vidieť, že po použití prvej diferencie nie je žiadny autokorelačný ani parciálny autokorelačný koeficient štatisticky významný na hladine významnosti 0,05 a ich hodnoty klesajú k nule veľmi rýchlo. To znamená, že časový rad prvých diferencií premennej dovoz tovarov a služieb je stacionárny a časový rad dovozu tovarov a služieb je integrovaný rádu jeden, teda $M_t \sim I(1)$.

Sample: 1997Q1 2009Q4 Included observations: 51						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.244	0.244	3.2207	0.073
		2	0.057	-0.003	3.3988	0.183
		3	0.167	0.163	4.9679	0.174
		4	-0.061	-0.153	5.1843	0.269
		5	0.093	0.161	5.6975	0.337
		6	0.066	-0.034	5.9568	0.428
		7	-0.020	0.016	5.9804	0.542
		8	0.050	-0.002	6.1366	0.632
		9	0.061	0.076	6.3782	0.702
		10	0.008	-0.034	6.3826	0.782
		11	0.018	0.010	6.4034	0.845
		12	-0.002	-0.024	6.4037	0.894
		13	-0.004	0.019	6.4049	0.930
		14	-0.002	-0.031	6.4052	0.955
		15	-0.008	0.009	6.4094	0.972
		16	-0.032	-0.043	6.4874	0.982
		17	0.006	0.037	6.4899	0.989
		18	0.017	-0.004	6.5127	0.994
		19	-0.022	-0.011	6.5533	0.996
		20	0.025	0.023	6.6061	0.998
		21	-0.023	-0.033	6.6524	0.999
		22	0.002	0.032	6.6530	0.999
		23	-0.023	-0.061	6.7021	1.000
		24	0.002	0.060	6.7027	1.000

Obr. 4.3.2 VACF a VPACF prvých diferencií premennej dovoz

(Zdroj: Vlastný výpočet)

Tieto dve metódy určovania rádu diferencovania majú však subjektívny charakter. Preto na posúdenie stupňa diferencovania premenných použijeme aj rozšírený Dickeyov-Fullerov test (ADF test).

Prvým krokom ADF testu je nájdenie najvhodnejšieho tvaru modelu obsahujúceho absolútny člen a trend, zapísané vo všeobecnom tvare (3.1.38). Pomocou Schwarzovho kritéria (SC)⁵³ zvolíme model (v zátvorke sú odhady smerodajných odchýlok):

⁵³ Bližšie pozri napr. LUKÁČIKOVÁ, A. – LUKÁČIK, M. 2008. *Ekonometrické modelovanie s aplikáciami*. Bratislava : Vydavateľstvo EKONÓM, 2008. s. 226

$$\Delta M_t = 0,9177 + 0,0332t - 0,2303M_{t-1} + 0,3671\Delta M_{t-1} + 0,0725\Delta M_{t-2} + 0,4406\Delta M_{t-3}$$

$$(0,3398) \quad (0,0170) \quad (0,0998) \quad (0,1559) \quad (0,1653) \quad (0,1916)$$

$$(4.3.1)$$

kde $F = 2,513$, čo je menej ako hodnota tabelovanej Φ_3 štatistiky a preto nulovú hypotézu $H_0 : \delta = \alpha_1 = 0$ na päťpercentnej hladine významnosti nemôžeme zamietnuť.

Postup ďalej pokračuje nájdením najvhodnejšieho tvaru modelu obsahujúceho iba absolútny člen (3.1.37). Opäť pomocou SC kritéria volíme model:

$$\Delta M_t = 0,301 - 0,0286M_{t-1} + 0,2459\Delta M_{t-1}$$

$$(0,1875) \quad (0,0232) \quad (0,1405)$$

$$(4.3.2)$$

v ktorom $F = 2,303$, čo je menej ako hodnota tabelovanej Φ_1 štatistiky a nemôžeme na 5% hladine významnosti zamietnuť nulovú hypotézu $H_0 : \delta = \mu = 0$. Z toho vyplýva, že skúmaný časový rad dovozu tovarov a služieb je typu *náhodná prechádzka* (random walk), teda rad je nestacionárny a integrovaný rádu jeden $I(1)$.

Na overenie stupňa integrovania môžeme pokračovať v opakovaní postupu ADF testu pre rad prvých diferencií premennej dovoz tovarov a služieb. Na zistenie stupňa integrácie premennej prvej diferenciie dovozu nájdeme opäť najvhodnejší tvar modelu obsahujúceho absolútny člen a trend. Pomocou SC kritéria má potom výsledný model tvar:

$$\Delta^2 M_t = 0,1621 - 0,0031t - 0,7696\Delta M_{t-1}$$

$$(0,1183) \quad (0,0039) \quad (0,1432)$$

$$(4.3.3)$$

kde $F = 14,433$ a to je viac ako hodnota tabelovanej Φ_3 štatistiky a môžeme zamietnuť nulovú hypotézu $H_0 : \delta = \alpha_1 = 0$ na 5% hladine významnosti a pokračujeme testovaním parametra δ . Hodnota testovacej charakteristiky $t_\delta = -0,7696/0,1432 = -5,3743$. Hodnota testovacej charakteristiky je menšia ako hodnota tabelovanej τ_t štatistiky a na päťpercentnej hladine významnosti môžeme teda zamietnuť nulovú hypotézu $H_0 : \delta = 0$ a časový rad prvých diferencií dovozu je stacionárny. Keďže časový rad prvých diferencií dovozu je stacionárny, môžeme konštatovať, že časový rad dovozu je integrovaný rádu

jeden, teda $M_t \sim I(1)$ čo nám potvrdila aj predchádzajúca grafická analýza pôvodného časového radu dovozu a výberovej autokorelačnej a výberovej parciálnej autokorelačnej funkcie.

Zisťovanie stupňa diferencovania je pre každú premennú veľmi podobné, preto pri ostatných premenných spomenieme iba najdôležitejšie hodnoty, na základe ktorých sa rozhodujeme. Výsledky ADF testu pre všetky použité premenné sú v tab. 4.3.1. Z výsledkov vidíme, že všetky časové rady uvažovaných premenných sú nestacionárne a integrované rádu jedna.

Tab. 4.3.1 Výsledky ADF testu pre uvažované premenné (dovoz tovarov a služieb do SR, konečná spotreba spolu, tvorba hrubého kapitálu)

Premenná	Φ_3 $H_0 : \delta = \alpha_1 = 0$	τ_t $H_0 : \delta = 0$	Φ_1 $H_0 : \delta = \mu = 0$	τ_μ $H_0 : \delta = 0$	Záver
M_t	F = 2,303 H_0	nepotrebuje	F = 2,303 H_0	nepotrebuje	I(1)
ΔM_t	F = 14,433 H_1	$t_\delta = -5,378 H_1$	nepotrebuje	nepotrebuje	I(0)
KSS_t	F = 1,717 H_0	nepotrebuje	F = 0,483 H_0	nepotrebuje	I(1)
ΔKSS_t	F = 13,538 H_1	$t_\delta = -3,743 H_1$	nepotrebuje	nepotrebuje	I(0)
THK_t	F = 4,060 H_0	nepotrebuje	F = 3,707 H_0	nepotrebuje	I(1)
ΔTHK_t	F = 21,581 H_1	$t_\delta = -3,671 H_1$	nepotrebuje	nepotrebuje	I(0)

(Zdroj: Vlastné výpočty)

4.3.2 Odhad VAR modelu dovozu tovarov a služieb do SR

Ak pomocou informačných kritérií Akaikeho a Schwarz a zvolíme oneskorenie o dve obdobia môžeme model VAR(2) zapísať v štrukturálnom tvare nasledovne:

$$M_t = \beta_{10} + \gamma_{11}KSS_t + \gamma_{12}THK_t + \beta_{11}M_{t-1} + \beta_{12}KSS_{t-1} + \beta_{13}THK_{t-1} + \beta_{14}M_{t-2} + \beta_{15}KSS_{t-2} + \beta_{16}THK_{t-2} + u_{t1} \quad (4.3.5)$$

$$KSS_t = \beta_{20} + \gamma_{21}M_t + \gamma_{22}THK_t + \beta_{21}M_{t-1} + \beta_{22}KSS_{t-1} + \beta_{23}THK_{t-1} + \beta_{24}M_{t-2} + \beta_{25}KSS_{t-2} + \beta_{26}THK_{t-2} + u_{t2} \quad (4.3.6)$$

$$THK_t = \beta_{30} + \gamma_{31}M_t + \gamma_{32}KSS_t + \beta_{31}M_{t-1} + \beta_{32}KSS_{t-1} + \beta_{33}THK_{t-1} + \beta_{34}M_{t-2} + \beta_{35}KSS_{t-2} + \beta_{36}THK_{t-2} + u_{t3} \quad (4.3.7)$$

Ak použijeme maticový zápis môžeme model upraviť na redukovaný tvar:

$$\begin{bmatrix} 1 & -\gamma_{11} & -\gamma_{12} \\ -\gamma_{21} & 1 & -\gamma_{22} \\ -\gamma_{31} & -\gamma_{32} & 1 \end{bmatrix} \begin{bmatrix} M_t \\ KSS_t \\ THK_t \end{bmatrix} = \begin{bmatrix} \beta_{10} \\ \beta_{20} \\ \beta_{30} \end{bmatrix} + \begin{bmatrix} \beta_{11} & \beta_{12} & \beta_{13} \\ \beta_{21} & \beta_{22} & \beta_{23} \\ \beta_{31} & \beta_{32} & \beta_{33} \end{bmatrix} \begin{bmatrix} M_{t-1} \\ KSS_{t-1} \\ THK_{t-1} \end{bmatrix} + \\ + \begin{bmatrix} \beta_{14} & \beta_{15} & \beta_{16} \\ \beta_{24} & \beta_{25} & \beta_{26} \\ \beta_{34} & \beta_{35} & \beta_{36} \end{bmatrix} \begin{bmatrix} M_{t-2} \\ KSS_{t-2} \\ THK_{t-2} \end{bmatrix} + \begin{bmatrix} u_{t1} \\ u_{t2} \\ u_{t3} \end{bmatrix} \quad (4.3.8)$$

$$\Gamma \mathbf{y}_t = \mathbf{B}_0 + \mathbf{B}_1 \mathbf{y}_{t-1} + \mathbf{B}_2 \mathbf{y}_{t-2} + \mathbf{u}_t$$

$$\mathbf{y}_t = \Gamma^{-1} \mathbf{B}_0 + \Gamma^{-1} \mathbf{B}_1 \mathbf{y}_{t-1} + \Gamma^{-1} \mathbf{B}_2 \mathbf{y}_{t-2} + \Gamma^{-1} \mathbf{u}_t$$

$$\mathbf{y}_t = \mathbf{C}_0 + \Phi_1 \mathbf{y}_{t-1} + \Phi_2 \mathbf{y}_{t-2} + \mathbf{a}_t \quad (4.3.9)$$

Z pôvodného štrukturálneho tvaru modelu sme takto získali model VAR(2) v štandardnom tvare (3.2.9):

$$\begin{aligned} M_t &= c_{10} + \phi_{11} M_{t-1} + \phi_{12} KSS_{t-1} + \phi_{13} THK_{t-1} + \phi_{14} M_{t-2} + \phi_{15} KSS_{t-2} + \phi_{16} THK_{t-2} + a_{t1} \\ KSS_t &= c_{20} + \phi_{21} M_{t-1} + \phi_{22} KSS_{t-1} + \phi_{23} THK_{t-1} + \phi_{24} M_{t-2} + \phi_{25} KSS_{t-2} + \phi_{26} THK_{t-2} + a_{t2} \\ THK_t &= c_{30} + \phi_{31} M_{t-1} + \phi_{32} KSS_{t-1} + \phi_{33} THK_{t-1} + \phi_{34} M_{t-2} + \phi_{35} KSS_{t-2} + \phi_{36} THK_{t-2} + a_{t2} \end{aligned}$$


Neznáme parametre modelu VAR(2) z diferencovaných časových radov premenných dovoz tovarov a služieb, konečná spotreba spolu a tvorba hrubého kapitálu odhadneme pomocou metódy najmenších štvorcov a dostaneme:

$$\begin{aligned} \Delta M_t &= 0,0474 + 0,1967 \Delta M_{t-1} + 0,5020 \Delta KSS_{t-1} + 0,1112 \Delta THK_{t-1} - 0,1172 \Delta M_{t-2} + \\ &+ 0,2963 \Delta KSS_{t-2} + 0,2216 \Delta THK_{t-2} \end{aligned} \quad (4.3.10)$$

$$\begin{aligned} \Delta KSS_t &= 0,0564 + 0,0067 \Delta M_{t-1} + 0,0299 \Delta KSS_{t-1} + 0,1741 \Delta THK_{t-1} - 0,0098 \Delta M_{t-2} + \\ &+ 0,0519 \Delta KSS_{t-2} + 0,1513 \Delta THK_{t-2} \end{aligned} \quad (4.3.11)$$

$$\begin{aligned} \Delta THK_t &= -0,0936 + 0,1159 \Delta M_{t-1} + 0,9269 \Delta KSS_{t-1} - 0,4377 \Delta THK_{t-1} + 0,0428 \Delta M_{t-2} + \\ &+ 0,3133 \Delta KSS_{t-2} - 0,0004 \Delta THK_{t-2} \end{aligned} \quad (4.3.12)$$

Inverzné korene charakteristickej polynomickej rovnice odhadovaného modelu VAR(2) sú menšie ako jedna a ležia vnútri jednotkového kruhu čo znamená, že skúmaný vektorovo autoregresný model spĺňa podmienku stacionarity (obr. 4.3.3).




Obr. 4.3.3 Inverzné korene charakteristickej polynomickej rovnice modelu VAR(2)
(Zdroj: Vlastné výpočty)

4.3.3 Diagnostická kontrola modelu VAR

4.3.3.1 Autokorelácia nesystematickej zložky

Z Obr. 4.3.4 vidieť, že takmer všetky (okrem dvoch) koeficienty výberovej autokorelačnej maticovej funkcie nepresahujú hranice $\pm 2/\sqrt{T}$ ($T = 52$) stanovené Bartletovou aproximáciou odhadu smerodajnej chyby jednotlivých výberových autokorelácií a vzájomných autokorelácií čo značí, že nesystematická zložka modelu VAR(2) je nezávislá a má charakter bieleho šumu.



Obr. 4.3.4 Výberové autokorelačné maticové funkcie modelu VAR(2)
(Zdroj: Vlastné výpočty)

Nezávislosť rezíduí overíme aj Portmanteauvým testom, ktorý testuje nulovú hypotézu o neautokorelovanosti rezíduí. Z tab. 4.3.2 vidíme, že hodnoty p-value sú vo všetkých oneskoreniach väčšie ako 5 % hladina významnosti a preto vo všetkých prípadoch nezamietame nulovú hypotézu o nezávislosti rezíduí.

Tab. 4.3.2 Výsledky Portmanteauovho testu nezávislosti rezíduí modelu VAR(2)

VAR Residual Portmanteau Tests for Autocorrelations					
H0: no residual autocorrelations up to lag h					
Date: 03/05/10 Time: 14:27					
Sample: 1997Q1 2009Q4					
Included observations: 49					
Lags	Q-Stat	Prob.	Adj Q-Stat	Prob.	df
1	0.329787	NA*	0.336804	NA*	NA*
2	1.258959	NA*	1.306374	NA*	NA*
3	15.39348	0.0807	16.38320	0.0993	9

4	25.77475	0.1050	27.70822	0.1666	18
5	29.10795	0.3557	31.42900	0.2539	27
6	38.45897	0.3588	42.11588	0.2233	36
7	41.40430	0.6251	45.56407	0.4485	45
8	49.82312	0.6361	55.66665	0.4118	54
9	62.84659	0.4817	71.69555	0.2117	63
10	71.55077	0.4928	82.69029	0.1827	72
11	77.68005	0.5839	90.64179	0.2173	81
12	84.09970	0.6553	99.20133	0.2379	90
*The test is valid only for lags larger than the VAR lag order. df is degrees of freedom for (approximate) chi-square distribution					

(Zdroj: Vlastné výpočty)

4.3.3.2 Normalita nesystematickej zložky


Pomocou mier šikmosti a špicatosti sme otestovali normalitu náhodnej zložky každej z troch rovníc modelu VAR(2) zvlášť a spoločne za celý model (tab. 4.3.3). Na 5 % hladine významnosti nemôžeme potvrdiť normálnu šikmosť a špicatosť rezíduí iba rovnice premennej dovoz tovarov a služieb keďže p-value je menšia ako hladina významnosti. Avšak potom nemôžeme prijať ani hypotézu o normalite rezíduí modelu VAR(2). Nenormalita rezíduí vektorovo autoregresného modelu môže byť spôsobená malým počtom pozorovaní a miery šikmosti a špicatosti nie sú v tomto prípade informatívne.

Tab. 4.3.3 Výsledky testu normality rezíduí modelu VAR(2)


VAR Residual Normality Tests				
Orthogonalization: Cholesky (LÜTKEPOHL)				
H0: residuals are multivariate normal				
Date: 03/05/10 Time: 19:23				
Sample: 1997Q1 2009Q4				
Included observations: 49				
Component	Skewness	Chi-sq	df	Prob.
1	-1.065395	9.080538	1	0.0026
2	-0.018657	0.002785	1	0.9579
3	0.605664	2.934635	1	0.0867
Joint		12.01796	3	0.0073
Component	Kurtosis	Chi-sq	df	Prob.
1	5.438477	11.89234	1	0.0006
2	2.217688	1.224025	1	0.2686
3	2.594346	0.329110	1	0.5662
Joint		13.44548	3	0.0038

(Zdroj: Vlastné výpočty)


Z grafického priebehu rezíduí jednotlivých rovníc vektorovo autoregresného modelu VAR(2) na obr. 4.3.5a až 4.3.5c vidieť, že rezíduá nemajú systematický priebeh a spĺňajú podmienku nezávislosti, avšak nespĺňajú podmienku normality, pretože ich hodnoty presahujú hranicu určenú dvojnásobkom smerodajnej odchýlky. Takto krátke časové rady (52 údajov), aké sme použili, však podmienku normality spĺňajú veľmi zriedka.



Obr. 4.3.5a Graf rezíduí modelu VAR(2) rovnice dovozu tovarov a služieb do SR
(Zdroj: Vlastné výpočty)



Obr. 4.3.5b Graf rezíduí modelu VAR(2) rovnice konečnej spotreby spolu
(Zdroj: Vlastné výpočty)



Obr. 4.3.5c Graf rezíduí modelu VAR(2) rovnice tvorby hrubého kapitálu
(Zdroj: Vlastné výpočty)

4.3.4 Prognóza dovozu tovarov a služieb do SR modelom VAR(2) na rok 2010

Kvalitu odhadnutého modelu VAR(2) overíme na základe simulácie ex-post. Keďže sme použili sezónne očistené hodnoty premených, upravíme ich na sezónne zaťažené pomocou priemerných sezónnych korigovaných indexov získaných metódou Census X11 (príloha P.2.11). Výsledky simulácie ex-post sú v tabuľke 4.3.4. Rozdiel medzi skutočnými hodnotami dovozu tovarov a služieb do SR a odhadnutými hodnotami je malý. V rokoch 2003 až 2007 model VAR(2) veľmi mierne podhodnocoval skutočnosť a v rokoch 2008 a 2009 skutočnosť nadhodnocoval. Za celé skúmané obdobie (1997Q1 – 2009Q4) sa v priemere hodnoty dovozu tovarov a služieb odhadnuté modelom VAR(2) odchyľujú od skutočných hodnôt dovozu o $\pm 0,3665$ mld. EUR, teda o 3,55 %.

Tab. 4.3.4 Simulácia ex-post, porovnanie hodnôt dovozu tovarov a služieb do SR s odhadom modelu VAR(2) za vybrané roky 2003 až 2009 (mld. EUR, s.c., sezónne zaťažený)

Obdobie	2003	2004	2005	2006	2007	2008	2009
Odhad	28,8245	31,0204	34,5253	41,2196	44,7616	48,3211	39,1143
Dovoz	28,9311	31,3409	35,2124	41,4879	45,3189	46,7063	38,4874
Rozdiel (%)	-0,37	-1,02	-1,95	-0,65	-1,23	3,46	1,63

(Zdroj: Vlastné výpočty)

Prognóza vektorovo autoregresného modelu je jednoduchá, pretože vysvetľujúcimi premennými sú iba oneskorené premenné. Prognózu na ďalšie obdobia vieme vypočítať po priamom dosadení vysvetľujúcich premenných. Pri použití sezónne očistených


premenných takáto prognóza predstavuje iba odhad trendu vývoja dovozu v roku 2010. Preto sme odhadnuté hodnoty dovozu tovarov a služieb do SR modelom VAR(2) prepočítali pomocou priemerných sezónnych korigovaných indexov získaných metódou Census X11 a dostali sme tak sezónne zaťaženú prognózu. Výsledky bodovej prognózy dovozu tovarov a služieb do SR (v mld. EUR) na rok 2010 sú v tab. 4.3.5. Z tabuľky vidíme, že vektorovo autoregresný model VAR(2) predpokladá na najbližšie obdobie rast hodnoty dovozu tovarov a služieb.

Tab. 4.3.5 Bodová prognóza dovoz tovarov a služieb do SR na rok 2010 (v mld. Eur, s.c., sezónne očistená a sezónne zaťažená) a priemerné sezónne korigované indexy

Obdobie	Dovoz tovarov a služieb (sezónne očistený)	Priemerné sezónne korigované indexy	Dovoz tovarov a služieb (sezónne zaťažený)
2010Q1	9,9543	0,9367	9,3242
2010Q2	9,9217	1,0100	10,0209
2010Q3	9,9674	0,9775	9,7431
2010Q4	10,0379	1,0757	10,7978

(Zdroj: Vlastný výpočet)

Na obr. 4.3.6 sú graficky zobrazené skutočné hodnoty dovozu tovarov a služieb do SR a hodnoty dovozu odhadnuté modelom VAR(2) za obdobie 97Q1 až 09Q4 a prognóza dovozu na rok 2010 (v mld. EUR).




Obr. 4.3.6 Skutočné hodnoty dovozu tovarov a služieb do SR a odhadnuté hodnoty modelom VAR(2) (97Q1 – 09Q4, mld. EUR, s.c., sezónne zaťažené) a prognóza na rok 2010

(Zdroj: Vlastný výpočet)

4.3.5 Analýza reakcie na impulz modelu VAR(2)

Analýza reakcie na impulz pomocou funkcie reakcie na impulz umožňuje charakterizovať dynamické vlastnosti vektorovo autoregresného modelu. Šok v i -tej premennej priamo ovplyvní nielen túto premennú, ale sa prenesie aj na všetky ostatné endogénne premenné cez dynamickú štruktúru VAR modelu. Funkcia reakcie na impulz vyjadruje vplyv jednorazového šoku na zmenu endogénnych premenných v modeli.

Na obr. 4.3.7 sú zobrazené funkcie reakcie na impulz pre náš odhadnutý model VAR(2). Vidieť, že reakcia na šok klesá celkom rýchlo a zmizne vo väčšine prípadov po dvoch až piatich pozorovaniach (štvrtrokoch), teda do jedného roku. Najdlhšie trvá odozva na šok spôsobený konečnou spotrebou, ktorý zmizne približne po šiestich pozorovaniach (štvrtrokoch), teda až za rok a pol. Vo všetkých prípadoch efekt jednotkového šoku v jednotlivých premenných zanikne dosť rýchlo, čo svedčí o stabilite systému.



Obr. 4.3.7 Analýza reakcie na impulz modelu VAR(2)

(Zdroj: Vlastné výpočty)

4.4 ECM model dovozu tovarov a služieb do SR

Pri tvorbe modelu s korekčným členom použijeme na vysvetlenie dovozu tovarov a služieb do SR (M) premenné domáci dopyt⁵⁴ (DD), vývoz tovarov a služieb (X) a ako cenový index použijeme podiel deflátoru dovozu tovarov a služieb SR a deflátoru hrubého domáceho produktu (DMHDP), t.j. pomer cien zahraničia k domácim cenám. Časové rady sú za obdobie 1997Q1 až 2009Q4 v mld. EUR stálych cien. Zdrojom údajov je databáza Štatistického úradu SR. Na lepšie vystihnúť trendu použijeme časové rady sezónne očistené. Premenné použijeme v zlogaritmovanom tvare. Logaritmus rieši problém nestacionarity vzhľadom na rozptyl a premenné sa interpretujú ako elasticity.

4.4.1 Analýza stacionarity uvažovaných premenných

Tvorba modelu s korekčným členom začína analýzou stacionarity, resp. určenia stupňa integrácie použitých premenných. Stacionaritu budeme overovať prostredníctvom rozšíreného Dickeyovho-Fullerovho testu, ktorého postup sme ilustrovali pri testovaní stacionarity premennej dovoz tovarov a služieb pri vytváraní VAR modelu v časti 4.3. Postup je pre všetky premenné analogický a preto iba zhrnieme najdôležitejšie výsledky do tabuľky 4.4.1. Premennú dovoz tovarov a služieb sme testovali ešte raz, pretože sa niekedy výsledok stupňa integrácie v pôvodných a zlogaritmovaných hodnotách môže odlišovať.

Tab. 4.4.1 Výsledky ADF testu uvažovaných premenných

Premenná	Φ_3 $H_0 : \delta = \alpha_1 = 0$	τ_t $H_0 : \delta = 0$	Φ_1 $H_0 : \delta = \mu = 0$	τ_μ $H_0 : \delta = 0$	Záver
$\ln M_t$	F = 1,170 H_0	nepotrebuje	F = 2,147 H_0	nepotrebuje	I(1)
$\Delta \ln M_t$	F = 19,386 H_1	$t_\delta = -6.226 H_1$	nepotrebuje	nepotrebuje	I(0)
$\ln DD_t$	F = 4,631 H_0	nepotrebuje	F = 3,730 H_0	nepotrebuje	I(1)
$\Delta \ln DD_t$	F = 18,252 H_1	$t_\delta = -3,501 H_1$	nepotrebuje	nepotrebuje	I(0)
$\ln X_t$	F = 1,707 H_0	nepotrebuje	F = 3,066 H_0	nepotrebuje	I(1)
$\Delta \ln X_t$	F = 21,099 H_1	$t_\delta = -6,495 H_1$	nepotrebuje	nepotrebuje	I(0)
$\ln DMHDP_t$	F = 6,662 H_0	nepotrebuje	F = 6,758 H_1	$t_\delta = -2,483 H_0$	I(1)
$\Delta \ln DMHDP_t$	F = 38,144 H_1	$t_\delta = -7,649 H_1$	nepotrebuje	nepotrebuje	I(0)

(Zdroj: Vlastné výpočty)

⁵⁴ Domáci dopyt predstavuje súčet spotreby domácností, spotreby vlády a hrubej tvorby kapitálu.

Z výsledkov testov stupňa integrácie vidíme, že všetky časové rady uvažovaných premenných sú nestacionárne a integrované I(1). Je preto splnená podmienka pre využitie koncepcie kointegrácie, lebo rád integrácie premenných je rovnaký, pričom sa nejedná o prípad integrácie rádu nula (t.j. prípad stacionarity).

4.4.2 Odhad modelu s korekčným členom dovozu tovarov a služieb do SR

Na odhad modelu s korekčným členom použijeme dvojkrokovú metódu Englea a Grangera^{55, 56}.

Prvým krokom metódy je analýza kointegrácie prostredníctvom overenia stacionarity rezíduí z dlhodobej (kointegračnej) rovnice v tvare (3.3.8):


$$\ln M = -0,1543 + 0,2928 \ln DD + 0,7698 \ln X - 0,3068 \ln DMHDP \quad (4.4.1)$$

(0,1159) (0,0827) (0,0457) (0,0931)

Všetky parametre (okrem konštanty) a model ako celok sú štatisticky významné na ľubovoľnej hladine významnosti. Dovoz z dlhodobého hľadiska je determinovaný domácim dopytom s elasticitou cca 0,29, vývozom tovarov a služieb s elasticitou cca 0,77 a podielom deflátorov dovozu a HDP s multiplikátorom cca -0,31, teda ak vzrastie relatívna cena dovozu oproti domácim cenám, dovoz klesne. Kointegračná rovnica vysvetľuje variabilitu hodnôt dovozu tovarov a služieb do SR na 99,12 % (obr. 4.4.1).

⁵⁵ Procedúru Englea a Grangera pre prípad viacerých premenných možno použiť ak predpokladáme jeden kointegračný vzťah a všetky uvažované premenné sú integrované rovnakého rádu. [Lukáčik, 2007, s. 243]

⁵⁶ Taký postup použili vo svojich prácach aj napr. Bors, 2000 alebo Domonkoš, Mikušová, 2007.



Obr. 4.4.1 Grafické zobrazenie dlhodobej rovnice, vyrovnaná priamka, rezíduá
(Zdroj: Vlastné výpočty)

Stacionaritu časového radu rezíduí získaných z odhadu kointegračnej rovnice overíme prostredníctvom ADF testu. V časovom rade rezíduí nepredpokladáme absolútny člen ani časový trend, preto odhadneme najvhodnejší model v tvare (3.1.36) podľa SC a dostaneme:

$$\Delta RESID_t = -0,2989 RESID_{t-1} \quad (4.4.2)$$

(0,1077)

Nulovú hypotézu o nestacionarite radu rezíduí kointegračnej rovnice zamietame, pretože testovacia štatistika $t = -0,2989/0,1077 = -2,7756$ je na hladine významnosti 0,05 menšia ako tabelovaná hodnota štatistiky Davidsona a Mackinnona. Uvažované premenné sú teda kointegrované a existuje medzi nimi dlhodobý vzťah. Kointegračný vektor je $[1 \ 0,1543 \ -0,2928 \ -0,7698 \ -0,3068]$.

V druhom kroku metódy Englea a Grangera použijeme kointegračný vektor a hodnoty rezíduálov z kointegračnej rovnice oneskorené o jedno obdobie (štvrt'rok) na odhad najvhodnejšieho tvaru modelu s korekčným členom. Výsledný ECM má tvar:


$$\begin{aligned} \Delta \ln M_t = & -0,0059 + 0,1396 \Delta \ln M_{t-1} + 0,7086 \Delta \ln DD_t + 0,1694 \Delta \ln DD_{t-4} + 0,7716 \Delta \ln X_t - \\ & (0,0026) \quad (0,0485) \quad (0,0843) \quad (0,0904) \quad (0,0456) \\ & -0,1925 \Delta \ln DMHDP_{t-2} - 0,6849 RESID_{t-1} - 0,0337 UM_t \quad (4.4.3) \\ & (0,0712) \quad (0,1599) \quad (0,0079) \end{aligned}$$

Z krátkodobého hľadiska sú zmeny dovozu tovarov a služieb závislé na domácom dopyte, ktorého 1% nárast spôsobí cca 0,71% nárast dovozu. Domáci dopyt ovplyvňuje úroveň dovozu aj s oneskorením o štyri obdobia, teda s ročným oneskorením s elasticitou cca 0,17. Zvýšenie vývozu o 1% spôsobí z krátkodobého hľadiska nárast dovozu o 0,77%. Na dovoz tovarov a služieb pôsobí nepriamo aj podiel deflátoru dovozu a deflátoru HDP s oneskorením dvoch štvrtrokov s elasticitou -0,19. To znamená, že dovoz tovarov a služieb do SR reaguje na zmenu cien s polročným oneskorením. Záporná hodnota tohto multiplikátora znamená, že buď so zvýšením cien dovozu alebo znížením domácich cien sa zníži hodnota dovozu tovarov a služieb do SR. V krátkom období bola dynamika medzikvartálnych zmien dovozu tovarov a služieb závislá aj od úrovne dovozu z predchádzajúceho obdobia (multiplikátor má hodnotu cca 0,14).

Parameter pred členom korigujúcim chybu (*RESID*) je záporný, čo znamená, že je splnený predpoklad o jeho znamienku a korekčný mechanizmus funguje. Koeficient krátkodobého prispôsobenia $\gamma = -0,6848$, čo znamená pomerne strednú až rýchlu konvergenciu k dlhodobej rovnováhe, lebo každý štvrtrok sa odklon od dlhodobej rovnováhy upraví o 68,48% smerom k rovnováhe, hore či dole.

Špecifikáciu rovnice ďalej dopĺňa umelá premenná UM, ktorá vysvetľuje nesystematické výkyvy vo vývoji dovozu tovarov a služieb, ktoré nedokázali zachytiť exogénne premenné vystupujúce v modeli. UM nadobúda hodnotu 1 v obdobiach 98Q3, 00Q2 a 05Q4. V ostatných obdobiach má hodnotu 0 (pozri obr. 4.4.1).

Všetky parametre modelu s korekčným členom sú štatisticky významné na hladine významnosti 0,1. Model ako celok je štatisticky významný na ľubovoľnej hladine významnosti. Model vysvetľuje variabilitu hodnôt dovozu tovarov a služieb na 92,34% (obr. 4.4.2). Rezíduá sú podľa Durbin-Watsonovej štatistiky nezávislé ($D-W = 2,18$) čo potvrdzuje aj graf autokorelačnej a parciálnej autokorelačnej funkcie rezíduí (obr. 4.4.3), na ktorom vidieť, že ani jeden koeficient nepresahuje 95 %-né tolerančné hranice.



Obr. 4.4.2 Rovnica ECM dovozu tovarov a služieb do SR, vyrovnaná priamka, rezíduá
(Zdroj: Vlastné výpočty)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.145	-0.145	1.0521	0.305
		2	-0.076	-0.099	1.3492	0.509
		3	0.246	0.226	4.5172	0.211
		4	-0.038	0.026	4.5934	0.332
		5	-0.098	-0.073	5.1192	0.402
		6	0.228	0.162	8.0479	0.235
		7	-0.041	0.005	8.1464	0.320
		8	-0.133	-0.093	9.1934	0.326
		9	0.194	0.092	11.469	0.245
		10	-0.145	-0.131	12.779	0.236
		11	-0.022	0.030	12.811	0.306
		12	0.156	0.068	14.406	0.276
		13	-0.135	-0.086	15.644	0.269
		14	0.114	0.183	16.549	0.281
		15	0.136	0.064	17.881	0.269
		16	-0.099	-0.005	18.602	0.290
		17	0.062	0.071	18.897	0.334
		18	0.026	-0.123	18.951	0.395
		19	-0.177	-0.105	21.516	0.309
		20	0.094	0.030	22.263	0.326

Obr. 4.4.3 Autokorelačná a parciálna autokorelačná funkcia rezíduí ECM dovozu tovarov a služieb do SR
(Zdroj: Vlastné výpočty)

4.4.3 Prognóza dovozu tovarov a služieb do SR ECM na rok 2010

Prognózu dovozu tovarov a služieb do SR na rok 2010 modelom s korekčným členom určíme dvomi spôsobmi. Prvý je na základe expertných prognóz vysvetľujúcich premenných získaných z MFSR. Druhú prognózu dovozu určíme na základe vlastných prognóz vysvetľujúcich premenných získaných ARIMA modelmi. Určeniu prognózy však predchádza overenie modelu.

4.4.3.1 Overenie modelu – dynamická simulácia ex-post


Vypovedaciu schopnosť modelu s korekčným členom overíme pomocou dynamickej simulácie ex-post, čo znamená vyčíslenie minulých hodnôt endogénnej premennej na základe modelu, s využitím hodnôt exogénnych premenných. Dynamickosť spočíva v tom, že vysvetľujúce oneskorené premenné nadobúdajú hodnoty vypočítané v predchádzajúcom období. V modeli sme použili premenné v tvare očistenom od sezónnosti. Preto odhadnuté hodnoty dovozu tovarov a služieb do SR modelom s korekčným členom prepočítame pomocou priemerných sezónnych korigovaných indexov získaných metódou Census X11 (príloha P.2.11) na sezónne zaťažené hodnoty. Porovnanie skutočných hodnôt dovozu tovarov a služieb s hodnotami dovozu odhadnutými ECM sú v tab. 4.4.2.

Tab. 4.4.2 Simulácia ex-post - porovnanie skutočných hodnôt dovozu tovarov a služieb do SR s odhadnutými hodnotami ECM (mld. EUR, s.c., sezónne zaťažené)

Obdobie	2003	2004	2005	2006	2007	2008	2009
Odhad	29,1023	31,3502	35,0587	41,6686	45,6409	47,2191	38,8939
Dovoz	28,9311	31,3409	35,2124	41,4879	45,3189	46,7063	38,4874
Rozdiel (%)	0,59	0,02	-0,43	0,43	0,71	1,09	1,06

(Zdroj: Vlastné výpočty)

Rozdiel medzi skutočnými hodnotami dovozu tovarov a služieb a odhadnutými hodnotami ECM je veľmi malý. Priemerne sa za sledované obdobie 1997Q1 až 2009Q4 modelom odhadnuté hodnoty dovozu odchyľujú od skutočných hodnôt o $\pm 0,1554$ mld. EUR, t.j. o 1,54 %. Tento veľmi malý rozdiel skutočných a odhadnutých hodnôt dovozu pozorovať aj z grafu na obr. 4.4.4, kde môžeme vidieť, že obe krivky sú takmer úplne prekryté.



Obr. 4.4.4 Porovnanie skutočných hodnôt dovozu tovarov a služieb do SR za obdobie 1997Q1 až 2009Q4 s odhadom ECM (mld. EUR, sezónne zaťažené)
(Zdroj: Vlastné výpočty)

4.4.3.2 Prognóza dovozu tovarov a služieb do SR ECM na rok 2010 základe expertných prognóz vysvetľujúcich premenných získaných z MFSR

Na prognózu dovozu tovarov a služieb do SR na rok 2010 modelom s korekčným členom potrebujeme najprv zistiť odhad vývoja vysvetľujúcich premenných (domáci dopyt, vývoz, deflátor dovozu a deflátor HDP) na toto obdobie. Použijeme na to expertný odhad Výboru pre makroekonomické prognózy Ministerstva financií SR z 10. februára 2010, v ktorom sa predpokladá domáci dopyt v roku 2010 na úrovni 46,921 mld. EUR (rast 1,06 %), vývoz 42,395 mld. EUR (rast 4,6 %) a podiel deflátoru dovozu a deflátoru HDP 0,8575 (pokles 3,03 %). Keďže potrebujeme štvrťročné údaje, rozdelíme celkovú ročnú hodnotu premenných do štvrťrokov podľa proporcie, ktorú mali jednotlivé štvrťroky na celkovej hodnote v roku 2009. Sezónne očistené hodnoty (trend) a sezónne zaťažené (prepočítané priemernými sezónnymi korigovanými indexmi získanými metódou Census X11) hodnoty prognózy ex-ante dovozu tovarov a služieb na rok 2010 sú v tab. 4.4.3.


Tab. 4.4.3 Prognóza ex-ante dovozu tovarov a služieb do SR ECM (mld. EUR, s.c., sezónne očistená a sezónne zaťažená), prognóza MF SR, proporcie a priemerné sezónne korigované indexy, rok 2010

Obdobie	Dovoz tovarov a služieb (sezónne očistený)	Dovoz tovarov a služieb (sezónne zaťažený)	Prognóza MF SR	Proporcia	Priemerné sezónne korigované indexy
2010Q1	10,5545	9,8867	10,0825	0,2474	0,9367
2010Q2	10,2741	10,3770	9,9703	0,2446	1,0100
2010Q3	9,9745	9,7504	10,1579	0,2492	0,9775
2010Q4	10,2741	11,0519	10,5492	0,2588	1,0757
Spolu	41,0772	41,066	40,762	x	x

(Zdroj: Vlastné výpočty, MF SR)

Model s korekčným členom predpokladá mierny rast úrovne dovozu tovarov a služieb na rok 2010. Porovnaním s prognózou Výboru pre makroekonomické prognózy Ministerstva financií SR vidíme, že ECM predpokladá vyššie hodnoty dovozu v roku 2010. Treba však podotknúť, že MFSR udáva vo svojej správe iba ročnú hodnotu dovozu tovarov a služieb a tá je 40,762 mld. EUR. My sme hodnoty dovozu pre jednotlivé štvrťroky v tab. 4.4.3 rozdelili podľa proporcie v roku 2009. Sezónne zaťažená hodnota dovozu tovarov a služieb za rok 2010 odhadnutým ECM je 41,066 mld. EUR. Teda náš model prognózuje hodnotu dovozu tovarov a služieb v roku 2010 vyššiu o 0,304 mld. EUR, t.j. o 0,75 %.

Grafické zobrazenie skutočných hodnôt dovozu tovarov a služieb do SR s odhadnutými hodnotami ECM je na obr. 4.4.5.



Obr. 4.4.5 Porovnanie skutočných hodnôt dovozu tovarov a služieb do SR za obdobie 1997Q1 až 2009Q4 s odhadom ECM a prognózou MF SR na rok 2010 (mld. EUR, s.c., sezónne zaťažené)

(Zdroj: Vlastné výpočty, MF SR)

4.4.3.3 Prognóza dovozu tovarov a služieb do SR ECM na rok 2010 na základe vlastných prognóz vysvetľujúcich premenných

Pri tejto prognóze dovozu tovarov a služieb na rok 2010 použijeme vlastný odhad prognózy vysvetľujúcich premenných na toto obdobie. Pomocou metodológie ARIMA modelov sme odhadli v roku 2010 hodnotu domáceho dopytu 47,1719 mld. EUR (rast 1,6 %), vývoz 40,1756 mld. EUR (pokles 0,89 %) a podiel deflátoru dovozu a deflátoru HDP 0,8494 (pokles 3,94 %). Porovnaním prognóz vysvetľujúcich premenných s odhadom Výboru pre makroekonomické prognózy Ministerstva financií SR z 10. februára 2010 zistíme, že náš odhad v roku 2010 predpokladá mierne vyšší rast domáceho dopytu a vyšší pokles deflátoru. Veľmi výrazný je však rozdiel vo vývoji vývozu, kde náš odhad predpokladá prakticky rovnaký objem vývozu ako v roku 2009 avšak odhad MF SR predpokladá rast vývozu v roku 2010 (až) 4,6 %. Hodnoty nášho odhadu vysvetľujúcich premenných a odhad MF SR sú v tabuľke 4.4.4.

Tab. 4.4.4 Autorov odhad vysvetľujúcich premenných uvažovaných v ECM na rok 2010 a odhad Ministerstva financií (mld. EUR, s.c.)

Premenná	Autor	Zmena oproti 2009	MF SR	Zmena oproti 2009
Domáci dopyt	47,1719	+1,6 %	46,921	+1,06 %
Vývoz	40,1756	-0,89 %	42,395	+4,6 %
Deflátor	0,8494	-3,94 %	0,8575	-3,03 %

(Zdroj: Vlastné výpočty, MF SR)

Sezónne zaťažený odhad hodnôt dovozu tovarov a služieb na rok 2010 modelom s korekčným členom, na základe vlastných prognóz vysvetľujúcich premenných, je v tabuľke 4.4.5. Vidíme, že ECM s prognózami vysvetľujúcich premennými odhadnutými autorom predpokladá nižšie hodnoty dovozu tovarov a služieb v roku 2010 v každom jednom štvrtroku ako odhad s prognózami vysvetľujúcich premenných MF SR. V roku 2010 predpokladá autorov odhad dovoz na úrovni 38,3964 mld. EUR, zatiaľ čo odhad vysvetľujúcich premenných pomocou MF SR predpokladá hodnotu dovozu 41,066 mld. EUR. Hodnota dovozu nižšia o 2,669 mld. EUR je spôsobená autorovým predpokladom poklesu vývozu tovarov a služieb zo SR v roku 2010 oproti roku 2009 o -0,89 %, zatiaľ čo MF SR predpokladá rast vývozu v roku 2010 až 4,6 %. Pri premennej vývoz je najvyššia elasticita (0,7716), ktorá „ťahá“ prognózu vývoja dovozu tovarov a služieb na rok 2010

a túto neovplyvní ani predpoklad vyšších hodnôt ostatných uvažovaných premenných v regresnej rovnici ako je predpoveď MF SR.

Tab. 4.4.5 Prognóza dovozu tovarov a služieb do SR ECM (mld. EUR, s.c., sezónne zaťažená), rok 2010

Obdobie	Dovoz (autorov odhad premenných)	Dovoz (odhad premenných MF SR)	Prognóza MF SR
2010Q1	9,0257	9,8867	10,0825
2010Q2	9,6649	10,3770	9,9703
2010Q3	9,3866	9,7504	10,1579
2010Q4	10,3198	11,0519	10,5492
Spolu	38,3964	41,066	40,762

(Zdroj: Vlastné výpočty, MF SR)

4.5 Porovnanie odhadnutých modelov dovozu tovarov a služieb do SR

Na modelovanie dovozu tovarov a služieb do Slovenskej republiky sme použili tri rôzne metodologické prístupy. Prvý prístup vychádza z Boxovej a Jenkinsovej metodológie modelov „autoregresných integrovaných kľzavých priemerov“ (ARIMA), ktoré analyzujú iba vývoj samotného časového radu. Zvolili sme model $ARIMA(0,1,0) \times (0,1,1)_4$ bez konštanty. Pri simulácii ex-post sme zistili, že hodnoty odhadnuté modelom sa od skutočných hodnôt odchyľujú o 5,13 %, o $\pm 0,6749$ mld. EUR

Druhý prístup vychádza z vektorovo autoregresných modelov (VAR), ktoré vyjadrujú viacrozmerné zovšeobecnenie modelov jednorozmerných časových radov. Pomocou informačných kritérií sme zvolili oneskorenie o dve obdobia a metódou najmenších štvorcov sme odhadli parametre modelu VAR(2). Simuláciou ex-post sme zistili, že za celé skúmané obdobie (1997Q1 – 2009Q4) sa v priemere hodnoty dovozu tovarov a služieb do SR odhadnuté modelom VAR(2) odchyľovali od skutočných hodnôt dovozu o $\pm 0,3665$ mld. EUR, teda o 3,55 %. Prostredníctvom analýzy reakcie na impulz sme zistili, že reakcia na šok v jednotlivých časových radoch klesala pomerne rýchlo a zmizla vo väčšine prípadov po dvoch až piatich pozorovaniach (štvrtrokoch), teda do jedného roku.

Tretí zvolený prístup vychádzal z metodológie modelov s korekčným členom (ECM). Na odhad ECM sme použili dvojkrokovú metódu Englea a Grangera. Koeficient krátkodobého prispôsobenia potvrdil pomerne strednú až rýchlu konvergenciu k dlhodobej rovnováhe, lebo každý štvrtrok sa odklon upraví o 68,48 % smerom k rovnováhe, hore či dole. Priemerne sa za sledované obdobie modelom odhadnuté hodnoty dovozu tovarov


a služieb odchyľovali od skutočných hodnôt o $\pm 0,1554$ mld. EUR, t.j. o 1,54 %. Modelom s korekčným členom sme určili prognózu dovozu tovarov a služieb do SR na rok 2010 dvomi spôsobmi. Prvý bol na základe expertných prognóz vysvetľujúcich premenných získaných z MFSR a druhý na základe vlastných prognóz vysvetľujúcich premenných získaných ARIMA modelmi.

Porovnanie prognózy dovozu tovarov a služieb na rok 2010 jednotlivými modelmi spolu aj s prognózou Ministerstva financií SR je v tab. 4.5.1, resp. obr. 4.5.1. Rozdiely v hodnotách dovozu v jednotlivých štvrtrokoch alebo spolu za rok sú malé. Celkovú najnižšiu úroveň dovozu v roku 2010 (38,3964 mld. EUR) predpokladá model ECM s prognózou vysvetľujúcich premenných vypočítanou autorom (ECM-autor) a najvyššiu hodnotu dovozu (41,066 mld. EUR) predpokladá ECM s prognózou vysvetľujúcich premenných odhadnutou Výborom pre makroekonomické prognózy Ministerstva financií SR (ECM-MFSR). Model ECM-autor predpokladá aj najnižšie hodnoty dovozu v každom štvrtroku.

Tab. 4.5.1 Porovnanie prognóz dovozu tovarov a služieb do SR modelom ARIMA, VAR, ECM s odhadom vývoja vysvetľujúcich premenných MF SR (ECM-MFSR) a s odhadom vývoja vysvetľujúcich premenných autorom (ECM-autor) a prognóza MF SR (mld. EUR, s.c., sezónne zaťažené) za štvrtroky 2010 a spolu za rok a chyby odhadu ex-post

Obdobie	ARIMA	VAR	ECM-MFSR	ECM-autor	MF SR
2010/Q1	9,2097	9,3242	9,8867	9,0257	10,0825
2010/Q2	9,9923	10,0209	10,3770	9,6649	9,9703
2010/Q3	9,9039	9,7431	9,7504	9,3866	10,1579
2010/Q4	11,0362	10,7978	11,0519	10,3198	10,5492
Spolu	40,1421	39,9043	41,066	38,3964	40,7599
Chyba ex-post	5,13 %	3,55 %	1,54 %	1,54 %	x

(Zdroj: Vlastné výpočty, MF SR)



Obr. 4.5.1 Porovnanie prognóz dovozu tovarov a služieb do SR modelom ARIMA, VAR, ECM s odhadom vývoja vysvetľujúcich premenných MF SR (ECM-MFSR) a s odhadom vývoja vysvetľujúcich premenných autorom (ECM-autor) a prognóza MF SR (mld. EUR, s.c., sezónne zaťažené) za štvrtroky 2010
(Zdroj: Vlastné výpočty, MF SR)

ZÁVER

Poznanie minulého, súčasného a aj budúceho vývoja dovozu tovarov a služieb je veľmi dôležité pre rozvoj krajiny s malou ekonomikou, akou je slovenská. Dovoz predstavuje časť zahraničného obchodu a tým sa stáva súčasťou hrubého domáceho produktu, ktorý je základným makroekonomickým ukazovateľom slúžiacim na meranie a porovnávanie výkonností ekonomík jednotlivých krajín. Schopnosť predvídať vývoj dovozu tovarov a služieb je dôležitá aj preto, lebo jeho súčasťou sú zložky, ktoré určujú ekonomický rast krajiny v budúcnosti. Poznaním jeho vývoja sa môže vhodnými opatreniami podporiť rast domácej ekonomiky. Z týchto dôvodov považujeme za dôležité analyzovať determinanty vývoja dovozu tovarov a služieb, aby tvorcovia hospodárskej politiky mali k dispozícii aj kvantitatívny nástroj pri politickom rozhodovaní.

Cieľom dizertačnej práce bolo prostredníctvom aktuálnych prístupov k modelovaniu makroekonomických časových radov navrhnúť vhodný prognostický model dovozu tovarov a služieb do SR a určiť jeho prognózu na jednotlivé štvrťroky roku 2010.

Prvý prístup vychádza z Boxovej a Jenkinsovej metodológie modelov „autoregresných integrovaných kľzavých priemerov“ (ARIMA). Nevyhnutnou podmienkou použitia tohto postupu je stacionárnosť časového radu. O makroekonomických časových radoch je známe, že sú nestacionárne. Nebolo tomu inak ani v prípade analyzovaného radu dovozu tovarov a služieb za obdobie Q1/97 až Q4/09 v mld. Eur s.c., ktorý bolo nutné stacionarizovať prostredníctvom transformácií (logaritmická transformácia, sezónna a nesezónna diferencia). Následne skúmaním výberovej autokorelačnej a parciálnej autokorelačnej funkcie stacionarizovaného radu sme zvolili niekoľko vhodných modelov. Porovnaním štandardnej chyby (RMSE) sme vybrali model s najnižšou hodnotou - $ARIMA(0,1,0) \times (0,1,1)_4$ bez konštanty. Podľa priemerných charakteristík rezíduí sa použitím zvoleného modelu dopustíme v období odhadu v priemere 4,22 % chyby (MAPE) a hodnoty odhadu sa budú v priemere odchyľovať od skutočných hodnôt o cca $\pm 0,4585$ mld. EUR (RMSE). Model veľmi mierne systematicky nadhodnocuje skutočnosť ($MPE < 0$) a hodnoty odhadu sú nadhodnotené v priemere každý štvrťrok o cca 0,53%, teda o 0,0469 mld. EUR. Na základe grafických analýz a testov môžeme konštatovať, že odhadnutý parameter $\hat{\theta}_1 = 0,838073$ je štatisticky významný,

model spĺňa predpoklad invertibility a rezíduá vyhovujú podmienkam bieleho šumu. Vyhodnotením chýb prognóz simulácie ex-post, sme zistili že prognózované hodnoty sa od skutočných hodnôt odchyľujú v priemere o 5,13 %, teda o $\pm 0,6749$ mld. EUR a model veľmi mierne systematicky nadhodnocuje skutočnosť. Hodnoty odhadu boli nadhodnotené v priemere každý štvrťrok o 2,94 %, teda o 0,2977 mld. EUR. Prognóza ex-ante naznačovala mierny rast dovozu v roku 2010, na úroveň 40,1421 mld. EUR.

Druhý použitý metodologický prístup bol vektorovo autoregresný (VAR) model, na vytvorenie ktorého sme použili sezónne očistené časové rady premenných dovoz tovarov a služieb, konečná spotreba spolu a tvorba hrubého kapitálu. Bázu tvorili údaje za obdobie 1997Q1 až 2009Q4 v mld. EUR stálych cien. Sezónne očistené časové rady sme použili z dôvodu lepšieho vystihnúť trendu. Prvým krokom pri vytváraní VAR modelu bolo overenie stacionarity uvažovaných časových radov. Grafickou analýzou a rozšíreným Dickeyovým–Fullerovým testom sme zistili, že všetky rady boli nestacionárne a integrované rádu jedna. Následne sme pomocou informačných kritérií Akaikeho a Schwarz zvolili oneskorenie o dve obdobia a metódou najmenších štvorcov sme odhadli parametre modelu VAR(2). Simuláciou ex-post sme zistili, že za celé skúmané obdobie (1997Q1 – 2009Q4) sa v priemere hodnoty dovozu tovarov a služieb do SR odhadnuté modelom VAR(2), po prepočítaní na sezónne zaťažené hodnoty pomocou priemerných sezónnych korigovaných indexov získaných metódou Census X11, odchyľovali od skutočných hodnôt dovozu o $\pm 0,3665$ mld. EUR, teda o 3,55%. Ďalej sme určili sezónne zaťaženú prognózu dovozu tovarov a služieb na rok 2010. Model VAR(2) predpokladal mierny rast úrovne dovozu (39,9043 mld. EUR). Analýzou reakcie na impulz sme zistili, že reakcia na šok klesala celkom rýchlo a zmizla vo väčšine prípadov po dvoch až piatich pozorovaniach (štvrťrokoch), teda do jedného roku. Vo všetkých prípadoch efekt jednotkového šoku v jednotlivých premenných zanikol pomerne rýchlo čo svedčí o stabilite systému.

Posledný použitý prístup bol založený na modeloch s korekčným členom (ECM). Pri tvorbe modelu sme použili na vysvetlenie dovozu tovarov a služieb premenné domáci dopyt, vývoz tovarov a služieb a ako cenový index sme použili podiel deflátoru dovozu a deflátoru hrubého domáceho produktu. Časové rady boli za obdobie 1997Q1 až 2009Q4 v mld. EUR stálych cien, sezónne očistené na lepšie vystihnúť trendu. Použili sme premenné v logaritmickom tvare, ktorý rieši problém nestacionarity vzhľadom na rozptyl

a premenné sa interpretujú ako elasticity. Na začiatku sme overili stacionaritu zlogaritmovaných premenných. Zistili sme, že všetky časové rady uvažovaných premenných boli nestacionárne a integrované stupňa jeden. Tým, že bol stupeň integrácie všetkých premenných rovnaký, bola splnená podmienka pre použitie koncepcie kointegrácie. Na odhad ECM sme použili dvojkrokovú metódu Englea a Grangera. Z krátkodobého hľadiska boli zmeny dovozu tovarov a služieb závislé na domácom dopyte, ktorého 1% nárast spôsobí cca 0,71% nárast dovozu. Domáci dopyt ovplyvňuje úroveň dovozu aj s oneskorením o štyri obdobia s elasticitou cca 0,17. Zvýšenie vývozu o 1% spôsobí z krátkodobého hľadiska nárast dovozu o 0,77%. Na dovoz tovarov a služieb pôsobí podiel deflátoru dovozu a deflátoru HDP s multiplikátorom -0,19 s oneskorením dvoch štvrt'rokov. To znamená, že dovoz tovarov a služieb do SR reaguje na zmenu cien s polročným oneskorením. Záporná hodnota tohto multiplikátora znamená, že buď so zvýšením cien dovozu alebo znížením domácich cien sa zníži hodnota dovozu tovarov a služieb do SR. V krátkom období je dynamika medzikvartálnych zmien dovozu tovarov a služieb závislá aj od úrovne dovozu z predchádzajúceho obdobia (multiplikátor má hodnotu cca 0,14). Koeficient krátkodobého prispôsobenia $\gamma = -0,6848$, čo znamená pomerne strednú až rýchlu konvergenciu k dlhodobej rovnováhe, lebo každý štvrt'rok sa odklon od dlhodobej rovnováhy upraví o 68,48 % smerom k rovnováhe, hore či dole.

Dynamickou simuláciou ex-post sme overili kvalitu modelu. Priemerne sa za sledované obdobie Q1/97 až Q4/09 modelom odhadnuté hodnoty dovozu tovarov a služieb do SR, po prepočítaní na sezónne zaťažené hodnoty pomocou priemerných sezónnych korigovaných indexov získaných metódou Census X11, odchyľovali od skutočných hodnôt o $\pm 0,1554$ mld. EUR, t.j. o 1,54 %.

Sezónne zaťažенú prognózu dovozu tovarov a služieb na rok 2010 modelom s korekčným členom sme vypočítali dvomi spôsobmi. V prvom sme hodnoty vysvetľujúcich premenných uvažovaných v ECM na rok 2010 určili na základe expertného odhadu Výboru pre makroekonomické prognózy Ministerstva financií SR (z 10. februára 2010). Tento prípad predpokladal hodnotu dovozu tovarov a služieb do SR v roku 2010 na úrovni 41,066 mld. EUR. Pri druhom spôsobe sme hodnoty uvažovaných vysvetľujúcich premenných v ECM určili na základe vlastného odhadu pomocou metodologického prístupu založenom na ARIMA modeloch. V tomto prípade model predpokladá hodnotu dovozu tovarov a služieb v roku 2010 na úrovni 38,3964 mld. EUR. Hodnota dovozu nižšia o 2,669 mld. EUR je spôsobená autorovým predpokladom poklesu vývozu tovarov a služieb zo SR v roku 2010 oproti roku 2009 o -0,89 %, zatiaľ čo MF SR predpokladá

v roku 2010 rast vývozu až 4,6 %. Pri premennej vývoz je najvyššia elasticita (0,7716), ktorá „ťahá“ prognózu vývoja dovozu tovarov a služieb na rok 2010 a túto neovplyvní ani predpoklad vyšších hodnôt ostatných uvažovaných premenných v regresnej rovnici ako je predpoveď MF SR. Prognóza dovozu tovarov a služieb do SR samotným MF SR je 40,7599 mld. EUR, čo je v strede medzi dvomi spôsobmi odhadu ECM.

Určiť, ktorý model (prognóza) lepšie vystihuje vývoj dovozu tovarov a služieb nie je jednoduché. Všetky modely veľmi dobre vystihujú minulý vývoj dovozu a vypočítané chyby (odchýlky) sú malé a podobné. Každý modelový prístup má svoje klady aj zápory, preto záleží na samotnom autorovi (analytikovi), pre ktorý prístup sa rozhodne. Ak chce zistiť (iba) prognózu vývoja makroekonomického ukazovateľa, vhodný je ARIMA model, pomocou ktorého sa dá jednoducho a rýchlo zistiť budúci vývoj časového radu. Nevýhodou tohto prístupu je práve to, že modeluje iba jeden časový rad a abstrahuje sa od ekonomickej teórie. Modely s korekčným členom sa už opierajú o ekonomickú teóriu a na rozdiel od klasických ekonometrických modelov vyjadrujú oddelene dlhodobý aj krátkodobý vplyv vysvetľujúcej premennej na vývoj vysvetľovanej premennej. ECM však vyžadujú od používateľa väčšie teoretické vedomosti na ich správnu konštrukciu a prognóza na ich základe závisí od presnosti odhadu budúceho vývoja vysvetľujúcich premenných vstupujúcich do modelu. Premostením medzi týmito dvomi prístupmi sú vektorovo autoregresné modely, ktoré môžeme na jednej strane chápať ako viacrozmerné zovšeobecnenie modelov jednorozmerných časových radov, na druhej strane sú však tieto modely základom pre vznik a riešenie otázok, s ktorými sa v jednorozmernom prípade nemôžeme stretnúť. Predpovede konštruované na základe modelov charakterizujúcich vzťahy medzi viacerými časovými radmi môžu byť presnejšie ako predpovede založené na modeli jedného časového radu.

LITERATÚRA

- ARLT, J. 1999. *Moderní metody modelování ekonomických časových řad*. Praha : Grada, 1999. 307 s. ISBN 80-7169-539-4.
- ARLT, J - ARLTOVÁ, M. 2007. *Ekonomické časové řady*. Praha : Grada Publishing, 2007. 285 s. ISBN 978-80-247-1319-9.
- ASTERIOU, D. - HALL, S. G. 2007. *Applied Econometrics : A Modern Approach using EViews and Microfit*. New York : Palgrave Macmillan, 2007. 397s. ISBN 978-0-230-50640-4.
- BANERJEE, A. et. al. 1993. *Cointegration, error correction, and the econometric analysis of non-stationary data*. Oxford : Oxford University Press, 1993. 352 p. ISBN 978-0-19-828810-7.
- BENÁČEK, V. – VÍŠEK, J. Á. *Determining Factors of Trade Specialization and Growth of a Small Economy in Transition: Impacts of the EU Opening-up on Czech Exports and Imports*. International Institute for Applied Systems Analysis, Austria, 2003.
- BORS, L. 2000. Price and demand sensitivity of the slovakias foreign trade. In *Ekonomický časopis*. 2000, r. 48, č. 5, s. 650 – 663.
- BOX, G. E. P. – JENKINS, G. M. – REINSEL, G. C. 1994. *Time series analysis: Forecasting and control*. New Jersey : Prentice Hall International, Inc. 1994. ISBN 0-13-060774-6.
- CRYER, J. D. – CHAN, K-S. 2008. *Time Series Analysis: With Applications in R*. New York : Springer. 2008. ISBN 978-0-387-75958-6.
- DAVIDSON, R. – MacKINNON, J. G. 1993. *Estimation and inference in econometrics*. New York : Oxford University pres. 1993. 875 s. ISBN 0-19-506011-3.
- DAVIDSON, R. – MacKINNON, J. G. 1999. *Econometric theory and methods*. New York : Oxford Univ. Press. 1999. 693 s.
- DICKEY, D. A. – FULLER, W. A. 1981. Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root. In *Econometrica*. 1981, vol. 49, no. 4, p. 1057-1072.
- DOMONKOS, T. - MIKUŠOVÁ, N. 2007. Modelovanie agregovaného dopytu v SR. In *INPROFORUM 2007 : inovace - podniky - regiony - organizace* [elektronický zdroj]. - České Budějovice : Ekonomická fakulta Jihočeské univerzity v Českých Budějovicích, 2007. ISBN 978-80-7394-016-4, s. 119-128.
- DRNÁKOVÁ, L. 2003. *Ekonomický model agregátneho dopytu Slovenskej republiky : diplomová práca*. Bratislava : UK, 2003. 60 s.
- ENGLE, R. F. – GRANGER, C. W. J. 1987. Cointegration and Error Correction: Representation, Estimation and Testing. In *Econometrica*. 1987, vol. 55, no. 2, p. 251-276.

- FITALA, I. 2007. *Ekonometrické modelovanie investícií* : diplomová práca. Bratislava : UK, 2007. 45 s.
- GRANGER, C. W. J. 2004. Time Series Analysis, Cointegration, and Applications. In *The American Economic Review*. 2004, vol. 94, no. 3, p. 421-425
- GRANGER, C. W. J – NEWBOLD, P. 1974. Spurious regressions in econometrics. In *Journal of econometrics*. 1974, vol. 2, no. 2, p. 111-120
- GRIFFITHS, W. E. - HILL, R. C. - JUDGE, G. G. 1993. *Learning and Practicing conometrics*. New York : John Wiley & Sons, Inc. 1993. 896 s. ISBN 978-0471513643.
- HALUŠKA J. - OLEXA M. - ORSÁGOVÁ J. 2001. Štvrťročný ekonometrický model slovenskej ekonomiky QEM-ECM-1.0. In *Ekonomický časopis*. 2001, r.49, č.51, s.847-867
- HALUŠKA, J. a kol. 2008. *Modelový aparát na rýchle odhady vývoja makroekonomických ukazovateľov slovenskej ekonomiky*. Bratislava : INFOSTAT, Edícia: Aktá. 2008. ISBN 978-80-89398-06-5.
- HAMILTON, J. D. 1994. *Time series analysis*. New Jersey : Princeton university press. 1994.
- HATRÁK, M. 1998. Error correction models and cointegration analysis in applied econometrics. In *CEJORE*. 1998, vol. 6, no. 3-4, p. 183 - 191
- HATRÁK, M. 2007. *Ekonometria*. Bratislava : Iura Edition, 2007. 503 s. ISBN 978-80-8078-150-7.
- HENDRY D. F. 1995. *Dynamic Econometrics*. Oxford : Oxford University Press, 1995. 869 p. ISBN 978-0-19-828316-4.
- HUČEK, J. 2002. *Modelovanie príjmov a spotreby obyvateľstva SR* : diplomová práca. Bratislava : UK, 2002. 62 s.
- CHATFIELD, Ch. 1995. *The analysis of time series*. London : Chapman and Hall/CRC. 1995.
- JURIOVÁ, J. 2009. Využívanie modelových prístupov ARIMA a ECM pri odhade priemyselnej produkcie. In *Slovenská štatistika a demografia*. 2009, č. 1 - 2. str. 3 - 29
- KATARZYNA, B. et. al. 2009. *An update of the macroeconomic model of the Polish economy NECMOD*. National Bank of Poland, 2009.
- KRASUĽOVÁ, T. 2000. *Ekonometrický model zahraničného obchodu SR* : diplomová práca. Bratislava : UK, 2000. 64 s.
- KRIVANSKÁ, K. 2002. *Ekonometrické modelovanie zahraničného obchodu SR* : diplomová práca. Bratislava : UK, 2002. 67 s.

- KOPECSNI, J. 2002. *Analýza efektívnosti národného hospodárstva* : diplomová práca. Bratislava : UK, 2002. 65 s.
- LIVERMORE, S. 2004. *An econometric model of the Slovak Republic*. Financial Policy Institute, Ministry of Finance of the SR. May 2004, p. 57
- LUKÁČIK, M. 2007. *Prognóza na základe modelov s korekčným členom*. In Vincúr, P. – Zajac, Š. a kolektív: *Úvod do prognostiky*. Bratislava : Sprint v.f.a., 2007. ISBN 978-80-89085-86-6.
- LUKÁČIKOVÁ, A. – LUKÁČIK, M. 2008. *Ekonometrické modelovanie s aplikáciami*. Bratislava : Vydavateľstvo EKONÓM, 2008. ISBN 978-80-225-2614-2.
- LÜTKEPOHL, H. 2005. *New introduction to multiple time series analysis*. Berlin : Springer, 2005. 764 s. ISBN 3-540-26239-3.
- MFSR. 2009. Makroekonomické prognózy MFSR na roky 2009 – 2012. Bratislava : Výbor pre makroekonomické prognózy Ministerstva financií, 2009.
- OLEXA, M. 1996. Econometric model of the slovak economy for the period of transition (EMSE – 1.0). Bratislava, INFOSTAT, 1996.
- OLEXA M., HALUŠKA J., KLEIN T., ORSÁGOVÁ J. 1999. Econometric model for transforming slovakia - EMSE 2.0. In *Ekonomický časopis*. 1999, r. 47, č. 3, s. 351-373
- PÁLENÍK, V. a kol. 1998. Construction and Verification of macroeconomic model ISWE97q3. In *Ekonomický časopis*. 1998, r. 46, č. 3, s.428-466
- PÁLENÍK, V. a kol. 2004. Konštrukcia modelu ECM – ISWE04q1. In *Zborník príspevkov - Ekomstat 2004*. Trenčianske Teplice 2004
- PÁLENÍK, V. – RADVANSKÝ, M. 2006. Aplikácie modelov HERMIN a CGE na hodnotenie finančných alokácií NSSR. In *Forum Statisticum Slovaca*. 2006, roč. 2, č. 2, s. 208 - 216.
- PHILLIPS, P. C. B. 1986. Understanding spurious regressions in econometrics. In *Journal of econometrics*. 1986, vol. 33, no. 3, p. 311 -340.
- PHILLIPS, P. C. B. 1987. Time series regression with a unit root. In *Econometrica*. 1987, vol. 55, no. 2, p. 277 -301.
- PHILLIPS, P. C. B. 1991. Error Correction and Long-Run Equilibrium in Continuous Time. In *Econometrica*. 1991, vol. 59, no. 4, p. 967-980
- RUBLÍKOVÁ, E. 2003. Testing for cointegration using Engle-Granger methodology. In *Mathematical Methods in Economics 2003* : Proceedings of the 21th International Conference. 10. - 12. September 2003. - Praha : Czech University of Agriculture in Prague, 2003. s. 235-237. ISBN 80-213-1046-4.

RUBLÍKOVÁ, E a kol. 2003. *Analýza časových radov : zbierka príkladov*. 2. vyd. Bratislava : Vydavateľstvo EKONÓM, 2003. 188 s. ISBN 80-225-1748-8.

RUBLÍKOVÁ, E. 2007. *Analýza časových radov*. Bratislava : Iura Edition, 2007. 207 s. ISBN 978-80-8078-139-2.

RUBLÍKOVÁ, E - PRÍHODOVÁ, I. 2008. *Analýza vybraných časových radov - ARIMA modely*. Bratislava : Vydavateľstvo EKONÓM, 2008. 214 s. ISBN 978-80-225-2540-4.

SIDERIS, D. - ZONZILOS, N. *The Greek model of the European system of central bank multi-country model*. Bank of Greece, 2005.

SIMS, CH. A. 1980. Macroeconomics and reality. In *Econometrica*. 1980, vol. 48, no. 1, p. 1-48.

ŠOLTÉS, E. 2008. *Regresná a korelačná analýza s aplikáciami*. Bratislava : Iura Edition, 2008. 287 s. ISBN 978-80-8078-163-7.

ŠTEKLÁČOVÁ, L. 2003. *Meranie produkčnej medzery SR : diplomová práca*. Bratislava : UK, 2003. 68 s.

VOGELVANG, B. 2005. *Econometrics: theory and applications with EViews*. Harlow : Prentice Hall, 2005. 363 s. ISBN 0-273-68374-8.

PRÍLOHY

1. ARIMA MODEL DOVOZU TOVAROV A SLUŽIEB

P.1.1 Odhadnuté autokorelačné koeficienty premennej Dovož

P.1.2 Odhadnuté parciálne autokorelačné koeficienty premennej Dovož

P.1.3 Odhadnuté autokorelačné koeficienty premennej Dovož po log. transformácii, sezónnej a absolútnej diferencii

P.1.4 Odhadnuté parciálne autokorelačné koeficienty premennej Dovož po log. transformácii, sezónnej a absolútnej diferencii

P.1.5 Odhad parametrov modelu ARIMA so štatisticky nevýznamnou konštantou

2. VAR MODEL DOVOZU TOVAROV A SLUŽIEB

P.2.1 ADF test premennej Dovož (konštantá, lineárny trend)

P.2.2 ADF test premennej Dovož (konštantá)

P.2.3 ADF test premennej Dovož (prvá diferencia, konštantá, lineárny trend)

P.2.4 ADF test premennej Konečná spotreba spolu (konštantá, lineárny trend)

P.2.5 ADF test premennej Konečná spotreba spolu (konštantá)

P.2.6 ADF test premennej Konečná spotreba spolu (prvá diferencia, konštantá, lineárny trend)

P.2.7 ADF test premennej Tvorba hrubého kapitálu (konštantá, lineárny trend)

P.2.8 ADF test premennej Tvorba hrubého kapitálu (konštantá)

P.2.9 ADF test premennej Tvorba hrubého kapitálu (prvá diferencia, konštantá, lineárny trend)

P.2.10 Odhad VAR modelu z diferencovaných premenných, 2 oneskorenia

P.2.11 Priemerné sezónné korigované indexy získané metódou Census X11

3. ECM MODEL DOVOZU TOVAROV A SLUŽIEB

P.3.1 ADF test premennej Dovož (logaritmus, konštantá, lineárny trend)

P.3.2 ADF test premennej Dovož (logaritmus, konštantá)

P.3.3 ADF test premennej Dovož (logaritmus, prvá diferencia, konštantá, lineárny trend)

- P.3.4** ADF test premennej Domáci dopyt (logaritmus, konštanta, lineárny trend)
- P.3.5** ADF test premennej Domáci dopyt (logaritmus, konštanta)
- P.3.6** ADF test premennej Domáci dopyt (logaritmus, prvá diferencia, konštanta, lineárny trend)
- P.3.7** ADF test premennej Vývoz (logaritmus, konštanta, lineárny trend)
- P.3.8** ADF test premennej Vývoz (logaritmus, konštanta)
- P.3.9** ADF test premennej Vývoz (logaritmus, prvá diferencia, konštanta, lineárny trend)
- P.3.10** ADF test premennej Podiel deflátoru dovozu a deflátoru HDP (logaritmus, konštanta, lineárny trend)
- P.3.11** ADF test premennej Podiel deflátoru dovozu a deflátoru HDP (logaritmus, konštanta)
- P.3.12** ADF test premennej Podiel deflátoru dovozu a deflátoru HDP (logaritmus, prvá diferencia, konštanta, lineárny trend)
- P.3.13** Kointegračná (dlhodobá) rovnica
- P.3.14** ADF test rezíduí kointegračnej rovnice (bez absolútneho člena a trendu)
- P.3.15** Rovnica ECM dovozu tovarov a služieb do SR

1. ARIMA MODEL DOVOZU TOVAROV A SLUŽIEB

P.1.1 Odhadnuté autokorelačné koeficienty premennej Dovož

			Lower 95,0%	Upper 95,0%
Lag	Autocorrelation	Std. Error	Prob. Limit	Prob. Limit
1	0,898736	0,138675	-0,271799	0,271799
2	0,882364	0,22427	-0,439562	0,439562
3	0,807789	0,28327	-0,5552	0,5552
4	0,815586	0,32456	-0,636127	0,636127
5	0,704762	0,361833	-0,70918	0,70918
6	0,674948	0,387332	-0,759159	0,759159
7	0,586894	0,409326	-0,802265	0,802265
8	0,575205	0,425201	-0,833379	0,833379
9	0,452332	0,43991	-0,86221	0,86221
10	0,413311	0,448765	-0,879566	0,879566
11	0,322051	0,456027	-0,893798	0,893798
12	0,309038	0,46038	-0,90233	0,90233
13	0,203429	0,464352	-0,910115	0,910115
14	0,165927	0,466063	-0,913468	0,913468
15	0,0881733	0,467197	-0,915692	0,915692
16	0,0911168	0,467517	-0,916319	0,916319
17	0,0107152	0,467859	-0,916988	0,916988

P.1.2 Odhadnuté parciálne autokorelačné koeficienty premennej Dovož

	Partial		Lower 95,0%	Upper 95,0%
Lag	Autocorrelation	Std. Error	Prob. Limit	Prob. Limit
1	0,898736	0,138675	-0,271799	0,271799
2	0,388184	0,138675	-0,271799	0,271799
3	-0,160824	0,138675	-0,271799	0,271799
4	0,282723	0,138675	-0,271799	0,271799
5	-0,459787	0,138675	-0,271799	0,271799
6	0,0507664	0,138675	-0,271799	0,271799
7	-0,0443271	0,138675	-0,271799	0,271799
8	0,034704	0,138675	-0,271799	0,271799
9	-0,281496	0,138675	-0,271799	0,271799
10	0,0263822	0,138675	-0,271799	0,271799
11	0,00836382	0,138675	-0,271799	0,271799
12	0,0403329	0,138675	-0,271799	0,271799
13	-0,0594343	0,138675	-0,271799	0,271799
14	-0,101031	0,138675	-0,271799	0,271799
15	0,0702211	0,138675	-0,271799	0,271799
16	0,0992318	0,138675	-0,271799	0,271799
17	-0,0339906	0,138675	-0,271799	0,271799

P.1.3 Odhadnuté autokorelačné koeficienty premennej Dovož po log. transformácii, sezónnej a absolútnej diferenci

			Lower 95,0%	Upper 95,0%
Lag	Autocorrelation	Std. Error	Prob. Limit	Prob. Limit
1	-0,074876	0,145865	-0,285891	0,285891
2	-0,0218831	0,14668	-0,287489	0,287489
3	-0,0930922	0,14675	-0,287625	0,287625
4	-0,306262	0,148001	-0,290077	0,290077
5	0,0851732	0,160921	-0,315401	0,315401
6	-0,0504844	0,161878	-0,317275	0,317275
7	0,0491103	0,162212	-0,317931	0,317931

8	-0,0520836	0,162528	-0,31855	0,31855
9	0,131815	0,162883	-0,319245	0,319245
10	-0,00202987	0,165137	-0,323663	0,323663
11	0,0419348	0,165138	-0,323664	0,323664
12	-0,0340845	0,165364	-0,324108	0,324108
13	-0,173881	0,165513	-0,324401	0,324401
14	-0,0184118	0,169355	-0,331931	0,331931
15	0,0798124	0,169398	-0,332015	0,332015

P.1.4 Odhadnuté parciálne autokorelačné koeficienty premennej Dovož po log. transformácii, sezónnej a absolútnej diferencií

	<i>Partial</i>		<i>Lower 95,0%</i>	<i>Upper 95,0%</i>
<i>Lag</i>	<i>Autocorrelation</i>	<i>Std. Error</i>	<i>Prob. Limit</i>	<i>Prob. Limit</i>
1	-0,074876	0,145865	-0,285891	0,285891
2	-0,0276445	0,145865	-0,285891	0,285891
3	-0,0974664	0,145865	-0,285891	0,285891
4	-0,32691	0,145865	-0,285891	0,285891
5	0,0221869	0,145865	-0,285891	0,285891
6	-0,0818217	0,145865	-0,285891	0,285891
7	-0,0309406	0,145865	-0,285891	0,285891
8	-0,164178	0,145865	-0,285891	0,285891
9	0,153293	0,145865	-0,285891	0,285891
10	-0,0363065	0,145865	-0,285891	0,285891
11	0,0597218	0,145865	-0,285891	0,285891
12	-0,0810331	0,145865	-0,285891	0,285891
13	-0,0763102	0,145865	-0,285891	0,285891
14	-0,0944259	0,145865	-0,285891	0,285891
15	0,128351	0,145865	-0,285891	0,285891

P.1.5 Odhad parametrov modelu ARIMA so štatisticky nevýznamnou konštantou

Data variable: Dovož

Number of observations = 52

Start index = Q1/97

Sampling interval = 1,0

Length of seasonality = 4

Forecast Summary

Math adjustment: Natural log

Nonseasonal differencing of order: 1

Seasonal differencing of order: 1

Forecast model selected: ARIMA(0,1,0)x(0,1,1)₄ with constant

Number of forecasts generated: 12

Number of periods withheld for validation: 0

	<i>Estimation</i>	<i>Validation</i>
<i>Statistic</i>	<i>Period</i>	<i>Period</i>
RMSE	0,450518	
MAE	0,340014	
MAPE	4,13354	
ME	0,00282566	
MPE	-0,0436176	

ARIMA Model Summary

Parameter	Estimate	Std. Error	t	P-value
SMA(1)	0,844186	0,0535078	15,7769	0,000000
Mean	-0,0022267	0,00256842	-0,866951	0,390568
Constant	-0,0022267			

Backforecasting: yes

Estimated white noise variance = 0,00349307 with 45 degrees of freedom

Estimated white noise standard deviation = 0,0591022

Number of iterations: 7

2. VAR MODEL DOVOZU TOVAROV A SLUŽIEB**P.2.1 ADF test premennej Dovož (konštanta, lineárny trend)**

Null Hypothesis: M has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 3 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.308165	0.4214
Test critical values: 1% level	-4.165756	
5% level	-3.508508	
10% level	-3.184230	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(M)

Method: Least Squares

Date: 02/19/10 Time: 18:30

Sample (adjusted): 1998Q1 2009Q4

Included observations: 48 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
M(-1)	-0.230346	0.099796	-2.308165	0.0261
D(M(-1))	0.367052	0.155890	2.354553	0.0234
D(M(-2))	0.072489	0.165293	0.438548	0.6633
D(M(-3))	0.440605	0.191581	2.299833	0.0266
C	0.917746	0.339777	2.701023	0.0100
@TREND(1997Q1)	0.033190	0.017033	1.948605	0.0582
R-squared	0.234604	Mean dependent var		0.111095
Adjusted R-squared	0.141264	S.D. dependent var		0.397313
S.E. of regression	0.368182	Akaike info criterion		0.958267
Sum squared resid	5.557891	Schwarz criterion		1.194456
Log likelihood	-16.51928	F-statistic		2.513415
Durbin-Watson stat	1.809264	Prob(F-statistic)		0.044892

P.2.2 ADF test premennej Dovož (konštanta)

Null Hypothesis: M has a unit root

Exogenous: Constant

Lag Length: 1 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.236477	0.6513
Test critical values: 1% level	-3.571310	
5% level	-2.922449	
10% level	-2.599224	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(M)

Method: Least Squares

Date: 02/19/10 Time: 18:34

Sample (adjusted): 1997Q3 2009Q4

Included observations: 50 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
M(-1)	-0.028648	0.023169	-1.236477	0.2226
D(M(-1))	0.245924	0.140464	1.750801	0.0866
C	0.301044	0.187545	1.605185	0.1153
R-squared	0.091024	Mean dependent var		0.104500
Adjusted R-squared	0.051504	S.D. dependent var		0.390352
S.E. of regression	0.380167	Akaike info criterion		0.962859
Sum squared resid	6.648249	Schwarz criterion		1.078685
Log likelihood	-20.59005	F-statistic		2.303211
Durbin-Watson stat	1.996808	Prob(F-statistic)		0.111353

P.2.3 ADF test premennej Dovož (prvá diferencia, konštanta, lineárny trend)

Null Hypothesis: D(M) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.372560	0.0003
Test critical values: 1% level	-4.156734	
5% level	-3.504330	
10% level	-3.181826	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(M,2)

Method: Least Squares

Date: 02/19/10 Time: 18:36

Sample (adjusted): 1997Q3 2009Q4

Included observations: 50 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(M(-1))	-0.769576	0.143242	-5.372560	0.0000
C	0.162058	0.118294	1.369967	0.1773
@TREND(1997Q1)	-0.003103	0.003916	-0.792389	0.4322
R-squared	0.385566	Mean dependent var		0.004143
Adjusted R-squared	0.358852	S.D. dependent var		0.479349
S.E. of regression	0.383823	Akaike info criterion		0.981998
Sum squared resid	6.776714	Schwarz criterion		1.097824
Log likelihood	-21.05895	F-statistic		14.43285
Durbin-Watson stat	1.985919	Prob(F-statistic)		0.000014

P.2.4 ADF test premennej Konečná spotreba spolu (konštanta, lineárny trend)

Null Hypothesis: KSS has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.517050	0.8105
Test critical values:		
1% level	-4.152511	
5% level	-3.502373	
10% level	-3.180699	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(KSS)

Method: Least Squares

Date: 02/19/10 Time: 19:03

Sample (adjusted): 1997Q2 2009Q4

Included observations: 51 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
KSS(-1)	-0.074442	0.049070	-1.517050	0.1360
C	0.425781	0.251799	1.690953	0.0975
@TREND(1997Q1)	0.006047	0.003532	1.712079	0.0935

R-squared	0.068084	Mean dependent var	0.066150
Adjusted R-squared	0.028428	S.D. dependent var	0.079485
S.E. of regression	0.078347	Akaike info criterion	-2.197216
Sum squared resid	0.288497	Schwarz criterion	-2.082495
Log likelihood	57.93040	F-statistic	1.716874
Durbin-Watson stat	1.732784	Prob(F-statistic)	0.190700

P.2.5 ADF test premennej Konečná spotreba spolu (konštanta)

Null Hypothesis: KSS has a unit root

Exogenous: Constant

Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	0.695053	0.9909
Test critical values: 1% level	-3.568308	
5% level	-2.921175	
10% level	-2.598551	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(KSS)

Method: Least Squares

Date: 02/19/10 Time: 19:06

Sample (adjusted): 1997Q2 2009Q4

Included observations: 51 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
KSS(-1)	0.007561	0.010879	0.695053	0.4904
C	0.013957	0.075937	0.183804	0.8549
R-squared	0.009964	Mean dependent var	0.066150	
Adjusted R-squared	-0.010661	S.D. dependent var	0.079485	
S.E. of regression	0.079907	Akaike info criterion	-2.176717	
Sum squared resid	0.306490	Schwarz criterion	-2.100236	
Log likelihood	56.41793	F-statistic	0.483099	
Durbin-Watson stat	1.765888	Prob(F-statistic)	0.490373	

P.2.6 ADF test premennej Konečná spotreba spolu (prvá diferencia, konštanta, lineárny trend)

Null Hypothesis: D(KSS) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 3 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.742738	0.0292
Test critical values: 1% level	-4.170583	
5% level	-3.510740	
10% level	-3.185512	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(KSS,2)

Method: Least Squares

Date: 02/19/10 Time: 19:09

Sample (adjusted): 1998Q2 2009Q4

Included observations: 47 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(KSS(-1))	-0.888423	0.237372	-3.742738	0.0006
D(KSS(-1),2)	0.010433	0.231205	0.045126	0.9642
D(KSS(-2),2)	0.238855	0.208247	1.146979	0.2582
D(KSS(-3),2)	0.500692	0.148527	3.371038	0.0017
C	0.017392	0.024585	0.707412	0.4834
@TREND(1997Q1)	0.001453	0.000872	1.666095	0.1035
R-squared	0.628556	Mean dependent var	-0.004576	
Adjusted R-squared	0.582125	S.D. dependent var	0.108380	
S.E. of regression	0.070060	Akaike info criterion	-2.357815	
Sum squared resid	0.196338	Schwarz criterion	-2.119296	
Log likelihood	60.22974	F-statistic	13.53756	
Durbin-Watson stat	2.157631	Prob(F-statistic)	0.000000	

P.2.7 ADF test premennej Tvorba hrubého kapitálu (konštanta, lineárny trend)

Null Hypothesis: THK has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 3 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.821046	0.1973
Test critical values: 1% level	-4.165756	

5% level	-3.508508
10% level	-3.184230

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(THK)

Method: Least Squares

Date: 02/19/10 Time: 19:13

Sample (adjusted): 1998Q1 2009Q4

Included observations: 48 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
THK(-1)	-0.288922	0.102416	-2.821046	0.0073
D(THK(-1))	-0.156717	0.147170	-1.064867	0.2932
D(THK(-2))	0.407759	0.153842	2.650498	0.0114
D(THK(-3))	0.389441	0.150677	2.584608	0.0134
C	0.553889	0.197809	2.800122	0.0078
@TREND(1997Q1)	0.007826	0.003771	2.075371	0.0443
R-squared	0.331165	Mean dependent var	0.010236	
Adjusted R-squared	0.249600	S.D. dependent var	0.227926	
S.E. of regression	0.197442	Akaike info criterion	-0.288000	
Sum squared resid	1.598318	Schwarz criterion	-0.051811	
Log likelihood	12.76799	F-statistic	4.060126	
Durbin-Watson stat	1.843646	Prob(F-statistic)	0.004377	

P.2.8 ADF test premennej Tvorba hrubého kapitálu (konštanta)

Null Hypothesis: THK has a unit root

Exogenous: Constant

Lag Length: 3 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.884591	0.3365
Test critical values:		
1% level	-3.577723	
5% level	-2.925169	
10% level	-2.600658	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(THK)

Method: Least Squares

Date: 02/19/10 Time: 19:16

Sample (adjusted): 1998Q1 2009Q4

Included observations: 48 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
THK(-1)	-0.114313	0.060657	-1.884591	0.0664
D(THK(-1))	-0.247488	0.145948	-1.695725	0.0973
D(THK(-2))	0.353590	0.157468	2.245470	0.0301
D(THK(-3))	0.357612	0.155684	2.297033	0.0267
C	0.302892	0.162576	1.863078	0.0695
R-squared	0.260902	Mean dependent var		0.010236
Adjusted R-squared	0.190512	S.D. dependent var		0.227926
S.E. of regression	0.205068	Akaike info criterion		-0.230660
Sum squared resid	1.766225	Schwarz criterion		-0.033836
Log likelihood	10.42051	F-statistic		3.706508
Durbin-Watson stat	1.844361	Prob(F-statistic)		0.011330

P.2.9 ADF test premennej Tvorba hrubého kapitálu (prvá diferencia, konštanta, lineárny trend)

Null Hypothesis: D(THK) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 3 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.671237	0.0129
Test critical values: 1% level	-4.170583	
5% level	-3.510740	
10% level	-3.185512	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(THK,2)

Method: Least Squares

Date: 02/19/10 Time: 19:18

Sample (adjusted): 1998Q2 2009Q4

Included observations: 47 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(THK(-1))	-1.117521	0.304399	-3.671237	0.0029
D(THK(-1),2)	-0.108111	0.343065	-0.315133	0.7543
D(THK(-2),2)	0.225058	0.294814	0.763390	0.4497
D(THK(-3),2)	0.351246	0.169616	2.070828	0.0449
C	0.011534	0.071416	0.161500	0.8725
@TREND(1997Q1)	9.50E-05	0.002409	0.039434	0.9687

R-squared	0.729563	Mean dependent var	0.000624
Adjusted R-squared	0.695759	S.D. dependent var	0.375646
S.E. of regression	0.207199	Akaike info criterion	-0.189167
Sum squared resid	1.717256	Schwarz criterion	0.049352
Log likelihood	10.35084	F-statistic	21.58177
Durbin-Watson stat	1.957439	Prob(F-statistic)	0.000000

P.2.10 Odhad VAR modelu z diferencovaných premenných, 2 oneskorenia

Vector Autoregression Estimates

Date: 03/23/10 Time: 19:12

Sample (adjusted): 1997Q4 2009Q4

Included observations: 49 after adjustments

Standard errors in () & t-statistics in []

	DM	DKSS	DTHK
DM(-1)	0.196745 (0.17160) [1.14656]	0.006709 (0.03151) [0.21293]	0.115906 (0.08403) [1.37930]
DM(-2)	-0.117171 (0.17687) [-0.66245]	-0.009786 (0.03248) [-0.30134]	0.042790 (0.08662) [0.49401]
DKSS(-1)	0.502032 (0.83196) [0.60343]	0.029867 (0.15276) [0.19552]	0.926989 (0.40742) [2.27526]
DKSS(-2)	0.296301 (0.86236) [0.34359]	0.051894 (0.15834) [0.32774]	0.313273 (0.42231) [0.74181]
DTHK(-1)	0.111186 (0.33142) [0.33548]	0.174141 (0.06085) [2.86167]	-0.437735 (0.16230) [-2.69705]
DTHK(-2)	0.221567 (0.31719) [0.69852]	0.151323 (0.05824) [2.59825]	-0.000421 (0.15533) [-0.00271]
C	0.047447 (0.08994) [0.52754]	0.056361 (0.01651) [3.41292]	-0.093596 (0.04404) [-2.12503]
R-squared	0.088961	0.291557	0.349918
Adj. R-squared	-0.041188	0.190351	0.257049
Sum sq. resids	6.709211	0.226187	1.608974
S.E. equation	0.399679	0.073385	0.195727
F-statistic	0.683533	2.880824	3.767868

Log likelihood	-20.81368	62.23830	14.16949
Akaike AIC	1.135252	-2.254624	-0.292632
Schwarz SC	1.405512	-1.984364	-0.022372
Mean dependent	0.112259	0.064189	0.001680
S.D. dependent	0.391694	0.081557	0.227075
Determinant resid covariance (dof adj.)	2.72E-05		
Determinant resid covariance	1.71E-05		
Log likelihood	60.34025		
Akaike information criterion	-1.605725		
Schwarz criterion	-0.794944		

P.2.11 Priemerné sezónné korigované indexy získané metódou Census X11

Obdobie	Index
1	0,93673
2	1,01002
3	0,977539
4	1,07571

3. ECM MODEL DOVOZU TOVAROV A SLUŽIEB

P.3.1 ADF test premennej Dovož (logaritmus, konštanta, lineárny trend)

Null Hypothesis: LNM has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.805012	0.9582
Test critical values: 1% level	-4.152511	
5% level	-3.502373	
10% level	-3.180699	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LNM)

Method: Least Squares

Date: 03/17/10 Time: 13:00

Sample (adjusted): 1997Q2 2009Q4

Included observations: 51 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LNM(-1)	-0.072756	0.090379	-0.805012	0.4249
C	0.136423	0.132511	1.029522	0.3085
@TREND(1997Q1)	0.000922	0.001930	0.477598	0.6352

R-squared	0.047437	Mean dependent var	0.015276
Adjusted R-squared	0.006903	S.D. dependent var	0.046325
S.E. of regression	0.046165	Akaike info criterion	-3.255079
Sum squared resid	0.100165	Schwarz criterion	-3.140358
Log likelihood	84.37699	F-statistic	1.170288
Durbin-Watson stat	1.699960	Prob(F-statistic)	0.319154

P.3.2 ADF test premennej Dovož (logaritmus, konštanta)

Null Hypothesis: LNM has a unit root

Exogenous: Constant

Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.465265	0.5428
Test critical values: 1% level	-3.568308	
5% level	-2.921175	
10% level	-2.598551	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LNM)

Method: Least Squares

Date: 03/17/10 Time: 13:02

Sample (adjusted): 1997Q2 2009Q4

Included observations: 51 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LNM(-1)	-0.030794	0.021016	-1.465265	0.1494
C	0.076500	0.042282	1.809275	0.0767
R-squared	0.042814	Mean dependent var	0.015276	
Adjusted R-squared	0.022873	S.D. dependent var	0.046325	
S.E. of regression	0.045792	Akaike info criterion	-3.290238	
Sum squared resid	0.100651	Schwarz criterion	-3.213757	
Log likelihood	84.25595	F-statistic	2.147003	
Durbin-Watson stat	1.763943	Prob(F-statistic)	0.149369	

P.3.3 ADF test premennej Dovož (logaritmus, prvá diferenciá, konštanta, lineárny trend)

Null Hypothesis: D(LNM) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

t-Statistic Prob.*

Augmented Dickey-Fuller test statistic	-6.225911	0.0000
Test critical values:	1% level	-4.156734
	5% level	-3.504330
	10% level	-3.181826

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LNM,2)

Method: Least Squares

Date: 03/17/10 Time: 13:04

Sample (adjusted): 1997Q3 2009Q4

Included observations: 50 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(LNM(-1))	-0.909416	0.146070	-6.225911	0.0000
C	0.030517	0.014644	2.083971	0.0427
@TREND(1997Q1)	-0.000622	0.000478	-1.300904	0.1998
R-squared	0.457365	Mean dependent var		0.000504
Adjusted R-squared	0.433772	S.D. dependent var		0.061754
S.E. of regression	0.046468	Akaike info criterion		-3.240819
Sum squared resid	0.099328	Schwarz criterion		-3.124994
Log likelihood	82.40007	F-statistic		19.38576
Durbin-Watson stat	2.005951	Prob(F-statistic)		0.000001

P.3.4 ADF test premennej Domáci dopyt (logaritmus, konštanta, lineárny trend)

Null Hypothesis: LNDD has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 4 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.477362	0.3374
Test critical values:	1% level	-4.170583
	5% level	-3.510740
	10% level	-3.185512

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LNDD)

Method: Least Squares

Date: 03/18/10 Time: 14:38

Sample (adjusted): 1998Q2 2009Q4

Included observations: 47 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LNDD(-1)	-0.193636	0.078162	-2.477362	0.0177
D(LNDD(-1))	-0.011151	0.134443	-0.082945	0.9343
D(LNDD(-2))	0.538051	0.133912	4.017944	0.0003
D(LNDD(-3))	0.228107	0.155036	1.471315	0.1492
D(LNDD(-4))	-0.326736	0.156111	-2.092965	0.0429
C	0.382834	0.153450	2.494845	0.0169
@TREND(1997Q1)	0.002139	0.000836	2.559223	0.0145
R-squared	0.416067	Mean dependent var		0.007508
Adjusted R-squared	0.326231	S.D. dependent var		0.025573
S.E. of regression	0.020991	Akaike info criterion		-4.750156
Sum squared resid	0.017185	Schwarz criterion		-4.471885
Log likelihood	116.2536	F-statistic		4.631406
Durbin-Watson stat	1.991917	Prob(F-statistic)		0.001215

P.3.5 ADF test premennej Domáci dopyt (logaritmus, konštanta)

Null Hypothesis: LNDD has a unit root

Exogenous: Constant

Lag Length: 4 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.099149	0.9433
Test critical values: 1% level	-3.581152	
5% level	-2.926622	
10% level	-2.601424	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LNDD)

Method: Least Squares

Date: 03/18/10 Time: 14:44

Sample (adjusted): 1998Q2 2009Q4

Included observations: 47 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LNDD(-1)	-0.002430	0.024505	-0.099149	0.9215
D(LNDD(-1))	-0.043890	0.142815	-0.307323	0.7602
D(LNDD(-2))	0.515909	0.142601	3.617841	0.0008
D(LNDD(-3))	0.105131	0.157295	0.668369	0.5077
D(LNDD(-4))	-0.445042	0.159118	-2.796932	0.0079
C	0.012447	0.054426	0.228706	0.8203

R-squared	0.318001	Mean dependent var	0.007508
Adjusted R-squared	0.232752	S.D. dependent var	0.025573
S.E. of regression	0.022400	Akaike info criterion	-4.638394
Sum squared resid	0.020071	Schwarz criterion	-4.399876
Log likelihood	112.6831	F-statistic	3.730229
Durbin-Watson stat	1.991709	Prob(F-statistic)	0.007265

P.3.6 ADF test premennej Domáci dopyt (logaritmus, prvá diferencia, konštanta, lineárny trend)

Null Hypothesis: D(LNDD) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 3 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.501321	0.0511
Test critical values: 1% level	-4.170583	
5% level	-3.510740	
10% level	-3.185512	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LNDD,2)

Method: Least Squares

Date: 03/18/10 Time: 14:45

Sample (adjusted): 1998Q2 2009Q4

Included observations: 47 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(LNDD(-1))	-0.923727	0.263822	-3.501321	0.0012
D(LNDD(-1),2)	-0.115619	0.264196	-0.437627	0.6640
D(LNDD(-2),2)	0.392958	0.244954	1.604210	0.1165
D(LNDD(-3),2)	0.472752	0.153560	3.078621	0.0037
C	0.003098	0.007616	0.406751	0.6864
@TREND(1997Q1)	0.000160	0.000261	0.612613	0.5436
R-squared	0.695265	Mean dependent var	-0.000483	
Adjusted R-squared	0.657173	S.D. dependent var	0.038084	
S.E. of regression	0.022299	Akaike info criterion	-4.647487	
Sum squared resid	0.019889	Schwarz criterion	-4.408968	
Log likelihood	112.8922	F-statistic	18.25232	
Durbin-Watson stat	2.023793	Prob(F-statistic)	0.000000	

P.3.7 ADF test premennej Vývoz (logaritmus, konštanta, lineárny trend)

Null Hypothesis: LNX has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.975235	0.9382
Test critical values: 1% level	-4.152511	
5% level	-3.502373	
10% level	-3.180699	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LNX)

Method: Least Squares

Date: 03/18/10 Time: 14:48

Sample (adjusted): 1997Q2 2009Q4

Included observations: 51 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LNX(-1)	-0.083527	0.085648	-0.975235	0.3344
C	0.148613	0.113641	1.307737	0.1973
@TREND(1997Q1)	0.001335	0.002143	0.622977	0.5363
R-squared	0.067731	Mean dependent var		0.020485
Adjusted R-squared	0.028060	S.D. dependent var		0.046686
S.E. of regression	0.046026	Akaike info criterion		-3.261080
Sum squared resid	0.099566	Schwarz criterion		-3.146359
Log likelihood	84.52700	F-statistic		1.707308
Durbin-Watson stat	1.796580	Prob(F-statistic)		0.192408

P.3.8 ADF test premennej Vývoz (logaritmus, konštanta)

Null Hypothesis: LNX has a unit root

Exogenous: Constant

Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.750884	0.4001
Test critical values: 1% level	-3.568308	
5% level	-2.921175	
10% level	-2.598551	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LNX)

Method: Least Squares

Date: 03/18/10 Time: 14:50

Sample (adjusted): 1997Q2 2009Q4

Included observations: 51 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LNX(-1)	-0.031366	0.017914	-1.750884	0.0864
C	0.081382	0.035377	2.300432	0.0258
R-squared	0.060032	Mean dependent var		0.020485
Adjusted R-squared	0.040450	S.D. dependent var		0.046686
S.E. of regression	0.045732	Akaike info criterion		-3.292857
Sum squared resid	0.100388	Schwarz criterion		-3.216376
Log likelihood	84.32142	F-statistic		3.065595
Durbin-Watson stat	1.876620	Prob(F-statistic)		0.086355

P.3.9 ADF test premennej Vývoz (logaritmus, prvá diferencia, konštanta, lineárny trend)

Null Hypothesis: D(LNX) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.495057	0.0000
Test critical values: 1% level	-4.156734	
5% level	-3.504330	
10% level	-3.181826	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LNX,2)

Method: Least Squares

Date: 03/18/10 Time: 14:51

Sample (adjusted): 1997Q3 2009Q4

Included observations: 50 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(LNX(-1))	-0.960604	0.147898	-6.495057	0.0000
C	0.037556	0.015261	2.460948	0.0177
@TREND(1997Q1)	-0.000695	0.000488	-1.424957	0.1609
R-squared	0.478447	Mean dependent var		2.94E-06

Adjusted R-squared	0.455771	S.D. dependent var	0.063633
S.E. of regression	0.046944	Akaike info criterion	-3.220472
Sum squared resid	0.101370	Schwarz criterion	-3.104647
Log likelihood	81.90157	F-statistic	21.09906
Durbin-Watson stat	1.972100	Prob(F-statistic)	0.000000

P.3.10 ADF test premennej Podiel deflátoru dovozu a deflátoru HDP (logaritmus, konštanta, lineárny trend)

Null Hypothesis: LNDMHDP has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 3 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.167523	0.1304
Test critical values: 1% level	-4.165756	
5% level	-3.508508	
10% level	-3.184230	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LNDMHDP)

Method: Least Squares

Date: 03/17/10 Time: 14:23

Sample (adjusted): 1998Q1 2009Q4

Included observations: 48 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LNDMHDP(-1)	-0.445436	0.140626	-3.167523	0.0029
D(LNDMHDP(-1))	-0.151634	0.156838	-0.966819	0.3393
D(LNDMHDP(-2))	-0.075074	0.155927	-0.481468	0.6327
D(LNDMHDP(-3))	0.359045	0.141632	2.535053	0.0152
C	0.009876	0.010450	0.945154	0.3501
@TREND(1997Q1)	-0.001279	0.000519	-2.464793	0.0180
R-squared	0.448260	Mean dependent var	-0.004464	
Adjusted R-squared	0.380974	S.D. dependent var	0.030026	
S.E. of regression	0.023624	Akaike info criterion	-4.534353	
Sum squared resid	0.022882	Schwarz criterion	-4.298164	
Log likelihood	112.5573	F-statistic	6.662065	
Durbin-Watson stat	2.153690	Prob(F-statistic)	0.000126	

P.3.11 ADF test premennej Podiel deflátoru dovozu a deflátoru HDP (logaritmus, konštanta)

Null Hypothesis: LNDMHDP has a unit root

Exogenous: Constant

Lag Length: 2 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.483446	0.1257
Test critical values: 1% level	-3.574446	
5% level	-2.923780	
10% level	-2.599925	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LNDMHDP)

Method: Least Squares

Date: 03/17/10 Time: 14:28

Sample (adjusted): 1997Q4 2009Q4

Included observations: 49 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LNDMHDP(-1)	-0.176051	0.070890	-2.483446	0.0169
D(LNDMHDP(-1))	-0.432070	0.136028	-3.176342	0.0027
D(LNDMHDP(-2))	-0.349867	0.140041	-2.498311	0.0163
C	-0.016268	0.004893	-3.324776	0.0018
R-squared	0.315432	Mean dependent var	-0.004896	
Adjusted R-squared	0.268757	S.D. dependent var	0.029856	
S.E. of regression	0.025530	Akaike info criterion	-4.418237	
Sum squared resid	0.028679	Schwarz criterion	-4.262304	
Log likelihood	110.0377	F-statistic	6.758045	
Durbin-Watson stat	1.766280	Prob(F-statistic)	0.000756	

P.3.12 ADF test premennej Podiel deflátoru dovozu a deflátoru HDP (logaritmus, prvá diferencia, konštanta, lineárny trend)

Null Hypothesis: D(LNDMHDP) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 1 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.648515	0.0000
Test critical values: 1% level	-4.161144	
5% level	-3.506374	

10% level -3.183002

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LNDMHDP,2)

Method: Least Squares

Date: 03/17/10 Time: 14:32

Sample (adjusted): 1997Q4 2009Q4

Included observations: 49 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(LNDMHDP(-1))	-1.874497	0.245080	-7.648515	0.0000
D(LNDMHDP(-1),2)	0.367585	0.150348	2.444894	0.0186
C	-0.017675	0.008807	-2.006995	0.0509
@TREND(1997Q1)	0.000328	0.000287	1.145561	0.2582
R-squared	0.722276	Mean dependent var		0.000182
Adjusted R-squared	0.703340	S.D. dependent var		0.049321
S.E. of regression	0.026863	Akaike info criterion		-4.316448
Sum squared resid	0.031752	Schwarz criterion		-4.160515
Log likelihood	107.5948	F-statistic		38.14356
Durbin-Watson stat	1.774882	Prob(F-statistic)		0.000000

P.3.13 Kointegračná (dlhodobá) rovnica

Dependent Variable: LNM

Method: Least Squares

Date: 03/23/10 Time: 20:30

Sample: 1997Q1 2009Q4

Included observations: 52

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LNDD	0.292785	0.082681	3.541153	0.0009
LNK	0.769849	0.045687	16.85035	0.0000
LNDMHDP	-0.306794	0.093138	-3.293951	0.0006
C	-0.154341	0.115926	-1.331378	0.1894
R-squared	0.991235	Mean dependent var		1.999132
Adjusted R-squared	0.990687	S.D. dependent var		0.310133
S.E. of regression	0.029929	Akaike info criterion		-4.106196
Sum squared resid	0.042995	Schwarz criterion		-3.956100
Log likelihood	110.7611	F-statistic		1809.452
Durbin-Watson stat	0.624239	Prob(F-statistic)		0.000000

P.3.14 ADF test rezíduí kointegračnej rovnice (bez absolútneho člena a trendu)

Null Hypothesis: RESID01 has a unit root

Exogenous: None

Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.775634	0.0064
Test critical values: 1% level	-2.611094	
5% level	-1.947381	
10% level	-1.612725	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(RESID02)

Method: Least Squares

Date: 03/23/10 Time: 20:47

Sample (adjusted): 1997Q2 2009Q4

Included observations: 51 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RESID02(-1)	-0.298899	0.107687	-2.775634	0.0077
R-squared	0.131329	Mean dependent var		-0.001150
Adjusted R-squared	0.131329	S.D. dependent var		0.023139
S.E. of regression	0.021567	Akaike info criterion		-4.815936
Sum squared resid	0.023256	Schwarz criterion		-4.778057
Log likelihood	123.8064	Durbin-Watson stat		1.980442

P.3.15 Rovnica ECM dovozu tovarov a služieb do SR

Dependent Variable: DLNM

Method: Least Squares

Date: 03/23/10 Time: 21:14

Sample (adjusted): 1998Q2 2009Q4

Included observations: 47 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
DLNM(-1)	0.139571	0.048545	2.875124	0.0066
DLNDD	0.708607	0.084327	8.403126	0.0000
DLNDD(-4)	0.169365	0.090394	1.873618	0.0687
DLNX	0.771599	0.045601	16.92079	0.0000
DLNDMHDP(-2)	-0.192482	0.071214	-2.702858	0.0102
RESID01(-1)	-0.684898	0.159848	-4.284662	0.0001
UM	-0.033747	0.007940	-4.250410	0.0001

C	-0.005932	0.002647	-2.240737	0.0310
R-squared	0.923362	Mean dependent var	0.013882	
Adjusted R-squared	0.909245	S.D. dependent var	0.043119	
S.E. of regression	0.012990	Akaike info criterion	-5.692521	
Sum squared resid	0.006412	Schwarz criterion	-5.374497	
Log likelihood	138.9280	F-statistic	65.40569	
Durbin-Watson stat	2.175493	Prob(F-statistic)	0.000000	