**VYSOKÁ ŠKOLA EKONOMICKÁ V PRAZE**

FAKULTA INFORMATIKY A STATISTIKY

# DIPLOMOVÁ PRÁCE

2012 Jan Maxa

**VYSOKÁ ŠKOLA EKONOMICKÁ V PRAZE**

FAKULTA INFORMATIKY A STATISTIKY

Název diplomové práce:

# Analýza a komparace inflace v ČR a SRN

Autor: **Jan Maxa**

Katedra: **Katedra ekonometrie**

Obor: **Ekonometrie a operační výzkum**

Vedoucí práce: **Prof. Ing. Roman Hušek, CSc.**

**Prohlášení**:

Prohlašuji, že jsem diplomovou práci na téma „Analýza a komparace inflace v ČR a SRN“ zpracoval samostatně. Veškerou použitou literaturu a další podkladové materiály uvádím v seznamu použité literatury.

V Praze dne 20. června 2012 .....

Jan Maxa

**Poděkování**:

Rád bych na tomto místě poděkoval Prof. Ing. Romanu Huškovi, CSc. za vedení mé diplomové práce a za podnětné návrhy, které ji obohatily.

## Abstrakt

*Název práce*: Analýza a komparace inflace v ČR a SRN
*Autor*: Jan Maxa
*Katedra*: Katedra ekonometrie
*Vedoucí práce*: Prof. Ing. Roman Hušek, CSc.

Cílem diplomové práce je analýza chování inflace v České republice a Spolkové republice Německo pomocí vybraných ekonometrických modelů. Úvod práce je věnován ekonomické teorii inflace – vysvětlení základních pojmů, způsobů jejího měření a jejímu cílování. Další kapitola je zaměřena na popis měnové politiky ČR a SRN. Dále je popsán ekonometrický aparát – model vektorové autoregrese (VAR model). S VAR modely úzce souvisí Grangerova kauzalita, analýza funkcí odezvy, kointegrace a model korekce chyby. Tyto ekonometrické modely jsou nejprve teoreticky popsány a následně jsou aplikovány na reálná data vybraných makroekonomických časových řad pro ČR a SRN. Konec práce je doplněn o ekonometrickou predikci použitých veličin.



**Klíčová slova**: inflace, VAR modely, Grangerova kauzalita, analýza funkcí odezvy, kointegrace, model korekce chyby



## Abstract

*Title*: Inflation analysis and its comparison in the Czech Republic and Germany
*Author*: Jan Maxa
*Department*: Department of Econometrics
*Supervisor*: Prof. Ing. Roman Hušek, CSc.

The aim of this paper is to analyse and compare inflation and its dynamics between two countries – the Czech Republic and Germany – applying a special kind of econometric models. The first part of this paper is dedicated to economic theory of inflation – fundamental terms, measuring methods and its targeting. The monetary policy in the Czech Republic and Germany is also shortly introduced. Next chapter tries to describe the econometric concept which is used in this paper – vector autoregression model (VAR model). In connection with the VAR models, Granger causality, impulse response function, cointegration and error correction model are mentioned as well. The empirical part includes application of selected models on real time series of macroeconomic indicators. Next to the interpretation of results, the forecasts are also implemented.



**Keywords**: inflation, VAR model, Granger causality, impulse response functions, cointegration, error correction model

# Obsah

**ÚVOD** ..... **7**

**1 INFLACE** ..... **9**

1.1 INFLACE A JEJÍ MĚŘENÍ ..... 9
1.2 FORMY INFLACE ..... 12
1.3 MONETÁRNÍ POLITIKA A CÍLOVÁNÍ INFLACE V ČR ..... 13
1.4 MĚNOVÁ POLITIKA V EU ..... 17

**2 MĚNOVÉ AGREGÁTY** ..... **19**

**3 ČASOVÉ ŘADY** ..... **20**

3.1 DRUHY ČASOVÝCH ŘAD A JEJICH ZÁKLADNÍ CHARAKTERISTIKY ..... 20
3.2 STACIONARITA ..... 22

**4 VÍCEROZMĚRNÉ MODELY ČASOVÝCH ŘAD** ..... **25**

4.1 VEKTOROVÉ AUTOREGRESE ..... 25
4.1.1 Stabilita a stacionarita VAR ..... 26
4.1.2 Konstrukce VAR modelu ..... 27
4.1.3 Odhad standardního tvaru VAR modelu ..... 28
4.1.4 Prognózy na základě modelu VAR ..... 29
4.1.5 Nedostatky VAR modelů ..... 30
4.2 GRANGEROVA KAUZALITA ..... 30
4.3 ANALÝZA FUNKCÍ ODEZVY („IMPULS-REAKCE“) ..... 32
4.4 KOINTEGRACE ..... 33
4.4.1 Kointegrované procesy ..... 33
4.4.2 Model korekce chyby ..... 35

**5 APLIKACE VYBRANÝCH MODELŮ NA ČR** ..... **37**

5.1 DATA ..... 37
5.2 ODHAD VAR MODELU A ANALÝZA FUNKCE ODEZVY ..... 39
5.3 ANALÝZA GRANGEROVY KAUZALITY ..... 40
5.4 KOINTEGRACE A MODEL KOREKCE CHYBY ..... 41
5.5 PREDIKCE ..... 42

**6 APLIKACE VYBRANÝCH MODELŮ NA SRN** ..... **45**

6.1 DATA ..... 45
6.2 ODHAD VAR MODELU A ANALÝZA FUNKCE ODEZVY ..... 47
6.3 ANALÝZA GRANGEROVY KAUZALITY ..... 47
6.4 KOINTEGRACE A MODEL KOREKCE CHYBY ..... 48
6.5 PREDIKCE ..... 50

**ZÁVĚR** ..... **52**

**SEZNAM LITERATURY** ..... **54**

**PŘÍLOHY** ..... **55**

# Úvod

Pojem inflace je termínem, se kterým se setkáváme skoro každý den. Ukazatel vývoje inflace patří k nejsledovanějším a nejostřeji diskutovaným veličinám. Při její analýze na ni není možné pohlížet jako na samostatnou a nezávislou veličinu, nýbrž je nutné mít na paměti širší okruh faktorů, které ji ovlivňují. Mezi takové faktory lze považovat výši HDP, peněžní zásobu apod. Právě ekonometrická kvantifikace vztahů inflace a dalších makroekonomických indikátorů je zásadní pro mnoho institucí, včetně centrálních bank a jejích měnových politik.

Existuje řada postupů a metod, pomocí kterých lze provádět ekonometrickou analýzu inflace. Mezi velmi známé ekonometrické techniky patří metoda vektorové autoregrese, tzv. VAR modely, se kterými s této práci budu pracovat. S VAR modely úzce souvisí i analýza funkce odezvy, Grangerova kauzalita, kointegrace a model korekce chyby.

Cílem této práce je provést analýzu inflace pro Českou republiku, kterou jsem vybral jako představitele postkomunistických zemí, a Spolkovou republiku Německo (SRN), jakožto vyspělé kapitalistické země, a zjistit, zda je na místě předpokládat mezi oběma zeměmi existenci podobných vztahů mezi inflací a ostatními makroekonomickými indikátory. Vybrané ekonometrické modely použiji tedy na dva soubory dat. První soubor obsahuje data o harmonizovaném indexu spotřebních cen (HISC), hrubém domácím produktu (HDP), peněžní zásobě a úrokové míře pro Českou republiku. Druhý soubor je pak složen z dat za Spolkovou republiku Německo.

Tato diplomová práce je složena ze šesti kapitol. První kapitolu věnuji popisu a bližšímu poznání základních pojmů a definic spojených s inflací včetně popisu jejích forem a způsobů měření. Dále je zde přiblížena problematika cílování inflace a obecně monetární politiky v ČR a zemích, ve kterých je národní měnou Euro. Krátce zde také shrnuji problematiku peněžní zásoby.

Třetí kapitola je zaměřena na popis základních definic z oblasti časových řad včetně popisu stacionarity, jakožto klíčové vlastnosti časových řad, a jejího testování.

Čtvrtá kapitola popisuje teoretický základ pro postupy, které pro analýzu inflace použiji, tj. zaměřuje se na popis vícerozměrných modelů časových řad se zaměřením na modely vektorových autoregresí (VAR modely) a kointegrace.

V páté kapitole se zabývám aplikací vybraných modelů na reálná data pro ČR a zhodnocením výsledků na základě empirických ekonometrických modelů. Nejprve je odhadnut VAR model, po jehož interpretaci následuje analýza funkce odezvy. V další části jsou hlubšímu zkoumání podrobeny jednotlivé dvojice proměnných ve smyslu Grangerovy kauzality. Cílem je zde nalézt odpověď na otázku, zda je možné zlepšit předpověď jedné proměnné zahrnutím druhé proměnné do regrese. Dále jsem se zabýval zkoumáním kointegrace a modelem korekce chyby, tedy zkoumáním dlouhodobých vztahů mezi

proměnnými. Vhodnost vybraných modelů pro analyzování inflace jsem nakonec posuzoval pomocí predikce ex post. Tato predikce je poté doplněna predikcí ex ante na tři období dopředu.

V kapitole šest jsou pak výše zmíněné modely aplikovány na data pro SRN.

Data jednotlivých proměnných pro Českou republiku jsem získal z internetových stránek Českého statistického úřadu (ČSÚ), Evropského statistického úřadu (Eurostat) a České národní banky (ČNB). Jako zdroj časových řad pro německou ekonomiku jsem použil stránky Evropské centrální banky (ECB), Eurostatu a ČNB.

# 1 Inflace

## 1.1 Inflace a její měření

Inflace patří mezi nejdůležitější a nejsledovanější makroekonomické indikátory. Obecně jí lze definovat jako všeobecný a opakovaný růst cenové hladiny v ekonomice v čase. Jde o oslabení reálné hodnoty (tj. kupní síly) dané měny vůči zboží a službám, které spotřebitel kupuje (Holman, 2002) – je-li v ekonomice přítomna inflace spotřebitelských cen, pak na nákup téhož koše zboží a služeb spotřebitel potřebuje čím dál více jednotek měny dané země. Informace o dosažené míře inflace jsou využívány např. pro účely valorizace mezd, důchodů a sociálních příjmů. V neposlední řadě jsou tyto informace využívány také v souvislosti s nájemnými či jinými smlouvami, v nichž je zakotvena revize původně dohodnutého finančního plnění v závislosti na vývoji inflace. Tato makroekonomická veličina hraje nezastupitelnou funkci ve fungování všech ekonomických subjektů. Inflace je obecně v ekonomice považována za jev negativní. Jejím závažným důsledkem je nejistota, a ta nastává tehdy, pokud je míra inflace kolísavá, tedy že změny cen kolísají značně a často. Další důsledkem vysoké inflace nebo vysokých inflačních očekávání je to, že lidé méně spoří s ohledem na budoucnost. Důvodem pro toto chování je fakt, že inflace by mohla časem narušit kupní sílu úspor. Růst cenové hladiny může dále vést ke změně struktury spotřeby a může mít vliv i na strukturu dovozu a vývozu, protože dovážené výrobky se stávají levnějšími ve srovnání s domácími. Na druhou stranu vysoká inflace představuje výhodu pro dlužníky, protože při inflaci dochází k poklesu hodnoty půjček.

Opakem inflace je tzv. *deflace*, která znamená pokles cenové hladiny. Pokud probíhá inflace, ale její míra se snižuje, mluvíme o *desinflaci*.

Měření cenové hladiny v praxi je nejčastěji realizováno pomocí indexu spotřebitelských cen, indexu cen výrobců a deflátoru hrubého domácího produktu (např. Helísek, 2002).

Index spotřebitelských cen (CPI, Consumer Price Index) patří v soustavě cenových indexů vypočítávaných v České republice mezi nejdůležitější indikátory cenového vývoje. V CPI je cenová hladina vyjádřená jako průměrná úroveň cen souboru (koše) spotřebních výrobků a služeb, které jsou spotřebovány průměrnou domácností. Spotřební koš je složen z cca 700 reprezentativních výrobků dle klasifikace CZ-COICOP (Classification of Individual Consumption by Purpose), která vychází z mezinárodní klasifikace individuální spotřeby dle účelu COICOP a která třídí výrobky a služby do 12 hlavních oddílů. Od roku 2012 se vývoj indexů spotřebitelských cen sleduje na nových spotřebních koších. V rámci revize byl revidován výběr cenových reprezentantů, váhový systém, soubor respondentů, metodika zjišťování a způsob výpočtu.

**Tabulka 1-1: Oddíly spotřebního koše ČR, SRN a jejich váhy**

| | Název | ČR | SRN |
|---|---|---|---|
| **01** | Potraviny a nealkoholické nápoje | 149,8 | 103,5 |
| **02** | Alkoholické nápoje, tabák | 96,0 | 39,0 |
| **03** | Odívání a obuv | 35,9 | 48,9 |
| **04** | Bydlení, voda, energie, paliva | 280,4 | 308,0 |
| **05** | Bytové vybavení, zařízení domácnosti, | 58,0 | 55,9 |
| **06** | Zdraví | 23,0 | 40,3 |
| **07** | Doprava | 105,0 | 131,9 |
| **08** | Pošty a telekomunikace | 36,1 | 31,0 |
| **09** | Rekreace a kultura | 90,4 | 115,6 |
| **10** | Vzdělávání | 7,8 | 7,4 |
| **11** | Stravování a ubytování | 48,6 | 44,0 |
| **12** | Ostatní zboží a služby | 69,0 | 74,5 |
| | | 1000 | 1000 |

*Zdroj: ČSÚ* a *http://www.destatis.de; stránky německého statistického úřadu*

Výpočet indexů spotřebitelských cen je prováděn na stálých vahách podle Laspeyresova vzorce[1]

$$I = \frac{\sum \frac{p_1}{p_0} * p_0 q_0}{\sum p_0 q_0} * 100,$$

kde $I$ je bazický index sledovaného období vzhledem k základnímu období,

$p_1$ je cena zboží (služby) ve sledovaném (běžném) období,

$p_0$ je cena zboží (služby v základním období,

$p_0 q_0$ je stálá váha – výdaje domácností na zboží (služby) v základním období.

Od roku 2012 je za základní období zvolen prosinec 2011.

S indexy spotřebitelských cen pak souvisí ukazatel, který je nazývaný jako míra inflace. Míra inflace vyjadřuje úhrnnou změnu cenové hladiny vyjádřenou relativně (web ČSÚ).

- Průměrná roční míra inflace – míra inflace vyjádřená přírůstkem průměrného ročního indexu spotřebitelských cen vyjadřuje procentní změnu průměrné cenové hladiny za 12 posledních měsíců proti průměru 12-ti předchozích měsíců

[1] Zdroj: Český statistický úřad: *Indexy spotřebitelských cen – metodická příručka* [online]; cit. [11. 4. 2012]; dostupné z: http://czso.cz/csu/redakce.nsf/i/isc_metodicka_prirucka/$File/manual_isc_2012.pdf

- Meziroční míra inflace – míra inflace vyjádřená přírůstkem indexu spotřebitelských cen ke stejnému měsíci předchozího roku vyjadřuje procentní změnu cenové hladiny ve vykazovaném měsíci daného roku proti stejnému měsíci předchozího roku.
- Měsíční míra inflace – míra inflace vyjádřená přírůstkem indexu spotřebitelských cen k předchozímu měsíci vyjadřuje procentní změnu cenové hladiny sledovaného měsíce proti předchozímu měsíci
- Bazické indexy – míra inflace vyjádřená přírůstkem indexu spotřebitelských cen k základnímu období (rok 2005=100) vyjadřuje změnu cenové hladiny sledovaného měsíce příslušného roku proti roku 2005

Druhým způsobem jak měřit cenovou hladinu je použitím indexu cen výrobců. Jedná se například o index cen zemědělských výrobců, průmyslových výrobců, stavebních prací atd. Tento index je založen na stejném principu jako CPI, koše obsahují příslušné výrobky a zboží, kterým jsou určeny váhy, a to dle struktury tržeb.

Třetím indexem je deflátor HDP, který lze vyjádřit jako poměr nominálního a reálného produktu v daném roce. Oproti CPI je v deflátoru zahrnuta mnohem širší skupina výrobků. CPI dále zahrnuje i ceny dovážených statku, kdežto deflátor v sobě obsahuje pouze statky vyrobené v dané ekonomice. Za nevýhodu deflátoru jsou považována především delší časová zpoždění spojená se získáváním a zpracováním potřebných údajů.

Za hlavní indikátor cenového vývoje je v Německu, stejně jako v ČR, považován index spotřebitelských cen. Opět se vychází ze spotřebního koše, který obsahuje cca 700 druhů zboží a služeb. Tyto položky jsou poté vynásobeny vahou, která odpovídá výdaji, který v průměru domácnosti utratí za tento typ zboží. Váhová struktura koše je mírně odlišná od české.

Jak je vidět v tabulce č. 1.1, největší rozdíl mezi oběma koši lze spatřit v položkách Potraviny a nealkoholické nápoje a Alkoholické nápoje a tabák, které obě v českém koši zaujímají větší váhu o přibližně 5%. Naopak Němci více utrácejí za dopravu.

V eurozóně se růst spotřebitelských cen měří tzv. harmonizovaným indexem spotřebitelských cen, často se používá jen jeho zkratka HICP. Harmonizované indexy spotřebitelských cen jsou sledovány na základě harmonizovaných standardů závazných pro všechny členské státy EU, tím je zajištěna srovnatelnost údajů ze všech zemí. HICP odpovídají cenovým indexům Laspeyresova typu a jsou počítány jako roční řetězové indexy zohledňující každoroční změny vah. Společnou klasifikaci pro harmonizované indexy spotřebitelských cen představuje COICOP. Verze této klasifikace (COICOP/HICP) byla upravena přímo pro HICP.

V jednotlivých zemích EU je HICP počítán národními statistickými úřady. Ty vypočítávají index HICP za svou zemi a své údaje pak posílají statistickému úřadu Evropských společenství neboli Eurostatu. Eurostat pak vypočítává index HICP za celou

eurozónu. Eurostat také zajišťuje kvalitu údajů jednotlivých zemí tím, že sleduje, zda dodržují právně závazné normy.

## 1.2 Formy inflace

Holman (2004) zmiňuje, že inflace v sobě zahrnuje tři komponenty, a to inflaci poptávkovou, setrvačnou a nabídkovou (nákladovou). Tyto jednotlivé druhy inflace se od sebe odlišují tím, jaký inflační impulz má za následek jejich vyvolání.

Poptávkový inflační impulz vychází ze zvýšení některé složky agregátních výdajů. Dojde-li v ekonomice, která vyrábí na svém potenciálním produktu, ke zvýšení peněžní zásoby centrální bankou, reaguje na to agregátní poptávka růstem. Protože v krátkém období je agregátní nabídka rostoucí, dojde ke zvýšení reálného domácího produktu na potenciální produkt. To znamená, že nezaměstnanost je pod svou přirozenou mírou a důsledkem toho, budou růst nominální mzdy, neboli bude docházet ke mzdové inflaci. Tato mzdová inflace poté vyvolá cenovou inflaci. To vše za předpokladu, že očekávaná inflace je nulová, produktivita práce neroste a že nedochází k nákladovým šokům.

Připustíme-li růst produktivity práce tempem $\eta$, je možné poptávkovou inflaci popsat vztahem, který je známý jako Phillipsova křivka (Holman 2004),

$$\pi = \varepsilon * (u^* - u) - \eta,$$

kde $\eta$ je cenová inflace, tj. růst cen v %, $\varepsilon$ je koeficient vyjadřující citlivost nominálních mezd na odchylky nezaměstnanosti od přirozené míry, $(u^* - u)$ je odchylka vyjadřující pokles nezaměstnanosti pod přirozenou míru a $\eta$ je růst produktivity práce v %.

Setrvačná inflace není vyvolána, na rozdíl od inflace poptávkové, poklesem nezaměstnanosti, nýbrž je vyvolána inflačními očekáváními. Na tomto místě je třeba rozlišit dva druhy očekávání: adaptivní a racionální. Adaptivní očekávání jsou taková očekávání, která lidé vytvářejí pouze na základě minulé zkušenosti, zatímco racionální očekávání jsou taková, která lidé vytvářejí nejen na základě minulé zkušenosti, ale také na základě informací o pravděpodobném budoucím vývoji. Rovnici Phillipsovy křivky rozšířené o inflační očekávání lze pak vyjádřit jako (Holman, 2004)

$$\pi = \pi_e + \left[\varepsilon \cdot \left(u^* - u\right) - \eta\right],$$

kde $\pi$, tj. celková inflace, je složena ze setrvačné inflace $\pi_e$ a poptávkové inflace, které je daná výrazem v hranaté závorce.

Jestliže je inflace vyvolána ze strany nabídky, jedná se o inflaci nabídkovou (nákladovou). Jako příčina této inflace zde stojí nepříznivý nabídkový (nákladový) šok, za kterým může stát zvýšení světových surovin (např. ropy), neúroda nebo vlna stávek, které si vynutí zvýšení mezd. Vyšší náklady pak tlačí ceny nahoru. Nákladový šok lze jen velmi těžko předvídat, a proto na něj není možné použít model racionálních očekávání. Růst nákladů nejen tlačí na růst cen, ale je také příčinou poklesu reálného produktu pod produkt potenciální a také

růstu nezaměstnanosti nad přirozenou míru. Pokud centrální banka nákladový šok akomoduje zvýšením peněžní zásoby, vyvolá tím poptávkovou a následně i setrvačnou inflaci. Tímto způsobem mohou probíhat všechny tři typy inflace. Celkovou inflaci lze v tomto případě popsat následujícím vztahem, který nám ukazuje rozdělení celkové inflace na inflace setrvačnou, poptávkovou a nabídkovou (ta je v rovnici vyjádřena symbolem ν), (Holman, 2004)

$$\pi = \pi_e + \left[\varepsilon \cdot \left(u^* - u\right) - \eta\right] + \nu .$$

Dalšími způsoby jak klasifikovat inflaci jsou, např. Hedija, Musil (2009)

- Podle očekávání
  - anticipovaná (očekávaná) – subjekty ji zakalkulují do svých rozhodování
  - neanticipovaná (neočekávaná) – ekonomické subjekty s ní nepočítají
- Podle vlivu na relativní ceny
  - vyrovnaná – nemění relativní ceny zboží a služeb, neboli ceny všeho zboží a služeb rostou stejným tempem
  - nevyrovnaná – mění relativní ceny, neboli ceny statků a služeb rostou rozdílným tempem
- Podle tempa růstu cenové hladiny
  - mírná – ceny rostou pomalu, jednociferné roční míry inflace
  - pádivá – ceny rostou tempem dvoj až trojciferných čísel
  - hyperinflace - mimořádná tempa růstu cenové hladiny v řádech tisíců procent

## 1.3 Monetární politika a cílování inflace v ČR

Hlavní úkol měnové politiky ČNB je právně kodifikován v ustanoveních článku 98 Ústavy ČR a v zákoně č. 6/1993 Sb., o České národní bance, které jí ukládají povinnost zabezpečovat cenovou stabilitu. Podobnou úlohu mají centrální banky ve většině demokratických zemí s tržní ekonomikou. Tohoto hlavního cíle banka dosahuje prostřednictvím změn v nastavení *repo sazby*. Repo operace jsou hlavním měnovým nástrojem. Změna tržních úrokových sazeb se do inflace promítne prostřednictvím transmisního mechanismu, jenž je chápán jako řetězec ekonomických vazeb, který umožňuje vhodným nastavením měnověpolitických nástrojů měnit inflaci.

**Graf 1-1: Transmisní mechanismy měnové politiky**

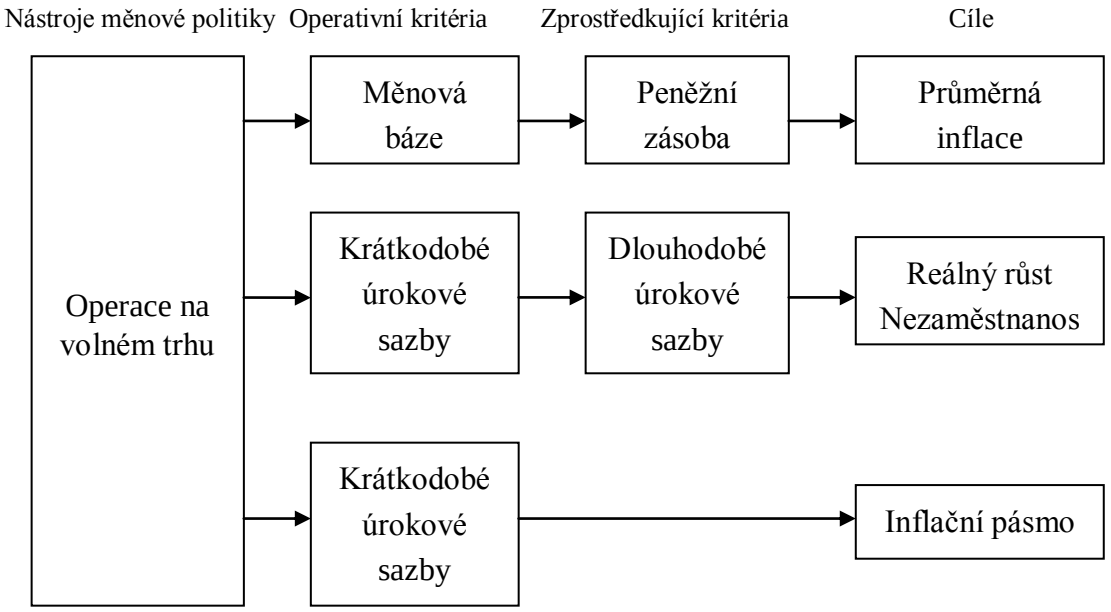


*Zdroj: Revenda (2004)*

Při plnění své základní měnověpolitické úlohy, tj. zabezpečení cenové stability, volí centrální banka jeden z několika možných měnověpolitických režimů. Měnověpolitický režim dává měnověpolitickému rozhodování určitou strukturu, která usnadňuje samotné rozhodování, ale především interpretaci tohoto rozhodování veřejnosti. Čtyřmi základními typy těchto režimů jsou *režim s implicitní nominální kotvou, cílování peněžní zásoby, cílování měnového kurzu* a *cílování inflace.*

- Režim s implicitní nominální kotvou spočívá v cílování určité veličiny přijaté interně v rámci centrální banky, aniž by došlo k jejímu explicitnímu vyhlášení. Možnost interního rozhodování dává bance relativně velkou volnost. Předpokladem pro úspěšné fungování tohoto režimu je vysoká důvěryhodnost centrální banky, jež umožní dosažení žádoucích změn inflace a jejích očekávání i bez explicitních cílů. Problémem tohoto režimu může být menší transparentnost.
- U cílování měnové zásoby se pozornost soustřeďuje na regulaci tempa růstu zvoleného peněžního agregátu. Vychází se zde z ekonomické teorie, že růst cen je v dlouhodobém horizontu ovlivňován vývojem peněžní nabídky. Cíl pro růst peněžního agregátu se většinou volí jako interval ke konci roku, nebo jako koridor v průběhu roku. Otázkou je ovšem samotná volba peněžního agregátu vhodného k cílování. V době finančních inovací, elektronizace a globalizace trhů se vazba mezi peněžními agregáty a cenovou hladinou rozvolňuje. Centrální banka dále nemusí být schopna vybraný peněžní agregát řídit s dostatečnou přesností. Nevýhodou tohoto kurzu je pomalá reakce inflace na změnu peněžní zásoby.
- V režimu cílování měnového kurzu se centrální banka snaží prostřednictvím změn úrokových sazeb a přímých devizových intervencí zajistit stabilitu nominálního měnového kurzu vůči měně tzv. kotevní země, a tak z této země "importovat' cenovou

stabilitu. K udržení závazku daného měnového kurzu je nutná vhodná kombinace hospodářských politik zajišťující nízký inflační diferenciál vůči kotevní zemi, dostatečné devizové rezervy, udržení konkurenceschopnosti a celkové důvěryhodnosti země včetně jejího institucionálního a právního rámce a politické stability. Jednou z hlavních nevýhod tohoto režimu je ztráta autonomie měnové politiky. Cílování měnového kurzu je vhodné pro malé, otevřené ekonomiky, kde se měnový kurz výrazným způsobem podílí na vývoje domácí cenové hladiny.

- U cílování inflace centrální banka s jistým předstihem veřejně vyhlásí inflační cíl (či posloupnost cílů), o jehož dosažení bude usilovat. Jedná se o aktivní a přímé formování inflačních očekávání. Tento režim zahrnuje do svého rozhodovacího schématu podstatně větší množství informací než jen měnový kurz nebo peněžní agregáty, např. také trh práce, dovozní ceny, ceny výrobců, mezeru výstupu, nominální a reálné úrokové sazby, nominální a reálný měnový kurz, hospodaření veřejných rozpočtů apod.

V prosinci 1997 rozhodla bankovní rada České národní banky o změně režimu měnové politiky a počínaje rokem 1998 přešla k cílování inflace (do té doby ČNB prosazovala režim kombinující kurzový závěs a cílování peněžní zásoby). Přechod k novému režimu měnové politiky nebyl změnou její úlohy, ale pouze způsobu, jakým je tato úloha plněna.

Významnými rysy cílování inflace je střednědobost této strategie, využívání prognózy inflace a veřejné explicitní vyhlášení inflačního cíle či posloupnosti cílů. Bankovní rada ČNB při svém měnověpolitickém rozhodování posuzuje nejnovější prognózu ČNB a vyhodnocuje rizika nenaplnění této prognózy. Změnami měnověpolitických nástrojů se centrální banka snaží kompenzovat excesivní inflační, resp. dezinflační tlaky, které vychylují budoucí inflaci mimo inflační cíl resp. toleranční pásmo kolem tohoto cíle. Například zvýšení repo sazby vede prostřednictvím tzv. transmisního mechanismu obvykle k oslabení agregátní poptávky, které má za následek oslabení cenového růstu. Snížení repo sazby má na inflaci obvykle opačný dopad. Pokud centrální banka očekává, že v budoucnosti budou převažovat inflační vlivy vychylující inflaci nad cílovanou hodnotu, je to signál, že měnová politika by měla být restriktivnější, tj. že repo sazba by měla být zvýšena.

Inflační vývoj, resp. očekávaný inflační vývoj může být ovšem důsledkem působení mimořádných šoků zpravidla na straně nabídky, jejichž inflační resp. dezinflační projevy za určitou dobu odezní, takže úsilí tyto projevy zcela eliminovat změnami nastavení měnověpolitických nástrojů by zbytečně krátkodobě rozkolísávalo ekonomiku. Pokud se prognóza inflace v důsledku zmíněných šoků pohybuje po jistou dobu mimo toleranční pásmo inflačního cíle, je to v režimu cílování inflace obvykle považováno za výjimku z úkolu centrální banky zajistit vývoj inflace poblíž inflačního cíle. ČNB tuto praxi také uplatňuje a v odůvodněných situacích pracuje s tzv. výjimkami ze závazku plnit inflační cíl.

V současnosti je vyhlášen ČNB inflační cíl ve výši 2%, který je platný od ledna 2010 s tím, že skutečná hodnota inflace by se neměla lišit od cíle o více než jeden procentní bod na obě strany.

**Graf 1-2: Inflační cíle ČNB**

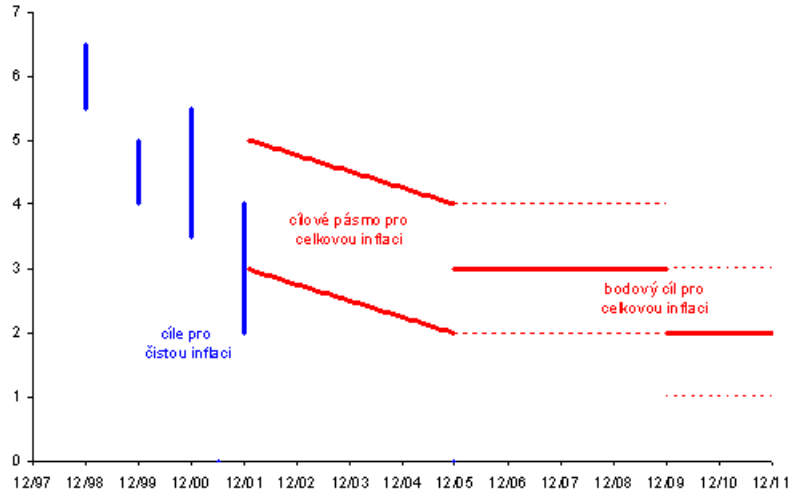


*Zdroj: ČNB*

Jak již bylo zmíněno v úvodu této kapitoly, hlavním měnověpolitickým nástrojem jsou repo operace, které se řadí do tzv. operací na volném trhu, jejichž cílem je usměrňovat vývoj úrokových sazeb. Repo operace jsou prováděné formou tendrů, při kterých ČNB přijímá od bank přebytečné finanční prostředky a naopak bankám poskytuje jako předmět finančního zajištění cenné papíry. Po uplynutí doby splatnosti proběhne reverzní transakce, v níž ČNB, vystupující jako dlužník, vrátí věřitelské bance zapůjčenou jistinu zvýšenou o dohodnutý úrok a věřitelská banka vrátí ČNB poskytnutý cenný papír. Protože základní dobou trvání těchto operací je 14 dní, je z hlediska měnové politiky považována za klíčovou sazbu dvoutýdenní repo sazba (2T repo sazba). Repo tendry slouží primárně k odčerpání přebytečné likvidity. Čas od času jsou prováděny transakce s dobou splatnosti kratší než 14 dní, naopak doplňkový nástroj v podobě tříměsíčního repo tendru se již nepoužívá. Poslední takto dlouhý tendr byl vypsán v lednu 2001.

Dvoutýdenní repo sazba se pohybuje v koridoru, který vytvořily úrokové sazby uplatňované u tzv. automatických facilit. Automatické facility jsou dalším měnovým nástrojem a slouží k poskytování nebo ukládání likvidity přes noc. Depozitní facilita poskytuje bankám možnost uložit přes noc u ČNB bez zajištění svou přebytečnou likviditu. Depozita jsou úročená diskontní sazbou. Diskontní sazba proto zpravidla představuje dolní mez pro pohyb krátkodobých úrokových sazeb (tedy i pro dvoutýdenní repo sazbu) na peněžním trhu.

Marginální zápůjční facilita poskytuje bankám, které mají s ČNB uzavřenou rámcovou repo smlouvu, možnost vypůjčit si přes noc od ČNB formou repo operace likviditu. Finanční prostředky v rámci této facility jsou úročeny lombardní sazbou. Vzhledem k trvalému

přebytku likvidity je tato facilita bankami využívána minimálně. Lombardní sazba představuje horní mez pro pohyb krátkodobých úrokových sazeb na peněžním trhu.

Třetím nástrojem, se kterým může ČNB pracovat, jsou povinné minimální rezervy (PMR). Každá banka (včetně stavebních spořitelen) a pobočka zahraniční banky, která má v ČR bankovní licenci nebo se rozhodne v ČR podnikat na základě tzv. "Jednotné licence", je povinna držet na svém účtu u ČNB určitý předem stanovený objem likvidních prostředků, tzv. povinné minimální rezervy. Předepsaný objem PMR je stanoven na 2 % ze základny pro výpočet PMR. S platností od července 2001 je touto základnou objem primárních závazků dané banky (tj. především vkladů od nebankovních subjektů), jejichž splatnost nepřevyšuje 2 roky. Funkce PMR jako měnověpolitického nástroje je v současné době nízká, nicméně zaujímají jinou důležitou úlohu, a to, že zajišťují plynulost mezibankovního platebního styku.

**Tabulka 1-2: Základní sazby ČNB**

| úrokové sazby | úroková sazba | platí od |
|---|---|---|
| **dvoutýdenní repo operace - *2T repo sazba*** | 0,75 % | květen 2010 |
| **depozitní facilita - *diskontní sazba*** | 0,25 % | srpen 2009 |
| **marginální zápůjční facilita - *lombardní sazba*** | 1,75 % | květen 2010 |
| **povinné minimální rezervy** | **sazba z primárních vkladů** | **platí od** |
| **banky** | 2,00 % | říjen 1999 |
| **stavební spořitelny a ČMZRB** | 2,00 % | říjen 1999 |

*Zdroj: ČNB*

## 1.4 Měnová politika v EU

Po nahrazení dvanácti národních měn jednou společnou měnou, došlo k převodu působnosti měnové politiky jednotlivých centrálních bank na jeden nadnárodní orgán, a tím je Evropská centrální banka (ECB). Členské země EU mají právo hlasováním se podílet na rozhodování o měnových zásazích celé unie.

ECB zahájila činnost k 1. 1. 1999. Jejích úkolem je zabezpečovat základní funkce centrální banky pro země Evropské měnové unie. Společně s centrálními bankami zemí Evropské unie tvoří Evropský systém centrálních bank. ECB provádí jednotnou měnovou politiku na území EU založenou na emisi a oběhu společné měny euro. Hlavním cílem měnové politiky ECB je cenová stabilita v podobě harmonizovaného indexu spotřebitelských cen. Horní hranice inflace měřené tímto indexem je stanovena na 2% meziročního přírůstku v eurozóně. Postup v měnové politice je kombinací dvou transmisních mechanismů, cílování inflace a regulace peněžní zásoby. Při cílování inflace se ECB snaží regulovat krátkodobou úrokovou míru. Tento postup uplatňuje také ČNB. ECB se také snaží kvantifikovat a regulovat vývoj peněžní zásoby v podobě měnového agregátu M3, a to opět pomocí krátkodobé úrokové míry. ECB preferuje používání tržních nástrojů. Operace na volném trhu

představují nákupy a prodeje cenných papírů mezi Evropskou centrální bankou a obchodními bankami členských zemí Evropské měnové unie. Základním rozdílem proti ČNB je *dodání likvidity* bankám, jde především o nákupy cenných papírů. Vyhlášená repo sazba má podobu minimální úrokové míry (minimal bid rate).

Do diskontních nástrojů v Evropské měnové unii obecně patří podmínky spojené s vkladovými a úvěrovými operacemi mezi ECB a obchodními bankami v členských zemích Evropské měnové unie. U diskontních nástrojů nenalezneme významnější rozdíly mezi ECB a ČNB. Rovněž podmínky povinných minimálních rezerv v Evropské měnové unii jsou podobné a jsou deponovány u národních centrálních bank. Sazby rezerv jsou také 2%.

**Tabulka 1-3: Základní sazby ECB**

| úrokové sazby | úroková sazba | platí od |
|---|---|---|
| **hlavní repo sazba (fixní sazba)** | 1,00 % | prosinec 2011 |
| **depozitní facilita - *diskontní sazba*** | 0,25 % | prosinec 2011 |
| **marginální zápůjční facilita - *lombardní sazba*** | 1,75 % | prosinec 2011 |

*Zdroj:* www.ecb.europa.eu

# 2 Měnové agregáty

Pro praktickou potřebu řízení množství peněz v oběhu byly vytvořeny ukazatele nazvané měnové agregáty. Pospíšil, Hobza a Puchinger (2006) definují peněžní agregát jako objem části peněžních prostředků s vymezeným stupněm likvidity. Obecně lze konstatovat, že je stanoven základní agregát M1 a každý následný měnový agregát zahrnuje v sobě měnový agregát předchozí s další částí peněžních prostředků s nižší likviditou.

- M1 = hotovostní oběživo + vklady na běžných účtech v bankách v domácí měně
- M2 = M1 + úsporné vklady v bankách v domácí měně + termínované vklady v bankách v domácí měně + vklady v bankách v zahraniční měně
- M3 = M2 + euroměnové vklady u domácích bank

Česká národní banka pro řízení měnové politiky sledovala před vstupem České republiky do Evropské unie dva měnové agregáty, a to agregát M1 a M2. Od vstupu do unie se sledované veličiny změnily vzhledem k potřebě a praktické harmonizaci předpisů a postupů v jednotlivých členských státech a sleduje tak harmonizované peněžní agregáty M1, M2 a M3.

Eurosystém definuje agregáty M1, M2 a M3 jako agregáty úzký, "střední" a široký. Tyto agregáty se liší podle likvidnosti zahrnutých aktiv. Strategie měnové politiky Eurosystému vyžaduje stanovení peněžního agregátu, který bude stabilním a spolehlivým ukazatelem inflace ve střednědobém horizontu. Proto Rada guvernérů ECB rozhodla, že stanoví referenční hodnotu pro meziroční dynamiku růstu peněžního agregátu M3, čímž dala tomuto agregátu prominentní roli ve strategii měnové politiky.

Úzký agregát M1 zahrnuje oběživo a také zůstatky, které lze okamžitě převést na oběživo nebo použít k bezhotovostní platbě, např. jednodenní vklady.

"Střední" peníze (M2) zahrnují úzké peníze (M1) a navíc vklady se splatností do dvou let a vklady s výpovědní lhůtou do tří měsíců. Tyto vklady lze relativně rychle přeměnit do složky úzkých peněz. Likvidita této druhé části agregátu M2 může být zpomalena stanovenými výpovědními lhůtami.

Široké peníze (M3) zahrnují M2 a obchodovatelné nástrojem, které jsou vydávané sektorem měnových finančních institucí. Do tohoto agregátu patří některé nástroje peněžního trhu, zejména akcie/podílové listy fondů peněžního trhu a papíry peněžního trhu, a repo operace.

# 3 Časové řady

## 3.1 Druhy časových řad a jejich základní charakteristiky

Důležitým úkolem statistických analýz ekonomických jevů je zkoumání jejich dynamiky. Empirická pozorování v ekonomické oblasti jsou většinou uspořádána do časové řady. Protože i tato práce využívá data ve formě časových řad, budou v této kapitole definovány základní pojmy z této oblasti.

Dle Arlta a Arltové (2007) se *ekonomickou časovou řadou* rozumí řada hodnot věcně a prostorově vymezeného ukazatele, která je uspořádána směrem od minulosti do přítomnosti. Analýza časových řad je soubor postupů, které jsou využívané pro popis a případně pro prognózu budoucího vývoje těchto řad.

Podle typu ukazatele, který se sleduje, lze rozeznat časové řady *intervalové* a *okamžikové*.

- Intervalové časové řady jsou řadami ukazatelů, jejichž hodnoty závisí na délce časového úseku sledování. V případě, že intervalové ukazatele nebudou vztaženy k intervalu o stejné délce, dochází ke zkreslení. Typickými intervalovými ukazateli jsou extenzivní ukazatele, jako například objem výroby nebo spotřeba surovin.
- Okamžikové časové řady jsou řadami ukazatelů, jejich hodnoty se vztahují k jistým časovým okamžikům. Hodnoty těchto ukazatelů nezávisí na délce časového úseku sledování. Příkladem okamžikového ukazatele je počet nezaměstnaných k určitému datu.

Klasifikaci časových řad lze dále provést podle délky intervalu sledování hodnot na *dlouhodobé*, tyto řady obsahují hodnoty pozorované v ročních nebo delších časových úsecích, *krátkodobé*, tyto řady sledují hodnoty v úsecích kratších, než je jeden rok, a posledním typem jsou *vysokofrekvenční* časové řady, které mají data sledovaná v období kratším, než je jeden týden.

Dále se v této práci používá *prostý aritmetický průměr*, který lze vyjádřit jako

$$\bar{y} = \frac{\sum_{t=1}^{T} y_t}{T}.$$

*Chronologický průměr* je užívá pro vyjádření průměrné hodnoty okamžikové časové řady v případě stejné vzdálenosti mezi jednotlivými okamžiky sledování, a lze ho vyjádřit ve tvaru

$$\bar{y} = \frac{1}{T-1} \cdot \left[ \frac{y_1 + y_2}{2} + \frac{y_2 + y_3}{2} + \cdots + \frac{y_{T-1} + y_T}{2} \right] =$$
$$= \frac{1}{T-1} \cdot \left[ \frac{1}{2} \cdot y_1 + \sum_{t=2}^{T-1} y_t + \frac{1}{2} \cdot y_T \right].$$

V případě nestejné délky jednotlivých okamžiků sledování se používá *vážený chronologický průměr* ve tvaru

$$\bar{y} = \frac{1}{d_1 + d_2 + \cdots + d_{T-1}} \cdot \left[ \frac{y_1 + y_2}{2} d_1 + \frac{y_2 + y_3}{2} d_2 + \cdots + \frac{y_{T-1} + y_T}{2} d_{T-1} \right].$$

*Trend* odráží dlouhodobé změny v průměrném chování časové řady, resp. obecnou tendenci vývoje zkoumaného jevu za dlouhé období. Kvantifikace dynamiky časových řad je možná například pomocí měr dynamiky:

- *Absolutní přírůstek* (první diference) udává, jak se změní hodnota v časové řadě v čase $t$ ve srovnání s hodnotou v čase $t-1$

$$\Delta X_t = X_t - X_{t-1},\ t = 2,3,\ldots,\ T.$$

- *Průměrný absolutní přírůstek* (průměrná diference)

$$\bar{\Delta} = \frac{1}{T-1} \left[ (y_2 - y_1) + (y_3 - y_2) + \cdots + (y_T - y_{T-1}) \right] =$$
$$= \frac{1}{T-1} \sum_{t=2}^{T} \Delta y_t = \frac{y_T - y_1}{T-1}.$$

- *Koeficient růst*u po vynásobení stem říká, na kolik procent hodnoty v čase $t-1$ se změnila hodnota v čase $t$

$$k_t = \frac{X_t}{X_{t-1}},\ t = 2,3,\ldots,\ T.$$

- *Průměrný koeficient růstu* je definován jako geometrický průměr koeficientů růstu

$$\bar{k} = \sqrt[T-1]{k_2 \cdot k_3 \cdot \ldots \cdot k_T} = \sqrt[T-1]{\frac{y_T}{y_1}}.$$

- *Relativní přírůstek* opět po vynásobení stem říká, o kolik procent hodnoty v čase $t-1$ se změnila hodnota v čase $t$

$$\delta_t = \frac{\Delta X_t}{X_{t-1}} = \frac{X_t - X_{t-1}}{X_{t-1}} = \frac{X_t}{X_{t-1}} - 1,\ t = 2,3,\ldots,\ T.$$

- *Průměrný koeficient růstu* se získá, když se od průměrného koeficientu růstu odečte jednička, neboli

$$\overline{\delta} = \overline{k} - 1.$$

## 3.2 Stacionarita

Základním předpokladem dynamických modelů časových řad je fakt, že jsou konstruovány z pozorování ekonomických veličin, která splňují vlastnost *stacionarity*. Jednoduchým příkladem stacionárních řad je taková časová řada, která se po celé sledované období pohybuje v okolí nějaké konstanty. Opakem stacionárních řad jsou řady označované jako *nestacionární*. Tyto řady vykazují zpravidla rostoucí trend a typickými příklady jsou zde časové řady inflace, hrubého domácího produktu, importu, exportu nebo mezd.

Pokud je časová řada nestacionární, je nutné ji transformovat na stacionární. K tomuto účelu se používají první nebo vyšší diference a takové transformované časové řady se poté označují jako *homogenní* nebo *integrované* řádu prvního nebo vyššího.

Stacionární časové řady se označují jako I(0), nestacionární řady se popisují jako I(*d*), kde *d* představuje stupeň integrace (první, druhý, atd.). Většina ekonomických časových řad v praxi je I(1), což znamená, že daná časová řada je stacionární po použití prvních diferencí.

Z důvodu důležitosti stacionárnosti pro kvalitu ekonometrické analýzy je nutné její existenci při konstrukci a odhadu dynamických modelů ekonometrických proměnných testovat. V případě, že je odhadován regresní model dvou časových řad, které jsou v důsledku trendu nestacionární, je odhadová funkce metody nejmenších čtverců (MNČ) nekonzistentní a nelze tedy použít standardní postupy statistické indukce. Při aplikaci MNČ indikují *t*-testy, *F*-testy i index determinace vhodnost modelu. Hušek (2007) dále uvádí, že častým důvodem pro použití prvních diferencí trendem zatížených proměnných místo originálních dat je existence tzv. *zdánlivé regrese*. Zdánlivá regrese se často vyskytuje v případech, kdy například dvě proměnné $Y_t$ a $X_t$, obsahující podobný trend, vykazují významnou regresní závislost, i když jediné, co mají společné, je právě jen stejný trend.

Na začátku ekonometrické analýzy je nutné z nestacionárních časových řad trend odstranit, a to lze obvykle dvěma způsoby. Jak uvádí Hušek (2007), prvním způsobem, jak eliminovat trend je pomocí zahrnutí časové proměnné jako jedné z vysvětlujících proměnných do regresního modelu. Druhým způsobem je nahrazení původních dat prvními nebo vyššími diferencemi.

Při předpokladu lineárního trendu lze regresní model specifikovat jako (Hušek, 2007)

$$Y_t = \delta_1 + \delta_2 t + u_t, \tag{3.1}$$

kde

$$u_t = \alpha u_{t-1} + \varepsilon_t$$

a $\varepsilon_t$ je tzv. bílý šum a $|\alpha| < 1$. Model (3.1) je trendově stacionární (TS). Druhý způsob specifikace modelu v případě lineárního trendu vychází z předpokladu, že proměnná $Y_t$ je generována vztahem

$$Y_t = \delta + Y_{t-1} + u_t \tag{3.2}$$

Model (3.2) je nazýván diferenčně stacionární (DS).

Rozlišení stochastických procesů na trendově a diferenčně stacionární je důležité jak ze statistického, tak i ekonomického pohledu. Pro posouzení toho, zda jsou časové řady typu DS nebo TS lze využít model

$$Y_t = \gamma + \delta t + \alpha Y_{t-1} + u_t\,. \tag{3.3}$$

Je-li $\alpha = 1$ a $\delta = 0$, jde o diferenčně stacionární model. V případě, že $|\alpha| < 1$, je proměnná $Y_t$ trendově stacionární. V prvním případě má rovnice (3.3) jednotkový kořen $(\alpha = 1)$.

K ověření hypotézy, že časová řada je DS nebo TS, lze také vyjít z upravené rovnice (3.3) vztažené k prvním diferencím,

$$\Delta Y_t = \gamma + \delta t + (\alpha - 1) Y_{t-1} + u_t\,. \tag{3.4}$$

Testuje se zde hypotéza $\alpha - 1 = 0$, resp. $\alpha = 1$ proti alternativě, že $\alpha - 1 < 0$, resp. $\alpha < 1$. Protože jde o zkoumání, že pro stochastický proces existuje jednotkový kořen, označují se tyto postupy jako *testy jednotkového kořenu*.

Prvním krokem tvorbě při tvorbě dynamického modelu je testování, zda je časová řada stacionární či nikoliv. Jednoduchým postupem je prozkoumání grafu dané časové řady a, protože v určitých případech je nestacionarita zcela zřejmá, subjektivním posouzením rozhodnout. Nicméně ve zbylých případech je nutné se spolehnout na přesnější statistické metody. Nejčastěji používanými testy jednotkových kořenů jsou postupy, které zpracovali Dickey a Fuller, označované jako DF testy. Tyto testy jsou založeny na regresním tvaru (3.4) a jeho jednodušší podobě

$$\Delta Y_t = (\alpha - 1) Y_{t-1} + u_t\,,$$
$$\Delta Y_t = \gamma + (\alpha - 1) Y_{t-1} + u_t\,.$$

Protože testy jednotkových kořenů platí pouze v případě, že náhodné složky testovaných modelů jsou sériově nezávislé, a jelikož tento požadavek není v ekonomických časových řadách velmi často splněn, byly navrženy modifikace DF testů, které nalézají uplatnění u velkých výběrů i v případě, že autokorelace náhodných složek. Dickey a Fuller navrhli upravené statistiky, známé jako rozšířené DF testy (ADF). Tento ADF test předpokládá autokorelační strukturu ve formě procesu typu AR($r$) a je založen na modelu ve tvaru

$$Y_t = \gamma + \delta t + \alpha Y_{t-1} + \sum_{j=1}^{r-1} \alpha_j \Delta Y_{t-j} + u_t \ . \tag{3.5}$$

Pro testování jednotkových kořenů se vedle DF testů používají rovněž například Phillips-Perronovy testy nebo tzv. KPSS test, pojmenovaný podle počátečních písmen čtyř autorů (Kwiatkowski, Philips, Schmidt a Shin), (Hušek, 2007).

# 4 Vícerozměrné modely časových řad

## 4.1 Vektorové autoregrese

Vektorové autoregresní modely neboli VAR modely, spadají do skupiny postupů pro dynamickou analýzu časových řad dvou a více proměnných, které neobsahují stochastický trend nebo jednotkový kořen (Hušek, 2007). Podstatou těchto modelů je, na rozdíl od modelů simultánně závislých rovnic (MSR), že proměnné v nich obsažené jsou náhodné, tj. mají endogenní charakter. VAR modely jsou založeny na skutečnosti, že endogenní proměnné (zejména makroekonomické) často vykazují společný trend a jsou sériově korelované. Model VAR obsahuje tolik rovnic, kolik je počet endogenních proměnných, přičemž délka zpoždění je pro všechny proměnné obvykle stejná. Exogenní proměnné se zpravidla neberou v úvahu, výjimkou je zahrnutí exogenních proměnných ve formě trendové proměnné či binárních (dummy, resp. umělých) proměnných. Každá endogenní proměnná je funkcí svých zpožděných hodnot, zpožděných hodnot ostatních endogenních proměnných modelu a bílého šumu. Mezi základní požadavky při práci s VAR modely je stacionarita zahrnutých proměnných. VAR modely jsou vhodné k předpovědím, ale často se uplatňují i při volbě a simulaci dopadů hospodářské politiky, v analýze funkcí odezvy (impulse response functions) a při dekompozici rozptylu chyby předpovědi. Další oblastí, kde se využívají, je testování Grangerovy kauzality. Na tyto modely je možné pohlížet jako na zobecnění jednorovnicových autoregresních (AR) modelů na časové řady více proměnných. Jako jejich přednost lze uvést relativní jednoduchost odhadu parametrů pomocí metody nejmenších čtverců (MNČ) nebo metody zobecněných nejmenších čtverců (MZNČ).

Obecně lze maticový standardní tvar *m*-rozměrného modelu s délkou zpoždění *p*, VAR(*p*), pro libovolné pozorování *t* vyjádřit vztahem (Hušek, 2007)

$$\mathbf{y}_t = \boldsymbol{\delta} + \boldsymbol{\Pi}_1 \mathbf{y}_{t-1} + \boldsymbol{\Pi}_2 \mathbf{y}_{t-2} + \ldots + \boldsymbol{\Pi}_p \mathbf{y}_{t-p} + \mathbf{v}_t , \tag{4.1}$$

kde $\boldsymbol{\delta}$ je $m \times 1$ vektor úrovňových konstant,

$\boldsymbol{\Pi}_i$ je matice $m \times m$ matice neznámých parametrů endogenních proměnných, zpožděných o *i* období ($i = 1, 2, \ldots, p$),

$\mathbf{y}$ je $m \times 1$ vektor pozorování běžných nebo stejně zpožděných hodnot endogenních proměnných,

$\mathbf{v}$ je $m \times 1$ vektor normálně rozdělených náhodných složek,

*m* je počet rovnic a zároveň endogenních proměnných modelu.

Dále se předpokládá, že všechny endogenní proměnné, které vstupují do systému, jsou typu I(0), tj. stacionární. Další předpoklad spočívá v tom, že náhodné složky obsažené ve

vektoru $\mathbf{v}_t$ jsou normálně rozdělené s nulovou střední hodnotu $E(\mathbf{v}_t) = \mathbf{0}$ a kovarianční matice, pro kterou platí $E(\mathbf{v}_t \mathbf{v}'_s) = \mathbf{\Sigma}$ pro $s = t$ a $E(\mathbf{v}_t \mathbf{v}'_s) = \mathbf{0}$ pro $s \neq t$, je pozitivně definitní.

Vektorový autoregresní model, kdy maximální délka zpoždění je rovna jednomu období, lze nazvat VAR modelem prvního řádu a označit jako VAR(1) model. Tento model lze přepsat v maticové formě jako

$$\mathbf{y}_t = \boldsymbol{\delta} + \mathbf{\Pi}_1 \mathbf{y}_{t-1} + \mathbf{v}_t,\ t = 1,2,\ldots, T. \tag{4.2}$$

Na modelu (4.2) je patrné, že vyjadřuje jednotlivé běžné hodnoty většího počtu endogenních proměnných jako lineární funkci pouze úrovňové konstanty a stejně zpožděných hodnot všech endogenních proměnných modelu. V tomto případě se jedná o tzv. neomezený redukovaný tvar, ve kterém jako regresory vystupují pouze endogenní zpožděné proměnné.

Rozepíšeme-li model (4.2) jako

$$\begin{aligned} Y_{1t} &= \delta_1 + \pi_{11} Y_{1,t-1} + \pi_{12} Y_{2,t-1} + \nu_{1t} \\ Y_{2t} &= \delta_2 + \pi_{21} Y_{2,t-1} + \pi_{22} Y_{2,t-1} + \nu_{2t}, \end{aligned}$$

je zřejmé, že jednotlivé složky mají následující podobu

$$\mathbf{y}_t = \begin{bmatrix} Y_{1t} \\ Y_{2t} \end{bmatrix} \qquad \mathbf{y}_{t-1} = \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \end{bmatrix} \qquad \boldsymbol{\delta} = \begin{bmatrix} \delta_1 \\ \delta_2 \end{bmatrix} \qquad \mathbf{\Pi}_1 = \begin{bmatrix} \pi_{11} & \pi_{12} \\ \pi_{21} & \pi_{22} \end{bmatrix} \qquad \mathbf{v}_t = \begin{bmatrix} \nu_{1t} \\ \nu_{2t} \end{bmatrix} .$$

### *4.1.1 Stabilita a stacionarita VAR*

Stabilita modelu VAR může být zkoumána z hlediska toho, jaká je jeho reakce na působení exogenního šoku na libovolnou vysvětlovanou endogenní proměnnou. Z tohoto hlediska je zajímavé zkoumat, jestli má tato změna trvalé následky, nebo zda efekt šoku trvá relativně krátkou dobu, tj. postupně odezní. V případě vzniku trvalých následků hovoříme o modelu, který je vůči šoku *nestabilní*, v opačném případě je VAR model *stabilní*. V případě, že má stabilní VAR model navíc alespoň první a druhé momenty konstantní v čase, jedná se o slabě (kovariančně) *stacionární*. Protože je ale stabilita postačující, ale nikoliv nutnou podmínkou stacionarita, mohou existovat modely, které nejsou stabilní.

Vyjdeme-li z modelu VAR(1) ve tvaru (4.2)

$$\mathbf{y}_t = \boldsymbol{\delta} + \mathbf{\Pi}_1 \mathbf{y}_{t-1} + \mathbf{v}_t,\ t = 1,2,\ldots, T.$$

pak stabilita modelu je zajištěna v případě, kdy charakteristická čísla matice $\mathbf{\Pi}_1$ jsou menší než jedna, takže $|\lambda_i| < 1$ pro $i$ = 1,2, …, $m$. Řada $\mathbf{\Pi}_1^s$, $s$ = 0,1,…, je potom absolutně sčitatelná (Arlt, Arltová, 2007). Charakteristická čísla matice $\mathbf{\Pi}_1$ lze určit jako kořeny charakteristické rovnice ve tvaru $|\mathbf{\Pi}_1 - \lambda \mathbf{I}_m| = 0$. Tuto rovnici lze rozepsat ve tvaru

$$\begin{vmatrix} \pi_{11}-\lambda & \pi_{12} & \cdots & \pi_{1m} \\ \pi_{21} & \pi_{22}-\lambda & \cdots & \pi_{2m} \\ \vdots & \vdots & \cdots & \vdots \\ \pi_{m1} & \pi_{m2} & \cdots & \pi_{mn}-\lambda \end{vmatrix} = 0.$$

V případě, že je výše uvedená podmínka stability splněna, je pak model VAR(1) možné považovat za stacionární.

### 4.1.2 Konstrukce VAR modelu

Sestavení modelu vektorové autoregrese lze charakterizovat v několika krocích. Prvním krokem je zajištění stacionárnosti časových řad ekonomických proměnných. Tento krok později umožní aplikovat při konstrukci, odhadu a testování VAR modelu postupy, určené pro jednorozměrné časové řady.

Po převedení časových řad na stacionární následuje v další fázi výběr jednotlivých proměnných modelu a stanovení společné délky maximálního zpoždění. Výběr proměnných se z velké části podřizuje ekonomickým poznatkům. Pak následuje volba vhodné délky zpoždění, přičemž se využívají apriorní informace a modifikovaná informační kritéria, která přihlížejí jednak k očekávané shodě s daty, tak i k rozsahu výběru pozorování. Při volbě délky zpoždění postupujeme tak, že odhadneme parametry několika modelů VAR s různou délkou zpoždění od 1 do $k$, určíme příslušná rezidua a zkoumáme jejich vlastnosti, přičemž se vychází z odhadované kovarianční matice

$$\hat{\mathbf{\Sigma}}_p = \frac{1}{T}\sum_{t=1}^{T} \mathbf{e}_t \mathbf{e}_t' .$$

V případě normality vektoru náhodných složek uvádí Hušek (2007) tyto informační kritéria pro VAR($p$) model:

- Akaikeho kritérium – AIC($p$)

$$AIC(p) = \ln\left(\left|\hat{\mathbf{\Sigma}}_p\right|\right) + \frac{2}{T} pk^2,\ p = 1,2,\ldots,k$$

Schwarzovo bayesovské kritérium – SBIC($p$)

$$SBIC(p) = \ln\left(\left|\hat{\mathbf{\Sigma}}_p\right|\right) + \frac{\ln T}{T} pk^2,\ p = 1,2,\ldots,k$$

- Hannanovo-Quinnovo kritérium – HQIC($p$)

$$HQIC(p) = \ln\left(\left|\hat{\mathbf{\Sigma}}_p\right|\right) + \frac{2\ln(\ln T)}{T} pk^2,\ p = 1,2,\ldots,k$$

Výraz $\left|\hat{\mathbf{\Sigma}}_p\right|$ vyjadřuje determinant odhadované kovarianční matice reziduí pro model VAR($p$) a parametr $T$ vyjadřuje počet efektivně využitých pozorování. Optimální model je

ten, který minimalizuje výše uvedená kritéria. Kritérium AIC($p$) délku zpoždění asymptoticky nadhodnocuje, zatímco zbylá dvě kritéria poskytují konzistentní odhady $p$. Pro malé výběry, kdy $T \geq 16$ obecně platí

$$\text{SBIC}(p) \leq \text{HQIC}(p) \leq \text{AIC}(p),$$

takže SBIC($p$) poskytuje nejmenší délku zpoždění a AIC($p$) největší. Všechny tři odhadnuté hodnoty $p$ se ale také mohou rovnat.

Dalším krokem výstavby modelu VAR je případné jeho zjednodušení. Je patrné, že modely VAR mají dva rozměry. Prvním je počet endogenních proměnných zahrnutých v modelu a druhý rozměrem je pak maximální délka zpoždění. Protože ne vždy je model odhadován z velkého počtu pozorování, je nutné vhodně volit počet parametrů. Toto zjednodušení je vyvoláno snahou zabránit poklesu počtu stupňů volnosti. Na druhé straně je zde také snaha zabránit snížení predikční schopnosti modelu v důsledku nedostatečné délky maximálního zpoždění.

Podstatou posledního kroku při konstrukci VAR modelu je ortogonalizace vektoru náhodných složek. Jde o transformaci, která zaručí, že kovarianční matice náhodných složek bude skalární (Hušek, 2007). Jinak řečeno, VAR($p$) model v obecném tvaru (4.1) musí splňovat požadavek, že libovolné vektory $\mathbf{v}_t$ a $\mathbf{v}_s$ ($t \neq s$) v každé z $m$ rovnic jsou sériově nezávislé.

### *4.1.3 Odhad standardního tvaru VAR modelu*

Je-li VAR model zkonstruován v souladu s požadavky přesné specifikace normálního standardního VAR($p$) modelu, je možné pro odhad konzistentní a asymptoticky normálně rozdělené funkce jeho parametrů aplikovat klasickou metodu nejmenších čtverců (Hušek, 2007). Aplikace nejmenších čtverců na jednotlivé rovnice je možná i pro velké počet rovnic, resp. proměnných, protože ve standardním tvaru VAR modely představují soustavu zdánlivě nezávislých lineárních rovnic. Následně je pak možné použít standardní diagnostické nástroje k ověření vhodnosti modelu, jako je testování významnosti odhadnutých parametrů nebo kritéria shody odhadovaného modelu s daty.

V obecném $m$-rozměrném modelu VAR($p$) vyjádřeném ve tvaru $\mathbf{y}_t = \boldsymbol{\delta} + \boldsymbol{\Pi}_1\mathbf{y}_{t-1} + \boldsymbol{\Pi}_2\mathbf{y}_{t-2} + ... + \boldsymbol{\Pi}_p\mathbf{y}_{t-p} + \mathbf{v}_t$, $t = 1,2,\ldots,T$, jsou odhadovanými parametry $\boldsymbol{\delta}$, $\boldsymbol{\Pi}_1$, $\boldsymbol{\Pi}_2$, $\boldsymbol{\Pi}_p$ a $\sigma_{ij}$.

Na každou z $m$ rovnic v modelu se aplikuje odhadová funkce nejmenších čtverců ve tvaru

$$\hat{\boldsymbol{\pi}}_i = \left(\mathbf{X}'\mathbf{X}\right)^{-1}\mathbf{X}'\mathbf{y}_i, i = 1,2,\ldots, m. \tag{4.3}$$

V případě, že vyjádříme kovarianční matici náhodných složek $\mathbf{v}_t$ ve VAR($p$) modelu jako

$$\mathbf{\Sigma} = \begin{vmatrix} \sigma_{11} & \sigma_{21} & \cdots & \sigma_{1m} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2m} \\ \vdots & \vdots & \cdots & \vdots \\ \sigma_{m1} & \sigma_{m2} & \cdots & \sigma_{mm} \end{vmatrix},$$

odhad jejích konzistentních prvků $\sigma_{ij}$ získáme ze vzorce

$$\hat{\sigma}_{ij} = \frac{(\mathbf{y}_i - \mathbf{X}\hat{\boldsymbol{\pi}}_i)'(\mathbf{y}_i - \mathbf{X}\hat{\boldsymbol{\pi}}_i)}{T}, \; i, j = 1,2,\ldots, m.$$

Konzistentní odhady parametrů VAR modelů jsou východiskem asymptotických testů statistické významnosti odhadových funkcí, a dále jsou i základem pro stanovení předpovědí.

### *4.1.4 Prognózy na základě modelu VAR*

Obecně je pod pojmem predikce chápán kvantitativní odhad pravděpodobnosti budoucích hodnot dané veličiny. Pomocí vektorových autoregresí, jejichž předpovědi spadají do skupiny vícerozměrných metod prognózování, lze stanovit krátkodobé předpovědi ex ante jednoduchou extrapolací. O předpovědi ex ante[2] hovoříme v tom případě, kdy hodnoty vysvětlované endogenní proměnné, ani některé (často všechny) hodnoty vysvětlujících predeterminovaných proměnných v období předpovědi neznáme s jistotou, jsme tedy nuceni je odhadovat (nebo je možné tyto hodnoty stanovit na základě nějaké apriorní informace).

Pro obecný model VAR($p$) vyjádřený jako (4.1) získáme optimální předpověď, tj. předpověď s minimální střední kvadratickou chybou, v období $T$ na období $T + 1$ vyjádřením podmíněného očekávání ve tvaru (Hušek, 2007)

$$\hat{\mathbf{y}}_{T+h|T} = E(y_{T+h} \mid \mathbf{y}_T, \mathbf{y}_{T+1}, \ldots) = \mathbf{\Pi}_1 \mathbf{y}_{T+h-1|T} + \ldots + \mathbf{\Pi}_p \mathbf{y}_{T+h-p|T}, \tag{4.4}$$

kde $\hat{\mathbf{y}}_{t+j|T} = \mathbf{y}_{t+j}$ pro $j \le 0$. Předpovědi pro horizont $h$ spočteme rekurzivně pro jednotlivé hodnoty $h$, takže nejdříve spočteme

$$\hat{\mathbf{y}}_{T+1|T} = \mathbf{\Pi}_1 \mathbf{y}_T + \ldots + \mathbf{\Pi}_p \mathbf{y}_{T+1-p|T}. \tag{4.5}$$

Vektor chyb předpovědí na $h$ období pro obecný VAR($p$) model je možné vyjádřit v následujícím tvaru

$$\mathbf{e}_h^+ = \mathbf{y}_{T+h} - \hat{\mathbf{y}}_{T+h|T} = \mathbf{v}_{T+h} + \mathbf{\Phi}_1 \mathbf{v}_{T+h-1} + \ldots + \mathbf{\Phi}_{h-1} \mathbf{v}_{T+1},$$

kde

$$\mathbf{\Phi}_j = \sum_{j=1}^{i} \mathbf{\Phi}_{i-j} \mathbf{\Pi}_j, \; i = 1,2,\ldots,$$

[2] Vedle předpovědi ex ante rozlišujeme i předpověď ex post. Tuto předpověď získáme tehdy, když můžeme stanovit hodnoty endogenních i predeterminovaných proměnných v období předpovědi s jistotou. Porovnáním předpovědi ex post se skutečnými hodnotami určíme chybu předpovědi.

přičemž platí, že $\mathbf{\Phi}_0 = \mathbf{I}$ a $\mathbf{\Pi}_j = \mathbf{0}$ pro období $j > p$. Takže $\mathbf{v}_t$ vyjadřuje chybu předpovědi v období $t-1$ na období $t$. Kovarianční matice chyb předpovědí na $h$ období má tvar

$$\mathbf{\Sigma}^+(h) = \sum_{j=0}^{h-1} \mathbf{\Phi}_j \mathbf{\Omega} \mathbf{\Phi}'_j \,.$$

V případě nezkorelovanosti náhodných složek s nulovou střední hodnotou poskytují předpovědi (4.3) nejlepší lineární předpovědi. V praktických úlohách se bodové předpovědi spočtou dosazením odhadnutých matic $\hat{\mathbf{\Pi}}_1$, $\hat{\mathbf{\Pi}}_2$, …, $\hat{\mathbf{\Pi}}_p$ do vzorců (4.3) a (4.4).

### *4.1.5 Nedostatky VAR modelů*

Přestože VAR modely disponují některými přednostmi oproti strukturním modelům simultánních rovnic, je vhodné zmínit i jejich nedostatky a omezení (Hušek, 2007).

- Vzhledem k ateoretickému charakteru nejsou vhodné k teoretické analýze a tím i k volbě.
- V případě snahy o co nejvyšší shodu modelu s daty, může aplikace VAR modelů vést ke zdánlivým vztahům a i k nejednoznačné interpretaci odhadnutých parametrů
- U výběrů malého rozsahu dochází k přeparametrizování. Odhady parametrů nejsou statisticky významné z důvodu malého počtu stupňů volnosti.
- I když ve VAR modelech existuje podmínka, že proměnné mají být stacionární, nedoporučují někteří autoři používat k dosažení stacionarity diference proměnných.
- Ačkoli jsou modely VAR prezentovány jako modely, kde v roli regresorů vystupují všechny stejně zpožděné endogenní proměnné, je doporučované v některých případech určit jejich jednotlivé rovnice s různou délkou zpoždění pro konkrétní proměnné. Pro určení optimální délky zpoždění je vhodné použít vícerozměrná informační kritéria.
- Blokové *F* testy pomáhají zjistit, které proměnné mají statisticky významný vliv na budoucí hodnoty všech vysvětlovaných proměnných. Tento test ale nedokáže vysvětlit znaménka odhadnutých parametrů, ani jak dlouho trvá vliv jednotlivých šoků. To lze zjistit pouze analýzou funkcí odezvy funkcí a dekompozicí rozptylu chyb předpovědi.
- Funkci odezvy i dekompozici rozptylů nelze zpravidla zcela přesně interpretovat, neboť jejich intervaly spolehlivosti jsou většinou značně široké.

## 4.2 Grangerova kauzalita

Jak již bylo zmíněno v předešlých kapitolách, mají VAR modely časté použití při testování vzájemných vazeb mezi proměnnými. Při zkoumání vazeb mezi proměnnými

zkoumáme, zda změny jedné proměnné předcházejí změně jiné proměnné. Jinými slovy testujeme existenci korelace mezi současnou hodnotou jedné proměnné a minulými hodnotami ostatních proměnných.

V ekonometrii a při prognózování hovoříme o kauzalitě tehdy, pokud určitá proměnná hraje významnou roli při určování ostatních proměnných v modelu. Toto pojetí kauzality poprvé uvedli Granger (1969) a Sims (1972). Uvedeme-li jednoduchý příklad, tak v jednoduchém dvourovnicovém modelu VAR(1) lze zkoumat hypotézu, podle které změny proměnné *X* předchází změnám proměnné *Y*. Jestliže proměnná *X* podmiňuje proměnnou *Y* ve smyslu Grangerovy kauzality, tak (Hušek 2007):

- zpožděná hodnota proměnné *X* pomáhá ke zlepšení přesnosti předpovědi *Y*, jinými slovy v regresi proměnné *Y* na jejích zpožděných hodnotách by zavedení běžných a minulých hodnot proměnné *X* do množiny vysvětlujících proměnných zlepšilo vypovídací schopnost modelu
- proměnná *Y* nemůže zvýšit přesnost předpovědi *X*

Dále je důležité uvést, že Grangerovo pojetí kauzality nelze zaměňovat s běžně chápaným pojmem příčinné závislosti. Podstatou testování Grangerovy kauzality je pouhé ověření, zda změny jedné proměnné náhodou nepředcházejí změnám jiné proměnné, ověřuje se tedy pouze existence časové precedence mezi proměnnými. Odpověď na otázku, která proměnná je příčinou a která následkem se nehledá.

K ověření platnosti výše uvedených dvou podmínek navrhl Granger (1969) testovací postupy založené na lineárních VAR modelech. Máme-li například dvě proměnné $X_t$ a $Y_t$ a chceme-li zkoumat nulovou hypotézu, že proměnná $X_t$ nepodmiňuje $Y_t$, vyjdeme z lineární regrese $Y_t$ na svých zpožděných hodnotách a stejně zpožděných hodnotách $X_t$. Tato regrese se označuje jako *regrese neomezená*, a lze ji formulovat jako (Hušek, 2007):

$$Y_t = \sum_{i=1}^{p} \alpha_i Y_{i-r} + \sum_{i=1}^{p} \beta_i X_{t-i} + u_t \ , \tag{4.6}$$

přičemž maximální zpoždění *p* volíme libovolně dlouhé. V případě, že koeficienty $\beta_i = 0$ ($i$ = 1,2,…, *p*), proměnná $X_t$ nesplňuje předpoklad Grangerovy kauzality. Dalším krokem je vyjádření lineární závislosti $Y_t$ na jejích hodnotách zpožděných o stejný počet období *p*. V tomto případě hovoříme o *regresi omezené* ve tvaru

$$Y_t = \sum_{i=1}^{p} \alpha_i Y_{t-i} + u_t \ . \tag{4.7}$$

K testování statistické významnosti zpožděných hodnot proměnné *X* v regresi (4.6) je používán postup založený na testování hypotéz

$H_0$: $\beta_i = 0$ pro $i$ = 1,2,…, *p* (proměnná *X* neovlivňuje proměnnou *Y* v Grangerově pojetí)

$H_1$: $\beta_i \neq 0$ pro $i = 1,2,\ldots, p$ (proměnná $X$ ovlivňuje $Y$)

Díky tomu, že je odhadová funkce (4.3) asymptoticky normální, je možné k ověření statistické významnosti zpožděných hodnot proměnné $X$ v regresi (4.6) využít $F$ testu s $q$ a $T$-$m$ stupni volnosti, jehož statistiku spočteme ze vztahu

$$F = \frac{(\mathbf{e}'\mathbf{e})_O - (\mathbf{e}'\mathbf{e})_N}{q(\mathbf{e}'\mathbf{e})_N}(T - m), \tag{4.8}$$

kde $(\mathbf{e}'\mathbf{e})_O$ a $(\mathbf{e}'\mathbf{e})_N$ jsou součty čtverců reziduí v omezené a neomezené regresi,

$T$ je počet pozorování,

$m$ je počet odhadnutých parametrů v neomezené regresi a

$q$ vyjadřuje počet omezení parametrů.

V případě, že pomocí $F$ testu zjistíme, že parametry $\beta_i$ v regresi (4.6) se významně odlišují od nuly, zamítáme nulovou hypotézu, že $X_t$ nepodmiňuje proměnnou $Y_t$ ve smyslu Grangerovy kauzality. Další krok spočívá v testování nulové hypotézy, která říká, že proměnná $Y_t$ nepodmiňuje v Grangerově smyslu $X_t$. Postup je stejný, pouze v rovnicích (4.6) a (4.7) obě proměnné prohodíme. K závěru, že $X_t$ podmiňuje $Y_t$ v Grangerově pojetí dojdeme tehdy, pokud v prvním kroku testování odmítneme nulovou hypotézu, že $X_t$ nepodmiňuje $Y_t$ a zároveň ve druhé fázi nulovou hypotézu přijmeme (tj. akceptujeme fakt, že $Y_t$ nepodmiňuje $X_t$). Jak již bylo zmíněno v úvodu kapitoly, tento závěr nemůže být interpretován tak, že $X_t$ je příčinou a $Y_t$ následkem. Pouze bylo prokázáno, že $X_t$ pomáhá zlepšit přesnost předpovědi $Y_t$.

## 4.3 Analýza funkcí odezvy („Impuls-Reakce“)

Po definování kauzálních závislostí jednotlivých procesů v Grangerově smyslu je dalším zajímavým krokem zkoumání, jakou *reakci* („response“) v jedné časové řadě vyvolá exogenní *impuls* („impulse“) v jiné časové řadě. Ve vícerozměrném systému je jedná o zkoumání vztahu vždy mezi dvěma jednorozměrnými řadami. Detailním popisem této problematiky se zabývá např. Arlt, Arltová (2007).

Po rozepsání má $l$-rozměrný stacionární model VAR(1)

$$\mathbf{X}_t = \boldsymbol{\varphi}_1 \mathbf{X}_{t-1} + \mathbf{a}_t$$

tvar

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

Vektor konstant je v tomto modelu nulový, tj. $\boldsymbol{\varphi}_0 = (\phi_{0,1}, \phi_{0,2}, \ldots, \phi_{0,l})' = \mathbf{0}$. Výchozím předpokladem je, že $\mathbf{a}_t$ pro $t < 0$ jsou nulové vektory a $\mathbf{X}_t = \mathbf{0}_l$ pro $t < 0$. Další předpoklad

je, že v čase $t$ = 0 bude vektor $\mathbf{a}_t$ obsahovat jednu jedničku a jinak samé nuly. Jednička znamená impuls v dané časové řadě, takže například $\mathbf{a}_0 = (0,1,0,\ldots 0)$ znamená, že impuls je u řady $X_{2t}$. Pro $t > 0$ bude $\mathbf{a}_t = \mathbf{0}$.

V čase $t = 0$ platí

$$\mathbf{X}_0 = \begin{bmatrix} X_{10} \\ X_{20} \\ \vdots \\ X_{l0} \end{bmatrix} = \begin{bmatrix} a_{10} \\ a_{20} \\ \vdots \\ a_{l0} \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \\ \vdots \\ 0 \end{bmatrix},$$

v čase $t = 1$

$$\mathbf{X}_1 = \boldsymbol{\varphi}_1 \mathbf{X}_0 = \begin{bmatrix} \phi_{1,11} & \phi_{1,12} & \cdots & \phi_{1,1l} \\ \phi_{1,21} & \phi_{1,22} & \cdots & \phi_{1,2l} \\ \vdots & \vdots & \vdots & \vdots \\ \phi_{1,l1} & \phi_{1,l2} & \cdots & \phi_{1,ll} \end{bmatrix} \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} \phi_{1,12} \\ \phi_{1,22} \\ \vdots \\ \phi_{1,l2} \end{bmatrix},$$

v čase $t = 2$

$$\mathbf{X}_2 = \boldsymbol{\varphi}_1 \mathbf{X}_1 = \boldsymbol{\varphi}_1^2 \mathbf{X}_0 = \begin{bmatrix} \phi_{1,11}\phi_{1,12} + \phi_{1,12}\phi_{1,22} + \ldots + \phi_{1,1l}\phi_{1,l2} \\ \phi_{1,21}\phi_{1,12} + \phi_{1,22}\phi_{1,22} + \ldots + \phi_{1,2l}\phi_{1,l2} \\ \vdots \\ \phi_{1,l1}\phi_{1,12} + \phi_{1,l2}\phi_{1,22} + \ldots + \phi_{1,ll}\phi_{1,l2} \end{bmatrix},$$

atd.

Reakci ve všech procesech v čase $t = 1$ na impuls ve druhém procesu v čase $t = 0$ udává druhý sloupec matice $\boldsymbol{\varphi}_1$, reakci ve všech procesech v čase $t = 2$ na impuls ve druhém procesu v čase $t = 0$ udává sloupec $\boldsymbol{\varphi}_1^2$, obecně reakci ve všech procesech v čase $t = i$ na impuls ve druhém procesu v čase $t = 0$ udává druhý sloupec matice $\boldsymbol{\varphi}_1^i$.

Odezvu v procesu $j$ na jednotkový impuls v procesu $k$ lze vyjádřit graficky tak, že na horizontální osu se vynese čas $t$ a na vertikální osu hodnoty odezvy $j$-tého procesu na impuls v $k$-tém procesu.

## 4.4 Kointegrace

### *4.4.1 Kointegrované procesy*

V praxi lze statisticky významné odhady parametrů v regresních funkcích získat zpravidla použitím jejich diferencí různých stupňů namísto původních hodnot. Tento postup lze aplikovat při analýze krátkodobé dynamiky, nicméně však již nedokáže zachytit a využít dlouhodobé vztahy mezi ekonomickými veličinami. Ve vícerozměrných modelech ekonomických časových řad je tedy vhodné rozlišovat mezi krátkodobými a dlouhodobými

vztahy. Krátkodobé vztahy existují pouze v relativně krátkém období a časem vymizí. Např. náhlé klimatické změny mohou dočasně snížit dodávky zemědělské produkce a tak zvýšit její cenu, časem se ale díky standardnímu klimatu, který opět nastane, dodávky zase obnoví na původní úroveň a ceny klesnou. Na druhou stranu, lze velmi často a priori vycházet z předpokladu, že dvě nebo více ekonomických proměnných jsou vzájemně svázány vztahem dlouhodobé rovnováhy. Systém s dlouhodobými vztahy tenduje k rovnovážnému stavu (ekvilibriu). Tento stav je možné charakterizovat jako situaci, kdy se tyto proměnné krátkodobě mohou (například vlivem šoků nebo změnou hospodářské politiky) odchylovat od stabilní úrovně, avšak působením ekonomických faktorů se v dlouhém období vracejí zpět do rovnováhy. Jinak řečeno, časové řady se nacházejí v ekvilibriu, pokud je odklon směrů vývoje časových řad pouze krátkodobý a existuje hranice, za kterou nemůže jít.

Jak již by zmíněno dříve, většina dat z makroekonomických veličin jsou nestacionární, ale integrovaná řádu jedna, tj. časová řada se stane stacionární po použití prvních diferencí. Z důvodu nekonstantního rozptylu by se dalo usuzovat, že tyto veličiny nemohou dlouhodobě dospět k nějakému rovnovážnému stavu. Ve skutečnosti je to však pro dvě nebo více proměnných, které jsou integrované, možné, a to tehdy, jsou-li určité lineární kombinace těchto proměnných integrované řádu nula. Takové proměnné se označují jako *kointegrované*.

Zkoumání a podstatu kointegrace mezi dvěma řadami je možné si obecně představit jako snahu rozpoznat a ověřit, zda existuje dlouhodobý vztah mezi jejich trendy, resp. jde-li o zdánlivou či skutečnou regresní závislost mezi těmito proměnnými. Kointegrační teorii poprvé zpracoval Granger (1981) a dále rozšířili Engle a Granger (1987).

Arlt a Arltová (2007) uvádějí základní pravidla, týkající se lineárních kombinací procesů typu I(0) a I(1),

- jestliže $X_t \sim$ I(0), pak $a + bX_t \sim$I(0)
- jestliže $X_t \sim$ I(1), pak $a + bX_t \sim$I(1)
- jestliže $X_t \sim$ I(0) a $Y_t \sim$I(0), pak $aX_t + bY_t \sim$I(0)
- jestliže $X_t \sim$ I(1) a $Y_t \sim$I(0), pak $aX_t + bY_t \sim$I(1)
- v zásadě platí, že pokud $X_t \sim$ I(1) a $Y_t \sim$I(1), pak $aX_t + bY_t \sim$I(1).

V praxi se ale vyskytují případy, kdy poslední pravidlo neplatí, tj. že lineární kombinace procesů, $X_t \sim$ I(1) a $Y_t \sim$I(1), je stacionární, tzn. $aX_t + bY_t \sim$I(0). Pokud jsou oba procesy $X_t$ a $Y_t$ typu I($d$) a existuje-li lineární kombinace $aX_t + bY_t \sim$I($d - c$), přičemž $c$ je kladné, pak se tyto procesy nazývají kointegrované řádu $d$, $c$, a označují se jako CI($d$, $c$). Vektor ($a$, $b$)' je označován jako tzv. kointegrační vektor.

V praktické ekonometrii je nicméně vhodné se zaměřit na případ, kdy kointegrační vektor vede ke stacionární lineární kombinaci, tzn. $d = c$. Kointegrační vztah je tak typu I(0). Při kointegraci dvou proměnných existuje pouze kointegrační vektor. V případě kointegrace obecně $m$ proměnných pak může existovat maximálně $m - 1$ vektorů.

Podle Arlta a Arltové (2007) existují 3 důvody, proč lze považovat princip kointegrace za základní myšlenku modelování integrovaných řad

1. Stacionární lineární kombinaci integrovaných (nestacionárních) časových řad je možné chápat jako odhad ekvilibria, které spojuje uvažované časové řady. Ekvilibrium je v tomto případě střední hodnota stacionárního generujícího procesu, jeho odhadem je pak průměr hodnot složené stacionární časové řady.
2. Regrese obsahující integrované časové řady má smysl pouze tehdy, jsou-li tyto časové řady kointegrované. Není-li tomu tak, každá časová řada má jiný směr vývoje. Test kointegrace je současně metodou pro odlišení zdánlivé a pravé regrese.
3. Skupinu kointegrovaných časových řad lze popsat modelem korekce chyby, jehož prostřednictvím je možné odlišit dlouhodobé a krátkodobé vztahy mezi časovými řadami.

Nejvíce rozšířeným testem kointegrace je pro svou jednoduchost Engleův-Grangerův test (EG test kointegrace), který je založen na testování jednotkových kořenů a který je užívaný při kointegraci dvou časových řad, kdy může existovat pouze jeden kointegrační vztah. Obecně při kointegraci více časových řad je možné použít Johansenův test kointegrace.

Dalším způsobem, jakým lze analyzovat kointegrované časové řady je model korekce chyby, pomocí kterého lze zjistit, zda mezi časovými řadami existují, vedle krátkodobých, i dlouhodobé vztahy.

### *4.4.2 Model korekce chyby*

Model korekce chyby (MKCH) představuje alternativu při specifikaci modelů z nestacionárních časových řad a je vhodný v těch případech, kdy není splněn předpoklad stacionárnosti proměnných, které jsou však kointegrované. Pro tyto modely je charakteristické to, že mají dynamickou strukturu, neboť obsahují zpožděné hodnoty vysvětlovaných i vysvětlujících proměnných. Výhoda tohoto přístupu spočívá v tom, že odhadem MKCH získáme informaci jak o dlouhodobém vztahu vysvětlované proměnné a zbylých regresorů, tak o jejich vztazích krátkodobých.

Hušek (2007) uvádí dva problémy, které vznikají v souvislosti s použitím MKCH. První nevýhodou je fakt, že předpokladem při použití jednorovnicového MKCH je exogenní charakter všech vysvětlujících proměnných. Dále v MKCH s více než dvěma proměnnými může existovat více než jeden kointegrační vztah.

Vyjdeme-li z dynamického jednorovnicového modelu obsahujícího proměnné $X_t$ a $Y_t$, které jsou integrované 1. řádu,

$$Y_t = \alpha + \beta_0 X_t + \beta_1 X_{t-1} + \gamma_1 Y_{t-1} + u_t, \tag{4.9}$$

tak v případě, že obě proměnné konvergují k dlouhodobým neměnným hodnotám $X_t = X_{t-1} = \overline{X}$ a $Y_t = Y_{t-1} = \overline{Y}$, dostaneme řešení pro implicitní rovnováhu modelu (4.9) ve tvaru

$$\overline{Y} = \alpha + \beta_0 \overline{X} + \beta_1 \overline{X} + \gamma_1 \overline{Y}, \tag{4.10}$$

a jednoduchou úpravou

$$(1-\gamma_1)\overline{Y} = \alpha + (\beta_0 + \beta_1)\overline{X},$$

získáme výsledný tvar

$$\overline{Y} = \frac{\alpha}{(1-\gamma_1)} + \frac{(\beta_0 + \beta_1)}{(1-\gamma_1)}\overline{X}. \tag{4.11}$$

Tvar (4.11) neobsahuje náhodnou složku, protože v případě rovnováhy je střední hodnota náhodné složky $u_t$ nulová.

V rovnovážném stavu lze model (4.11) přepsat do podoby

$$Y_t = \rho_1 + \rho_2 X_t, \tag{4.12}$$

kde $\rho_1 = \dfrac{\alpha}{(1-\gamma_1)}$,

$\rho_2 = \dfrac{(\beta_0 + \beta_1)}{(1-\gamma_1)}$,

$|\gamma_1| < 1$.

Rozdíl mezi $Y_t$ a $\rho_1 + \rho_2 X_t$ může být popisován jako nerovnováha.

Model (4.9) lze pomocí prvních diferencí obou proměnných přepsat jako (Hušek, 2007)

$$\Delta Y_t = \alpha + \beta_0 \Delta X_t + \delta(Y_{t-1} - \rho_2 X_{t-1}) + u_t, \tag{4.13}$$

kde $\delta = -(1-\gamma_1)$, takže $\delta < 0$.

Tvar (4.13) je vyjádřením modelu korekce chyby, který je nelineární v parametrech.

Výraz $\delta(Y_{t-1} - \rho_2 X_{t-1})$ označován jako tzv. *rovnovážná chyba* a představuje odchylku vysvětlované proměnné od dlouhodobé rovnováhy. Změna $\Delta Y_t$ je složena jednak ze změny vyvolané změnou $\Delta X_t$, reprezentující pohyb po dlouhodobé trajektorii a jednak částí odchylky $(Y_{t-1} - \rho_2 X_{t-1})$ od rovnováhy.

Kointegrační parametr $\rho_2$ charakterizuje dlouhodobou závislost mezi *Y* a *X*, zatímco parametr $\beta_0$ vyjadřuje krátkodobou reakci mezi změnami *Y* a *X*. Poslední parametr $\delta$ měří *rychlost přizpůsobení* k rovnováze v čase.

# 5 Aplikace vybraných modelů na ČR

Analýzou vztahů mezi cenovou hladinou a vybranými makroekonomickými veličinami, jako je výše HDP nebo peněžní zásoby se zabývá řada ekonometrických studií. Důraz je kladen na kvantifikace ekonomických vztahů mezi úrovní cen a těmito veličinami, což umožňuje mj. stanovit podmíněné předpovědi vývoje inflace.

Obecně lze ekonometrický model pro obě země využitý v této práci popsat jako

$$P = f(R, M, Y, \varepsilon),$$

kde $P$ je inflace

$R$ je úroková míra

$M$ je peněžní zásoba

$Y$ hrubý domácí produkt a

$\varepsilon$ je náhodná složka.

Inflace, jako vysvětlující proměnná, vystupuje jako funkce úrokové míry, peněžní zásoby, hrubého domácího produktu a náhodné složky.

## 5.1 Data

Zdrojem dat o hrubém domácím produktu a inflaci pro Českou republiku byly internetové stránky Českého statistického úřadu, resp. Evropského statistického úřadu. Časové řady úrokové míry a peněžní zásoby byly získány z veřejné databáze časových řad ARAD, která je součástí informačního systému České národní banky. Časové řady mají formu čtvrtletních pozorování za období I/2002 až IV/2011.

Míra inflace je měřena pomocí harmonizovaného indexu spotřebních cen, který je ve formě bazického indexu (rok 2005=100). Data byla k dispozici ve formě měsíčních pozorování, která jsem pomocí váženého chronologického průměru převedl na čtvrtletní časové řady.

Za indikátor úrokové míry jsem zvolil ukazatel 1RPRIBOR v procentech.

Za indikátor peněžní zásoby pak byl zvolen peněžní agregát M2, jehož jednotky jsou mld. Kč.

Hrubý domácí produkt je v běžných cenách v mil. Kč. Tato řada byla stažena již jako sezónně očištěná.

Jako označení jednotlivých proměnných v dalších částech práce jsem zvolil názvy *ISC_CR, PRIBOR_CR, M2_CR* a *HDP_CR*.

**Obrázek 5-1: Průběhy jednotlivých proměnných pro ČR**

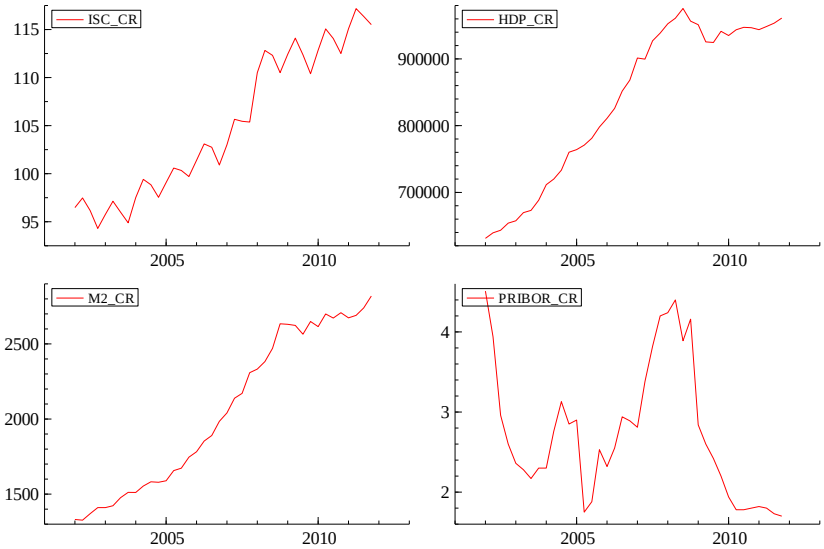


*Zdroj: Vlastní výpočet v GiveWin*

Prvním krokem je očištění všech řad od sezónnosti. Statistickými testy byla významná sezónnost zjištěna u proměnných *ISC* a *M2*. Pro očištění jsem zvolil metodu X12 ARIMA, která je součástí softwaru GiveWin 2.10. Vedle tohoto softwaru budu v této práci pro výpočty používat ještě program Gretl 1.8.7. Průběhy sezónně očištěných řad *SAISC_CR* a *SAM2_CR* jsou připojeny v příloze č. 2.

Jak bylo zmíněno v předešlých kapitolách, u časových řad je nutné zkoumat jejich stacionaritu. Pro testování stacionarity jsem použil rozšířený Dickey-Fullerův test (ADF test) jednotkových kořenů s konstantou. Nulová hypotéza zde říká, že jednotkový kořen existuje, tudíž je časová řada nestacionární. V tabulce č. 5.1 jsou výsledky ADF testů všech čtyř proměnných.

**Tabulka 5-1: ADF testy**

| Proměnná | *p*-value |
|---|---|
| **SAISC_CR** | 0,996 |
| **HDP_CR** | 0,282 |
| **SAM2_CR** | 0,941 |
| **PRIBOR_CR** | 0,228 |

*Zdroj: Vlastní výpočet v Gretl*

Z výše uvedené tabulky je vidět, že všechny proměnné jsou nestacionárního charakteru. Pro převedení časových řad na stacionární jsem nejprve vytvořil logaritmy všech pozorování a poté spočítal jejich první diference. Nové časové řady nesou označení *DLSAISC_CR*, *DLHDP_CR*, *DLSAM2_CR* a *DLPRIBOR_CR*. Průběhy takto transformovaných řad jsou k nahlédnutí v příloze č. 4.

Výsledky ADF testů pro první diference logaritmů jsou obsaženy v tabulce č. 5.2.

**Tabulka 5-2: ADF testy transformovaných proměnných**

| Proměnná | *p*-value |
|---|---|
| **DLSAISC_CR** | 0,014 |
| **DLHDP_CR** | 0,000 |
| **DLSAM2_CR** | 0,003 |
| **DLPRIBOR_CR** | 0,000 |

*Zdroj: Vlastní výpočet v Gretl*

Jak se vidět z hodnot *p*-value, transformované časové řady jsou již stacionární.

## 5.2 Odhad VAR modelu a analýza funkce odezvy

V této práci budu odhadovat čtyřrovnicový VAR model se čtyřmi endogenními proměnnými.

Z důvodu malého počtu pozorování jsem volil časové zpoždění o délce pouze jednoho zpoždění. Dále byla do modelu z důvodu eliminace skoku v časové řadě *DLSAISC_CR* přidána binární nula-jednotková proměnná *D*, která obsahuje jedničku na pozici v I/2008.

Odhad modelu VAR(1) včetně sdružených diagnostických testů pro data za období III/2002 až IV/2011 je uveden v příloze č. 6. Celkový *F*-test indikuje vhodnost modelu jako celku. Dílčí *F*-testy, indikující statistickou významnost parametrů jednotlivých zpožděných proměnných ve všech rovnicích najednou, označily odhady parametrů pro proměnné *DLSAISC_CR* a *DLPRIBOR_CR* jako nevýznamné, nicméně jsem se z důvodu analýzy Grangerovy kauzality rozhodl ponechat model jako čtyřrovnicový.

Testy diagnostické kontroly ukazují, že model VAR(1) je přijatelný. Breuschův-Godfreyův modifikovaný test (AR 1-3 test) ukazuje, že ani v jedné rovnici rezidua nevykazují autokorelaci. Test normality prokázal reziduální nenormalitu u časové řady *DLPRIBOR_CR*, ostatní časové řady jsou v pořádku. Test reziduální podmíněné heteroskedasticity (ARCH test) neprokázal její existenci ani v jedné zkoumané rovnici. Rovněž reziduální heteroskedasticita (hetero test a hetero-X test) nebyla prokázána. Vícerozměrná zobecnění výše zmíněných testů poskytují také pozitivní výsledky.

Co je týče odhadů jednotlivých parametrů modelu, tak v rovnici pro *DLSAISC_CR* vyšly tři statisticky významné parametry. Jedním z nich je parametr pro zpožděnou hodnotu vysvětlované proměnné, dále pak jsou to parametry *DLSAM2_CR* a *D*. Nepočítáme-li dummy proměnnou, tak oba statisticky významné parametry indikují pozitivní vztah s indexem spotřebních cen *DLSAISC_CR*. V rovnici pro *DLHDP_CR* vyšla na 5% hladině významnosti podstatná hodnota proměnné *DLSAM2_CR*, na 10% jsou pak významné parametry pro zpožděnou hodnotu HDP a také úrokové sazby. V další rovnici pro *DLSAM2_CR* jsou na 5%

hladině statisticky významné proměnné *DLHDP_CR* a *DLSAM2_CR*. V poslední rovnici není významná žádná z vysvětlujících proměnných. Rezidua modelu jsou obsažena v příloze č. 7.

V příloze č. 8 jsou zachyceny reakce jednotlivých časových řad na jednotkové exogenní impulsy. Vychází se z výše uvedeného VAR(1) modelu. Exogenní šoky rozkmitávají jednotlivé rovnice v modelu, které se buď vracejí po určitém počtu období na svoji původní úroveň, nebo se ustálí na úrovni nové. V příloze je patrné, že například na šok v peněžní zásobě *DLSAM2_CR* reaguje v prvních obdobích index spotřebních cen *DLSAISC_CR* poměrně silně, v dalších obdobích reakce klesá. Příkladem, kdy je nastolena nová rovnováha, je vztah peněžní zásoby a úrokové míry. Je vidět, že na šok v peněžní zásobě nereaguje úroková míra *DLPRIBOR_CR* navrácením se na původní úroveň, nýbrž ustálením na nové rovnováze.

## 5.3 Analýza Grangerovy kauzality

V tomto odstavci je otestována Grangerova kauzalita mezi jednotlivými časovými řadami. GK je opět zkoumána pro model VAR(1) z předcházející kapitoly. Statisticky významné testy jsou uvedeny v tabulce č. 5.3.

**Tabulka 5-3: Grangerova kauzalita**

```
Test for excluding: DLSAM2_CR_1@DLSAISC_CR
Subset Chi^2(1) =   5.3686 [0.0205]*

Test for excluding: DLSAM2_CR_1@DLHDP_CR
Subset Chi^2(1) =   5.0652 [0.0244]*

Test for excluding: DLHDP_CR_1@DLSAM2_CR
Subset Chi^2(1) =   8.4439 [0.0037]**

Test for excluding: DLPRIBOR_CR_1@DLHDP_CR
Subset Chi^2(1) =   2.9030 [0.0884]
```

*Zdroj: Vlastní výpočet v GiveWin*

Z výsledků je patrné, že byla zjištěna oboustranná Grangerova kauzalita v prvním zpoždění mezi proměnnými *DLSAM2_CR* a *DLHDP_CR*, a to na 5% hladině významnosti. Dále byl prokázán statisticky významný vliv, opět na 5% hladině významnosti, proměnné *DLSAM2_CR* na proměnnou *DLSAISC_CR*. Na 10% hladině významnosti pak *DLPRIBOR_CR* zvyšuje kvalitu předpovědi proměnné *DLHDP_CR*.

## 5.4 Kointegrace a model korekce chyby

Tato kapitola je věnována problematice kointegrační analýzy časových řad. Podobně jako v práci např. Arlt a Arltová (2007) nebude do tohoto modelu zahrnuta původní proměnná *ISC_CR*, ale její transformovaná proměnná *MI*, která vyjadřuje čtvrtletní míru inflace a která byla spočítána jako koeficient růstu *SAISC_CR*. Před analýzou byla tato časová řada zlogaritmována a vynásobena stem. Takto nově vytvořená proměnná je označena jako *LMI_CR*.

V příloze č. 10 je výstup odhadu VAR(1) modelu logaritmovaných časových řad. Tento model tedy obsahuje časové řady *LMI_CR*, *LHDP_CR*, *LSAM2_CR* a *LPRIBOR_CR*. Celkový *F*-test indikuje vhodnost modelu jako celku, pozitivní výsledky dávají i dílčí *F*-testy. Až na reziduální nenormalitu u časové řady *LPRIBOR_CR* vyšly diagnostické testy v zásadě v pořádku.

V příloze č. 11 je k nahlédnutí Johansenův test kointegrace („*Trace test*“). Na prvním řádku tento test ukazuje, že na 5% hladině významnosti model obsahuje více než 0 kointegračních vektorů, ve druhém řádku prokazuje, že systém obsahuje více než 1 vektor, na třetím řádku ale již existence více než 2 vektorů prokázána není. Lze tedy konstatovat přítomnost maximálně dvou kointegračních vektorů. Odhad těchto vektorů je vidět v příloze č. 12. Na konci tabulky je informace o neidentifikovanosti matice beta.

Tato informace indikuje potřebu zavedení dodatečných restrikcí. Provedl jsem tedy omezení v kointegračních vztazích podle Arlta a Arltové (2007). V prvním vztahu jsem zavedl omezení, že parametr u *LPRIBOR _CR* bude nulový. Tato restrikce vede k funkci dlouhodobé poptávky po penězích. Ve druhém vztahu jsem určil parametry u *LHDP_CR* a *LSAM2_CR* jako nulové. Toto omezení znamená kointegraci mezi nominální úrokovou sazbou a mírou inflace, tj. Fisherův efekt. Kointegrační matice vyjadřující tato omezení má tvar

$$\boldsymbol{\beta}' = \begin{bmatrix} \beta_{LMI_CR} & \beta_{LHDP_CR} & 1 & 0 \\ \beta_{LMI_CR} & 0 & 0 & 1 \end{bmatrix}, \tag{5.1}$$

kde řádky vyjadřují kointegrační vektory a jednotlivé složky v řádcích vyjadřují parametry pro proměnné *LMI_CR*, *LHDP_CR*, *LSAM2_CR* a *LPRIBOR_CR*.

V příloze č. 13 jsou k nahlédnutí výsledky po dosazení restrikcí. Matice beta je již identifikovaná. V případě, že je v prvním vztahu nulový parametr u úrokové míry, lze rovnici popsat jako

$$C_{1t} = -0{,}76408 LMI_CR_t - 0{,}55047 LHDP_CR_t + LSAM2_CR_t, \tag{5.2}$$

druhý kointegrační vztah má pak tvar

$$C_{2t} = -0{,}92912 LMI_CR_t + LPRIBOR_CR_t . \tag{5.3}$$

Z prvního výše uvedeného vztahu vyplývá, že *LSAM2_CR* je v přímém vztahu s *LMI_CR* a *LHDP_CR*. Ve druhém pak *LPRIBOR_CR* je v přímém vztahu s *LMI_CR*. Tyto výsledky odpovídají teoretickým předpokladům.

Kointegrační analýza může mít také formu jednorovnicového podmíněného modelu. Vyšel jsem z předcházejícího modelu s proměnnými *LPRIBOR_CR* a *LMI_CR*. Odhady parametru jsou k nahlédnutí v příloze č. 14. Rovnice má tvar

$$LPRIBOR_CR_t = 0{,}820319 LMI_CR_t . \tag{5.4}$$

V rovnici (5.4) lze vidět, že odhad parametru je podobný jako v rovnici (5.3). Diagnostické testy indikují přítomnost autokorelace a reziduální heteroskedasticity. Nicméně dle Arlta a Arltové (2007) by přítomnost autokorelace neměla hrát roli. Přítomnost heteroskedasticity z důvodu další analýzy opomenu. Pro test kointegrace je použit test ADF, jenž je uveden v příloze č. 15 a který prokazuje stacionaritu reziduí statické regrese, tudíž prokazuje kointegraci analyzovaných časových řad.

Z důvodu přítomnosti autokorelace ve statické regresi (5.4), je vhodné do tohoto modelu přidat zpoždění, model tak dynamizovat a tím autokorelaci odstranit. Model dynamické regrese má tvar

$$LPRIBOR_CR_t = \alpha \cdot LPRIBOR_CR_{t-1} + \beta_0 \cdot LMI_CR_t - \delta \cdot D_t + a_t . \tag{5.5}$$

Model (5.5) lze vyjádřit ve formě MKCH, který má tvar

$$\Delta LPRIBOR_CR_t = \beta_0 \cdot \Delta LMI_CR_t - (1-\alpha)\left[ LPRIBOR_CR_{t-1} - \frac{\beta_0}{1-\alpha} LMI_CR_{t-1} \right] - \delta \cdot D_t + a_t \tag{5.6}$$

Z diagnostických testů, jež jsou obsaženy v odhadu dynamického modelu v příloze č. 16, je patrné, že autokorelace byla odstraněna. Parametr $\alpha$ je roven hodnotě 0,898, což vyhovuje předpokladům, tj. že $\alpha \in (0{,}1)$. Kointegrační parametr $[\beta_0 / (1-\alpha)]$, měřící dlouhodobou závislost mezi proměnnými, je roven 1,618 a indikuje přímou závislost. Parametr $\beta_0$, který vyjadřuje krátkodobou reakci mezi proměnnými, je roven 0,165. Rychlost přizpůsobení k rovnováze, tedy parametr $(\alpha - 1)$ je roven hodnotě -0,102.

## 5.5 Predikce

V této kapitole je provedena predikce ex post na období II/2011 – IV/2011 a následně je provedena predikce ex ante na období I/2012 – III/2012.

Predikce ex post na tři období je provedena na základě VAR(1) modelu s daty za období III/2002 – I/2011, jenž je uveden v příloze č. 17.

Tabulky č. 5.4 a 5.5 obsahují skutečné hodnoty jednotlivých proměnných srovnané s jejími bodovými předpověďmi. Proměnné *ISC_CR* a *M2_CR* jsou opět sezónně očištěné.

**Tabulka 5-4: Srovnání skutečných hodnot s predikcí ex post proměnných ISC_CR a HDP_CR za období II/2011 – IV/2011**

| | ISC_CR | ISC_CR PRE | Odchylka v % | HDP_CR | HDP_CR PRE | Odchylka v % |
|---|---|---|---|---|---|---|
| IV/2010 | 114,44 | 114,44 | | 946 762 | 946 762 | |
| I/2011 | 115,01 | 115,01 | | 943 873 | 943 873 | |
| **II/2011** | **115,42** | **115,15** | -0,24% | **948 622** | **943 124** | -0,58% |
| **III/2011** | **116,23** | **115,35** | -0,76% | **953 602** | **945 165** | -0,88% |
| **IV/2011** | **117,5** | **115,89** | -1,37% | **961 131** | **952 615** | -0,89% |

*Zdroj: Vlastní výpočet*

**Tabulka 5-5: Srovnání skutečných hodnot s predikcí ex post proměnných M2_CR a PRIBOR_CR za období II/2011 – IV/2011**

| | M2_CR | M2_CR PRE | Odchylka v % | PRIBOR_CR | PRIBOR_CR PRE | Odchylka v % |
|---|---|---|---|---|---|---|
| IV/2010 | 2674,61 | 2674,61 | | 1,8 | 1,8 | |
| I/2011 | 2678,86 | 2678,86 | | 1,82 | 1,82 | |
| **II/2011** | **2691,16** | **2678,83** | -0,46% | **1,8** | **1,84** | 2,48% |
| **III/2011** | **2767,25** | **2693,79** | -2,65% | **1,73** | **1,88** | 8,58% |
| **IV/2011** | **2785,52** | **2744,46** | -1,47% | **1,7** | **1,87** | 10,11% |

*Zdroj: Vlastní výpočet*

Jak je z uvedených tabulek vidět, tak, kromě úrokové míry, vycházely předpovídané hodnoty vždy menší, než byly ve skutečnosti. Obecně však nejsou odchylky příliš velké. Nejméně přesná vyšla předpověď pro úrokovou míru.

Predikci ex ante jsem založil na původním VAR(1) modelu s daty za období III/2002 až IV/2011 uvedeného v příloze č. 6. V příloze č. 18 jsou pak k nahlédnutí graficky vyvedené bodové a 95% intervalové předpověď jednotlivých proměnných na období I – III/2012.

V tabulce č. 5.6 jsou uvedeny konkrétní bodové předpovědi ex ante časových řad přepočtené na úrovňové hodnoty.

**Tabulka 5-6: Predikce ex ante na období I – III/2012**

| | ISC_CR | HDP_CR | M2_CR | PRIBOR_CR |
|---|---|---|---|---|
| **I/2012** | 118,02 | 963 877 | 2 812,13 | 1,79 |
| **II/2012** | 118,30 | 968 300 | 2 832,48 | 1,81 |
| **III/2012** | 118,51 | 971 824 | 2 851,18 | 1,83 |

*Zdroj: Vlastní výpočet*

Podle bodových předpovědí ex ante by měl harmonizovaný index spotřebitelských cen s bází v roce 2005 dosáhnout v období I/2012 hodnoty 118,02. Ve zbylých dvou čtvrtletí by měl index mírně vzrůst na úroveň 118,30 v období II/2012, resp. 118,51 v období III/2012. Na základě měsíčních dat z Evropského statistického úřadu jsem vypočet HISC pro první čtvrtletí 2012, které je ve výši 119,40. Odhad na základě VAR modelu vyšel tedy mírně podhodnocený.

# 6 Aplikace vybraných modelů na SRN

## 6.1 Data

Data o německém hrubém národním produktu byla získána z internetových stránek německé centrální banky, míry inflace byly staženy ze stránek Evropského statistického úřadu, časové řady peněžní zásoby a úrokové míry byly dostupné na stránkách Evropské centrální banky, resp. v databázi časových řad ARAD. Všechny sledované časové řady jsou ve formě čtvrtletních údajů za období I/2002 až IV/2011.

Inflace je opět kvůli srovnatelnosti měřena pomocí harmonizovaného indexu spotřebních cen, který je formě bazického indexu (rok 2005=100). Čtvrtletní pozorování byla transformována z měsíčních dat pomocí váženého chronologického průměru.

Indikátorem úrokové míry je ukazatel EURIBOR s dobou splatnosti 1 rok.

Peněžní zásoba je měřena pomocí agregátu M2 v mld. EUR

Hrubý domácí produkt, který je v běžných cenách v mld. EUR, je také sezóně očištěn.

Pro vzájemné odlišení od dat pro ČR jsou proměnné označeny názvy *ISC_SRN*, *EURIBOR_SRN*, *M2_SRN* a *HDP_SRN*.

**Obrázek 6-1: Průběhy jednotlivých proměnných pro SRN**

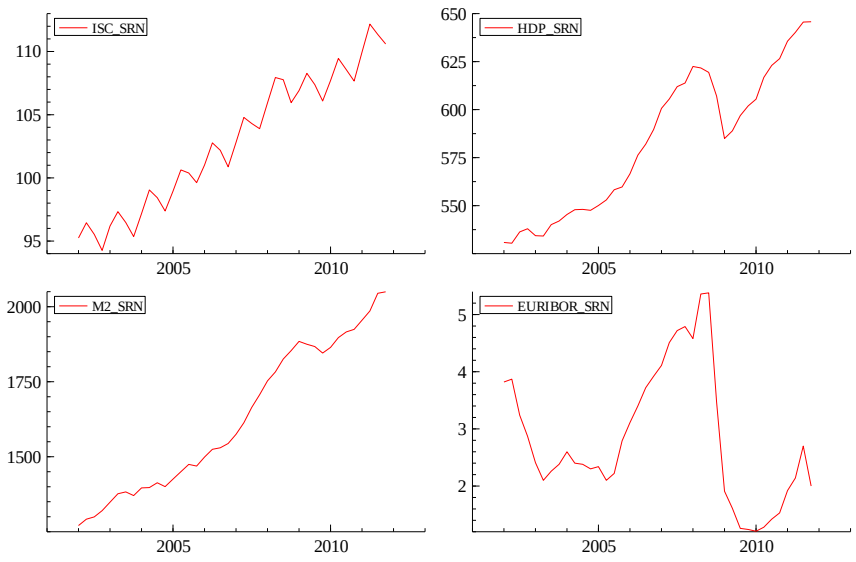


*Zdroj: Vlastní výpočet v GiveWin*

Již z obrázku 6.1 je patrné, že časová řada indexu spotřebních cen vykazuje sezónnost. Tu je potřeba odstranit. Vedle této proměnné byla statistickými testy zjištěna významná sezónnost ještě navíc i u peněžní zásoby. Metodou X12 ARIMA byly tyto dvě časové řady očištěny a jejich nový průběh je k nahlédnutí v příloze č. 19. Nové řady budou nést označení *SAISC_SRN* a *SAM2_SRN*.

Dalším krokem je ověření stacionarity u sledovaných řad. Opět již pouhým subjektivním posouzením grafů lze předpokládat, že minimálně *SAISC_SRN* a *SAM2_SRN* jsou nestacionární. Výsledky rozšířeného ADF testu jednotkových kořenů s konstantou pro všechny proměnné jsou k nahlédnutí v tabulce č. 6.1.

**Tabulka 6-1: ADF testy**

| Proměnná | *p*-value |
|---|---|
| **SAISC_SRN** | 0,997 |
| **HDP_SRN** | 0,947 |
| **SAM2_SRN** | 0,996 |
| **EURIBOR_SRN** | 0,582 |

*Zdroj: Vlastní výpočet v Gretl*

Na základě testů se prokázaly domněnky o nestacionaritě indexu spotřebních cen a peněžní zásoby. Časové řady hrubého domácího produktu a úrokové míry rovněž vlastnost stacionarity nevykazují. Za účelem stacionarizace časových řad jsem data, opět stejně jako u dat pro ČR, logaritmoval a poté vytvořil jejich první diference. Tyto proměnné jsou označeny jako *DLSAISC_SRN*, *DLHDP_SRN*, *DLSAM2_SRN* a *DLEURIBOR_SRN*.

Výsledky ADF testů pro transformované proměnné jsou obsaženy v tabulce č. 6.2, a je v nich vidět, že vytvoření diferencí logaritmů původních dat pomohlo časové řady na 5% hladině významnosti stacionarizovat.

**Tabulka 6-2: ADF testy**

| Proměnná | *p*-value |
|---|---|
| **DLSAISC_SRN** | 0,003 |
| **DLHDP_SRN** | 0,006 |
| **DLSAM2_SRN** | 0,008 |
| **DLEURIBOR_SRN** | 0,025 |

*Zdroj: Vlastní výpočet v Gretl*

## 6.2 Odhad VAR modelu a analýza funkce odezvy

Je odhadován čtyřrovnicový model VAR s jedním zpožděním a čtyřmi endogenními proměnnými *DLSAISC_SRN*, *DLHDP_SRN*, *DLSAM2_SRN* a *DLEURIBOR_SRN*.

V příloze č. 23 je odhad VAR(1) modelu za období III/2002 až IV/2011. Celkový *F*-test indikuje model jako celek za vhodný. Podobně jako u dat pro Českou republiku vyšly v dílčích *F*-testech dvě proměnné jako nevýznamné. Proměnná *DLHDP_SRN* se svou *p*-hodnotou 0,058 překročila 5% hranici jen nepatrně. Výsledný model jsem se nicméně rozhodl ponechat jako čtyřrovnicový.

V časové řadě *DLHDP_SRN* byla statisticky významná nenormalita a reziduální heteroskedasticita. Testy pro ostatní proměnné vyšly v pořádku.

V rovnici pro *DLSAISC_SRN* jsou na 1% hladině významnosti podstatné proměnné *DLHDP_SRN* a *DLSAM2_SRN* . Zpožděná proměnná inflace je významná na 10% hladině. Všechny tři tyto koeficienty indikují pozitivní závislost s *DLSAISC_SRN*. Ve druhé rovnici je hrubý domácí produkt statisticky významně závislý pouze na prvním zpoždění sebe samotného. Ostatní proměnné vycházejí nevýznamné. Ve třetí rovnici obsahující jako vysvětlovanou proměnnou *DLSAM2_SRN* jsou významné na 1% dva koeficienty, a to jednak u zpoždění proměnné *DLSAISC_SRN* a pak také u prvního zpoždění proměnné *DLSAM2_SRN*. Nakonec v poslední rovnici je na 10% hladině statisticky významný pouze koeficient u zpoždění proměnné *DLSAM2_SRN*. Hranici 10% těsně překročila proměnná *DLHDP_SRN*. Rezidua pro tento VAR(1) model jsou uvedeny v příloze č. 24.

V příloze č. 25 je k nahlédnutí analýza funkce odezvy. Z výstupu je patrné, že systém se vrací do rovnováhy přibližně po 20 období. Velmi silně reaguje na exogenní šok v peněžní zásobě proměnná míry inflace. Reakce dosáhne svého maxima přibližně po dvou až třech období, pak reakce rychle klesá. Zajímavá je reakce hrubého domácího produktu na jednotkový impuls v peněžní zásobě. Během prvních asi 2 období dochází nejprve k poklesu HDP, který je pak následován poměrně silnou reakcí směrem vzhůru.

## 6.3 Analýza Grangerovy kauzality

V tomto odstavci je otestována Grangerova kauzalita mezi jednotlivými časovými řadami Německa. GK je opět zkoumána pro model VAR(1) z předcházející kapitoly. Statisticky významné testy jsou uvedeny v tabulce č. 6.3. Z tabulky je zřejmé, že oboustranná kauzalita v Grangerově pojetí byla zjištěna mezi proměnnými *DLSAM2_SRN* a *DLSAISC_SRN*. Dalším testem byl na 1% hladině významnosti zjištěn statisticky podstatný vliv proměnné *DLHDP_SRN* na proměnnou *DLSAISC_SRN*. Vlivy *DLSAM2_SRN* a *DLHDP_SRN* na *DLEURIBOR_SRN* vyšly statisticky méně významné (10% hladina významnosti). Zbylé testy, které jsou významné na více než 10% hladině významnosti jsou k nahlédnutí v příloze č. 26.

**Tabulka 6-3: Testy Grangerovy kauzality**

```
Test for excluding: DLHDP_SRN_1@DLSAISC_SRN
Subset Chi^2(1) =   7.5629 [0.0060]**

Test for excluding: DLSAM2_SRN_1@DLSAISC_SRN
Subset Chi^2(1) =   13.074 [0.0003]**

Test for excluding: DLSAISC_SRN_1@DLSAM2_SRN
Subset Chi^2(1) =   9.5240 [0.0020]**

Test for excluding: DLSAM2_SRN_1@DLEURIBOR_SRN
Subset Chi^2(1) =   3.5930 [0.0580]

Test for excluding: DLHDP_SRN_1@DLEURIBOR_SRN
Subset Chi^2(1) =   2.8039 [0.0940]
```

*Zdroj: Vlastní výpočet v GiveWin*

## 6.4 Kointegrace a model korekce chyby

Tato kapitola je zaměřena na zkoumání možné kointegrace mezi časovými řadami pro Německo. V tomto modelu jsem vynechal proměnnou *SAISC_SRN* a místo ní jsem použil její transformovanou proměnnou *LMI_SRN*, kterou jsem vytvořil stejným postupem jako proměnnou *LMI_CR*.

Model, které zde použiji pro analýzu kointegrace obsahuje časové řady *LMI_SRN*, *LHDP_SRN*, *LSAM2_SRN* a *LEURIBOR_SRN*. Výsledky odhadu modelu VAR(1) s logaritmovanými daty pro Německo jsou k nahlédnutí v příloze č. 27. Dílčí *F*-testy potvrzují statistickou významnost parametrů jednotlivých zpožděných proměnných ve všech rovnicích najednou. Celkový *F*-test rovněž indikuje vhodnost modelu jako celku.

Podíváme-li se na odhady jednotlivých parametrů a na *t*-testy, zjistíme, že *LMI_SRN* závisí na 5% pouze na prvním zpoždění sebe sama, *LHDP_SRN* závisí na svém prvním zpoždění a také na prvním zpoždění *LEURIBOR_SRN*, *LSAM2_SRN* závisí na *LMI_SRN*, *LSAM2_SRN* a *LEURIBOR_SRN*. Konečně v poslední rovnici závisí *LEURIBOR_SRN* na prvním zpoždění všech zahrnutých proměnných.

Příloha č. 28 obsahuje odhady matic alfa a beta a dále Johansenův test kointegrace. Skutečnost, že charakteristická čísla (0,81107, 0,61130) jsou výrazně vyšší než druhá dvě (0,24744, 0,019760) naznačuje, že by systém mohl obsahovat dva kointegrační vztahy. Na prvním řádku tento test ukazuje, že na 1% hladině významnosti model obsahuje více než 0 kointegračních vektorů, ve druhém řádku prokazuje, že systém obsahuje více než 1 vektor, na třetím řádku ale již existence více než 2 vektorů prokázána není. Lze tedy konstatovat přítomnost maximálně dvou kointegračních vektorů. V příloze č. 29 jsou odhady těchto vektorů. Na konci tabulky je sdělení, že matice beta není identifikovaná a bude tedy i zde nutné zavést dodatečné restrikce.

Omezení jsem volil opět taková, která vedou k funkci dlouhodobé poptávky po penězích, parametr u *LEURIBOR_SRN* bude nulový, a Fisherovu efektu, kdy jsou nulové parametry u *LHDP_SRN* a *LSAM2_SRN*. Kointegrační matice má formu (5.1).

V příloze č. 30 jsou k nahlédnutí výsledky modelu včetně restrikcí. Obě omezení vedla k identifikaci matice beta. První kointegrační vztah lze vyjádřit jako

$$C_{1t} = -1{,}8425 LMI_SRN_t - 1{,}1272 LHDP_SRN_t + LSAM2_SRN_t, \qquad (6.1)$$

druhý kointegrační vztah má formu

$$C_{2t} = LEURIBOR_SRN_t + 2{,}1138 LMI_SRN_t. \qquad (6.2)$$

Vztah (6.1) podporuje ekonomickou teorii, protože podle tohoto vztahu je peněžní zásoba v přímé závislosti s mírou inflace a hrubým domácím produktem. Druhý vztah (6.2) již s ekonomickými teoriemi nesouhlasí. Podle tohoto vztahu je úroková míra a míra inflace v nepřímé závislosti. Tento výsledek je nejspíše zapříčiněn poměrně krátkou časovou řadou sledovaných veličin.

Nyní se pokusím zjistit, zda pomocí statické regrese jednorovnicového modelu s proměnnými *LEURIBOR_SRN* a *LMI_SRN* získám podobné závěry jako ve vztahu (6.2) nebo zda již výsledky budou v souladu s teorií. Odhady regrese jsou v příloze č. 31. Rovnice statické regrese má tvar

$$LEURIBOR_SRN_t = 1{,}58684 LMI_SRN_t. \qquad (6.3)$$

V této rovnici má již odhadnutý parametr sklon správný. Diagnostickými testy byla zjištěna přítomnost autokorelace a reziduální heteroskedasticity. Příloha č. 32 obsahuje ADF test pro testování kointegrace. Uvedený test prokazuje stacionaritu reziduí statické regrese. Obě časové řady jsou kointegrované.

Protože rezidua regrese pro *LEURIBOR_SRN* vykazují autokorelace, je vhodné model dynamizovat pomocí zpoždění. Dynamický model má tvar

$$LEURIBOR_SRN_t = \alpha \cdot LEURIBOR_SRN_{t-1} + \beta_0 \cdot LMI_SRN_t + \beta_1 \cdot LMI_SRN_{t-1} + a_t. \qquad (6.4)$$

Odhady parametrů regrese (6.4) jsou uvedeny v příloze č. 33. Tento model lze rovněž vyjádřit ve formě modelu korekce chyby, jehož tvar je následující

$$\Delta LEURIBOR_SRN_t = \beta_0 \cdot \Delta LMI_SRN_t - (1-\alpha)\left[LEURIBOR_SRN_{t-1} - \frac{\beta_0 + \beta_1}{1-\alpha} LMI_SRN_{t-1}\right] + a_t \qquad (6.5)$$

Z diagnostických testů lze vyčíst, že rezidua v modelu již autokorelaci nevykazují, rovněž i zbylé testy dopadly příznivě. Parametr $\alpha$ je roven hodnotě 0,811 a vyhovuje tak předpokladu, že se má nacházet v intervalu $(0,1)$. Dlouhodobá informace o vztahu mezi proměnnými, která je zachycena v parametru $[(\beta_0 + \beta_1)/(1-\alpha)]$, má hodnotu 2,113 a

indikuje tak přímou závislost. Krátkodobé parametry $\beta_0$ a $\beta_1$ jsou rovny hodnotám 0,227, resp. 1,173. Současná hodnota úrokové míry je tedy o něco málo více závislá na současné hodnotě míry inflace, než na hodnotě minulé. Rychlost přizpůsobení k rovnováze, tedy parametr $(\alpha - 1)$ je roven hodnotě -0,189.

## 6.5 Predikce

V této kapitole je provedena predikce ex post na období II/2011 – IV/2011 a následně predikce ex ante na období I/2012 – III/2012.

Predikci ex post na 3 období jsem provedl na základě VAR(1) modelu s daty pro Německo za období III/2002 – I/2011. Odhad tohoto modelu je k nahlédnutí v příloze č. 34.

Tabulky č. 6.4 a 6.5 obsahují skutečné hodnoty jednotlivých proměnných srovnané s jejími bodovými předpověďmi. Proměnné *ISC_SRN* a *M2_SRN* jsou opět sezónně očištěné.

**Tabulka 6-4: Srovnání skutečných hodnot s predikcí ex post proměnných ISC_SRN a HDP_SRN za období II/2011 – IV/2011**

| | ISC_SRN | ISC_SRN PRE | Odchylka v % | HDP_SRN | HDP_SRN PRE | Odchylka v % |
|---|---|---|---|---|---|---|
| IV/2010 | 109,08 | 109,08 | | 626,56 | 626,56 | |
| I/2011 | 110,00 | 110,00 | | 635,62 | 635,62 | |
| **II/2011** | 110,80 | 110,69 | -0,10% | 640,24 | 641,47 | 0,19% |
| **III/2011** | 111,23 | 111,30 | 0,07% | 645,59 | 644,95 | -0,10% |
| **IV/2011** | 112,07 | 111,99 | -0,07% | 645,77 | 647,53 | 0,27% |

*Zdroj: Vlastní výpočet*

**Tabulka 6-5: Srovnání skutečných hodnot s predikcí ex post proměnných M2_SRN a EURIBOR_SRN za období II/2011 – IV/2011**

| | M2_SRN | M2_SRN PRE | Odchylka v % | EURIBOR_SRN | EURIBOR_SRN PRE | Odchylka v % |
|---|---|---|---|---|---|---|
| IV/2010 | 1930,90 | 1930,90 | | 1,53 | 1,53 | |
| I/2011 | 1954,66 | 1954,66 | | 1,92 | 1,92 | |
| **II/2011** | 1985,85 | 1988,72 | 0,14% | 2,14 | 2,20 | 2,67% |
| **III/2011** | 2038,01 | 2022,86 | -0,74% | 2,70 | 2,30 | -14,95% |
| **IV/2011** | 2056,76 | 2057,73 | 0,05% | 2,00 | 2,45 | 22,75% |

*Zdroj: Vlastní výpočet*

Predikce ex post pro proměnnou *ISC_SRN* vyšla relativně dobře. Maximální odchylka je pouze 0,1%. O něco hůře dopadly predikce pro *HDP_SRN* a *M2_SRN*. Nejméně přesná vyšla opět předpověď pro úrokovou míru.

Druhý typ předpovědi, ex ante, jsem založil na odhadech modelu VAR(1) za období III/2002 až IV/2011 uloženého v příloze č. 23. V příloze č. 35 jsou představeny v grafické podobě bodové a 95% intervalové předpovědi proměnných na období I-III/2012.

V tabulce č. 6.6 jsou k nahlédnutí předpovědi převedené na úrovňové hodnoty.

**Tabulka 6-6: Predikce ex ante na období I – III/2012**

| | ISC_SRN | HDP_SRN | M2_SRN | EURIBOR_SRN |
|---|---|---|---|---|
| **I/2012** | 112,48 | 648,32 | 2 090,56 | 1,83 |
| **II/2012** | 112,95 | 650,35 | 2 118,72 | 1,74 |
| **III/2012** | 113,37 | 652,21 | 2 145,09 | 1,68 |

*Zdroj: Vlastní výpočet*

Podle bodových předpovědí ex ante lze očekávat mírný růst indexu spotřebitelských cen. V prvním čtvrtletí by měl dosáhnout úrovně 112,48, ve druhém pak úrovně 112,95 a ve třetím hodnoty 113,37. Na základě dat Eurostatu dosáhl index spotřebitelských cen v Německu v prvním čtvrtletí roku 2012 hodnoty 112,56. Tato úroveň je přibližně shodná s hodnotou predikovanou.

# Závěr

Tato diplomová práce je zaměřena na inflaci a jejím cílem bylo na vybraných ekonometrických modelech poukázat, v jakých vztazích je inflace s některými makroekonomickými indikátory v České republice a v Německu. Nejdříve byly uvedeny základní pojmy spojené s inflací, časovými řadami a ekonometrickými modely vektorových autoregresí (VAR), které byly pak aplikovány v empirické části práce.

Na základě predikce ex post se jeví koncepce VAR modelů jako poměrně vhodný instrument pro modelování inflace. Odchylky od skutečných hodnot se u obou modelů pohybovaly v zásadě pod 1%, nejméně přesná vycházela predikce pro úrokovou míru. Pro Českou republiku měl model odchylky mírně vyšší, než tomu bylo u modelu pro Německo.

Navzdory pozitivním výsledkům predikce jsem se setkal při psaní s několika problémy. S časovými řadami souvisí, při použití modelů VAR, podmínka jejich stacionarity. Protože bývají makroekonomická data v zásadě nestacionární, byl jsem i v této práci nucen pro obě země časové řady vhodně upravit. Převedením původním dat nejdříve na logaritmy a posléze na jejich první diference se ovšem ztrácí část důležité informace, která je podstatná pro kvalitní předpověď. Vedle toho jsem některé časové řady ještě navíc očišťoval o sezónnost, čímž bylo odtržení od původních hodnot ještě podtrženo. Dalším problémem byla kointegrace, která je pro makroekonomické indikátory typická a se kterou jsem se v práci rovněž setkal. Další překážkou bylo zjištění statistické nevýznamnosti některých dílčích *F*-testů, indikujících nevýznamnost daných parametrů ve všech rovnicích najednou. Tyto výsledky jsem nicméně opomenul a oba modely jsem ponechal v původním tvaru. Rovněž diagnostické testy nedopadaly vždy pozitivně. V modelu za Českou republiku se především jedná o přítomnost nenormality v časové řadě pro úrokovou míru. Při odhadu statické regrese se pak v modelu vyskytla heteroskedasticita a autokorelace, která ovšem po přidání zpoždění vymizela. V modelu pro SRN je negativní vlastnosti projevily u časové řady hrubého domácího produktu. Autokorelace se objevila opět při odhadu statické regrese, nicméně dynamizací byla odstraněna.

V rámci zkoumání grangerovy kauzality vyplynulo, že pro Českou republiku pomáhá zlepšit předpověď inflace pouze peněžní zásoba. Dále byla zjištěna oboustranná kauzalita peněžní zásoby a hrubého domácího produktu, a rovněž vliv úrokové míry na předpověď hrubého domácího produktu. Co se týče výsledků pro Německo, tak jako předstihové indikátory inflace zde vystupují hrubý domácí produkt a peněžní zásoba, u které je závislost oboustranná. Dále bylo zjištěno, že peněžní zásoba a hrubý domácí produkt vystupují jako předstihové indikátory rovněž pro úrokovou míru.

V rámci predikce ex ante byly předpovídány hodnoty proměnných pro obě země na první až třetí čtvrtletí roku 2012. V současné době jsou již k dispozici hodnoty

harmonizovaných indexů spotřebitelských cen pro první čtvrtletí, a je tedy možné provést porovnání skutečných hodnot a vypočtených predikcí. Zatímco cenová hladina v České republice klesla mezi třetím a čtvrtým čtvrtletím roku 2011 z hodnoty 116,37 na úroveň 115,51, v prvním čtvrtletí roku 2012 vzrostla na úroveň 119,40. Bodová předpověď je na úrovni 118,02, predikovala tedy sice růst, ale ne tak výrazný. V rámci predikce pro Německo byla odhadnuta úroveň cenové hladiny pro první čtvrtletí 2012 ve výši 112,48, zatímco ve skutečnosti dosáhla výše 112,56. Model tedy i zde správně předpovídal růst a dosáhl možné shody s realitou.

Na závěr je nutné připomenout, že tato práce zahrnuje do analýzy pouze čtyři faktory, takže je tedy pouhým zjednodušením skutečnosti a nezahrnuje ostatní faktory, které zkoumané veličiny nebo jejich okolí ovlivňují a které by mohly analýzu a predikci zpřesnit. Mezi takové veličiny patří například měnový kurz nebo nezaměstnanost.

# Seznam literatury


[1] ARLT, J. – ARLTOVÁ, M.: *Ekonomické časové řady – vlastnosti, metody modelování, příklady a aplikace*. Praha: Professional Publishing, 2007.

[2] ENGLE, R. F. – GRANGER, C. W. J.: *Co-integration and Error Correction: Representation, Estimation and Testing*. Econometrica. 1987.

[3] GRANGER, C. W. J.: *Investigating Causal Relations by Econometric Models and Cross-Spectral Methods*. Econometrica, 1969.

[4] GRANGER, C. W. J.: *Some Properties of Time Series Data and Their Use in Econometric Model Specification*. Journal of Econometrics, 1981.

[5] HEDIJA, V. - MUSIL, P.: *Praktikum makroekonomie*. Plzeň: Aleš Čeněk, s.r.o., 2009.

[6] HELÍSEK, M.: *Makroekonomie – základní kurs*. Praha: Melandrium, 2002.

[7] HOLMAN, R.: *Ekonomie*. Praha: C. H. Beck, 2002.

[8] HOLMAN, R.: *Makroekonomie – středně pokročilý kurz.* Praha: C. H. Beck, 2004.

[9] HUŠEK, R.: *Ekonometrická analýza*. Praha: Oeconomica, 2007.

[10] POSPÍŠIL, R. – HOBZA, V. – PUCHINGER, Z.: *Finance a bankovnictví*. Olomouc: 2006.

[11] REVENDA, Z.: *Centrální bankovnictví*. Praha: Management Press, 2011.

[12] REVENDA, Z. a kol.: *Peněžní ekonomie a bankovnictví*. Praha: Management Press, 2004.

[13] SIMS, C. A.: *Money, Income and Causality*. American Economic Review, 1972.


## Internetové zdroje


**http://www.czso.cz**, **http://www.cnb.cz**, **ec.europa.eu/eurostat**, **www.ecb.int/**, **http://www.bundesbank.de**

# PŘÍLOHY

Příloha 1: Struktura měnových agregátů

| Obsah měnového agregátu | M1 | M2 | M3 |
|---|---|---|---|
| **Emitované oběživo** | X | X | X |
| **Jednodenní vklady** | X | X | X |
| **Vklady s dohodnutou splatností do 2 let** | | X | X |
| **Vklady s výpovědní lhůtou do 3 měsíců** | | X | X |
| **Repo operace** | | | X |
| **Akcie/podílové listy fondů peněžního trhu** | | | X |
| **Emitované dluhové cenné papíry do 2 let** | | | X |

*Zdroj: ČNB*

Příloha 2: Sezónně očištěné časové řady *SAISC_CR* a *SAM2_CR*

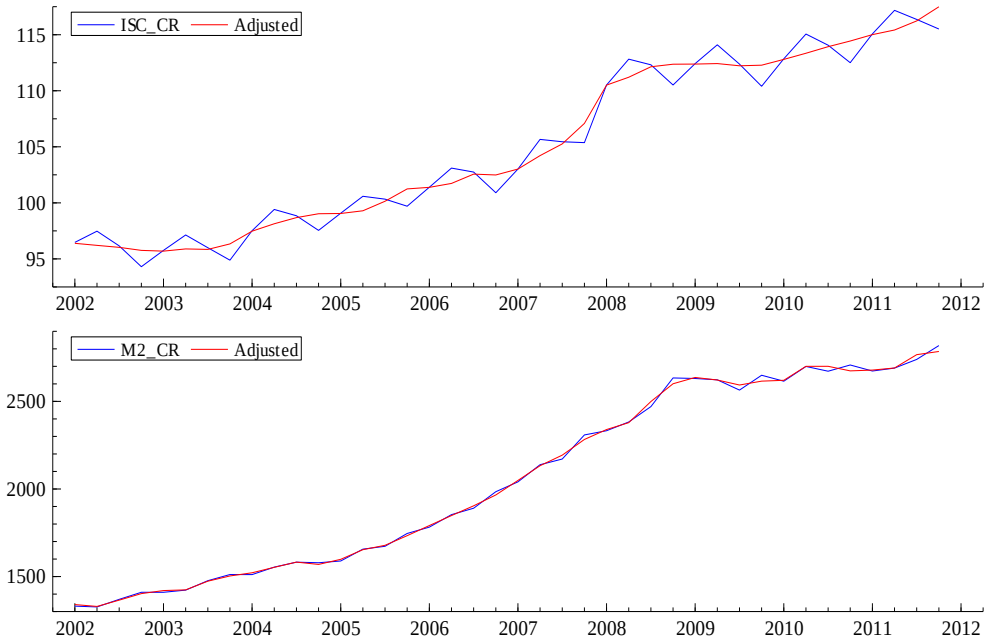


*Zdroj: Vlastní výpočet v GiveWin*

## Příloha 3: ADF testy

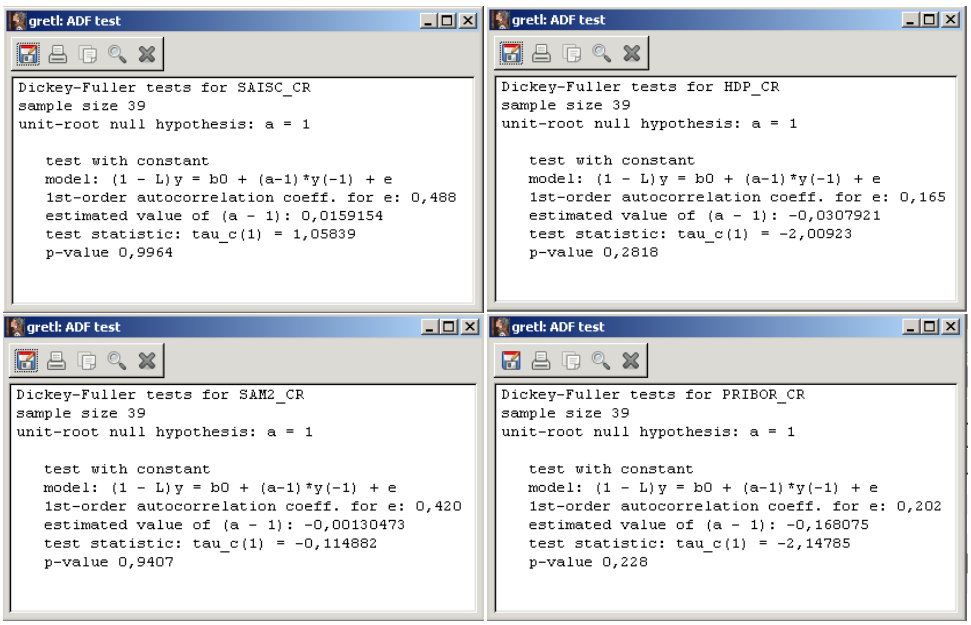

```
gretl: ADF test
Dickey-Fuller tests for SAISC_CR
sample size 39
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: 0,488
   estimated value of (a - 1): 0,0159154
   test statistic: tau_c(1) = 1,05839
   p-value 0,9964
```

```
gretl: ADF test
Dickey-Fuller tests for HDP_CR
sample size 39
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: 0,165
   estimated value of (a - 1): -0,0307921
   test statistic: tau_c(1) = -2,00923
   p-value 0,2818
```

```
gretl: ADF test
Dickey-Fuller tests for SAM2_CR
sample size 39
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: 0,420
   estimated value of (a - 1): -0,00130473
   test statistic: tau_c(1) = -0,114882
   p-value 0,9407
```

```
gretl: ADF test
Dickey-Fuller tests for PRIBOR_CR
sample size 39
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: 0,202
   estimated value of (a - 1): -0,168075
   test statistic: tau_c(1) = -2,14785
   p-value 0,228
```

*Zdroj:Vlastní výpočet v Gretl*

## Příloha 4: Průběhy transformovaných časových řad pro ČR

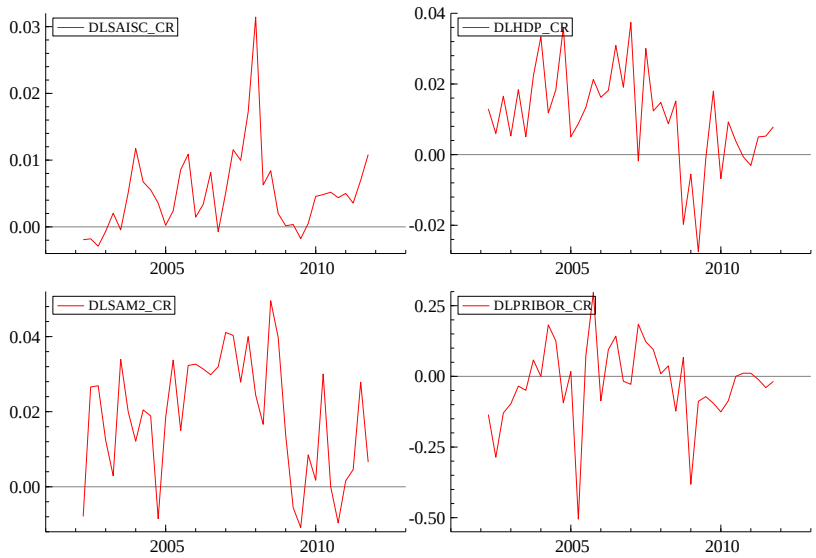


*Zdroj: Vlastní výpočet v GiveWin*

Příloha 5: ADF testy transformovaných proměnných pro ČR

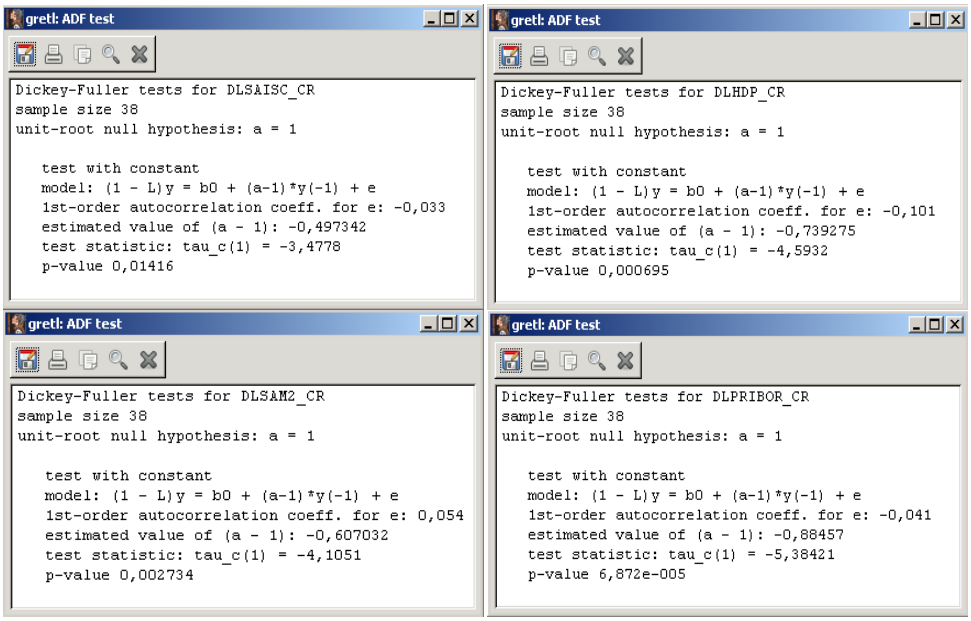

```
gretl: ADF test
Dickey-Fuller tests for DLSAISC_CR
sample size 38
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: -0,033
   estimated value of (a - 1): -0,497342
   test statistic: tau_c(1) = -3,4778
   p-value 0,01416
```

```
gretl: ADF test
Dickey-Fuller tests for DLHDP_CR
sample size 38
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: -0,101
   estimated value of (a - 1): -0,739275
   test statistic: tau_c(1) = -4,5932
   p-value 0,000695
```

```
gretl: ADF test
Dickey-Fuller tests for DLSAM2_CR
sample size 38
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: 0,054
   estimated value of (a - 1): -0,607032
   test statistic: tau_c(1) = -4,1051
   p-value 0,002734
```

```
gretl: ADF test
Dickey-Fuller tests for DLPRIBOR_CR
sample size 38
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: -0,041
   estimated value of (a - 1): -0,88457
   test statistic: tau_c(1) = -5,38421
   p-value 6,872e-005
```

*Zdroj: Vlastní výpočet v Gretl*

Příloha 6: Odhad VAR(1) modelu pro data III/2002 – IV/2011

```
VAR( 1) Estimating the system by OLS (using data_DP_CR.in7)
        The estimation sample is: 2002 (3) to 2011 (4)

URF equation for: DLSAISC_CR
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_CR_1         0.295659     0.1260     2.35   0.025
DLHDP_CR_1          0.0771881    0.05188     1.49   0.146
DLSAM2_CR_1         0.0920726    0.03974     2.32   0.027
DLPRIBOR_CR_1    -0.000264663   0.004936  -0.0536   0.958
D              U    0.0217308   0.004651     4.67   0.000

sigma = 0.00430641   RSS = 0.0006119905543

URF equation for: DLHDP_CR
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_CR_1       -0.0916315     0.4098   -0.224   0.824
DLHDP_CR_1           0.305920     0.1688     1.81   0.079
DLSAM2_CR_1          0.290963     0.1293     2.25   0.031
DLPRIBOR_CR_1       0.0273630    0.01606     1.70   0.098
D              U  -0.00167744    0.01513   -0.111   0.912

sigma = 0.0140106   RSS = 0.006477756252

URF equation for: DLSAM2_CR
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_CR_1         0.179155     0.4454    0.402   0.690
DLHDP_CR_1           0.533058     0.1834     2.91   0.006
DLSAM2_CR_1          0.513685     0.1405     3.66   0.001
DLPRIBOR_CR_1     0.000386515    0.01746   0.0221   0.982
D              U  -0.00581097    0.01645   -0.353   0.726
```

```
sigma = 0.0152281   RSS = 0.007652543847

URF equation for: DLPRIBOR_CR
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_CR_1          4.02445      4.402    0.914   0.367
DLHDP_CR_1            2.11266      1.813     1.17   0.252
DLSAM2_CR_1          -1.49771      1.389    -1.08   0.289
DLPRIBOR_CR_1       0.0678411     0.1725    0.393   0.697
D              U   -0.0324975     0.1625   -0.200   0.843

sigma = 0.150496   RSS = 0.7474164472

log-likelihood     401.521433  -T/2log|Omega|      617.20009
|Omega|       7.80341262e-015  log|Y'Y/T|        -30.7903561
R^2(LR)              0.816191  R^2(LM)               0.25663
no. of observations        38  no. of parameters          20

F-test on regressors except unrestricted: F(16,92) = 4.274 [0.0000] **
F-tests on retained regressors, F(4,30) =
DLSAISC_CR_1       1.50441 [0.226]    DLHDP_CR_1       3.14597 [0.028]*
 DLSAM2_CR_1       4.06076 [0.010]**DLPRIBOR_CR_1      0.832057 [0.515]
           D U     6.59284 [0.001]**

correlation of URF residuals (standard deviations on diagonal)
                DLSAISC_CR     DLHDP_CR    DLSAM2_CR  DLPRIBOR_CR
DLSAISC_CR       0.0043064      0.30547      0.16617      0.24626
DLHDP_CR           0.30547     0.014011      0.21343    -0.025527
DLSAM2_CR          0.16617      0.21343     0.015228     -0.26697
DLPRIBOR_CR        0.24626    -0.025527     -0.26697      0.15050
correlation between actual and fitted
   DLSAISC_CR     DLHDP_CR    DLSAM2_CR  DLPRIBOR_CR
      0.77256      0.42234      0.53703      0.37083

DLSAISC_CR  : Portmanteau( 5): 7.3284
DLHDP_CR    : Portmanteau( 5): 3.08682
DLSAM2_CR   : Portmanteau( 5): 2.74193
DLPRIBOR_CR : Portmanteau( 5): 1.33955
DLSAISC_CR  : AR 1-3 test:      F(3,30)  =   1.1896 [0.3304]
DLHDP_CR    : AR 1-3 test:      F(3,30)  =   1.0026 [0.4052]
DLSAM2_CR   : AR 1-3 test:      F(3,30)  =   1.3195 [0.2864]
DLPRIBOR_CR : AR 1-3 test:      F(3,30)  =  0.26038 [0.8533]
DLSAISC_CR  : Normality test:   Chi^2(2) =  0.53406 [0.7657]
DLHDP_CR    : Normality test:   Chi^2(2) =   3.8111 [0.1487]
DLSAM2_CR   : Normality test:   Chi^2(2) =  0.77554 [0.6786]
DLPRIBOR_CR : Normality test:   Chi^2(2) =   7.6035 [0.0223]*
DLSAISC_CR  : ARCH 1-3 test:    F(3,27)  =  0.19120 [0.9015]
DLHDP_CR    : ARCH 1-3 test:    F(3,27)  = 0.062003 [0.9794]
DLSAM2_CR   : ARCH 1-3 test:    F(3,27)  =  0.44531 [0.7226]
DLPRIBOR_CR : ARCH 1-3 test:    F(3,27)  =  0.35817 [0.7836]
DLSAISC_CR  : hetero test:      F(8,24)  =   1.0526 [0.4267]
DLHDP_CR    : hetero test:      F(8,24)  =   1.7858 [0.1298]
DLSAM2_CR   : hetero test:      F(8,24)  =   1.1137 [0.3890]
DLPRIBOR_CR : hetero test:      F(8,24)  =  0.38071 [0.9204]
DLSAISC_CR  : hetero-X test:    F(14,18) =   1.1679 [0.3725]
DLHDP_CR    : hetero-X test:    F(14,18) =   1.4425 [0.2296]
DLSAM2_CR   : hetero-X test:    F(14,18) =  0.70179 [0.7466]
DLPRIBOR_CR : hetero-X test:    F(14,18) =  0.61614 [0.8189]
```

```
Vector Portmanteau( 5): 55.2429
Vector AR 1-3 test:        F(48,71)  =  0.87403 [0.6872]
Vector Normality test:     Chi^2(8)  =   13.133 [0.1074]
Vector hetero test:        F(80,103) =  0.89454 [0.6975]
Vector hetero-X test:      F(140,91) =  0.74926 [0.9381]
```

Zdroj: Vlastní výpočet v GiveWin

Příloha 7: Rezidua modelu VAR(1) pro období III/2002 – IV/2011

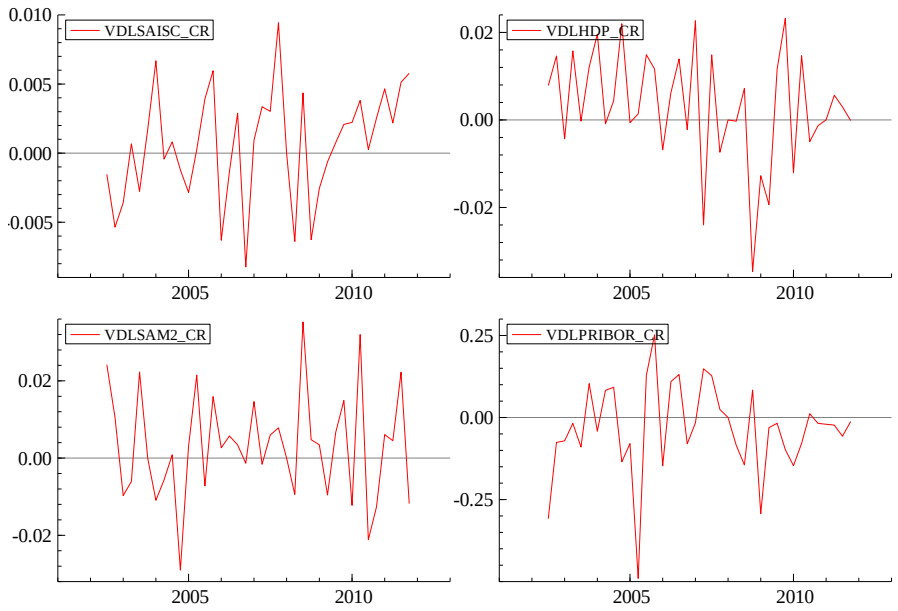


*Zdroj: Vlastní výpočet v GiveWin*

Příloha 8: Analýza funkce odezvy pro model VAR(1) za období III/2002 – IV/2011

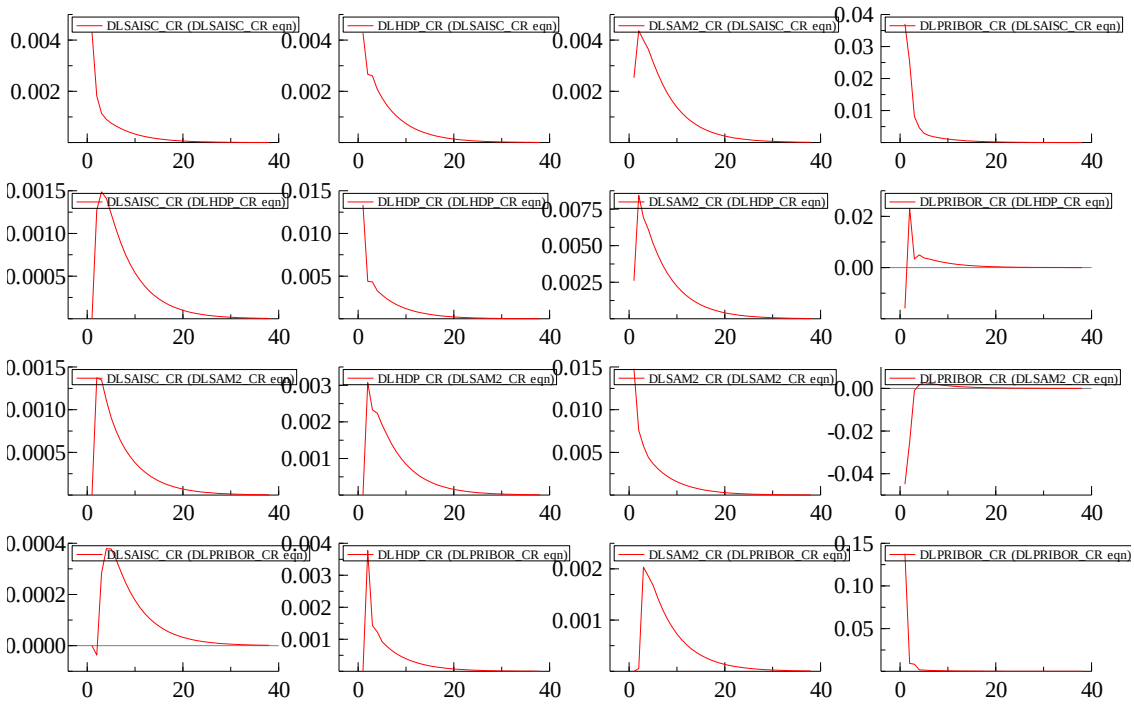


*Zdroj: Vlastní výpočet v GiveWin*

Příloha 9: Nevýznamné testy Grangerovy kauzality

```
Test for excluding: DLHDP_CR_1@DLSAISC_CR
Subset Chi^2(1) =   2.2139 [0.1368]

Test for excluding: DLPRIBOR_CR_1@DLSAISC_CR
Subset Chi^2(1) =0.0028747 [0.9572]

Test for excluding: DLSAISC_CR_1@DLHDP_CR
Subset Chi^2(1) = 0.050005 [0.8231]

Test for excluding: DLSAISC_CR_1@DLSAM2_CR
Subset Chi^2(1) =  0.16181 [0.6875]

Test for excluding: DLPRIBOR_CR_1@DLSAM2_CR
Subset Chi^2(1) =0.00049032 [0.9823]

Test for excluding: DLSAISC_CR_1@DLPRIBOR_CR
Subset Chi^2(1) =  0.83598 [0.3606]

Test for excluding: DLHDP_CR_1@DLPRIBOR_CR
Subset Chi^2(1) =   1.3580 [0.2439]

Test for excluding: DLSAM2_CR_1@DLPRIBOR_CR
Subset Chi^2(1) =   1.1631 [0.2808]
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha 10: Odhad modelu VAR(1) pro logaritmovaná data III/2002 – IV/2011

```
VAR(1) Estimating the system by OLS
The estimation sample is: 2002 (3) to 2011 (4)

URF equation for: LMI_CR
                  Coefficient  Std.Error  t-value  t-prob
LMI_CR_1             0.352237     0.1214     2.90   0.007
LHDP_CR_1           0.0584238     0.2316    0.252   0.802
LSAM2_CR_1         -0.0152533     0.4067  -0.0375   0.970
LPRIBOR_CR_1        -0.408963     0.2699    -1.52   0.139
D              U      2.43812     0.4587     5.32   0.000

sigma = 0.418486   RSS = 5.779301398

URF equation for: LHDP_CR
                  Coefficient  Std.Error  t-value  t-prob
LMI_CR_1           0.00402133   0.003588     1.12   0.270
LHDP_CR_1             1.02581   0.006846     150.   0.000
LSAM2_CR_1         -0.0441505    0.01202    -3.67   0.001
LPRIBOR_CR_1      -0.00817204   0.007979    -1.02   0.313
D              U   0.00598721    0.01356    0.442   0.662

sigma = 0.0123696   RSS = 0.005049193497
```

```
URF equation for: LSAM2_CR
                  Coefficient  Std.Error  t-value  t-prob
LMI_CR_1           0.00290651   0.004260    0.682   0.500
LHDP_CR_1           0.0146471   0.008128     1.80   0.081
LSAM2_CR_1           0.973888    0.01427     68.2   0.000
LPRIBOR_CR_1        0.0176894   0.009473     1.87   0.071
D              U  -0.00544763    0.01610   -0.338   0.737

sigma = 0.0146866   RSS = 0.007117974395

URF equation for: LPRIBOR_CR
                  Coefficient  Std.Error  t-value  t-prob
LMI_CR_1             0.130172    0.03680     3.54   0.001
LHDP_CR_1            0.118561    0.07020     1.69   0.101
LSAM2_CR_1          -0.192351     0.1233    -1.56   0.128
LPRIBOR_CR_1         0.748452    0.08182     9.15   0.000
D              U   0.00313301     0.1390   0.0225   0.982

sigma = 0.126853   RSS = 0.5310236011

log-likelihood     242.894996  -T/2log|Omega|     458.573653
|Omega|       3.29689336e-011  log|Y'Y/T|        -2.68348595
R^2(LR)                     1  R^2(LM)              0.756868
no. of observations        38  no. of parameters          20

F-test on regressors except unrestricted: F(16,92) = 6459.13 [0.0000] **
F-tests on retained regressors, F(4,30) =
    LMI_CR_1       3.48961 [0.019]*    LHDP_CR_1       5860.38 [0.000]**
  LSAM2_CR_1       1232.24 [0.000]**LPRIBOR_CR_1       27.6348 [0.000]**
           D U     9.57432 [0.000]**
correlation of URF residuals (standard deviations on diagonal)
                    LMI_CR      LHDP_CR     LSAM2_CR   LPRIBOR_CR
LMI_CR             0.41849      0.35630      0.36416      0.41485
LHDP_CR            0.35630     0.012370      0.12665      0.10606
LSAM2_CR           0.36416      0.12665     0.014687      0.20103
LPRIBOR_CR         0.41485      0.10606      0.20103      0.12685
correlation between actual and fitted
       LMI_CR      LHDP_CR     LSAM2_CR   LPRIBOR_CR
      0.77591      0.99644      0.99846      0.90592

LMI_CR      : Portmanteau( 5): 6.55373
LHDP_CR     : Portmanteau( 5): 3.77407
LSAM2_CR    : Portmanteau( 5): 3.61607
LPRIBOR_CR  : Portmanteau( 5): 4.01407
LMI_CR      : AR 1-3 test:      F(3,30)  =   2.4657 [0.0814]
LHDP_CR     : AR 1-3 test:      F(3,30)  =  0.74776 [0.5322]
LSAM2_CR    : AR 1-3 test:      F(3,30)  =   1.0514 [0.3843]
LPRIBOR_CR  : AR 1-3 test:      F(3,30)  =  0.98883 [0.4113]
LMI_CR      : Normality test:   Chi^2(2) =   5.3856 [0.0677]
LHDP_CR     : Normality test:   Chi^2(2) =   1.3418 [0.5112]
LSAM2_CR    : Normality test:   Chi^2(2) =  0.59977 [0.7409]
LPRIBOR_CR  : Normality test:   Chi^2(2) =   9.7229 [0.0077]**
```

```
LMI_CR       : ARCH 1-3 test:    F(3,27)  =   1.2766 [0.3023]
LHDP_CR      : ARCH 1-3 test:    F(3,27)  =   2.6419 [0.0696]
LSAM2_CR     : ARCH 1-3 test:    F(3,27)  =   1.0566 [0.3838]
LPRIBOR_CR   : ARCH 1-3 test:    F(3,27)  =  0.21800 [0.8830]
LMI_CR       : hetero test:      F(8,24)  =   1.1142 [0.3886]
LHDP_CR      : hetero test:      F(8,24)  =   1.4320 [0.2341]
LSAM2_CR     : hetero test:      F(8,24)  =  0.28432 [0.9647]
LPRIBOR_CR   : hetero test:      F(8,24)  =   1.2912 [0.2943]
LMI_CR       : hetero-X test:    F(14,18) =   1.0973 [0.4196]
LHDP_CR      : hetero-X test:    F(14,18) =   1.4454 [0.2284]
LSAM2_CR     : hetero-X test:    F(14,18) =  0.21733 [0.9971]
LPRIBOR_CR   : hetero-X test:    F(14,18) =  0.92355 [0.5533]

Vector Portmanteau( 5): 88.6855
Vector AR 1-3 test:       F(48,71) =   1.1931 [0.2464]
Vector Normality test:    Chi^2(8) =   19.802 [0.0111]*
Vector hetero test:       F(80,103)=   1.0010 [0.4947]
Vector hetero-X test:     F(140,91)=  0.95051 [0.6102]
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha 11: Johansenův test kointegrace pro VAR(1) s logaritmovanými časovými řadami

```
I(1) cointegration analysis, 2002 (3) to 2011 (4)
  eigenvalue    loglik for rank
                  182.1482   0
     0.82774      215.5642   1
     0.65684      235.8856   2
     0.17499      242.5270   3
    0.019184      242.8950   4

  H0:rank<=  Trace test [ Prob]
      0          121.49 [0.000] **
      1          54.662 [0.000] **
      2          14.019 [0.085]
      3         0.73607 [0.452]

Asymptotic p-values based on: No constant
Unrestricted variables:
[0] = D
Number of lags used in the analysis: 1

beta (scaled on diagonal; cointegrating vectors in columns)
LMI_CR              1.0000       8.3355    -0.035729     -0.11507
LHDP_CR             1.1322       1.0000     -0.61600       1.2337
LSAM2_CR           -2.0541      -1.9508       1.0000      -2.3619
LPRIBOR_CR         0.58319      -5.8405      0.84119       1.0000

alpha
LMI_CR            -0.22002    -0.054717     -0.66680    -0.039321
LHDP_CR          0.0097070  -0.00076570    -0.023082    0.0011109
LSAM2_CR          0.016711   -0.0016834   0.00015748   -0.0020205
LPRIBOR_CR       0.0089030     0.013485     -0.19021    -0.017975
```

```
long-run matrix, rank 4
                    LMI_CR      LHDP_CR     LSAM2_CR   LPRIBOR_CR
LMI_CR            -0.64776     0.058424    -0.015253     -0.40896
LHDP_CR          0.0040213     0.025813    -0.044151   -0.0081720
LSAM2_CR         0.0029065     0.014647    -0.026112     0.017689
LPRIBOR_CR         0.13017      0.11856     -0.19235     -0.25155
```

*Zdroj: Vlastní výpočet v GiveWin*

## Příloha 12: Odhady kointegračních vektorů

```
Cointegrated VAR (1) in:
[0] = LMI_CR
[1] = LHDP_CR
[2] = LSAM2_CR
[3] = LPRIBOR_CR
Unrestricted variables:
[0] = D
Number of lags used in the analysis: 1

beta
LMI_CR              1.0000       8.3355
LHDP_CR             1.1322       1.0000
LSAM2_CR           -2.0541      -1.9508
LPRIBOR_CR         0.58319      -5.8405

alpha
LMI_CR            -0.22002    -0.054717
LHDP_CR          0.0097070  -0.00076570
LSAM2_CR          0.016711   -0.0016834
LPRIBOR_CR       0.0089030     0.013485

Standard errors of alpha
LMI_CR            0.066498     0.013243
LHDP_CR          0.0020199   0.00040224
LSAM2_CR         0.0021540   0.00042895
LPRIBOR_CR        0.020021    0.0039870

Restricted long-run matrix, rank 2
                    LMI_CR      LHDP_CR     LSAM2_CR   LPRIBOR_CR
LMI_CR            -0.67611     -0.30382      0.55867      0.19126
LHDP_CR          0.0033245     0.010224    -0.018445     0.010133
LSAM2_CR         0.0026796     0.017237    -0.031042     0.019577
LPRIBOR_CR         0.12131     0.023565    -0.044593    -0.073567

Standard errors of long-run matrix
LMI_CR             0.12887     0.076443      0.13901     0.086521
LHDP_CR          0.0039143    0.0023220    0.0042225    0.0026281
LSAM2_CR         0.0041742    0.0024761    0.0045029    0.0028026
LPRIBOR_CR        0.038798     0.023015     0.041853     0.026049

Reduced form beta
LMI_CR             -1.0000      0.00000
LHDP_CR            0.00000      -1.0000
LSAM2_CR          0.018319       1.7981
LPRIBOR_CR         0.85284      -1.2684
```

```
Standard errors of reduced form beta
LMI_CR              0.00000      0.00000
LHDP_CR             0.00000      0.00000
LSAM2_CR           0.043374     0.055146
LPRIBOR_CR          0.33527      0.42626

Moving-average impact matrix
     0.051222     -0.41722      0.76758      0.27996
     0.036119       1.1630     -0.29373      0.17593
     0.061522      0.29720      0.46449      0.32449
     0.058738     -0.49560      0.89004      0.32130

log-likelihood     235.885635  -T/2log|Omega|     451.564292
no. of observations        38  no. of parameters          16
rank of long-run matrix     2  no. long-run restrictions   0
beta is not identified
No restrictions imposed
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha 13: Odhady kointegračních vektorů pro přidání restrikcí

```
Cointegrated VAR (1) in:
[0] = LMI_CR
[1] = LHDP_CR
[2] = LSAM2_CR
[3] = LPRIBOR_CR
Unrestricted variables:
[0] = D
Number of lags used in the analysis: 1

General cointegration restrictions:
&11=0;&10=1;&13=0;&14=0;&15=1;

beta
LMI_CR             -0.76408     -0.92912
LHDP_CR            -0.55047      0.00000
LSAM2_CR             1.0000      0.00000
LPRIBOR_CR          0.00000       1.0000

Standard errors of beta
LMI_CR             0.024466      0.02097
LHDP_CR           0.0038386      0.00000
LSAM2_CR            0.00000      0.00000
LPRIBOR_CR          0.00000      0.00000

alpha
LMI_CR              0.59382      0.22882
LHDP_CR           -0.017822     0.010719
LSAM2_CR          -0.029569     0.021478
LPRIBOR_CR        -0.055149    -0.089122
```

```
Standard errors of alpha
LMI_CR              0.13996     0.098289
LHDP_CR           0.0042334    0.0029729
LSAM2_CR          0.0044856    0.0031500
LPRIBOR_CR         0.041212     0.028941

Restricted long-run matrix, rank 2
                    LMI_CR      LHDP_CR     LSAM2_CR   LPRIBOR_CR
LMI_CR            -0.66633     -0.32688      0.59382      0.22882
LHDP_CR           0.0036575    0.0098103    -0.017822     0.010719
LSAM2_CR          0.0026379     0.016277    -0.029569     0.021478
LPRIBOR_CR          0.12494     0.030358    -0.055149    -0.089122

Standard errors of long-run matrix
LMI_CR              0.12899     0.077046      0.13996     0.098289
LHDP_CR           0.0039016    0.0023304    0.0042334    0.0029729
LSAM2_CR          0.0041340    0.0024692    0.0044856    0.0031500
LPRIBOR_CR         0.037982     0.022686     0.041212     0.028941

Moving-average impact matrix
     0.056698     -0.48011      0.87218      0.29801
     0.037360       1.1416     -0.25714      0.17126
     0.063887      0.26155      0.52486      0.32198
     0.052679     -0.44608      0.81036      0.27689

log-likelihood     235.837491  -T/2log|Omega|     451.516148
no. of observations        38  no. of parameters          15
rank of long-run matrix     2  no. long-run restrictions   1
beta is identified
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha 14: Odhad statické regrese (5.4)

```
Modelling LPRIBOR_CR by OLS (using data_DP_CR.in7)
The estimation sample is: 2002 (2) to 2011 (4)

                  Coefficient  Std.Error  t-value  t-prob Part.R^2
LMI_CR               0.820319     0.1492     5.50   0.000   0.4429

sigma                0.747274  RSS                21.2199232
log-likelihood       -43.4705  DW                       0.49
no. of observations        39  no. of parameters           1
mean(LPRIBOR_CR)     0.946592  var(LPRIBOR_CR)     0.0806768

AR 1-3 test:      F(3,35)  =   3.0302 [0.0422]*
ARCH 1-3 test:    F(3,32)  =   2.3114 [0.0949]
Normality test:   Chi^2(2) =   4.6882 [0.0959]
hetero test:      F(2,35)  =   31.282 [0.0000]**
hetero-X test:    F(2,35)  =   31.282 [0.0000]**
RESET test:       F(1,37)  =   4.5027 [0.0406]*
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha 15: Test kointegrace regrese (5.4)

```
Unit-root tests (using data_DP_CR.in7)
The sample is 2002 (3) - 2011 (4)

residuals: ADF tests (T=38; 5%=-1.95 1%=-2.62)
D-lag    t-adf      beta Y_1    sigma   t-DY_lag  t-prob       AIC  F-prob
  0     -2.862**     0.70107   0.4797                       -1.443
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha 16: Model dynamické regrese (5.5)

```
Modelling LPRIBOR_CR by OLS (using data_DP_CR.in7)
The estimation sample is: 2003 (1) to 2011 (4)

                  Coefficient  Std.Error  t-value  t-prob Part.R^2
LPRIBOR_CR_1         0.898499    0.03147     28.6   0.000   0.9611
LMI_CR               0.164988    0.04641     3.56   0.001   0.2770
D                   -0.363541     0.1721    -2.11   0.042   0.1191

sigma                0.125451  RSS               0.519355739
log-likelihood        25.2145  DW                       2.26
no. of observations        36  no. of parameters           3
mean(LPRIBOR_CR)       0.9307  var(LPRIBOR_CR)     0.0816039

AR 1-3 test:      F(3,30)  =  0.32940 [0.8041]
ARCH 1-3 test:    F(3,27)  = 0.049625 [0.9851]
Normality test:   Chi^2(2) =   9.7238 [0.0077]**
hetero test:      F(5,27)  =  0.32884 [0.8911]
hetero-X test:    F(6,26)  =  0.65021 [0.6896]
RESET test:       F(1,32)  = 0.096032 [0.7587]
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha 17: Odhad modelu VAR(1) pro období III/2002 – I/2011

```
Estimating the system by OLS
The estimation sample is: 2002 (3) to 2011 (1)

URF equation for: DLSAISC_CR
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_CR_1         0.257906     0.1268     2.03   0.051
DLHDP_CR_1          0.0855504    0.05173     1.65   0.109
DLSAM2_CR_1         0.0864948    0.03970     2.18   0.037
DLPRIBOR_CR_1     0.000346511   0.004892   0.0708   0.944
D              U    0.0224433   0.004617     4.86   0.000

sigma = 0.00425877   RSS = 0.0005441135995

URF equation for: DLHDP_CR
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_CR_1        -0.123200     0.4362   -0.282   0.780
DLHDP_CR_1           0.311172     0.1779     1.75   0.091
DLSAM2_CR_1          0.293433     0.1365     2.15   0.040
DLPRIBOR_CR_1       0.0276488    0.01682     1.64   0.111
D              U  -0.00132419    0.01588  -0.0834   0.934

sigma = 0.0146466   RSS = 0.0064356969
```

```
URF equation for: DLSAM2_CR
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_CR_1         0.143268     0.4547    0.315   0.755
DLHDP_CR_1           0.519931     0.1855     2.80   0.009
DLSAM2_CR_1          0.535970     0.1423     3.77   0.001
DLPRIBOR_CR_1     0.000732389    0.01754   0.0418   0.967
D              U  -0.00595456    0.01655   -0.360   0.722

sigma = 0.0152689   RSS = 0.006994224647

URF equation for: DLPRIBOR_CR
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_CR_1          4.29006      4.688    0.915   0.367
DLHDP_CR_1            2.08330      1.912     1.09   0.285
DLSAM2_CR_1          -1.50293      1.467    -1.02   0.314
DLPRIBOR_CR_1       0.0641195     0.1808    0.355   0.725
D              U   -0.0361505     0.1707   -0.212   0.834

sigma = 0.157415   RSS = 0.7433814682

log-likelihood      368.31333  -T/2log|Omega|     566.964725
|Omega|       8.50617274e-015  log|Y'Y/T|        -30.6926266
R^2(LR)              0.818293  R^2(LM)               0.25356
no. of observations        35  no. of parameters          20

F-test on regressors except unrestricted: F(16,83) = 3.88366 [0.0000] **
F-tests on retained regressors, F(4,27) =
DLSAISC_CR_1       1.16490 [0.348]    DLHDP_CR_1       2.87841 [0.042]*
 DLSAM2_CR_1       4.05362 [0.011]* DLPRIBOR_CR_1      0.727297 [0.581]
           D U     7.24716 [0.000]**

correlation of URF residuals (standard deviations on diagonal)
                DLSAISC_CR     DLHDP_CR    DLSAM2_CR  DLPRIBOR_CR
DLSAISC_CR       0.0042588      0.30979      0.15632      0.28328
DLHDP_CR           0.30979     0.014647      0.20992    -0.021198
DLSAM2_CR          0.15632      0.20992     0.015269     -0.26294
DLPRIBOR_CR        0.28328    -0.021198     -0.26294      0.15741
correlation between actual and fitted
   DLSAISC_CR     DLHDP_CR    DLSAM2_CR  DLPRIBOR_CR
      0.79125      0.41590      0.55108      0.37592

Vector Portmanteau( 5): 57.0188
Vector AR 1-3 test:      F(48,59) =  0.75357 [0.8434]
Vector Normality test:   Chi^2(8) =   12.553 [0.1282]
Vector hetero test:      F(80,84) =  0.76666 [0.8838]
Vector hetero-X test:    F(140,66)=  0.59812 [0.9941]
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha 18: Bodová a intervalová předpověď ex ante na období I – III/2012 pro VAR(1) model s daty III/2002 – IV/2011

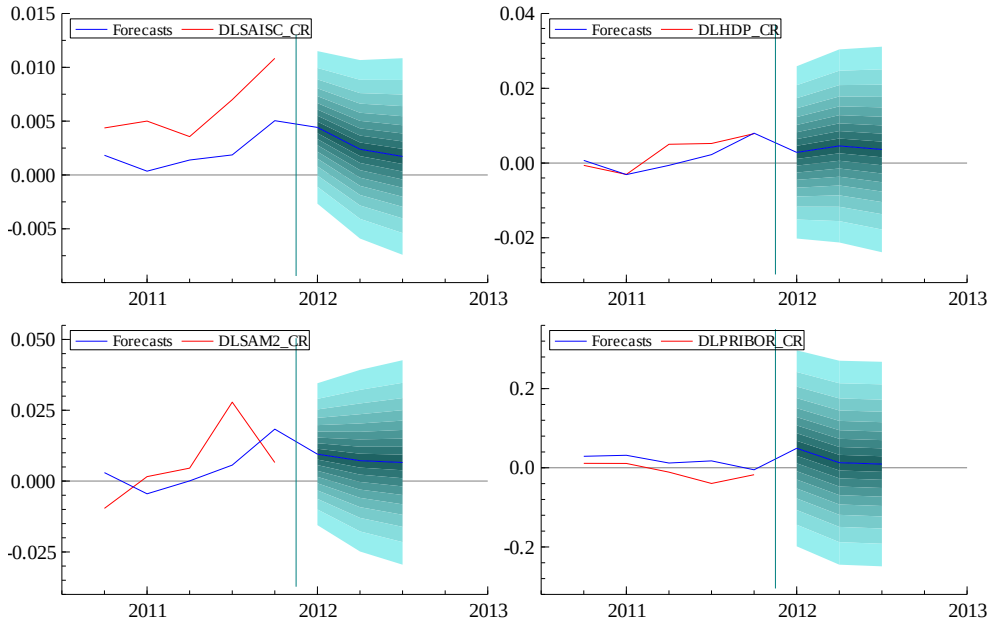


*Zdroj: Vlastní výpočet v GiveWin*

Příloha 19: Průběhy sezónně očištěných časových řad *SAISC_SRN* a *SAM2_SRN*

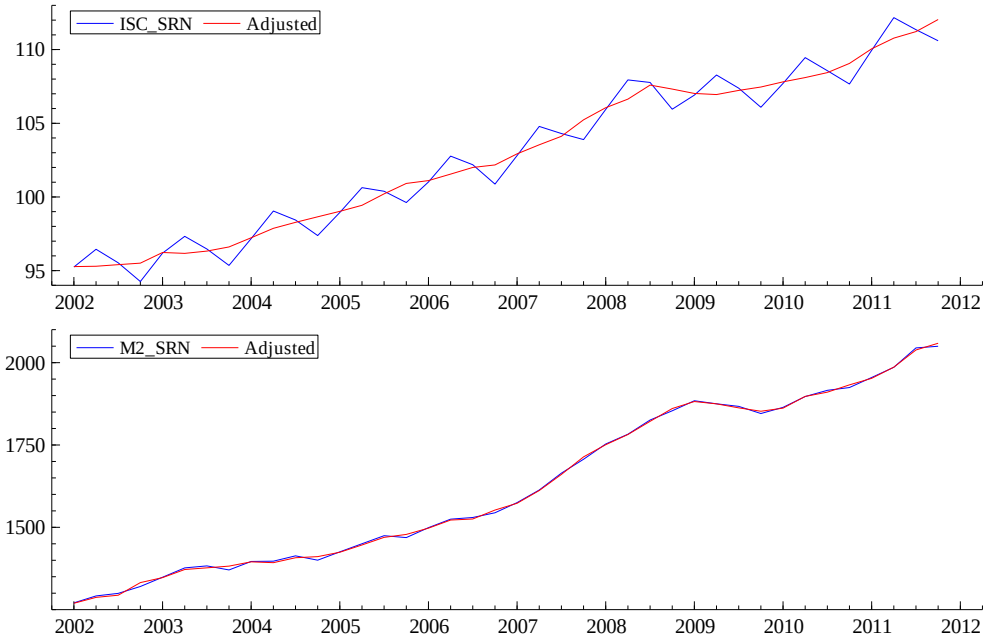


*Zdroj: Vlastní výpočet v GiveWin*

Příloha 20: ADF testy pro *SAISC_SRN*, *HDP_SRN*, *SAM2_SRN* a *EURIBOR_SRN*

```
gretl: ADF test
Dickey-Fuller tests for SAISC__SRN
sample size 39
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: 0,385
   estimated value of (a - 1): 0,0117876
   test statistic: tau_c(1) = 1,11106
   p-value 0,9969
```

```
gretl: ADF test
Dickey-Fuller tests for HDP_SRN
sample size 39
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: 0,444
   estimated value of (a - 1): -0,00166433
   test statistic: tau_c(1) = -0,0606421
   p-value 0,9467
```

```
gretl: ADF test
Dickey-Fuller tests for SAM2_SRN
sample size 39
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: 0,505
   estimated value of (a - 1): 0,0113292
   test statistic: tau_c(1) = 1,01929
   p-value 0,996
```

```
gretl: ADF test
Dickey-Fuller tests for EURIBOR_SRN
sample size 39
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: 0,478
   estimated value of (a - 1): -0,0951134
   test statistic: tau_c(1) = -1,37956
   p-value 0,5823
```

*Zdroj: Vlastní výpočet v Gretl*

Příloha 21: ADF testy pro první diference logaritmů proměnných *SAISC_SRN*, *HDP_SRN*, *SAM2_SRN* a *EURIBOR_SRN*

```
gretl: ADF test
Dickey-Fuller tests for DLSAISC__SR
sample size 38
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: -0,030
   estimated value of (a - 1): -0,620971
   test statistic: tau_c(1) = -4,0544
   p-value 0,003139
```

```
gretl: ADF test
Dickey-Fuller tests for DLHDP_SRN
sample size 38
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: 0,057
   estimated value of (a - 1): -0,568693
   test statistic: tau_c(1) = -3,78886
   p-value 0,006383
```

```
gretl: ADF test
Dickey-Fuller tests for DLSAM2_SRN
sample size 38
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: -0,076
   estimated value of (a - 1): -0,553207
   test statistic: tau_c(1) = -3,70465
   p-value 0,007949
```

```
gretl: ADF test
Dickey-Fuller tests for DLEURIBOR_SRN
sample size 38
unit-root null hypothesis: a = 1

   test with constant
   model: (1 - L)y = b0 + (a-1)*y(-1) + e
   1st-order autocorrelation coeff. for e: 0,035
   estimated value of (a - 1): -0,490873
   test statistic: tau_c(1) = -3,25243
   p-value 0,02452
```

*Zdroj: Vlastní výpočet v Gretl*

Příloha č. 22: Průběhy proměnných *DLSAISC_SRN*, *DLHDP_SRN*, *DLSAM2_SRN* a *DLEURIBOR_SRN*

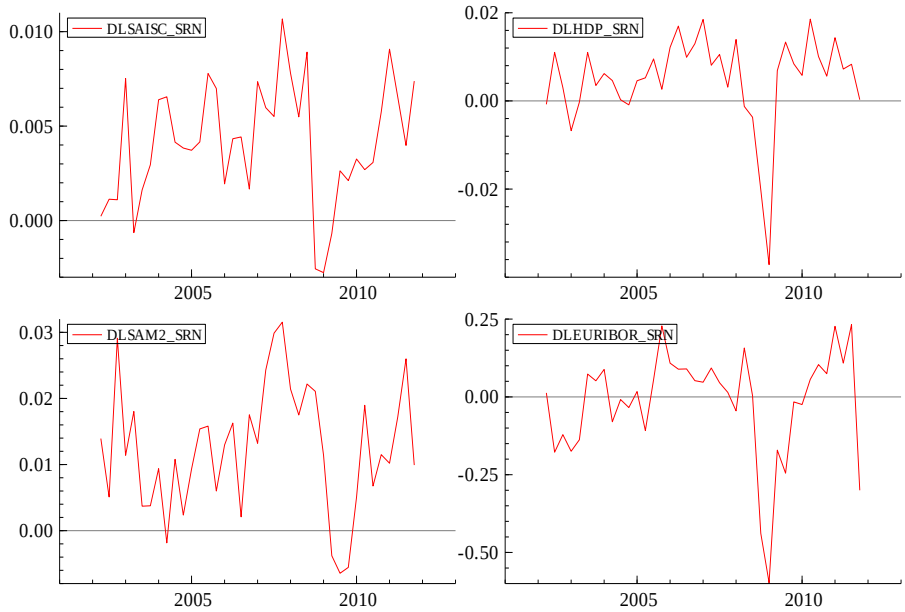


*Zdroj: Vlastní výpočet v GiveWin*

Příloha č. 23: Odhad VAR(1) modelu pro data III/2002 – IV/2011 za SRN

```
Estimating the system by OLS
The estimation sample is: 2002 (3) to 2011 (4)

URF equation for: DLSAISC_SRN
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_SRN_1        0.271426     0.1463     1.86   0.072
DLHDP_SRN_1          0.154226    0.05608     2.75   0.009
DLSAM2_SRN_1         0.154829    0.04282     3.62   0.001
DLEURIBOR_SRN_1  -0.000419347   0.003462   -0.121   0.904

sigma = 0.00276981   RSS = 0.0002608435237

URF equation for: DLHDP_SRN
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_SRN_1        0.380226     0.5230    0.727   0.472
DLHDP_SRN_1          0.512640     0.2005     2.56   0.015
DLSAM2_SRN_1       -0.0441392     0.1530   -0.288   0.775
DLEURIBOR_SRN_1   -0.00476006    0.01237   -0.385   0.703

sigma = 0.0099002   RSS = 0.003332473674

URF equation for: DLSAM2_SRN
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_SRN_1         1.33628     0.4330     3.09   0.004
DLHDP_SRN_1          0.164161     0.1660    0.989   0.330
DLSAM2_SRN_1         0.441522     0.1267     3.48   0.001
DLEURIBOR_SRN_1   -0.00668902    0.01024   -0.653   0.518

sigma = 0.0081967   RSS = 0.00228432106
```

```
URF equation for: DLEURIBOR_SRN
                   Coefficient  Std.Error  t-value  t-prob
DLSAISC_SRN_1          5.16258      7.672    0.673   0.506
DLHDP_SRN_1            4.92413      2.941     1.67   0.103
DLSAM2_SRN_1          -4.25599      2.245    -1.90   0.067
DLEURIBOR_SRN_1       0.279089     0.1815     1.54   0.133

sigma = 0.145239   RSS = 0.7172072605

log-likelihood      456.864561  -T/2log|Omega|      672.543218
|Omega|        4.23909599e-016  log|Y'Y/T|        -32.8338688
R^2(LR)               0.922938  R^2(LM)               0.331963
no. of observations         38  no. of parameters          16

F-test on regressors except unrestricted: F(16,95) = 7.83025 [0.0000] **
F-tests on retained regressors, F(4,31) =
DLSAISC_SRN_1       3.06767 [0.031]*  DLHDP_SRN_1       2.56831 [0.058]
DLSAM2_SRN_1       8.26036 [0.000]**DLEURIBOR_SRN_1       1.03066 [0.407]

correlation of URF residuals (standard deviations on diagonal)
                DLSAISC_SRN    DLHDP_SRN   DLSAM2_SRNDLEURIBOR_SRN
DLSAISC_SRN       0.0027698      0.39541    -0.036119      0.30542
DLHDP_SRN           0.39541    0.0099002     0.013074      0.49799
DLSAM2_SRN        -0.036119     0.013074    0.0081967    -0.026031
DLEURIBOR_SRN       0.30542      0.49799    -0.026031      0.14524
correlation between actual and fitted
  DLSAISC_SRN    DLHDP_SRN   DLSAM2_SRNDLEURIBOR_SRN
      0.59660      0.41226      0.58865      0.59750
DLSAISC_SRN : Portmanteau( 5): 4.72095
DLHDP_SRN   : Portmanteau( 5): 1.19831
DLSAM2_SRN  : Portmanteau( 5): 3.27746
DLEURIBOR_SRN: Portmanteau( 5): 0.905321
DLSAISC_SRN : AR 1-3 test:       F(3,31)  =   1.0643 [0.3784]
DLHDP_SRN   : AR 1-3 test:       F(3,31)  =  0.24056 [0.8674]
DLSAM2_SRN  : AR 1-3 test:       F(3,31)  =   1.4924 [0.2359]
DLEURIBOR_SRN: AR 1-3 test:       F(3,31)  =  0.79948 [0.5036]
DLSAISC_SRN : Normality test:    Chi^2(2) =   4.3454 [0.1139]
DLHDP_SRN   : Normality test:    Chi^2(2) =   8.2240 [0.0164]*
DLSAM2_SRN  : Normality test:    Chi^2(2) =   1.3655 [0.5052]
DLEURIBOR_SRN: Normality test:    Chi^2(2) =   2.9690 [0.2266]
DLSAISC_SRN : ARCH 1-3 test:     F(3,28)  =  0.40037 [0.7538]
DLHDP_SRN   : ARCH 1-3 test:     F(3,28)  =   6.8129 [0.0014]**
DLSAM2_SRN  : ARCH 1-3 test:     F(3,28)  =  0.95172 [0.4291]
DLEURIBOR_SRN: ARCH 1-3 test:     F(3,28)  =   1.7083 [0.1880]
DLSAISC_SRN : hetero test:       F(8,25)  =   1.1289 [0.3786]
DLHDP_SRN   : hetero test:       F(8,25)  =   8.8013 [0.0000]**
DLSAM2_SRN  : hetero test:       F(8,25)  =  0.80530 [0.6041]
DLEURIBOR_SRN: hetero test:       F(8,25)  =   1.1451 [0.3692]
DLSAISC_SRN : hetero-X test:     F(14,19) =   1.7360 [0.1304]
DLHDP_SRN   : hetero-X test:     F(14,19) =   5.3031 [0.0005]**
DLSAM2_SRN  : hetero-X test:     F(14,19) =  0.87819 [0.5912]
DLEURIBOR_SRN: hetero-X test:     F(14,19) =   1.0578 [0.4457]
```

```
Vector Portmanteau( 5): 75.834
Vector AR 1-3 test:        F(48,75) =    1.5791 [0.0374]*
Vector Normality test:     Chi^2(8) =    6.5164 [0.5896]
Vector hetero test:        F(80,110)=    1.4543 [0.0343]*
Vector hetero-X test:      F(140,99)=    1.2239 [0.1428]
```

Zdroj: Vlastní výpočet v GiveWin

## Příloha č. 24: Rezidua pro model VAR(1) s daty pro SRN

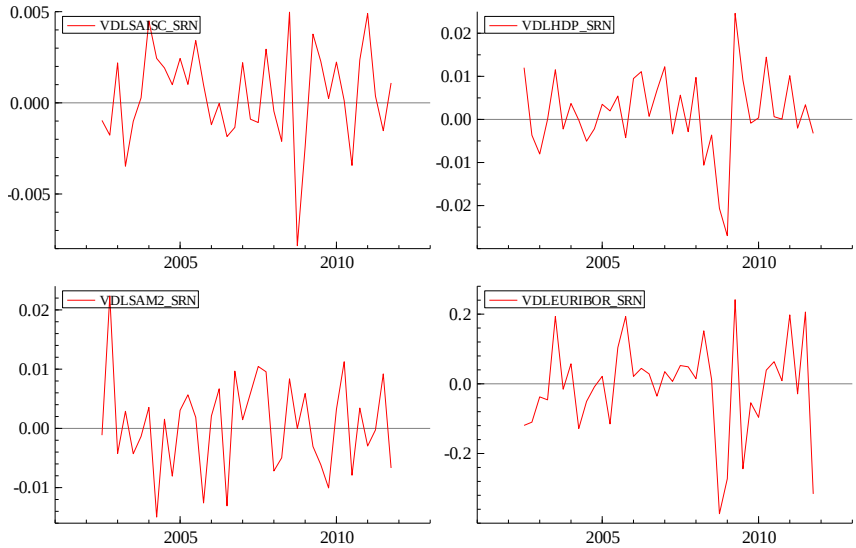


*Zdroj: Vlastní výpočet v GiveWin*

## Příloha č. 25: Analýza funkce odezvy pro SRN

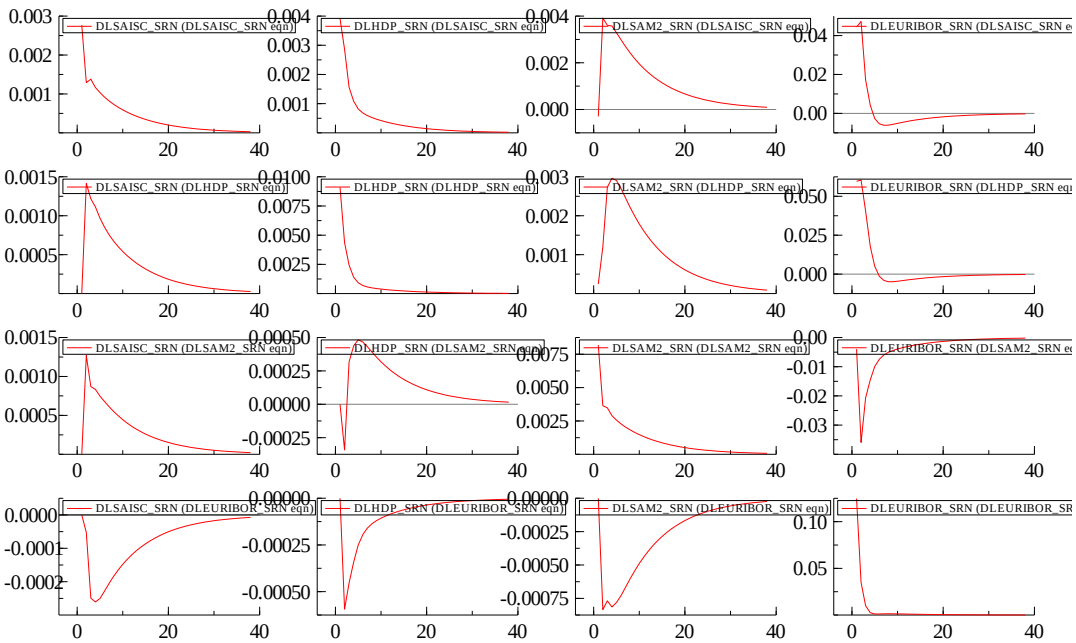


*Zdroj: Vlastní výpočet v GiveWin*

Příloha č. 26: Nevýznamné testy Grangerovy kauzality pro SRN

```
Test for excluding: DLEURIBOR_SRN_1@DLSAISC_SRN
Subset Chi^2(1) = 0.014673 [0.9036]

Test for excluding: DLSAISC_SRN_1@DLHDP_SRN
Subset Chi^2(1) =  0.52857 [0.4672]

Test for excluding: DLSAM2_SRN_1@DLHDP_SRN
Subset Chi^2(1) = 0.083173 [0.7730]

Test for excluding: DLEURIBOR_SRN_1@DLHDP_SRN
Subset Chi^2(1) =  0.14798 [0.7005]

Test for excluding: DLHDP_SRN_1@DLSAM2_SRN
Subset Chi^2(1) =  0.97844 [0.3226]

Test for excluding: DLEURIBOR_SRN_1@DLSAM2_SRN
Subset Chi^2(1) =  0.42630 [0.5138]

Test for excluding: DLSAISC_SRN_1@DLEURIBOR_SRN
Subset Chi^2(1) =  0.45276 [0.5010]
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha č. 27: Odhad modelu VAR(1) pro logaritmovaná data III/2002 – IV/2011 za SRN

```
Estimating the system by OLS
The estimation sample is: 2002 (3) to 2011 (4)

URF equation for: LMI_SRN
                  Coefficient  Std.Error  t-value  t-prob
LMI_SRN_1            0.373050     0.1651     2.26   0.030
LHDP_SRN_1           0.473353     0.8236    0.575   0.569
LSAM2_SRN_1         -0.366190     0.7014   -0.522   0.605
LEURIBOR_SRN_1     -0.0369038     0.1393   -0.265   0.793

sigma = 0.3036   RSS = 3.133887747

URF equation for: LHDP_SRN
                  Coefficient  Std.Error  t-value  t-prob
LMI_SRN_1          0.00544359   0.005287     1.03   0.310
LHDP_SRN_1            1.04275    0.02637     39.5   0.000
LSAM2_SRN_1        -0.0349814    0.02246    -1.56   0.129
LEURIBOR_SRN_1     -0.0114525   0.004461    -2.57   0.015

sigma = 0.00972043   RSS = 0.003212550099

URF equation for: LSAM2_SRN
                  Coefficient  Std.Error  t-value  t-prob
LMI_SRN_1           0.0102176   0.004253     2.40   0.022
LHDP_SRN_1        -0.00560915    0.02121   -0.264   0.793
LSAM2_SRN_1           1.00464    0.01806     55.6   0.000
LEURIBOR_SRN_1      0.0101325   0.003588     2.82   0.008

sigma = 0.00781806   RSS = 0.002078149485
```

```
URF equation for: LEURIBOR_SRN
                  Coefficient  Std.Error  t-value  t-prob
LMI_SRN_1            0.263191    0.07965     3.30   0.002
LHDP_SRN_1           0.852950     0.3972     2.15   0.039
LSAM2_SRN_1         -0.724286     0.3383    -2.14   0.040
LEURIBOR_SRN_1       0.783034    0.06720     11.7   0.000

sigma = 0.146429   RSS = 0.7290121799

log-likelihood     287.099699  -T/2log|Omega|     502.778356
|Omega|        3.2187799e-012  log|Y'Y/T|         -5.7810017
R^2(LR)                      1  R^2(LM)              0.748703
no. of observations         38  no. of parameters          16

F-test on regressors except unrestricted: F(16,95) = 5183.35 [0.0000] **
F-tests on retained regressors, F(4,31) =
   LMI_SRN_1       3.83839 [0.012]*   LHDP_SRN_1       567.187 [0.000]**
 LSAM2_SRN_1       740.292 [0.000]**LEURIBOR_SRN_1       76.7464 [0.000]**

correlation of URF residuals (standard deviations on diagonal)
                   LMI_SRN     LHDP_SRN    LSAM2_SRN LEURIBOR_SRN
LMI_SRN            0.30360      0.35519     0.074513      0.47651
LHDP_SRN           0.35519    0.0097204     0.063022      0.63837
LSAM2_SRN         0.074513     0.063022    0.0078181      0.17281
LEURIBOR_SRN       0.47651      0.63837      0.17281      0.14643
correlation between actual and fitted
      LMI_SRN     LHDP_SRN    LSAM2_SRN LEURIBOR_SRN
      0.38858      0.98865      0.99867      0.94377
```

```
LMI_SRN      : Portmanteau( 5): 2.90248
LHDP_SRN     : Portmanteau( 5): 5.63407
LSAM2_SRN    : Portmanteau( 5): 2.29076
LEURIBOR_SRN: Portmanteau( 5): 2.44399
LMI_SRN      : AR 1-3 test:       F(3,31)  =  0.49637 [0.6875]
LHDP_SRN     : AR 1-3 test:       F(3,31)  =   2.2325 [0.1041]
LSAM2_SRN    : AR 1-3 test:       F(3,31)  =  0.24374 [0.8651]
LEURIBOR_SRN: AR 1-3 test:       F(3,31)  =   1.0807 [0.3717]
LMI_SRN      : Normality test:    Chi^2(2) =   3.5650 [0.1682]
LHDP_SRN     : Normality test:    Chi^2(2) =   7.9851 [0.0185]*
LSAM2_SRN    : Normality test:    Chi^2(2) =   1.0479 [0.5922]
LEURIBOR_SRN: Normality test:    Chi^2(2) =   3.6803 [0.1588]
LMI_SRN      : ARCH 1-3 test:     F(3,28)  =  0.83304 [0.4870]
LHDP_SRN     : ARCH 1-3 test:     F(3,28)  =  0.42730 [0.7350]
LSAM2_SRN    : ARCH 1-3 test:     F(3,28)  =   1.4057 [0.2618]
LEURIBOR_SRN: ARCH 1-3 test:     F(3,28)  =  0.98391 [0.4145]
LMI_SRN      : hetero test:       F(8,25)  =   2.0014 [0.0884]
LHDP_SRN     : hetero test:       F(8,25)  =   2.3906 [0.0457]*
LSAM2_SRN    : hetero test:       F(8,25)  =  0.75468 [0.6443]
LEURIBOR_SRN: hetero test:       F(8,25)  =   2.1213 [0.0721]
LMI_SRN      : hetero-X test:     F(14,19) =   4.0887 [0.0026]**
LHDP_SRN     : hetero-X test:     F(14,19) =   8.5421 [0.0000]**
LSAM2_SRN    : hetero-X test:     F(14,19) =  0.43001 [0.9438]
LEURIBOR_SRN: hetero-X test:     F(14,19) =   3.3104 [0.0083]**
```

```
Vector Portmanteau( 5): 80.9696
Vector AR 1-3 test:       F(48,75) =   1.3059 [0.1481]
Vector Normality test:    Chi^2(8) =   9.0648 [0.3369]
Vector hetero test:       F(80,110)=   1.2394 [0.1478]
Vector hetero-X test:     F(140,99)=   1.4912 [0.0176]*
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha č. 28: Johansenův test kointegrace pro VAR(1) s logaritmovanými časovými řadami pro SRN

```
I(1) cointegration analysis, 2002 (3) to 2011 (4)
  eigenvalue    loglik for rank
                  231.7041   0
     0.81107      263.3652   1
     0.61130      281.3193   2
     0.24744      286.7205   3
    0.019760      287.0997   4

  H0:rank<=  Trace test [ Prob]
      0          110.79 [0.000] **
      1          47.469 [0.000] **
      2          11.561 [0.066]
      3         0.75839 [0.444]

Asymptotic p-values based on: No constant
Number of lags used in the analysis: 1

beta (scaled on diagonal; cointegrating vectors in columns)
LMI_SRN             1.0000       1.0753    0.0064811      -7.9679
LHDP_SRN           -3.4886       1.0000      -1.2252       181.49
LSAM2_SRN           3.0698     -0.88896       1.0000      -156.32
LEURIBOR_SRN        2.8963     -0.28286      0.38617       1.0000

alpha
LMI_SRN         -0.0044928     -0.55838     -0.47704    0.0023781
LHDP_SRN         0.0010328    0.0043118    -0.034246  4.6429e-007
LSAM2_SRN        0.0035292    0.0064248    0.0043946  3.1197e-005
LEURIBOR_SRN    -0.0065029      0.25980     -0.32523   0.00094773

long-run matrix, rank 4
                   LMI_SRN     LHDP_SRN    LSAM2_SRN LEURIBOR_SRN
LMI_SRN           -0.62695      0.47335     -0.36619    -0.036904
LHDP_SRN         0.0054436     0.042751    -0.034981    -0.011453
LSAM2_SRN         0.010218   -0.0056091    0.0046404     0.010133
LEURIBOR_SRN       0.26319      0.85295     -0.72429     -0.21697
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha č. 29: Odhady kointegračních vektorů pro SRN

```
Cointegrated VAR (1) in:
[0] = LMI_SRN
[1] = LHDP_SRN
[2] = LSAM2_SRN
[3] = LEURIBOR_SRN
Number of lags used in the analysis: 1

beta
LMI_SRN             1.0000       1.0753
LHDP_SRN           -3.4886       1.0000
LSAM2_SRN           3.0698     -0.88896
LEURIBOR_SRN        2.8963     -0.28286

alpha
LMI_SRN         -0.0044928     -0.55838
LHDP_SRN         0.0010328    0.0043118
LSAM2_SRN        0.0035292    0.0064248
LEURIBOR_SRN    -0.0065029      0.25980

Standard errors of alpha
LMI_SRN           0.013106      0.15354
LHDP_SRN        0.00046362    0.0054317
LSAM2_SRN       0.00032759    0.0038380
LEURIBOR_SRN     0.0064894     0.076029

Restricted long-run matrix, rank 2
                   LMI_SRN     LHDP_SRN    LSAM2_SRN LEURIBOR_SRN
LMI_SRN           -0.60491     -0.54271      0.48259      0.14493
LHDP_SRN         0.0056692   0.00070866  -0.00066241    0.0017718
LSAM2_SRN         0.010438   -0.0058872    0.0051226    0.0084043
LEURIBOR_SRN       0.27285      0.28248     -0.25091    -0.092321

Standard errors of long-run matrix
LMI_SRN            0.16562      0.16021      0.14230     0.057682
LHDP_SRN         0.0058590    0.0056674    0.0050340    0.0020405
LSAM2_SRN        0.0041399    0.0040045    0.0035569    0.0014418
LEURIBOR_SRN      0.082009     0.079328     0.070461     0.028562

Reduced form beta
LMI_SRN           -1.0000      0.00000
LHDP_SRN          0.00000      -1.0000
LSAM2_SRN        0.0066118      0.88185
LEURIBOR_SRN      -0.40190      0.71502

Standard errors of reduced form beta
LMI_SRN           0.00000      0.00000
LHDP_SRN          0.00000      0.00000
LSAM2_SRN        0.024253     0.023600
LEURIBOR_SRN      0.17177      0.16715

Moving-average impact matrix
     0.090014     -0.77620      0.69050      0.18927
     0.081703      0.82480      0.15396      0.15811
      0.27064     -0.62235       1.5470      0.55376
     -0.21952       1.9211      -1.6927     -0.46184

log-likelihood     281.319289  -T/2log|Omega|     496.997946
no. of observations        38  no. of parameters          12
rank of long-run matrix     2  no. long-run restrictions   0
beta is not identified
No restrictions imposed
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha č. 30: Odhady kointegračních vektorů pro přidání restrikcí

```
Cointegrated VAR (1) in:
[0] = LMI_SRN
[1] = LHDP_SRN
[2] = LSAM2_SRN
[3] = LEURIBOR_SRN
Number of lags used in the analysis: 1

General cointegration restrictions:
&11=0;&10=1;&13=0;&14=0;&15=1;

beta
LMI_SRN            -1.8425       2.1138
LHDP_SRN           -1.1272      0.00000
LSAM2_SRN           1.0000      0.00000
LEURIBOR_SRN       0.00000       1.0000

Standard errors of beta
LMI_SRN            0.19854      0.33187
LHDP_SRN          0.011341      0.00000
LSAM2_SRN          0.00000      0.00000
LEURIBOR_SRN       0.00000      0.00000

alpha
LMI_SRN            0.49795      0.14915
LHDP_SRN        -0.0012590    0.0016474
LSAM2_SRN        0.0035967    0.0080435
LEURIBOR_SRN      -0.25616    -0.093531

Standard errors of alpha
LMI_SRN           0.14309     0.056988
LHDP_SRN        0.0050432    0.0020085
LSAM2_SRN       0.0035769    0.0014245
LEURIBOR_SRN     0.070670     0.028145

Restricted long-run matrix, rank 2
                  LMI_SRN     LHDP_SRN    LSAM2_SRN LEURIBOR_SRN
LMI_SRN          -0.60222     -0.56129      0.49795      0.14915
LHDP_SRN        0.0058020    0.0014192   -0.0012590    0.0016474
LSAM2_SRN        0.010375   -0.0040542    0.0035967    0.0080435
LEURIBOR_SRN      0.27428      0.28874     -0.25616    -0.093531

Standard errors of long-run matrix
LMI_SRN           0.16345      0.16129      0.14309     0.056988
LHDP_SRN        0.0057606    0.0056847    0.0050432    0.0020085
LSAM2_SRN       0.0040857    0.0040319    0.0035769    0.0014245
LEURIBOR_SRN     0.080724     0.079660     0.070670     0.028145

Moving-average impact matrix
     0.096138     -0.81288      0.72115      0.20101
     0.082778      0.84544      0.13712      0.15868
      0.27045     -0.54478       1.4833      0.54923
     -0.20322       1.7183      -1.5243     -0.42488

log-likelihood     281.312348  -T/2log|Omega|     496.991005
no. of observations        38  no. of parameters          11
rank of long-run matrix     2  no. long-run restrictions   1
beta is identified
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha č. 31: Odhad statické regrese pro SRN

```
Modelling LEURIBOR_SRN by OLS
The estimation sample is: 2002 (2) to 2011 (4)

                  Coefficient  Std.Error  t-value  t-prob Part.R^2
LMI_SRN               1.58684     0.1939     8.18   0.000   0.6380

sigma                0.630954  RSS                 15.127891
log-likelihood       -36.8717  DW                      0.786
no. of observations        39  no. of parameters           1
mean(LEURIBOR_SRN)     0.946668  var(LEURIBOR_SRN)     0.175363

AR 1-3 test:      F(3,35)  =   4.2221 [0.0119]*
ARCH 1-3 test:    F(3,32)  =  0.42307 [0.7377]
Normality test:   Chi^2(2) =   1.1231 [0.5703]
hetero test:      F(2,35)  =   22.035 [0.0000]**
hetero-X test:    F(2,35)  =   22.035 [0.0000]**
RESET test:       F(1,37)  = 0.037713 [0.8471]
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha č. 32: Test kointegrace regrese v modelu (6.3)

```
Unit-root tests (using data_DP_SRN.in7)
The sample is 2002 (3) - 2011 (4)

residuals: ADF tests (T=38; 5%=-1.95 1%=-2.62)
D-lag    t-adf      beta Y_1    sigma   t-DY_lag  t-prob       AIC  F-prob
  0     -3.542**     0.55041   0.4899                        -1.401
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha č. 33: Dynamický model (6.4)

```
Modelling LEURIBOR_SRN by OLS
The estimation sample is: 2003 (1) to 2011 (4)

                  Coefficient  Std.Error  t-value  t-prob Part.R^2
LEURIBOR_SRN_1       0.810653    0.04391     18.5   0.000   0.9117
LMI_SRN              0.226646    0.07459     3.04   0.005   0.2186
LMI_SRN_1            0.173399    0.08413     2.06   0.047   0.1140

sigma                0.140109  RSS               0.647803555
log-likelihood        21.2366  DW                       1.38
no. of observations        36  no. of parameters           3
mean(LEURIBOR_SRN)     0.926026  var(LEURIBOR_SRN)     0.183181

AR 1-3 test:      F(3,30)  =  0.59357 [0.6241]
ARCH 1-3 test:    F(3,27)  =  0.31564 [0.8139]
Normality test:   Chi^2(2) =   1.5047 [0.4713]
hetero test:      F(6,26)  =  0.98195 [0.4574]
hetero-X test:    F(9,23)  =  0.87943 [0.5569]
RESET test:       F(1,32)  =  0.26855 [0.6079]
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha č. 34: Odhad modelu VAR(1) pro SRN a období III/2002 – I/2011

```
Estimating the system by OLS
The estimation sample is: 2002 (3) to 2011 (1)

URF equation for: DLSAISC_SRN
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_SRN_1        0.285343     0.1594     1.79   0.083
DLHDP_SRN_1          0.154377    0.05852     2.64   0.013
DLSAM2_SRN_1         0.150624    0.04764     3.16   0.003
DLEURIBOR_SRN_1  -0.000742393   0.003802   -0.195   0.846

sigma = 0.00287956   RSS = 0.0002570485476

URF equation for: DLHDP_SRN
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_SRN_1        0.357260     0.5716    0.625   0.537
DLHDP_SRN_1          0.510335     0.2098     2.43   0.021
DLSAM2_SRN_1       -0.0316408     0.1708   -0.185   0.854
DLEURIBOR_SRN_1   -0.00348871    0.01363   -0.256   0.800

sigma = 0.0103251   RSS = 0.003304861975

URF equation for: DLSAM2_SRN
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_SRN_1         1.22496     0.4610     2.66   0.012
DLHDP_SRN_1          0.164341     0.1692    0.971   0.339
DLSAM2_SRN_1         0.470514     0.1378     3.42   0.002
DLEURIBOR_SRN_1   -0.00503654    0.01100   -0.458   0.650

sigma = 0.00832781   RSS = 0.002149926303

URF equation for: DLEURIBOR_SRN
                  Coefficient  Std.Error  t-value  t-prob
DLSAISC_SRN_1         1.31253      7.445    0.176   0.861
DLHDP_SRN_1           4.66889      2.733     1.71   0.098
DLSAM2_SRN_1         -2.62501      2.225    -1.18   0.247
DLEURIBOR_SRN_1      0.391127     0.1776     2.20   0.035

sigma = 0.134487   RSS = 0.5606893137

log-likelihood     422.920386  -T/2log|Omega|     621.571781
|Omega|       3.75457088e-016  log|Y'Y/T|        -32.9753504
R^2(LR)              0.921373  R^2(LM)              0.343369
no. of observations        35  no. of parameters          16

F-test on regressors except unrestricted: F(16,86) = 6.99579 [0.0000] **
F-tests on retained regressors, F(4,28) =
DLSAISC_SRN_1       2.34097 [0.079]   DLHDP_SRN_1       2.30537 [0.083]
DLSAM2_SRN_1       6.11787 [0.001]**DLEURIBOR_SRN_1       1.85206 [0.147]

correlation of URF residuals (standard deviations on diagonal)
               DLSAISC_SRN    DLHDP_SRN   DLSAM2_SRNDLEURIBOR_SRN
DLSAISC_SRN      0.0028796      0.41068   -0.0076255      0.40700
DLHDP_SRN          0.41068     0.010325   -0.0071917      0.52115
DLSAM2_SRN      -0.0076255   -0.0071917    0.0083278     -0.15228
DLEURIBOR_SRN      0.40700      0.52115     -0.15228      0.13449
correlation between actual and fitted
  DLSAISC_SRN    DLHDP_SRN   DLSAM2_SRNDLEURIBOR_SRN
      0.57998      0.41406      0.58790      0.64249
```

*Zdroj: Vlastní výpočet v GiveWin*

Příloha č. 35: Bodová a intervalová předpověď ex ante na období I – III/2012 pro VAR(1) model pro Německo s daty III/2002 – IV/2011

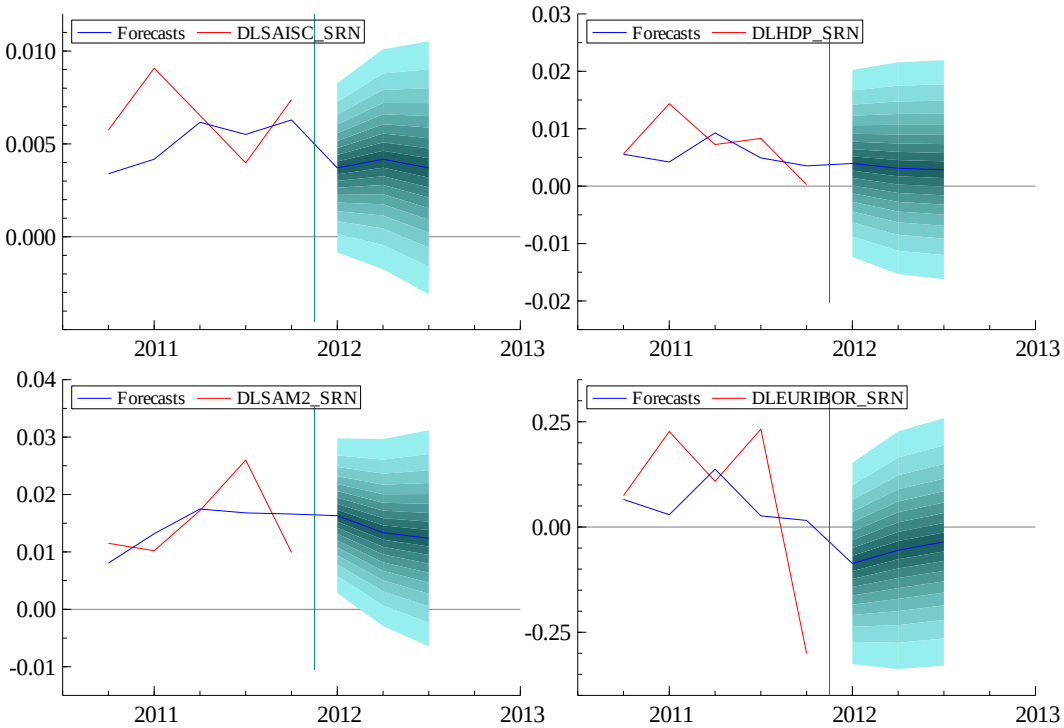


*Zdroj: Vlastní výpočet v GiveWin*

Příloha č. 36: Operace na volném trhu a stálé facility ECB

| Operace měnové politiky | Typ transakce | | Splatnost | Četnost provádění | Postup |
|---|---|---|---|---|---|
| | Poskytnutí likvidity | Stažení likvidity | | | |
| ***Operace na volném trhu*** | | | | | |
| **Hlavní refinanční operace** | Zpětné transakce | | 1 týdny | Týdně | Standardní tendry |
| **Dlouhodobé refinanční operace** | Zpětné transakce | | 3 měsíce | Měsíčně | Standardní tendry |
| **Vylaďovací operace** | Zpětné transakce | Zpětné transakce | Není standardizováno | Nepravidelně | Urychlené tendry |
| | Devizové swapy | Sběr vkladů s pevným termínem | | | Bilaterální záležitost |
| | | Devizové swapy | | | |
| **Strukturální operace** | Zpětné transakce | Emise ECB dluhopisů | Standardizováno / Nestandardizováno | Pravidelně i nepravidelně | Standardní tendry |
| | Přímé nákupy | Přímé prodeje | | Nepravidelně | Bilaterální záležitost |
| ***Stálé facility*** | | | | | |
| **Marginální výpůjční facilita** | Zpětné transakce | | Přes noc | Na základě dohody s protistranou | |
| **Depozitní facilita** | | Depozita | Přes noc | | |

*Zdroj:* www.ecb.europa.eu