

**Základy programovacieho jazyka
EViews a ich aplikácia na analýzy,
prognózy a rýchle odhady vývoja
makroekonomických ukazovateľov
2. časť**

**Ing. Miroslav Klůčik
Ing. Jana Juriová**

infostat[®] Inštitút informatiky
a štatistiky
DÁVAME INFORMÁCIÁM ZMYSEL

**Základy programovacieho jazyka EViews
a ich aplikácia na analýzy, prognózy a rýchle odhady
vývoja makroekonomických ukazovateľov
2. časť**

**Ing. Miroslav Klúčik
Ing. Jana Juriová**

Príručka *Základy programovacieho jazyka EViews a ich aplikácia na analýzy, prognózy a rýchle odhady vývoja makroekonomických ukazovateľov (2. časť)* vznikla ako súčasť riešenia výskumného projektu "*Modelový aparát na rýchle odhady vývoja makroekonomických ukazovateľov slovenskej ekonomiky*", ktorý INFOSTAT začal riešiť v roku 2008 s pokračovaním v rokoch 2009 a 2010 s podporou Agentúry na podporu výskumu a vývoja. Príručka je určená pre užívateľov, ktorí využívajú ekonometrické nástroje na analýzu a prognózu dát. Druhá časť príručky pomôže výskumníkovi získať základné znalosti spojené s prácou s jednoduchými ekonometrickými modelmi a ďalšími štatistickými analytickými nástrojmi, ktoré sú využiteľné pri dokumentácii vlastnej výskumnej práce.

Copyright © INFOSTAT, Inštitút informatiky a štatistiky

Obsah tohto dokumentu je chránený autorským zákonom. Nemožno ho meniť alebo z neho odstrániť informácie o správe práv k nemu. Na spracovanie, preklad, adaptáciu, zaradenie do súborného diela, vystavenie, vykonanie alebo prenos dokumentu je nutný súhlas nositeľa majetkových práv. Vyhradené je aj právo alebo prenos na udelenie súhlasu na rozmnožovanie a verejné rozširovanie rozmnožením, predajom alebo inou formou prevodu vlastníckeho práva. Bez súhlasu možno z obsahu tohto dokumentu použiť iba krátku časť vo forme citácie, len na účel jeho recenzie alebo kritiky alebo na vyučovacie účely, vedeckovýskumné účely alebo umelecké účely. Rozsah citácie nesmie presiahnuť rámec odôvodnený jej účelom. Majetkové práva vykonáva INFOSTAT, Inštitút informatiky a štatistiky Bratislava.

Práca neprešla jazykovou úpravou.

Obsah

1.	Prognózovanie z rovnice	7
1.1	Statická prognóza.....	8
1.2	Dynamická prognóza.....	14
1.3	Praktický príklad pre hodnotenie prognóz.....	19
	Program 1.1.....	21
2.	Modely s členom korigujúcim chyby	25
2.1	Testovanie ekonometrického modelu časových radov.....	25
2.1.1	Narušenia spojené s modelovaním časových radov	26
	Heteroskedasticita.....	26
	Autokorelácia	27
	Multikolinearita	29
2.1.2	Stacionarita a kointegrácia časových radov.....	30
2.2	Konštrukcia modelu s členom korigujúcim chyby.....	37
2.2.1	Testovanie časových radov na stacionaritu	38
2.2.2	Dlhodobý vzťah ECM.....	42
2.2.3	Krátkodobý vzťah ECM.....	46
2.2.4	Prognózy	50
	Program 2.1	53
3.	ARIMA modelovanie.....	60
3.1	Princípy ARIMA modelovania	60
3.2	Odhad ARIMA modelov	64
3.3	Overovanie (verifikácia) ARIMA modelov (Diagnostics)	68
3.4	Prognózovanie z ARIMA modelov.....	72
	Program 3.1.....	73
3.5	ARIMAX modely.....	74
	Program 3.2.....	74
4.	Zdroje	76
5.	Register príkazov	77
6.	Register obrázkov	78

Úvod

Príručka *Základy programovacieho jazyka EViews a ich aplikácia na analýzy, prognózy a rýchle odhady vývoja makroekonomických ukazovateľov (2. časť)* vznikla ako súčasť riešenia výskumného projektu "Modelový aparát na rýchle odhady vývoja makroekonomických ukazovateľov slovenskej ekonomiky", ktorú INFOSTAT začal riešiť v roku 2008 s pokračovaním v rokoch 2009 a 2010 s podporou Agentúry na podporu výskumu a vývoja¹.

1. časť príručky sa venovala základnej práci s pracovnými hárkami a databázami EViews-u, boli vysvetlené najdôležitejšie príkazy spojené s prácou s objektami pracovného hárku a rovnako najvyužívanejšie príkazy pre kontrolu spúšťania programov, teda popis cyklov IF..THEN..ENDIF, FOR...NEXT či WHILE..WEND. V závere prvej časti boli popísané základy regresných odhadov, teda využívanie objektu rovnice, špeciálnych funkcií v rovniciach (umelé premenné) a ďalšie vlastnosti regresných odhadov (testy).

Druhá časť príručky je pokračovaním prvej časti a je určená pre tých, ktorí majú záujem o využívanie ekonometrie pri makroekonomických analýzach v praxi.

V 1. kapitole sa pozrieme na spôsoby tvorby prognózy z jednoduchých regresných modelov, kde si predstavíme základné druhy prognóz z rovnice. 2. kapitola sa venuje ekonometrickému modelovaniu pomocou *modelov s členmi korigujúcimi chyby*, ktoré patria v súčasnosti medzi najrozšírenejšie nástroje ekonometrickej analýzy makroekonomických modelárov. Na konci 2. kapitoly je uvedený príklad z praktického využitia *modelov s členmi korigujúcimi chyby* na rýchle odhady hrubého domáceho produktu a jeho zložiek na reálnom príklade z tohto roku pre Slovenskú republiku. 3. kapitola obsahuje popis ďalšieho prístupu k modelovaniu, a to *ARIMA modelovania* časových radov, založenom na Box-Jenkinsovej metodológii, pričom je popísané aj ich využitie pri konštrukcii *ARIMAX modelov*. Aj v tomto prípade sú predstavené praktické aplikácie tohto typu modelov.

Záverečný druhý diel príručky uzatvára výučbu základných nástrojov na analýzu časových radov, ktoré ponúka EViews pre tú časť užívateľov, ktorí pracujú s makroekonomickými časovými radmi.

Výhodou tejto príručky je, že sa zaoberá skutočnými údajmi a postupmi, ktoré sa využívajú na analýzy, prognózy a rýchle odhady makroekonomických ukazovateľov slovenskej ekonomiky. Oboznámenie sa s programovacím jazykom EViews-u si však vyžaduje dlhší čas, pričom nutnou podmienkou je pravidelná praktická práca s programom a jednotlivými príkazmi. Užívatelia, ku ktorým sa dostane táto príručka či už v tlačenej alebo elektronickej forme, môžu využiť možnosť ovplyvniť autorov konštruktívnymi pripomienkami a návrhmi pre prípadné ďalšie verzie či časti príručky, za čo autori vopred vyjadrujú poďakovanie.


¹ Táto práca bola podporovaná Agentúrou na podporu výskumu a vývoja na základe zmluvy č. APVV-0032-07.

1. Prognózovanie z rovnice

Posledná kapitola v publikácii – *Základy programovacieho jazyka EViews a ich aplikácia na analýzy, prognózy a rýchle odhady vývoja makroekonomických ukazovateľov (1. časť)*², ďalej len *1. časť príručky*, bola venovaná odhadom jednoduchej regresnej rovnice metódou najmenších štvorcov. V tejto kapitole sa pomocou vzťahu vysvetľujúcich premenných a závisle premennej odhadovali parametre rovnice a chyba odhadu. V prvom kroku je potrebné špecifikovať regresný model (reprezentáciu rovnice), v ďalšom kroku odhadneme regresný model v zvolenom časovom rozpätí súboru a nakoniec môžeme výsledný regresný model diagnostikovať.

V poslednej kapitole *1. časti príručky* sme spomínali tri základné charakteristiky objektu rovnice, a to metódu odhadu, druh náhľadu na rovnice a procesy odhadu rovnice (obr. 1.1). Kým v danej kapitole sme si vysvetľovali podrobne predovšetkým druh náhľadu na rovnice, táto časť sa bude zaoberať poslednou základnou charakteristikou rovníc a to procesmi odhadu rovníc – konkrétne prognózami. Po špecifikácii závisle a nezávisle premenných regresnej rovnice, po výbere metódy na odhad parametrov rovnice, po odhadoch správneho tvaru rovnice a po overení a testovaní náležitostí rovnice môžeme finálnu regresnú rovnicu využiť na prognózovanie závisle premennej do budúcnosti.

Obr. 1.1 Objekt rovnice a jeho syntax



Po stanovení konečného tvaru rovnice je možné použiť jeden z dvoch hlavných typov prognóz, a to **statickú prognózu** alebo **dynamickú prognózu**. Pomocou statickej prognózy vypočítame tzv. vyrovnané hodnoty – fitted values, v prípade dynamickej prognózy hovoríme

² Miroslav Kľúčik, *Základy programovacieho jazyka EViews a ich aplikácia na analýzy, prognózy a rýchle odhady vývoja makroekonomických ukazovateľov (1. časť)*, 2010, http://www.infostat.sk/new_web/sk/pdf/APVV_2Eb.pdf

o prognózovaných hodnotách – forecasted values. Aby bol výpočet prognózy možný, musia byť pozorovania vysvetľujúcich premenných na obdobie prognózy vopred známe. V prípade, že to tak nie je, budú namiesto prognózovaných pozorovaní vložené do pozorovaní NA (not available) hodnoty. Obdobie prognózy nemusí byť stanovené len na neznáme pozorovania závisle premennej do budúcnosti (na koniec časového radu), ale môže byť stanovené aj na už známu minulosť, čo umožní porovnávať prognostickú silu regresného vzťahu na reálnych hodnotách. V tomto prípade sa prepíšu reálne hodnoty závisle premennej na prognózované podľa stanoveného obdobia prognózy (Forecast sample). Pri prognóze je vytvorený nový časový rad – prognózovaný časový rad, ktorý bude obsahovať hodnoty prognózované alebo vyrovnané (fitted) podľa stanoveného obdobia prognózy. Pri konštrukcii prognózy je v možnostiach prognózy (*Options*) k dispozícii i voľba medzi vložením NA hodnôt alebo prognózovaných hodnôt do pozorovaní mimo obdobia prognózy (obr. 1.2).

1.1 Statická prognóza

Pri statickej prognóze najprv overíme, či sú k dispozícii všetky hodnoty vysvetľujúcich premenných (časovo neposunutých) na pravej strane rovnice na celé obdobie prognózy a následne sa môže vyrátať prognóza na základe pôvodne odhadnutých parametrov rovnice. Statická prognóza teda dokáže vypočítať prognózované hodnoty iba na toľko krokov dopredu, koľko je známych hodnôt vysvetľujúcich premenných na pravej strane prognózovanej rovnice.

Časové rozpätie statickej prognózy


Ako východiskové je nastavené celé časové rozpätie aktuálneho súboru. Rozhodujúce pre prognózu je práve nastavenie tohto časového rozpätia. V prípade, že nastavíme Sample na východiskovú hodnotu, t.j. na celý rozsah súboru, všetky údaje okrem prvého pozorovania prognózovaného obdobia sa zmenia, t.j. vymenia sa skutočné hodnoty za prognózované. Ak nastavíme rozsah prognózy iba od konca odhadnutého obdobia, prognóza bude vytvorená iba na toto obdobie. Hodnoty vysvetľovaného časového radu pre obdobie pred prognózovaným obdobím sa dosadia podľa toho, či zvolíme „Insert actuals out-of-sample observations“ z menu objektu rovnice alebo nie (pozri obr. 1.2). V prípade kladnej odpovede EViews zaplní obdobie pred prognózou skutočnými hodnotami, v prípade negatívnej odpovede ostanú tieto pozorovania prázdne, teda NA. Túto voľbu je samozrejme možné realizovať i prostredníctvom programu v programovacom jazyku, ako bude možné vidieť nižšie.

Statickú prognózu vykonáme pomocou príkazu FIT, ktorého všeobecný syntax je nasledovný:

```
názov_rovnice.fit(možnosti) názov_prognózov_čas_radu názov_č_radu_rezíduí
```

Za špecifikáciou príkazu sa môžu uviesť podľa tohto syntaxu názvy časových radov pre prognózovaný časový rad alebo pre rezíduá (t.j. štandardnú chybu odhadu). Medzi možnosťami v zátvorke je pre nás najdôležitejšia možnosť `f=actual` a `f=na`. Daná možnosť je zhodná s označením možnosti „Insert actuals for out-of-sample observations“ na obr. 1.2.

Obr. 1.2 Dialógové okno pre prognózu rovnice 1



Možnosť `f=actual` je východiskovou, takže v prípade, že v zátvorke neuvedieme nič, program vykoná túto možnosť. V prípade, ak chceme, aby program dosadil namiesto pozorovaní mimo prognózovaného obdobia prázdne NA pozorovania, napíšeme do zátvorky možnosť `f=na`. Medzi ďalšími možnosťami je napríklad možnosť `'g'`, ktorá zobrazí na grafe prognózy i pásmo štandardnej chyby prognózy. Možnosť `'e'` zasa vytvorí tabuľku hodnotenia prognózy. Takúto tabuľku uvidíme neskôr na obr. 1.4 v dolnej časti obrázku.

Statické prognózy môžu byť teda dvojakého druhu, a to v závislosti od dosadenia hodnôt v období pred prognózovaným obdobím. Záleží na tom, či sa hodnoty tohto obdobia zmenia ako prognózované alebo sa dosadia namiesto týchto pozorovaní skutočné hodnoty. Pri skutočných prognózach v praxi to môže predstavovať rozdiel, napr. ak chceme interpretovať prognózu ako medziročný rast určitého indexu, je rozdiel, či prognózovanú hodnotu vydělíme medziročnou hodnotou pôvodnou (skutočnou) alebo prognózovanou zo statickej prognózy na celé obdobie. V nasledujúcom príklade porovnávame všetky spomenuté spôsoby:


```
smpl 1993q1 2009q4
genr sd1=0
genr sd2=0
genr sd3=0
genr sd4=0
smpl 1993q1 1993q1
genr sd1=1
smpl 1993q2 1993q2
genr sd2=1
smpl 1993q3 1993q3
```

```

genr sd3=1
smpl 1993q4 1993q4
genr sd4=1
smpl 1994q1 2009q4
genr sd1=sd1(-4)
genr sd2=sd2(-4)
genr sd3=sd3(-4)
genr sd4=sd4(-4)
smpl @all
coef(10) pc00
equation zz_pc1.ls log(pc) = pc00(1) + pc00(2) * log(cpi2000) + pc00(3) * log(wret_0)
+pc00(4) * sd2 + pc00(5) * sd3 + pc00(6) * sd4
zz_pc1.makesresid residpc1
smpl 2009q4 2009q4                                ‘ prvý typ prognózy
zz_pc1.fit(f=na) z_pc1staticna
zz_pc1.fit(f=actual) z_pc1staticact                  ‘ druhý typ prognózy
smpl 2000q1 2009q4                                ‘ tretí typ prognózy
zz_pc1.fit z_pc1staticfull
    
```

Predpokladáme, že máme otvorený súbor so všetkými potrebnými časovými radmi so štvrt'ročnou periodicitou. Prvá časť programu predstavuje vytvorenie štyroch sezónnych umelých premenných, ktoré sme si už vysvetlili v *1. časti príručky*. Potom si vytvoríme v našom súbore objekt vektor koeficientov s označením **PC00** a s názvom PC00, ktorý budeme potrebovať na uloženie odhadnutých parametrov rovnice. Pre nás bude postačovať 10 riadkov, teda maximálne 10 parametrov rovnice. Ideme odhadnúť regresnú rovnicu pre deflátor konečnej spotreby domácností (PC), teda vlastne podiel spotreby domácností v bežných a stálych cenách. Spotreba domácností je jedna zo zložiek HDP. Rovnicu si nazveme ZZ_PC1 (znaky „z“ na začiatku nám zabezpečia uloženie rovnice na koniec súboru, čo je praktické pri hľadaní objektu odhadnutej rovnice neskôr). Nesmieme zabudnúť, že rovnica by sa mala odhadovať pri plnom rozsahu súboru (celé časové rozpätie pracovného hárku). V rovnici je závislou premennou deflátor PC s nasledujúcimi vysvetľujúcimi premennými: index spotrebiteľských cien (CPI2000), mzdy v maloobchode (WRET_0) a tri umelé sezónne premenné pre 2. až 4. štvrt'rok (SD2, SD3, SD4). Premenné v rovnici okrem sezónnych premenných sú logaritmované. Uvedená rovnica je jednoduchou regresnou rovnicou a v praxi by sa nemala využívať bez toho, že by sa neotestovali podmienky stacionarity premenných. K riešeniu tohto problému sa dostaneme v 2. kapitole. Zatiaľ nám tento jednoduchý výpočtový postup postačuje na vysvetlenie procesu tvorby prognózy v EViews-e pomocou programovacieho jazyka. V nasledujúcom riadku si vytvoríme časový rad rezíduí rovnice pomocou príkazu MAKERESID a časový rad si nazveme RESIDPC1. Na obr. 1.3 nižšie je zobrazený výstup odhadnutej rovnice v tabuľkovej i grafickej forme (rezíduá).

Obr. 1.3 Odhadnutá jednoduchá regresná rovnica deflátora konečnej spotreby domácností



V príklade chceme ukázať výsledky všetkých troch možných typov prognóz pomocou statickej prognózy. Jednotlivé typy prognóz sú naznačené v príkazoch aj komentármi napravo. Pre každý typ prognózy je dôležitý stanovený Sample. Prvým prípadom bude prognóza, pri ktorej odhadujeme iba posledný štvrt'rok, t.j. štvrt'rok, ktorý je neznámy. V tomto prípade ide o 4. štvrt'rok roku 2009. K dispozícii však musíme mať všetky údaje na pravej strane rovnice, aby dokázal program vyrátať statickú prognózu. Prvým prípadom bude prognóza, keď dosadíme za hodnoty mimo prognózovaného obdobia NA hodnoty. Rovnica je odhadnutá na skutočných údajoch od začiatku roka 2000 po 3. štvrt'rok 2009. Prognózovaný je teda len 4. štvrt'rok 2009. Ostatné pozorovania by mali ostať prázdne. Prognózovaný časový rad si nazveme Z_PC1STATICNA. Výsledok môžeme vidieť na obr. 1.4 a obr. 1.5 nižšie. V druhom prípade tvoríme prognózu rovnako – iba na posledný štvrt'rok 2009, avšak za hodnoty mimo tohto obdobia dosadzujeme *actual* – teda skutočné hodnoty časového radu (deflátor konečnej spotreby domácností). V tomto prípade stanovený Sample nemusíme meniť, ale do možností príkazu FIT musíme uviesť $f=actual$ (nemusíme písať vôbec, ak nechceme, lebo daná možnosť je prednastavená). Prognózovaný časový rad si nazveme Z_PC1STATICACT. V poslednom treťom prípade prognózované obdobie a obdobie, za ktoré bola odhadnutá rovnica, majú prienik. Prognóza sa začne tvoriť v 1. štvrt'roku 2000 a skončí až v poslednom štvrt'roku 2009. Odhadnutá rovnica tento posledný štvrt'rok ešte nezahŕňa, lebo nemala údaj za deflátor konečnej spotreby domácností. Všetky tri grafické výstupy môžeme vidieť na obr. 1.4 nižšie. Ako vidieť z obr. 1.4 pri statickej prognóze na posledný štvrt'rok roka 2009 je vytvorený iba graf prognózy, na rozdiel od prognózy na celý rozsah súboru, kde je vytvorená aj tabuľka s hodnotením prognózy. Hodnoty, resp. pozorovania sa medzi prognózovaným časovým radom a pôvodným časovým radom PC deflátoru budú odlišovať. Toto môžeme vidieť na obr. 1.5, kde sú zobrazené hodnoty jednotlivých prognózovaných časových radov a časového radu PC na začiatku a na konci rozsahu súboru. Z tabuľky na obrázku môžeme vidieť, že pre prvý typ prognózy obsahuje prognózovaný časový rad iba jednu hodnotu, a to v prognózovanom období posledného štvrt'roku 2009 (smpl 2009q4 2009q4). V druhom prípade sa zhodujú hodnoty pred prognózovaným obdobím so skutočnými hodnotami časového radu deflátor konečnej spotreby

domácností v štvrtom stĺpci tabuľky (PC). Tretím typom je statická prognóza na celé obdobie pracovného hárku, teda na celé obdobie časového radu deflátoru PC. Ako vidíme hodnoty sa oproti skutočným líšia v celom období. Teda statická prognóza prepočíta hodnoty od prvého pozorovania až po posledné skutočné obdobie. Všimnime si zároveň, že posledná prognózovaná hodnota na 4. štvrťrok 2009 je rovnaká pre všetky tri typy prognózy. Z tohto hľadiska je jedno aký *sample* používame, avšak problém môže nastať pri interpretácii (ako už bolo spomenuté vyššie). V prípade interpretácie prognózy ako medziročného rastu deflátoru konečnej spotreby domácností (PC/PC(-4)) sa bude prognóza líšiť. Pri prvom type prognózy ju dokonca nebudeme môcť vypočítať, lebo nebudeme poznať menovateľ (NA). V ďalších typoch budú prognózy nasledovné:


```
series prognozaACT = z_pc1staticact/z_pc1staticact(-4)
series prognozaFULL = z_pc1staticfull/z_pc1staticfull(-4)
```

Pre posledný štvrťrok 2009:

```
prognozaACT = 1.4468188/1.4345032 = 1.0086
prognozaFULL = 1.4468188/1.4402971 = 1.0045
```

Ako vidíme, výsledky by sa líšili. V prvom prípade by išlo o prognózovaný rast deflátoru konečnej spotreby o 0.86% a v druhom prípade o rast o 0.45%.

Obr. 1.4 Tri typy statickej prognózy časového radu – grafický výstup



Obr. 1.5 Tri typy statickej prognózy časového radu – tabuľkový výstup

Group: UNTITLED Workfile: UNTITLED					
View	Proc	Object	Print	Name	Freeze
Default	Sort	Transpose	Edit+/-	Smpl+/-	InsDel
Title	Sam				
obs	Z_PC1STATICNA	Z_PC1STATICACT	Z_PC1STATICFULL	PC	
1999Q3	NA	NA	NA	NA	
1999Q4	NA	NA	NA	NA	
2000Q1	NA	1.0010984713	0.9977933330	1.0010984713	
2000Q2	NA	0.9937821383	1.0016672402	0.9937821383	
2000Q3	NA	1.0027478992	1.0000245932	1.0027478992	
2000Q4	NA	1.0023419033	1.0010283287	1.0023419033	
2001Q1	NA	1.0023419033	1.0010283287	1.0023419033	
2001Q2	NA	1.0023419033	1.0010283287	1.0023419033	
2001Q3	NA	1.0023419033	1.0010283287	1.0023419033	
2001Q4	NA	1.0023419033	1.0010283287	1.0023419033	
2002Q1	NA	1.0023419033	1.0010283287	1.0023419033	
2002Q2	NA	1.0023419033	1.0010283287	1.0023419033	
2002Q3	NA	1.0023419033	1.0010283287	1.0023419033	
2002Q4	NA	1.0023419033	1.0010283287	1.0023419033	
2003Q1	NA	1.0023419033	1.0010283287	1.0023419033	
2003Q2	NA	1.0023419033	1.0010283287	1.0023419033	
2003Q3	NA	1.0023419033	1.0010283287	1.0023419033	
2003Q4	NA	1.0023419033	1.0010283287	1.0023419033	
2004Q1	NA	1.0023419033	1.0010283287	1.0023419033	
2004Q2	NA	1.0023419033	1.0010283287	1.0023419033	
2004Q3	NA	1.0023419033	1.0010283287	1.0023419033	
2004Q4	NA	1.0023419033	1.0010283287	1.0023419033	
2005Q1	NA	1.0023419033	1.0010283287	1.0023419033	
2005Q2	NA	1.0023419033	1.0010283287	1.0023419033	
2005Q3	NA	1.0023419033	1.0010283287	1.0023419033	
2005Q4	NA	1.0023419033	1.0010283287	1.0023419033	
2006Q1	NA	1.0023419033	1.0010283287	1.0023419033	
2006Q2	NA	1.0023419033	1.0010283287	1.0023419033	
2006Q3	NA	1.0023419033	1.0010283287	1.0023419033	
2006Q4	NA	1.0023419033	1.0010283287	1.0023419033	
2007Q1	NA	1.0023419033	1.0010283287	1.0023419033	
2007Q2	NA	1.0023419033	1.0010283287	1.0023419033	
2007Q3	NA	1.0023419033	1.0010283287	1.0023419033	
2007Q4	NA	1.0023419033	1.0010283287	1.0023419033	
2008Q1	NA	1.0023419033	1.0010283287	1.0023419033	
2008Q2	NA	1.0023419033	1.0010283287	1.0023419033	
2008Q3	NA	1.4414203721	1.4362399684	1.4414203721	
2008Q4	NA	1.4345032155	1.4402971535	1.4345032155	
2009Q1	NA	1.4699685799	1.4665884717	1.4699685799	
2009Q2	NA	1.4501714805	1.4566105804	1.4501714805	
2009Q3	NA	1.4403463396	1.4552430260	1.4403463396	
2009Q4	1.4468188365	1.4468188365	1.4468188365	NA	

1.2 Dynamická prognóza

Pri **dynamickej prognóze**, na rozdiel od statického prognózovania, odhadnutá rovnica obsahuje dynamickú špecifikáciu, ktorou je časovo posunutá závisle premenná. Teda prognózované hodnoty sú vytvárané prostredníctvom časovo posunutej závisle premennej (napr. v čase $t-1$). Možnosť výpočtu dynamickej prognózy je k dispozícii iba vtedy, ak odhadnutá rovnica obsahuje túto časovo posunutú premennú, prípadne ak rovnica obsahuje diferencovanú závisle premennú (napr. medzikvartálna diferencia $dy = y/y(-1)$).

Dynamická prognóza nie je jednokroková ale multikroková. Pri dynamickej prognóze je veľmi dôležitý začiatok obdobia prognózy. Od toho závisí, ktoré hodnoty začne EViews využívať pre danú prognózu. Preto je dôležité, ktorá je prvá hodnota, ktorá vstupuje do prognózy. Pri dynamickej prognóze využívame príkaz FORECAST, ktorého všeobecný popis je nasledovný:

názov_rovnice.forecast(možnosti) názov_prognózov_čas_radu názov_č_radu_rezíduí

Rovnako ako pri statickej prognóze za príkazom a jeho možnosťami (*Options*) je možné uviesť názov prognózovaného časového radu i názov časového radu, ktorý bude obsahovať štandardnú chybu odhadu. Možnosti príkazu FORECAST sú rovnaké ako pri príkaze FIT pre statickú prognózu, t.j. možnosť ,g' je pre vytvorenie grafu prognózy aj s 2-percentnou štandardnou chybou odhadu a možnosť ,e' pre vytvorenie tabuľky s hodnotením prognózy. Ďalej sú rovnaké i možnosti týkajúce sa dosadenia hodnôt mimo prognózovaného obdobia, t.j. využitie možnosti **f=actual**, prípadne **f=na**.

Rovnicu, ktorú sme použili pre statickú prognózu nemôžeme použiť, lebo na pravej strane rovnice sa nenachádza časovo posunutá vysvetľujúca premenná. Vidíme to aj z obr. 1.2, kde nebola v dialógovom okne k dispozícii voľba pre dynamickú prognózu (*no dynamics in equation*). Preto si musíme vytvoriť novú rovnicu. Pri dynamickej prognóze je dôležitý začiatok prognózovaného obdobia, preto v nasledujúcom príklade uvedieme viacero možností prognózy. Prípad **f=na** nevyužijeme, lebo sme si ho už dostatočne vysvetlili pri statickej prognóze.

```

smpl @all
coef(10) pc00b
equation zz_pc2.ls log(pc) = pc00b(1) + pc00b(2) * log(pc(-1)) + pc00b(3) * sd3 +
pc00b(4) * sd4
zz_pc2.makesid residpc2
smpl 2009q4 2009q4                                ‘ prvá prognóza – iba posledný štvrťrok
zz_pc2.forecast(f=actual) z_pc2dyn1
smpl 2005q1 2009q4                                ‘ druhá prognóza – druhá polovica sample
zz_pc2.forecast(f=actual) z_pc2dyn2
smpl 2000q1 2009q4                                ‘ tretia prognóza – celý sample
zz_pc2.forecast z_pc2dynfull
smpl 2009q4 2009q4                                ‘ statická prognóza – iba posledný štvrťrok
zz_pc2.fit z_pc2staticact
smpl 2000q1 2009q4                                ‘ statická prognóza – celý sample
zz_pc2.fit z_pc2staticfull
smpl @all
group progcrad z_pc2dyn1 z_pc2dyn2 z_pc2dynfull Z_PC2STATICACT
Z_PC2STATICFULL
series dynprognosa1 = z_pc2dyn1/z_pc2dyn1(-4)
series dynprognosa2 = z_pc2dyn2/z_pc2dyn2(-4)
series dynprognosa3 = z_pc2dynfull/z_pc2dynfull(-4)
group prognozy dynprognosa1 dynprognosa2 dynprognosa3 prognozaACT
prognozaFULL


```

V príklade sme si najprv (predpokladáme, že sezónne premenné už máme vytvorené) vytvorili objekt vektoru koeficientov PC00B pre odhadnuté parametre novej rovnice ZZ_PC2 v ďalšom príklade. V tomto prípade je závisle premenná PC (deflátor konečnej spotreby domácností) vysvetľovaná tou istou premennou, avšak posunutou o jeden štvrťrok dozadu (lagged z angl.) – PC(-1). Ďalej boli v jednoduchnej regresnej rovnici významné i dve umelé sezónne premenné pre 3. a 4. štvrťrok (SD3 a SD4). Tento prístup nie je zatiaľ otestovaný vzhľadom na to, že uvedená premenná (deflátor konečnej spotreby) je nestacionárnou veličinou. K problémom stacionarity sa však dostaneme v 2. kapitole, pričom pre účely vysvetlenia príkazu prognóz je použitie jednoduchnej regresnej rovnice v tejto kapitole postačujúce. Z odhadnutej rovnice extrahujeme i rezíduá a nazveme ich RESIDPC2. Prvý typ dynamickej prognózy aplikujeme iba na posledný štvrťrok 2009. To znamená, že odhadnutú rovnicu máme od 2000Q2 (vzhľadom na posunutú premennú sa posunul začiatok *sample* na 2. štvrťrok) do 2009Q3. Nastavíme *sample* na posledný štvrťrok 2009 a pomocou príkazu FORECAST spravíme dynamickú prognózu, pričom nesmieme zabudnúť, aby nám uložil program do obdobia pred posledným štvrťrokom skutočné údaje (*f=actual*). Rovnako postupujeme i v druhom prípade, pričom zmeníme iba časové rozpätie na polovicu celého rozpätia. V poslednom prípade aplikujeme prognózu na celý *sample*, v zátvorke možnosť *f=actual* nemusíme uvádzať (rovnako ani v predošlých prípadoch, lebo daná voľba je prednastavená v prípadoch neuvedenia žiadnych možností). Aby sme mohli výsledky prognóz porovnať i so statickými prognózami, použijeme statickú simuláciu na posledný štvrťrok a následne i na celý *sample* odhadu. Keď máme vytvorené všetky tri prognózované časové rady z dynamickej prognózy, dáme ich do spoločnej skupiny časových radov PROGRAD aj s vypočítanými statickými prognózami (Z_PC2STATICACT, Z_PC2STATICFULL). Potom vyrátame medziročné rasty prognózovaného deflátoru konečnej spotreby domácností z regresných odhadov. Všetky tri prognózy dáme do spoločnej skupiny s názvom PROGNOZY a pridáme i vypočítané prognózy statickej prognózy

PROGNOZAACT (statická prognóza iba pre posledný štvrt'rok so skutočnými údajmi predchádzajúcich pozorovaní) a PROGNOZAFULL (statická prognóza na celé obdobie 2000Q1 až 2009Q4).

Ak by sme robili dynamickú prognózu uvedenej rovnice ručne pomocou Menu, v okne pre prognózu sa v tomto prípade už objaví voľba možnosti dynamickej prognózy (obr. 1.6 na rozdiel od obr. 1.2), a to z dôvodu, že špecifikácia rovnice v našom prípade už obsahuje časovo posunutú závisle premennú. V tejto súvislosti treba spomenúť fakt, že kým dynamickú prognózu možno vykonať iba pri splnení vyššie spomenutých podmienok, statickú prognózu možno vykonať v oboch prípadoch, teda aj pri časovo posunutých alebo diferencovaných vysvetľovaných závisle premenných na ľavej strane rovnice. Ak spravíme dynamickú prognózu v prvom prípade (prognóza na jeden štvrt'rok), EViews nám vytvorí iba stĺpcový graf, ako to bolo v prvých dvoch typoch statickej prognózy (obr. 1.4), a v ďalších dvoch prípadoch dynamickej prognózy i hodnotenie daných prognóz ako v poslednom prípade statickej prognózy na spomenutom obrázku. V prípade polovičného *sample* bude graf naľavo obsahovať iba prognózu s hranicami štandardnej chyby prognózy od roku 2005 (95% interval spoľahlivosti prognózy), kým v poslednom prípade bude graf obsahovať štandardnú chybu počas celého *sample*.

Obr. 1.6 Dialógové okno pre prognózu rovnice 2



Ak si otvoríme skupinu PROGCRAD s piatimi prognózovanými časovými radmi pomocou dynamickej a statickej prognózy (obr. 1.7), uvidíme, že prognózy všetkých troch dynamických simulácií sú pre posledný štvrt'rok odlišné. Zároveň vidíme, že sa líšia i prognózy od roku 2005 a prognóza na celý *sample* odhadu (hneď od 1. štvrt'roka 2005). Vyplýva z toho, čo sme spomenuli už skôr, že dynamická prognóza je multikrokovou prognózou a závisí od začiatku prognózovacieho obdobia, t.j. od obdobia, od ktorého sa začína prognóza rátať a odlišovať sa začne už od prvého kroku výpočtu. Dynamická prognóza na celé obdobie odhadu sa teda líši od

prvých dynamických simulácií. Ak porovnáme dynamické prognózy so statickými, zistíme, že dynamická prognóza na posledný štvrt'rok 2009 sa rovná prognózam statickým (prvý, štvrtý a piaty stĺpec z obr. 1.7). Z uvedeného vyplýva, že vzorec pre výpočet dynamickej a statickej prognózy na jeden štvrt'rok je rovnaký. Takisto i prvá hodnota pre statickú a dynamickú prognózu by sa mala rovnať, čo sa potvrdzuje, ako môžeme vidieť porovnaním hodnoty z 2. štvrt'roka 2000 tretieho stĺpca (dynamická prognóza na celý sample) a posledného stĺpca (statická prognóza na celý sample). To, že sa prvý krok dynamickej a statickej prognózy zhoduje potvrdzuje i Help v EViews-e, kde je postup výpočtu opísaný podrobnejšie.

Obr. 1.7 Porovnanie dynamickej a statickej prognózy – tabuľkový výstup

Group: PROGRAD Workfile: FE_FEB10::Untitled\						
View	Proc	Object	Print	Name	Freeze	Default
Sort	Transpose	Edit+/-	Smpl+/-	InsDel	Title	Sample
obs	Z_PC2DYN1	Z_PC2DYN2	Z_PC2DYNFULL	Z_PC1STATICACT	Z_PC1STATICFULL	
2000Q1	1.0010984713	1.0010984713	NA	1.0010984713	NA	
2000Q2	0.9937821383	0.9937821383	1.0255735230	0.9937821383	1.0255735230	
2000Q3	1.0027478992	1.0027478992	1.0313673794	1.0027478992	1.0002375124	
2000Q4	1.0073419033	1.0073419033	1.0355109105	1.0073419033	1.0076309586	
2004Q3	1.2413620109	1.2413620109	1.2414583055	1.2413620109	1.2490916411	
2004Q4	1.2294058579	1.2294058579	1.2404070030	1.2294058579	1.2403133602	
2005Q1	1.2783129210	1.2525691223	1.2634767938	1.2783129210	1.2525691223	
2005Q2	1.2734665748	1.2755325684	1.2863422032	1.2734665748	1.3010409882	
2009Q1	1.4699685799	1.4079281011	1.4158655316	1.4699685799	1.4555187257	
2009Q2	1.4501714805	1.4292681364	1.4371100134	1.4501714805	1.4905308080	
2009Q3	1.4403463396	1.4246534861	1.4322606589	1.4403463396	1.4449287430	
2009Q4	1.4334246877	1.4182222650	1.4255922552	1.4334246877	1.4334246877	


Hlavný rozdiel medzi statickou a dynamickou prognózou je teda ten, že statická je jednokroková (do odhadnutej rovnice sa dosadia aktuálne hodnoty a vypočíta sa prognóza), a dynamická prognóza je multikroková, to znamená, že výpočet sa začína od prvého pozorovania a prepočítava sa pre každé ďalšie pozorovanie (teda rozhodujúci je začiatok obdobia prognózy). Statická a dynamická prognóza by mali byť identické v prvom prognózovanom pozorovaní. V ďalších pozorovaniach sa budú líšiť vtedy, ak obsahujú časovo posunutú závisle premennú (čo je náš prípad) alebo ARMA špecifikácie (t.j. napríklad pri rovniciach s diferencovanými vysvetľovanými premennými).

Na ďalšom obrázku môžeme vidieť grafické porovnanie všetkých piatich prognózovaných časových radov (obr. 1.8). Dynamická prognóza na celý *sample* (Z_PC2DYNFULL) a statická prognóza na celý *sample* (Z_PC2STATICFULL) sa líšia viditeľne od čiernej krivky skutočných hodnôt deflátor konečnej spotreby domácností PC (teda *actual* hodnoty prognózovaných časových radov Z_PC2DYN1 a Z_PC2STATICACT, ktoré sa v grafe na obrázku prekrývajú).

Rozdiely medzi jednotlivými prognózami vypočítané ako medziročné rasty deflátoru PC sú tiež výraznejšie, ako je vidieť z tabuľkového výstupu skupiny PROGNOZY (obr. 1.9), ktorý sme si vytvorili vyššie v programe z medziročných rastov všetkých piatich prognózovaných časových radov. Podľa dynamickej prognózy na celý *sample* by mal deflátor PC vzrásť v poslednom štvrt'roku 2009 medziročne o 2.3%, podľa dynamickej prognózy na polovicu *sample* je to o trochu menej (2.2%). Statické simulácie však prognózujú pokles deflátoru o 0.07%

podľa simulácie na celom *sample* odhadu resp. 0,08% podľa statickej prognózy iba na posledný štvrt'rok (resp. dynamickej na posledný štvrt'rok). Zvyčajne sa v praxi využíva pri interpretácii dvoch prognóz ich interval, t.j. prognóza v intervale -0.08% až +2.3%, čo je v priemere rast deflátoru PC o 1.1%. V praxi sa využívajú často len prognózy na celý *sample*, t.j. prognózovaná hodnota z posledného štvrt'roka 2009 by sa mala porovnávať medziročne so simulovanou hodnotou. Takže z našich piatich typov prognóz by sme mali využívať iba tretiu a piatu možnosť (podľa stĺpcov), t.j. *full sample* pre statickú a dynamicкую prognózu a výsledky prognóz potom spriemerovať $[(2.2\% + (-0.07\%))/2 = 1.1\%]$.

Obr. 1.8 Porovnanie dynamickej a statickej prognózy – grafický výstup



Obr. 1.9 Porovnanie medziročných rastov dynamickej a statickej prognózy

Group: PROGNOZY Workfile: FE_FEB10::Untitled\													
View	Proc	Object	Print	Name	Freeze	Default	Sort	Transpose	Edit+/-	Smpl+/-	InsDel	Title	Sample
obs		DYNPROGNOZA1		DYNPROGNOZA2		DYNPROGNOZA3		PROGNOZAAC		PROGNOZAFUL			
2007Q3		1.0190505307		1.0294425074		1.0286639082		1.0190505307		1.0187336985			
2007Q4		1.0388980579		1.0286447571		1.0278875388		1.0388980579		1.0185368850			
2008Q1		1.0434815372		1.0278689134		1.0271324736		1.0434815372		1.0378394349			
2008Q2		1.0511040996		1.0271143591		1.0263981136		1.0511040996		1.0422956530			
2008Q3		1.0488743881		1.0263804957		1.0256838771		1.0488743881		1.0497054169			
2008Q4		1.0385081293		1.0256667418		1.0249891995		1.0385081293		1.0475381011			
2009Q1		1.0320855006		1.0249725333		1.0243135329		1.0320855006		1.0374603085			
2009Q2		1.0086381782		1.0242973226		1.0236563453		1.0086381782		1.0312150581			
2009Q3		0.9992548791		1.0236405781		1.0230171201		0.9992548791		1.0084064317			
2009Q4		0.9992481524		1.0230017838		1.0223953558		0.9992481524		0.9992747787			

1.3 Praktický príklad pre hodnotenie prognóz

V praxi sa pri rýchlych odhadoch HDP a jeho častí každý štvrt'rok opakuje proces popísaný v predošlej podkapitole pre všetky odhadnuté rovnice a prognózy. Pre účely lepšieho prehľadu by však bol vhodný automatizovaný postup pre odhad rovnice, prognózu rovnice a následné porovnanie prognóz s realitou, resp. porovnanie dynamických a statických prognóz navzájom. Toto porovnanie môže slúžiť ako základ pre výber najlepšieho typu prognózy. Predstavíme si preto komplexný príklad (na konci tohto textu – Program 1.1), ktorý bude využívať i cyklické príkazy vysvetlené v 1. časti príručky.

Program pre porovnanie prognóz sa začne vytvorením pracovného súboru, vložením potrebných časových radov do súboru, špecifikáciou a odhadom rovníc (zatiaľ len jednoduchých regresných rovníc), tvorbou prognózy a v poslednom kroku porovnaním prognóz dynamických a statických so skutočnosťou.

V prvom riadku je stanovený východiskový adresár pomocou príkazu CD, ďalej vytvoríme pracovný súbor s názvom PROGPNOROVN so štvrt'ročnou periodicitou. Do pracovného súboru vložíme vyše 300 štvrt'ročných časových radov z Excel-u pomocou príkazu READ. Ďalšia sekcia programu obsahuje príkazy na vytvorenie sezónnych premenných a trendovej premennej, ktoré môžeme neskôr využiť pri odhade rovníc. Podrobenejšie sme tieto premenné popísali v 1. časti príručky.

Vytvoríme objekt koeficientov s názvom PEG00, aby sa nám parametre odhadnutej rovnice ukladali priamo do tohto objektu. V ďalšom kroku odhadneme jednoduchú regresnú rovnicu pre deflátor celkového vývozu tovarov a služieb (PEGS). Deflátor vývozu vzniká podielom vývozu tovarov a služieb SR v bežných cenách a stálych cenách, teda je indikátorom vývozného cenového hladiny³. V logaritmickú rovnicu sú vysvetľujúcimi premennými výrobné ceny na export (PPIEXP) a časovo posunutá závisle premenná o jeden štvrt'rok späť (PEGS(-1)). Tento vzťah možno interpretovať tak, že hodnota deflátoru závisí aj od hodnoty deflátoru z predošlého štvrt'roka. Pri odhade rovnice dbáme na zvolený *sample* súboru, aby bol stanovený na celé obdobie. Keďže rovnica obsahuje názvy koeficientov PEG00 s číslom v zátvorke (poradím), tieto sa ihneď po exekúcii daného riadku zapíšu automaticky do objektu PC00. Rovnako si uložíme aj rezíduá a to do objektu RESIDZPEGS (časový rad). Opäť musíme zdôrazniť, že tento vzťah nie je overený, a nemusí spĺňať potrebné testovacie štatistiky (kointegrácia, stacionarita). Východiskom je tvorba *modelov s členmi korigujúcimi chyby*, ktorými sa budeme zaoberať v 2. kapitole. Zatiaľ je toto zjednodušenie v súlade s našim cieľom a to na jednoduchom príklade vysvetliť príkazy programovacieho jazyka EViews-u spojené s prognózovaním jednoduchej regresnej rovnice.

Ďalším krokom je vytvorenie prognózy. Využijeme oba druhy prognóz, teda statickú i dynamickú a následne ich porovnáme. Cieľom tohto programu je porovnávanie prognóz s realitou, chceme zistiť ako sa správal jednoduchý regresný model pred posledným štvrt'rokom 2009 (z predošlých príkladov). Prognózu budeme vytvárať vždy na nanovo nastavenom *sample*, rozšírenom vždy o jeden štvrt'rok dopredu. Pre účely porovnania a zároveň z hľadiska stability parametrov nám stačí obdobie od roku 2007. Dynamickú a statickú prognózu vykonáme vždy od začiatku časového obdobia – 2000Q1, pričom pravá hranica časového obdobia sa bude posúvať od 2007Q1, vždy o jeden štvrt'rok dopredu pre každú prognózu. Prognózy na posledný štvrt'rok porovnáme na konci so skutočnou hodnotou, resp. skutočným rastom deflátoru celkového vývozu. Budeme teda simulovať situáciu, akoby sme od roku 2007 robili každý štvrt'rok prognózu. Týmto nám vznikne reálnejší pohľad na kvalitu prognózy. Cyklus FOR..NEXT sme premietli do vytvárania *sample*, za ktorý sa bude počítať statická a dynamická

³ Celkový vývoz tovarov a služieb je jednou zo zložiek HDP podľa výdavkovej metódy.

prognóza s tým, že sa dosadí na pravú stranu príkazu SMPL reťazcová premenná (SMPL 2000q1 %1). Tento reťazec využijeme i v ďalších dvoch riadkoch programu, pri príkaze FIT a FORECAST na vytvorenie prognózy. Tento reťazec sa stane súčasťou názvu prognózovaného časového radu, pričom sa priradí vždy na koniec názvu (pozri všeobecný syntax príkazov FIT a FORECAST v tejto kapitole). Takto budeme môcť ľahšie identifikovať, ku ktorému obdobiu patrí daný prognózovaný časový rad. Každý prognózovaný časový rad (statický aj dynamický) zaradíme do skupiny s názvom RESULT1, ktorú sme si vytvorili pomocou príkazu GROUP pred začiatkom cyklu FOR..NEXT. Následne vypočítame medziročné rasty našich prognóz, pričom sa stále nachádzame v prvom cykle FOR..NEXT. V tomto ešte nastavíme nové časové rozpätie SMPL %1 %1, následne vytvoríme ďalší cyklus – podradený vnorený cyklus FOR..NEXT (tentoraz kombinácia reťazcovej so skalárnou premennou), pomocou ktorého vypočítame medziročný rast každého prognózovaného časového radu v skupine RESULT1 v percentuálnom vyjadrení a následne tento vnorený cyklus ukončíme. Program sa bude spúšťať tým spôsobom, že najprv sa začne cyklus nadradený t.j. 2007Q1, potom sa spustí cyklus podradený FOR !r, a až následne po jeho ukončení (t.j. po vystriedaní všetkých časových radov v skupine RESULT1), sa vráti program do nadradeného cyklu FOR...NEXT, t.j. do druhého cyklu 2007Q2 atď.

V ďalšej časti programu, kde nám ešte prebieha nadradený cyklus, priradíme jednotlivé štvrťročné medziročné rasty do finálnych dvoch časových radov. Všimnite si, že náš program obsahuje komentáre, ktoré sa začínajú znakom `!`, a pokračuje zvýrazneným popisom ďalšieho odseku programu. Zvýraznenie pomocou znaku hviezdičky (*) výrazne uľahčí prehľad nad textom programu. O komentároch sme hovorili v *1. časti príručky* v kapitole 2.7.1. Prvý zo spomenutých časových radov bude predstavovať všetky štvrťročné prognózy (medziročné rasty v percentách) statickej prognózy a druhý časový rad prognózy dynamickej prognózy. Základom programu pre toto dosadenie hodnôt pre každý časový rad sú dva príkazy, prvým je príkaz SMPL a druhým SERIES, pričom sa výslednému vytvorenému časovému radu (AA_PEGSST a AB_PEGSDY) priradí hodnota v stanovenom *sample* podľa príkazu @ELEM. Sample je stanovený vždy iba na jeden štvrťrok, aby nám do výsledného časového radu nevložil program hodnotu pomocou príkazu @ELEM do iných pozorovaní. Všetky uvedené príkazy sme si už bližšie vysvetlili v *1. časti príručky*. Pomocou nadradeného cyklu sa bude meniť *sample* od 2007Q1 až po 2009Q4 (pre každý z týchto štvrťrokov bude dosadená do časového radu jedna hodnota prognózy – medziročný rast v %). Zároveň sa toto časové obdobie bude meniť i vnútri príkazu @ELEM, a to aj v prvej časti – v názve časových radov XPEGSST{%1} a XPEGSDY{%1}, teda všetkých časových radov, ktoré sú členmi pôvodnej skupiny RESULT1. V druhej časti príkazu @ELEM sa bude meniť i odkaz na časové obdobie *sample*. Výsledné časové rady AA_PEGSST, AB_PEGSDY obsahujú teraz už všetky prognózy medziročného rastu deflátoru celkového vývozu v % pre každý štvrťrok od roku 2007 až po koniec roka 2009.

Posledná časť programu obsahuje už len jednoduché dodatočné výpočty. Najprv vypočítame percentuálne rasty skutočného (reálne zverejnené výsledky) deflátoru celkového vývozu tovarov a služieb SR. Následne vytvoríme skupinu _POROVN, ktorá bude obsahovať časové rady skutočných rastov PEGSYOY a časové rady medziročných rastov podľa statickej prognózy AA_PEGSST a dynamickej prognózy AB_PEGSDY. Následne vytvoríme pomocou príkazu FREEZE čiarový graf s názvom _POROVNANIE, ktorý je zobrazený na obr. 1.10. Názov grafu sa začína na podčiarkovník `_`, pomocou ktorého môžeme potom výsledný graf ľahšie nájsť na začiatku pracovného súboru. Toto je výhodou hlavne pri rozsiahlych súboroch s veľkým počtom objektov.

Podľa obr. 1.10 vidíme, že bližšie k zelenej krivke, t.j. k realite, je modrá krivka, teda statická prognóza, aj keď v predposlednom štvrťroku prognózy 2009Q3 bola bližšie k realite dynamická prognóza. Overiť kvalitu prognóz si môžeme pomocou kvantitatívnych ukazovateľov merania chýb, napr. pomocou priemernej štvorcovej odchýlky (Root Mean

Squared Error – RMSE) alebo priemernej absolútnej odchýlky (Mean Absolute Error – MAE). Oba ukazovatele (1), (2) sú podrobnejšie popísané v Help-e EViews-u.

$$(1) \text{ RMSE} = \sqrt{\sum_{t=T+1}^{T+h} (\hat{y}_t - y_t)^2 / h}$$

kde t je čas, h je počet pozorovaní, $\hat{y}_t$ je prognóza a y_t je skutočnosť.

$$(2) \text{ MAE} = \sum_{t=T+1}^{T+h} |\hat{y}_t - y_t| / h$$

kde t je čas, h je počet pozorovaní, $\hat{y}_t$ je prognóza a y_t je skutočnosť.

Tieto dva vzorce jednoducho prepíšeme do programu z Help-u EViews-u (*sample* nastavíme na obdobie 2007q1 až 2009q3) tým, že výsledná hodnota bude SCALAR – skalárny objekt. Príkazy @SUM (súčet hodnôt časového radu), @ABS (absolútna hodnota) sme si predstavili v 1. časti príručky. Príkaz @OBS predstavuje počet pozorovaní časového radu v aktuálne nastavenom časovom rozpätí (*sample*). V oboch prípadoch ukazovateľov merania chyby odhadu platí, že čím menšia odchýlka, tým lepší model. V prípade RMSE bola hodnota chyby statického modelu 1.52 a dynamického 2.76. V prípade MAE statická prognóza vykázala absolútnu chybu 0.36 a dynamická 1.28. Na základe oboch ukazovateľov merania chyby prognózy lepšie výsledky ponúkala statická prognóza (čo potvrdilo aj grafické porovnanie), ktorú by sme na základe týchto výsledkov mali vo výpočtoch v budúcnosti preferovať.

Výsledný program je základom tvorby modelov pre rýchle odhady HDP a jeho zložky. Automatizácia výpočtového procesu uľahčuje výrazne prácu pri rýchlych odhadoch každý štvrt'rok. Väčšiu pozornosť si však vyžaduje hľadanie optimálnych vzťahov medzi závisle a nezávisle premennými, čím sa dosahuje maximálna vypovedacia schopnosť modelov. V nasledujúcich kapitolách si predstavíme základné ekonometrické modely využívané v súčasnosti hlavne na rýchle odhady HDP slovenskej ekonomiky a jej odvetví.

Program 1.1

```
cd "c:\documents and settings\klucik.klucik\my
documents\work\flashestim\february10\"
workfile prognporovn q 1993 2010
read(t=xls, s=all1) "c:\documents and settings\klucik.klucik\my
documents\work\data\data_quarterly.xls" 225
'***** vytvorenie sezonnych a trendovej premennej*****
smpl 1993q1 1993q1
genr t = 1993
smpl 1993q2 2010q4
genr t=t(-1) + 0.25
smpl 1993q1 2010q4
genr sd1=0
genr sd2=0
genr sd3=0
genr sd4=0
smpl 1993q1 1993q1
```




```

genr sd1=1
smpl 1993q2 1993q2
genr sd2=1
smpl 1993q3 1993q3
genr sd3=1
smpl 1993q4 1993q4
genr sd4=1
smpl 1994q1 2010q4
genr sd1=sd1(-4)
genr sd2=sd2(-4)
genr sd3=sd3(-4)
genr sd4=sd4(-4)
'***** odhad prognozovanej rovnice *****
smpl @all
coef(10) peg00
equation zpegs.ls log(pegs) = peg00(1) + peg00(2) * log(ppiexp) + c(3) * log(pegs(-1))
zpegs.makeresid residzpegs
'***** vypocet prognozy *****
group result1
for %1 2007q1 2007q2 2007q3 2007q4 2008q1 2008q2 2008q3 2008q4 2009q1 2009q2
2009q3 2009q4
    smpl 2000q1 %1
    zpegs.fit pegsst{%1}
    zpegs.forecast pegsdy{%1}
    result1.add pegsst{%1} pegsdy{%1}
'***** vypocet medzirocnych rastov *****
smpl %1 %1
    for !r = 1 to result1.@count
        %2 = result1.@seriesname(!r)
        series x{%2} = ({%2}/{%2}(-4)*100)-100
    next
'***** dosadenie prognozy do noveho casoveho radu *****
smpl %1 %1
series aa_pegsst = @elem(xpegsst{%1}, {%1})
series ab_pegsdy = @elem(xpegsdy{%1}, {%1})
next
'***** dodatocne vypocty *****
smpl @all
series pegsyoy = (pegs/pegs(-4)*100)-100
'***** zaverene porovnanie *****
smpl 2007q1 2009q4
group _porovn aa_pegsst ab_pegsdy pegsyoy
freeze(_porovnanie) _porovn.line
'***** vyhodnotenie prognozy *****
smpl 2007q1 2009q3
series _st = (aa_pegsst-pegsyoy)^2
series _dy = (ab_pegsdy-pegsyoy)^2
scalar _rmsest = (@sum(_st)/@obs(_st))^1/2
scalar _rmsedy = (@sum(_dy)/@obs(_dy))^1/2
series _st2 = aa_pegsst-pegsyoy

```

```
series _dy2 = ab_pegsdy-pegsyoy
scalar _maest = @abs(@sum(_st2))/@obs(_st2)
scalar _maedy = @abs(@sum(_dy2))/@obs(_dy2)
```

Obr. 1.10 Porovnanie statických a dynamických prognóz s realitou



2. Modely s členom korigujúcim chyby

Ekonometrické modely slúžia na modelovanie ekonomických vzťahov pomocou matematických a štatistických nástrojov. V praxi sa stretávame s jednorovnicovými modelmi, ktoré vysvetľujú iba vývoj jednej makroekonomickej premennej (napr. vývoz) a s modelmi viacrovnicovými, pracujúcimi so sústavou rovníc, ktoré popisujú celú sústavu procesov súčasne (model celej ekonomiky). Medzi najpoužívanejšie ekonometrické modely patria lineárne regresné modely, generalizované lineárne modely, ARIMA modely, VAR (vector autoregressive) modely a modely s členom korigujúcim chyby (Error Correction Models – ECM). V tejto príručke sa budeme zaoberať posledne menovanými modelmi (táto kapitola) a ARIMA modelmi (nasledujúca kapitola).

V *1. časti príručky* sme popisovali jednoduchú regresiu, kde na ľavej strane bola vysvetľovaná premenná (závisle premenná) a na pravej strane sa nachádzali vysvetľujúce premenné, ktorými mohli byť okrem reálnych premenných i sezónne premenné alebo trend. Objektom nášho záujmu sú jednorovnicové stochastické ekonometrické modely, t.j. tie, ktoré majú na pravej strane náhodnú zložku, teda chybu odhadu. Závisle premenné budú vysvetľované nezávisle premennými, pričom do úvahy budeme brať i spätné väzby, t.j. pôjde o simultánne ekonometrické modely. Na rozdiel od *1. časti príručky*, kde sme abstrahovali od teoretických základov a podmienok na tvorbu regresných rovníc, budeme sa v tomto prípade zaoberať i podmienkami odhadov nutnými na interpretáciu kvantifikovaných vzťahov ekonometrického modelu.

Základom **modelov s členom korigujúcim chyby** je integrácia krátkodobého a dlhodobého vývoja vzájomne závislých premenných. V prvom kroku sa odhadne dlhodobý vzťah medzi závisle a nezávisle premennými a v ďalšom kroku sa odhadne ich krátkodobý vzťah, pričom sa využijú rezíduá z dlhodobého vzťahu oneskorené o jedno obdobie. Takto odhadnutý ECM znamená, že v krátkodobom vzťahu sa odchýlka z dlhohodovej rovnováhy medzi premennými čiastočne koriguje v nasledujúcom období. Na základe identifikovanej odchýlky od dlhohodovej rovnováhy, ktorá môže vzniknúť v určitom období (štvrt'roku), sú schopné korigovať vývoj vysvetľovanej premennej v nasledujúcom období (štvrt'roku) [Haluška et al, 2008]⁴. Pri modelovaní s členmi korigujúcimi chyby musíme jednotlivé časové rady (vysvetľované i vysvetľujúce) analyzovať z hľadiska tzv. stacionarity a kointegrácie. Okrem toho musíme sledovať i ďalšie narušenia pri odhade vzťahov. Všetky nutné podmienky modelovania by sme mali kontrolovať pomocou testov.

2.1 Testovanie ekonometrického modelu časových radov

Modelovanie ekonomických časových radov musí spĺňať určité požiadavky. Po prvé, musí spĺňať určité štatistické parametre, a po druhé, výsledný model musí byť interpretovateľný z ekonomického hľadiska. Pri každej z fáz ekonometrického modelovania (konštrukcia modelu, kvantifikácia modelu – odhad, overenie modelu) treba kontrolovať plnenie rôznych kritérií. Pred kvantifikáciou samotného modelu s členmi korigujúcimi chyby je dôležitá najmä otázka stacionarity časových radov, neskôr pri tvorbe modelu sledujeme kointegráciu časových radov. Okrem toho musia byť otestované niektoré narušenia, ako napríklad autokorelácia

⁴ Podrobnejšie je ECM model a jeho aplikácia popísaná v dokumentoch [Haluška et al, 2008] a [Haluška et al, 2010].

a heteroskedasticita rezíduí či multikolinearita časových radov. Na jednotlivé atribúty sa pozrieme bližšie v nasledujúcich kapitolách.

2.1.1 Narušenia spojené s modelovaním časových radov

Heteroskedasticita

Pri odhade ekonometrických modelov pomocou metódy najmenších štvorcov je jednou z podmienok aj konštantný rozptyl náhodných zložiek, teda homoskedasticita. Pri narušení tejto podmienky hovoríme o heteroskedasticite rozptylov náhodnej zložky (rezíduí). V tomto prípade dochádza pri odhadoch k skresleniu testovacích štatistík (štandardné chyby) jednotlivých parametrov modelu, aj keď ostávajú konzistentné.

Heteroskedasticita sa v makroekonomických časových radoch často nenachádza, nájdeme ju najčastejšie v časových radoch z finančnej oblasti. Na prítomnosť heteroskedasticity v rezíduách využívame v EViews-e Whiteov test na heteroskedasticitu. Nulovou hypotézou je neprítomnosť heteroskedasticity v rezíduách z regresie pomocou metódy najmenších štvorcov. Na detekciu heteroskedasticity využíva Whiteov test pomocnú regresiu, ktorá slúži okrem toho i na detekciu ďalších špecifikácií modelu, ako sú nezávislosť regresorov od štandardných chýb či správnosť lineárnej špecifikácie modelu. Porušenie týchto podmienok sa tiež prejaví vo významnosti štatistík tohto testu. V EViews-e sú k dispozícii dve verzie Whiteovho testu – so spoločnými výrazmi (*cross terms*) a bez spoločných výrazov (*no cross terms*). Test so spoločnými výrazmi je pôvodný Whiteov test, avšak pri regresiach s väčším počtom premenných na pravej strane rovnice sa počet spoločných výrazov zvyšuje, čo nie je praktické, preto sa zaviedol test bez týchto spoločných výrazov. Keďže hypotézou testu je žiadna heteroskedasticita, p-hodnota (pravdepodobnosť, hladina významnosti) v prípade odmietnutia tejto hypotézy na úrovni 95% musí mať hodnotu 0.05 a menej. V tom prípade sa potvrdí existencia heteroskedasticity v rezíduách.

Whiteov test heteroskedasticity spúšťame v EViews-e pomocou príkazu WHITE. Východiskovým testom je Whiteov test bez spoločných výrazov (*no cross terms*). Všeobecný syntax tohto príkazu je nasledujúci:

```
názov_rovnice.white(možnosť)
```

V prípade, že chceme použiť Whiteov test aj so spoločnými výrazmi, použijeme v zátvorke možnosť „c“, a ak chceme výstup testu vytlačiť v tlačiarňu, tak napíšeme i možnosť „p“:


```
názov_rovnice.white(c, p)
```

V prípade, ak sa potvrdí existencia heteroskedasticity v rezíduách regresnej rovnice odhadnutej pomocou metódy najmenších štvorcov, môžeme využiť ďalšie nástroje na odstránenie tejto heteroskedasticity z rovnice, t.j. odstrániť skreslenosť odhadov štandardných chýb zapríčinených heteroskedasticitou. Tieto možnosti sú k dispozícii k príkazu LS (*least squares*), a spomínali sme ich už pri krátkom popise metódy najmenších štvorcov v podkapitole 4.3 v 1. časti príručky. Pripomenieme si všeobecný syntax príkazu LS:

```
názov_rovnice.ls(možnosť) špecifikácia_rovnice
```

Medzi možnosťami príkazu LS sa nachádzajú aj možnosti ls(h) alebo ls(n), v prvom prípade pôjde o odhad pomocou metódy najmenších štvorcov, pri ktorom budú štandardné chyby konzistentné s Whiteovou heteroskedasticitou a v druhom prípade budú konzistentné s Neweyho-Westovou heteroskedasticitou. Neweyho-Westova metóda predpokladá v rezíduách na rozdiel od Whiteovej metódy okrem heteroskedasticity i prítomnosť autokorelácie, takže štandardné chyby budú očistené okrem vplyvu heteroskedasticity i o vplyv autokorelácie v rezíduách. Tieto dve metódy možno nájsť v menu objektu rovnice napravo – *Options* – ako vidieť z obr. 2.4:

Obr. 2.4 Odhady parametrov konzistentné s heteroskedasticitou – menu objektu rovnice



Autokorelácia

Jednou z podmienok regresných odhadov z rovníc je, že výsledné odhadnuté rezíduá nesmú byť vzájomne autokorelované. Autokorelácia znamená, že rezíduá z odhadnutej rovnice sú autokorelované, t.j. náhodné zložky z rôznych pozorovaní sú vzájomne závislé. Autokoreláciu náhodnej zložky testujeme najčastejšie pomocou Durbin-Watsonovej štatistiky, ktorú sme krátko spomenuli už v 1. časti príručky pri popise výstupov z odhadnutej rovnice. Hodnotu tejto štatistiky získame pomocou príkazu @dw. Ide o skalárnu veličinu, takže ju budeme môcť extrahovať pomocou príkazu scalar a to dvomi spôsobmi:

```
scalar názov_skalárnej_veličiny = @dw
scalar názov_skalárnej_veličiny = názov_rovnice.@dw
```

V prvom prípade nám EViews uloží do skalárnej veličiny Durbin-Watsonovu štatistiku z tej rovnice, ktorá bola naposledy odhadnutá. V druhom prípade uvedieme názov rovnice, z ktorého chceme extrahovať danú hodnotu štatistiky (za názvom rovnice musí byť bodka a následne @dw).

Durbin-Watsonov test meria vzájomnú asociáciu susedných pozorovaní rezíduí z regresných odhadov. Výsledok tohto testu sa pohybuje v intervale od 0 do 4, pričom pod hodnotou 2 potvrdzuje test pozitívnu koreláciu v časovom rade (prvého rádu), nad hodnotou 2 ide o negatívnu koreláciu. V praxi sa považujú reziduá za neautokorelované, ak sa Durbin-Watsonova štatistika pohybuje okolo 2.0 (1.5-2.5). V prípade, ak obsahuje špecifikácia rovnice časovo posunutú závisle premennú (oneskorenú, legovanú), nie je Durbin-Watsonova štatistika platná. V týchto prípadoch použijeme na testovanie prítomnosti autokorelácií v reziduách alternatívne testy: Q-štatistiku a Breuschov-Godfreyho LM (Langrage multiplier) test.

Q-štatistiku a Breuschov-Godfreyho LM test nájdeme v menu objektu rovnice a rovnako môžeme použiť i zodpovedajúce príkazy. Tieto boli už spomenuté v 1. časti príručky medzi príkazmi na náhľad na objekt rovnice:

<code>názov_rovnice.correl(počet_oneskorení, možnosť)</code>	‘ Q-štatistika
<code>názov_rovnice.auto(počet_rádov_oneskorenia, možnosť)</code>	‘ Breuschov-Godfreyho LM test

V prípade Q-štatistiky musíme uviesť najväčší počet oneskorení (lags), ktoré sa použijú pri výpočte autokorelácie. Medzi možnosťami za uvedeným počtom oneskorení je možné uviesť znak „p“, ktorý nám vytlačí korelogram. Ak uvedený riadok napíšeme do programu osamotene, ako vyššie v príklade, po spustení nám EViews iba otvorí náhľad na danú rovnicu a korelogram rezíduí. Ak by sme chceli tabuľku uložiť pod určitým názvom, použijeme navyše príkaz FREEZE:

```
freeze(názov_tabuľky) názov_rovnice.correl(počet_oneskorení)
```

Korelogram sa tak uloží do tabuľky pod názvom v zátvorke za príkazom FREEZE. Konkrétny príklad si uvedieme neskôr v ďalších kapitolách. V prípade, ak neuvedíme v zátvorke počet oneskorení, EViews automaticky (prednastavená hodnota) počíta autokorelácie a parciálne korelácie za 24 spätných pozorovaní⁵. Príkaz CORREL je možné použiť pre výpočet autokorelácií a parciálnych korelácií aj pri iných objektoch (napríklad pri skupinách časových rádov).

Príkaz pre výpočet Breuschovho-Godfreyho LM testu je tiež možné spustiť dvoma spôsobmi ako Q-štatistiku. Prvý spôsob je, že EViews otvorí náhľad na určenú rovnicu a druhý, pomocou príkazu FREEZE vytvorí tabuľkový objekt so štatistikami testu.

```
freeze(názov_tabuľky) názov_rovnice.auto(počet_rádov_oneskorenia)
```

EViews pri spustení príkazu AUTO vytvorí dve tabuľky, pričom pre nás je dôležitá horná tabuľka, kde sú výsledky testu. Možnosti v zátvorke za príkazom AUTO zahrňujú uvedenie počtu rádov oneskorenia autokorelácie (korelácia druhého, tretieho rádu atď.) a možnosť tlače výstupu („p“).

⁵ Výnimkou je prípad, keď na danú rovnicu už raz bol tvorený náhľad na korelogram autokorelácií, v tom prípade po zadaní príkazu `názov_rovnice.correl` zobrazí počet oneskorení, ktoré boli naposledy v tej skupine vypočítané.

Nulová hypotéza testu je, že sa v rezíduách autokorelácia nachádza, preto keď hodnota pravdepodobnosti (Probability) je blízka hodnote 0.00, indikuje to, že rezíduá danej rovnice sú autokorelované. Príklad na konkrétnej rovnici uvedieme v nasledujúcej podkapitole (2.2.3).

Multikolinearita

Ďalším problémom pri hľadaní vzťahov medzi ekonomickými veličinami je multikolinearita. Multikolinearita je vzájomná závislosť vysvetľujúcich premenných, inými slovami medzi premennými existuje relatívne vysoká vzájomná korelácia. Ak máme na pravej strane rovnice vzájomne závislé premenné, nemôžeme ich použiť, lebo sa tým skresľuje odhad rovnice aj ich interpretovateľnosť. Na testovanie vzájomnej závislosti môžeme využiť jednoduchú korelačnú maticu pomocou príkazu COR. Tentoraz na rozdiel od predošlého príkladu však nepoužijeme príkaz ako náhľad na objekt rovnice, ale ako náhľad na skupinu časových radov:

```
názov_skupiny_časových_radov.cor(možnosti)
```

a v prípade ak chceme uložiť výsledky v tabuľke:

```
freeze(názov_novej_tabuľky) názov_skupiny_časových_radov.cor
```

Medzi možnosti príkazu COR patria dve nasledujúce: znak „p“ bude znamenať tlač korelačnej matice a pomocou znaku „i“ vypočíta EViews korelácie vždy v spoločnom časovom rozsahu pre dva časové rady (jeden pár) v skupine (*pairwise sample*). V druhom prípade, keď v zátvorke neuvedíme možnosti, EViews vypočíta korelácie medzi členmi skupiny časových radov v jednom spoločnom výbere (*common sample*).


Extrémnym príkladom multikolinearity je, keď EViews nedokáže odhadnúť rovnicu a vypíše chybové hlásenie „*Near singular matrix*“. To sa stane v prípade, ak niektorú vysvetľujúcu premennú možno úplne vysvetliť pomocou ďalších vysvetľujúcich premenných v danej rovnici (exaktná kolinearita). Môže sa to stať vtedy, ak dáme na pravú stranu rovnice všetky štyri umelé sezónne premenné (pri štvrt'ročných údajoch), ako v nasledujúcom príklade:

```
' použijeme vlastne sezonne premenne
smpl 1993q1 2010q4
genr sd1=0
genr sd2=0
genr sd3=0
genr sd4=0
smpl 1993q1 1993q1
genr sd1=1
smpl 1993q2 1993q2
genr sd2=1
smpl 1993q3 1993q3
genr sd3=1
smpl 1993q4 1993q4
genr sd4=1
smpl 1994q1 2010q4
genr sd1=sd1(-4)
genr sd2=sd2(-4)
genr sd3=sd3(-4)
genr sd4=sd4(-4)
```

```
equation eqChybove.ls log(HDP) = c(1) + c(2) * sd1 + c(3) * sd2 + c(4) * sd3 + c(5) *
sd4
' pri použití sezonných premenných priamo z EViews-u:
equation eqChybove2.ls log(HDP) = c(1) + c(2) * @seas(1) + c(3) * @seas(2) + c(4) *
@seas(3) + c(5) * @seas(4)
```

V príklade sme použili oba spôsoby sezónnych premenných, vlastné sezónne premenné aj automatické premenné EViews-u. S predpokladom, že máme už vytvorený súbor a v ňom premenné (HDP) využité v rovniciach, môžeme spustiť tento krátky program zo samostatného okna (typu Program) pomocou tlačítka Run. Výsledkom bude textové okno s chybami zo spustenia programu – obr. 2.5.

Obr. 2.5 Chybové hlásenia



2.1.2 Stacionarita a kointegrácia časových radov

Ekonomické časové rady sú na základe výsledkov rôznych aplikácií vnímané väčšinou ako nestacionárne časové rady. Nestacionárnosť je predovšetkým výsledkom stochastického, t.j.

náhodného trendu. Pre vnútornú stabilitu regresných modelov je však nutnou podmienkou stacionarita časových radov.

V praxi možno pri ekonometrickom modelovaní využiť i nestacionárne časové rady. V tomto prípade je však nutné dokázať ich kointegráciu. Ak sú dva nestacionárne časové rady kointegrované, znamená to, že ich kombinácia môže byť stacionárna. Kointegrácia dvoch nestacionárnych časových radov sa interpretuje ako rovnovážny vzťah dvoch premenných z dlhodobého hľadiska. Dlhodobý kointegračný vzťah je základom modelov s členmi korigujúcimi chyby – modelov typu ECM.

Ďalším pojmom, s ktorým sa stretávame pri ekonometrickom modelovaní je integrácia časových radov. Pri nediferencovanom pôvodnom časovom rade, ktorý je stacionárny, hovoríme o integrovanom časovom rade stupňa nula s označením $I(0)$. Ak je časový rad stacionárny až po prvej diferencií, ide o integrovaný časový rad prvého stupňa $I(1)$ atď. Pre všetky časové rady, ktoré chceme modelovať, musíme zistiť informáciu, pre ktorú diferenciú (rád) sú stacionárne. Do dlhodobého vzťahu môžu vstupovať iba nestacionárne rady s rovnakým stupňom integrácie. Napríklad, všetky časové rady v rovnici musia byť integrované prvého stupňa $I(1)$. V tomto prípade môžeme hľadať ich vzájomný dlhodobý rovnovážny vzťah v regresnej rovnici. Príkladom môže byť vzťah, kde máme na ľavej strane vysvetľovanú premennú – hrubý domáci produkt (HDP) a na pravej strane konštantu a vysvetľujúcu premennú - produkciu v stavebníctve (CONPROD). Odhadnuté reziduá z rovnice by mali byť v prípade ich rovnovážneho vzťahu a rovnakého rádu integrácie stacionárne. V prípade viacerých vysvetľujúcich premenných na pravej strane rovnice môžeme využiť kointegračný test, keďže môže existovať medzi premennými viac ako jeden kointegračný vektor.


V prvej etape odhadu ECM musíme otestovať časové rady na stacionaritu, následne po odhade dlhodobého vzťahu testujeme na stacionaritu i reziduá. V treťom poslednom kroku môžeme testovať časové rady z dlhodobého vzťahu i na kointegráciu, v tom prípade, ak je na pravej strane rovnice viac ako jedna vysvetľujúca premenná.

Na stacionaritu testujeme v EViews-e časové rady pomocou tzv. Unit-root testov, teda testov na jednotkový koreň. Ak sa nachádza koreň (polynómu AR procesu) vnútri jednotkového kruhu, je časový rad stacionárny, ak mimo tohto kruhu, tak je nestacionárny. Predstavíme si dva základné testy, ktoré budeme využívať – ADF test (Augmented Dickey-Fuller test) a PP test (Phillips-Peron test). Ďalšími testami v EViews-e je modifikovaný Dickeyho-Fullerov test – GLS transformovaný DF test, Kwiatkovského test (KPSS), ERS Point Optimal test a Ngeho a Perronov test.


Prístupom z Menu sa tieto testy nachádzajú v dialógu okna na objekt časového radu **View/Unit Root Test...**. Z možností sú pre nás k dispozícii v ľavej časti okna pre testy na jednotkové korene (obr. 2.1) nasledujúce: typ testu na jednotkový koreň, voľba medzi diferenciáciou časového radu (úroveň, prvá diferenciá, druhá diferenciá) a nakoniec voľba o zaradení konštanty a trendu do rovnice (exogénnych regresorov) pri testovaní existencie jednotkového koreňa. Napravo v okne pre testy na jednotkové korene sa nachádzajú možnosti pre pokročilých používateľov testov, ide o voľbu počtu oneskorení (*lags*) a voľbu informačného kritéria pre voľbu výsledného modelu. Tieto možnosti napravo sa menia v závislosti od zvolenej metódy na testovanie jednotkového koreňa (typ testu). Na obr. 2.1 je zobrazený ADF test stacionarity pre index spotrebiteľských cien (CPI2000) pri prvej diferencií časového radu a pri exogénne zadanej konštante vo výslednej rovnici. Ako vidíme z obrázku, tabuľka výsledkov má dve časti, v hornej sú základné informácie o teste (nulová hypotéza, exogénne premenné, oneskorenie, typ testu, výsledok testu). Podľa p-hodnoty vo výške 0.2468 nemôžeme zamietnuť hypotézu o existencii jednotkového koreňa, teda časový rad indexu spotrebiteľských cien Slovenska je v prvej diferencií nestacionárny (rovnako ako bol aj v nediferencovanej podobe). Stacionaritu potvrdila až druhá diferenciá časového radu. Dolná časť výsledkovej tabuľky ADF testu ukazuje rovnicu testu, pomocou ktorej EViews odhadol ADF štatistiky. Na obr. 2.2 je

zobrazený výsledok testu jednotkového koreňa pre prvú diferenciu indexu spotrebiteľských cien pomocou PP testu (iba horná časť tabuľky). Ako vidieť z obrázku, p-hodnota je 0.00, to znamená, že môžeme odmietnuť nulovú hypotézu o jednotkovom koreni a teda, že index spotrebiteľských cien je v prvej diferencii stacionárny. Tento výsledok je iný ako podľa ADF testu, to znamená, že v realite by sme potrebovali otestovať tento časový rad dôkladnejšie (napr. pridať do testovacej rovnice exogénne premenné alebo vyskúšať ďalšie testy v ponuke EViews-u), aby sme mohli jednoznačne rozhodnúť o stacionarite, resp. nestacionarite časového radu indexu spotrebiteľských cien v prvej diferencii.

Obr. 2.1 ADF test stacionarity



Obr. 2.2 PP test stacionarity



Pre všetky testy na jednotkový koreň v EViews-e sa využíva jediný príkaz UROOT, pričom je možné ho využiť ako samostatný príkaz alebo náhľad na objekt časového radu⁶:

```
uroot(možnosti) názov_časového_radu
názov_časového_radu.uroot(možnosti)
```

Oba všeobecné popisy príkazu UROOT sú identické. Medzi možnosťami v zátvorke môžeme uviesť nasledujúce:

const – použitie konštanty v testovacej rovnici

trend – použitie konštanty a aj lineárneho časového trendu v testovacej rovnici

none – testovacia rovnica bude bez konštanty a trendu (táto možnosť je k dispozícii iba pre ADF a PP testy)

dif= celé číslo – rad diferencie časového radu pre testovanie (0-testovanie časového radu v úrovni, 1-prvá diferencia časového radu, 2-druhá diferencia časového radu)

Prednastavenými hodnotami v prípade neuvedenia žiadnych možností v príkaze je možnosť *const* (zaraďenie konštanty do testovacej rovnice) a *dif=0* pre testovanie časového radu v jeho úrovni (*level*), teda nediferencovaného časového radu. V predošlých verziách (pred verziou EViews 5.0) sa používali nasledujúce možnosti pre diferenciu časového radu: „*l*“ pre *const*, „*t*“ pre *trend* a „*n*“ pre *none*. Pre voľbu typu testu jednotkového koreňa časového radu sa udávajú nasledujúce možnosti (v angličtine):

adf – Augmented Dickey-Fuller

dfgls – GLS detrended Dickey-Fuller

pp – Phillips-Perron

kps – Kwiatkowski, Phillips, Schmidt, Shin

ers – Elliot, Rothenberg, Stock (Point Optimal)

np – Ng, Perron

⁶ Alternatívou je dialóg okna objektu skupiny časových radov, v tom prípade sa využíva test na nájdenie spoločného jednotkového koreňa pre viac časových radov (testy pre jednotkový koreň v prierezových dátach), týmto prípadom sa však nebudeme v tejto príručke zaoberať.

Východiskový, teda prednastavený, je ADF test, ktorý sa spustí v prípade, ak nevedieme v zátvorke príkazu UROOT žiadne možnosti.

K dispozícii sú aj ďalšie možnosti, tie sú však spojené s pokročilými možnosťami jednotlivých testov a tými sa nebudeme v tejto príručke zaoberať. Podrobnosti sú uvedené v Help-e EViews-u, prípadne v dokumentoch *EViews 5 Command and Programming Reference* alebo *EViews 5 User's Guide*.

Nasledovne príklady pre príkaz UROOT sú názornou ukážkou (jednej z možností) k spusteniu výsledkov prezentovaných na obr. 2.1 (ADF test) a na obr. 2.2 (PP test):

```
uroot(dif=1) cpi2000
cpi2000.uroot(pp, dif=1)
```

Ak sme overili stacionaritu (rád integrácie) všetkých časových radov, môžeme časové rady, ktoré majú rovnaký rád integrácie, použiť do dlhodobého vzťahu modelu s členom korigujúcim chyby. Kointegračný vzťah je potvrdený stacionárnymi rezíduami, t.j. testom na jednotkový koreň pomocou ADF alebo PP testu na potvrdenie stacionarity rezíduí. Kritické hodnoty pre testovacie štatistiky sú však platné iba pre pôvodné časové rady a pre rezíduá sa líšia (pre viac informácií pozri EViews Help).

Ako podporu nášho tvrdenia o kointegračnom vzťahu vyplývajúceho zo stacionárnych rezíduí z testov na jednotkový koreň v EViews-e, môžeme využiť kointegračný test. Pri viac ako jednej vysvetľujúcej premennej na pravej strane rovnice dokáže určiť zároveň koľko kointegračných vektorov existuje z vysvetľujúcich premenných.

Johansenov kointegračný test sa nachádza v Menu objektu skupiny časových radov pod náhľadom: *Group/View/Cointegration Test...*. Kointegračný test vykonáme na časových radoch, ktoré sú nestacionárne. Na začiatku treba prijať predpoklady o trende pre vykonanie testu pre výpočty testu, ktoré vyplývajú z charakteru výpočtu samotného testu (asymptotické rozdelenie LR (likelihood ratio) testovacej štatistiky). Predpoklady o trende časových radov sú dané k dispozícii automaticky pod očísľovanými voľbami bodov 1 až 6:

1. v prípade, ak časové rady majú nulový priemer
2. ak sa zdá, že žiadny z časových radov nemá trend
3. v prípade, ak časové rady majú trend a predpokladáte, že ide o stochastický trend
4. v prípade, ak sa zdá, že niektoré časové rady sú trendovo stacionárne
5. v prípade predpokladu kvadratického trendu v dátach a lineárneho trendu v kointegračnej rovnici
6. všetkých päť predošlých predpokladov naraz

Prvý a piaty prípad sa vyskytujú veľmi zriedkavo, v poslednom prípade budú pri výpočte zvažované všetky predpoklady z prvých piatich možností na základe senzitivity výsledkov a predpokladu charakteru trendu v časových radoch.

Medzi ďalšie predpoklady výpočtu kointegračného testu patrí zaradenie exogénnych premenných (napríklad sezónne premenné⁷) a intervaly oneskorenia (*lag intervals*), ktoré sa použijú pri pomocnej VAR regresii (*VAR – vector autoregression*).

Johansenov kointegračný test je založený na tzv. stopovej štatistike (*trace statistics*) a na maximálnej vlastnej štatistike (*maximum eigenvalue statistics*). Horná časť tabuľky výsledkov

⁷ V prípade, ak sú sezónne premenné typu 0-1, je potrebné ich špecifikáciu zmeniť – pozri EViews Help – Johansenov kointegračný test – coint.

zobrazuje testy pre počet kointegračných vzťahov podľa týchto dvoch štatistík. Výsledok testu je zobrazený pod tabuľkou napr. „*Trace test indicates 2 cointegrating eqn(s) at the 0.05 level*“, v tomto prípade test identifikoval 2 kointegračné vektory. Prvá tabuľka zhora je test podľa stopovej štatistiky, druhá podľa maximálnej vlastnej štatistiky. Ilustračný príklad pre tri premenné (Y00_0 – HDP, CONPROD – stavebná produkcia, IPI – priemyselná produkcia) je zobrazený na obr. 2.3a a 2.3b. Druhá časť výsledkov kointegračného testu obsahuje kointegračné vzťahy a upravené parametre podľa normalizácie (najprv podľa $b'S11*b=I$ a v ďalšej tabuľke podľa α). Posledné časti výsledovej tabuľky (*Cointegrating equations*) sú odhady z rôznych normalizácií pre každý kointegračný vzťah. Pre bližšie informácie pozrite Help EViews-u. Pre nás je najdôležitejšia horná časť tabuľky s popisom výsledného počtu nájdených kointegračných vektorov.

Pri aplikácii kointegračného testu aplikujeme pomocou príkazu COINT, ktorý má všeobecný tvar nasledujúci:

```
coint(možnosť_testu, n, možnosť) názov_časového_radu1 názov_časového_radu2 ...
@exogénna_premenná1 @exogénna_premenná2 ...
```


Pri dialógu okna objektu skupiny časových radov (Group) je príkaz rovnaký ako vyššie, s tým, že sa nachádza za názvom skupiny a je oddelený od neho bodkou. Na konci nie je potrebné vymenovávať názvy časových radov a názvy exogénnych premenných:

```
názov_skupiny.coint(možnosť_testu, počet_oneskorení, možnosť)
```

Medzi možnosťami testu na prvom mieste patrí šesť vymenovaných predpokladov o trende, ktoré sme spomínali vyššie. Tieto sa označujú v možnostiach ako *a*, *b*, *c*, *d*, *e* a posledná možnosť *s* (sumarizuje prvých päť možností). Ďalšou možnosťou je zadanie počtu oneskorení (lags). Poslednou možnosťou sú ostatné možnosti, medzi ktoré patrí definícia reštrikcií, počet iterácií v odhade atď. Podrobnosti je možné nájsť v Help-e EViews-u pre príkaz COINT. Aby bolo možné test spustiť, musíme definovať v zátvorke za príkazom COINT minimálne predpoklady o trende, teda jednu z možností písmen *a* až *s* spomenutých vyššie. Počet oneskorení je prednastavený v prípade vynechania tejto možnosti na 2, ostatné možnosti za počtom oneskorení nie je nutné vypisovať. Minimálny tvar príkazu COINT pre náhľad na objekt skupiny časových radov je nasledujúci (pre prípad z obr. 2.3a a obr. 2.3b sme využili tretí predpoklad o trende, teda písmeno *c*):

```
názov_skupiny.coint(c)
```

Obr. 2.3a Ilustračné výsledky kointegračného testu



Obr. 2.3b Ilustračné výsledky kointegračného testu

1 Cointegrating Equation(s):			Log likelihood	15.61566
Normalized cointegrating coefficients (standard error in parentheses)				
Y00_0	CONPROD_00	IPI		
1.000000	-0.457135	-0.003550		
	(0.03545)	(0.00041)		
Adjustment coefficients (standard error in parentheses)				
D(Y00_0)	0.823879			
	(0.33413)			
D(CONPROD...	5.129845			
	(1.09404)			
D(IPI)	212.4153			
	(41.2216)			
2 Cointegrating Equation(s):				
			Log likelihood	22.12214
Normalized cointegrating coefficients (standard error in parentheses)				
Y00_0	CONPROD_00	IPI		
1.000000	0.000000	-0.009091		
		(0.00055)		
0.000000	1.000000	-0.012122		
		(0.00118)		
Adjustment coefficients (standard error in parentheses)				
D(Y00_0)	0.788863	-0.460644		
	(0.32742)	(0.16511)		
D(CONPROD...	4.942652	-2.794201		
	(1.02646)	(0.51763)		
D(IPI)	219.0565	-81.16684		
	(38.9927)	(19.6636)		

2.2 Konštrukcia modelu s členom korigujúcim chyby

V tejto podkapitole si predstavíme konkrétny príklad ECM – jednorovnicového modelu, ktorý bude popisovať vývoj HDP. Tvorba modelu typu ECM bude pozostávať z nasledujúcich krokov: najprv otestujeme časové rady na stacionaritu a preveríme ich, či sú kointegrované (zároveň vykonáme aj test na kointegráciu), následne kvantifikujeme dlhodobý vzťah medzi HDP a vysvetľujúcimi premennými. Vysvetľujúce premenné analyzujeme z hľadiska multikolinearity. V treťom kroku otestujeme reziduá z dlhodobého vzťahu (heteroskedasticita, autokorelácia, stacionarita). V poslednom kroku môžeme vytvoriť modelový krátkodobý vzťah ECM a analyzovať finálne atribúty modelu.

2.2.1 Testovanie časových radov na stacionaritu

V tomto kroku importujeme do novovytvoreného súboru štvrťročné údaje o vývoji hospodárstva, ktoré máme uložené v Excel-i.

```
cd "c:\documents and settings\klucik.klucik\my documents\work\flashestim\may10\"
workfile ecmmode1 q 1993 2014
read(t=xls, s=all1) "c:\documents and settings\klucik.klucik\my
documents\work\data\data_quarterly.xls" 163
read(t=xls, s=all2) "c:\documents and settings\klucik.klucik\my
documents\work\data\data_quarterly.xls" 46
read(t=xls, s=all3) "c:\documents and settings\klucik.klucik\my
documents\work\data\data_quarterly.xls" 154
read(t=xls, s=all4) "c:\documents and settings\klucik.klucik\my
documents\work\data\data_quarterly.xls" 84
read(t=xls, s=all5) "c:\documents and settings\klucik.klucik\my
documents\work\data\data_quarterly.xls" 255

***** vytvorenie trendovej a sezonnych premennych *****
smpl 1993q1 1993q4
genr t = 1993
smpl 1993q2 2010q4
genr t=t(-1) + 0.25

smpl @all
for !a = 1 to 4
genr sd{!a}=0
next
for !b = 1 to 4
smpl 1993q{!b} 1993q{!b}
genr sd{!b}=1
next
smpl 1994q1 2010q12
for !c = 1 to 4
genr sd{!c}=sd{!c}(-4)
next

***** ulozenie suboru *****
wfsave ecmmode1
```


Po nastavení aktuálneho adresára pomocou príkazu CD nasleduje vytvorenie súboru s názvom ECMMODEL1 a príkaz READ, ktorým importujeme všetky listy Excel-ovského súboru do novovytvoreného pracovného súboru ECMMODEL1. Za komentárom zvýraznenom hviezdíčkami vytvoríme trendovú premennú a sezónne premenné pre každý štvrťrok každého roka. Na rozdiel od Programu 1.1 z 1. kapitoly sme skrátili program na vytvorenie sezónnych premenných (dummy variables) pomocou cyklu FOR..NEXT. Následne po ďalšom komentári uložíme pracovný súbor ECMMODEL1 pomocou príkazu WFSAVE. Tento príkaz sme v 1. časti príručky nepoužili, namiesto toho sme používali príkaz SAVE. Oba tieto príkazy sú identické v tom prípade, ak sa za príkazom nachádza názov pracovného súboru. Rozdiel medzi nimi je

ten, že príkaz WFSAVE je užší a dá sa použiť len na uloženie súboru EViews-u, príkaz SAVE ukladá i pod určenými názvami objekty v pracovnom súbore. Príkaz SAVE sme si vysvetlili v 1. časti príručky. Všeobecný syntax príkazu WFSAVE je nasledujúci:

```
wfsave(možnosti) [cesta]názov_súboru
```

Medzi možnosťami príkazu sú vo verzii EViews 5.0 i voľby precíznosti uloženia (pozri obr. 2.6 nižšie): „1“ pre uloženie s presnosťou 7 desatinných miest a „2“ pre dvojnásobnú (double) presnosť – pre 16 desatinných miest. Treťou možnosťou je využitie kompresie pri uložení súboru pomocou možnosti „c“. Kompresia súboru slúži na zníženie veľkosti súboru (šetrenie miesta). Napríklad 6 MB pracovný súbor (*.WF1) bez kompresie má po kompresii veľkosť 5MB. Ako vidíme z dialógu na obr. 2.6, pod spomínanými možnosťami je i možnosť „Prompt on each Save“ – „Pýtať sa pri každom uložení“, ktorú si však nemožno zvoliť pomocou príkazu WFSAVE. Táto možnosť sa dá nastaviť z Menu EViews-u – *Options\Workfile Storage Defaults ...* Poslednou možnosťou uloženia súboru je zálohovanie súborov, pri zakliknutí danej možnosti sa uloží záložný súbor (predošlá verzia) s príponou *.~F1.

Obr. 2.6 Možnosti uloženia pracovného súboru



V nasledujúcom kroku môžeme otestovať zvolené časové rady na stacionaritu. Najprv otestujeme nediferencované časové rady (Level), v prípade nestacionarity i v prvej diferencií časových radov. Pre znázornenie uvádzame iba časové rady, ktoré budú súčasťou jednorovnicového ekonometrického modelu ECM (teda HDP Y00_0, tržby v stavebníctve TURNCON_00 a tržby v priemysle TURNIND_SC_00). Keďže hľadaný vzťah bude log-lineárny, testovať budeme časové rady v tejto transformovanej podobe, v akej budú vystupovať v rovnici. Na testovanie využijeme obe testovacie metódy podrobnejšie rozpísané v predošlej podkapitole – ADF test a PP test:

```
group __adftesty y00_0 turncon_00 turnind_sc_00

for !a = 1 to __adftesty.@count
%1 = __adftesty.@seriesname(!a)
series t{%1} = log({%1})
    freeze(_adf0{%1}) t{%1}.uroot
    freeze(_adf1{%1}) t{%1}.uroot(dif=1)
    freeze(_pp0{%1}) t{%1}.uroot(pp)
```



```
freeze(_pp1{%1}) t{%1}.uroot(pp, dif=1)  
next
```

Najprv vytvoríme skupinu časových radov zloženú z tých, ktoré chceme testovať. Následne pomocou cyklu FOR..NEXT kombinovaného s reťazcovou i skalárnou veličinou extrahujeme z danej skupiny časových radov každý časový rad, na ktorom prevedieme 5 operácií: prvou je logaritmovanie daného časového radu (a uloženie pod novým menom, a to pridaním písmena t na začiatok názvu), v druhom kroku otestovanie stacionarity pomocou prednastaveného ADF testu (neuvádzame v zátvorke v možnostiach za príkazom UROOT) nediferencovaného časového radu. V treťom kroku prevedieme ten istý test, ale v prvej diferencií časového radu. V posledných dvoch krokoch využijeme na testovanie stacionarity i PP test, pričom v prvom prípade pôjde o nediferencovaný časový rad a v druhom o prvú diferenciú časového radu. Tieto kroky sú vykonané v kombinácii s príkazom FREEZE, tak aby sa uložila tabuľka v tabuľkovom objekte, pričom názov tabuľky vytvoríme pridaním prípony na začiatok časového radu podľa typu testu a podľa diferencie transformácie pôvodného časového radu (__ADF0, __ADF1, __PP0, __PP1).

Z výsledkov zisťujeme, že žiadny z troch časových radov nie je stacionárny v nediferencovanej podobe, a to podľa oboch testov. Naopak všetky časové rady sú stacionárne v prvej diferencií podľa PP testu, pričom podľa ADF testu to tak nie je v prípade tržieb v stavebníctve a HDP. V prípade HDP je stacionarita potvrdená na hranici 99% v prípade PP testu pre prvú diferenciú časového radu (príklad pre HDP je na obr. 2.7a a obr. 2.7b – iba horná časť testov). Po ďalšej analýze sa zistilo, že na stacionaritu tržieb v stavebníctve podľa ADF testu v prvej diferencií časových radov má vplyv hlavne dĺžka oneskorení (lags). Pričom pri skrátení tejto dĺžky sa výsledky testov približujú PP testu a stávajú sa stacionárnymi. V konečnom dôsledku však môžeme usúdiť, že všetky tri časové rady – HDP, tržby v stavebníctve i tržby v priemysle sú integrované prvého radu – teda v prvej diferencií – I(1) a môžu byť použité do modelovania dlhodobého rovnovážneho vzťahu.

Testovanie časových radov na stacionaritu prebieha väčšinou pomocou menu, nakoľko je to praktickejšie. V prípade väčšieho počtu testovaných časových radov je však praktické všetky časové rady automaticky otestovať na stacionaritu v nediferencovanej podobe a v prvej diferencií pri východiskových nastaveniach a výsledné tabuľky uložiť v súbore.

Obr. 2.7a Výsledky ADF testov pre HDP

Obn. 2.7a Vysledky ADF testov pre TY00_0

Table: _ADFO Y00_0		Workfile: FE_FEB10ECM::Untitled\								
View	Proc	Object	Print	Name	Edit+/-	CellFmt	InsDel	Grid+/-	Title	Comments+/-
Augmented Dickey-Fuller Unit Root Test on TY00_0										
	A	B	C	D	E					
1	Null Hypothesis: TY00_0 has a unit root									
2	Exogenous: Constant									
3	Lag Length: 5 (Automatic based on SIC, MAXLAG=9)									
4										
5					t-Statistic	Prob.*				
6										
7	Augmented Dickey-Fuller test statistic				0.491332	0.9845				
8	Test critical values:		1% level	-3.592462						
9			5% level	-2.931404						
10			10% level	-2.603944						
11										

Table: _ADF1 Y00_0		Workfile: FE_FEB10ECM::Untitled\								
View	Proc	Object	Print	Name	Edit+/-	CellFmt	InsDel	Grid+/-	Title	Comments+/-
Augmented Dickey-Fuller Unit Root Test on D(TY00_0)										
	A	B	C	D	E					
1	Null Hypothesis: D(TY00_0) has a unit root									
2	Exogenous: Constant									
3	Lag Length: 4 (Automatic based on SIC, MAXLAG=9)									
4										
5					t-Statistic	Prob.*				
6										
7	Augmented Dickey-Fuller test statistic				-2.452530	0.1336				
8	Test critical values:		1% level	-3.581152						
9			5% level	-2.926622						
10			10% level	-2.601424						
11										

Obr. 2.7b Výsledky PP testov pre HDP

Table: _PP0Y00_0					
Workfile: FE_FEB10ECM::Untitled\					
View	Proc	Object	Print	Name	Edit+/- CellFmt InsDel Grid+/- Title Comments+/-
Phillips-Perron Unit Root Test on TY00_0					
	A	B	C	D	E
1	Null Hypothesis: TY00_0 has a unit root				
2	Exogenous: Constant				
3	Bandwidth: 17 (Newey-West using Bartlett kernel)				
4					
5				Adj. t-Stat	Prob.*
6					
7	Phillips-Perron test statistic			-0.528252	0.8766
8	Test critical values:			1% level	-3.568308
9				5% level	-2.921175
10				10% level	-2.598551
11					

Table: _PP1Y00_0					
Workfile: FE_FEB10ECM::Untitled\					
View	Proc	Object	Print	Name	Edit+/- CellFmt InsDel Grid+/- Title Comments+/-
Phillips-Perron Unit Root Test on D(TY00_0)					
	A	B	C	D	E
1	Null Hypothesis: D(TY00_0) has a unit root				
2	Exogenous: Constant				
3	Bandwidth: 9 (Newey-West using Bartlett kernel)				
4					
5				Adj. t-Stat	Prob.*
6					
7	Phillips-Perron test statistic			-12.04945	0.0000
8	Test critical values:			1% level	-3.571310
9				5% level	-2.922449
10				10% level	-2.599224

2.2.2 Dlhodobý vzťah ECM

Hľadaným výsledkom modelovania má byť log-lineárny vzťah medzi vysvetľovanou premennou – HDP a vysvetľujúcimi premennými, ktorými sú kvantitatívne informácie o vývoji hospodárstva Slovenskej republiky. Zlogaritmovaný časový rad HDP ako vysvetľovaná premenná na ľavej strane rovnice a zlogaritmované časové rady tržieb v stavebníctve a v priemysle ako vysvetľujúce premenné na pravej strane rovnice (spolu s náhodnou zložkou a konštantou) vyjadrujú dlhodobý rovnovážny vzťah medzi danými premennými. Zároveň vykonáme i test na kointegráciu, a to medzi premennými daného rovnovážneho vzťahu. Z ekonomického hľadiska musí byť pre dlhodobý vzťah daná rovnica interpretovateľná. V našom prípade sú výsledné parametre odhadnutej rovnice pomocou metódy najmenších štvorcov elasticitami vplyv jednotlivých vysvetľujúcich premenných na vývoj HDP (Y00_0) z dlhodobého hľadiska⁸. Príkazy spojené s vytvorením dlhodobého vzťahu budú vyzeráť nasledovne:

⁸ Dlhodobý rovnovážny vzťah medzi nestacionárnymi premennými X_t a Y_t odhadnutý v 1. kroku má tvar $Y_t = a + b * X_t + ut$, kde X je vektor vysvetľujúcich premenných a ut je náhodná (reziduálna) premenná s nulovou strednou hodnotou a konštantným rozptylom, t.j. stacionárny časový rad.

```
coef(10) hdp00
equation _ecmlong.ls log(y00_0) = hdp00(1) + hdp00(2) * log(turnind_sc_00) +
hdp00(3) * log(turncon_00) + hdp00(4) * sd4
_ecmlong.makeresid _residhdp

freeze(_adf0res) _residhdp.uroot(none)
freeze(_pp0res) _residhdp.uroot(pp, none)

group _multicol turncon_00 turnind_sc_00
freeze(_multicolinear) _multicol.cor
freeze(_heterosked) _ecmlong.white

freeze(_coint) _multicol.coint(c) @ sd4
```

V prvom kroku sme vytvorili pomocou príkazu COEF objekt koeficientov s názvom HDP00, kde sa budú ukladať parametre odhadnutej rovnice. Rovnicu s názvom _ECMLONG odhadujeme preto s parametrami s názvom hdp00(1), hdp00(2) atď. Vo výslednej rovnici sa okrem vysvetľujúcich premenných tržieb v stavebníctve a tržieb v priemysle na pravej strane ukázala ako štatisticky významná i externá premenná vo forme sezónnej premennej pre 4. štvrt'rok. Následne z odhadnutej rovnice vytvoríme pomocou príkazu MAKERESID časový rad rezíduí s názvom _RESIDHDP (odhadnutá náhodná zložka). Následne otestujeme odhadnuté rezíduá na stacionaritu pomocou ADF testu a PP testu, pričom nastavíme tentoraz v možnostiach externé premenné na NONE, t.j. žiadne (bez konštanty a lineárneho trendu). Tabuľky výstupov oboch testov vytvoríme pomocou príkazu FREEZE. Pomocný nástroj na nájdenie multikolinearity medzi vysvetľujúcimi premennými je korelačný diagram, ktorý vytvoríme pomocou príkazu COR a FREEZE, ktorý nám uloží výstupnú tabuľku do nového objektu. V poslednom kroku otestujeme rezíduá z odhadnutej rovnice na heteroskedasticitu.

Na obr. 2.8 nižšie je zobrazená výstupná tabuľka dlhodobej rovnice, t.j. dlhodobého vzťahu medzi HDP a tržbami v stavebníctve a v priemysle, ktorého rezíduá vstúpia neskôr do krátkodobého ECM vzťahu. Z výstupnej tabuľky môžeme na základe Durbin-Watsonovej štatistiky (1.55), ktorej hodnota sa nachádza medzi 1.5-2.0, predpokladať absenciu autokorelácie v dlhodobom vzťahu. Dôležitý z hľadiska interpretovateľnosti výsledkov je parameter R^2 , ktorý hovorí koľko percent z rozptylu vysvetľovanej premennej je vysvetlených pomocou rovnice. Keďže je vyšší ako 97%, môžeme hovoriť o vysokej výpovednej schopnosti regresného vzťahu. Pre účely ekonometrickej analýzy je však pre nás rovnako dôležitý i pohľad ekonomickej interpretovateľnosti. O tejto nám dávajú informácie napríklad výšky a znamienka parametrov jednotlivých vysvetľujúcich premenných. Z tohto hľadiska môžeme potvrdiť vyššiu elasticitu vývoja HDP od vývoja tržieb v priemysle (0.6) než elasticitu zmien vývoja HDP od tržieb v stavebníctve (0.2). Oba parametre sú zároveň kladné, čo hovorí o rovnakom smere zmien a teda o pozitívnej lineárnej závislosti premenných. Negatívny je koeficient parametra sezónnej umelej premennej pre 4. štvrt'rok, ktorý hovorí o pravidelnom znížení HDP v 4. štvrt'roku počas celého odhadnutého obdobia.

Obr. 2.8 Výstup z dlhodobej rovnice pre ECM model

	Coefficient	Std. Error	t-Statistic	Prob.
HDP00(1)	0.031298	0.006330	4.944788	0.0000
HDP00(2)	0.608348	0.047468	12.81599	0.0000
HDP00(3)	0.206446	0.025923	7.963696	0.0000
HDP00(4)	-0.083794	0.012014	-6.974894	0.0000

R-squared	0.972282	Mean dependent var	-0.051184
Adjusted R-squared	0.969511	S.D. dependent var	0.157281
S.E. of regression	0.027463	Akaike info criterion	-4.241812
Sum squared resid	0.022627	Schwarz criterion	-4.062240
Log likelihood	76.11081	Durbin-Watson stat	1.556408

Na ďalšom obrázku (obr. 2.9 nižšie) je zobrazený tabuľkový výstup z ADF a PP testov pre stacionaritu rezíduí. Podľa výsledkov oboch testov môžeme vyvrátiť s 99% pravdepodobnosťou nulovú hypotézu o jednotkovom koreni v rezíduách, t.j. časový rad rezíduí z dlhodobej rovnice môžeme považovať za stacionárny a môžeme ho využiť pri konštrukcii krátkodobého vzťahu modelu ECM⁹.

Korelačná analýza medzi vysvetľujúcimi premennými – tržbami v stavebníctve a tržbami v priemysle – dokázala vysokú korelačnú závislosť s koeficientom 0.83, teda existuje podozrenie na prítomnosť kolinearít medzi dvoma premennými. Avšak vzhľadom na to, že obe vysvetľujúce premenné mohli byť využité v dlhodobom vzťahu s HDP pri dodržaní všetkých podmienok regresného odhadu, problém multikolinarít preto nepredstavuje v tomto prípade významný problém.

Ďalším testom prevedeným v programe pre dlhodobý vzťah pre ECM model vyššie je test na heteroskedasticitu rezíduí. Týmto testom chceme dokázať, že v rezíduách heteroskedasticita nie je prítomná, a teda naopak rezíduá sú homoskedastické (konštantný rozptyl náhodnej zložky). Na obr. 2.10 je zobrazená horná časť Whiteovho testu na heteroskedasticitu. Podľa výstupu môžeme skonštatovať, že v intervale spoľahlivosti 95% sú rezíduá homoskedastické. Tento výsledok je štatisticky veľmi tesný, keďže na potvrdenie hypotézy o neexistencii heteroskedasticity by p-hodnota mala byť väčšia ako 0.05.

⁹ Opäť však ide iba o predpoklad, nakoľko kritické hodnoty testov pre rezíduá sa líšia od kritických hodnôt pre pôvodné časové rady, preto by sme mali vyhľadať v literatúre správne kritické hodnoty (pozri bližšie EViews Help – Cointegration Test).

Obr. 2.9 ADF a PP test pre stacionárnosť rezíduí z dlhodobého vzťahu

Table: _ADFORES Workfile: FE_FEB10ECM::Untitled\					
View	Proc	Object	Print	Name	Edit+/- CellFmt InsDel Grid+/- Title Comments+/-
Augmented Dickey-Fuller Unit Root Test on _RESIDHDP					
	A	B	C	D	E
1	Null Hypothesis: _RESIDHDP has a unit root				
2	Exogenous: None				
3	Lag Length: 0 (Automatic based on SIC, MAXLAG=8)				
4					
5					t-Statistic Prob.*
6					
7	Augmented Dickey-Fuller test statistic				-4.637857 0.0000
8	Test critical values: 1% level				-2.636901
9	5% level				-1.951332
10	10% level				-1.610747
11					

Table: _PPORES Workfile: FE_FEB10ECM::Untitled\					
View	Proc	Object	Print	Name	Edit+/- CellFmt InsDel Grid+/- Title Comments+/-
Phillips-Perron Unit Root Test on _RESIDHDP					
	A	B	C	D	E
1	Null Hypothesis: _RESIDHDP has a unit root				
2	Exogenous: None				
3	Bandwidth: 4 (Newey-West using Bartlett kernel)				
4					
5					Adj. t-Stat Prob.*
6					
7	Phillips-Perron test statistic				-4.586547 0.0000
8	Test critical values: 1% level				-2.636901
9	5% level				-1.951332
10	10% level				-1.610747
11					

Obr. 2.10 Whiteov test na heteroskedasticitu v rezíduách z dlhodobej rovnice

Table: _HETEROSKED Workfile: FE_FEB10ECM::Untitled\					
View	Proc	Object	Print	Name	Edit+/- CellFmt InsDel Grid+/- Title Comments+/-
	A	B	C	D	E
1	White Heteroskedasticity Test:				
2					
3	F-statistic	2.439132	Prob. F(5,28)		0.059030
4	Obs*R-squared	10.31585	Prob. Chi-Square(5)		0.066765
5					
6					

Posledným testom, ktorým chceme potvrdiť zaradenie uvedených vysvetľujúcich premenných do dlhodobej rovnice ECM, je kointegračný test. Johansenov kointegračný test (príkaz COINT) predpokladá existenciu dvoch kointegračných rovníc (obr. 2.11). Tabuľka výstupu testu bola uložená do objektu _COINT a ako základ pre výpočet testu slúžil objekt _MULTICOL, kde sme už mali uložené potrebné časové rady pre kointegračný test, takže nebolo potrebné vytvárať ďalší objekt. Pri príkaze COINT sme použili v zátvorke možnosť „c“, teda predpoklad existencie trendu v dátach, t.j. trend v HDP, tržbách v stavebníctve a priemysle,

zároveň však predpoklad prítomnosti konštanty a absencie trendu v kointegračnej rovnici. Za príkaz COINT, znak „@“ a po medzere patria názvy exogénnych premenných, v našom prípade ide o sezónnu premennú SD4. V tejto súvislosti si však musíme pripomenúť, že kritické hodnoty testu neberú do úvahy exogénnu premennú (viď poznámka obr. 2.11).

Obr. 2.11 Johansenov kointegračný test pre premenné ECM

	A	B	C	D	E
1	Date: 12/15/10 Time: 14:41				
2	Sample (adjusted): 2000Q3 2009Q3				
3	Included observations: 37 after adjustments				
4	Trend assumption: Linear deterministic trend				
5	Series: TURNCON_00 TURNIND_SC_00				
6	Exogenous series: SD4				
7	Warning: Critical values assume no exogenous series				
8	Lags interval (in first differences): 1 to 1				
9					
10	Unrestricted Cointegration Rank Test (Trace)				
11					
12	Hypothesized		Trace	0.05	
13	No. of CE(s)	Eigenvalue	Statistic	Critical Value	Prob.**
14					
15	None *	0.675820	45.54030	15.49471	0.0000
16	At most 1 *	0.099101	3.861414	3.841466	0.0494
17					
18	Trace test indicates 2 cointegrating eqn(s) at the 0.05 level				
19					

2.2.3 Krátkodobý vzťah ECM

Po analýze dlhodobého rovnovážneho vzťahu a rezíduí z neho, môžeme pristúpiť ku konštrukcii samotného modelu ECM.

Kedže všeobecne platí [Haluška a kol. 2009], že ak dlhodobý rovnovážny vzťah medzi nestacionárnymi premennými X_t a Y_t odhadnutý v 1. kroku je stacionárny časový rad, potom zodpovedajúci model ECM odhadnutý pomocou stacionárnych premenných v 2. kroku má všeobecný tvar $DY_t = c DX_t - l * ut-1$ resp. $DY_t = c DX_t - l * (Y_{t-1} - a - b * X_{t-1}) + et$, kde

$$DY_t = Y_t - Y_{t-1}$$

$$DX_t = X_t - X_{t-1}$$

et je náhodná (reziduálna) premenná s rovnakými vlastnosťami ako ut .

Takže v ďalších krokoch vytvoríme aj pomocou rezíduí z dlhodobého vzťahu krátkodobý vzťah a zároveň otestujeme štatistickú a ekonomickú výrokovú schopnosť modelu.

```
coef(10) shdp00
equation _ecmshort.ls dlog(y00_0) = shdp00(1) * __ecmresid(-1) + shdp00(2)
*dlog(turncon_00) + shdp00(3) * d(sd4)
_ecmshort.makesid _residhdpshort
freeze(_residshort) _ecmshort.resids
```



```
freeze(_adf0ressh) _residhdpshort.uroot(none)
freeze(_pp0ressh) _residhdpshort.uroot(pp,none)

freeze(_heteroskedsh) _ecmshort.white


freeze(_autokorelQst) _ecmshort.correl(24)
freeze(_autokorellm) _ecmshort.auto(3)
```

V prvom kroku opäť vytvoríme objekt koeficientov pre ukladanie odhadnutých parametrov z krátkodobej rovnice. Následne odhadneme rovnicu, pričom v tomto príklade krátkodobá rovnica už neobsahuje na rozdiel od dlhodobej rovnice vplyv tržieb v priemysle na vývoj HDP, nakoľko sa táto premenná neukázala ako štatisticky významná. Ostatné vysvetľujúce premenné sú vo forme diferencií logaritmov a rezíduá z dlhodobej rovnice sú v súlade s teóriou o ECM posunuté v čase o jedno pozorovanie späť. Následne po odhadnutí rovnice uložíme náhodnú zložku z krátkodobej rovnice ECM ako časový rad s názvom `_ECMSHORT`. Výsledný tabuľkový výstup z rovnice je zobrazený na obr. 2.12. Na obr. 2.13 sú zobrazené rezíduá, ktoré sme uložili v grafickom objekte pomocou príkazu `FREEZE` a náhľadu na rovnicu `RESIDS`. Výstup z rovnice nám opäť dáva hlavnú informáciu o výrokovej schopnosti celého modelu prostredníctvom parametra R^2 , ktorý je oproti dlhodobej rovnici výrazne nižší (0.83), stále však môžeme hovoriť o pomerne vysokej výrokovej schopnosti modelu. Korekčný parameter ECM, t.j. parameter časovo posunutých rezíduí z dlhodobej rovnice má negatívnu hodnotu, čo je v súlade s teóriou. Tento parameter slúži ako informácia o korekciách odchýlok z dlhodobého vzťahu a jeho výška (0.33) hovorí, akú časť (33%) z nerovnováhy z predošlého štvrt'roku sa prostredníctvom neho koriguje v aktuálnom období. Ostatné parametre krátkodobého vzťahu hovoria o krátkodobej elasticite zmien HDP na zmeny jednotlivých vysvetľujúcich premenných (na rozdiel od dlhodobého vzťahu, kde išlo o dlhodobú elasticitu HDP na zmeny vysvetľujúcich premenných). Z toho vyplýva napríklad, že elasticita zmien HDP na zmeny tržieb stavebníctva je približne rovnaká ako v dlhodobom vzťahu (0.25 vers. 0.20), čo hovorí o zmene HDP o 0.25% pri 1% zmene tržieb v stavebníctve. Rovnako aj sezónna premenná pre 4. štvrt'rok v sledovanom období hovorí o spomalení HDP, zatiaľ čo pri dlhodobom vzťahu sa dala interpretovať ako pokles HDP, nakoľko v krátkodobom vzťahu ide o relatívne zmeny oproti predošlému štvrt'roku.


Pomocou testov ADF a PP môžeme otestovať novoodhadnuté rezíduá, ktoré by mali byť stacionárne. Testy potvrdili stacionárnosť rezíduí, ako vidieť z p-hodnôt z tabuľky výsledkov testov na obr. 2.14.

Ďalším testom vykonanom v programe bol Whiteov test heteroskedasticity. Ako vidíme z obr. 2.15 test potvrdil prítomnosť heteroskedasticity v rezíduách z krátkodobého vzťahu ECM. Toto zistenie môže byť teda dôvodom pre zdokonalenie vzťahu v krátkodobom či dlhodobom vzťahu, kde by sme mohli experimentovať s novými vysvetľujúcimi premennými, ktoré by nám zlepšili štatistické charakteristiky odhadnutého modelu. Následkom toho by sa zrejme už heteroskedasticita v krátkodobom vzťahu z modelu neobjavovala.

Obr. 2.12 Výstup z krátkodobej rovnice pre ECM model



Obr. 2.13 Rezíduá z krátkodobého vzťahu v tvare ECM



Obr. 2.14 ADF a PP test pre stacionárnosť rezíduí z krátkodobého vzťahu ECM

Table: _ADFORESSH Workfile: FE_FEB10ECM::Untitled\					
View Proc Object Print Name Edit+/- CellFmt InsDel Grid+/- Title Comments+/-					
Augmented Dickey-Fuller Unit Root Test on _RESIDHDPSHORT					
	A	B	C	D	E
1	Null Hypothesis: _RESIDHDPSHORT has a unit root				
2	Exogenous: None				
3	Lag Length: 0 (Automatic based on SIC, MAXLAG=8)				
4					
5					t-Statistic
6					Prob.*
7	Augmented Dickey-Fuller test statistic				-6.127031 0.0000
8	Test critical values: 1% level				-2.639210
9	5% level				-1.951687
10	10% level				-1.610579
11					

Table: _PPORESSH Workfile: FE_FEB10ECM::Untitled\					
View Proc Object Print Name Edit+/- CellFmt InsDel Grid+/- Title Comments+/-					
Phillips-Perron Unit Root Test on _RESIDHDPSHORT					
	A	B	C	D	E
1	Null Hypothesis: _RESIDHDPSHORT has a unit root				
2	Exogenous: None				
3	Bandwidth: 8 (Newey-West using Bartlett kernel)				
4					
5					Adj. t-Stat
6					Prob.*
7	Phillips-Perron test statistic				-6.213749 0.0000
8	Test critical values: 1% level				-2.639210
9	5% level				-1.951687
10	10% level				-1.610579
11					


Obr. 2.15 Test na heteroskedasticitu rezíduí z krátkodobého vzťahu ECM

Table: _HETEROSKEDSH Workfile: FE_FEB10ECM::Untitled\					
View Proc Object Print Name Edit+/- CellFmt InsDel Grid+/- Title Comments+/-					
	A	B	C	D	E
1	White Heteroskedasticity Test:				
2					
3	F-statistic	2.883641	Prob. F(8,24)		0.021145
4	Obs*R-squared	16.17369	Prob. Chi-Square(8)		0.039961
5					

Posledným testom kvality krátkodobého vzťahu a tým pádom i modelu ECM vo finálnej podobe je test rezíduí na autokoreláciu. Keďže Durbin-Watsonova štatistika je v krátkodobom vzťahu neplatná, lebo ako sme už spomenuli v stati 2.1.1 – táto je použiteľná iba v prípadoch, ak sa na pravej strane rovnice nenachádza časovo posunutá závisle premenná. V tomto prípade môžeme použiť alternatívne testy, teda Q-štatistiku alebo Breuschov-Godfreyho LM test. Na test Q-štatistiky využijeme príkaz CORREL a na Breuschov-Godfreyho LM test príkaz AUTO. V kombinácii s príkazom FREEZE vytvoríme tabuľky obsahujúce výstupy z týchto testov, pričom v možnostiach jednotlivých príkazov uvedieme v zátvorke maximálny počet oneskorení pre výpočet korelogramu v prípade príkazu CORREL a v prípade príkazu AUTO zasa rád

korelácie, pre ktorý chceme test vypočítať. Na obr. 2.16 sú zobrazené tabuľkové výstupy oboch testov (iba najdôležitejšie časti testov). Oba testy potvrdili predpoklad absencie autokorelácie v rezíduách.

Obr. 2.16 Test autokorelácie rezíduí z krátkodobého vzťahu ECM



2.2.4 Prognózy

Odhadnutý finálny jednorovnicový model v tvare ECM z predošlej podkapitoly môžeme využiť na prognózu vysvetľovanej premennej, teda HDP. K prognózovaniu využijeme príkazy pre dynamické a statické prognózy z 1. kapitoly tejto príručky – FIT a FORECAST. Pomocou týchto príkazov spravíme dynamickú a statickú prognózu modelu odhadnutého v predošlej podkapitole (krátkodobý ECM vzťah = finálna podoba ECM). Následne porovnáme oba typy prognóz aj späťne v čase, a to v grafickej i v matematickej forme (hodnotenie prognóz podľa 1. kapitoly).

Výsledný ECM model v tvare $dlog(y00_0) = shdp00(1) * _ecmresid(-1) + shdp00(2) * dlog(turncon_00) + shdp00(3) * d(sd4)$ z rovnice `_ECMSHORT` použijeme na statickú

a dynamickú prognózu na obdobie od prvého až po posledné pozorovanie časového radu HDP (Y00_0), t.j. od 1. štvrťroku 2000 po 4. štvrťrok 2009.

```
smpl 2000m1 2009m4
_ecmshort.fit hdpst
_ecmshort.forecast hdpdy
```

Prognózované časové rady budú mať názov HDPST (ako statická prognóza) a HDPDY (ako dynamická prognóza). V prípade, keď chceme porovnať prognózy aj za spätné obdobie pred posledným štvrťrokom 2009, napríklad od roku 2007, použijeme cyklus FOR..NEXT:

```
group results
for %1 2007q1 2007q2 2007q3 2007q4 2008q1 2008q2 2008q3 2008q4 2009q1 2009q2
2009q3 2009q4
    smpl 2000q1 %1
    _ecmshort.fit hdpst{%1}
    _ecmshort.forecast hdpdy{%1}
    results.add hdpst{%1} hdpdy{%1}
next
```

Ak chceme objektívne porovnať prognózy, musíme vložiť každú prognózu pre jednotlivý štvrťrok do objektu časového radu a následne porovnať so skutočnosťou, teda s časovým radom HDP so všetkými doteraz známymi pozorovaniami. Vnorený program pre dosadzovanie prognóz do časových radov bude rovnaký ako v programe 1.1 v 1. kapitole tejto príručky, s tým rozdielom, že tentoraz nepôjde o medziročné rasty v percentách, ale o prognózy úrovne (level) časového radu.

```
group results
for %1 2007q1 2007q2 2007q3 2007q4 2008q1 2008q2 2008q3 2008q4 2009q1 2009q2
2009q3 2009q4
    smpl 2000q1 %1
    _ecmshort.fit hdpst{%1}
    _ecmshort.forecast hdpdy{%1}
    results.add hdpst{%1} hdpdy{%1}
    smpl %1 %1
    series aa_hdpst = @elem(hdpst{%1}, {%1})
    series ab_hdpdy = @elem(hdpdy{%1}, {%1})
next
```

Rozdielne z hľadiska interpretácie oproti Programu 1.1 z 1. kapitoly bude i porovnávanie statickej a dynamickej prognózy od roku 2007 po rok 2009, z tohto hľadiska už nepôjde o percentuálne odchýlky od reálnych medziročných rastov skúmanej premennej, ale o odchýlky v absolútnych hodnotách bázičských indexov od reálneho časového radu HDP tiež v podobe bázičského indexu. Vzorce priemernej štvorcovej odchýlky (Root Mean Squared Error – RMSE) a priemernej absolútnej odchýlky (Mean Absolute Error – MAE) vypočítame prostredníctvom príkazov v EViews-e postupne nasledovným spôsobom:

```
smpl 2007q1 2009q3
series _st = (aa_hdpst-y00_0)^2
series _dy = (ab_hdpdy-y00_0)^2
```

```

scalar _RMSEst = (@sum(_st)/@obs(_st))^1/2
scalar _RMSEdy = (@sum(_dy)/@obs(_dy))^1/2
series _st2 = aa_hdpst-y00_0
series _dy2 = ab_hdpdy-y00_0
scalar _MAEst = @abs(@sum(_st2))/@obs(_st2)
scalar _MAEdy = @abs(@sum(_dy2))/@obs(_dy2)

```

Z kvantitatívneho hľadiska bola presnejšia statická prognóza z modelu ECM, keď hodnota RMSE bola 0.0016 na rozdiel od dynamickej, ktorá dosiahla štvorcovú odchýlku 0.0109. Výsledky potvrdil aj test pomocou absolútnej odchýlky, ktorá bola pri statickej prognóze 0.024 a pri dynamickej prognóze 0.130, teda približne 6-násobne vyššia.

Na ďalšom obrázku (obr. 2.17) je zobrazený výsledný graf pre porovnanie prognózy statickej i dynamickej s realitou (ochýlky v absolútnych hodnotách) získaný pomocou programu:


```

smpl 2007q1 2009q4
group _porovn aa_hdpst ab_hdpdy y00_0
freeze(_porovnanie) _porovn.line

```

Obr. 2.17 potvrdzuje, že uprednostníme statickú pred dynamickou prognózou HDP z modelu typu ECM.

Obr. 2.17 Porovnanie statickej a dynamickej prognózy HDP z ECM modelu s realitou



Teraz si uvedieme kompaktný program pre konštrukciu a prognózu modelu ECM pre ďalšiu zložku HDP, ktorou je spotreba domácností v stálych cenách. Nasledujúci model na rozdiel od predošlých modelov nie je zjednodušený, ale skutočný – extrahovaný z pôvodného dokumentu [Haluška a kol., 2010].

Program 2.1

```
***** vytvorenie suboru a importovanie dat*****
cd "c:\documents and settings\klucik.klucik\my documents\work\flashestim\may10\"
workfile ecmcompact q 1993 2014
read(t=xls, s=all1) "c:\documents and settings\klucik.klucik\my
documents\work\data\data_quarterly.xls" 163
read(t=xls, s=all2) "c:\documents and settings\klucik.klucik\my
documents\work\data\data_quarterly.xls" 46
read(t=xls, s=all3) "c:\documents and settings\klucik.klucik\my
documents\work\data\data_quarterly.xls" 154
read(t=xls, s=all4) "c:\documents and settings\klucik.klucik\my
documents\work\data\data_quarterly.xls" 84
read(t=xls, s=all5) "c:\documents and settings\klucik.klucik\my
documents\work\data\data_quarterly.xls" 255
***** vytvorenie sezonnych a trendovej premennej*****
smpl 1993q1 1993q1
genr time = 1993
smpl 1993q2 2014q4
genr time=time(-1) + 0.25

smpl @all
for !a = 1 to 4
    genr sd{!a}=0
next
for !b = 1 to 4
    smpl 1993q{!b} 1993q{!b}
    genr sd{!b}=1
next
smpl 1994q1 2014q4
for !c = 1 to 4
    genr sd{!c}=sd{!c}(-4)
next
***** ulozenie suboru *****
wfsave ecmcompact
*****vypocet bazickych indexov*****
smpl @all
group bazicke1 AD AED C CBIALCT CCLOTH CEDU CFOOD CFURN
CHEALTH CHOTEL CHOUS CMISCELL CPOST CRECRE CITRANSPI CX DD DED EG
EGS EGP ES F FI FP_SC G I W9 LD9 CPI
for !v = 1 to bazicke1.@count
    %13 = bazicke1.@seriesname(!v)
    series {%13}bi={%13}/((@elem{%13}, "2000Q1")+@elem{%13}, "2000Q2")
+@elem{%13}, "2000Q3")+@elem{%13}, "2000Q4"))/4)
next
*****testy stacionarity *****
series mzdovabaza = w9bi*ld9bi/cpibi
group __adftesty c00_0 mzdovabaza
```



```

freeze(premenne1) __adftesty.line(n)
freeze(premenne2) __adftesty.cor

for !a = 1 to __adftesty.@count
%1 = __adftesty.@seriesname(!a)
    series t{%1} = log({%1})
    freeze(_adf0{%1}) t{%1}.uroot
    freeze(_adf1{%1}) t{%1}.uroot(dif=1)
    freeze(_pp0{%1}) t{%1}.uroot(pp)
    freeze(_pp1{%1}) t{%1}.uroot(pp, dif=1)
next

'*****odhad dlhodobej rovnice pre ECM*****
coef(10) cc00
equation _ecmlong.ls LOG(CBI)=cc00(1)+cc00(2)*LOG((W9BI*LD9BI)/CPIBI)
+cc00(3)*TIME +cc00(4)*SD3+cc00(5)*SD4
_ecmlong.makesresid _residcbi

freeze(_residlong) _ecmlong.resids

freeze(_adf0res) _residcbi.uroot(none)
freeze(_pp0res) _residcbi.uroot(pp, none)

freeze(_heterosked) _ecmlong.white
freeze(_coint) __adftesty.coint(d) @ sd3 sd4

'*****odhad kratkodobej rovnice pre ECM*****
coef(10) scc00
equation _ecmshort.ls DLOG(CBI)=scc00(2)*DLOG((W9BI*LD9BI)/CPIBI)
+scc00(3)*_RESIDCBI(-1)+scc00(4)*D(SD3)+scc00(5)*SD3(-1)
_ecmshort.makesresid _residcbishort
freeze(_residshort) _ecmshort.resids

freeze(_adf0ressh) _residcbishort.uroot(none)
freeze(_pp0ressh) _residcbishort.uroot(pp,none)

freeze(_heteroskedsh) _ecmshort.white

freeze(_autokorelQst) _ecmshort.correl(24)
freeze(_autokorelLM) _ecmshort.auto(3)

'***** vypocet prognozy *****
group results
for %1 2007q1 2007q2 2007q3 2007q4 2008q1 2008q2 2008q3 2008q4 2009q1 2009q2
2009q3 2009q4
    smpl 2000q1 %1
    _ecmshort.fit cbist{%1}
    _ecmshort.forecast cbidy{%1}

```

```

results.add cbist{%1} cbidy{%1}
'***** vypocet medzirocnych rastov *****'
smpl %1 %1
  for !r = 1 to results.@count
    %2 = results.@seriesname(!r)
    series x{%2} = ({%2}/{%2}*(-4)*100)-100
  next
'***** dosadenie prognozy do noveho casoveho radu *****'
smpl %1 %1
series aa_cbist = @elem(xcbist{%1}, {%1})
series ab_cbidy = @elem(xcbidy{%1}, {%1})
next
'***** dodatočne výpočty *****'
smpl @all
series cbiyoy = (cbi/cbi*(-4)*100)-100
'***** zaverene porovnanie *****'
smpl 2007q1 2009q4
group _compar aa_cbist ab_cbidy cbiyoy
freeze(_comparison) _compar.line
'***** vyhodnotenie prognozy *****'
smpl 2007q1 2009q3
series _st = (aa_cbist-cbi)^2
series _dy = (ab_cbidy-cbi)^2
scalar _RMSEst = (@sum(_st)/@obs(_st))^1/2
scalar _RMSEdy = (@sum(_dy)/@obs(_dy))^1/2
series _st2 = aa_cbist-cbi
series _dy2 = ab_cbidy-cbi
scalar _MAEst = @abs(@sum(_st2))/@obs(_st2)
scalar _MAEdy = @abs(@sum(_dy2))/@obs(_dy2)

```

V Programe 2.1 sú uvedené pre ľahšiu orientáciu v každom príslušnom odstavci komentáre. Komentáre sú zvýraznené hviezdikami „*“ a riadok, v ktorom sú napísané sa musí začínať na znak „“. V prvom odstavci sme vytvorili východiskový adresár pomocou príkazu CD a následne vytvorili nový súbor ECMCOMPACT so štvrt'ročnou frekvenciou pozorovaní so začiatkom v roku 1993 a koncom v 2014. Do tohto súboru sme pomocou príkazu READ vložili všetky časové rady, ktoré máme uložené v Excel-ovskom súbore DATA_QUARTERLY.XLS. Dáta máme v tomto súbore uložené v štyroch osobitných hárkoch. Napriek tomu, že ide o jeden a ten istý súbor, musíme použiť štyri samostatné riadky príkazov pomocou výrazu READ. V každom z nich uvedieme v zátvorke za daným príkazom v možnostiach (*Options*) názov konkrétneho pracovného hárku. Ako vidíme z príkladu, tak program neobsahuje v daných možnostiach vopred nastavenú bunku. Dáta máme uložené v súbore od ľavého horného rohu listu, pričom prvý stĺpec je popisný s dátumom pozorovania (štvrt'rokom) a prvý riadok je popisný s názvami jednotlivých časových radov. Všetky časové rady v súbore sú uložené v stĺpcoch. Ak by boli uložené v riadkoch, museli by sme v možnostiach v zátvorke príkazu READ použiť znak „t“ na čítanie časových radov z riadkov. Na konci príkazu READ sa už potom nachádza iba počet časových radov, ktorý chceme preniesť. V našom prípade prenášame všetky časového rady, čo je vidieť z posledného príkazu READ, kde prenášame 255 časových radov, čo je v našej verzii Excel-u maximum stĺpcov.

V ďalšom odstavci Programu 2.1 pod komentárom s názvom „vytvorenie sezónnych a trendovej premennej“ vytvárame ako obvykle vlastné sezónne a trendové umelé premenné (dummy variables). Tieto majú rovnakú funkciu ako EViews-ovské vlastné príkazy @SEAS(x) pre sezónne premenné a @TREND pre trendovú premennú. Výhodou vlastných premenných je, že môžeme použiť aj ich vlastné diferencie (medzikvartálne zmeny) a pri trendovej umelej premennej môžeme použiť následne v rovniciach i podmienky, ktoré nemôžeme použiť v kombinácii s klasickým EViews-ovským @TREND. Na vytvorenie trendovej premennej s názvom TIME nám postačia štyri riadky. V prvom nastavíme rozsah súboru iba na jeden štvrt'rok (úvodný štvrt'rok súboru) a stanovíme začiatok trendu na hodnotu rovnú hodnote číslu – roka teda 1993 – toto spravíme pomocou príkazu GENR, ktorý je v tomto prípade identický k príkazu SERIES, a je jedno, ktorý z nich využijeme. V treťom riadku nastavíme pomocou príkazu SMPL obdobie súboru na zvyšné pozorovania, teda na všetky okrem 1. štvrt'roka 1993. Opäť pomocou príkazu GENR stanovíme hodnotu trendovej premennej TIME, pričom každé pozorovanie bude mať odlišnú hodnotu. V našom prípade sme si zvolili rast trendu po jednej štvrtine jednotky tak, aby každý začínajúci rok (1. štvrt'rok každého roka) mal hodnotu daného roku, napr. pozorovanie z 1. štvrt'roka 2005 (2005q1) sa bude rovnat hodnote 2005. Keďže EViews vypočítava hodnoty od začiatku po koniec rozsahu súboru, stačí nám, ak zadáme, že $TIME = TIME(-1)$ teda minulé pozorovanie plus hodnota štvrt'roka, teda 0.25. Ak by sme chceli počítať od konca rozsahu súboru, t.j. od posledného pozorovania – posledného štvrt'roka 2014 a zadali príkaz vo forme $GENR TIME = TIME(1) - 0.25$, program EViews-u by vygeneroval chybové hlásenie, nakoľko hodnota TIME v poslednom pozorovaní je pre program ešte neznáma. Umelé sezónne premenné pre každý štvrt'rok vytvoríme na rozdiel od Programu 1.1 na konci 1. kapitoly tejto príručky, rýchlejšim spôsobom, a to pomocou použitia troch cyklov FOR..NEXT so skalárnou veličinou. V prvom cykle so skalárnou veličinou A (!a) vytvoríme pomocou príkazu GENR všetky štyri sezónne premenné a stanovíme zároveň predbežné hodnoty všetkých ich pozorovaní na nula na celého obdobie súboru. Druhý cyklus FOR..NEXT so skalárnou veličinou B (!b) priradí v každom zo štyroch štvrt'rokov hodnotu jedna v roku 1993, t.j. do 1. štvrt'roka premennej s názvom SD1, do 2. štvrt'roka premennej s názvom SD2 atď. Posledný cyklus so skalárnou veličinou !c priradí každému zo štyroch sezónnych premenných pre ďalšie roky hodnotu z predošlého roku (štyri pozorovania späť). Podrobnosti o sezónnych premenných a trendovej umelej premennej môžete nájsť v 1. časti príručky.

Pracovný súbor ECMCOMPACT uložíme príkazom WFSAVE.

V tejto časti programu predpokladáme, že máme potrebné časové rady k dispozícii v stálych cenách, nakoľko v rovniciach pre rýchle odhady pracujeme so zložkami HDP iba v stálych cenách. Všetky časové rady môžeme previesť na bážické indexy. V prvom kroku ich vložíme do spoločnej skupiny časových radov s názvom BAZICKE1. Pomocou cyklu FOR..NEXT kombinovaného skalárnou veličinou a reťazcovou veličinou extrahujeme z danej skupiny jeden časový rad za druhým a pomocou jednoduchého vzorca vyrátame bážický index s bážou roka 2000. Výslednému časovému radu bude priradená prípona BI na konci názvu.

Ďalšia časť programu je rezervovaná na testy stacionarity vybraných časových radov. Pre jednoduchosť budeme analyzovať iba časové rady, ktoré nám neskôr vstúpia do modelov s členom korigujúcim chyby (model pre konečnú spotrebu domácností). Keďže nemusíme testovať stacionaritu umelých premenných (sezónne premenné, trend), ostávajú nám k dispozícii časové rady konečnej spotreby domácností a mzdovej bázy. Mzdovú bázu vypočítame ako podiel násobku miezd vo vybraných odvetviach (W9BI) so zamestnanosťou vo vybraných odvetviach (LD9BI) a indexu spotrebiteľských cien. Ide teda o mzdovú bázu v stálych cenách,

resp. reálnu mzdovú bázu (suma všetkých miezd v odvetviach). Oba časové rady (konečná spotreba domácností, reálna mzdová báza) sa stanú súčasťou spoločnej skupiny `__ADFTESTY`. Pomocou príkazu `FREEZE` si vytvoríme najprv dva náhľady, prvým náhľadom bude jednoduchý graf oboch časových radov, aby sme mohli porovnať ich vývoj a druhým náhľadom korelogram jednoduchých korelácií medzi premennými. Graf vytvoríme príkazom `LINE`, pričom znak „n“ v zátvorke znamená, že graf bude normalizovaný, pre ľahšiu porovnateľnosť. Korelogram vytvoríme pomocou príkazu `COR`, rovnako ako príponu za názov skupiny časových radov oddelený bodkou. Korelogram slúži na odhalenie prípadnej multikolinearity medzi vysvetľovanou a vysvetľovanými premennými v regresnej rovnici. Ďalšie štatistiky zistíme na matematicky upravených časových radoch. Pôjde o testy jednotkového koreňa (test stacionarity) v rovnakej forme, v akej sa bude vyskytovať v rovniciach – v logitmickej transformácii. Jednotlivé časové rady zo skupiny `__ADFTESTY` extrahujeme opäť pomocou cyklu `FOR..NEXT` a kombinácie skalárnej a reťazcovej veličiny. V prvom kroku transformujeme časové rady na logaritmované pomocou príkazu `SERIES`, pričom pridáme na začiatok časových radov predponu `T`. Ďalšie štyri príkazy sú už náhľadmi na jednotlivé transformované časové rady pomocou príkazu `FREEZE`. V zátvorke za príkazom `FREEZE` uvádzame názov tabuľky, pod ktorým nám vznikne náhľad. Pre ľahšiu identifikáciu priradíme k jednotlivým tabuľkám predpony `_ADF0`, `_ADF1`, `_PP0` a `_PP1` (`ADF`=Augmented Dickey-Fuller test, `PP` = Phillip-Perron test, `0` = level, `1` = prvá diferenciácia časového radu). Za zátvorkou s názvom novej tabuľky píšeme názov časového radu, ktorého náhľad ideme vytvoriť. Keďže sme v predošlom kroku transformovali časové rady na logaritmy a nachádzame sa stále vnútri cyklu `FOR..NEXT` použijeme rovnakú identifikáciu časového radu ako za príkazom `SERIES`, teda `t{%1}` s identifikáciou reťazca. Príkaz `FOR..NEXT` nám aj tu vymení za reťazec `{%1}` názov časového radu v skupine `__ADFTESTY` aj s predponou `T`, teda už transformovaný časový rad do logaritmického tvaru. Testy na jednotkový koreň sú uvádzané pomocou príkazu `UROOT`, ktorý je oddelený od názvu časového radu bodkou. V zátvorke za príkazom `UROOT` sa môžu uvádzať náležitosti (možnosti) daného príkazu. Prednastavenými možnosťami sú `ADF` test a nulová diferenciácia časového radu, teda časový rad v úrovni (level). Preto v druhom až treťom prípade vnútri cyklu uvádzame `dif=1`, prípadne aj `pp` (teda `PP` test). Celý cyklus nám vytvoril štyri tabuľky z testov na jednotkové korene časových radov, ktoré nájdeme na začiatku pracovného súboru, nakoľko sme im priradili názvy so začiatkom na podčiarkovník `_`.

V ďalšej časti programu odhadneme dlhodobú regresnú rovnicu pre konečnú spotrebu domácností, ktorá bude neskôr východiskom pre krátkodobú regresnú rovnicu v tvare `ECM`, teda modelu s členom korigujúcim chyby. V Programe 2.1 sme si vybrali vzťah pre konečnú spotrebu domácností, ktorý bol súčasťou finálnej verzie dokumentu z roku 2010 [Haluška a kol., 2010]. Pre dlhodobú rovnicu musíme v prvom kroku vytvoriť objekt koeficientov `CC00` pre odhadnuté parametre z dlhodobej regresnej rovnice. Dlhodobú rovnicu nazveme `_ECMLONG` a odhadneme pomocou metódy najmenších štvorcov (`LS`) a príkazu `EQUATION` na vytvorenie objektu rovnice. Objekt rovnice je vytvorený priamo reprezentáciou log-lineárneho vzťahu. Do objektu časového radu s názvom `_RESIDCBI` uložíme pomocou príkazu `MAKERESID` i reziduá z tejto odhadnutej dlhodobej rovnice. V predošlých podkapitolách sme si rozobrali testy rezíduí na stacionaritu a heteroskedasticitu. Tieto vytvoríme pomocou príkazu `FREEZE` z náhľadov na reziduá, teda časový rad rezíduí s názvom `_RESIDCBI`. Prvý príkaz `FREEZE` slúži priamo na grafický náhľad na časový rad, aby sme mohli výsledky testov porovnať s tvarom danej krivky. Ďalšie dva príkazy sú v kombinácii s príkazom na testy stacionarity (existencie jednotkového koreňa) `UROOT`. V prvom prípade pomocou východiskového `ADF` testu a v druhom prípade `PP` testu. Oba príkazy testujú časový rad rezíduí bez konštanty a lineárneho trend (náliežitosť príkazu `UROOT` „none“ v zátvorke za príkazom). Štvrtým príkazom je príkaz `WHITE` na test prítomnosti heteroskedasticity v reziduách. Pre indikáciu

existencie kointegrácie medzi premennými v dlhodobom vzťahu testujeme časové rady v skupine __ASFTESTY na kointegráciu, pričom v Johansenovom teste využívame možnosť „d“ pre predpoklad trendu v kointegračnej rovnici i v dátach. Do testu zahrňame i sezónne premenné SD3 a SD4, ktoré uvedieme za znak „@“ a medzeru. Výsledky Johansenovho testu (jeden nájdený kointegračný vektor) uložíme v objekte _COINTEG.

V ďalšom bloku Programu 2.1 píšeme program pre odhad krátkodobej rovnice v tvare ECM, konkrétne finálneho modelu na konečnú spotrebu domácností. Rovnako ako v predošlom prípade musíme pred odhadom rovnice vytvoriť objekt koeficientov a po odhade uložiť reziduá. Rovnako si vytvoríme jednoduchý grafový objekt zachytávajúci reziduá z finálneho krátkodobého ECM vzťahu pomocou príkazu FREEZE a RESIDS. Následne dva príkazy pre testy na jednotkový koreň rezíduí na potvrdenie kvality odhadnutého modelu a test na heteroskedasticitu (WHITE). Poslednými testami sú testy na autokoreláciu rezíduí z rovnice, nakoľko Durbin-Watsonova štatistika z výstupu rovnice nie je pri krátkodobých rovniciach platná. Prvým z nich je korelogram autokorelácií a parciálnych korelácií (Q-štatistika) pomocou príkazu CORREL s uvedením možnosti počtu oneskorení v zátvorke za príkazom, druhým je LM test na autokoreláciu pomocou príkazu AUTO a stanovením rádu korelácie v zátvorke za príkazom.


Ďalší odsek sa zaoberá výpočtom prognózy z modelu ECM (z výslednej krátkodobej rovnice), t.j. tzv. rýchlym odhadom konečnej spotreby domácností, ktorý sa realizuje každý štvrt'rok na základe vývoja agregácie mesačných ukazovateľov. Keďže predpokladáme, že v dobe rýchleho odhadu poznáme všetky informácie, ktoré sú na pravej strane rovnice, môžeme spraviť prognózu konečnej spotreby domácností na daný štvrt'rok (jedno pozorovanie dopredu). Výpočet prognózy realizujeme zložitejšiou schémou a to pomocou dvojitého cyklu FOR..NEXT. Táto schéma nám rovnako simuluje prognózy pre predošlé štvrt'roky od roku 2007, aby sme mohli následne po tomto cykle porovnať kvalitu dynamickej a statickej prognózy za dané obdobie. Vonkajší hlavný cyklus, ktorý sa začína v prvom riadku výrazom FOR bude využívať reťazcovú premennú, definovanú v našom prípade ako %1. Tento reťazec bude postupne predstavovať jednotlivé štvrt'roky – teda výraz 2007q1, 2007q2 atď. Reťazec využijeme v stanovení obdobia odhadu (bez zloženej zátvorky) alebo ako pridanie prípony za názov prognózovaného časového radu či na konci cyklu na dosadenie prognózy do nového časového radu (v zloženej zátvorke). V prvej časti cyklu (výpočet prognózy) vyrátame pomocou príkazov FIT a FORECAST prognózu krátkodobých rovníc aj s následným uvedením názvov časových radov vytvorených z prognózy. Oba následne pridáme (ADD) do skupiny časových radov vytvorenej tesne pred začiatkom cyklu s názvom RESULTS. V druhej časti cyklu iniciujeme vnorený cyklus, ktorý nám pomôže vyrátať z prognózovaných časových radov (indexov) medziročné rasty. Vnútorňý cyklus bude rovnako ako vonkajší využívať reťazec definovaný tentoraz ako %2. Výsledkom vnútorného cyklu budú časové rady s predponou X, ktoré budú predstavovať percentuálne prognózované rasty konečnej spotreby domácností pomocou dynamickej i statickej prognózy na obdobie stanovené v rozsahu súboru, t.j. od roku 2007 po koniec roka 2009. V poslednej časti vonkajšieho cyklu vyjmeme z konkrétneho štvrt'roka prognózu (pomocou príkazu @ELEM) a dosadíme prognózy za uvedené obdobie do časového radu. Výsledkom budú dva časové rady, jeden pre statické prognózy AA_CBIST a druhý pre dynamicke prognózy AB_CBIDY.

V časti „dodatkové výpočty“ iba vytvoríme časový rad s názvom CBIYOY, ktorý bude predstavovať medziročné rasty v % pôvodného časového radu konečnej spotreby domácností (bázického indexu). V „záverečnom porovnaní“ vytvoríme grafový objekt dvoch finálnych časových radov pre jednotlivé typy prognózy a následne vo „vyhodnotení prognózy“ toto porovnanie realizujeme v matematickej forme pomocou výpočtu vzorcov pre priemernú absolútnu (MAE) a priemernú štvorcovú odchýlku prognóz od reality (RMSE). Jednotlivé

vzorce musíme rozpisovať do viacerých riadkov, nakoľko niektoré majú charakter objektu typu skalár (SCALAR) a niektoré charakter objektu časového radu (SERIES).

Na obrázku 2.18 môžeme vidieť výstup z grafického objektu porovnávajúci prognózy dynamické so statickými prognózami konečnej spotreby domácností v porovnaní s realitou (zelená krivka zvýraznená prostredníctvom Menu).

Obr. 2.18 Porovnanie prognózy konečnej spotreby domácností z ECM modelu



3. ARIMA modelovanie

ARIMA modelovanie patrí medzi často využívané metódy modelovania časových radov v prípade, že pre modelovaný časový rad nie sú k dispozícii žiadne vhodné vysvetľujúce premenné. Prognostický model je v takom prípade založený na 3 základných stavebných nástrojoch – štatistických procesoch.

Prvým nástrojom je AR (autoregressive) člen alebo tzv. autoregresný proces. Často používaný AR(1) model je autoregresným procesom 1. rádu, ale vo všeobecnosti je možné používať aj dodatočné AR členy vyšších rádov. Každý člen AR v prognostickom modeli zodpovedá časovo posunutej hodnote modelovaného časového radu (y_t). Autoregresný model rádu p , AR(p) má potom nasledujúci tvar:

$$y_t = \rho_1 y_{t-1} + \rho_2 y_{t-2} + \dots + \rho_p y_{t-p} + \varepsilon_t$$

kde ε_t je náhodná chybová zložka.

Druhým nástrojom je člen predstavujúci stupeň integrácie časového radu (I - integrated). Každý stupeň integrácie zodpovedá určitému stupňu diferencovania prognózovaného časového radu. Časový rad integrovaný 1. stupňa znamená, že pôvodný časový rad je transformovaný do podoby prvých diferencií. Časový rad integrovaný 2. stupňa zodpovedá použitiu druhých diferencií atď.

Člen MA (moving average) predstavuje posledný, tretí nástroj a nazýva sa aj modelom kľazových priemerov. MA model využíva časovo posunuté hodnoty chýb predikcie na zlepšenie súčasnej prognózy. MA člen 1. rádu využíva najaktuálnejšiu chybu predikcie, MA člen 2. rádu prognózu z dvoch najaktuálnejších období atď. MA(q) model, teda MA model rádu q má nasledujúci tvar:

$$y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

Špecifikácie AR a MA je možné kombinovať do ARMA(p, q) špecifikácie:

$$y_t = \rho_1 y_{t-1} + \rho_2 y_{t-2} + \dots + \rho_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

Aplikácia popísaných procesov priamo na jeden vybraný časový rad vedie k získaniu modelu jednej premennej, ktorý uvažuje podmienenú strednú hodnotu ako konštantu a rezíduá získava ako odchýlky časového radu od svojho priemeru.

3.1 Princípy ARIMA modelovania

Základné princípy ARIMA modelovania definovali Box a Jenkins v roku 1976 a preto v tomto prípade hovoríme aj o tzv. Box-Jenkinsovej metodológii. Pri ARIMA modelovaní sa prostredníctvom tejto metodológie zostavuje kompletný prognostický model kombináciou troch typov nástrojov popísaných vyššie.

Prvým krokom v tvorbe ARIMA modelu je analýza autokorelačných vlastností modelovaného časového radu. Na tento účel je možné použiť **korelogram** časového radu. Príklad korelogramu pre mesačný časový rad bazického indexu stavebnej produkcie v stálych cenách (ISP) môžeme vidieť na obr. 3.1, ktorý je zostrojený v pracovnom súbore ISP.WF1 výberom z menu časového radu View/Correlogram... alebo je možné využiť príkaz CORREL, ktorého všeobecný zápis je nasledovný:

¹⁰ Niektorí autori príp. programové systémy zvyknú používať opačné znamienka pre MA koeficienty.


názov_časového_radu.correl(n, možnosť)

Príkaz zobrazí autokorelačnú funkciu a parciálnu autokorelačnú funkciu vybraného časového radu spolu s Q štatistikou a hladinou významnosti pre každý posun n (lag). Hodnota n teda špecifikuje najvyšší posun, do ktorého sa autokorelácie zobrazia na grafe. V rámci možností korelogramu je možné zvoliť priamo tlač korelogramu, ak zvolíme možnosť p .

Nasledujúci príkaz zostrojí korelogram časového radu ISP až do posunu 24. V prípade mesačných časových radov je vhodné mať pre analýzu k dispozícii aspoň 2 celé roky, aby bolo možné analyzovať v časovom rade aj vývoj sezónnosti.

`isp.correl(24)`

Obr. 3.1 Korelogram pôvodného časového radu ISP



Štatisticky významné koeficienty autokorelácie (t.j. koeficienty prekračujúce hranice spoľahlivosti), ktoré neklesajú rýchlo k 0, poukazujú na nestacionárny časový rad. Navyše kolísavý, cyklický korelogram so sezónnou frekvenciou indikuje použitie sezónneho ARMA modelu pre analyzovaný časový rad ISP.

Fáza určovania parametrov ARIMA modelu sa nazýva identifikácia. Charakter korelácie (závislosti) medzi súčasnými a minulými hodnotami časového radu poskytuje návod pre výber vhodnej špecifikácie. Základnou podmienkou použitia ARMA modelov je stacionarita časového radu¹¹ a preto je potrebné analyzovať uvažovaný časový rad najskôr z tohto hľadiska.

Ak pôvodný časový rad nie je stacionárny, na stacionarizáciu jeho úrovne slúži druhý nástroj spomenutý vyššie a to diferencovanie časového radu. Pre stacionarizáciu variability časového radu sa používajú vhodné analytické transformácie, napr. logaritmická transformácia.

Diferencovanie

Na diferencovanie časových radov sa v EViews-e používa operátor **d**. Ak chceme získať prvé diferencie, jednoducho použijeme názov časového radu v zátvorkách po **d**, napr. **d(ISP)** predstavuje 1. diferencie časového radu ISP alebo **ISP-ISP(-1)**. Ak chceme špecifikovať diferencie vyšších rádov, zadávame rád diferencie do zátvorky za názov časového radu: **d(X,n,s)** kde **n** predstavuje n-tú diferenciu časového radu **X** a **s** predstavuje stupeň sezónneho diferencovania, ak je pôvodný časový rad nestacionárny v sezónnej úrovni (ako je to aj v prípade časového radu ISP). Napr. **d(X,0,4)** špecifikuje 1. sezónne diferencie štvrt'ročného časového radu **X** alebo **X-X(-4)**, pričom obyčajné diferencie sa nevyužívajú.

Ak potrebujeme pracovať s logaritmovanými hodnotami, je možné použiť operátor **dlog**, ktorý vracia diferencie logaritmovaných hodnôt. Napr. **dlog(X)** špecifikuje 1. diferencie **log(X)** alebo **log(X)-log(X(-1))**. Rovnako ako v prípade jednoduchého **d** operátora je možné zvoliť parametre **n** a **s**, **dlog(X,n,s)**.

Obr. 3.2 predstavuje korelogram už stacionarizovaného časového radu ISP po nasledujúcej úprave:

```
series sdliisp=dlog(isp,1,12)
sdliisp.correl(24)
```

Autokorelácie (Autocorrelation) sa interpretujú ako korelačné koeficienty súčasnej hodnoty časového radu s hodnotou posunutou o určitý počet období. Parciálne autokorelácie (Partial Correlation) majú trochu zložitejšiu interpretáciu, keďže merajú pridanú koreláciu súčasného a posunutého časového radu. Napr. parciálna autokorelácia pre posun 4 meria pridanú prognostickú silu časového radu y_{t-4} v prípade, keď časové rady y_{t-1} , ..., y_{t-3} sú už v modeli zahrnuté. V skutočnosti zodpovedá parciálna autokorelácia presne regresnému koeficientu časového radu y_{t-4} v regresii, v ktorej už vystupujú aj všetky predchádzajúce časové rady s menšími posunom


Na základe korelogramu stacionárneho časového radu je teda možné identifikovať vhodné parametre a navrhnúť potenciálne ARIMA modely. Ak autokorelačná funkcia plynulo klesá, zaniká geometrickým radom a parciálne autokorelácie od posunu 1 sú nulové, je vhodné použiť autoregresný model 1. rádu. Alebo ak sú autokorelácie nulové od posunu 1 a parciálne autokorelácie geometricky klesajú, prichádza do úvahy proces kľzavých priemerov 1. rádu. Zjednodušene je možné zovšeobecniť, že počet štatisticky významných koeficientov

¹¹ Časový rad sa považuje za stacionárny, ak sa jeho štatistické vlastnosti (priemer, variabilita) v čase nemenia.

autokorelácie určuje rád MA modelu a počet štatisticky významných parciálnych koeficientov autokorelácie určuje rád AR modelu. Ak majú autokorelácie sezónny vzor, ponúka sa použitie sezónnej ARMA špecifikácie.

V prípade nášho vzorového časového radu ISP (v stacionarizovanej podobe) môžeme na základe štatisticky významných koeficientov autokorelácie uvažovať MA parametre 1. až 8. stupňa a na základe štatisticky významných parciálnych koeficientov autokorelácie AR parametre 1. až 4. stupňa. Navyše aj autokorelačný koeficient na mieste so sezónnym posunom (teda s posunom 1 roka) je štatisticky významný, čo určuje vhodnosť použitia sezónneho MA modelu. Na základe kombinácií uvedených parametrov môžeme odhadnúť rôzne typy ARIMA modelov.

Obr. 3.2 Korelogram stacionarizovaného časového radu ISP



Avšak treba mať na pamäti, že pridávanie parametrov do modelu síce zvyšuje jeho presnosť, ale cieľom ARIMA analýzy je čo najúspornejšia reprezentácia procesu, ktorý generuje daný časový rad. Po odhade ARIMA modelov sa preto pristupuje k ich overovaniu a nájdeniu čo najúspornejšej verzie modelu s najvyššou vypovedacou schopnosťou, teda nájdenie najlepšej kombinácie medzi jednoduchosťou a presnosťou modelu (kapitola 3.3).

3.2 Odhad ARIMA modelov

Pri odhade ARIMA modelov vstupujú do špecifikácie rovnice okrem diferencovaného časového radu (postup diferencovania v EViews-e je popísaný v predchádzajúcej kapitole) ešte AR a MA procesy.

AR a MA modely

AR a MA časti modelu sa v rovnici špecifikujú pomocou kľúčových slov **ar** a **ma**. Tradičné ARMA modely neobsahujú žiadnu inú premennú na pravej strane rovnice okrem konštanty. V tomto prípade bude zoznam regresorov rovnice obsahovať len konštantu a AR a MA parametre. Napr. `c ar(1) ar(2) ma(1) ma(2)` je štandardný Box-Jenkinsov model ARMA(2, 2).

Sezónne autoregresné členy (**sar**) a sezónne členy kľzavých priemerov (**sma**) sa odporúča použiť v prípade časových radov so systematickou sezónnosťou. Napr. v prípade mesačných časových radov: `c ar(1) sar(12)` sa jedná o sezónny model ARMA(1, 0)(1, 0)₁₂.

Pri odhade modelu s ARMA parametrami používa EViews automaticky nelineárne metódy odhadov. Štandardne sa používa nelineárna metóda najmenších štvorcov (NLS – Nonlinear Least Squares). Nelineárne metódy odhadov si vyžadujú nastavenie východiskových hodnôt koeficientov (starting values). V prípade odhadov modelov s ARMA parametrami sú východiskové hodnoty koeficientov nastavené ako odhady z OLS aplikovanej na zjednodušenú verziu modelu (obr. 3.3) (viac o možnostiach východiskových hodnôt koeficientov je možné nájsť v odkazoch na odhad nelineárnych modelov pomocou nelineárnej metódy najmenších štvorcov - NLS).

Pomocou dialógového okna *Options v Equation Estimation* je možné kontrolovať iteratívny proces odhadu. Vzhľadom na technickú náročnosť tejto problematiky sa nebudeme venovať všetkým možnostiam (podrobnejšie sú vysvetlené v Help-e programu). Jedna z možností okna sa týka výlučne MA modelov, ktoré sa vo všeobecnosti ťažko odhadujú.


Ak sa do modelu zahrnie priveľa MA členov, môže sa znížiť počet stupňov voľnosti a ohroziť stabilita a spoľahlivosť odhadov. Preto je pri špecifikácii modelu potrebné vyhnúť sa vysokým rádom MA členov, pokiaľ nie sú vyslovene nevyhnutné. Napr. ak je autokorelačný koeficient s posunom 32 vysoko štatisticky významný (v korelograme by sme v tomto období mohli vidieť vysoký vrchol), neznamená to, že musíme nevyhnutne zahrnúť člen MA(32) do modelu, pokiaľ sa pravidelne v každom 32. období nedialo niečo mimoriadne. Pravdepodobnejšie je, že vysoká autokorelácia je jednoducho výsledkom jednej alebo viacerých extrémnych hodnôt v analyzovanom časovom rade.

Ak EViews pri odhade modelu s MA členmi zobrazí chybové hlásenie, že nemôže zlepšiť súčet štvorcov (sum-of-squares) alebo že konvergencia modelu zlyhala pri maximálnom počte iterácií (opakovaní), môže to byť znakom, že dáta sú príliš diferencované. Vtedy je

potrebné znova skontrolovať korelogram časového radu a zistiť, či nie je možné odhad zopakovať pri menšom počte diferencií.

Ak aj napriek tomu problémy pri odhade pretrvávajú, je možné vypnúť voľbu Backcast MA terms (spätné predpovedanie MA členov).

Obr. 3.3 Ponuka nastavení pri odhade ARIMA modelu



Ak odhadujeme integrovaný model, teda ARMA model pre časový rad, ktorý musel byť z dôvodu stacionarizácie diferencovaný, existujú v EViews-e dva možné spôsoby odhadu. Prvým spôsobom je generovanie nového časového radu, ktorý obsahuje diferencované dáta a tento nový časový rad sa použije pri odhade ARMA modelu. Napr. model ARIMA(1, 1, 1) pre časový rad M môžeme odhadnúť nasledovným spôsobom:

```
series dm = d(m)
equation eq1.ls dm c ar(1) ma(1)
```

Druhou alternatívou je zahrnutie operátora diferencovania d do špecifikácie rovnice. Napr. rovnaký model ARIMA(1,1,1) môžeme odhadnúť aj pomocou nasledujúceho príkazu:

```
equation eq2.ls d(m) c ar(1) ma(1)
```

Ak chceme používať odhadnutý model na prognózovanie, je vhodnejšie používať druhý uvedený spôsob. Pretože ak definujeme novú premennú, napr. DM z nášho príkladu vyššie a použijeme ju pri odhade modelu, pri prognózovaní z odhadnutého modelu bude EViews

prognózovať závisle premennú DM. To znamená, že získame prognózu pre diferencovaný časový rad. V takom prípade, ak chceme získať prognózy pôvodnej premennej, v tomto prípade M, bude potrebné manuálne transformovať prognózované hodnoty a teda aj upraviť vypočítané štandardné chyby. Navyše ak sú nejaké iné transformácie alebo posuny M zahrnuté ako regresory, EViews nebude vedieť identifikovať, že sú vo vzťahu k M. Takže ak v špecifikácii modelu použijeme operátor diferencovania pre závisle premennú, $d(m)$, procedúra prognózovania (Forecast z menu odhadnutého modelu) poskytuje možnosť zvoliť prognózu pôvodnej premennej, v našom prípade M.

Nasledujúcim príkazom odhadneme jeden z identifikovaných modelov pre časový rad ISP:

```
equation isp_211_011.ls dlog(isp,1,12) ar(1) ar(2) ma(1) sma(12)
```

Na obr. 3.4 môžeme vidieť výstup z odhadu modelu $ARIMA(2, 1, 1)(0, 1, 1)_{12}$ pre časový rad ISP. Výstup z odhadu s AR a MA špecifikáciami je rovnaký ako v prípade metódy najmenších štvorcov, ale tabuľka je rozšírená o spodnú časť, ktorá obsahuje navyše inverzné korene AR a MA polynómov. Tieto výsledky slúžia na overenie základných podmienok, ktoré majú spĺňať procesy AR a MA – podmienka stacionarity pre AR procesy a podmienka invertibility pre MA procesy (bližšie je splnenie týchto podmienok popísané v nasledujúcej kapitole týkajúcej sa overovania modelu).

Interpretácia odhadov pre ARIMA modely sa mierne odlišuje od interpretácie v prípade regresných modelov. Kým odhadnuté koeficienty, ich štandardné chyby a t štatistiky môžeme interpretovať obvyklým spôsobom, výsledky týkajúce sa rezíduí sa líšia. S ARIMA modelmi sa totiž spájajú dva rôzne typy rezíduí. Prvé rezíduá sú rovnaké ako v prípade OLS pre regresné modely, ktoré sa vypočítajú ako rozdiel pôvodných a odhadnutých hodnôt za minulosť. Tieto rezíduá predstavujú chyby, ktoré by sme pozorovali, ak by sme urobili predikciu na základe súčasnej informácie, ale neuvažovali by sme informáciu, ktorá je obsiahnutá v posunutých rezíduách. Tento prvý typ rezíduí EViews v prípade ARIMA modelov automaticky nepočíta. Druhý typ rezíduí je chybou prognózy na jedno obdobie dopredu. Tieto rezíduá reprezentujú chybu prognózy, ktorá by vznikla, ak by sa pri prognóze použila aj predikcia rezíduí založených na minulých hodnotách a nielen súčasná informácia. V ARIMA modeloch sú potom regresné štatistiky – ako sú štandardná chyba regresie a Durbin-Watson štatistika založené na chybách prognózy na jedno obdobie dopredu.

Obr. 3.4 Výstup odhadu modelu ARIMA(2, 1, 1)(0, 1, 1)₁₂

Equation: ISP_211_011 Workfile: ISP\Monthly				
View Proc Object Print Name Freeze Estimate Forecast Stats Resids				
Dependent Variable: DLOG(ISP,1,12)				
Method: Least Squares				
Date: 03/30/10 Time: 08:09				
Sample (adjusted): 2001M04 2010M01				
Included observations: 106 after adjustments				
Convergence achieved after 12 iterations				
Backcast: 1998M12 1999M12				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.933212	0.176554	-5.285717	0.0000
AR(2)	-0.399774	0.092287	-4.331866	0.0000
MA(1)	0.585840	0.184364	3.177633	0.0020
SMA(12)	-0.863329	0.034722	-24.86381	0.0000
R-squared	0.441824	Mean dependent var	-0.001749	
Adjusted R-squared	0.425407	S.D. dependent var	0.075210	
S.E. of regression	0.057010	Akaike info criterion	-2.854159	
Sum squared resid	0.331520	Schwarz criterion	-2.753651	
Log likelihood	155.2704	Durbin-Watson stat	1.888762	
Inverted AR Roots	-.47-.43i	-.47+.43i		
Inverted MA Roots	.99	.86-.49i	.86+.49i	.49-.86i
	.49+.86i	-.00-.99i	-.00+.99i	-.49-.86i
	-.49+.86i	-.59	-.86+.49i	-.86-.49i
	-.99			

3.3 Overovanie (verifikácia) ARIMA modelov (Diagnostics)

Po odhade potenciálnych ARIMA špecifikácií je potrebné odhadnuté modely overiť, či spĺňajú všetky podmienky kvality tohto typu modelov a či nie je ešte potrebné upraviť navrhnuté špecifikácie modelov. EViews poskytuje širokú paletu diagnostickej kontroly po každom odhade.

Stacionarita a invertibilita

Ako už bolo uvedené v predchádzajúcej kapitole AR procesy by mali spĺňať podmienku stacionarity. Pre jednoduchý AR(1) model by mal odhad jeho parametra ρ_1 ležať v intervale $(-1,1)$, vtedy môžeme hovoriť o stacionárnom AR procese. Ak je absolútna hodnota parametra väčšia ako 1, autoregresný proces je explozívny. Podmienkou stacionarity pre AR procesy všeobecne je, že inverzné (obrátené) korene AR polynómu posunutých hodnôt musia ležať vnútri jednotkového kruhu. EViews tieto korene zobrazí pod názvom **Inverted AR Roots** v spodnej časti tabuľky odhadu modelu.


Na druhej strane, MA procesy by mali spĺňať podmienku invertibility. Ak má polynóm MA procesu inverzné korene (**Inverted MA Roots**) mimo jednotkového kruhu, môžeme povedať, že MA proces nie je invertibilný, čo sťažuje interpretáciu a využitie výsledkov pre MA proces. Avšak podľa teórie existuje vždy ekvivalentná interpretácia MA modelu, kde recipročné korene ležia vo vnútri jednotkového kruhu (Hamilton, 1994, str. 65). Preto je v takom prípade potrebné znovu odhadnúť model s inými východiskovými hodnotami, pokiaľ nezískame MA proces spĺňajúci požiadavku invertibility, alebo je možné vypnúť možnosť spätného predpovedania (MA backcasting).

Ak sa korene MA procesu v absolútnej hodnote blížia k 1, je to znakom prehnane diferencovaných údajov. Takýto proces bude predstavovať problém pri odhade modelu a aj pri prognózovaní. Ak je to možné, je potrebné takýto proces odhadnúť znova pre menej diferencované dáta.

Oba typy inverzných koreňov (AR aj MA) môžu byť komplexné čísla a ich absolútna hodnota by nemala byť väčšia ako 1. Vo výstupe odhadu modelu vypíše EViews oznam, ak niektorý typ procesu nespĺňa požadovanú podmienku, či už invertibility alebo stacionarity.


Ďalšou možnosťou kontroly inverzných koreňov je aj ich grafické alebo tabuľkové zobrazenie pomocou voľby z panela nástrojov odhadu rovnice View/Arma Structure..., ktoré ponúka aj možnosť Roots (obr. 3.5). Tento diagnostický náhľad na ARMA štruktúru modelu je k dispozícii iba v prípade modelov, ktoré obsahujú aspoň jeden AR alebo MA člen.

Obr. 3.5 Menu pre diagnostiku modelov s ARMA štruktúrou



Inverzné korene z odhadu modelu $ARIMA(2,1,1)(0,1,1)_{12}$ pre časový rad ISP sú zobrazené na obr. 3.6.

Obr. 3.6 Inverzné korene modelu $ARIMA(2, 1, 1)(0, 1, 1)_{12}$ pre časový rad ISP



Inverzné korene sú zobrazené v komplexnej rovine, pričom horizontálna os predstavuje reálnu časť každého koreňa a vertikálna os jeho imaginárnu časť. Ako môžeme vidieť na obr. 3.6, ani jeden z inverzných koreňov sa nenachádza zvonka jednotkovej kružnice a preto môžeme povedať, že použitý AR proces je stacionárny a použitý MA proces invertibilný. Jednotlivé korene obsahuje aj tabuľkové zobrazenie, ktoré je možné zvoliť z diagnostickej ponuky na obr. 3.5 a to kliknutím na možnosť Table. Korene sú zobrazené zostupne od koreňa s najvyššou absolútnou hodnotou. Pre imaginárne (združené) korene sa v tabuľke navyše uvádza aj cyklus patriaci ku každému koreňu. Cyklus pre reálne korene je nekonečný a v tabuľke sa neuvádza.

Autokorelácia rezíduí


Najdôležitejším znakom správne špecifikovaného ARIMA modelu je skutočnosť, že v jeho rezíduách nezostala žiadna nevysvetlená autokorelácia (rezíduá by mali mať približne vlastnosti bieleho šumu). Predmetom skúmania sú autokorelácie aj parciálne autokorelácie inovácií (rezíduí z odhadnutého ARIMA modelu). Durbin-Watsonova štatistika zobrazovaná vo výstupe odhadu modelu je testom pre AR(1) proces (v prípade, že v modeli nie je zahrnutá posunutá závisle premenná). Avšak v EViews-e sa používajú aj iné všeobecnejšie testy pre autokoreláciu rezíduí.

Ak sa v príkaze CORREL použije namiesto názvu časového radu názov rovnice, zobrazí príkaz korelogram rezíduí z danej rovnice:

```
equation isp_211_011.ls dlog(isp,1,12) ar(1) ar(2) ma(1) sma(12)
isp_211_011.correl(12)
```

Testy pre autokoreláciu rezíduí môžeme nájsť aj v paneli nástrojov modelu *View/Residual Tests/* a to konkrétne *Correlogram-Q-statistic* a *Serial Correlation LM Test...* Korelogram rezíduí na 12 období pre odhad modelu uvedeného na obr. 3.4 môžeme vidieť na obr. 3.7, ktorý zodpovedá aj výstupu z príkazu CORREL uvedeného vyššie.

Obr. 3.7 Korelogram rezíduí ARIMA modelu odhadnutého na obr. 3.4



Ak by niektorý z koeficientov prekročil hladinu významnosti, znamená to, že v modeli existuje v reziduách závislosť, ktorú je potrebné ešte vysvetliť. Napr. v našom prípade sú 4. koeficient autokorelácie a parciálnej autokorelácie tesne pod hladinou významnosti, avšak následné koeficienty nie sú štatisticky významné (okrem prvého nasledujúceho) a preto už nie je potrebné ďalej meniť špecifikáciu modelu. Môžeme teda zovšeobecniť, že ak už v reziduách nie je žiadna autokorelácia, koeficienty autokorelácie a parciálnej autokorelácie pre všetky posuny by sa mali blížiť k nule a všetky testovacie štatistiky Q by mali byť vysoko štatisticky nevýznamné (s vysokou pravdepodobnosťou).

Ďalšou alternatívou pre testovanie autokorelácie rezíduí je LM test autokorelácie časových radov, ktorý sa používa v prípade AR modelov vyšších rádo (t.j. ak je v modeli zahrnutá aj časovo posunutá závisle premenná). Okrem už spomenutej ponuky z panelu nástrojov odhadu rovnice (View/Residual Tests/Serial Correlation LM Test...) môžeme použiť aj príkaz AUTO. Jeho všeobecný syntax je nasledovný:

```
názov_rovnice.auto(stupeň autokorelácie, možnosti)
```

V zátvorke príkazu je potrebné špecifikovať stupeň autokorelácie, ktorú chceme otestovať a môže nasledovať aj možnosť vytlačiť výstup pomocou kľúčového písmena *p*.

```
equation isp_211_011.ls dlog(isp,1,12) ar(1) ar(2) ma(1) sma(12)
isp_211_011.auto(12)
```

Obrázok 3.8 predstavuje výstupnú tabuľku testu autokorelácie rezíduí z modelu ARIMA(2,1,1)(0,1,1)₁₂ pre časový rad ISP.

LM test autokorelácie patrí do skupiny asymptotických testov (testov veľkých výberov), ktoré sú známe ako testy Lagrangeovho násobiteľa (Lagrange multiplier). Na rozdiel od Durbin-Watsonovej štatistiky pre AR(1) procesy, LM test sa môže použiť aj pre testovanie vyšších rádo ARMA procesov a je ho možné použiť aj bez ohľadu na to, či sa v modeli vyskytuje posunutá závisle premenná. Z toho dôvodu sa v prípade testovania autokorelácie rezíduí modelu prednostne odporúča použiť LM test.

Nulová hypotéza LM testu je taká, že v testovanom časovom rade neexistuje autokorelácia až do posunu, ktorý je špecifikovaný stupňom autokorelácie. Testovacia štatistika je založená na regresii rezíduí od pôvodných regresorov a posunutých rezíduí až do určitého rádu. EVIEWS ponúka 2 testovacie štatistiky z tohto typu regresie. F štatistika je testom vynechanej premennej spoločného významu všetkých posunutých rezíduí. Keďže vynechávané premenné sú rezíduá a nie nezávisle premenné, presné rozdelenie F štatistiky v zmysle nulovej hypotézy nie je známe, ale uvádza sa z dôvodov porovnávania.

Uvádzaná štatistika Obs*R-squared je testovacou štatistikou Breusch-Godfrey LM testu. LM štatistika sa vypočíta ako počet pozorovaní vynásobený R^2 z vyššie spomenutej regresie testu. Za relatívne všeobecných podmienok má LM štatistika distribučné rozdelenie χ^2 .

LM test autokorelácie je k dispozícii buď pre rezíduá z OLS alebo dvojstupňovej OLS. Pôvodná regresia môže zahrňať aj AR a MA členy a v takom prípade sa testovacia regresia modifikuje tak, aby zohľadnila aj ARMA členy.

Ak test potvrdí autokoreláciu časového radu rezíduí, štandardné chyby odhadu metódou najmenších štvorcov nie sú platné a nemôžu sa použiť.

Pravdepodobnosť uvedená v tabuľke výstupu predstavuje hladinu významnosti, na ktorej nulovú hypotézu zamietame. To znamená, že v našom prípade (obr. 3.8) nie sú rezíduá autokorelované.

Obr. 3.8 Výstup LM testu autokorelácie rezíduí z modelu na obr. 3.4

Equation: ISP_211_011 Workfile: ISP\Monthly				
View	Proc	Object	Print	Name
Freeze	Estimate	Forecast	Stats	Resids
Breusch-Godfrey Serial Correlation LM Test:				
F-statistic	0.812092	Probability	0.637351	
Obs*R-squared	10.35618	Probability	0.584744	
Test Equation:				
Dependent Variable: RESID				
Method: Least Squares				
Date: 04/09/10 Time: 13:56				
Presample missing value lagged residuals set to zero.				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.026347	0.739566	-0.035625	0.9717
AR(2)	-0.122398	0.687691	-0.177984	0.8591
MA(1)	-0.689898	0.673469	-1.024395	0.3084
SMA(12)	-0.043561	0.042317	-1.029403	0.3060
RESID(-1)	0.736719	1.316844	0.559458	0.5772
RESID(-2)	-0.307075	0.518076	-0.592722	0.5549
RESID(-3)	0.104739	0.308917	0.339054	0.7354
RESID(-4)	-0.282478	0.228288	-1.237371	0.2192
RESID(-5)	0.084651	0.144318	0.586557	0.5590
RESID(-6)	-0.076641	0.131940	-0.580878	0.5628
RESID(-7)	0.032684	0.142108	0.229994	0.8186
RESID(-8)	0.081275	0.129320	0.628481	0.5313
RESID(-9)	0.106601	0.115402	0.923742	0.3581
RESID(-10)	-0.027862	0.112445	-0.247782	0.8049
RESID(-11)	-0.080497	0.111643	-0.721024	0.4728
RESID(-12)	0.176765	0.121839	1.450806	0.1503
R-squared	0.097700	Mean dependent var	-3.29E-05	
Adjusted R-squared	-0.052684	S.D. dependent var	0.056190	
S.E. of regression	0.057651	Akaike info criterion	-2.730552	
Sum squared resid	0.299130	Schwarz criterion	-2.328523	
Log likelihood	160.7192	Durbin-Watson stat	1.997284	

3.4 Prognózovanie z ARIMA modelov

Poslednou fázou pri použití ARIMA modelov je ich prognostická aplikácia. Pri tvorbe prognózy je možné využiť rovnaké možnosti ako v prípade ECM modelov. Jednotlivé možnosti konštrukcie prognóz sú podrobne popísané už v 1. kapitole príručky.

Pre ilustráciu uvádzame program (Program 3.1) pre vytvorenie ARIMA modelu pre jeden vybraný časový rad - HDP v stálych cenách (y00), pričom pri prognózovaní sa konštruuje statická prognóza na 1 štvrt'rok dopredu.

Program 3.1

```

***** nactanie udajov *****

smpl 1997q1 2010q2
read(t=xls, ad2, s=all1) "d:\Databazy\data_quarterly.xls" 1

***** testovanie stacionarity povodneho casoveho radu *****

graph graf1.line y00
freeze(kor_y00) y00.correl(24)
freeze(adf_test_y00) y00.uroot(trend)

***** testovanie stacionarity diferencovaneho casoveho radu *****

series sdly00=dlog(y00,1,4)
graph graf2.line sdly00
sdly00.correl(24)
freeze(adf_test_y00) y00.uroot(trend)

***** odhad a testy modelu *****

equation y00_011_011.ls dlog(y00,1,4) (1) sma(4)
y00_011_011.makesresid resid_y00
freeze(kor_resid_y00) resid_y00.correl(24)
freeze(lmtest_y00) y00_011_010.auto(12)

***** vypocet prognozy *****

smpl 2010q2 2010q2
y00_011_011.fit(f=actual) y00f_011_011

```

Ak by sme program aplikovaný pri odhade modelu HDP rozobrali na jednotlivé časti, prvý krok predstavuje načítanie samotného modelovaného časového radu z Excel-u do EViews-u. V druhom kroku je potrebné skonštruovať korelogram pôvodného časového radu a na jeho základe posúdiť stacionaritu uvažovaného časového radu. Ak o stacionarite nevieme rozhodnúť na základe korelogramu, prípadne priebehu samotného časového radu, môžeme použiť niektorý z testov stacionarity, napr. v tomto prípade Augmented Dickey-Fullerov test jednotkového koreňa. Keďže v prípade vybraného časového radu sa nepotvrdila jeho stacionarita, v ďalšom kroku bolo potrebné použiť stacionarizujúce transformácie (prvé sezónne aj nesezónne diferencie). Na základe korelogramu stacionarizovaného časového radu boli navrhnuté vhodné ARMA špecifikácie, ktoré sa použili pri odhade modelu (v našom programe uvádzame len odhad definitívnej verzie modelu). Všetky odhadnuté modely je potrebné otestovať spôsobom uvedeným v programe. Teda v prvom rade zistiť, či v rezíduách nezostala ešte nevysvetlená autokorelácia. Ak by sa ukázalo, že sa autokorelácia potvrdila, je potrebné zahrnúť do modelu ešte ďalšie vhodné ARMA členy.

Ak by sme mali k dispozícii viacero kvalitných odhadnutých modelov, pre prognostickú aplikáciu je najvhodnejšie použiť taký, ktorý dosahuje najlepšiu kombináciu presnosti a jednoduchosti. To znamená, že ak máme k dispozícii modely s približne rovnako veľkým vysvetleným rozptylom závisle premennej (R-squared), vyberieme taký, ktorý minimalizuje penalizačné miery (Schwarz criterion, Akaike info criterion), pričom prednosť má Schwarzovo kritérium.

3.5 ARIMAX modely

V ekonometrii sa ARIMA modely zvyčajne aplikujú na reziduá z regresného modelu a v takom prípade hovoríme o ARIMAX modeloch. V EViews-e je v prípade tohto typu modelov možné využiť na pravej strane rovnice ARIMA špecifikácie súčasne s vysvetľujúcimi premennými.

ARIMAX modely sú označované aj ako dynamická regresia a pri ich konštrukcii sa vychádza z jednoduchého regresného modelu jednej závisle premennej vysvetlenej jednou alebo viacerými nezávisle premennými. Ak sú reziduá z jednoduchého regresného modelu stacionárne, môžeme pre tento časový rad reziduí identifikovať vhodný ARMA model. V prípade nestacionárnych reziduí je možné využiť pre pôvodné časové rady vhodné transformačné postupy popísané vyššie (diferencovanie, prípadne vhodné matematické transformácie, napr. logaritmická transformácia).

Postup odhadu ARIMAX modelu predstavíme na konkrétnom príklade v programe 3.2. Predmetom modelovania je znova časový rad HDP v stálych cenách (y00), ktorého vývoj sme založili na časovom rade tržieb zisťovaných v mesačnej odvetvovej štatistike v 10 štatisticky sledovaných odvetviach.

Program 3.2

```
***** nactanie udajov *****

smpl 1997q1 2010q2
read(t=xls, ad2, s=all1) "d:\Databazy\data_quarterly.xls" 1
read(t=xls, fb2, s=all3) "d:\Databazy\data_quarterly.xls" 1

***** testovanie rezidui z jednoducheho regresneho modelu *****

smpl 2000q1 2010q2
equation y00_turn.ls y00 turn
y00_turn.makesresid rez_y00
freeze(kor_rez_y00) rez_y00.correl(24)
freeze(adf_test_rez_y00) rez_y00.uroot(none)

equation dy00_dturn.ls dlog(y00) dlog(turn)
dy00_dturn.makesresid rez_dy00
freeze(kor_rez_dy00) rez_dy00.correl(24)
freeze(adf_test_rez_dy00) rez_dy00.uroot(none)

***** odhad a testy ARIMAX modelu *****

equation y00_arimax.ls dlog(y00) dlog(turn) ma(1) sar(4)
y00_arimax.makesresid resid_y00
```


4. Zdroje

Drnáková L.: Ekonometrický model agregátneho dopytu Slovenskej Republiky, Fakulta matematiky, fyziky a informatiky UK v Bratislave, Bratislava, 2003.

EViews-Help - Copyright © 1994-2004 Quantitative Micro Software, LLC. All rights reserved. Help system build: April 16, 2004. <http://www.eviews.com>.

EViews 5 User's Guide, Quantitative Micro Software, LLC, 2004.

EViews 5 Command and Programming Reference

Haluška J., Olexa M., Juriová J., Kľúčik M.: [Modelový aparát na rýchle odhady vývoja makro-ekonomických ukazovateľov slovenskej ekonomiky \(Využitie makroekonomických a odvetvových informácií kvantitatívneho charakteru\)](#), Aktá č. 1, INFOSTAT, január 2010, ISBN 978-80-89398-14-0

Haluška J., Olexa M., Juriová J., Kľúčik M.: [Modelový aparát na rýchle odhady vývoja makro-ekonomických ukazovateľov slovenskej ekonomiky \(Využitie konjunkturálnych a spotrebiteľských prieskumov\)](#), Aktá č. 16, INFOSTAT, december 2008, ISBN 978-80-89398-06-5

Hamilton J. D.: Time Series Analysis. Princeton University Press, 1994.

Kľúčik M.: [Základy programovacieho jazyka EViews a ich aplikácia na analýzy, prognózy a rýchle odhady vývoja makroekonomických ukazovateľov, 1. časť](#), Dokumenty č. 1, INFOSTAT, január 2010, ISBN 978-80-89398-15-7

Kľúčik M., Haluška J.: [Construction of Composite Leading Indicator for the Slovak Economy](#). Scientific Annals of the "Alexandru Ioan Cuza", University of Iasi, Romania, 2008 (s. 363 – 370)

Krivanská K.: Ekonometrické modelovanie zahraničného obchodu SR, Fakulta Matematiky, Fyziky a Informatiky UK v Bratislave, Bratislava, 2002

Lukáčik M., Lukáčiková A., Szomolányi K.: Ekonometrické prognózovanie importu Slovenskej republiky. Ekonomické rozhľady, roč. 36, č. 2, 2007, s. 179–192.

Lukáčik M., Lukáčiková A.: Heteroskedasticita v ekonometrických modeloch. Ekonomika a informatika, roč. 5, č. 1, 2007, s. 96–106

Rublíková E., Prihodová I.: Analýza vybraných časových radov - ARIMA modely. Vydavateľstvo EKONÓM, 2008.

5. Register príkazov

	<i>strana</i>		<i>strana</i>		<i>strana</i>
@abs	21, 23, 52, 55	equation	10, 15, 22, 29, 30, 43, 46, 54, 57, 65 66, 70, 71, 73, 74	makeresid	7, 10, 15, 22, 43, 46, 54, 57, 73, 74
@all	10, 15, 22, 38, 53, 55			output	7
@count	22, 39, 53-55			fit	7-8, 10-11, 14-15, 20, 22, 50-51, 54, 58, 73, 75
@dw	27-28	resids	7, 46-47, 54, 58		
@elem	20, 22, 51, 53, 55,				
	58			results	7
@obs	21-23, 52, 55	for..next	5, 19-20, 22, 38, 40, 51, 54-58	save	38, 39
@seas(i)	30, 56			for..to..next	22, 38-39, 53-55
@seriesname(i)	22, 39, 53, 55	forecast	7, 14-15, 20, 22, 50-51, 55, 58		
@sum	21, 22, 23, 52, 55			freeze	20, 22, 28-29, 39-40, 43, 46-47, 49, 52, 54-55, 57 58, 73-75
@trend	56				
add	22, 51, 55, 58				
auto	28, 47, 49, 54, 58, 71, 73, 75	genr	9-10, 21-22, 29, 38, 53, 56 15, 20, 22, 39, 43, 51-55 73	updatecoefs	7
cd	19, 21, 38, 53, 55			uroot	33-34, 39-40, 43, 47, 54, 57, 73-74
coef	10, 15, 22, 43, 46, 54				
coint	34, 35, 43, 45-46, 54			while..wend	5
cor	29, 43, 54, 57	if..then..endif	5	white	26, 43, 47, 54, 57-58
correl	7, 28, 47, 49, 54, 58, 60-62, 70, 73-75	line	22, 52, 54-55, 57, 73 7, 10, 15, 22, 26, 29-30, 43, 46, 54, 57, 65-66, 70-71, 73-74		
displayname	7				

6. Register obrázkov

Obr. 1.1 Objekt rovnice a jeho syntax	7
Obr. 1.2 Dialógové okno pre prognózu rovnice 1	9
Obr. 1.3 Odhadnutá jednoduchá regresná rovnica deflátora konečnej spotreby domácností	11
Obr. 1.4 Tri typy statickej prognózy časového radu – grafický výstup	13
Obr. 1.5 Tri typy statickej prognózy časového radu – tabuľkový výstup.....	14
Obr. 1.6 Dialógové okno pre prognózu rovnice 2	16
Obr. 1.7 Porovnanie dynamickej a statickej prognózy – tabuľkový výstup	17
Obr. 1.8 Porovnanie dynamickej a statickej prognózy – grafický výstup	18
Obr. 1.9 Porovnanie medziročných rastov dynamickej a statickej prognózy	18
Obr. 1.10 Porovnanie statických a dynamických prognóz s realitou	23
Obr. 2.4 Odhady parametrov konzistentné s heteroskedasticitou – menu objektu rovnice	27
Obr. 2.5 Chybové hlásenia	30
Obr. 2.1 ADF test stacionarity	32
Obr. 2.2 PP test stacionarity	33
Obr. 2.3a Ilustračné výsledky kointegračného testu	36
Obr. 2.3b Ilustračné výsledky kointegračného testu	37
Obr. 2.6 Možnosti uloženia pracovného súboru.....	39
Obr. 2.7a Výsledky ADF testov pre HDP	41
Obr. 2.7b Výsledky PP testov pre HDP	42
Obr. 2.8 Výstup z dlhodobej rovnice pre ECM model	44
Obr. 2.9 ADF a PP test pre stacionárnosť rezíduí z dlhodobého vzťahu	45
Obr. 2.10 Whiteov test na heteroskedasticitu v rezíduách z dlhodobej rovnice	45
Obr. 2.11 Johansenov kointegračný test pre premenné ECM.....	46
Obr. 2.12 Výstup z krátkodobej rovnice pre ECM model.....	48
Obr. 2.13 Rezíduá z krátkodobého vzťahu v tvare ECM.....	48
Obr. 2.14 ADF a PP test pre stacionárnosť rezíduí z krátkodobého vzťahu ECM	49
Obr. 2.15 Test na heteroskedasticitu rezíduí z krátkodobého vzťahu ECM.....	49
Obr. 2.16 Test autokorelácie rezíduí z krátkodobého vzťahu ECM	50
Obr. 2.17 Porovnanie statickej a dynamickej prognózy HDP z ECM modelu s realitou	52
Obr. 2.18 Porovnanie prognózy konečnej spotreby domácností z ECM modelu	59
Obr. 3.1 Korelogram pôvodného časového radu ISP	61
Obr. 3.2 Korelogram stacionarizovaného časového radu ISP	63
Obr. 3.3 Ponuka nastavení pri odhade ARIMA modelu	65
Obr. 3.4 Výstup odhadu modelu ARIMA(2, 1, 1)(0, 1, 1) ₁₂	67
Obr. 3.5 Menu pre diagnostiku modelov s ARMA štruktúrou.....	68
Obr. 3.6 Inverzné korene modelu ARIMA(2, 1, 1)(0, 1, 1) ₁₂ pre časový rad ISP	69
Obr. 3.7 Korelogram rezíduí ARIMA modelu odhadnutého na obr. 3.4	70
Obr. 3.8 Výstup LM testu autokorelácie rezíduí z modelu na obr. 3.4	72
Obr. 3.9 Výstup z odhadu ARIMAX modelu z programu 3.2	75

Vydal: INFOSTAT
Inštitút informatiky a štatistiky,
Dúbravská cesta 3
845 24 Bratislava 45

V edícii: Dokumenty

Pod číslom: 1

Vedúci redaktor: Ing. Michal Olexa, PhD.

Výkonný redaktor: Ing. Miroslav Klúčik

Počet strán: 80

Počet výtlačkov: 9

ISBN: 978-80-89398-19-5

D1-150/2011

