VYSOKÁ ŠKOLA EKONOMICKÁ V PRAZE

FAKULTA INFORMATIKY A STATISTIKY



DIPLOMOVÁ PRÁCE

2011 Sára Bisová

VYSOKÁ ŠKOLA EKONOMICKÁ V PRAZE

FAKULTA INFORMATIKY A STATISTIKY



Název diplomové práce

Modely vývoje inflace a její volatility v ČR

Autor:	**Sára Bisová**
Katedra:	**Katedra ekonometrie**
Studijní program:	**Kvantitativní metody v ekonomice**
Studijní obor:	**Ekonometrie a operační výzkum**
Vedoucí práce:	**Prof. Ing. Roman Hušek, CSc.**

Prohlášení:

Prohlašuji, že jsem diplomovou práci na téma „Modely vývoje inflace a její volatility v ČR“ zpracovala samostatně. Veškerou použitou literaturu a další podkladové materiály uvádím v seznamu použité literatury.

V Praze dne 15. dubna 2011 .....

Sára Bisová

Poděkování:

Za velmi příjemnou spolupráci a ochotu zodpovědět všechny dotazy týkající se mé diplomové práce děkuji svému vedoucímu práce, panu Prof. Ing. Romanu Huškovi, CSc.

ABSTRAKT

Název práce: Modely vývoje inflace a její volatility v ČR
Autor: Sára Bisová
Katedra: Katedra ekonometrie
Vedoucí práce: Prof. Ing. Roman Hušek, CSc.

Cílem diplomové práce je modelování a analýza vývoje inflace v České republice na základě aplikace vybraných ekonometrických modelů. V práci je nejdříve stručně popsána ekonomická teorie inflace – vysvětlení základních pojmů, způsoby měření inflace, postupy jejího sledování ze strany České národní banky a krátký pohled do historického vývoje inflace v české ekonomice. Dále jsou zvoleny dva ekonometrické přístupy k modelování inflace – modely volatility časových řad (speciálně modely ARCH a GARCH) a modely VAR (modely vektorové autoregrese). V souvislosti s modely VAR je zkoumána také Grangerova kauzalita, analýza funkcí odezvy, kointegrace a modely korekce chyby. Ekonometrické přístupy modelování jsou nejdříve teoreticky popsány. Dále jsou vybrány vhodné konkrétní modely pro odhad a ty jsou následně aplikovány na reálná data vybraných makroekonomických časových řad. Výsledky jsou interpretovány a aplikované modely srovnány co do kvality ekonometrické analýzy a predikce.

Klíčová slova: inflace, VAR, volatilita, ARCH, GARCH, kointegrace, Grangerova kauzalita, analýza funkcí odezvy, model korekce chyby

ABSTRACT

Title: Models of inflation and its volatility in CZ
Author: Sára Bisová
Department: Department of Econometrics
Supervisor: Prof. Ing. Roman Hušek, CSc.

This paper focuses on analysing and modelling inflation and its dynamics in Czech Republic applying a special kind of econometric models. Firstly economic theory of inflation is mentioned – fundamental terms, measuring methods of inflation, the way Czech national bank is monitoring the inflation and obviously a short summary of historical evolution of inflation in Czech economy. In the second part of this paper two econometric concepts of modelling time series are introduced – vector autoregression models (VAR models) and volatility models, concretely ARCH and GARCH models. In connection with the VAR models, Granger causality, impulse response functions, cointegration and error correction models are described. The empirical part includes application of selected models on real time series of chosen macroeconomic indicators. The estimation outputs are interpreted and forecasts are implemented. The quality of chosen econometric models for modelling inflation in Czech Republic is discussed.

Keywords: inflation, VAR, volatility, ARCH, GARCH, cointegration, Granger causality, impulse response functions, error correction model

OBSAH

SEZNAM OBRÁZKŮ 6
SEZNAM TABULEK 7
1 ÚVOD 8
2 EKONOMICKÁ TEORIE INFLACE 10
2.1 Základní pojmy a vztahy 10
2.2 Způsoby měření inflace 13
2.3 ČNB a režim cílování inflace 14
2.4 Historický vývoj inflace v ČR 16
2.5 Empirické studie dynamiky inflace 18
3 EKONOMETRICKÉ MODELY VAR 19
3.1 Vektorové autoregresní modely a jejich odhad 19
3.2 Grangerova kauzalita a analýza funkcí odezvy 22
3.3 Kointegrace 24
3.4 Modely korekce chyby 26
4 MODELY PODMÍNĚNÉ HETEROSKEDASTICITY 27
4.1 Modely ARCH 27
4.1.1 ARCH(1) 27
4.1.2 ARCH(q) 29
4.2 Modely GARCH 30
4.2.1 GARCH(1,1) 30
4.2.2 GARCH(p,q) 31
4.3 Odhad modelů ARCH a GARCH 32
5 EMPIRICKÁ ANALÝZA A PREDIKCE NA ZÁKLADĚ VAR MODELŮ 33
5.1 Data 33
5.2 Odhad modelů VAR 36
5.2.1 Výběr VAR modelu a funkce odezvy 36
5.2.2 Grangerova kauzalita 37
5.2.3 Kointegrace a model korekce chyby 38
5.2.4 Predikce na základě modelu VAR(1) 40
6 ANALÝZA A PREDIKCE VOLATILITY INFLACE 43
6.1 Modely ARCH a GARCH – odhad modelu v jednom kroku 43
6.1.1 Odhad modelu ARCH(1) a predikce – odhad modelu v jednom kroku 45
6.2 Modely ARCH a GARCH – odhad modelu ve dvou krocích 49
6.2.1 Odhad modelu ARCH(1) a predikce – odhad modelu ve dvou krocích 52
7 ZÁVĚR 57
SEZNAM LITERATURY 59
SEZNAM PŘÍLOH 61
PŘÍLOHY 63

SEZNAM OBRÁZKŮ

Obrázek 5.1 - Průběhy časových řad pro ČR - M2, 1RPRIBOR, ISC a HDP 34
Obrázek 5.2 - Kointegrační vztahy 39
Obrázek 6.1 - Diagnostické testy modelu ARCH(1) pro data II/1997 - III/2010 46
Obrázek 6.2 - Skutečné a vyrovnané hodnoty a histogram reziduí pro ARCH(1) a data II/1997 - 1II/2010 46
Obrázek 6.3 - Diagnostické testy modelu ARCH(1) pro data II/1997 – I/2010 47
Obrázek 6.4 - Skutečné a vyrovnané hodnoty a histogram reziduí modelu ARCH(1) pro data II/1997 - I/2010 47
Obrázek 6.5 - Predikce ex post proměnné *DL_ISC_SA* a podmíněného rozptylu na období II-III/2010 48
Obrázek 6.6 - Předpověď ex ante proměnné *DL_ISC_SA* a podmíněného rozptylu na období IV/2010 - I/2011 49
Obrázek 6.7 - AR(1) proces pro proměnnou *DL_ISC_SA* a období II/1997 - III/2010 50
Obrázek 6.8 - Skutečné a vyrovnané hodnoty proměnné *DL_ISC_SA* modelem AR(1), data II/1997 - III/2010 51
Obrázek 6.9 - Diagnostické testy modelu ARCH(1), data II/1997 - III/2010 53
Obrázek 6.10 - Histogram reziduí modelu ARCH(1) a ACF a PACF funkce, data II/1997 - III/2010 53
Obrázek 6.11 - Předpověď podmíněných rozptylů na základě modelu ARCH(1), data II/1997 - I/2010 54
Obrázek 6.12 - Intervalová předpověď pro proměnnou *ISC_SA* na období II-III/2010, model ARCH(1) odhadnutý na datech II/1997 - I/2010 55
Obrázek 6.13 - Předpověď podmíněných rozptylů na základě modelu ARCH(1), data II/1997 - III/2010 56
Obrázek 6.14 - Intervalová předpověď pro proměnnou *ISC_SA* na období IV/2010 a I/2011, model ARCH(1) odhadnutý na datech II/1997 - III/2010 56

SEZNAM TABULEK

Tabulka 2.1 - Vývoj meziročního indexu spotřebitelských cen v ČSR v letech 1939 - 1968.. 16
Tabulka 2.2 - Vývoj míry inflace v ČR v letech 1969 - 2011 17
Tabulka 5.1 - Kritické hodnoty ADF testu pro zvolené hladiny významnosti..... 35
Tabulka 5.2 - Výsledky ADF testů proměnných v úrovňových hodnotách 35
Tabulka 5.3 - Výsledky ADF testů pro první diference logaritmů proměnných..... 36
Tabulka 5.4 - Informační kritéria pro modely VAR(1) - VAR(3) a data II/1997 - III/2010.... 37
Tabulka 5.5 - Grangerovy testy kauzality 38
Tabulka 5.6 - Srovnání skutečnosti s predikcí ex post na období II-III/2010, proměnné HDP a ISC 41
Tabulka 5.7 - Srovnání skutečnosti s predikcí ex post na období II-III/2010, proměnné M2 a PRIBOR1R..... 41
Tabulka 5.8 - Srovnání skutečnosti s predikcí ex post na období II-III/2010, HDP a ISC, VAR(1) model se sezónními proměnnými 41
Tabulka 5.9 - Srovnání skutečnosti s predikcí ex post na období II-III/2010, M2 a PRIBOR1R, VAR(1) model se sezónními proměnnými 42
Tabulka 5.10 - Predikce ex ante na období IV/2010 - I/2011, VAR(1) 42
Tabulka 5.11 - Predikce ex ante na období IV/2010 – I/2011, VAR(1) se sezónními proměnnými 42
Tabulka 6.1 - Parametry modelů ARCH pro *DL_ISC_SA*, odhad za období II/1997 - III/2010 44
Tabulka 6.2 - Parametry a jejich významnosti modelů ARCH pro *DL_ISC_SA* za období II/1997 - III/2010 44
Tabulka 6.3 - Parametry modelů GARCH pro *DL_ISC_SA*, odhad za období II/1997 - III/2010 44
Tabulka 6.4 - Parametry a jejich významnosti modelů GARCH pro *DL_ISC_SA*, odhad za období II/1997 - III/2010 45
Tabulka 6.5 - Odhad modelu ARCH(1) na datech II/1997 - III/2010..... 46
Tabulka 6.6 - Odhad modelu ARCH(1) na datech II/1997 - I/2010 47
Tabulka 6.7 - Predikce ex post pro model ARCH(1) a data II/1997 - I/2010 48
Tabulka 6.8 - Predikce ex ante pro model ARCH(1) a data II/1997 - III/2010 49
Tabulka 6.9 - Parametry a jejich významnosti modelů ARCH pro *DL_ISC_SA* za období II/1997 - III/2010 51
Tabulka 6.10 - Parametry a jejich významnosti modelů GARCH pro *DL_ISC_SA*, odhad za období II/1997 - III/2010 52
Tabulka 6.11 - Odhad modelu ARCH(1) na datech II/1997 - III/2010..... 53
Tabulka 6.12 - Predikce ex post na období II-III/2010 pro model AR(1) a data II/1997 - I/2010 54
Tabulka 6.13 - Predikce ex ante pro model AR(1) a data II/1997 - III/2010 55

1 ÚVOD

S pojmem inflace se setkáváme takřka každý den. Tato veličina je jednou z nejdůležitějších a nejostřeji sledovaných a diskutovaných makroekonomických veličin vůbec. Jedním ze základních cílů České národní banky (dále ČNB) je právě péče o cenovou stabilitu. Inflaci, stejně jako většinu ostatních makroekonomických veličin, je pochopitelně nutno chápat a sledovat v širších souvislostech. Při analýze inflace je nutné, kromě minulého vývoje této veličiny, vzít v úvahu mnoho faktorů, které cenovou hladinu ovlivňují. Mezi takové faktory patří různé transformace české ekonomiky, jako je například vstup České republiky do Evropské unie (EU) či příprava na vstup do Evropské měnové unie (EMU) atd. Pro ekonometrickou analýzu a předpověď inflace je pak stěžejní kvantifikace vztahů mezi inflací a proměnnými, jako jsou výše HDP, nezaměstnanost, peněžní zásoba, úrokové sazby, měnový kurz a mnoho dalších. Sledování těchto vztahů je zásadní pro každou centrální banku při provádění její monetární politiky. V posledních několika desetiletích je věnována pozornost také inflačním očekáváním ekonomických subjektů, zejména při realizaci režimu cílování inflace, který je od roku 1998 vlastní i České republice.

Metodologií, kterými lze ekonometrickou analýzu inflace provádět, existuje řada. Pro svou práci jsem si zvolila dvě techniky ekonometrického modelování - modely vektorové autoregrese, tzv. VAR modely (Vector Autoregression), a modely volatility časových řad neboli modely podmíněné heteroskedasticity. V souvislosti s VAR modely je věnována pozornost také pojmům: Grangerova kauzalita, kointegrace, modely korekce chyby a analýza funkcí odezvy. Z modelů zabývajících se volatilitou časových řad se zaměřím na lineární modely, konkrétně modely ARCH (Autoregressive Conditional Heteroscedasticity) neboli modely autoregresní podmíněné heteroskedasticity a GARCH (Generalized ARCH) neboli zobecněné modely ARCH.

Diplomovou práci tvoří sedm kapitol. V první části práce, ve druhé kapitole, se věnuji základním pojmům a definicím s inflací spojených a způsobům jejího měření. Krátce zde shrnuji také historický vývoj inflace a způsob jejího monitorování ze strany ČNB, zejména pak nedávný přechod České republiky na měnovou politiku v režimu cílování inflace. Dále se zde zmiňuji o některých provedených studiích, které se dané problematiky týkají.

Třetí a čtvrtá kapitola jsou zaměřeny na teoretický základ týkající se obou zmíněných metodologií, které jsem k modelování inflace a její volatility v ČR zvolila, tj. k VAR modelům a modelům volatility časových řad.

V páté a šesté kapitole se zabývám analýzou a predikcí inflace a její volatility v ČR a zhodnocením výsledků na základě testů empirických ekonometrických modelů. S využitím reálných dat jsem zvolila pro obě metodologie modely vhodné pro modelování inflace v ČR a následně provádím samotné odhady parametrů těchto modelů a jejich testy. Výsledky

odhadů jsou interpretovány a na jejich základě také porovnána vhodnost aplikovaných modelů pro analyzování inflace v ČR. Toto porovnání je založeno především na predikci ex post. Posléze uvádím také predikci ex ante na dvě čtvrtletí dopředu. V závěru jsou zhodnoceny výsledky celé práce a shrnuty poznatky, ke kterým jsem dospěla.

Reálná data vybraných makroekonomických časových řad pro českou ekonomiku jsem získala z internetových stránek Českého statistického úřadu (ČSÚ) a ČNB. Data jsem před samotnými odhady empirických ekonometrických modelů vhodně upravila.

2 EKONOMICKÁ TEORIE INFLACE

2.1 Základní pojmy a vztahy

Inflace je jedním z nejdůležitějších makroekonomických agregátů. Tento pojem lze stručně definovat jako **všeobecný** a **opakovaný růst cenové hladiny v ekonomice v čase.** Zásadní charakteristikou inflace je přitom **dlouhodobost** růstu agregátní cenové hladiny. Tato makroekonomická veličina hraje zásadní roli ve fungování všech ekonomických subjektů, při tvorbě fiskální a měnové politiky, při vyhodnocování fungování a vývoje země jako takové, při komparaci zemí mezi sebou. Inflace je obecně považována za negativní jev, který způsobuje neefektivnost v ekonomice, kdy dochází k přerozdělování bohatství a pokřivování cenové informace [14]. Růst cenové hladiny v dané ekonomice může vést ke změně struktury spotřeby a omezení vývozu (dovážené komodity se stávají levnějšími ve srovnání s domácími). Kupní síla peněžní jednotky s inflací klesá, klesá i kupní síla mezd. Vysoká a nestálá inflace ekonomice jako celku škodí. Ne pro všechny subjekty však inflace představuje ztrátu či riziko. Při inflaci dochází k poklesu hodnoty půjček a vkladů, což představuje nevýhodu pro věřitele, ale naopak výhodu pro dlužníky. Opakem k pojmu inflace je tzv. deflace, která představuje upevnění měny, podporu vývozu a naopak omezení dovozu a zlepšení platební bilance.

Existuje mnoho způsobů klasifikace inflace, zde uvedu jen některé z nich [14].

- Dle očekávání:
    - anticipovaná (očekávaná);
    - neanticipovaná (neočekávaná).
- Dle vlivu na relativní ceny:
    - vyrovnaná – relativní ceny zboží se nemění, neboť ceny rostou stejným tempem;
    - nevyrovnaná – ceny zboží rostou různým tempem, a tak se mění relativní ceny zboží, a to bez změny spotřebitelských preferencí.
- Dle stupně inflace:
    - mírná – jednociferný (procentní) roční růst míry inflace, kdy roste cenová hladina pomalejším tempem než reálný produkt. Taková inflace nepředstavuje pro ekonomiku vážný problém;
    - pádivá – dvou až trojciferný (procentní) roční růst míry inflace, kdy cenová hladina roste rychlejším tempem než reálný produkt. Tento typ inflace již působí ekonomice značné problémy, ale peníze ještě plní své funkce;

- hyperinflace – více než trojciferný (procentní) roční růst míry inflace, kdy peníze ztrácejí kupní sílu a své funkce již neplní, což vede k rozpadu peněžní soustavy.

- Dle příčiny vzniku:
  - poptávková – tento typ inflace je vyvolán nadměrným růstem agregátní poptávky. Růst agregátní poptávky sníží nezaměstnanost pod přirozenou míru nezaměstnanosti, což způsobí růst nominálních mezd a posléze také cen [16];
  - nabídková – tato inflace je vyvolána tzv. nepříznivými nákladovými (nabídkovými) šoky, jako je například růst ceny ropy.

Dalším typem inflace je tzv. setrvačná inflace, která je vyvolána inflačními očekáváními, kterým je věnována pozornost zejména v posledních několika desetiletích.

Poslední tři typy inflace jsou obsaženy v tzv. **rozšířené Phillipsově**[1] **křivce** - vyjadřující vztah mezi nezaměstnaností a cenovou inflací [16; str. 316]

$$\pi = \pi_e + [\varepsilon(u^* - u) - \eta] + \upsilon, \tag{2.1}$$

kde

- π je celková inflace;
- π_e…….. očekávaná (resp. setrvačná) inflace, (jedná se přitom o tzv. adaptivní očekávání, kdy se očekávání inflace zakládají na dřívějším vývoji inflace);
- ε …..… koeficient, který představuje citlivost nominálních mezd na odchylky nezaměstnanosti od její přirozené míry;
- u^* …..… přirozená míra nezaměstnanosti;
- u …….. míra nezaměstnanosti;
- η …….. tempo růstu produktivity práce;
- $[\varepsilon(u^* - u) - \eta]$ …….. poptávková inflace;
- υ …….. nákladová inflace.

Původní Phillipsova křivka přitom vyjadřovala vztah mezi nezaměstnaností a růstem nominálních mezd neboli mzdovou inflací. Rovnici později upravili Samuelson a Solow[2] tak, aby odrážela vztah mezi nezaměstnaností a cenovou inflací. Vzorec vypadal následovně [16; str. 300]

$$\pi = g - \eta, \tag{2.2}$$

[1] Novozélandský ekonom Alban William Philips (1914 – 1975).
[2] Americký ekonom a držitel Nobelovy ceny za ekonomii z roku 1970 Paul Antony Samuelson (1915 – 2009) a americký ekonom Robert Merton Solow (narozen 1924).

kde

- π je cenová inflace;
- g …….. mzdová inflace (růst nominálních mezd);
- η …….. růst produktivity práce.

Phillipsova křivka naznačovala možnost volby mezi inflací a nezaměstnaností. Stačilo by tedy, aby stát manipuloval s agregátní poptávkou a mohl by dosáhnout žádoucí kombinace obou veličin. Po roce 1969 se však v USA začala zvyšovat inflace i nezaměstnanost současně (tzv. stagflace), což myšlence "trade off" mezi inflací a nezaměstnaností odporovalo [16].

Dalším ze základních vztahů, týkajících se inflace, se zabýval Fischer[3] v po něm pojmenované tzv. Fischerově rovnici [12; str.442]

$$r^e \equiv i - \pi^e, \tag{2.3}$$

kde

- r^e je (očekávaná) reálná úroková míra;
- i …….. nominální úroková míra;
- π^e …….. očekávaná míra inflace.

Vztah mezi inflací a peněžním růstem pak zkoumá tzv. **kvantitativní teorie peněz** (jedním z prvních autorů byl britský filosof Hume[4]), která dává do vztahu nominální produkt $P.Y$, peněžní zásobu M a rychlost oběhu peněz V [12; str. 480]

$$MV = PY. \tag{2.4}$$

Dle zastánců kvantitativní teorie je rychlost obratu peněz poměrně stabilní veličina, měnící se v dlouhém období jen velmi pomalu, a ekonomika dlouhodobě pracuje na potenciálním produktu. To znamená, že změny v peněžní zásobě M mají za následek proporcionální změny v cenové hladině P (prostřednictvím tzv. transmisního mechanismu, viz např. [16]). Tato teorie zaznamenala od dob svého vzniku mnoho kritik.

Posledním pojmem, o kterém se v této podkapitole zmíním, je pojem tzv. **čisté inflace**. Některé služby a zboží jsou státem regulovány[5]. Čistá inflace je měřena na neúplném spotřebním koši bez komodit s administrativními cenami, tedy z komodit z neregulované části spotřebního koše.

[3] Americký ekonom Irving Fischer (1967 – 1947).
[4] Britský filosof David Hume (1711 – 1776).
[5] Takových položek je ve spotřebním koši celkem 117, například elektřina či plyn, dálniční známka, poštovní známka ad.

2.2 Způsoby měření inflace

V praxi je měření inflace realizováno zpravidla pomocí indexu spotřebitelských cen, indexu cen výrobců (obdoba indexu spotřebitelských cen vycházející ovšem z vlastního spotřebního koše, který zahrnuje ceny potravin, zpracovatelského a těžebního průmyslu) a deflátoru hrubého domácího produktu (poměr HDP v běžných cenách a HDP ve stálých cenách). V ČR je nejčastější konstrukce indexů spotřebitelských cen, budu se proto podrobněji věnovat právě jim.

Indexy spotřebitelských cen (CPI, Consumer Price Index), nazývané též indexy životních nákladů, jsou jedním z nejdůležitějších indikátorů cenového vývoje a jsou, jak již bylo zmíněno, užívány k měření inflace v České republice. Výpočty cenových indexů jsou konstruovány na základě spotřebního koše reprezentativních výrobků (700 položek) dle klasifikace CZ-COICOP (Classification of Individual Consumption by Purpose), která třídí výrobky a služby do 12 hlavních oddílů. Oddíly spotřebního koše, počty cenových reprezentantů dle klasifikace CZ-COICOP a užívané váhy pro výpočet indexu spotřebitelských cen jsou uvedeny v přílohách č. 1 a 2 [11].

K výpočtům indexu spotřebitelských cen se užívá především Laspeyresova indexu, který užívá jako váhy množství zboží ze základního období. Z toho vyplývá určitá výpočetní výhoda oproti Paascheho indexu (užívajícího jako váhy množství zboží z běžného období), neboť váhy jsou v daném období stálé[6]. Výpočet indexu spotřebitelských cen se stálými vahami podle Laspeyresova vzorce [11]

$$I = \frac{\sum_{i=1}^{n} \frac{p_{1,i}}{p_{0,i}} \cdot p_{0,i} q_{0,i}}{\sum_{i=1}^{n} p_{0,i} q_{0,i}} \cdot 100, \quad i = 1,2,...,n, \tag{2.5}$$

kde

- I je bazický index sledovaného období vzhledem k základnímu období;
- $p_{1,i}$, kde $i = 1, \ldots, n$ …… cena i-té komodity ve sledovaném, běžném období;
- $p_{0,i}$, kde $i = 1, \ldots, n$ …… cena i-té komodity v základním období;
- $q_{0,i}$, kde $i = 1, \ldots, n$ …… množství i-té komodity v základním období;
- $p_{0,i} q_{0,i}$, kde $i = 1, \ldots, n$ …… výdaje domácností na i-tou komoditu v základním období (stálá váha).

Za základní období je zvolen prosinec roku 2009 (ke změně došlo v roce 2010, předtím byl základem prosinec 2005). Ceny se zjišťují měsíčně a to dvěma způsoby [11]:

[6] Nevýhodou Laspeyresova indexu je fakt, že neodráží spotřebitelskou substituci způsobenou změnami v cenách a zkresluje tedy růst cen směrem nahoru [15].

- *místním cenovým zjišťováním* pracovníky terénního zjišťování ČSÚ (celkem 47 pracovníků);
- sledováním cen - tzv. *centrálně sledované ceny* - pracovníky oddělení statistiky spotřebitelských cen ČSÚ Praha a OSZ Hradec Králové a pracovníky oddělení terénních zjišťování Praha.

S indexy spotřebitelských cen pak souvisí ukazatel nazývaný míra inflace. Míra inflace je úhrnná změna cenové hladiny, vyjádřená relativně. V České republice je každý měsíc konstruována (na základě zjištěných bazických indexů spotřebitelských cen) [22]:

- *měsíční míra inflace* – procentní změna cenové hladiny (přírůstek indexu spotřebitelských cen) sledovaného měsíce oproti měsíci bezprostředně předcházejícímu;
- *meziroční míra inflace* – procentní změna cenové hladiny (přírůstek indexu spotřebitelských cen) sledovaného měsíce oproti stejnému měsíci předchozího roku;
- *průměrná roční míra inflace* – podíl aritmetického průměru (resp. součtu bazických indexů) posledních 12 měsíců a aritmetického průměru (resp. součtu bazických indexů) předcházejících 12 měsíců;
- *míra inflace ve formě bazických indexů* – přírůstek indexu spotřebitelských cen sledovaného měsíce vzhledem k základnímu období (např. rok 2005 = 100).

Dále existují tzv. **harmonizované indexy spotřebitelských cen** (HICP). Jsou to indexy, které vznikly pro účely srovnatelnosti indexů spotřebitelských cen mezi členskými zeměmi Evropské unie (EU). Rozdíly mezi HICP a indexy spotřebitelských cen ČR jsou ve struktuře spotřebního koše, a tudíž i ve vahách. Váhy pro výpočet HICP jsou obměňovány v prosinci každého roku.

2.3 ČNB a režim cílování inflace

Vztah ČNB k inflaci je zásadní. Jak již bylo řečeno v úvodu, hlavním úkolem a cílem ČNB je péče o cenovou stabilitu české ekonomiky. Paralelně s dosahováním tohoto cíle však musí ČNB podporovat udržitelný hospodářský růst, tj. volit úroveň úrokových sazeb (hlavní nástroj ČNB) udržující inflaci na nízké a stabilní úrovni a zároveň zabezpečující i stabilní tempo růstu ekonomiky. Při sledování a plnění svých cílů má ČNB vysokou míru nezávislosti při rozhodování, která ji chrání zejména před případnými politickými tlaky. Dalším úkolem ČNB je její transparentnost směrem k veřejnosti. Prostřednictvím pravidelných zpráv, a dalšími cestami, informuje veřejnost o inflačních cílech, inflačních prognózách ad. Dále se ČNB zabývá zjišťováním inflačních očekávání domácností, nefinančních korporací a finančních trhů. Režim Českou národní bankou vyhlašovaného inflačního cíle je pro veřejnost transparentní a srozumitelná měnová politika, která ve veřejnosti zakotvuje již zmíněná inflační očekávání [8].

Udržování nízké úrovně inflace je hlavním cílem převážné většiny centrálních bank vyspělých zemí světa (včetně Evropské centrální banky). Nízká úroveň inflace je pak také

jedním ze základních kritérií, jedná se o tzv. maastrichtská konvergenční kritéria, pro vstup země do eurozóny a pro přijetí společně měny, eura [8].

ČNB provádí měnovou politiku v režimu **cílování inflace** od ledna roku 1998 (mezi další základní měnově politické režimy patří režim s implicitní nominální kotvou, cílování peněžní zásoby a cílování měnového kurzu). Od tohoto okamžiku musí ČNB plnit závazek udržovat inflaci na úrovni vyhlášeného inflačního cíle (toho je dosahováno prostřednictvím řízení krátkodobé úrokové sazby centrální banky). Základním nástrojem ČNB je tzv. **dvoutýdenní repo sazba**. Dříve používaným nástrojem měnové politiky byly povinné minimální rezervy. Lombardní a diskontní sazbu pak ČNB mění automaticky s repo sazbou. Dosahování cílů ČNB probíhá přes tzv. transmisní mechanismus měnové politiky. Transmisní mechanismus je řetězec ekonomických vazeb, kdy na začátku stojí změna v nastavení měnově politických nástrojů, která vede ke změnám na tzv. zprostředkujících trzích. Tyto změny následně vyvolají změny na dalších zprostředkujících trzích a postupně se tak efekt přenese až na cílové trhy, které se centrální banka rozhodla ovlivnit [9].

Základním rysem cílování inflace je především střednědobost inflačního cíle. Jsou tedy akceptovány krátkodobé výkyvy inflačního cíle mimo oscilační pásmo v důsledku exogenních šoků (hovoří se o tzv. výjimce ze závazku plnit inflační cíl [6]). ČNB musí sledovat prognózy inflace a dalších ukazatelů a vyhodnocovat rizika jejich nenaplnění. Vychází přitom z dat Českého statistického úřadu, tedy instituce nezávislé na ČNB, což zvyšuje důvěryhodnost inflačního cílování [6].

Mezi problémy režimu cílování inflace patří fakt, že inflace je tzv. konečný cíl měnové politiky, kdy mezi použitím měnově politických nástrojů a jejich dopadem na inflaci existuje zpoždění 12 až 18 měsíců (pro rozhodování ČNB je pak právě v takto vzdáleném tzv. horizontu měnové politiky prognóza inflace nejsledovanější, neboť právě ta ovlivňuje současné nastavení úrokových sazeb) [8]. Dalším rizikem jsou již zmíněné exogenní šoky. Pokud by například v rámci dosahování inflačního cíle ČNB reagovala na nákladové šoky[7], které se čas od času vyskytují v každé ekonomice, měnovými restrikcemi, mohla by stáhnout ekonomiku do recese (měnovou restrikcí totiž vyvolá další pokles domácího produktu a zaměstnanosti) [16]. Nákladovým šokem mohou být například úpravy nepřímých daní či změny regulovaných cen, jejichž rozsah je jen obtížně předvídatelný. ČNB v případě exogenního šoku využije výjimky ze závazku plnit inflační cíl, jak již bylo zmíněno výše.

Ze začátku realizace režimu cílování inflace v rámci ČR používala ČNB jako ukazatel tzv. čistou inflaci (viz. podkapitola 2.1). V dubnu roku 2001 však došlo k přechodu z čisté inflace na cílování tzv. **celkové inflace** (přírůstku indexu spotřebitelských cen). Od ledna 2010 je platný inflační cíl meziročního přírůstku spotřebitelských cen (v celkové inflaci) ve výši 2 %, přičemž ČNB se snaží udržovat skutečnou inflaci v oscilačním pásmu jeden procentní bod od vytyčeného cíle na obě strany (předtím platil cíl 3 % v celkové inflaci, platný od ledna 2006 do prosince 2009, opět s tolerančním pásmem jeden procentní bod na

[7] Situace, kdy dochází k poklesu domácího produktu a tlaku na růst inflace.

obě strany). Tabulky a grafy s konkrétními inflačními cíly od okamžiku přechodu ČR na režim cílování inflace až po současnost obsahují přílohy č. 3, 4 a 5 [6].

Existují teorie podporující myšlenku nulové inflace jako cíl centrální banky. Takto vytyčený cíl by byl zajisté lákavým inflačním cílem (při dlouhodobém udržování nulové inflace by se cenová hladina neměnila). Proti této myšlence ovšem hovoří fakt, že pokud by se měla centrální banka zaměřit na cíl nulové inflace, zákonitě by poklesla její zodpovědnost za stabilní tempo růstu ekonomiky. „*My osobně se domníváme, že centrální banky by si vedle udržování nízké inflace měly ponechat také jistou část zodpovědnosti za stabilizování hospodářského cyklu. Silný důraz na to, aby centrální banka držela míru inflace nízkou, například v rozmezí 0 až 4 procent, je naprosto dostačující.*“ [12; str. 475]. Snaha docílit dlouhodobě nulové inflace je proto příliš drastický cíl, který může mít mnoho nepříjemných vedlejších účinků.

2.4 Historický vývoj inflace v ČR

Vývoj inflace je zachycen v tabulkách č. 2.1 a 2.2, které obsahují [24]:

- *vývoj meziročního indexu spotřebitelských cen v letech 1939 – 1968* (tabulka č. 2.1 níže), vztahujícího se k území celého tehdejšího Československa. (Do roku 1951 byly indexy počítány pouze za domácnosti dělníků v Praze a do roku 1955 bylo do indexu ze služeb zahrnuto pouze nájemné z bytů. Data za rok 1952 nebyla vůbec dohledána, a tak je výpočet indexů za rok 1953 vztažen k hodnotám z roku 1951).

Tabulka 2.1 - Vývoj meziročního indexu spotřebitelských cen v ČSR v letech 1939 - 1968

ROK	INDEX	ROK	INDEX
1939	109,7	1954	92,1
1940	123,2	1955	96,8
1941	116,4	1956	97,3
1942	108,5	1957	97,9
1943	98,9	1958	100,1
1944	100,6	1959	97,5
1945	105,5	1960	98,2
1946	181,9	1961	99,4
1947	95,6	1962	101
1948	98,9	1963	100,6
1949	111,8	1964	99,9
1950	101	1965	99,5
1951	104,8	1966	100,5
1952	N/A	1967	102
1953	33,4	1968	101,3

Zdroj: **http://www.estav.cz/finance/inflace39.html**
Původní zdroj: ČSÚ

- *vývoj míry inflace v letech 1969 – 2011* (tabulka č. 2.2 níže), kde je míra inflace měřená přírůstkem průměrného ročního indexu spotřebitelských cen pro území ČR. Pro rok 2011

obsahuje tabulka odhad míry inflace dle ČMKOS (Českomoravská konfederace odborových svazů) a dle MF (Ministerstvo financí ČR).

Tabulka 2.2 - Vývoj míry inflace v ČR v letech 1969 - 2011

ROK	MÍRA INFLACE (v %)	ROK	MÍRA INFLACE (v %)
1969	4,0	1991	56,6
1970	2,2	1992	11,1
1971	-0,4	1993	20,8
1972	-0,4	1994	10
1973	0,3	1995	9,1
1974	0,4	1996	8,8
1975	0,6	1997	8,5
1976	0,9	1998	10,7
1977	1,3	1999	2,1
1978	1,5	2000	3,9
1979	3,7	2001	4,7
1980	2,9	2002	1,8
1981	0,8	2003	0,1
1982	5,0	2004	2,8
1983	1,0	2005	1,9
1984	1,0	2006	2,5
1985	2,3	2007	2,8
1986	0,5	2008	6,3
1987	0,1	2009	1,0
1988	0,2	2010	1,5
1989	1,4	2011	2,0 (odhad ČMKOS)
1990	9,7	2011	2,2 (odhad MF)

Zdroj: **http://www.estav.cz/finance/inflace.html**
Původní zdroj: ČSÚ

V poměrně nedávné historii zaznamenala česká ekonomika hned několik přelomů, které se promítly do jejího vývoje. Roku 1989 se vydala na složitou cestu přechodu z centrálně plánované ekonomiky na ekonomiku tržní. Tato přeměna je označována jako tzv. proces transformace české ekonomiky. Nejvyšší míra inflace byla zaznamenána roku 1991 (pádivá inflace), kdy se projevila skoková liberalizace většiny centrálně kontrolovaných cen v souvislosti s realizací ekonomické reformy. Dalším zlomem, který se zapsal do naší historie výkyvem v mnoha makroekonomických veličinách, bylo rozdělení Československa na dva samostatné státy v roce 1993 (došlo ke vzniku dvou centrálních bank namísto jedné a k rozdělení měny). V tomto roce byla ovlivněna inflace zejména zavedením **daně z přidané hodnoty** v rámci daňové reformy (1. ledna 1993). V tabulce č. 2.2 je patrný také razantní pokles míry inflace mezi roky 1998 a 1999 vyvolaný výše popisovaným přechodem na režim cílování inflace. V tomto období došlo k mimořádnému poklesu inflace zejména z důvodu poklesu cen potravin a přibrždění deregulace státem korigovaných cen [19]. V roce 2001 došlo k růstu míry inflace a to především jako reakce na deregulaci cen nájemného, elektřiny a plynu, dopravy, pošt a telekomunikací a na výrazný nárůst cen potravin [19]. Dalším důležitým okamžikem, a začátkem mnoha změn ve vývoji české ekonomiky, byl vstup ČR do

EU (od 1. května 2004), kdy došlo k mírnému nárůstu míry inflace. Nárůst pak nastal také v roce 2008, kdy se do české ekonomiky promítla světová finanční krize.

2.5 Empirické studie dynamiky inflace

Na téma zkoumání a modelování inflace a její dynamiky proběhlo v historii mnoho studií. Já se v této podkapitole zmíním pouze o několika takových.

Na počátku 80. let vystoupil Engle [13] s originální koncepcí **modelování volatility** časových řad, kdy navrhl koncept ARCH (Autoregressive Conditional Heteroscedasticity). Tento model, dnes běžně využívaný k modelování finančních časových řad, demonstroval na modelování inflace UK a to konkrétně pomocí modelu ARCH(4), který omezil předpokladem lineárně klesajících vah čtverců minulých reziduí a model tak v podstatě redukoval na ARCH(1)[8]. Odhad byl proveden metodou maximální věrohodnosti. Ve studii autor ilustroval použitelnost ARCH modelů pro získání lepších odhadů a realističtějších předpovědí ve srovnání s metodou nejmenších čtverců (dále MNČ). Tato metodologie vychází z předpokladu, že převážná většina finančních a ekonomických časových řad vykazuje podmíněnou heteroskedasticitu, tj. v čase proměnlivou volatilitu. Postupem času byla koncepce dále rozvíjena a byly navrženy další modely volatility (například model GARCH(1,1), který navrhl v roce 1986 Bollerslev).

Zajímavou studií se zabýval Melecký v roce 2001 [21], kde porovnával vhodnost několika tradičních modelů inflace pro českou ekonomiku. Zde došel autor, při srovnávání modifikovaného *P**-modelu pro otevřenou ekonomiku s monetaristickým modelem inflace, modelem s redukovaným tvarem Phillipsovy křivky a portfoliovým modelem inflace, k závěru, že nejlepší vypovídací schopnost s ohledem na rozsah modelu má právě modifikovaný *P**-model, který tak autor doporučil jako vhodný instrument predikce dynamiky inflace v krátkodobém horizontu. Ve studii dále došel k závěru, že se nepotvrdil předpoklad nelineární závislosti inflace na mezeře výstupu, který postuluje Phillipsova křivka, a lze tedy pro českou ekonomiku předpokládat lineární závislost, kterou v sobě zmíněný *P**-model zahrnuje.

Poslední studií, kterou v této práci uvedu, je studie autorů Arlta a Radkovského z roku 1999 [4] pojednávající o možnostech využití modelování a konstrukce předpovědí volatility časových řad při tvorbě měnové politiky centrální banky[9]. Zde se autoři snaží poukázat na význam analýzy a modelování volatility časových řad na makroekonomické úrovni[10]. V závěru studie poukazují na problematiku volby vhodného modelu volatility a na obecně známý problém nedostatečné délky měsíčních a čtvrtletních časových řad makroekonomických veličin v české ekonomice.

[8] Redukoval tak počet odhadovaných parametrů na dva parametry v ARCH(1) namísto pěti v ARCH(4).
[9] Vychází se z transmisního mechanismu.
[10] Většina předchozích studií na téma uvedené metodologie je zaměřena spíše na mikroekonomickou úroveň.

3 EKONOMETRICKÉ MODELY VAR

VAR modely, neboli modely vektorové autoregrese, spadají do skupiny vícerozměrných modelů časových řad a lze je chápat jako vícerozměrné zobecnění modelů jednorozměrných časových řad AR [2]. Tyto dynamické modely, na rozdíl od modelů simultánně závislých rovnic, nevyžadují rozlišovat endogenní a exogenní resp. predeterminované proměnné, tj. všechny proměnné obsažené v modelech VAR jsou endogenní (exogenní proměnné se vyskytují pouze ve formě trendové proměnné či sezónních "dummy" (resp. umělých, binárních) proměnných). Tyto modely vycházejí z předpokladu, že mezi endogenními proměnnými VAR modelu existují určité vztahy, že tyto proměnné často vykazují společný trend a jsou sériově zkorelované. V modelu VAR se vyskytuje tolik rovnic, kolik obsahuje endogenních proměnných, přičemž délka zpoždění je pro všechny proměnné stejná. Každá endogenní proměnná je pak funkcí svých zpožděných hodnot, zpožděných hodnot ostatních endogenních proměnných modelu a bílého šumu. Základním požadavkem pro práci s VAR modely je stacionarita zahrnutých proměnných. Modely VAR se využívají zejména pro prognózování, k testování Grangerovy kauzality a při analýze dopadu hospodářské politiky na základě funkcí odezvy ad. [18]. Výhoda VAR modelů spočívá především v jednoduchosti jejich odhadu (při splnění Gauss-Markovových požadavků (např. [17]) aplikací klasické MNČ na každou rovnici modelu zvlášť), specifikace a tvorby předpovědí.

3.1 Vektorové autoregresní modely a jejich odhad

Model VAR(1), kde délka zpoždění je $p = 1$ a který obsahuje dvě endogenní proměnné X_t a Y_t, lze zapsat následovně, v tzv. **standardním tvaru** modelu [18, str. 256]

$$\begin{aligned} Y_t &= \omega_1 + \beta_{11} Y_{t-1} + \alpha_{11} X_{t-1} + v_{t1}, \quad t = 1, 2, ..., T, \\ X_t &= \omega_2 + \beta_{21} Y_{t-1} + \alpha_{21} X_{t-1} + v_{t2}, \quad t = 1, 2, ..., T, \end{aligned} \tag{3.1}$$

kde

- X_{t-1} a Y_{t-1}, kde $t = 1, 2, ..., T$ jsou zpožděné hodnoty endogenních proměnných;
- v_{t1} a v_{t2}, kde $t = 1, 2, ..., T$ …… náhodné složky mající charakter procesu bílého šumu.

Definice [2, str. 26]: Je-li stochastický proces $\{a_t\}$ řadou nekorelovaných náhodných veličin jednoho pravděpodobnostního rozdělení s nulovou střední hodnotou $E(a_t) = 0$, konstantním rozptylem $D(a_t) = \sigma_a^2$ a autokovarianční funkcí $\gamma_k = C(a_t, a_{t-k}) = 0$, pro všechna $k \neq 0$, potom se označuje jako **proces bílého šumu**.

V maticové formě lze pak model (3.1) zapsat [18, str. 257]

$$\mathbf{z}_t = \boldsymbol{\omega} + \boldsymbol{\Pi}\mathbf{z}_{t-1} + \mathbf{v}_t, \quad t = 1, 2, ..., T, \tag{3.2}$$

kde

$$\mathbf{z}_t = \begin{bmatrix} Y_t \\ X_t \end{bmatrix}, \quad \mathbf{z}_{t-1} = \begin{bmatrix} Y_{t-1} \\ X_{t-1} \end{bmatrix}, \quad \boldsymbol{\omega} = \begin{bmatrix} \omega_1 \\ \omega_2 \end{bmatrix}, \quad \boldsymbol{\Pi} = \begin{bmatrix} \pi_{11} & \pi_{12} \\ \pi_{21} & \pi_{22} \end{bmatrix}, \quad \mathbf{v}_t = \begin{bmatrix} v_{t1} \\ v_{t2} \end{bmatrix}.$$

Maticová forma standardního tvaru neomezeného *m*-rozměrného VAR(*p*) modelu lze obecně vyjádřit [18, str. 257] jako

$$\mathbf{z}_t = \boldsymbol{\omega} + \boldsymbol{\Pi}_1\mathbf{z}_{t-1} + \boldsymbol{\Pi}_2\mathbf{z}_{t-2} + ... + \boldsymbol{\Pi}_p\mathbf{z}_{t-p} + \mathbf{v}_t, \quad t = 1, 2, ..., T, \tag{3.3}$$

kde

- $\mathbf{z}_t$ je $m \times 1$ rozměrný vektor napozorovaných hodnot endogenních proměnných;
- $\boldsymbol{\omega}$ …….. $m \times 1$ rozměrný vektor obsahující úrovňové konstanty;
- $\boldsymbol{\Pi}_i$, kde i = 1, 2, …, p …….. $m \times m$ matice parametrů endogenních proměnných, zpožděných o i období;
- m ……..počet endogenních proměnných VAR modelu (tj. počet rovnic modelu);
- p ……..maximální délka zpoždění;
- $\mathbf{v}_t$ …….. $m \times 1$ rozměrný vektor náhodných složek.

Pro náhodné složky obsažené ve vektoru $\mathbf{v}_t$ pak platí, že jsou normálně rozdělené s nulovou střední hodnotou $E(\mathbf{v}_t) = \mathbf{0}$ a kovarianční matice, pro kterou platí $E(\mathbf{v}_t\mathbf{v}_s) = \boldsymbol{\Sigma}$ pro $t = s$ a $E(\mathbf{v}_t\mathbf{v}_s) = \mathbf{0}$ pro $t \neq s$, je pozitivně definitní matice. Každá z rovnic modelu (3.3), stejně jako v modelu (3.2), obsahuje stejné vysvětlující proměnné, takže každá endogenní proměnná je lineární kombinací shodně časově zpožděných endogenních proměnných. Rovnice v modelu (3.3) jsou soustavou **zdánlivě nezávislých rovnic**. Soustavy rovnic (3.2) a (3.3) představují tzv. redukovaný tvar modelu VAR[11]. VAR model (3.3) obsahuje [$m(1+mp)$] parametrů [17].

Problémy spojené s VAR modely [4], [17]:

- často vzniká problém s určením řádu modelu *p*;
- s rostoucí délkou maximálního zpoždění *p* rychle roste počet odhadovaných parametrů VAR modelu a s tím klesá počet stupňů volnosti. To může činit problémy zejména v případě, máme-li k dispozici krátké časové řady;

[11] Redukovaný tvar VAR modelu se vyznačuje tím, že se v každé rovnici vyskytuje v nezpožděném tvaru pouze vysvětlovaná proměnná. Regresory jsou pouze ve formě zpožděných hodnot endogenních proměnných modelu [17].

- požadavek stacionarity[12] proměnných často vyžaduje jejich transformaci, která však může vést ke ztrátě informace o vztazích mezi proměnnými;
- existuje-li mezi endogenními proměnnými kointegrační vztah[13], který je I(0), stacionarizací proměnných diferencováním vzniká v modelu VAR tzv. specifikační chyba (vynecháním kointegrační kombinace z modelu)[14]. V této souvislosti se proto využívá modelů korekce chyby (MKCH) [18].

Postup konstrukce a odhadu VAR modelu lze shrnout do několika kroků [17], [18]:

- *volba proměnných modelu* – čím více proměnných v modelu, tím více rovnic a parametrů, které je třeba odhadnout. Při volbě proměnných se uplatňuje tzv. Grangerova kauzalita, popsaná v podkapitole 3.2 níže;
- *stacionarizace časových řad vhodnou transformací dat*– stacionaritu[15] časové řady zjišťujeme aplikací tzv. testů jednotkových kořenů[16] (např. Dickey-Fullerův test (DF test), rozšířený Dickey-Fullerův test (ADF) test). Není-li některá časová řada stacionární, stacionarizuje se přechodem na první či vyšší diference;
- *volba maximální délky zpoždění modelu*:
    - pro volbu optimální délky zpoždění je možné použít tzv. modifikovaná informační kritéria, např. Akaikeho informační kritérium (AIC), Hannan-Quinnovo informační kritérium (HQ), Schwartzovo informační kritérium (SC) ad. Volíme variantu, která hodnotu zvoleného informačního kritéria minimalizuje;
    - počet zpoždění modelu se často volí tak, aby vymizela autokorelace náhodných složek ve všech rovnicích modelu (v rámci tohoto postupu by se ovšem mohlo stát, že do modelu zahrneme příliš mnoho zpoždění vzhledem k počtu pozorování);
    - v praxi je někdy vhodné předem zvolit (resp. omezit) maximální délku zpoždění, bez ohledu na informační kritéria (pro ČR se zpravidla užívá pro kvartální data maximální délka dvě až tři zpoždění);
- *ortogonalizace náhodných složek* – jde o transformaci vektoru náhodných složek resp. reziduí tak, aby byla jejich kovarianční matice skalární. Uvažujeme-li model VAR (*p*), viz (3.3), pak pro tento model musí platit sériová nezávislost libovolných vektorů $\mathbf{v}_t$ a $\mathbf{v}_s$ (kdy $t \neq s$) v každé rovnici modelu. Předpoklad ortogonality náhodných složek je podstatný především pro konzistenci odhadu parametrů VAR modelu získaných na základě MNČ, při prognózování a konstrukci funkcí odezvy;

[12] Symbolem I(0) se označují stacionární časové řady ve svých úrovňových hodnotách, nestacionární časové řady pak symbolem I(*k*), kde *k* je stupeň integrace. Časová řada typu I(1) je stacionární po prvních diferencích.
[13] Pojem kointegrace je podrobněji vysvětlen v podkapitole 3.3.
[14] Většina ekonomických časových řad je přitom stacionární až po transformaci pomocí prvních diferencí, převážně se tedy jedná o časové řady typu I(1).
[15] Vyžaduje se přitom alespoň slabá stacionarita. Definici pojmu stacionarita uvádí např. [2].
[16] Postup při testování jednotkových kořenů je uveden např. v [17].

- *volba odhadové techniky* - v modelu VAR se nevyskytují exogenní proměnné, kromě trendů nebo umělých nula jednotkových proměnných. Odhad modelu (3.3) lze získat přímou aplikací MNČ na jednotlivé rovnice modelu (získané odhady jsou konzistentní a asymptoticky vydatné)[17];
- *diagnostická kontrola modelu* - po odhadu parametrů modelu je nutné zkoumat vhodnost tohoto modelu. Zkoumá se autokorelace nesystematické složky a dále její normalita a heteroskedasticita.

V souvislosti se stacionaritou a VAR modely je vhodné zmínit také pojem stabilita. VAR model je stabilní, jestliže dynamický efekt působení exogenního šoku na libovolnou endogenní proměnnou modelu trvá poměrně krátkou dobu. Trvá-li efekt šoku dlouho, pak je VAR model nestabilní. Jestliže je VAR model stabilní a zároveň má model v čase konstantní alespoň první a druhé momenty, pak je tento model slabě stacionární (neboli stacionární v kovariancích) [17]. Stabilita je postačující, ne však nutnou, podmínkou stacionarity (stacionární mohou být i nestabilní modely). Ve VAR(1) modelu (3.2), pro *m* endogenních proměnných (a tedy *m* rovnic), se provádí určování stability na základě tzv. charakteristických kořenů matice **Π**. Stabilita je zajištěna v případě, že jsou všechny charakteristické kořeny matice **Π** menší než jedna[18] [17].

3.2 Grangerova kauzalita a analýza funkcí odezvy

S VAR modely úzce souvisí pojem Grangerova kauzalita[19]. Jedná se o zkoumání vzájemných vazeb mezi proměnnými, tj. zda změny jedné proměnné předcházejí změně jiné proměnné[20]. V podstatě zkoumáme, zda existuje korelovanost mezi současnou hodnotou jedné proměnné a minulými hodnotami jiných proměnných. „*Jednou z možností aplikace VAR modelů je jejich využití k testování směru kauzální závislosti. V ekonometrii je chápána kauzalita jako schopnost určité proměnné predikovat jinou proměnnou.*“ [18, str. 264]. V případě, že se prokáže ve smyslu Grangerovy kauzality vliv proměnné X_t na proměnnou Y_t, znamená to, že zpožděné hodnoty proměnné X_t, jakožto regresory, zvyšují kvalitu předpovědi proměnné Y_t. „*Jestliže proces* $\{X_t\}$ *může být předpovídán přesněji díky informacím z procesu* $\{Z_t\}$ *zařazeným k ostatním informacím, potom* $\{Z_t\}$ *kauzálně působí na* $\{X_t\}$.“ [2, str. 175].

Postup při **testování Grangerovy kauzality** pro dvě stacionární proměnné X_t a Y_t je následující [18]:

- odhadneme dvourovnicový model VAR(*p*) bez úrovňových konstant [18, str. 264]

[17] Za splnění určitých předpokladů lze k odhadu VAR modelu použít také metodu maximální věrohodnosti.
[18] Při existenci jednoho jednotkového kořene časovou řadu stabilizujeme její transformací na první diference, které již většinou jsou stacionární [17].
[19] Pojem Grangerova kauzalita byl zaveden Grangerem v roce 1969.
[20] V případě, že se na základě zkoumání Grangerovy kauzality neprokáže závislost mezi některými proměnnými, jedna z proměnných je do VAR modelu zařazena zbytečně a je tedy vhodné ji z modelu vynechat.

$$Y_t = \sum_{i=1}^{p} \alpha_i Y_{t-i} + \sum_{i=1}^{p} \beta_i X_{t-i} + u_{t1}, \quad t = 1, 2, ..., T, \tag{3.4}$$

$$X_t = \sum_{i=1}^{p} \gamma_i Y_{t-i} + \sum_{i=1}^{p} \delta_i X_{t-i} + u_{t2}, \quad t = 1, 2, ..., T, \tag{3.5}$$

kde u_{t1} a u_{t2} jsou sférické nezkorelované náhodné složky;

- nejprve se zaměříme na rovnici (3.4), kde testujeme nulovou hypotézu, že proměnná X_t nepodmiňuje v Grangerově pojetí proměnnou Y_t:
  - vyjádříme lineární regresi proměnné Y_t na jejích zpožděných hodnotách – tzv. omezená regrese [18, str. 264]

$$Y_t = \sum_{i=1}^{p} \alpha_i Y_{t-i} + u_{t1}, \quad t = 1, 2, ..., T, \tag{3.6}$$

  - vyjádříme lineární regresi proměnné Y_t na jejích zpožděných hodnotách a na zpožděných hodnotách proměnné X_t – tzv. neomezená regrese [18, str. 265]

$$Y_t = \sum_{i=1}^{p} \alpha_i Y_{t-i} + \sum_{i=1}^{p} \beta_i X_{t-i} + u_{t1}, \quad t = 1, 2, ..., T, \tag{3.7}$$

    přičemž zpoždění p v regresích (3.6) a (3.7) může být libovolné.

  - obě regrese odhadneme MNČ a provedeme F-test pomocí F statistiky s q a (T-m) stupni volnosti [18, str. 265]

$$F = \frac{(\mathbf{e}'\mathbf{e})_O - (\mathbf{e}'\mathbf{e})_N}{q(\mathbf{e}'\mathbf{e})_N}(T - m), \tag{3.8}$$

    kde

    - $(\mathbf{e}'\mathbf{e})_O$ a $(\mathbf{e}'\mathbf{e})_N$ jsou spočtené součty čtverců reziduí MNČ odhadnutých regresí (3.6) a (3.7);
    - T …….. počet pozorování;
    - q …….. počet omezení parametrů;
    - p …….. maximální délka zpoždění;
    - m …….. $m = 2p$ je počet odhadnutých parametrů neomezené regrese.

    Je-li hodnota statistiky F vypočtená dle vzorce (3.8) větší než kritická hodnota $F_{q,T-m}$, odmítneme nulovou hypotézu ve prospěch alternativní. To znamená, že proměnná X_t podmiňuje v Grangerově pojetí proměnnou Y_t, neboli β_i parametry se v regresi (3.4) významně liší od nuly.
- Analogicky bychom testovali rovnici (3.5), kde by zněla nulová hypotéza tak, že proměnná Y_t nepodmiňuje z hlediska Grangerovy kauzality proměnnou X_t. Pokud na

základě testu Grangerovy kauzality v rovnici (3.4) odmítneme nulovou hypotézu a zároveň přijmeme nulovou hypotézu v rovnici (3.5), pak můžeme prohlásit, že proměnná X_t podmiňuje v Grangerově pojetí proměnnou Y_t.

Postup lze rozšířit také na systém více proměnných. Např. pro proměnné X_t, Y_t, Z_t bychom zjišťovali, zda proměnná X_t nebo Z_t podmiňují ve smyslu Grangerovy kauzality proměnnou Y_t [18].

Informaci o znaménku vztahu mezi proměnnými, nebo o tom, jak dlouho přetrvá efekt vyvolaný určitými jednorázovými změnami v systému, nám poskytne tzv. odezva na impuls. **Funkce odezvy** (impulse response functions) měří efekt neočekávaného exogenního (inovačního) šoku (impulsu) na běžnou i budoucí hodnoty libovolné vysvětlované proměnné (ve zvolené rovnici VAR modelu). Neboli jakou reakci v jedné časové řadě vyvolá jednotkový impuls (šok, jednotková změna) v jiné časové řadě systému. V m-rozměrném VAR modelu lze sledovat od okamžiku impulsu celkem m^2 odezev (pro každou endogenní proměnnou v každé rovnici VAR modelu). V případě stacionarity proměnných VAR modelu vliv všech těchto impulsů časem odezní. V takovém případě je systém stabilní. Vyhodnocuje se, za jak dlouho po šoku se systém navrátí do rovnováhy. Odvození a interpretaci funkcí odezvy je možné nalézt např. v [17] či [2].

3.3 Kointegrace

Ve vícerozměrných modelech ekonomických časových řad je vhodné rozlišovat mezi krátkodobými a dlouhodobými vztahy. Krátkodobé vztahy mezi proměnnými existují poměrně krátkou dobu a časem vymizí. Tyto vztahy existují mezi časovými řadami s krátkou pamětí, tj. stacionárními časovými řadami. Naproti tomu dlouhodobé vztahy, existující mezi nestacionárními časovými řadami, s časem nemizí, mají dlouhodobý charakter. Zde se informace z minulosti kumulují. V rámci dlouhodobých vztahů systém tenduje k rovnováze (ekvilibriu). Ekvilibrium je rovnovážný stav, ke kterému je systém neustále přitahován. Časové řady jsou v ekvilibriu, pokud je odklon směrů jejich vývoje pouze krátkodobý a existuje mez, za kterou nemůže jít. Jinými slovy, pokud je rozdíl (nepřekračující určitou mez) v chování časových řad krátkodobý a s časem vymizí, lze říci, že jsou časové řady v rovnováze, stavu, který se ze statistického hlediska nazývá **kointegrace časových řad**[21]. Kointegraci lze tedy považovat za vztah dlouhodobé rovnováhy více proměnných.

Většina makroekonomických časových řad je nestacionární (zpravidla typu I(1)). Provádíme-li regresi nestacionárních časových řad, získané výsledky budou zkreslené (jedná se o tzv. zdánlivou regresi, kdy poměr determinace, t-testy i F-testy indikují vhodnost lineárního regresního modelu, ačkoliv ve skutečnosti vztah mezi časovými řadami neexistuje). Stává se, že pro dvě či více nestacionárních časových řad existuje jejich lineární kombinace,

[21] Vzhledem k tomu, že systém je neustále vystavován šokům, není nikdy v ekvilibriu. Hovoříme proto o konvergenci systému k dlouhodobému rovnovážnému stavu.

pro kterou již stacionarita platí, a tato kombinace je tedy integrovaná I(0). To znamená, že mohou existovat vzájemně závislé nestacionární proměnné, které se vyvíjí stejným směrem (případně mají stejný či velmi podobný trend) a jejich kombinací lze nestacionaritu odstranit. Takové proměnné označujeme jako kointegrované[22] proměnné. V tomto případě již riziko zdánlivé regrese nehrozí. „*Nejsou-li proměnné X a Y kointegrované, mohou v čase divergovat, takže mezi nimi neexistuje žádný dlouhodobý vztah*.“ [18, str. 269].

Většina makroekonomických proměnných obsahuje trend[23], který je může spojovat. Pokud v případě nestacionárních kointegrovaných proměnných přejdeme v souvislosti s jejich stacionarizací na první diference, tento kointegrační vztah (kointegrační kombinaci) z modelu vynecháme, čímž vzniká tzv. specifikační chyba.

Uvažujeme-li lineární kombinaci proměnných X_t, Y_t ve tvaru (předpokládáme, že proměnné jsou integrované I(1)) [18]

$$Y_t = \beta_1 + \beta_2 X_t + u_t, \quad t = 1, 2, ..., T, \tag{3.9}$$

pak přechodem na první diference získáme model

$$\Delta Y_t = \beta_2 \Delta X_t + \Delta u_t, \quad t = 1, 2, ..., T. \tag{3.10}$$

Použitím prvních diferencí ΔX_t a ΔY_t, které jsou typu I(0), sice bude odhad regrese (3.10) MNČ korektní (nepůjde již o zdánlivou regresi), ale rovnice (3.10) bude popisovat pouze krátkodobý vztah mezi proměnnými (dochází ke ztrátě dlouhodobé informace), což z hlediska analýzy není výhodné. V některých případech platí, že pro dvě proměnné X_t a Y_t typu I(1) je jejich lineární kombinace typu I(0). Pak jsou tyto dvě proměnné kointegrované typu CI(1,1)[24] [18].

Definice [2, str. 237]: Jsou-li oba procesy $\{X_t\}$ a $\{Y_t\}$ typu I(d) a existuje-li lineární kombinace $\{aX_t + bY_t\} \sim$ I(d-c), kde c>0, potom se tyto dva procesy nazývají kointegrované řádu d, c, a označují se jako $\{X_t\}$, $\{Y_t\} \sim$ CI(d, c). Vektor (a, b)´ se nazývá kointegrační vektor.

V empirické ekonometrii nás většinou zajímají případy, kdy $d = c$, tedy kdy kointegrační vektor vede k lineární kombinaci typu I(0). Při kointegraci dvou proměnných existuje pouze jeden kointegrační vektor. V případě kointegrace m proměnných pak může být počet kointegračních vektorů nejvýše (m-1) [18].

Existují různé testy kointegrace, například **Engel-Grangerův (EG) test kointegrace**, užívaný při existenci jednoho kointegračního vztahu. Pomocí tohoto testu lze

[22] Koncept kointegrace zavedl v roce 1981 Granger.

[23] Deterministický trend odstraníme zahrnutím proměnné čas do modelu, stochastický trend pak přechodem na první diference proměnných [18].

[24] V tomto případě regrese (3.9) není zdánlivou regresí, poněvadž lineární kombinace proměnných X_t a Y_t ve tvaru $u_t = Y_t - \beta_1 - \beta_2 X_t$, kde t = 1, 2 … , T, která je stacionární (I(0)), obsahuje dlouhodobý vzájemný vztah proměnných [18].

zjistit, zda dvě proměnné typu I(1) jsou CI(1,1), (např. [18]). Dále je možné užít také Johansenova testu kointegrace pro odhad počtu kointegračních vektorů v případě více proměnných v systému.

Skupinu kointegrovaných časových řad lze popsat modelem korekce chyby, jehož prostřednictvím je možné odlišit krátkodobé a dlouhodobé vztahy mezi těmito časovými řadami.

3.4 Modely korekce chyby

V případě, že časové řady zahrnuté do VAR modelu nejsou stacionární, případně jsou-li tyto časové řady nestacionární ale kointegrované[25], je možné přejít na tzv. **model korekce chyby** (MKCH)[26]. Jedná se o dynamický model, jehož výhoda spočívá v tom, že v sobě zahrnuje krátkodobou i dlouhodobou informaci o vztahu mezi proměnnými. Tento model nevyžaduje stacionaritu proměnných v případě existence kointegrace.

Vyjdeme-li z dynamického modelu [17, str. 141]

$$Y_t = \gamma + \alpha_1 Y_{t-1} + \beta_0 X_t + \beta_1 X_{t-1} + u_t, \quad t = 1, 2, ..., T, \tag{3.11}$$

vhodnými úpravami lze získat MKCH [17, str. 141]

$$\Delta Y_t = \beta_0 \Delta X_t - (1 - \alpha_1)\left[Y_{t-1} - \psi_0 - \psi_1 X_{t-1}\right] + u_t, \quad t = 1, 2, ..., T, \tag{3.12}$$

kde $\psi_0 = \dfrac{\gamma}{1-\alpha_1}$ a $\psi_1 = \dfrac{\beta_0 + \beta_1}{1-\alpha_1}$.

V modelu (3.12) dále předpokládáme $\alpha_1 \in (0,1)$. Parametr β_0 zachycuje krátkodobou informaci. Dlouhodobá informace, neboli souhrn dlouhodobých vlivů, je pak obsažena v parametru ψ_1. Výraz $-(1-\alpha_1)\left[y_{t-1} - \psi_0 - \psi_1 x_{t-1}\right]$ je tzv. rovnovážná chyba, která vyjadřuje odchylku vysvětlované proměnné od dlouhodobé rovnováhy. Člen $(\alpha_1 - 1)$ vyjadřuje rychlost přizpůsobení k rovnováze v čase (resp. zatížení). Krátkodobé vztahy jsou tedy vztahy mezi diferencovanými proměnnými, dlouhodobé pak mezi proměnnými nediferencovanými. Model (3.12) je MKCH nelineární v parametrech, ekvivalentní k modelu (3.11). Hranatá závorka v (3.12) obsahuje

$$Y_{t-1} - \psi_0 - \psi_1 X_{t-1} = \varepsilon_{t-1}, \quad t = 1, 2, ..., T, \tag{3.13}$$

kde ε_{t-1} je po odhadu reziduum v období *t*-1. Záporné hodnoty rezidua levou stranu rovnice (3.12) zvyšují, kladné naopak snižují. Jde o určité korigování hodnot proměnné Y_t vzhledem k rovnováze. Za předpokladu, že má náhodná složka ve (3.12) vlastnosti bílého šumu, lze model odhadovat pomocí MNČ.

[25] Nejčastěji endogenní vysvětlovaná proměnná I(1).

[26] V případě, že bychom proměnné diferencovali, ztratili bychom informaci o vztahu dlouhodobé rovnováhy mezi proměnnými, jak již bylo zmíněno v podkapitole 3.3.

4 MODELY PODMÍNĚNÉ HETEROSKEDASTICITY

O modelech volatility časových řad (resp. modelech proměnlivé volatility) již bylo něco málo řečeno v podkapitole 2.5. Aplikace této metodologie je vhodná v případě, že zkoumáme časové řady, jejichž volatilita se s časem mění, čímž se vyznačuje většina finančních i ekonomických časových řad. Za průlomem v modelování volatility stál Engle[27], který se ve svém článku v roce 1982 zabýval popisem a aplikací modelu ARCH na inflaci UK. Nejčetnější aplikace modelu se ale později přesunula do finančního sektoru. V následujících studiích Bollerslev[28] v roce 1986 vyvinul model GARCH, jakožto zobecněný ARCH model, který se později stal velmi hojně aplikovaným - a je tomu tak dodnes. Postupem času se vyvíjely další a další modely volatility (IGARCH, FIGARCH, GARCH-M, EGARCH ad.), kterými se však z důvodu rozsahu této práce nebudu dále zabývat.

Modely ARCH i GARCH spadají do skupiny modelů, které charakterizují tzv. **podmíněnou heteroskedasticitu**. Zabývají se variabilitou neboli druhým podmíněným momentem časových řad. V případě porušení požadavku homoskedasticity, tedy konečného a konstantního rozptylu, podává klasická MNČ odhady, které sice jsou nestranné a konzistentní, ale ztrácejí vydatnost a dokonce i asymptotickou vydatnost. Získáme vychýlené odhady standardních chyb, intervalové odhady jsou podhodnocené či nadhodnocené a statistické testy ztrácejí na síle [17]. Heteroskedasticita, která činí problémy při aplikaci MNČ, není však pro modely ARCH a GARCH překážkou. Modely ARCH a GARCH, používané k modelování autokorelované volatility náhodných složek, se vyznačují tím, že je v nich obsažena lineární funkční forma modelu podmíněného rozptylu. Proto se také tyto modely nazývají lineární modely volatility. Modely volatility umožňují zpřesnit intervalové předpovědi časových řad, zachytit měnící se podmínky nejistoty na trhu, zefektivnit rozhodování o optimálním portfoliu atd. [2].

4.1 Modely ARCH

Jak již bylo zmíněno, modely ARCH poprvé popsal Engle v roce 1982. Předpokládal, že podmíněný rozptyl reziduí je funkcí čtverců náhodných složek (resp. reziduí) minulých období.

4.1.1 ARCH(1)

Model ARCH(1) má podmíněný rozptyl ve tvaru, např. [2], [13], [17]

$$h_t = \omega + \alpha_1 \varepsilon_{t-1}^2 \text{ [29]}, \quad t = 1, 2, ..., T, \tag{4.1}$$

[27] Americký ekonom Robert Fry Engle III (narozen 1942), držitel Nobelovy ceny za ekonomii z roku 2003.
[28] Dánský ekonom Tim Peter Bollerslev (narozen 1958).
[29] Označení h_t je ekvivalentní k označení σ_t^2. Toto značení je převzato z [13].

kde musí platit $\omega > 0$ a $\alpha_1 \geq 0$, aby byl podmíněný rozptyl h_t kladný. Je-li $\alpha_1 = 0$, pak je podmíněný rozptyl v čase konstantní a proces $\{\varepsilon_t\}$ je podmíněně homoskedastický. Ze vzorce (4.1) je zřejmé, že v modelu ARCH(1) je podmíněný rozptyl náhodné složky funkcí pouze jedné zpožděné hodnoty reziduí ε_{t-1}. Model (4.1) je tzv. dílčím modelem. Úplný model ARCH(1) pak může vypadat následovně (vyjdeme-li z lineárního regresního modelu (LRM), tedy z předpokladu stochastické lineární závislosti mezi vysvětlovanou proměnnou Y_t a k vysvětlujícími proměnnými X_{it}, $i = 1, 2, \ldots, k$) [17, str.151]

$$Y_t = \beta_1 + \beta_2 X_{2t} + ... + \beta_k X_{kt} + \varepsilon_t, \quad t = 1, 2, ..., T, \tag{4.2}$$

$$h_t = \omega + \alpha_1 \varepsilon_{t-1}^2, \quad t = 1, 2, ..., T, \tag{4.3}$$

kde $\varepsilon_t \sim NI(0, h_t)$, kde $t = 1, 2\ldots, T$. Vztah (4.2) vyjadřuje **rovnici podmíněného průměru** a vztah (4.3) **rovnici podmíněného rozptylu**[30].

Autoregresní tvar modelu (4.1) je [2, str.130]

$$\varepsilon_t^2 = \omega + \alpha_1 \varepsilon_{t-1}^2 + v_t, \qquad t = 1, 2, ..., T, \tag{4.4}$$

kde $v_t = \varepsilon_t^2 - h_t = h_t(e_t^2 - 1)$. Podmíněná a nepodmíněná střední hodnota procesu $\{v_t\}$ je nulová, což znamená, že proces není autokorelovaný. Proces ARCH(1) je stacionární v kovariancích, jestliže $\alpha_1 < 1$. Nepodmíněná střední hodnota procesu $\{\varepsilon_t^2\}$ neboli nepodmíněný rozptyl procesu $\{\varepsilon_t\}$ má tvar [2, str. 130]

$$D(\varepsilon_t) = \frac{\omega}{1 - \alpha_1}, \quad t = 1, 2, ..., T, \tag{4.5}$$

takže proces $\{\varepsilon_t\}$ je nepodmíněně homoskedastický. Autokorelační funkce je ve zpoždění k rovna $\rho_k = \alpha_1^k$.

Špičatost náhodných veličin ε_t [2, str. 130]

$$KU_\varepsilon = \frac{E(\varepsilon_t^4)}{E(\varepsilon_t^2)^2} = \frac{3(1 - \alpha_1^2)}{1 - 3\alpha_1^2}, \quad t = 1, 2, ..., T, \tag{4.6}$$

pro $3\alpha_1^2 < 1$, jinak je ∞. Je větší než špičatost normálního rozdělení[31].

Z (4.4) vyplývá, že je-li ε_{t-1} v absolutní hodnotě vysoké, je velmi pravděpodobné, že také ε_t bude v absolutní hodnotě vysoké [2]. Parametr α_1 lze chápat jako určitou váhu, která je přiřazena hodnotě náhodné složky v období (t-1). S touto vahou je informace přenášena přes podmíněný rozptyl z období (t-1) do období t.

[30] V dalším textu budu vždy uvádět pouze dílčí modely, tedy modely podmíněných rozptylů.
[31] Špičatost normálního rozdělení je 3.

4.1.2 ARCH(q)

Model ARCH(q) je poměrně jednoduchým rozšířením modelu ARCH(1), kdy je do modelu zahrnut vliv nejen jednoho zpoždění, nýbrž q zpoždění reziduí. Obecný model ARCH(q) pak můžeme vyjádřit v následující formě, např. [2], [13], [17]

$$h_t = \omega + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + ... + \alpha_q \varepsilon_{t-q}^2 \quad t = 1, 2, ..., T\,, \tag{4.7}$$ [32]

kde opět kladný podmíněný rozptyl h_t zaručují podmínky $\omega > 0$ a $\alpha_i \geq 0$, kde i = 1, 2, … , q.

Model ARCH(q) v autoregresním tvaru pak vypadá následovně [2, str. 130]

$$\varepsilon_t^2 = \omega + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + ... + \alpha_q \varepsilon_{t-q}^2 + v_t, \quad t = 1, 2, ..., T, \tag{4.8}$$

kde $v_t = \varepsilon_t^2 - h_t$.

Pomocí operátoru zpoždění je možné model (4.8) vyjádřit [2, str. 130]

$$(1 - \alpha_1 B - \alpha_2 B^2 - ... - \alpha_q B^q)\varepsilon_t^2 = \omega + v_t, \quad t = 1, 2, ..., T. \tag{4.9}$$

Proces ARCH(q) je stacionární v kovariancích pokud platí, že kořeny polynomiální rovnice [2, str. 131]

$$(1 - \alpha_1 B - \alpha_2 B^2 - ... - \alpha_q B^q) = 0\,, \tag{4.10}$$

leží vně jednotkového kruhu.

Nepodmíněný rozptyl procesu $\{\varepsilon_t\}$ má tvar [2, str. 130]

$$D(\varepsilon_t) = \frac{\omega}{1 - \alpha_1 - \alpha_2 - ... - \alpha_q}, \quad t = 1, 2, ..., T, \tag{4.11}$$

z čehož vyplývá, že je v čase konstantní a proces $\{\varepsilon_t\}$ je tak nepodmíněně homoskedastický.

Omezení modelů ARCH(q) může spočívat ve stanovování délky zpoždění q. Vysoké q znamená velký počet odhadovaných parametrů. Engle navrhl řešit tento problém apriorním omezením počtu zpoždění na q = 4 a lineárně degresivními vahami [13, str.1002]

$$h_t = \omega + \alpha_1 (0{,}4\varepsilon_{t-1}^2 + 0{,}3\varepsilon_{t-2}^2 + 0{,}2\varepsilon_{t-3}^2 + 0{,}1\varepsilon_{t-4}^2), \quad t = 1, 2, ..., T. \tag{4.12}$$

---

[32] Obecný model ARCH(q) původně uvedl Engle (pro LRM bez úrovňové konstanty) ve tvaru [13, str. 994]

$y_t \left| \psi_{t-1} \sim N(x_t \beta, h_t) \right.$,

$h_t = \omega + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + ... + \alpha_q \varepsilon_{t-q}^2$

$\varepsilon_t = y_t - x_t \beta$

kde ψ_{t-1} jsou všechny relevantní informace do času t-1, x_t může zahrnovat zpožděné hodnoty závisle proměnné a exogenní proměnné.

4.2 Modely GARCH

V případě potřeby užití modelu ARCH(q) s vysokým počtem zpoždění (tj. vysokým q) vyvstává řada problémů[33]. To lze řešit přechodem na modely GARCH. Modely GARCH, neboli zobecněné modely ARCH, jsou rozšířením modelů ARCH o zpožděný podmíněný rozptyl. V modelech GARCH(p,q) se někdy nazývá parametr p jako GARCH člen a parametr q jako ARCH člen.

4.2.1 GARCH(1,1)

V případě rozšíření modelu ARCH(1) o podmíněný rozptyl zpožděný o jedno období získáme model GARCH(1,1). Rovnice podmíněného rozptylu modelu GARCH(1,1) pak vypadá následovně [2, str. 131]

$$h_t = \omega + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1}, \quad t = 1, 2, ..., T, \tag{4.13}$$

kde musí platit $\omega > 0$ a $\alpha_1 > 0$ a $\beta_1 \geq 0$, aby byl podmíněný rozptyl h_t kladný.

Pomocí operátoru zpoždění je možné model (4.13) vyjádřit ve tvaru [2, str. 131]

$$(1 - \beta_1 B) h_t = \omega + \alpha_1 \varepsilon_{t-1}^2, \quad t = 1, 2, ..., T, \tag{4.14}$$

potom za podmínky $\beta_1 < 1$ platí

$$h_t = (1 - \beta_1 B)^{-1} (\omega + \alpha_1 \varepsilon_{t-1}^2) = (1 + \beta_1 B + \beta_1^2 B^2 + ...)(\omega + \alpha_1 \varepsilon_{t-1}^2), \tag{4.15}$$

kde t = 1, 2, … , T, což je model ARCH(∞).

Model (4.13) lze úpravami převést na model ARMA(1,1)

$$\varepsilon_t^2 = \omega + (\alpha_1 + \beta_1) \varepsilon_{t-1}^2 + v_t - \beta_1 v_{t-1}, \quad t = 1, 2, ..., T, \tag{4.16}$$

kde $v_t = \varepsilon_t^2 - h_t$. Pokud platí $\alpha_1 + \beta_1 < 1$, pak je model GARCH(1,1) stacionární v kovariancích.

Nepodmíněný rozptyl procesu $\{\varepsilon_t\}$ má tvar [2, str. 131]

$$D(\varepsilon_t) = \frac{\omega}{1 - \alpha_1 - \beta_1}, \quad t = 1, 2, ..., T, \tag{4.17}$$

z čehož vyplývá, že je v čase konstantní a proces $\{\varepsilon_t\}$ je tak nepodmíněně homoskedastický.

Hodnoty $\alpha_1 + \beta_1$ blízké jedničce naznačují značnou trvalost volatility [18].

Špičatost náhodných veličin ε_t [2, str. 132]

[33] Velký počet odhadovaných parametrů, stacionarita ad.

$$KU_\varepsilon = \frac{E(\varepsilon_t^4)}{E(\varepsilon_t^2)^2} = \frac{3(1-(\alpha_1+\beta_1)^2)}{1-(\alpha_1+\beta_1)^2-2\alpha_1^2}, \quad t = 1, 2, ..., T, \tag{4.18}$$

pro $3\alpha_1^2 + 2\alpha_1\beta_1 + \beta_1^2 < 1$, jinak je ∞. Je větší než špičatost normálního rozdělení.

Autokorelační funkce procesu $\{\varepsilon_t^2\}$ [2, str. 132]

$$\rho_1 = \alpha_1 + \frac{\alpha_1^2\beta_1}{1-2\alpha_1\beta_1-\beta_1^2}, \tag{4.19}$$

$$\rho_k = (\alpha_1+\beta_1)^{k-1}\rho_1, \quad k = 2, 3, ..., \tag{4.20}$$

přičemž s rostoucím zpožděním k hodnoty autokorelační funkce exponenciálně klesají a rychlost tohoto poklesu závisí na hodnotě $\alpha_1 + \beta_1$. Blíží-li se součet k hodnotě jedna, pokles autokorelační funkce je pozvolný.

Model GARCH(1,1) je nejužívanějším modelem skupiny GARCH modelů. Je vhodný pro předpovědi.

4.2.2 GARCH(p,q)

Rovnice podmíněného rozptylu obecného modelu GARCH(p,q) má tvar [2, str. 132]

$$h_t = \omega + \sum_{i=1}^{q}\alpha_i\varepsilon_{t-i}^2 + \sum_{i=1}^{p}\beta_i h_{t-i}, \quad t = 1, 2, ..., T, \tag{4.21}$$

kde musí platit $\omega > 0$ a $\alpha_i > 0$ pro i = 1, 2, … , q a $\beta_i \geq 0$ pro i = 1, 2, … , p, aby byl podmíněný rozptyl h_t kladný.

Pomocí operátoru zpoždění lze model (4.21) zapsat [2, str. 132]

$$h_t = \omega + \alpha(B)\varepsilon_t^2 + \beta(B)h_t, \quad t = 1, 2, ..., T, \tag{4.22}$$

kde $\alpha(B) = \alpha_1 B + \alpha_2 B^2 + ... + \alpha_q B^q$ a $\beta(B) = \beta_1 B + \beta_2 B^2 + ... + \beta_p B^p$.

Model (4.21) lze vhodnými úpravami převést na model ARMA(m, p), kde $m = \max\{p, q\}$ [2, str. 133]

$$\varepsilon_t^2 = \omega + \sum_{i=1}^{m}(\alpha_i+\beta_i)\varepsilon_{t-i}^2 - \sum_{i=1}^{p}\beta_i v_{t-i} + v_t, \quad t = 1, 2, ..., T, \tag{4.23}$$

nebo pomocí operátoru zpoždění

$$\varepsilon_t^2 = \omega + [\alpha(B)+\beta(B)]\varepsilon_t^2 + v_t - \beta(B)v_t, \quad t = 1, 2, ..., T, \tag{4.24}$$

kde $v_t = \varepsilon_t^2 - h_t$. Pokud platí, že kořeny polynomiální rovnice [2, str. 133]

$$1 - \alpha(B) - \beta(B) = 0\,, \tag{4.25}$$

leží vně jednotkového kruhu, pak je model GARCH(*p, q*) stacionární v kovariancích.

Nepodmíněný rozptyl procesu $\{\varepsilon_t\}$ má tvar [2, str. 133]

$$D(\varepsilon_t) = \frac{\omega}{1 - \alpha(1) - \beta(1)}, \quad t = 1, 2, ..., T. \tag{4.26}$$

Je-li člen *p* nulový, pak je model GARCH(*p, q*) ekvivalentní s modelem ARCH(*q*). Jsou-li členy *p* a *q* nulové, pak proces $\{\varepsilon_t\}$ je bílý šum.

Mezi omezení modelů GARCH patří případy, kdy odhadnuté parametry modelu nesplňují podmínky nezápornosti a kladnosti. V takovém případě je možné koeficienty apriorně omezit.

4.3 Odhad modelů ARCH a GARCH

Jak již bylo zmíněno, odhad modelů ARCH a GARCH pomocí MNČ poskytuje odhady nestranné a konzistentní, ne však maximálně vydatné. Odhad kovarianční matice parametrů je vychýlený, statistické testy nedávají důvěryhodné výsledky. Vydatnější odhady parametrů modelů ARCH a GARCH lze získat například na základě **metody maximální věrohodnosti** (MMV). Takové odhady jsou nestranné a konzistentní a oproti klasické MNČ také asymptoticky vydatnější [17], [18].

Nejsou-li v rámci úplného modelu splněny předpoklady podmíněné normality náhodných složek v LRM, pak lze parametry rovnice podmíněného průměru a podmíněného rozptylu konzistentně odhadnout pomocí MMV pouze tehdy, jsou-li obě rovnice přesně specifikovány. Konzistentní odhady asymptotické kovarianční matice a standardních chyb lze získat pomocí **metody kvazi maximální věrohodnosti** (MKMV), která je vůči nedodržení normality robustní. Pro odhady modelů ARCH a GARCH získané metodou MKMV platí, že jsou konzistentní a asymptoticky normální. Problémy s přesností odhadů se obecně vyskytují v případech, kdy je rozdělení náhodných složek nesymetrické [18].

Při odhadu lze postupovat tak, že se v první fázi odhadnou parametry rovnice průměru a ve druhém kroku se na základě získaných reziduí z rovnice průměru odhadnou parametry rovnice podmíněného rozptylu (volatility) [2].

5 EMPIRICKÁ ANALÝZA A PREDIKCE NA ZÁKLADĚ VAR MODELŮ

Při analýze inflace s využitím VAR modelů, založené na reálných datech české ekonomiky, se budu opírat o ekonomický **model RMPY**, kde

- *R* je úroková míra 1RPRIBOR;
- *M* …….. peněžní agregát M2;
- *P* …….. inflace – zvolila jsem index spotřebitelských cen (ISC) ve formě bazických indexů (rok 2005=100);
- *Y* …….. hrubý domácí produkt v běžných cenách (HDP).

Budu sledovat závislost inflace na zbylých zmíněných proměnných modelu, tedy obecně[34]

$$P = f(R, M, Y, \varepsilon) \tag{5.1}$$

5.1 Data

Data klíčových veličin pro ČR jsem získala z internetových stránek Českého statistického úřadu a České národní banky ve formě čtvrtletních časových řad, a to konkrétně za období II/1997 – III/2010 ([22], [23]).

Úroková míra 1RPRIBOR v procentech i peněžní agregát M2 v mil. Kč jsou čtvrtletní časové řady a byly získány z internetových stránek ČNB.

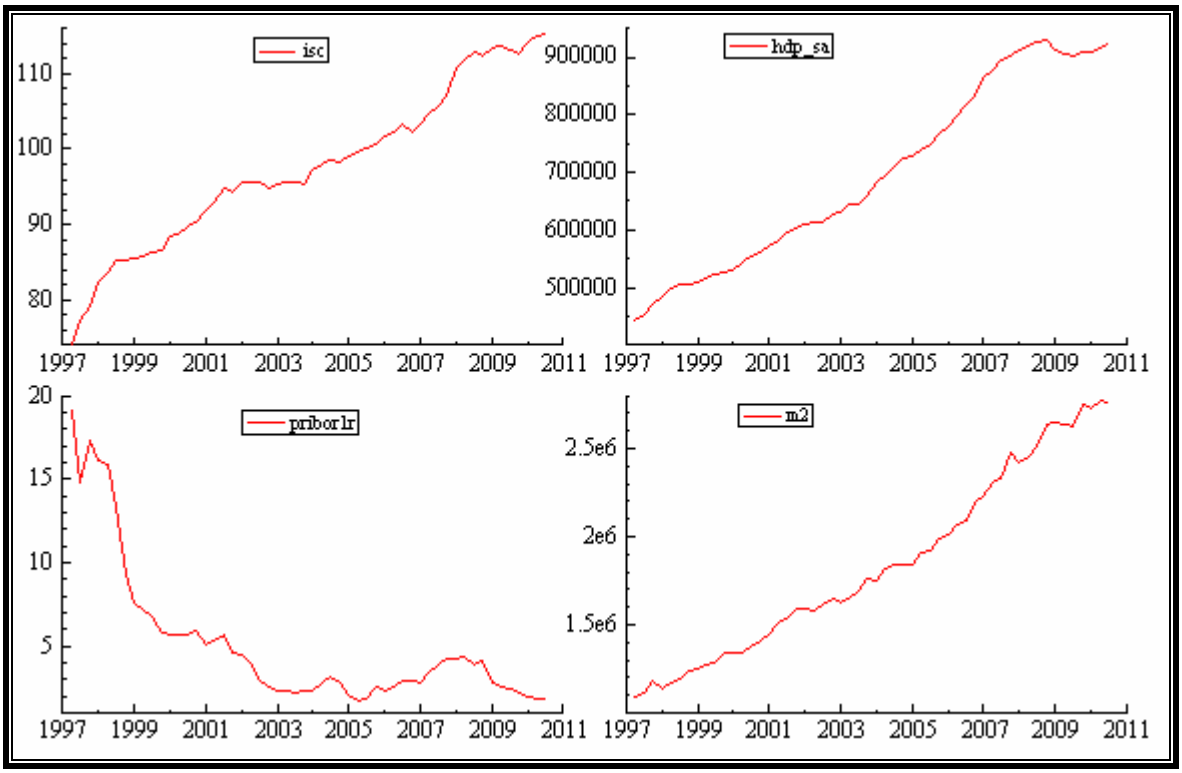
Indexy spotřebitelských cen - bazické indexy (rok 2005=100), byly získány z internetových stránek ČSÚ. Čtvrtletní časovou řadu ISC jsem odvodila váženým chronologickým průměrem z měsíčních dat.

Hrubý domácí produkt v běžných cenách v mil. Kč je ve formě čtvrtletní časové řady, která byla jako jediná sezónně očištěná již z internetových stránek ČSÚ.

Následující obrázek č. 5.1 vykresluje průběh výše popsaných časových řad.

[34] *PRIBOR1R, ISC, HDP* a *M2* jsem zvolila jako označení jednotlivých proměnných, která budu v dalším textu a výpočtech užívat

Obrázek 5.1 - Průběhy časových řad pro ČR - M2, 1RPRIBOR, ISC a HDP



Zdroj: Vlastní výpočet v GiveWin

Z průběhu všech časových řad je zřejmá jejich nestacionarita. Funkce ACF a PACF proměnných jsou k nahlédnutí v příloze č. 6.

Pro výpočty v následujících kapitolách byly použity software GiveWin 2.10 s moduly PcGive 10.0 a OxPack 3.1 a software EViews 6.

Pro další práci bylo nutné časové řady očistit od sezónnosti. Statisticky významná sezónnost nebyla prokázána pouze u časové řady 1RPRIBOR. Časová řada HDP byla získána již sezónně očištěná (*HDP_SA*). Zbylé časové řady – ISC a M2 jsem sezónně očistila komplexní a v praktických aplikacích často užívanou metodou X12 ARIMA. Sezónně očištěné řady *ISC_SA* a *M2_SA* jsou k nahlédnutí v příloze č. 7 - 8.

U jednotlivých časových řad jsem zkoumala jejich stacionaritu. Stacionarita je klíčovou podmínkou pro možnost odhadu parametrů stochastického procesu. V případě splnění podmínky stacionarity chápeme časovou řadu jako výběr z jednoho rozdělení. K testování jsem použila **ADF test** existence jednotkových kořenů. Užila jsem model s konstantou

$$X_t = c + \Phi X_{t-1} + \sum_{i=1}^{p-1} \gamma_i \Delta X_{t-i} + a_t, \quad t = 1, 2, ..., T. \tag{5.1}$$

Nulová hypotéza říká, že $\Phi = 1$ - tj. jednotkový kořen existuje a daná časová řada je nestacionární. Testové kritérium $t = [\hat{\Phi} - 1 / s_{\hat{\Phi}}]$, kde $s_{\hat{\Phi}}$ je odhad směrodatné chyby odhadu, má tzv. Dickey-Fullerovo rozdělení.

Kritické hodnoty, na 1%, 5% a 10% hladině významnosti, jsou uvedeny v následující tabulce č. 5.1.

Tabulka 5.1 - Kritické hodnoty ADF testu pro zvolené hladiny významnosti

Hladiny významnosti	Kritické hodnoty
1%	-3,55
5%	-2,91
10%	-2,59

Zdroj: Vlastní výpočet

Jednotlivé výsledky ADF testů jsou k nahlédnutí v tabulce č. 5.2 (testy pro období II/1997 – III/2010).

Tabulka 5.2 - Výsledky ADF testů proměnných v úrovňových hodnotách

Proměnná	*t*-statistika	*p*-value
ISC_SA	-0,696	0,839
HDP_SA	-0,490	0,885
M2_SA	1,658	1,000
PRIBOR1R	-4,359	0,001

Zdroj: Vlastní výpočet

Z tabulky č. 5.2 je zřejmé, že všechny proměnné kromě *PRIBOR1R* jsou ve svých úrovňových hodnotách nestacionární. Co se týká časové řady *PRIBOR1R*, její stacionarita je zřejmě zapříčiněna krátkou časovou řadou tohoto ukazatele. Zajímavé je, že již při přidání jediné hodnoty – I/1997 - do časové řady, se řada jeví jako nestacionární, jak je vidět v příloze č. 9. Zde je hodnota testového kritéria -1,584 a *p*-value 0,484, což vypovídá o nestacionaritě řady *PRIBOR1R* v období I/1997 – III/2010. Pro období II/1997 – III/2010 je i logaritmovaná časová řada *L_PRIBOR1R* nestacionární, jak je možné vidět v příloze č. 10. Budu proto dále předpokládat nestacionaritu časové řady *PRIBOR1R* i v období II/1997 – III/2010. Časové řady jsem nejprve převedla na logaritmy a posléze provedla diferencování[35] za účelem stacionarizace časových řad. Diference logaritmů proměnných jsem zvolila zejména z důvodu poměrně dobré interpretace transformovaných hodnot, které odpovídají logaritmovaným koeficientům růstu. Koeficienty růstu jsou tzv. míry dynamiky a lze je obecně zapsat jako

$$k_t = \frac{y_t}{y_{t-1}}, \quad t = 1, 2, ..., T. \tag{5.2}$$

Logaritmy koeficientů růstu pak mají tvar

$$\ln k_t = \ln y_t - \ln y_{t-1}, \quad t = 1, 2, ..., T. \tag{5.3}$$

Pro první diference logaritmů jednotlivých proměnných jsou výsledky ADF testů obsaženy v tabulce č. 5.3.

[35] Stacionarizace diferencováním zbaví časovou řadu deterministického a stochastického trendu.

Tabulka 5.3 - Výsledky ADF testů pro první diference logaritmů proměnných

Proměnná v 1. diferencích	*t*-statistika	*p*-value
DL_ISC_SA	-4,421	0,001
DL_HDP_SA	-2,968	0,045
DL_M2_SA	-7,751	0,000
DL_PRIBOR1R	-5,704	0,000

Zdroj: Vlastní výpočet

Transformované časové řady jsou již všechny stacionární (v úrovňových hodnotách tedy I(1)).

5.2 Odhad modelů VAR

Vzhledem k ekonomickému modelu, který je popsán v úvodu kapitoly č. 5, budu odhadovat čtyřrovnicový VAR model (čtyři endogenní proměnné). Optimální délku zpoždění volím dle hodnot informačních kritérií a také s ohledem na autokorelaci náhodné složky, která je nežádoucí, protože - mimo jiné - deformuje *t*-testy[36]. Pro krátké časové řady není vhodné volit velký počet zpoždění z důvodu klesajícího počtu stupňů volnosti. Pro ČR se ve čtvrtletních VAR modelech zpravidla užívají dvě zpoždění, vzhledem k malému počtu pozorování je však možné, že bude optimální jen jedno zpoždění. Budu srovnávat VAR modely pro tři různá zpoždění.

K eliminaci odlehlých pozorování v časové řadě prvních diferencí logaritmů indexů spotřebitelských cen jsem do modelu zahrnula nula-jednotkovou (tzv. dummy) proměnnou *D*. Hodnota jedna je přítomna na pozicích třetího čtvrtletí roku 1997, prvního čtvrtletí roku 1998 a poslední pak na pozici prvního čtvrtletí roku 2008. Proměnné modelu jsou tedy *DL_PRIBOR1R*, *DL_M2_SA*, *DL_HDP_SA*, *DL_ISC_SA* a *D*.

5.2.1 Výběr VAR modelu a funkce odezvy

Provedla jsem odhad modelu VAR(1), VAR(2) a VAR(3) pro data II/1997 – III/2010. Poslední dvě pozorování (za období II/2010 a III/2010) jsem následně z odhadu vynechala pro analýzu predikce ex post.

Hodnoty informačních kritérií pro modely VAR(1), VAR(2) a VAR(3) a období II/1997 – III/2010 jsou uvedeny v tabulce č. 5.4.

[36] Pozitivní autokorelace podhodnocuje směrodatné chyby odhadů, a tím nadhodnocuje *t*-statistiky. Důsledkem toho může být, že *t*-testy indikují, že parametry jsou různé od nuly, ačkoliv opak je pravdou. Autokorelace také nadhodnocuje koeficient vícenásobné determinace R^2 a *F*-statistiku.

Tabulka 5.4 - Informační kritéria pro modely VAR(1) - VAR(3) a data II/1997 - III/2010

Model	T	p	log-likelihood	SC	HQ	AIC
VAR(1)	52	20	576.70618	-20.661	-21.124	-21.412
VAR(2)	51	36	581.62412	-20.033	-20.876	-21.397
VAR(3)	50	52	576.91340	-19.008	-20.239	-20.997

Zdroj: Vlastní výpočet v GiveWin

Vidíme, že z hlediska informačních kritérií se jeví jako nejvhodnější model VAR(1), tedy model zahrnující jen jedno zpoždění. Odhad modelu VAR(1) pro období II/1997 – III/2010 je uveden v příloze č. 11. V této příloze jsou obsaženy také sdružené diagnostické testy sloužící k ověřování vhodnosti modelu. Celkové *F*-testy indikují, že model VAR(1) jako celek je vhodný. Breusch-Godfreyův test (AR 1-4 test) ukazuje, že rezidua nevykazují autokorelaci a test normality (Jarque-Bera test) neprokázal reziduální nenormalitu. Reziduální podmíněná heteroskedasticita (ARCH test) ani reziduální heteroskedasticita (hetero test) také nejsou prokázány. Všechny uvedené testy dopadly pozitivně i v případě jednorozměrného provedení týkajícího se reziduí jednotlivých rovnic modelu zvlášť. *F*-testy poukazují na možnost vynechání proměnné *DL_PRIBOR1R* z modelu (významná až na 10% hladině významnosti) a uvažování pouze třírovnicového modelu cenových indexů, hrubého domácího produktu a agregátu M2. Vzhledem k významné GK (podkapitola 5.2.2 níže) prokazující vliv proměnné *DL_PRIBOR1R* na proměnnou *DL_M2_SA* ve smyslu Grangerovy kauzality, jsem však model ponechala v původním čtyřrovnicovém tvaru.

V rovnici pro *DL_PRIBOR1R* vyšla statisticky významná zpožděná hodnota této proměnné na 5% hladině významnosti. V rovnici pro *DL_M2_SA* vyšla na 5% hladině významnosti podstatná zpožděná hodnota této proměnné a dále proměnná *DL_HDP_SA* a dummy proměnná *D*. Na 10% hladině významnosti pak také proměnné *DL_PRIBOR1R* a *DL_ISC_SA*. V rovnici pro *DL_HDP_SA* je na 5% hladině významná zpožděná hodnota této proměnné a dále proměnná *DL_M2_SA*. Konečně v rovnici pro *DL_ISC_SA* je na 5% hladině významná její zpožděná hodnota a proměnné *DL_M2_SA* a *D*. V příloze č. 12 jsou obsažena rezidua modelu VAR(1), v příloze č. 13 pak funkce ACF a PACF těchto reziduí.

V příloze č. 15 se nacházejí výstupy reakcí jednotlivých časových řad na jednotkové exogenní impulsy. Šok rozkmitává rovnice modelu, které se po určité době navrací do původní rovnováhy, případně se ustálí na rovnováze nové. Z výstupů je zřejmé, že počet období, po kterých se systém vrací do rovnováhy, je průměrně kolem 20 období (počet pozorování je přitom 53). V příloze č. 15 je však vidět, že v některých případech ustálení trvá poměrně dlouho.

5.2.2 Grangerova kauzalita

Základní myšlenka zkoumání GK spočívá v tom, že působí-li určitá časová řada na jinou časovou řadu, pak by také měla pomoci zlepšit její předpověď. Zkoumala jsem GK pro

model VAR(1) z předchozí podkapitoly 5.2.1. Statisticky významné testy jsou obsaženy v následující tabulce č. 5.5 (nevýznamné testy jsou pak k nahlédnutí v příloze. č. 14).

Tabulka 5.5 - Grangerovy testy kauzality

```
Test for excluding: dl_m2_sa_1@dl_isc_sa
Subset Chi^2(1) =   9.8516 [0.0017]**

Test for excluding: dl_hdp_sa_1@dl_m2_sa
Subset Chi^2(1) =   8.9179 [0.0028]**

Test for excluding: dl_m2_sa_1@dl_hdp_sa
Subset Chi^2(1) =   4.5603 [0.0327]*

Test for excluding: dl_isc_sa_1@dl_m2_sa
Subset Chi^2(1) =   4.0040 [0.0454]*

Test for excluding: dl_pribor1r_1@dl_m2_sa
Subset Chi^2(1) =   3.8335 [0.0502]
```

Zdroj: Vlastní výpočet v GiveWin

Na 5 % hladině významnosti byla prokázána oboustranná GK proměnných *DL_M2_SA* a *DL_ISC_SA*. Dále byla prokázána oboustranná GK proměnných *DL_HDP_SA* a *DL_M2_SA* na 5% hladině významnosti. Na 10% hladině významnosti je významný také vliv proměnné *DL_PRIBOR1R* na proměnnou *DL_M2_SA* ve smyslu GK.

5.2.3 Kointegrace a model korekce chyby

V první fázi jsem zkoumala kointegraci více proměnných. Při odhadu kointegračních vektorů bylo zapotřebí identifikovat kointegrační matici. V této souvislosti jsem získala lepší výsledky (v souladu s ekonomickou teorií) při použití transformované proměnné *ISC_SA*. Proměnná *MI* vyjadřuje čtvrtletní míru inflace a byla získána jako koeficienty růstu sezónně očištěné časové řady indexu spotřebitelských cen. Koeficienty růstu byly zlogaritmovány a následně vynásobeny stem (proměnná *L_MI100*).

V příloze č. 16 je výstup odhadu VAR(1) modelu logaritmovaných časových řad (proměnné *L_M2_SA, L_HDP_SA, L_PRIBOR1R, L_MI100*) a umělé proměnné *D* za období II/1997 – III/2010. Pro takto sestavený VAR(1) model jsem dále zkoumala kointegraci. V příloze č. 18 je obsažen **Johansenův test kointegrace**. Z výstupů je patrná existence maximálně dvou kointegračních vektorů. Při odhadu těchto vektorů však bylo zapotřebí identifikovat kointegrační matici na základě dodatečných restrikcí. Provedla jsem tedy restrikce ve formě [2, str. 265][37]

[37] Omezení vedoucí k dlouhodobé poptávce po penězích a Fisherovu efektu.

$$\boldsymbol{\beta}' = \begin{bmatrix} 1 & \beta_{L_HDP_SA} & 0 & \beta_{L_MI100} \\ 0 & 0 & 1 & \beta_{L_MI100} \end{bmatrix}, \tag{5.4}$$

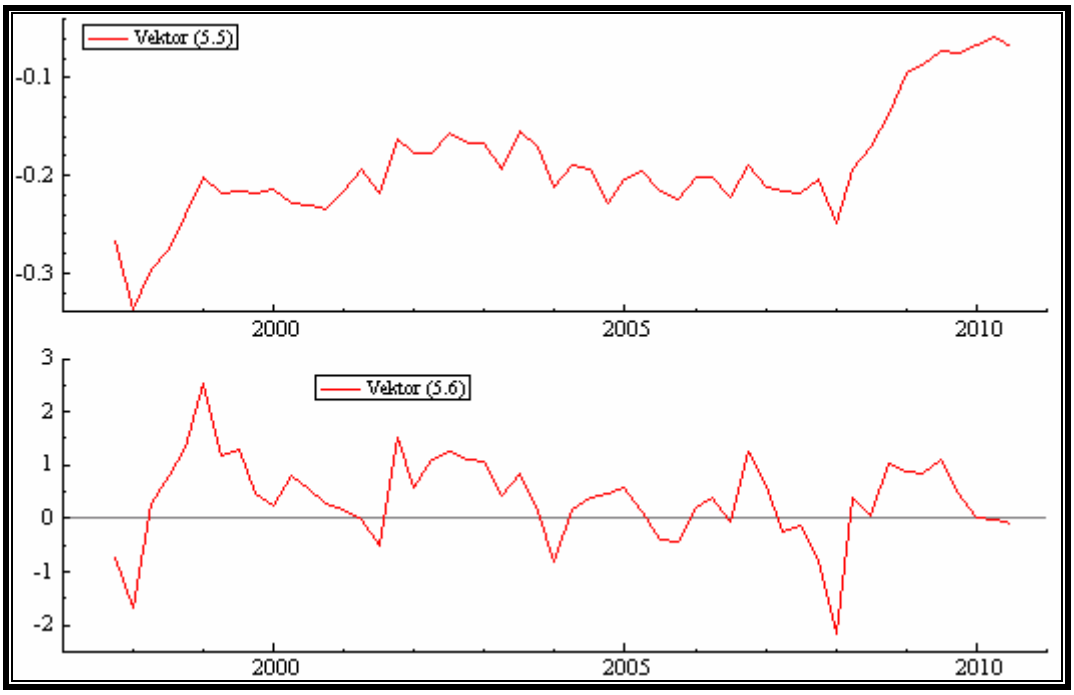
kde řádky vyjadřují kointegrační vektory a jednotlivé složky v řádcích vyjadřují kointegrační parametry postupně pro proměnné *L_M2_SA*, *L_HDP_SA*, *L_PRIBOR1R* a *L_MI100*. Po aplikaci restrikcí jsem získala odhady kointegračních vektorů ve tvaru (výstupy jsou obsaženy v příloze č. 19)

$$C_{1t} = L_M2_SA_t - 1{,}084 L_HDP_SA_t - 0{,}025 L_MI100_t, \qquad t = 1, 2, ..., 53, \tag{5.5}$$

$$C_{2t} = L_PRIBOR1R_t - 1{,}272 L_MI100_t, \qquad t = 1, 2, ..., 53. \tag{5.6}$$

Dle vztahu (5.5) je měnový agregát M2 v přímé závislosti s hrubým domácím produktem a s mírou inflace. Ve vztahu (5.6) je pak úroková míra v přímé závislosti s mírou inflace. Tyto vztahy souhlasí s ekonomickou teorií. Kointegrační vektory (5.5) a (5.6) jsou zobrazeny na obrázku č. 5.2.

Obrázek 5.2 – Kointegrační vztahy



Zdroj: Vlastní výpočet v GiveWin

Kointegraci jsem dále zkoumala pomocí statické regrese mezi jednotlivými dvojicemi logaritmovaných časových řad. Kointegrace každého takového páru časových řad se posuzuje pomocí testování stacionarity reziduí konkrétní statické regrese. Rezidua získaná na základě odhadů většiny takto definovaných regresí však neprošly diagnostickými testy. Totéž vyšlo i pro kombinace více proměnných.

Bez ohledu na diagnostické testy jsem, v návaznosti na kointegrační analýzu výše, zkoumala statickou regresi mezi proměnnými *L_PRIBOR1R* a *L_ISC_SA* (v tomto případě

jsem do výpočtů zahrnula logaritmovanou sezónně očištěnou časovou řadu indexu spotřebitelských cen)

$$L_PRIBOR1R_t = \alpha \cdot L_ISC_SA_t + \zeta_t, \quad t = 1, 2, ..., 54. \tag{5.7}$$

Všechny časové řady v regresi (5.7) jsou typu I(1). Odhad regrese (5.7) pro data II/1997 – III/2010 je obsažen v příloze č. 20. Diagnostické testy nedopadly sice pozitivně, ale v rámci hlubšího zkoumání tyto nedostatky opomenu a budu pokračovat v analýze kointegrace. Přítomnost autokorealce a podmíněné heteroskedasticity by při testu kointegrace neměly hrát roli [2]. Pro testování kointegrace byl využit ADF test, který potvrzuje stacionaritu reziduí regrese (5.7), jak je možné vidět v příloze č. 21. Časové řady jsou tedy kointegrované.

Vzhledem k již zmíněné autokorelaci v modelu (5.7) je nutné tento model dynamizovat a autokorelaci tak odstranit. Zvolený model dynamické regrese pak má tvar

$$L_PRIBOR1R_t = \delta \cdot D_t + \alpha \cdot L_PRIBOR1R_{t-1} + \beta_0 \cdot L_ISC_SA_t + \beta_1 \cdot L_ISC_SA_{t-1} + \zeta_t,$$

$$t = 1, 2, ..., 54. \tag{5.8}$$

Konečně MKCH má tvar

$$\Delta L_PRIBOR1R_t = \delta \cdot \Delta D_t + \beta_0 \cdot \Delta L_ISC_SA_t - (1-\alpha)\left[L_PRIBOR1R_{t-1} - \right.$$
$$\left. - \frac{\beta_0 + \beta_1}{1-\alpha} L_ISC_SA_{t-1} \right] + \zeta_t,$$

$$t = 1, 2, ..., 54, \tag{5.9}$$

kde musí platit $\alpha \in (0;1)$.

Odhad modelu (5.8) je obsažen v příloze č. 22. Diagnostické testy jsou již všechny v pořádku, autokorelace byla odstraněna. Parametr α je roven hodnotě 0,86, což vyhovuje předpokladům. Parametr β_0, který zachycuje krátkodobou informaci, je roven hodnotě 16,073. Dlouhodobá informace je pak obsažena ve členu $[(\beta_0 + \beta_1)/(1-\alpha)]$, který je roven hodnotě 0,065. Hodnota dlouhodobého multiplikátoru indikuje přímou závislost mezi proměnnými *L_ISC_SA* a *L_PRIBOR1R*. Rychlost přizpůsobení k rovnováze v čase, tedy člen $(\alpha - 1)$, je rovna hodnotě -0,14. Tato hodnota indikuje existenci dlouhodobého vztahu.

5.2.4 Predikce na základě modelu VAR(1)

V této podkapitole se budu zabývat predikcí. Nejdříve jsem prováděla predikci ex post na období II/2010 a III/2010, následně predikci ex ante na období IV/2010 a I/2011.

Na základě VAR(1) modelu a dat II/1997 – I/2010, jehož odhad je obsažen v příloze č. 25, jsem provedla predikci ex post na dvě období. V příloze č. 23 jsou obsaženy grafy pro bodové a 95% intervalové předpovědi všech časových řad na dvě čtvrtletí dopředu. V příloze č. 24 je pak grafické srovnání se skutečností. Odchylky bodových předpovědí od skutečnosti

nejsou příliš velké, nejméně přesná vyšla předpověď pro úrokovou míru. Pro přesnější předpovědi by bylo zapotřebí delších časových řad.

Tabulky č. 5.6 a 5.7 obsahují konkrétní hodnoty bodových předpovědí transformované na úrovňové hodnoty proměnných.

Tabulka 5.6 - Srovnání skutečnosti s predikcí ex post na období II-III/2010, proměnné HDP a ISC

	HDP	HDP_PRE	Odchylka v %		ISC	ISC_PRE	Odchylka v %
IV/2009	909 749	909 749			113,38	113,38	
I/2010	907 274	907 274			113,97	113,97	
II/2010	**915 409**	**909 973**	-0,59%		**114,52**	**114,37**	-0,13%
III/2010	**923 238**	**919 035**	-0,46%		**115,13**	**114,67**	-0,40%

Zdroj: Vlastní výpočet

Tabulka 5.7 - Srovnání skutečnosti s predikcí ex post na období II-III/2010, proměnné M2 a PRIBOR1R

	M2	M2_PRE	Odchylka v %		PRIBOR1R	PRIBOR1R_PRE	Odchylka v %
IV/2009	2 705 506	2 705 506			2,2	2,20	
I/2010	2 733 520	2 733 520			1,94	1,94	
II/2010	**2 779 609**	**2 751 767**	-1,00%		**1,78**	**1,88**	5,59%
III/2010	**2 783 682**	**2 767 560**	-0,58%		**1,78**	**1,86**	4,75%

Zdroj: Vlastní výpočet

Pro případné zlepšení predikcí jsem dále do VAR(1) modelu vložila sezónní proměnné. Výstupy jsou obsaženy v tabulkách č. 5.8 a 5.9 (opět přepočtené na úrovňové hodnoty).

Tabulka 5.8 - Srovnání skutečnosti s predikcí ex post na období II-III/2010, HDP a ISC, VAR(1) model se sezónními proměnnými

	HDP	HDP_PRE	Odchylka v %		ISC	ISC_PRE	Odchylka v %
IV/2009	909 749	909 749			113,38	113,38	
I/2010	907 274	907 274			113,97	113,97	
II/2010	**915 409**	**912 696**	-0,30%		**114,52**	**114,36**	-0,14%
III/2010	**923 238**	**921 114**	-0,23%		**115,13**	**114,76**	-0,32%

Zdroj: Vlastní výpočet

Tabulka 5.9 - Srovnání skutečnosti s predikcí ex post na období II-III/2010, M2 a PRIBOR1R, VAR(1) model se sezónními proměnnými

	M2	M2_PRE	Odchylka v %		PRIBOR1R	PRIBOR1R_PRE	Odchylka v %
IV/2009	2 705 506	2 705 506			2,2	2,20	
I/2010	2 733 520	2 733 520			1,94	1,94	
II/2010	2 779 609	2 760 090	-0,70%		1,78	1,90	6,99%
III/2010	2 783 682	2 790 323	0,24%		1,78	1,82	2,23%

Zdroj: Vlastní výpočet

Z tabulek č. 5.8 a 5.9 je zřejmé, že předpověď některých proměnných se zahrnutím sezónních proměnných do VAR(1) modelu zlepšila, některých naopak zhoršila. Kupříkladu bodová předpověď hrubého domácího produktu se zlepšila oproti VAR modelu bez sezónních proměnných. Bodová předpověď úrokové míry se naopak zhoršila pro období II/2010. Hodnoty směrodatných chyb odhadů z tabulek č. 5.6 – 5.9 jsou obsaženy v příloze č. 27.

Dále jsem provedla predikci ex ante, kterou jsem již zakládala na odhadu modelu VAR(1) za období II/1997 – III/2010. Odhad tohoto modelu (bez sezónních proměnných) je obsažen v příloze č. 11. V příloze č. 26 jsou obsaženy grafické výstupy bodové a 95% intervalové předpovědi všech zkoumaných časových řad na období IV/2010 a I/2011. Konkrétní hodnoty bodových předpovědí přepočtených časových řad na úrovňové hodnoty jsou k nahlédnutí v tabulce č. 5.10.

Tabulka 5.10 - Predikce ex ante na období IV/2010 - I/2011, VAR(1)

	HDP	M2	ISC	PRIBOR1R
IV/2010	928 761	2 804 553	115,51	1,77
I/2011	933 783	2 823 773	115,85	1,77

Zdroj: Vlastní výpočet

Provedla jsem také predikci na základě modelu VAR(1) se sezónními proměnnými. Predikované hodnoty jsou obsaženy v tabulce č. 5.11 (úrovňové hodnoty proměnných).

Tabulka 5.11 - Predikce ex ante na období IV/2010 – I/2011, VAR(1) se sezónními proměnnými

	HDP	M2	ISC	PRIBOR1R
IV/2010	928 317	2 801 275	115,51	1,79
I/2011	933 237	2 838 486	115,78	1,56

Zdroj: Vlastní výpočet

Dle provedené bodové predikce ex ante by měl index spotřebitelských cen dosáhnout hodnoty 115,51 ve čtvrtém čtvrtletí roku 2010 a hodnoty 115,85 (pro VAR model bez sezónních proměnných) resp. 115,78 (pro VAR model se sezónními proměnnými) v prvním čtvrtletí roku 2011. Báze je rok 2005. Hodnoty směrodatných chyb odhadů z tabulek č. 5.10 – 5.11 jsou obsaženy v příloze č. 28.

6 ANALÝZA A PREDIKCE VOLATILITY INFLACE

V této kapitole se budu zabývat aplikací modelů volatility ARCH a GARCH na časovou řadu indexu spotřebitelských cen. Analýzu jsem zakládala na čtvrtletních datech za období II/1997 – III/2010. Pro výpočty jsem využívala data celé této časové řady, období II/2010 a III/2010 jsem poté z výpočtů vynechala pro predikci ex post. Časovou řadu bazických indexů jsem nejdříve očistila od sezónnosti metodou X12 ARIMA. Dále jsem řadu logaritmovala a posléze převedla na první diference s cílem stacionarizace. Transformovaná řada (*DL_ISC_SA*) je již stacionární, jak bylo zmíněno v podkapitole 5.1.

Portmanteau test poukazuje pro takto upravenou časovou řadu na autokorelaci, Jarqeův-Beraův test na nenormální rozdělení. ARCH test prokazuje podmíněnou heteroskedasticitu, což naznačuje možnost uvažovat pro modelování indexu spotřebitelských cen modely volatility. Diagnostické testy jsou obsaženy v příloze č. 29.

Zvažovala jsem zahrnout do modelu zpoždění modelované proměnné. Zpoždění o dvě a více období vyšla statisticky nevýznamná, rozhodla jsem se tedy, vložit do modelu pouze jedno zpoždění a dále také konstantu.

6.1 Modely ARCH a GARCH – odhad modelu v jednom kroku

Nejdříve jsem odhadovala model (4.2) - (4.3), resp. jiný model podmíněného rozptylu, najednou, v jednom kroku. Zaměřila jsem se přitom na vybrané modely ARCH a GARCH pro období II/1997 – III/2010. K odhadu jsem použila software GiveWin 2.10 s moduly PcGive 10.0 a OxPack 3.1. Jedná se o nelineární iterativní optimalizaci.

Z modelů typu ARCH jsem provedla odhady modelů ARCH(1), ARCH(2) a ARCH(3). Hodnoty parametrů těchto modelů, jejich statistické významnosti a hodnoty věrohodnostních funkcí jsou uvedeny v tabulkách č. 6.1 a 6.2. Při výpočtech úplného modelu v jednom kroku jsem se často setkávala s existencí většího počtu lokálních maxim věrohodnostní funkce. Při hledání globálního maxima jsem v PcGive volila generování počátečních hodnot parametrů. To bylo zpravidla časově náročné a při volbě různého počtu generovaných hodnot jsem v několika případech získala odlišná řešení. V následujících tabulkách uvádím vždy nejlepší nalezené řešení (s nejvyšší hodnotou věrohodnostní funkce).

Tabulka 6.1 - Parametry modelů ARCH pro *DL_ISC_SA*, odhad za období II/1997 - III/2010

	ω	α_1	α_2	α_3
ARCH(1)	1,47E-05	0,766	-	-
	(0,002)	(0,054)	-	-
ARCH(2)	7,99E-06	0,873	0,127	-
	(0,003)	(1,000)	(0,269)	-
ARCH(3)	1,47E-05	0,765	4,88E-15	2,22E-16
	(0,002)	(0,054)	(1,000)	(1,000)

Zdroj: Vlastní výpočet

Tabulka 6.2 - Parametry a jejich významnosti modelů ARCH pro *DL_ISC_SA* za období II/1997 - III/2010

	Konstanta	DL_ISC_SA(-1)	Věrohodnostní funkce
ARCH(1)	0,003	0,479	196,829440
	(0,002)	(0,000)	
ARCH(2)	0,001	0,812	197,107788
	(0,233)	(0,000)	
ARCH(3)	0,003	0,479	196,829440
	(0,002)	(0,000)	

Zdroj: Vlastní výpočet

Ze třídy GARCH modelů jsem provedla odhady modelů GARCH(1,0), GARCH(2,0), GARCH(1,1), GARCH(1,2), GARCH(2,1) a GARCH(2,2). Hodnoty GARCH parametrů zvolených modelů a jejich významnosti jsou uvedeny v tabulce č. 6.3. Hodnoty zbylých parametrů modelů a hodnoty věrohodnostních funkcí jsou uvedeny v tabulce č. 6.4.

Tabulka 6.3 – Parametry modelů GARCH pro *DL_ISC_SA*, odhad za období II/1997 - III/2010

	ω	α_1	α_2	β_1	β_2
GARCH(1,0)	2,38E-05	-	-	0,252	-
	(0,999)	-	-	(1,000)	-
GARCH(2,0)	2,80E-05	-	-	0,086	0,035
	(0,997)	-	-	(1,000)	(1,000)
GARCH(1,1)	1,75E-05	0,727	-	-0,051	-
	(0,002)	(0,063)	-	(0,181)	-
GARCH(1,2)	1,75E-05	0,727	9,66E-15	-0,051	-
	(0,002)	(0,063	(1,000)	(0,181)	-
GARCH(2,1)	5,26E-06	0,685	-	0,315	1,97E-14
	(0,172)	(1,000)	-	(0,169)	(1,000)
GARCH(2,2)	2,71E-05	0,705	0,381	-0,556	-0,087
	(0,092)	(0,050)	(0,523)	(0,503)	(0,107)

Zdroj: Vlastní výpočet

Tabulka 6.4 - Parametry a jejich významnosti modelů GARCH pro *DL_ISC_SA*, odhad za období II/1997 - III/2010

	Konstanta	DL_ISC_SA(-1)	Věrohodnostní funkce
GARCH(1,0)	0,003	0,602	195,324040
	(0,003)	(0,000)	
GARCH(2,0)	0,003	0,602	195,324042
	(0,003)	(0,000)	
GARCH(1,1)	0,003	0,492	196,993239
	(0,000)	(0,000)	
GARCH(1,2)	0,003	0,492	196,993239
	(0,000)	(0,000)	
GARCH(2,1)	0,003	0,474	196,262021
	(0,001)	(0,000)	
GARCH(2,2)	0,003	0,424	197,827207
	(0,000)	(0,000)	

Zdroj: Vlastní výpočet

V ARCH modelech souhlasí všechny hodnoty ARCH parametrů s podmínkami z podkapitoly 4.1. V GARCH(1,1), GARCH(1,2) a GARCH(2,2) modelech nejsou splněny podmínky $\beta_i \geq 0$ pro $i = 1, 2$, aby byl podmíněný rozptyl h_t kladný.

Z tabulek č. 6.1 – 6.4 je zřejmé, že pro čtvrtletní časovou řadu indexů spotřebitelských cen za období II/1997 – III/2010 vyšel jako nejvhodnější model ARCH(1). V modelech ARCH s řádem $q > 1$ a zvolených GARCH modelech vycházela převážná většina parametrů statisticky nevýznamných. V modelu ARCH(2) pak byla statisticky nevýznamná dokonce konstanta, jak je možné vidět v tabulce č. 6.2.

Dle statistické významnosti parametrů přichází v úvahu pro hlubší analýzu pouze model ARCH(1). Tento model jsem tedy dále testovala a na jeho základě prováděla predikci.

6.1.1 Odhad modelu ARCH(1) a predikce – odhad modelu v jednom kroku

Při použití různých počátečních hodnot bylo dosaženo maxima věrohodnostní funkce s hodnotou 196,82944. V ARCH(1) modelu jsou na 5% hladině významnosti statisticky významné všechny parametry, kromě parametru α_1, který je statisticky významný až na 10% hladině významnosti. Odhad modelu ARCH(1) na datech II/1997 – III/2010 je obsažen v příloze č. 31. Shrnutí výstupů je k nahlédnutí v tabulce č. 6.5.

Tabulka 6.5 - Odhad modelu ARCH(1) na datech II/1997 - III/2010

	Odhad parametru	Směrodatná odchylka odhadu	Robustní směrodatná odchylka	t-hodnota	t-pravděpodobnost
DL_ISC_SA(-1)	0,479	0,082	0,103	4,64	0,000
Konstanta	2,59E-03	8,26E-04	7,96E-04	3,26	0,002
ω	1,47E-05	5,25E-06	4,40E-06	3,34	0,002
α_1	0,766	0,348	0,388	1,97	0,054

Zdroj: Vlastní výpočet

Obrázek č. 6.1 obsahuje diagnostické testy modelu ARCH(1). Byla prokázána normalita reziduí a podmíněná homoskedasticita. Autokorelace prokázána nebyla. Obdobně vyšly i diagnostické testy ostatních odhadovaných modelů ARCH a GARCH.

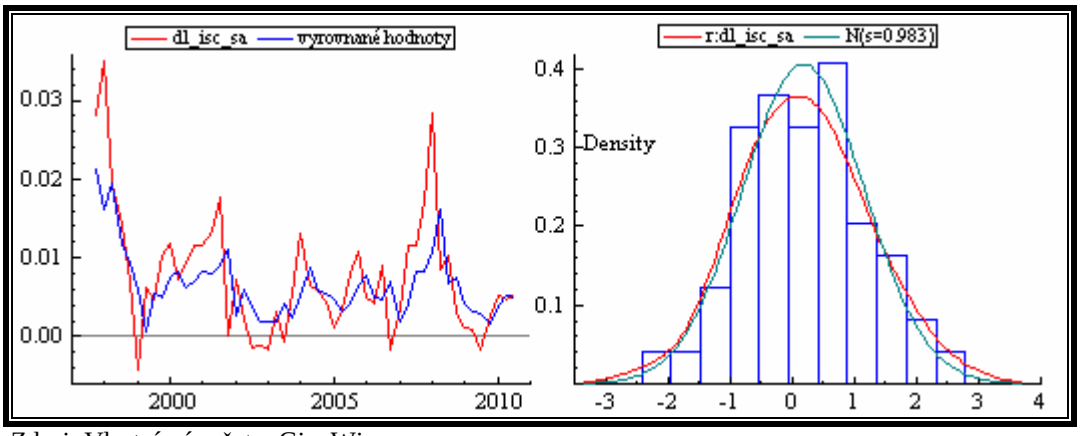
Obrázek 6.1 - Diagnostické testy modelu ARCH(1) pro data II/1997 - III/2010

```
Descriptive statistics for scaled residuals:
Asymptotic test:   Chi^2(2) = 0.087540 [0.9572]
Normality test:    Chi^2(2) =  0.56070 [0.7555]
ARCH 1-2 test:     F(2,44)  =  0.29312 [0.7474]
Portmanteau(12):   Chi^2(11)=   12.438 [0.3317]
```

Zdroj: Vlastní výpočet v GiveWin

Obrázek č. 6.2 vykresluje skutečné a modelem ARCH(1) vyrovnané hodnoty zkoumané časové řady. Dále je zde uveden histogram reziduí modelu ARCH(1).

Obrázek 6.2 - Skutečné a vyrovnané hodnoty a histogram reziduí pro ARCH(1) a data II/1997 – 1II/2010



Zdroj: Vlastní výpočet v GiveWin

Na základě odhadu modelu ARCH(1) pro data II/1997 – I/2010 jsem provedla predikci ex post. S využitím celé časové řady (II/1997 – III/2010) jsem posléze provedla predikci ex ante.

Pro účely predikce ex post byl model ARCH(1) odhadnut na datech II/1997 – I/2010. Výstupy odhadu jsou uvedeny v příloze č. 30, shrnutí v následující tabulce č. 6.6.

Tabulka 6.6 - Odhad modelu ARCH(1) na datech II/1997 - I/2010

	Odhad parametru	Směrodatná odchylka odhadu	Robustní směrodatná odchylka	t-hodnota	t-pravděpodobnost
DL_ISC_SA(-1)	0,477	0,087	0,104	4,59	0,000
Konstanta	2,61E-03	8,96E-04	8,47E-04	3,08	0,003
ω	1,69E-05	6,09E-06	4,86E-06	3,47	0,001
α_1	0,688	0,346	0,395	1,74	0,088

Zdroj: Vlastní výpočet

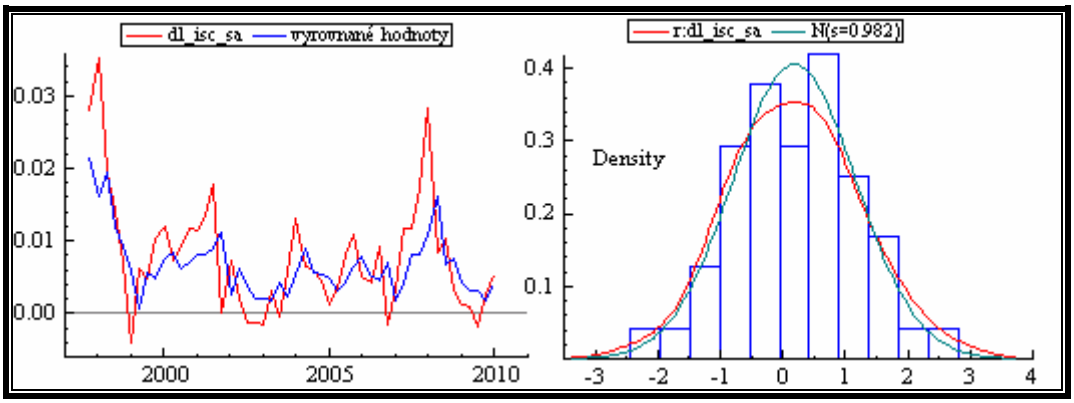
Obrázek č. 6.3 obsahuje diagnostické testy modelu ARCH(1) pro data II/1997 – I/2010. Obrázek č. 6.4 pak zachycuje skutečné a modelem ARCH(1) vyrovnané hodnoty modelované časové řady. Je zde uveden také histogram reziduí modelu ARCH(1).

Obrázek 6.3 - Diagnostické testy modelu ARCH(1) pro data II/1997 – I/2010

```
Descriptive statistics for scaled residuals:
Asymptotic test:   Chi^2(2) =   0.14253 [0.9312]
Normality test:    Chi^2(2) =   0.48778 [0.7836]
ARCH 1-2 test:     F(2,42)  =   0.37196 [0.6916]
Portmanteau(12):   Chi^2(11)=    11.840 [0.3758]
```

Zdroj: Vlastní výpočet v GiveWin

Obrázek 6.4 – Skutečné a vyrovnané hodnoty a histogram reziduí modelu ARCH(1) pro data II/1997 - I/2010



Zdroj: Vlastní výpočet v GiveWin

Výstupy bodové predikce ex post jsou uvedeny v tabulce č. 6.7. Predikce byla provedena pro dvě období – II/2010 a III/2010. Jsou zde zachyceny skutečné hodnoty, hodnoty predikované (převedené na úrovňové hodnoty) a procentní odchylky predikce od reality. Na základě procentních odchylek je možné konstatovat, že bodový odhad je poměrně přesný. Odchylka od skutečnosti v období II/2010 činí 0,04 %, v období III/2010 pak 0,01 %. Směrodatné chyby odhadů jsou uvedeny pro transformovanou časovou řadu, tj. pro *DL_ISC_SA*. Předpověď proměnné *DL_ISC_SA* nepřepočtená na úrovňové hodnoty činí

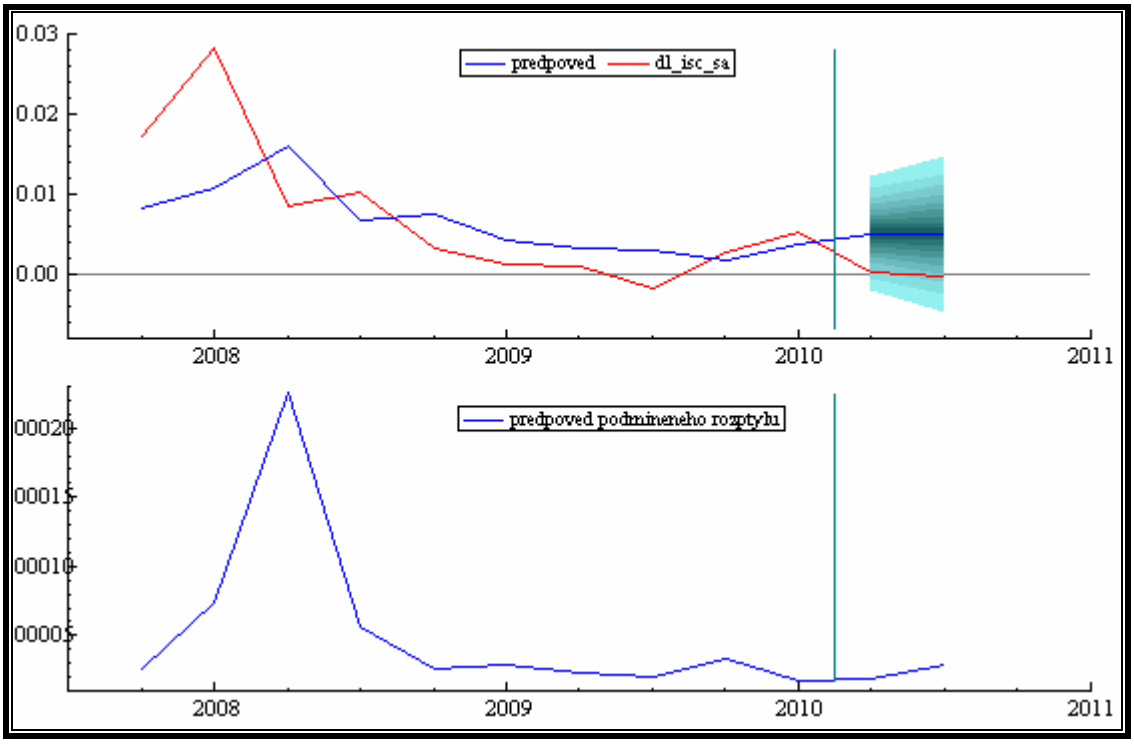
0,0051050 pro období II/2010 a 0,0050488 pro období III/2010. Na obrázku č. 6.5 jsou zachyceny grafické předpovědi proměnné *DL_ISC_SA* a podmíněného rozptylu.

Tabulka 6.7 - Predikce ex post pro model ARCH(1) a data II/1997 - I/2010

	ISC	ISC_PRE	Odchylka v %	Směrodatná chyba odhadu
IV/2009	113,38	113,38		
I/2010	113,97	113,97		
II/2010	**114,52**	**114,56**	0,04%	0,004
III/2010	**115,13**	**115,14**	0,01%	0,006

Zdroj: Vlastní výpočet

Obrázek 6.5 - Predikce ex post proměnné *DL_ISC_SA* a podmíněného rozptylu na období II-III/2010



Zdroj: Vlastní výpočet v GiveWin

Predikce ex ante byla provedena na dvě období dopředu - IV/2010 a I/2011. Bodová predikce indexu spotřebitelských cen v úrovňových hodnotách je obsažena v tabulce č. 6.8. Uvedené směrodatné chyby odhadů se týkají proměnné *DL_ISC_SA*. Předpověď proměnné *DL_ISC_SA* nepřepočtená na úrovňové hodnoty činí 0,0051424 pro období IV/2010 a 0,0050551 pro období I/2011.

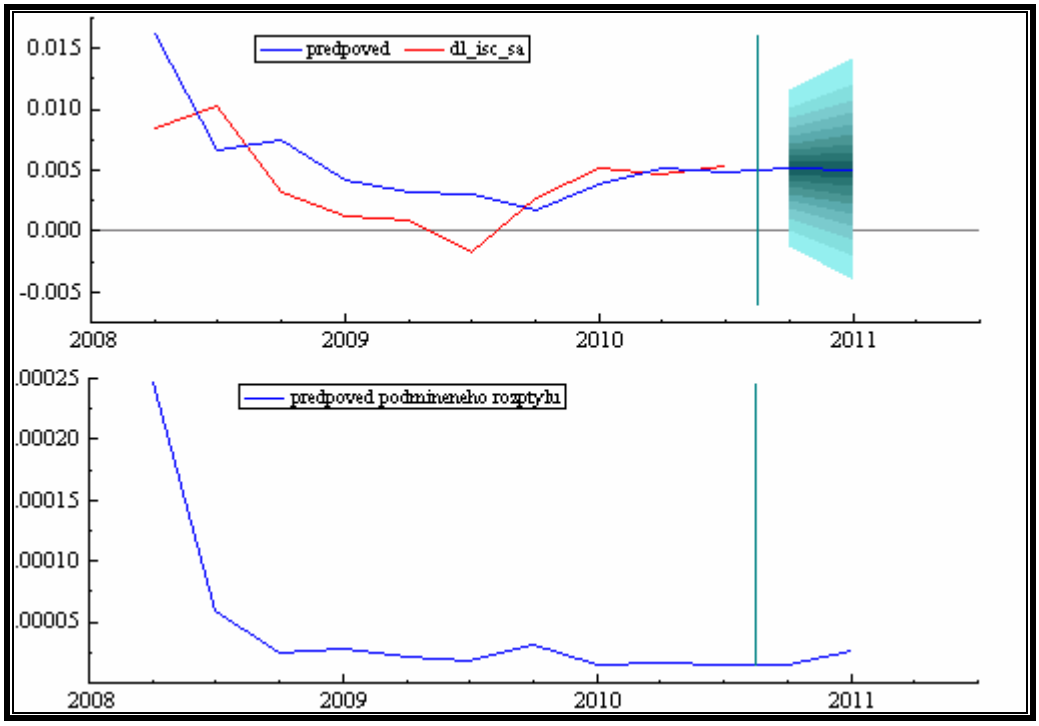
Tabulka 6.8 - Predikce ex ante pro model ARCH(1) a data II/1997 - III/2010

	ISC	Směrodatná chyba odhadu
IV/2010	115,72	0,004
I/2011	116,31	0,006

Zdroj: Vlastní výpočet

Dle bodové predikce ex ante by měla inflace ve formě bazického indexu dosáhnout ve čtvrtém čtvrtletí roku 2010 hodnoty 115,72 a v prvním čtvrtletí roku 2011 hodnoty 116,31. Báze je rok 2005. Grafické výstupy predikce ex ante proměnné *DL_ISC_SA* a podmíněného rozptylu jsou vykresleny na obrázku č. 6.6.

Obrázek 6.6 - Předpověď ex ante proměnné *DL_ISC_SA* a podmíněného rozptylu na období IV/2010 - I/2011



Zdroj: Vlastní výpočet v GiveWin

6.2 Modely ARCH a GARCH – odhad modelu ve dvou krocích

Vzhledem k často vyskytovanému problému s hledáním globálního maxima věrohodnostní funkce při odhadech úplného modelu v jednom kroku, jak jsem uvedla v podkapitole 6.1, jsem rozdělila model na dvě části. Rozdělením odhadu úplného modelu na rovnici podmíněného průměru a rovnici podmíněného rozptylu došlo ke zlepšení hledání optima při řešení jednotlivých modelů.

Základní model (4.2) má tvar AR(1) procesu s konstantou

$$DL_ISC_SA_t = c + \Phi DL_ISC_SA_{t-1} + u_t, \quad t = 1, 2, ..., 53, \tag{6.1}$$

kde u_t je náhodná složka a při splnění podmínky $|\Phi| < 1$ je proces AR(1) stacionární.

Analýzu jsem prováděla opět pro sezónně očištěnou čtvrtletní časovou řadu indexu spotřebitelských cen převedenou na první diference logaritmů (*DL_ISC_SA*).

Odhad AR(1) modelu (6.1) pro proměnnou *DL_ISC_SA* a období II/1997 – III/2010 je obsažen na obrázku č. 6.7 (odhad modelu metodou maximální věrohodnosti). Zde jsou AR člen pro první zpoždění a konstanta *c* statisticky významné. Při odhadu AR(2) procesu již byl AR člen pro druhé zpoždění statisticky nevýznamný. Na obrázku č. 6.7 jsou zachyceny také diagnostické testy AR(1) modelu. Normalita je splněna, autokorelace a podmíněná heteroskedasticita prokázány nebyly.

Obrázek 6.7 - AR(1) proces pro proměnnou *DL_ISC_SA* a období II/1997 - III/2010

```
The estimation sample is:  1997 (3) - 2010 (3)
The dependent variable is: dl_isc_sa

                 Coefficient  Std.Error  t-value  t-prob
AR-1                0.760926     0.1078     7.06   0.000
Constant          0.00977383   0.003478     2.81   0.007

log-likelihood     191.996977
no. of observations        53  no. of parameters          3
AIC.T             -377.993954  AIC               -7.1319614
mean(dl_isc_sa)    0.00828264  var(dl_isc_sa)   7.77205e-005
sigma              0.00641136  sigma^2          4.11055e-005

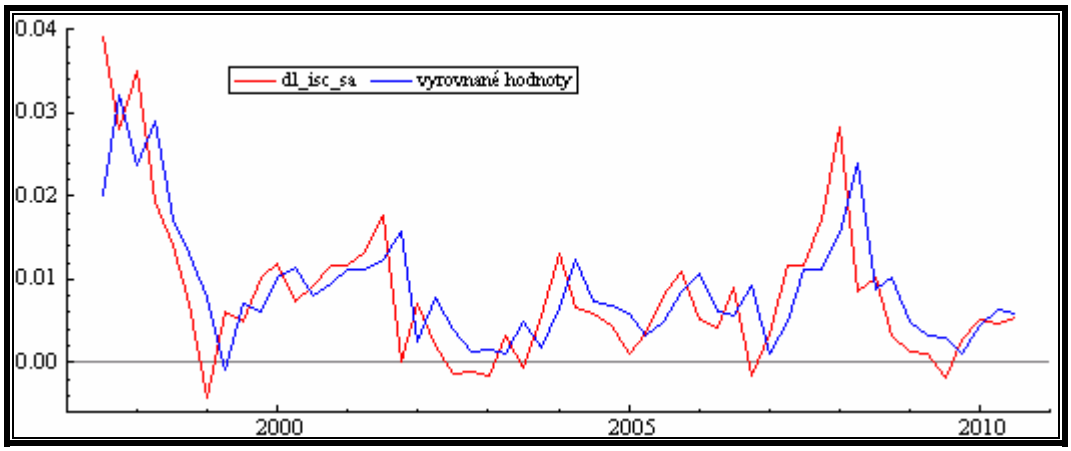
Descriptive statistics for residuals:
Normality test:   Chi^2(2) =   5.6551 [0.0592]
ARCH 1-1 test:    F(1,49)  =  0.65108 [0.4236]
Portmanteau(12):  Chi^2(11)=   11.791 [0.3795]
```

Zdroj: Vlastní výpočet v GiveWin

Hodnota parametru Φ = 0,761 odpovídá podmínce stacionarity procesu.

Na obrázku č. 6.8 jsou vykresleny skutečné hodnoty diferencí logaritmů sezónně očištěné časové řady indexu spotřebitelských cen a hodnoty vyrovnané AR(1) procesem aplikovaným na data II/1997 – III/2010.

Obrázek 6.8 - Skutečné a vyrovnané hodnoty proměnné *DL_ISC_SA* modelem AR(1), data II/1997 - III/2010



Zdroj: Vlastní výpočet v GiveWin

Přestože v modelu AR(1) nebyla prokázána podmíněná heteroskedasticita, aplikovala jsem na získaná rezidua modely volatility. Provedla jsem odhady vybraných modelů ARCH a GARCH. K odhadu jsem opět použila software GiveWin 2.10, moduly PcGive 10.0 a OxPack 3.1.

Z modelů typu ARCH jsem provedla odhady modelů ARCH(1), ARCH(2), ARCH(3). Hodnoty parametrů těchto modelů, jejich statistické významnosti a hodnoty věrohodnostních funkcí jsou uvedeny v tabulce č. 6.9.

Tabulka 6.9 - Parametry a jejich významnosti modelů ARCH pro *DL_ISC_SA* za období II/1997 - III/2010

	ω	α_1	α_2	α_3	Věrohodnostní funkce
ARCH(1)	1,76E-05	0,884	-	-	194,248945
	(0,000)	(0,027)	-	-	
ARCH(2)	1,12E-05	0,871	0,129	-	195,531179
	(0,013)	(1,000)	(0,218)	-	
ARCH(3)	1,12E-05	0,871	0,129	4,44E-16	195,531179
	(0,004)	(1,000)	(1,000)	(1,000)	

Zdroj: Vlastní výpočet

Ze třídy GARCH modelů jsem provedla odhady modelů GARCH(1,0), GARCH(2,0), GARCH(1,1), GARCH(1,2), GARCH(2,1) a GARCH(2,2). Hodnoty ARCH a GARCH parametrů zvolených modelů a jejich významnosti jsou uvedeny v tabulce č. 6.10. Jsou zde obsaženy také hodnoty věrohodnostních funkcí odhadů jednotlivých modelů.

Tabulka 6.10 - Parametry a jejich významnosti modelů GARCH pro *DL_ISC_SA*, odhad za období II/1997 - III/2010

	ω	α_1	α_2	β_1	β_2	Věrohodnostní funkce
GARCH(1,0)	1,67E-06	-	-	0,946	-	192,940004
	(0,890)	-	-	(0,009)	-	
GARCH(2,0)	1,67E-06	-	-	0,945	0,001	192,939932
	(0,994)	-	-	(0,995)	(1,000)	
GARCH(1,1)	9,77E-06	0,876	-	0,124	-	195,413369
	(0,061)	(1,000)	-	(0,270)	-	
GARCH(1,2)	1,56E-05	0,902	0,400	-0,302	-	195,657829
	(0,140)	(1,000)	(0,572)	(0,521)	-	
GARCH(2,1)	9,77E-06	0,876	-	0,124	0,000	195,413369
	(0,061)	(1,000)	-	(0,270)	(1,000)	
GARCH(2,2)	2,33E-05	0,891	0,865	-0,891	0,135	196,377180
	(0,055)	(1,000)	(1,000)	(0,000)	(0,207)	

Zdroj: Vlastní výpočet

V ARCH modelech souhlasí parametry s podmínkami, které jsou uvedeny v podkapitole 4.1. V GARCH(1,2) a GARCH(2,2) modelech pak nejsou splněny podmínky $\beta_i \geq 0$ pro $i = 1, 2$, aby byl podmíněný rozptyl h_t kladný. Závěry jsou tedy obdobné jako v podkapitole 6.1.

Z tabulek č. 6.9 a 6.10 je evidentní, že i při rozdělení odhadu modelu do dvou kroků, tj. na odhad rovnice podmíněného průměru a rovnice podmíněného rozptylu zvlášť, je pro čtvrtletní časovou řadu indexu spotřebitelských cen *DL_ISC_SA* za období II/1997 – III/2010 nejvhodnější model ARCH(1), obdobně jako při odhadu úplného modelu v jednom kroku. V ostatních modelech ARCH s řádem $q > 1$ a ve zvolených GARCH modelech vycházelo obecně mnoho statisticky nevýznamných ARCH a GARCH parametrů.

Provedla jsem podrobnější analýzu modelu ARCH(1). Tento model jsem dále testovala a na jeho základě provedla predikci podmíněných rozptylů a intervalovou predikci inflace.

6.2.1 Odhad modelu ARCH(1) a predikce – odhad modelu ve dvou krocích

Nejdříve jsem aplikovala model ARCH(1) na rezidua AR(1) procesu, jehož výstupy jsou obsaženy na obrázku č. 6.7 výše (data II/1997 – III/2010). Při odhadu bylo dosaženo maxima věrohodnostní funkce s hodnotou 194,248945. Výstupy odhadu jsou obsaženy v příloze č. 34. Přehled výsledků odhadu je zachycen v tabulce č. 6.11.

Tabulka 6.11 - Odhad modelu ARCH(1) na datech II/1997 - III/2010

	Odhad parametru	Směrodatná odchylka odhadu	Robustní směrodatná odchylka	t-hodnota	t-pravděpodobnost
ω	1,76E-05	6,31E-06	3,90E-06	4,51	0,000
α_1	0,884	0,381	0,388	2,28	0,027

Zdroj: Vlastní výpočet

Obrázek č. 6.9 obsahuje diagnostické testy modelu ARCH(1). Byla prokázána normalita reziduí a podmíněná homoskedasticita. Autokorelace prokázána nebyla.

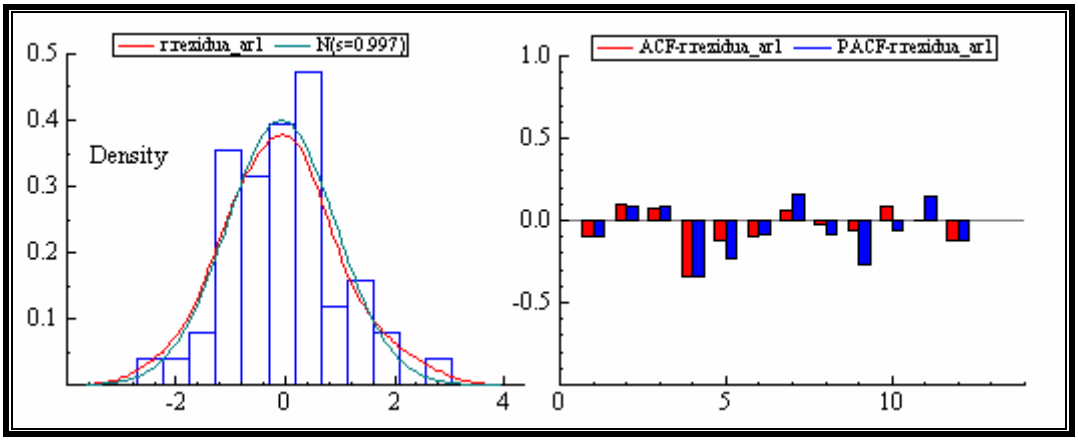
Obrázek 6.9 - Diagnostické testy modelu ARCH(1), data II/1997 - III/2010

```
Descriptive statistics for scaled residuals:
Normality test:    Chi^2(2) =    1.2286 [0.5410]
Asymptotic test:   Chi^2(2) =   0.49744 [0.7798]
ARCH 1-2 test:     F(2,47)  =   0.81714 [0.4479]
Portmanteau(12):   Chi^2(12)=    10.756 [0.5500]
```

Zdroj: Vlastní výpočet v GiveWin

Obrázek č. 6.10 vykresluje histogram reziduí modelu ARCH(1), autokorelační funkci a parciální autokorelační funkci.

Obrázek 6.10 - Histogram reziduí modelu ARCH(1) a ACF a PACF funkce, data II/1997 – III/2010



Zdroj: Vlastní výpočet v GiveWin

Na základě odhadu modelu AR(1) z dat II/1997 – I/2010 (příloha. č. 33) jsem provedla predikci ex post na období II/2010 a III/2010. Posléze jsem aplikací shodného modelu na data II/1997 – III/2010 provedla předpověď ex ante.

Výstupy bodové predikce ex post jsou uvedeny v tabulce č. 6.12. Jsou zde uvedeny skutečné hodnoty, hodnoty predikované a procentní odchylky predikce od reality. Na základě procentních odchylek je možné konstatovat, že odhad je poměrně kvalitní. Pro druhé čtvrtletí roku 2010 se liší bodová předpověď od skutečnosti o 0,16 % a pro třetí čtvrtletí roku 2010 o 0,35 %. Tabulka č. 6.12 obsahuje také směrodatné chyby bodových odhadů (směrodatné

chyby odhadů platí pro nepřepočtené hodnoty předpovědi, tedy pro *DL_ISC_SA*). Hodnoty předpovědí proměnné *DL_ISC_SA* činí 0,0063568 pro období II/2010 a 0,0072167 pro období III/2010.

Tabulka 6.12 - Predikce ex post na období II-III/2010 pro model AR(1) a data II/1997 - I/2010

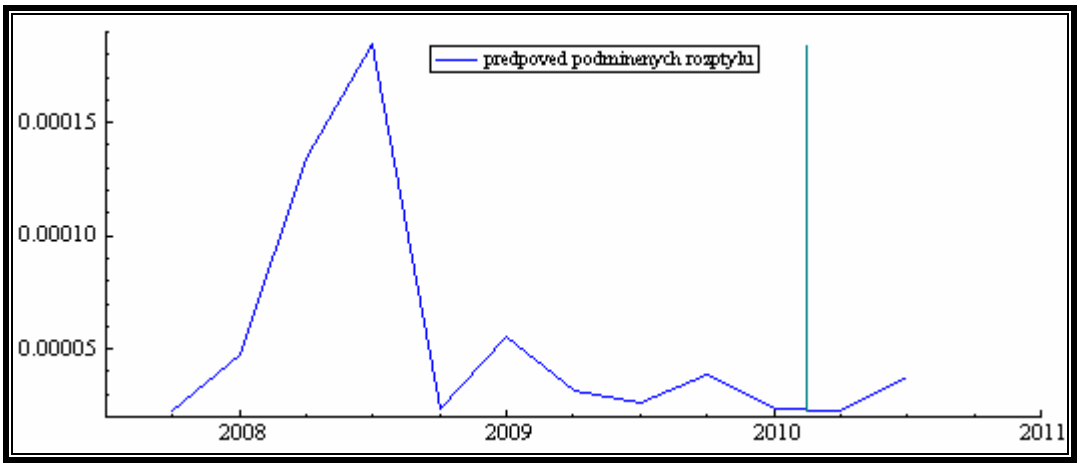
	ISC	ISC_PRE	Odchylka v %	Směrodatná chyba odhadu
IV/2009	113,38	113,38		
I/2010	113,97	113,97		
II/2010	**114,52**	**114,70**	0,16%	0,007
III/2010	**115,13**	**115,53**	0,35%	0,008

Zdroj: Vlastní výpočet

Grafické výstupy predikce ex post proměnné *DL_ISC_SA* na období II/2010 a III/2010 jsou uvedeny v příloze č. 35.

Modelování podmíněné heteroskedasticity má význam při konstrukci intervalových předpovědí. Umožňuje předvídat proměnlivou směrodatnou chybu, čímž se může intervalová předpověď zúžit. Předpověď podmíněných rozptylů na základě aplikace ARCH(1) modelu (odhad je uveden v příloze č. 32) na rezidua AR(1) procesu a data II/1997 – I/2010 je obsažena na obrázku č. 6.11. Podmíněné směrodatné chyby předpovědí[38] jsou 0,0047626 pro období II/2010 a 0,0061484 pro období III/2010.

Obrázek 6.11 - Předpověď podmíněných rozptylů na základě modelu ARCH(1), data II/1997 – I/2010



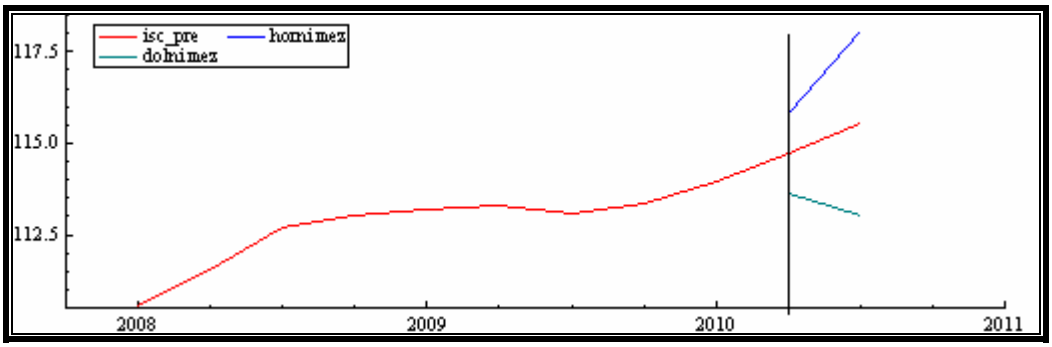
Zdroj: Vlastní výpočet v GiveWin

Intervalová předpověď[39] je obsažena na obrázku č. 6.12.

[38] Směrodatné chyby předpovědí jsou získány jako odmocniny z předpovědí podmíněných rozptylů z obrázku č. 6.11.

[39] Intervalová předpověď je konstruována na základě směrodatných chyb odhadů. Pro 95% intervalovou předpověď získáme horní mez přičtením dvojnásobku směrodatné chyby odhadu k bodové předpovědi a dolní mez odečtením dvojnásobku směrodatné chyby odhadu od bodové předpovědi.

Obrázek 6.12 - Intervalová předpověď pro proměnnou *ISC_SA* na období II-III/2010, model ARCH(1) odhadnutý na datech II/1997 – I/2010



Zdroj: Vlastní výpočet v GiveWin

Predikci ex ante jsem konstruovala na základě odhadu modelu AR(1) pro data II/1997 – III/2010. Predikce byla provedena na dvě období dopředu – IV/2010 a I/2011. Bodové odhady byly přepočítány na úrovňové hodnoty indexu spotřebitelských cen. Výsledky jsou obsaženy v tabulce č. 6.13. Jsou zde uvedeny také směrodatné chyby odhadů (platí pro nepřepočtené hodnoty předpovědí, tedy pro *DL_ISC_SA*). Hodnoty bodové predikce proměnné *DL_ISC_SA* činí 0,0063884 pro období IV/2010 a 0,0071978 pro období I/2011.

Tabulka 6.13 - Predikce ex ante pro model AR(1) a data II/1997 - III/2010

	ISC	Směrodatná chyba odhadu
IV/2010	115,87	0,006
I/2011	116,70	0,008

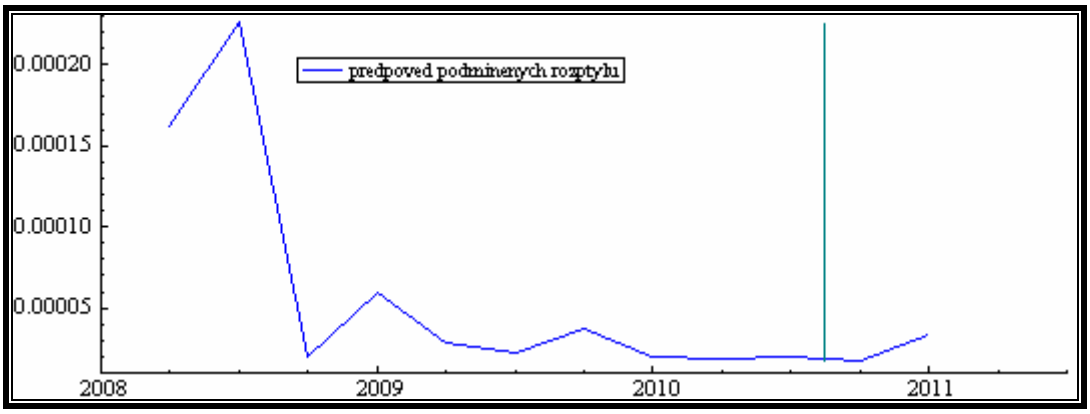
Zdroj: Vlastní výpočet

Grafické výstupy predikce ex ante proměnné *DL_ISC_SA* jsou obsaženy v příloze č. 36.

Dle bodové predikce ex ante by měla inflace ve formě bazického indexu dosáhnout ve čtvrtém čtvrtletí roku 2010 hodnoty 115,87 a v prvním čtvrtletí roku 2011 hodnoty 116,70. Báze je rok 2005.

Aplikace modelu ARCH(1) na rezidua regrese (6.1) a období II/1997 – III/2010 je obsažena v příloze č. 34. Tohoto odhadu jsem dále využila pro předpověď podmíněných rozptylů na období IV/2010 a I/2011, která je uvedena na obrázku č. 6.13.

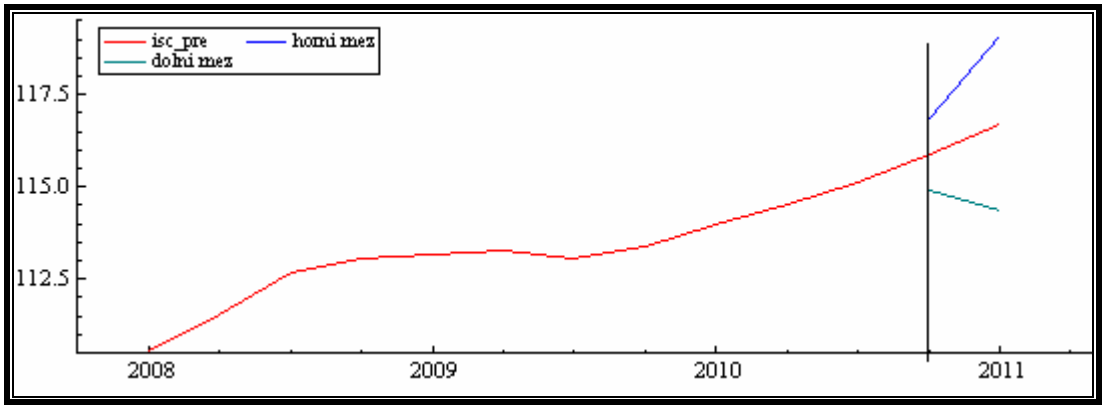
Obrázek 6.13 - Předpověď podmíněných rozptylů na základě modelu ARCH(1), data II/1997 – III/2010



Zdroj: Vlastní výpočet v GiveWin

Podmíněné směrodatné chyby předpovědí jsou 0,0042341 pro období IV/2010 a 0,0057812 pro období I/2011. Grafické výstupy 95% intervalové predikce ex ante pro období IV/2010 a I/2011 a proměnnou *DL_ISC_SA* na základě modelu ARCH(1) jsou vykresleny na následujícím obrázku č. 6.14.

Obrázek 6.14 - Intervalová předpověď pro proměnnou *ISC_SA* na období IV/2010 a I/2011, model ARCH(1) odhadnutý na datech II/1997 – III/2010



Zdroj: Vlastní výpočet v GiveWin

V obou případech předpovědí, ex post i ex ante, vyšly směrodatné chyby předpovědí získané aplikací modelu ARCH(1) na rezidua regrese (6.1) poměrně vysoké. To je příčinou širokých intervalových předpovědí inflace z obrázků 6.12 a 6.14.

7 ZÁVĚR

Cílem této diplomové práce bylo aplikovat dvě ekonometrické koncepce modelování časových řad, VAR modely a modely volatility časových řad ARCH a GARCH, a zjištění, zda jsou tyto přístupy aplikovatelné na reálná data české ekonomiky.

Ačkoliv se na základě analýzy predikce ex post jeví oba přístupy jako poměrně kvalitní, je nutné konstatovat, že v průběhu výpočtů vyvstalo napovrch hned několik problémů, které je činí méně atraktivními a použitelnými. Co se týká VAR modelů, jako negativní stránku jejich aplikace na makroekonomická data obecně hodnotím nutnost stacionarity použitých časových řad, které jsou v realitě zpravidla nestacionární. Stacionarizací ztrácíme značnou část informace, která je pro kvalitní předpověď jejich vývoje podstatná. Zásadním problémem VAR modelů je ovšem kointegrace, která je pro makroekonomické veličiny velmi typická. S problémy jsem se setkávala nejen při zjišťování kointegrace a odhadování kointegračních vektorů, ale také při snaze o přechod na model korekce chyby. V souvislosti s odhady VAR modelů vyhodnotila všechna zvažovaná kritéria pro česká data jako nejvhodnější model VAR(1). Předpokládala jsem, že optimální bude zahrnutí dvou zpoždění.

Další překážka, se kterou jsem se často setkávala, byly negativní výsledky diagnostických testů. Největší problém činil požadavek normality, jehož nesplnění znesnadňuje odhady, testy hypotéz o parametrech, intervalové předpovědi ad. (*t*-statistiky nemusí mít *t* rozdělení, *F*-statistiky nemusí mít *F* rozdělení ad.). Nenormalita bývá často způsobena odlehlými pozorováními, z tohoto důvodu však byla do VAR modelů zahrnuta dummy proměnná. Nenormalita může souviset s existencí heteroskedasticity, se kterou jsem se také často setkávala. Problémy však činila i autokorelace, která ovšem zpravidla s dynamizací modelů vymizela.

Co se týká modelů ARCH a GARCH, nepovažuji jejich aplikaci na modelování volatility inflace v ČR jako příliš efektivní. Tento závěr podporuje také fakt, že při odhadech v rámci šesté kapitoly skončila převážná většina modelů ARCH i GARCH jako nevhodná, s mnoha statisticky nevýznamnými parametry. Jedním z důvodů může být nepříliš vysoká proměnlivost volatility inflace v ČR v čase. V čase proměnlivá volatilita je základní myšlenkou, na které jsou modely ARCH a GARCH založeny, bez jejího splnění nemá jejich užití příliš velký smysl. S aplikací režimu cílování inflace logicky souvisí fakt, že míra inflace nemusí příliš kolísat. Očekávala jsem, že by tento problém mohl být do jisté míry vyvrácen probíhající finanční krizí, to se ovšem nepotvrdilo, k výraznějšímu rozkolísání inflace dosud nedošlo.

Přesvědčivé výsledky bodových predikcí ex post na základě obou metodologií považuji za důsledek nepříliš proměnlivého vývoje nejen inflace, ale i ostatních ukazatelů, vyskytujících se ve VAR modelech v rámci páté kapitoly. Ve všech případech předpovědí

však vyšly směrodatné chyby odhadů poměrně vysoké, což je příčinou širokých intervalových předpovědí.

Obecně lze říci, že při ekonometrickém modelování zakládajícím se na čtvrtletních datech většiny makroekonomických veličin české ekonomiky může vyvstat řada nepříjemností souvisejících s faktem, že jsou tyto časové řady poměrně krátké a často nesourodé. Tato nesourodost je způsobena především různými transformacemi české ekonomiky, kterými v minulosti prošla, jako je například přechod na tržní ekonomiku, vstup do EU nebo již zmíněný přechod na režim cílování inflace ad. Další poznámka, kterou je nutné zmínit, je, že predikce je utvářena na základě modelů a modely jsou vždy určitým zjednodušením reality (někdy dosti podstatným). Nemohou tedy logicky obsáhnout všechny faktory, které zkoumané proměnné a jejich okolí ovlivňují (např. aktuálně doznívající finanční krizi žádný model předvídat nemohl). Další problém je také podstatné odtržení od původních hodnot, kterého je dosaženo očišťováním od sezónnosti, logaritmováním a následným diferencováním časových řad.

VAR modely vzbudily na počátku jejich vzniku velké nadšení, zejména v oblasti prognózování. Toto nadšení však s postupem času ustoupilo a to především v souvislosti se zkoumáním kointegrace.

V současné době je již k dispozici hodnota indexu spotřebitelských cen pro čtvrté čtvrtletí roku 2010. Tuto hodnotu jsem na základě všech zvolených modelů v páté a šesté kapitole (modelů VAR(1) a ARCH(1)) odhadovala v rámci predikce ex ante a je tedy možné skutečnou hodnotu s provedenými predikcemi porovnat. Zatímco cenová hladina vzrostla z hodnoty 114,98 na hodnotu 115,24 mezi druhým a třetím čtvrtletím roku 2010, ve čtvrtém čtvrtletí došlo k poklesu na hodnotu 114,94. Bodová předpověď na základě VAR(1) modelu činí 115,51 (podkapitola 5.2.4), na základě ARCH(1) modelu odhadovaného v jednom kroku (podkapitola 6.1.1) byla získána hodnota 115,72 a na základě AR(1) modelu (podkapitola 6.2.1) pak hodnota 115,87. Je tedy zřejmé, že ve všech případech dochází k odchýlení od reality. Zatímco ve skutečnosti došlo k nepatrnému poklesu indexu spotřebitelských cen, všechny použité modely předpovídají růst tohoto ukazatele. Nejblíže skutečnosti je předpověď ex ante získaná aplikací VAR(1) modelu (predikce ex post byla totiž oproti skutečnosti nepatrně podhodnocená, na rozdíl od modelů volatility). Měsíční indexy spotřebitelských cen však v lednu (116,3) a únoru (116,4) roku 2011 opět vzrostly a tak se zřejmě získaná predikce ex ante na první čtvrtletí roku 2011 opět přiblíží realitě.

SEZNAM LITERATURY

[1] ARLT, J.: *Moderní metody modelování ekonomických časových řad.* Praha: Grada, 1999. ISBN 80-7169-539-4.

[2] ARLT, J. – ARLTOVÁ, M.: *Ekonomické časové řady.* Praha: Professional Publishing, 2009. ISBN 978-80-86946-85-6.

[3] ARLT, J. – ARLTOVÁ, M. – RUBLÍKOVÁ, E.: *Analýza ekonomických časových řad s příklady.* Praha: Vysoká škola ekonomická v Praze, 2002. ISBN 80-245-0307-7.

[4] ARLT, J. – RADKOVSKÝ, Š.: Význam modelování a předpovídání volatility časových řad pro tvorbu měnové politiky centrální banky. Výzkumná publikace ČNB, 1999, č. 13, 46 str.

[5] CIPRA, T: *Finanční ekonometrie.* Praha: EKOPRESS, s.r.o., 2008. ISBN 978-80-86929-43-9.

[6] Česká národní banka: *Cílování inflace v ČR* [online]; cit. [16.1.2011]; dostupné z www: [http://www.cnb.cz/cs/menova_politika/cilovani.html].

[7] Česká národní banka: *Komentář ČNB ke zveřejněným údajům o vývoji inflace v lednu roku 2011* [online]; cit. [16.1.2011]; dostupné z www: [http://www.cnb.cz/cs/verejnost/pro_media/stanoviska/stanoviska_2011/11_01_inflace.html].

[8] Česká národní banka: *Měnová politika České národní banky* [online]; cit. [16.1.2011]; dostupné z www: [http://www.cnb.cz/miranda2/export/sites/www.cnb.cz/cs/verejnost/publikace/download/10065_CNB_Fact_sheet_2010_CZ_web.pdf].

[9] Česká národní banka: *Transmisní mechanismus měnové politiky* [online]; cit. [16.1.2011]; dostupné z www: [http://www.cnb.cz/cs/faq/transmisni_mechanismus_mp.html].

[10] Česká národní banka: *Zpráva o inflaci / I_2011* [online]; cit. [16.1.2011]; dostupné z www: [http://www.cnb.cz/miranda2/export/sites/www.cnb.cz/cs/menova_politika/zpravy_o_inflaci/2011/2011_I/download/zoi_I_2011.pdf].

[11] Český statistický úřad: *Indexy spotřebitelských cen – metodická příručka* [online]; cit. [16.1.2011]; dostupné z www: [http://www.czso.cz/csu/redakce.nsf/i/isc_metodicka_prirucka/$File/manual_isc_2011.pdf].

[12] DORNBUSCH, R. – FISCHER, S.: *Makroekonomie.* Praha: Státní pedagogické nakladatelství, 1994. ISBN 80-04-25556-6.

[13] ENGLE, R.: Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of UK Inflation. *Econometrica*, 1982, Vol. 50, No. 4, s. 987-1007.

[14] HEDIJA, V. - MUSIL, P.: *Praktikum makroekonomie.* Plzeň: Aleš Čeněk, s.r.o., 2009. ISBN 978-80-7380-158-8.

[15] HOLMAN, R.: *Mikroekonomie - středně pokročilý kurz.* Praha: C. H. Beck, 2002. ISBN 80-7179-737-5.

[16] HOLMAN, R.: *Makroekonomie - středně pokročilý kurz.* Praha: C. H. Beck, 2010. ISBN 978-80-7179-861-3.

[17] HUŠEK, R.: *Ekonometrická analýza.* Praha: Oeconomica, 2007. ISBN 978-80-245-1300-3.

[18] HUŠEK, R.: *Aplikovaná ekonometrie: teorie a praxe.* Praha: Oeconomica, 2009. ISBN 978-80-245-1623-3.

[19] CHVÁLOVÁ, J.: Inflace – jak se měří a vývoj v letech 1996 až 2001. *Bulletin*, roč. 2002, č. 8; [online]; cit. [16.1.2011];dostupné z www:

[http://osz.cmkos.cz/CZ/Z_tisku/Bulletin/08_2002/index.html].

[20] LEJNAROVÁ, Š. – RÁČKOVÁ, A. - ZOUHAR, J.: *Základy ekonometrie v příkladech.* Praha: Oeconomica, 2009. ISBN 978-80-245-1564-9.

[21] MELECKÝ, M.: Komparace vybraných jednoduchých modelů inflace v podmínkách české ekonomiky. *Finance a úvěr*, 2001, roč. 51, č. 5, s. 265-279.

[22] **http://www.czso.cz**

[23] **http://www.cnb.cz**

[24] **http://www.estav.cz/finance/inflace.html**

[25] **http://www.pcgive.com/pcgive/index.html**

SEZNAM PŘÍLOH

Příloha 1: Oddíly spotřebního koše a počty cenových reprezentantů pro výpočet ISC v ČR. 63
Příloha 2: Váhy pro výpočet ISC v ČR od roku 2010 dle COICOP 63
Příloha 3: Inflační cíle ČNB stanovené v čisté inflaci 64
Příloha 4: Cílové pásmo stanovené v celkové inflaci v období leden 2002 – prosinec 2005 .. 64
Příloha 5: Inflační cíle ČNB 64
Příloha 6: Funkce ACF a PACF proměnných (sezónně očištěná pouze proměnná HDP) 65
Příloha 7: Časová řada ISC sezónně očištěná metodou X12 ARIMA 65
Příloha 8: Časová řada M2 sezónně očištěná metodou X12 ARIMA 66
Příloha 9: ADF test pro proměnnou *PRIBOR1R*, I/1997 – III/2010 66
Příloha 10: ADF test pro proměnnou *L_PRIBOR1R*, II/1997 – III/2010 66
Příloha 11: Odhad VAR(1) modelu pro data II/1997 – III/2010 67
Příloha 12: Rezidua modelu VAR(1) pro období II/1997 – III/2010 69
Příloha 13: ACF a PACF funkce pro rezidua modelu VAR(1) a období II/1997 – III/2010 ... 69
Příloha 14: Grangerovy testy kauzality pro model VAR(1) a data II/1997 – III/2010 70
Příloha 15: Analýza funkcí odezvy pro model VAR(1) a data II/1997 – III/2010 71
Příloha 16: Odhad modelu VAR(1) a data II/1997 – III/2010 (logaritmované časové řady) ... 71
Příloha 17: Testování stacionarity v modelu VAR(1), logaritmované časové řady a data II/1997 – III/2010 73
Příloha 18: Johansenův test kointegrace (Trace test) pro model VAR(1), II/1997 – III/2010 (logaritmované časové řady) 74
Příloha 19: Odhad kointegračních vektorů po restrikcích pro model VAR(1) a data II/1997 – III/2010 (logaritmované časové řady) 75
Příloha 20: Odhad statické regrese (5.7) na datech II/1997– III/2010 76
Příloha 21: Test kointegrace regrese (5.7) 77
Příloha 22: Odhad parametrů MKCH (5.9) 77
Příloha 23: Bodová a intervalová předpověď ex post na období II-III/2010 na základě modelu VAR(1) a období II/1997 – I/2010 (bez sezónních proměnných) 78
Příloha 24: Skutečné a predikované hodnoty časových řad na období II-III/2010 na základě VAR(1) modelu pro období II/1997 - I/2010 (bez sezónních proměnných) 78
Příloha 25: VAR(1) model pro období II/1997 – I/2010 (bez sezónních proměnných) 79
Příloha 26: Bodová a intervalová předpověď ex ante na období IV/2010 a I/2011 pro VAR(1) model a období II/1997 – III/2010 (bez sezónních proměnných) 80
Příloha 27 - Směrodatné chyby odhadů predikce ex post (nepřepočtené na úrovňové hodnoty), VAR(1) a data II/1997 – I/2010 81
Příloha 28 - Směrodatné chyby odhadů predikce ex ante (nepřepočtené na úrovňové hodnoty), VAR(1) a data II/1997 – III/2010 81
Příloha 29: Diagnostické testy pro proměnnou *DL_ISC_SA*, období II/1997 - III/2010 81

Příloha 30: Odhad modelu ARCH(1) pro proměnnou *DL_ISC_SA* a období II/1997 – I/2010 (odhad úplného modelu v jednom kroku) 82
Příloha 31: Odhad modelu ARCH(1) pro proměnnou *DL_ISC_SA* a období II/1997 – III/2010 (odhad úplného modelu v jednom kroku) 82
Příloha 32: Odhad modelu ARCH(1) pro rezidua AR(1) procesu proměnné *DL_ISC_SA* a období II/1997 – I/2010 83
Příloha 33: Odhad modelu AR(1) proměnné *DL_ISC_SA* pro období II/1997 – I/2010 83
Příloha 34: Odhad modelu ARCH(1) pro rezidua AR(1) procesu proměnné *DL_ISC_SA* a období II/1997 – III/2010 84
Příloha 35: Predikce ex post na období II/2010 a III/2010 na základě modelu AR(1) pro proměnnou *DL_ISC_SA* 84
Příloha 36: Predikce ex ante na období IV/2010 a I/2011 na základě modelu AR(1) pro proměnnou *DL_ISC_SA* 85

PŘÍLOHY

Příloha 1: Oddíly spotřebního koše a počty cenových reprezentantů pro výpočet ISC v ČR

ODDÍLY COICOP	POČET POLOŽEK
1. Potraviny a nealkoholické nápoje	161
2. Alkoholické nápoje a tabák	21
3. Odívání a obuv	67
4. Bydlení, voda, energie, paliva	46
5. Bytové vybavení, zař. domácnosti, opravy	81
6. Zdraví	20
7. Doprava	81
8. Pošty a telekomunikace	4
9. Rekreace a kultura	110
10. Vzdělávání	12
11. Stravování a ubytování	42
12. Ostatní zboží a služby	55
CELKEM	700

Zdroj: ČSÚ

Příloha 2: Váhy pro výpočet ISC v ČR od roku 2010 dle COICOP

ODDÍLY COICOP	VÁHA V PROMILE
1. Potraviny a nealkoholické nápoje	170,3
2. Alkoholické nápoje, tabák	86
3. Odívání a obuv	47,2
4. Bydlení, voda, energie, paliva	253,4
5. Bytové vybavení, zař. domácnosti; opravy	55,2
6. Zdraví	25
7. Doprava	114,9
8. Pošty a telekomunikace	39,9
9. Rekreace a kultura	93,7
10. Vzdělávání	7,8
11. Stravování a ubytování	44,2
12. Ostatní zboží a služby	62,4
CELKEM	1 000,00

Zdroj: ČSÚ

Příloha 3: Inflační cíle ČNB stanovené v čisté inflaci

CÍL PRO ROK	VE VÝŠI	PLNĚNÍ K	STANOVENO
1998	5,5 - 6,5 %	prosinec 98	prosinec 97
1999	4 - 5 %	prosinec 99	listopad 98
2000	3,5 - 5,5 %	prosinec 00	prosinec 97
2001	2 - 4 %	prosinec 01	duben 00
2005	1 - 3 %	prosinec 05	duben 99

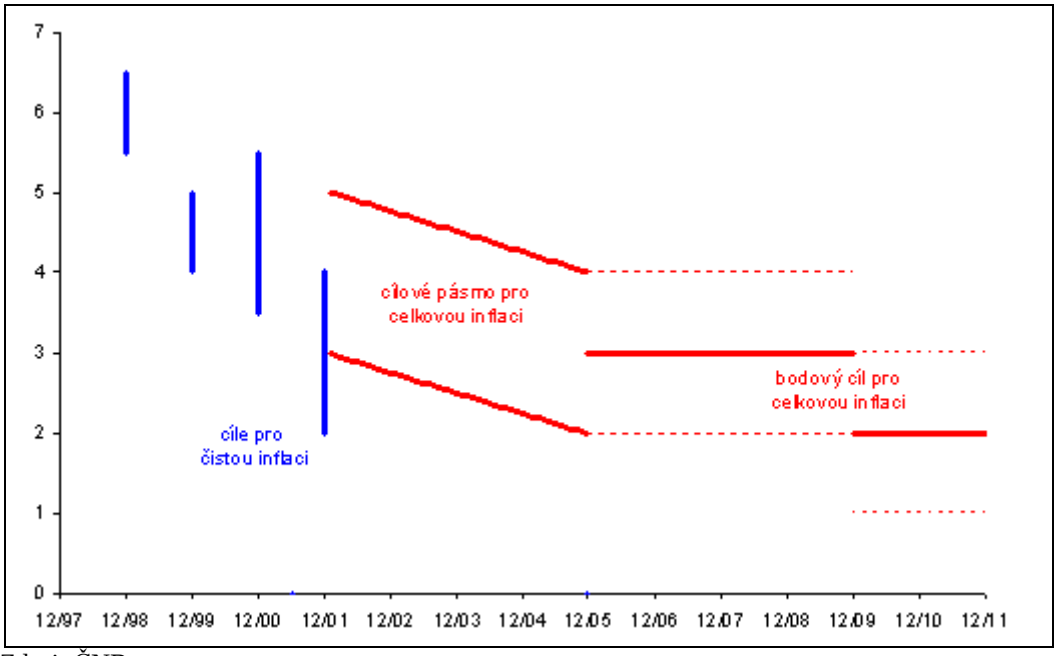
Zdroj: ČNB

Příloha 4: Cílové pásmo stanovené v celkové inflaci v období leden 2002 – prosinec 2005

	PRO MĚSÍC	VE VÝŠI	PLNĚNÍ K	STANOVENO
ZAČÁTEK PÁSMA	leden 02	3 - 5 %	leden 02	duben 01
KONEC PÁSMA	prosinec 05	2 - 4 %	prosinec 05	

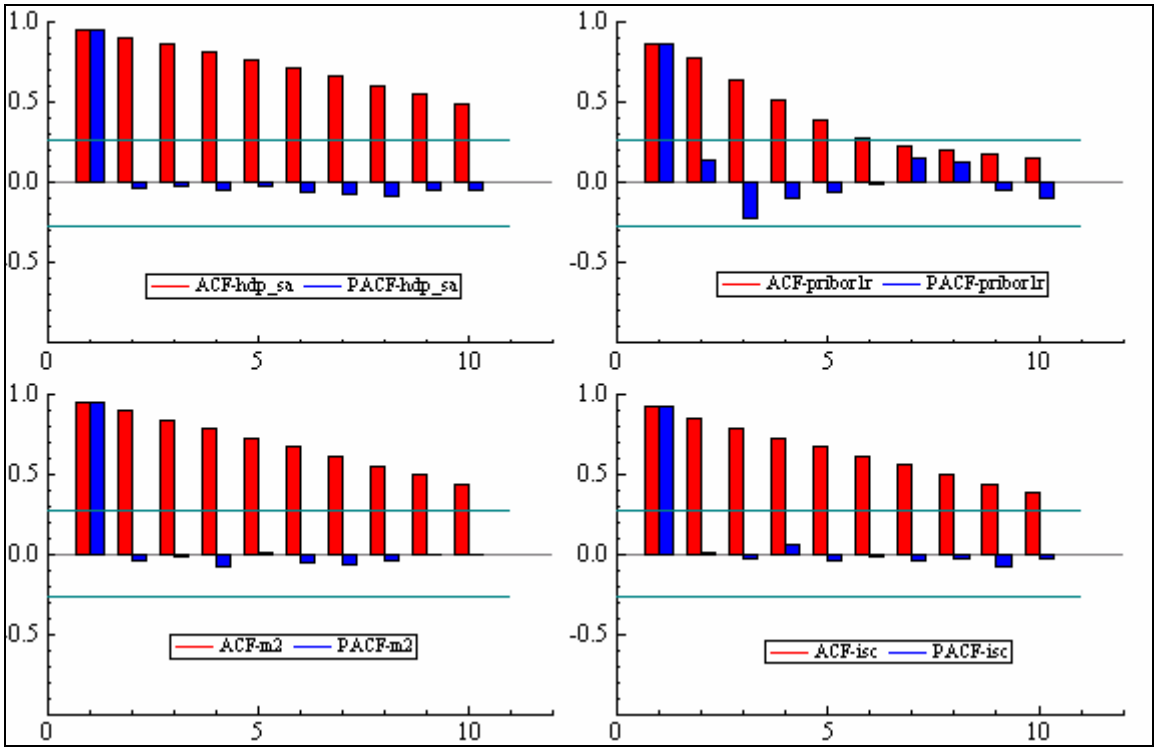
Zdroj: ČNB

Příloha 5: Inflační cíle ČNB



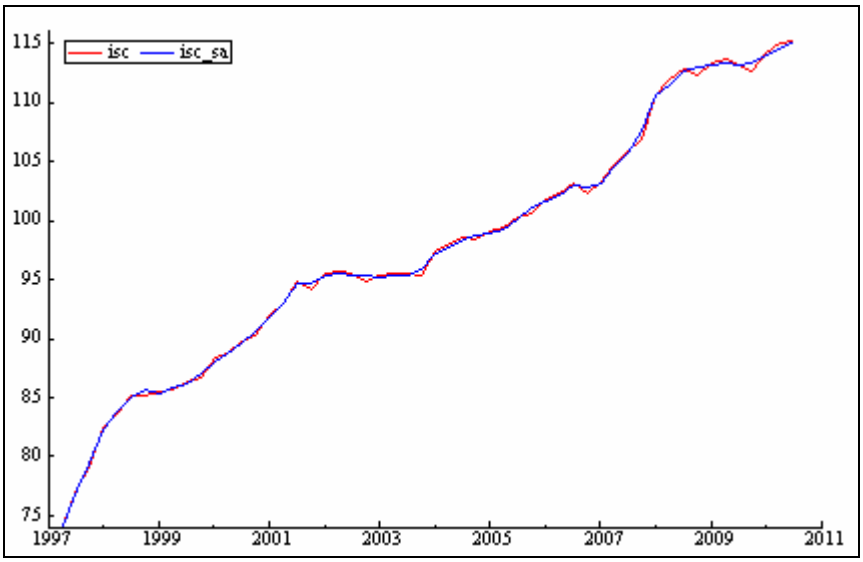
Zdroj: ČNB

Příloha 6: Funkce ACF a PACF proměnných (sezónně očištěná pouze proměnná HDP)



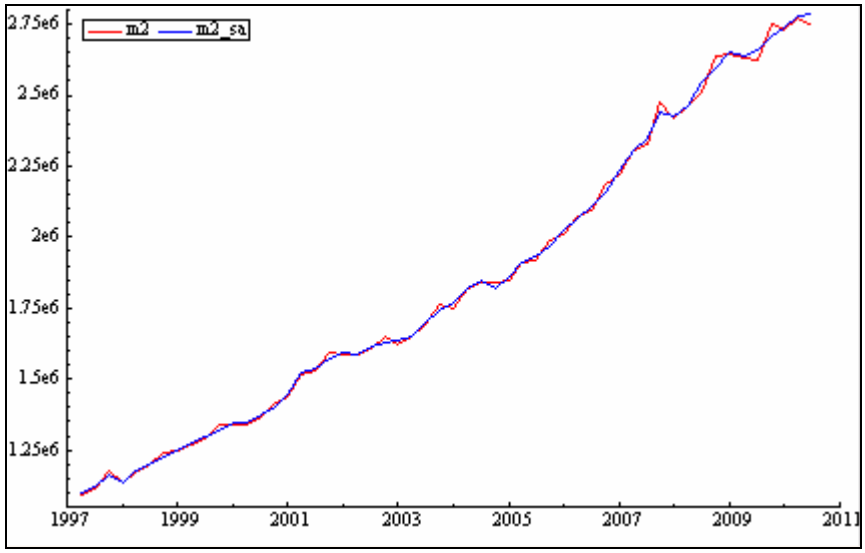
Zdroj: Vlastní výpočet v GiveWin

Příloha 7: Časová řada ISC sezónně očištěná metodou X12 ARIMA



Zdroj: Vlastní výpočet v EViews

Příloha 8: Časová řada M2 sezónně očištěná metodou X12 ARIMA



Zdroj: Vlastní výpočet v EViews

Příloha 9: ADF test pro proměnnou *PRIBOR1R*, I/1997 – III/2010

Null Hypothesis: PRIBOR1R has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		-1.583459	0.4840
Test critical values:	1% level	-3.557472	
	5% level	-2.916566	
	10% level	-2.596116	

Zdroj: Vlastní výpočet v EViews

Příloha 10: ADF test pro proměnnou *L_PRIBOR1R*, II/1997 – III/2010

Null Hypothesis: L_PRIBOR1R has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		-2.249794	0.1918
Test critical values:	1% level	-3.560019	
	5% level	-2.917650	
	10% level	-2.596689	

Zdroj: Vlastní výpočet v EViews

Příloha 11: Odhad VAR(1) modelu pro data II/1997 – III/2010

```
VAR(1) Estimating the system by OLS
       The estimation sample is: 1997 (4) to 2010 (3)

URF equation for: dl_isc_sa
                  Coefficient  Std.Error  t-value  t-prob
dl_isc_sa_1          0.450986    0.07869     5.73   0.000
dl_m2_sa_1           0.129111    0.04114     3.14   0.003
dl_hdp_sa_1         0.0814433    0.06325     1.29   0.204
dl_pribor1r_1    -0.000254701   0.004563  -0.0558   0.956
D             U     0.0147285   0.003560     4.14   0.000

sigma = 0.00436868   RSS = 0.000897010573


URF equation for: dl_m2_sa
                  Coefficient  Std.Error  t-value  t-prob
dl_isc_sa_1          0.456352     0.2281     2.00   0.051
dl_m2_sa_1           0.257753     0.1192     2.16   0.036
dl_hdp_sa_1          0.547458     0.1833     2.99   0.004
dl_pribor1r_1      -0.0258943    0.01323    -1.96   0.056
D             U    -0.0433352    0.01032    -4.20   0.000

sigma = 0.0126615   RSS = 0.007534687067


URF equation for: dl_hdp_sa
                  Coefficient  Std.Error  t-value  t-prob
dl_isc_sa_1          0.263832     0.1790     1.47   0.147
dl_m2_sa_1           0.199849    0.09358     2.14   0.038
dl_hdp_sa_1          0.501001     0.1439     3.48   0.001
dl_pribor1r_1     -0.00845024    0.01038   -0.814   0.420
D             U   -0.00484741   0.008098   -0.599   0.552

sigma = 0.00993897   RSS = 0.004642807028


URF equation for: dl_pribor1r
                  Coefficient  Std.Error  t-value  t-prob
dl_isc_sa_1          0.121874      2.547   0.0479   0.962
dl_m2_sa_1           0.677447      1.331    0.509   0.613
dl_hdp_sa_1         -0.831634      2.047   -0.406   0.686
dl_pribor1r_1        0.340763     0.1477     2.31   0.025
D             U    -0.0866846     0.1152   -0.752   0.456

sigma = 0.141398   RSS = 0.93968799
```

```
log-likelihood   576.706182  -T/2log|Omega|   871.845397
|Omega|     2.73535477e-015  log|Y'Y/T|      -31.2099533
R^2(LR)            0.901978  R^2(LM)            0.288833
no. of observations      52  no. of parameters        20

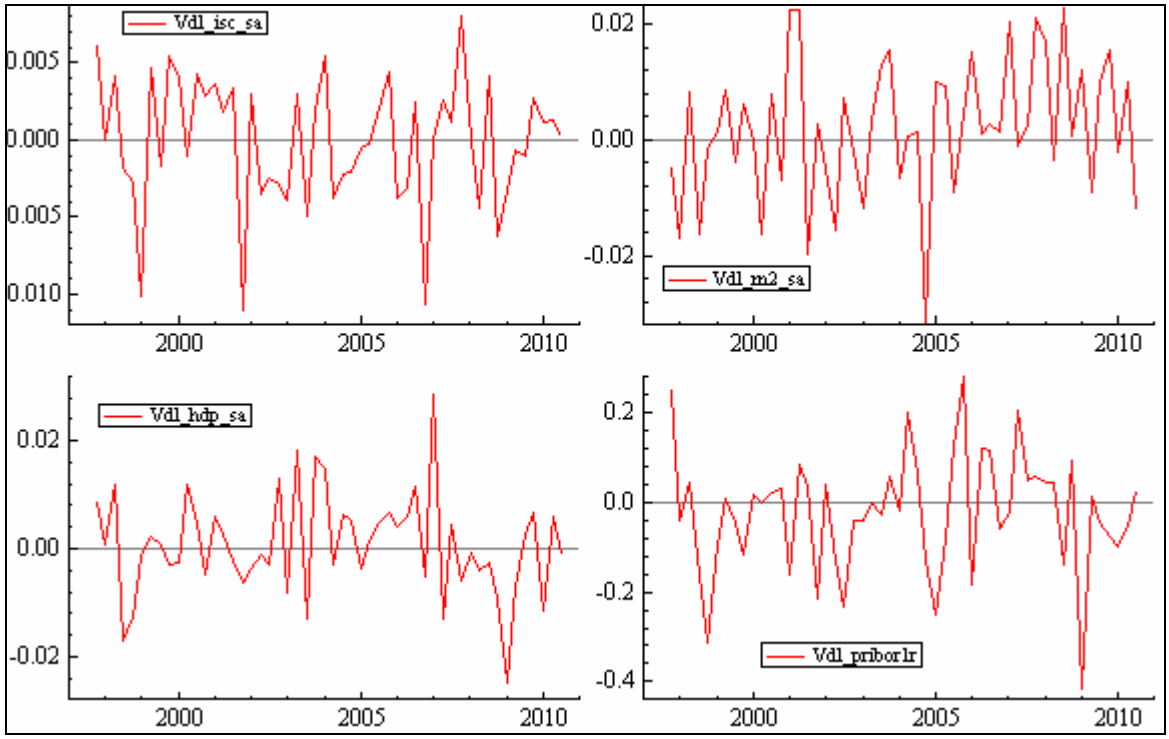
F-test on regressors except unrestricted:
F(16,135) = 9.61274 [0.0000] **
F-tests on retained regressors, F(4,44) =
 dl_isc_sa_1          8.81555 [0.000]**
 dl_m2_sa_1           3.30575 [0.019]*
 dl_hdp_sa_1          4.67986 [0.003]**
 dl_pribor1r_1        2.37713 [0.066]
 D             U      12.5411 [0.000]**

correlation of URF residuals (standard deviations on diagonal
              dl_isc_sa   dl_m2_sa   dl_hdp_sa  dl_pribor1r
dl_isc_sa     0.0043687    0.16873     0.31112      0.35030
dl_m2_sa        0.16873   0.012661     0.14402     -0.11964
dl_hdp_sa       0.31112    0.14402   0.0099390      0.33141
dl_pribor1r     0.35030   -0.11964     0.33141      0.14140
correlation between actual and fitted
    dl_isc_sa     dl_m2_sa    dl_hdp_sa  dl_pribor1r
      0.84609      0.52139      0.51278      0.25336


Vector Portmanteau( 6): 97.6196
Vector AR 1-4 test:      F(64,111)=   1.1712 [0.2313]
Vector Normality test:   Chi^2(8) =   12.350 [0.1363]
Vector hetero test:      F(80,192)=  0.91392 [0.6731]
Vector hetero-X test:    F(140,205)=  0.74642 [0.9681]
```

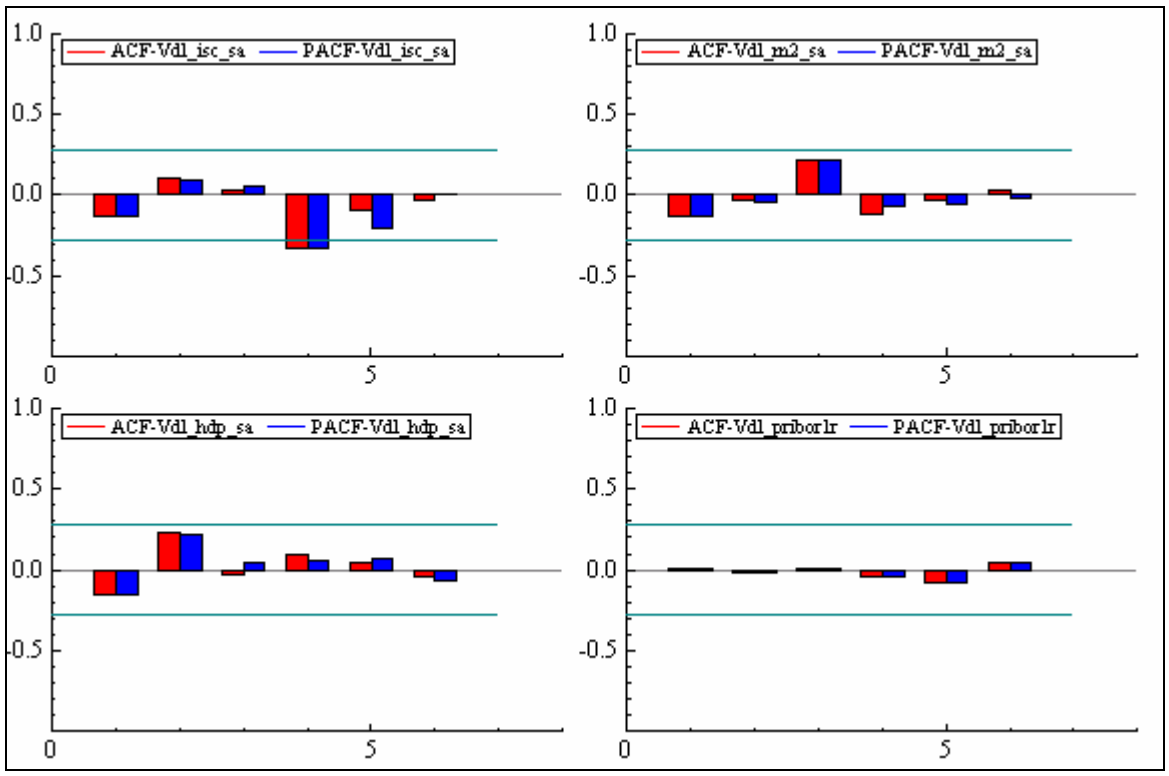
Zdroj: Vlastní výpočet v GiveWin

Příloha 12: Rezidua modelu VAR(1) pro období II/1997 – III/2010



Zdroj: Vlastní výpočet v GiveWin

Příloha 13: ACF a PACF funkce pro rezidua modelu VAR(1) a období II/1997 – III/2010



Zdroj: Vlastní výpočet v GiveWin

Příloha 14: Grangerovy testy kauzality pro model VAR(1) a data II/1997 – III/2010

```
Test for excluding: dl_m2_sa_1@dl_isc_sa
Subset Chi^2(1) =   9.8516 [0.0017]**

Test for excluding: dl_hdp_sa_1@dl_m2_sa
Subset Chi^2(1) =   8.9179 [0.0028]**

Test for excluding: dl_m2_sa_1@dl_hdp_sa
Subset Chi^2(1) =   4.5603 [0.0327]*

Test for excluding: dl_isc_sa_1@dl_m2_sa
Subset Chi^2(1) =   4.0040 [0.0454]*

Test for excluding: dl_pribor1r_1@dl_m2_sa
Subset Chi^2(1) =   3.8335 [0.0502]

Test for excluding: dl_hdp_sa_1@dl_isc_sa
Subset Chi^2(1) =   1.6578 [0.1979]

Test for excluding: dl_hdp_sa_1@dl_pribor1r
Subset Chi^2(1) =   0.16501 [0.6846]

Test for excluding: dl_m2_sa_1@dl_pribor1r
Subset Chi^2(1) =   0.25890 [0.6109]

Test for excluding: dl_pribor1r_1@dl_isc_sa
Subset Chi^2(1) =   0.0031154 [0.9555]

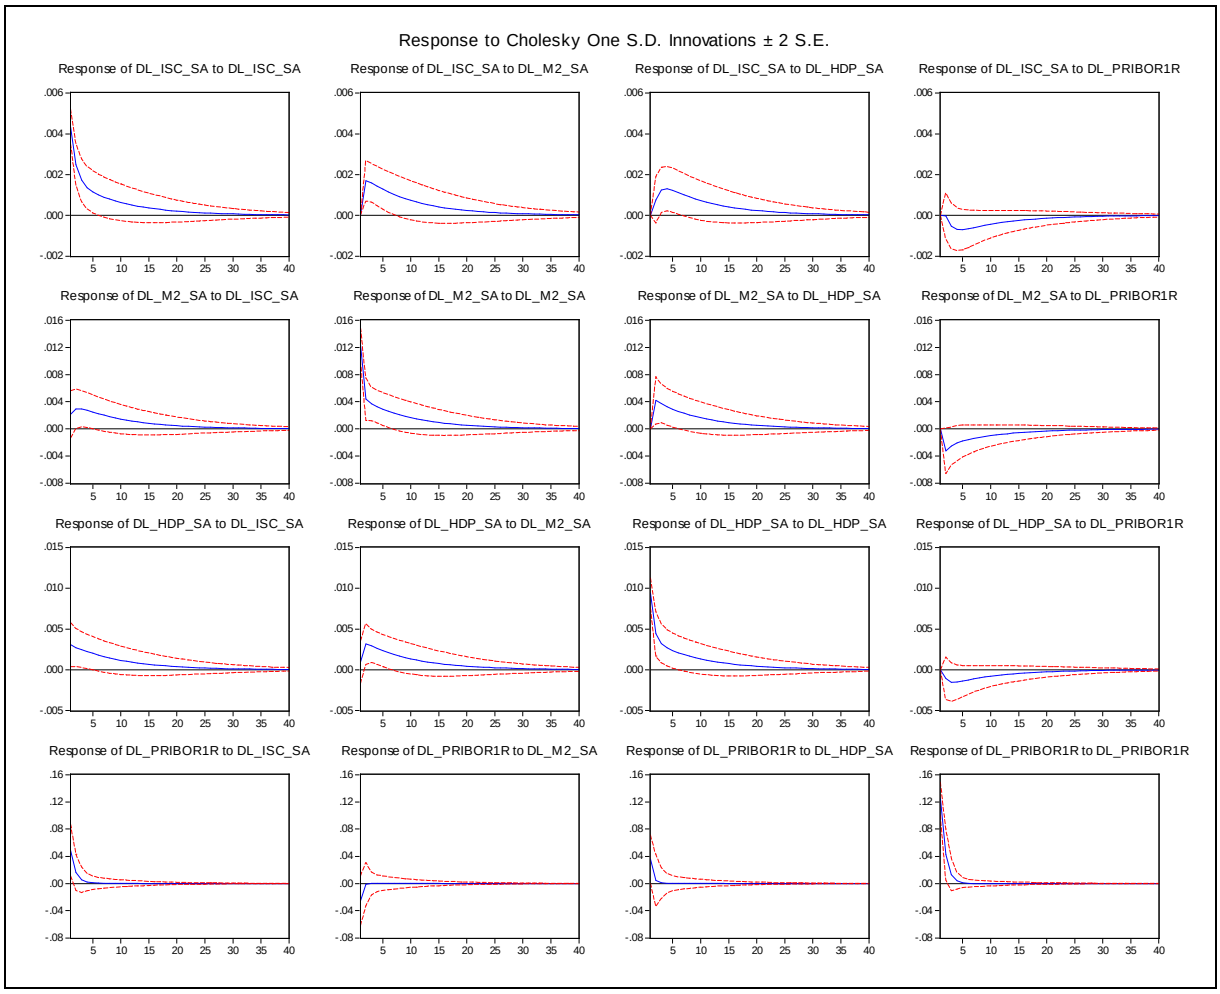
Test for excluding: dl_pribor1r_1@dl_hdp_sa
Subset Chi^2(1) =   0.66254 [0.4157]

Test for excluding: dl_isc_sa_1@dl_hdp_sa
Subset Chi^2(1) =   2.1719 [0.1406]

Test for excluding: dl_isc_sa_1@dl_pribor1r
Subset Chi^2(1) =0.0022898 [0.9618]
```

Zdroj: Vlastní výpočet v GiveWin

Příloha 15: Analýza funkcí odezvy pro model VAR(1) a data II/1997 – III/2010



Zdroj: Vlastní výpočet v EViews

Příloha 16: Odhad modelu VAR(1) a data II/1997 – III/2010 (logaritmované časové řady)

```
VAR(1) Estimating the system by OLS
       The estimation sample is: 1997 (4) to 2010 (3)

URF equation for: l_m2_sa
                  Coefficient   Std.Error   t-value   t-prob
l_m2_sa_1            0.893043     0.04130      21.6    0.000
l_hdp_sa_1           0.116182     0.04443      2.61    0.012
l_pribor1r_1      -0.00423922    0.003795     -1.12    0.270
l_mi100_1          0.00392803    0.002352      1.67    0.102
D              U   -0.0357890    0.008616     -4.15    0.000

sigma = 0.0111588    RSS = 0.005852367527
```

```
  URF equation for: l_hdp_sa
                    Coefficient  Std.Error  t-value  t-prob
  l_m2_sa_1           -0.115454    0.03626    -3.18   0.003
  l_hdp_sa_1            1.12515    0.03901     28.8   0.000
  l_pribor1r_1      -0.00748890   0.003332    -2.25   0.029
  l_mi100_1          0.00495953   0.002065     2.40   0.020
  D              U   0.00369796   0.007564    0.489   0.627

  sigma = 0.00979629   RSS = 0.004510463216

  URF equation for: l_pribor1r
                    Coefficient  Std.Error  t-value  t-prob
  l_m2_sa_1           -0.700598     0.4458    -1.57   0.123
  l_hdp_sa_1           0.759547     0.4797     1.58   0.120
  l_pribor1r_1         0.828490    0.04097     20.2   0.000
  l_mi100_1           0.0898750    0.02539     3.54   0.001
  D              U   0.00602022    0.09301   0.0647   0.949

  sigma = 0.120467   RSS = 0.6820780098

  URF equation for: l_mi100
                    Coefficient  Std.Error  t-value  t-prob
  l_m2_sa_1            -1.03102      1.794   -0.575   0.568
  l_hdp_sa_1            1.12552      1.930    0.583   0.563
  l_pribor1r_1        0.0345617     0.1648    0.210   0.835
  l_mi100_1            0.443547     0.1021     4.34   0.000
  D              U      1.80143     0.3742     4.81   0.000

  sigma = 0.484637   RSS = 11.03903659

log-likelihood     358.760744  -T/2log|Omega|     653.899959
|Omega|       1.19534831e-011  log|Y'Y/T|        -3.79508437
R^2(LR)                    1  R^2(LM)              0.780014
no. of observations        52  no. of parameters          20

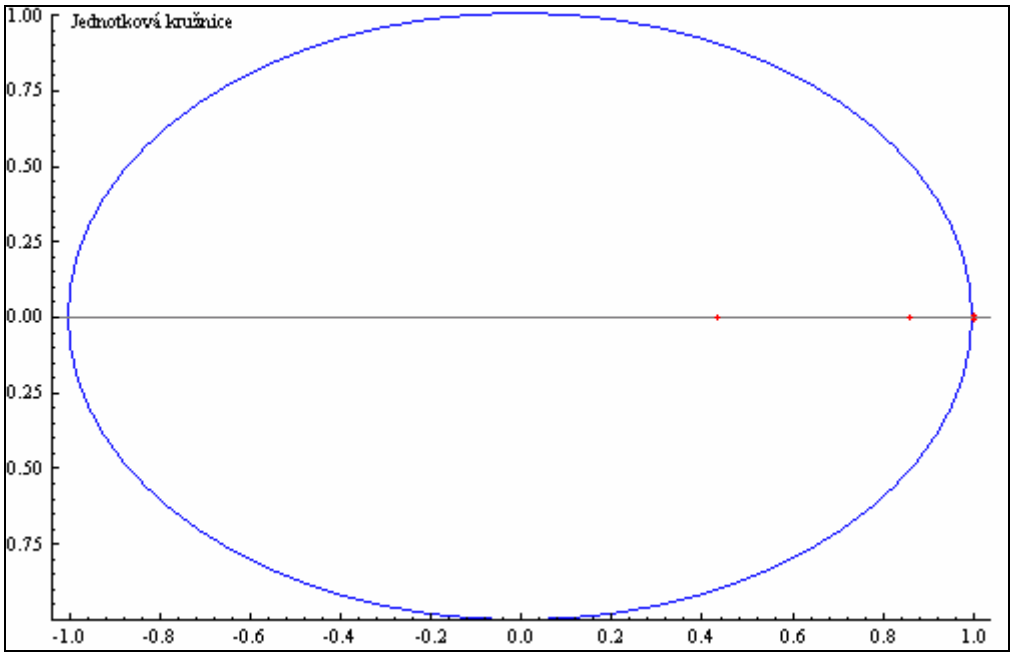
F-test on regressors except unrestricted:
F(16,135) = 9156.73 [0.0000] **
F-tests on retained regressors, F(4,44) =
l_m2_sa_1          118.233 [0.000]**
l_hdp_sa_1         266.240 [0.000]**
l_pribor1r_1       174.758 [0.000]**
l_mi100_1          4.92597 [0.002]**
D            U     16.1693 [0.000]**
```

```
correlation of URF residuals (standard deviations on diagonal)
             l_m2_sa     l_hdp_sa   l_pribor1r      l_mi100
l_m2_sa     0.011159     0.026556     0.067875      0.23943
l_hdp_sa    0.026556    0.0097963      0.50572      0.44099
l_pribor1r  0.067875      0.50572      0.12047      0.57982
l_mi100      0.23943      0.44099      0.57982      0.48464
correlation between actual and fitted
      l_m2_sa     l_hdp_sa   l_pribor1r      l_mi100
      0.99925      0.99916      0.98054      0.80623

Vector Portmanteau( 6): 94.3758
Vector AR 1-4 test:      F(64,111)=  0.94021 [0.6011]
Vector Normality test:   Chi^2(8) =   17.991 [0.0213]*
Vector hetero test:      F(80,192)=  0.93542 [0.6280]
Vector hetero-X test:    F(140,205)=   1.0890 [0.2877]
```

Zdroj: Vlastní výpočet v GiveWin

Příloha 17: Testování stacionarity v modelu VAR(1), logaritmované časové řady a data II/1997 – III/2010



Zdroj: Vlastní výpočet v GiveWin

Příloha 18: Johansenův test kointegrace (Trace test) pro model VAR(1), II/1997 – III/2010 (logaritmované časové řady)

```
     I(1) cointegration analysis, 1997 (4) to 2010 (3)
       eigenvalue    loglik for rank
                       265.1450   0
          0.89807      324.5144   1
          0.67351      353.6176   2
          0.17670      358.6729   3
        0.0033738      358.7607   4

       H0:rank<=  Trace test [ Prob]
           0          187.23 [0.000] **
           1          68.493 [0.000] **
           2          10.286 [0.107]
           3         0.17574 [0.746]

     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
l_m2_sa      1.0000  -0.93228    6.8804    65.520
l_hdp_sa    -1.0844    1.0000   -7.4696   -70.149
l_pribor1r 0.049442  -0.91361    1.0000  -0.48316
l_mi100   -0.087491    1.1760 -0.063077    1.0000

alpha
l_m2_sa   -0.098228   -0.0042611   -0.0032066   0.00014288
l_hdp_sa  -0.073299   -0.0014172   -0.0052155  -0.00011587
l_pribor1r  0.10868     0.079084     -0.10474  -0.00022715
l_mi100      1.3178     -0.39595     -0.39247  -0.00026940

long-run matrix, rank 4
            l_m2_sa     l_hdp_sa   l_pribor1r      l_mi100
l_m2_sa    -0.10696      0.11618   -0.0042392    0.0039280
l_hdp_sa   -0.11545      0.12515   -0.0074889    0.0049595
l_pribor1r -0.70060      0.75955     -0.17151     0.089875
l_mi100     -1.0310       1.1255     0.034562     -0.55645
```

Zdroj: Vlastní výpočet v GiveWin

Příloha 19: Odhad kointegračních vektorů po restrikcích pro model VAR(1) a data II/1997 – III/2010 (logaritmované časové řady)

```
Cointegrated VAR
The estimation sample is: 1997 (4) to 2010 (3)

Cointegrated VAR (1) in:
[0] = l_m2_sa
[1] = l_hdp_sa
[2] = l_pribor1r
[3] = l_mi100
Unrestricted variables:
[0] = D
Number of lags used in the analysis: 1

General cointegration restrictions:
&8=1;&10=0;&12=0;&13=0;&14=1;

beta
l_m2_sa              1.0000       0.00000
l_hdp_sa            -1.0843       0.00000
l_pribor1r           0.00000       1.0000
l_mi100            -0.024537      -1.2724

Standard errors of beta
l_m2_sa              0.00000       0.00000
l_hdp_sa          0.00093372       0.00000
l_pribor1r           0.00000       0.00000
l_mi100             0.011606      0.080142

alpha
l_m2_sa            -0.097502   -0.00092932
l_hdp_sa           -0.073136    -0.0023052
l_pribor1r          0.091667     -0.068332
l_mi100               1.4061       0.43155

Standard errors of alpha
l_m2_sa             0.0080544     0.0017472
l_hdp_sa            0.0072234     0.0015669
l_pribor1r           0.093180      0.020213
l_mi100               0.37207      0.080710
```

```
Restricted long-run matrix, rank 2
              l_m2_sa  l_hdp_sa   l_pribor1r    l_mi100
l_m2_sa     -0.097502   0.10572  -0.00092932  0.0035750
l_hdp_sa    -0.073136  0.079303   -0.0023052  0.0047279
l_pribor1r   0.091667 -0.099397    -0.068332   0.084699
l_mi100        1.4061   -1.5246      0.43155   -0.58362

Standard errors of long-run matrix
l_m2_sa     0.0080544  0.0087335  0.0017472   0.0022853
l_hdp_sa    0.0072234  0.0078325  0.0015669   0.0020495
l_pribor1r   0.093180    0.10104   0.020213    0.026439
l_mi100       0.37207    0.40345   0.080710     0.10557

 Moving-average impact matrix
       -2.4023       3.6892     0.048191     0.022165
       -2.3937       3.5955     0.031229     0.018997
        10.016      -10.861      0.74303     0.081205
        7.8718      -8.5356      0.58394     0.063818

 log-likelihood     353.513186
 -T/2log|Omega|     648.652401
 no. of observations        52
 no. of parameters          15
 rank of long-run matrix     2
 no. long-run restrictions   1
 beta is identified
```

Zdroj: Vlastní výpočet v GiveWin

Příloha 20: Odhad statické regrese (5.7) na datech II/1997– III/2010

```
Modelling l_pribor1r by OLS
The estimation sample is: 1997 (2) to 2010 (3)

        Coefficient Std.Error t-value t-prob Part.R^2
l_isc_sa   0.302056   0.01992    15.2  0.000   0.8127

sigma             0.669944  RSS             23.7877576
log-likelihood    -54.4877  DW                  0.0473
no. of observations     54  no. of parameters        1
mean(l_pribor1r)    1.3947  var(l_pribor1r)  0.406406

AR 1-4 test:      F(4,49)  =   68.407 [0.0000]**
ARCH 1-4 test:    F(4,45)  =   99.709 [0.0000]**
Normality test:   Chi^2(2) =   16.216 [0.0003]**
hetero test:      F(2,50)  =   68.939 [0.0000]**
hetero-X test:    F(2,50)  =   68.939 [0.0000]**
RESET test:       F(1,52)  =   86.326 [0.0000]**
```

Zdroj: Vlastní výpočet v GiveWin

Příloha 21: Test kointegrace regrese (5.7)

```
Unit-root tests
The sample is 1997 (3) - 2010 (3)

residuals: ADF tests (T=53; 5%=-1.95 1%=-2.61)
D-lag  t-adf  beta Y_1   sigma  t-DY_lag t-prob  AIC  F-prob
  0   -2.307*  0.93269  0.1401                -3.912
```

Zdroj: Vlastní výpočet v GiveWin

Příloha 22: Odhad parametrů MKCH (5.9)

```
Modelling l_pribor1r by OLS
The estimation sample is: 1997 (3) to 2010 (3)

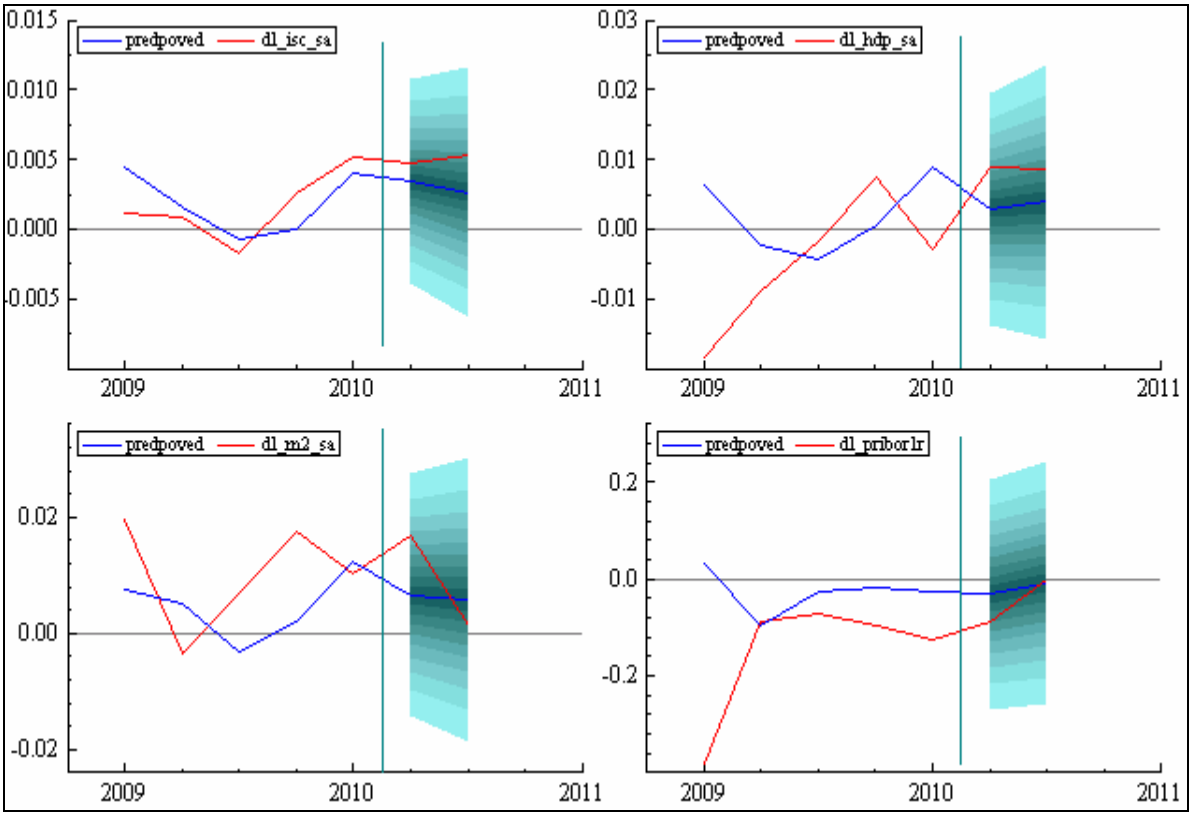
            Coefficient  Std.Error  t-value  t-prob Part.R^2
l_pribor1r_1   0.857845    0.02657     32.3   0.000   0.9551
l_isc_sa        16.0732      2.603     6.17   0.000   0.4375
l_isc_sa_1     -16.0640      2.604    -6.17   0.000   0.4372
D              -0.355031    0.08808    -4.03   0.000   0.2490

sigma                0.103032  RSS                 0.520164477
log-likelihood        47.3297  DW                         1.95
no. of observations         53  no. of parameters             4
mean(l_pribor1r)      1.36539  var(l_pribor1r)         0.367684

AR 1-4 test:       F(4,45)  =  0.31740 [0.8649]
ARCH 1-4 test:     F(4,41)  =  0.45294 [0.7697]
Normality test:    Chi^2(2) =   3.6301 [0.1628]
hetero test:       F(7,41)  =  0.51204 [0.8201]
hetero-X test:     F(12,36) =   1.1574 [0.3486]
RESET test:        F(1,48)  =  0.98837 [0.3251]
```

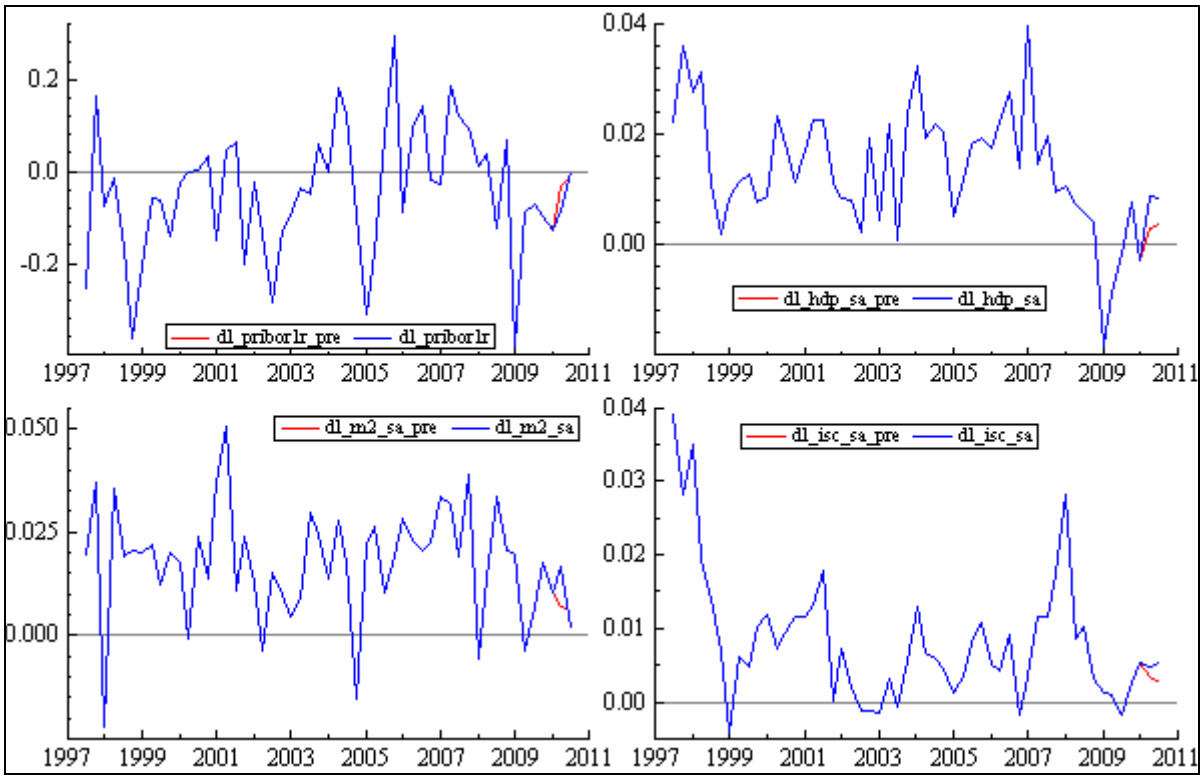
Zdroj: Vlastní výpočet v GiveWin

Příloha 23: Bodová a intervalová předpověď ex post na období II-III/2010 na základě modelu VAR(1) a období II/1997 – I/2010 (bez sezónních proměnných)



Zdroj: Vlastní výpočet v GiveWin

Příloha 24: Skutečné a predikované hodnoty časových řad na období II-III/2010 na základě VAR(1) modelu pro období II/1997 - I/2010 (bez sezónních proměnných)



Zdroj: Vlastní výpočet v GiveWin

Příloha 25: VAR(1) model pro období II/1997 – I/2010 (bez sezónních proměnných)

```
VAR(1) Estimating the system by OLS
       The estimation sample is: 1997 (4) to 2010 (1)

URF equation for: dl_isc_sa
                  Coefficient  Std.Error  t-value  t-prob
dl_isc_sa_1          0.448729    0.08074     5.56   0.000
dl_m2_sa_1           0.127954    0.04222     3.03   0.004
dl_hdp_sa_1         0.0835058    0.06501     1.28   0.206
dl_pribor1r_1    -0.000149445   0.004677  -0.0320   0.975
D              U    0.0147627   0.003637     4.06   0.000

sigma = 0.00446045   RSS = 0.0008953043349

URF equation for: dl_m2_sa
                  Coefficient  Std.Error  t-value  t-prob
dl_isc_sa_1          0.437665     0.2303     1.90   0.064
dl_m2_sa_1           0.256722     0.1204     2.13   0.039
dl_hdp_sa_1          0.566205     0.1855     3.05   0.004
dl_pribor1r_1      -0.0259604    0.01334    -1.95   0.058
D              U   -0.0432935    0.01037    -4.17   0.000

sigma = 0.0127253   RSS = 0.007286947835


URF equation for: dl_pribor1r
                  Coefficient  Std.Error  t-value  t-prob
dl_isc_sa_1          0.219616      2.611   0.0841   0.933
dl_m2_sa_1           0.705740      1.365    0.517   0.608
dl_hdp_sa_1         -0.925202      2.102   -0.440   0.662
dl_pribor1r_1        0.338599     0.1512     2.24   0.030
D              U   -0.0875495     0.1176   -0.745   0.460

sigma = 0.144237   RSS = 0.9361877607
URF equation for: dl_hdp_sa
                  Coefficient  Std.Error  t-value  t-prob
dl_isc_sa_1          0.253253     0.1831     1.38   0.174
dl_m2_sa_1           0.195949    0.09576     2.05   0.047
dl_hdp_sa_1          0.510964     0.1475     3.46   0.001
dl_pribor1r_1     -0.00812410    0.01061   -0.766   0.448
D              U  -0.00473014   0.008249   -0.573   0.569

sigma = 0.0101179   RSS = 0.004606750182
```

```
log-likelihood      551.743638  -T/2log|Omega|      835.531345
|Omega|        3.05727071e-015  log|Y'Y/T|         -31.0864519
R^2(LR)                0.90317  R^2(LM)                0.290028
no. of observations         50  no. of parameters           20

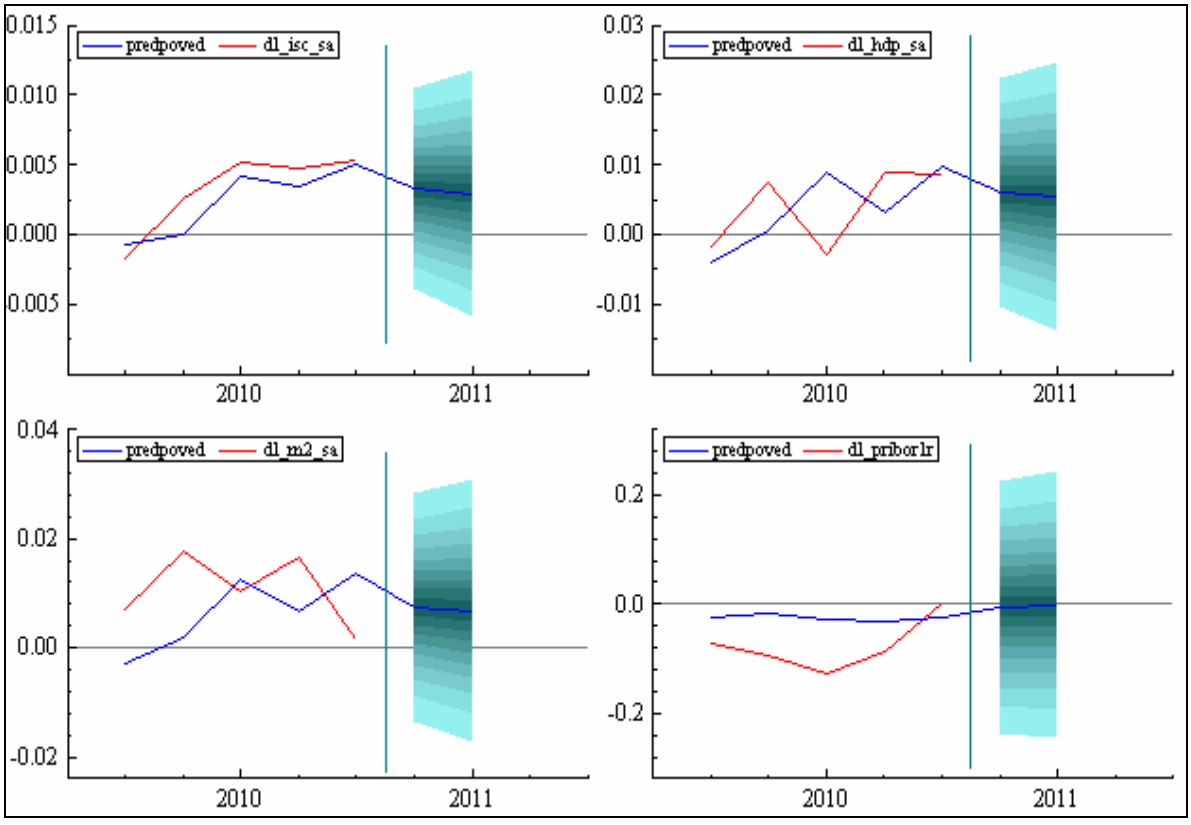
F-test on regressors except unrestricted:
                              F(16,128) = 9.24706 [0.0000] **

F-tests on retained regressors, F(4,42) =
dl_isc_sa_1      8.24076 [0.000]**
dl_hdp_sa_1      4.80134 [0.003]**
          D U    12.1317 [0.000]**
dl_m2_sa_1       3.10562 [0.025]*
dl_pribor1r_1    2.27770 [0.077]


   Vector Portmanteau( 6): 93.7209
   Vector AR 1-4 test:       F(64,104)=   1.1786 [0.2262]
   Vector Normality test:    Chi^2(8) =   11.213 [0.1899]
   Vector hetero test:       F(80,179)=  0.88915 [0.7216]
   Vector hetero-X test:     F(140,189)=  0.71066 [0.9835]
```

Zdroj: Vlastní výpočet v GiveWin

Příloha 26: Bodová a intervalová předpověď ex ante na období IV/2010 a I/2011 pro VAR(1) model a období II/1997 – III/2010 (bez sezónních proměnných)



Zdroj: Vlastní výpočet v GiveWin

Příloha 27 - Směrodatné chyby odhadů predikce ex post (nepřepočtené na úrovňové hodnoty), VAR(1) a data II/1997 – I/2010

VAR(1) model bez sezónních proměnných				
	HDP	M2	ISC	PRIBOR1R
II/2010	0,010	0,013	0,004	0,144
III/2010	0,012	0,015	0,005	0,152
VAR(1) model se sezónními proměnnými				
	HDP	M2	ISC	PRIBOR1R
II/2010	0,010	0,013	0,005	0,132
III/2010	0,012	0,014	0,006	0,140

Zdroj: Vlastní výpočet

Příloha 28 - Směrodatné chyby odhadů predikce ex ante (nepřepočtené na úrovňové hodnoty), VAR(1) a data II/1997 – III/2010

VAR(1) model bez sezónních proměnných				
	HDP	M2	ISC	PRIBOR1R
IV/2010	0,010	0,013	0,004	0,141
I/2011	0,012	0,015	0,005	0,149
VAR(1) model se sezónními proměnnými				
	HDP	M2	ISC	PRIBOR1R
IV/2010	0,010	0,013	0,005	0,130
I/2011	0,012	0,014	0,005	0,137

Zdroj: Vlastní výpočet

Příloha 29: Diagnostické testy pro proměnnou *DL_ISC_SA*, období II/1997 - III/2010

```
---- Maximum likelihood estimation of ARFIMA(0,0,0) model
The estimation sample is:  1997 (3) - 2010 (3)
The dependent variable is: dl_isc_sa

                 Coefficient  Std.Error  t-value  t-prob

log-likelihood     158.783207
no. of observations         53  no. of parameters           1
AIC.T             -315.566413  AIC                -5.95408327
mean(dl_isc_sa)    0.00828264  var(dl_isc_sa)   7.77205e-005
sigma               0.0120964  sigma^2           0.000146323

Descriptive statistics for residuals:
Normality test:    Chi^2(2) =   27.297 [0.0000]**
ARCH 1-1 test:     F(1,51)  =   42.515 [0.0000]**
Portmanteau(12):   Chi^2(12)=   122.14 [0.0000]**
```

Zdroj: Vlastní výpočet v GiveWin

Příloha 30: Odhad modelu ARCH(1) pro proměnnou *DL_ISC_SA* a období II/1997 – I/2010 (odhad úplného modelu v jednom kroku)

```
Modelling dl_isc_sa by restricted GARCH(0,1)
The estimation sample is: 1997 (4) to 2010 (1)

              Coefficient  Std.Error  robust-SE t-value t-prob
dl_isc_sa_1 Y     0.477318    0.08660     0.1040    4.59  0.000
Constant    X   0.00261205  0.0008960  0.0008469    3.08  0.003
alpha_0     H 1.68720e-005 6.091e-006 4.863e-006    3.47  0.001
alpha_1     H     0.688106     0.3458     0.3947    1.74  0.088

log-likelihood     187.663198  HMSE                  2.02778
mean(h_t)        4.19693e-005  var(h_t)         2.10991e-009
no. of observations        50  no. of parameters           4
AIC.T              -367.326395  AIC                -7.3465279
mean(dl_isc_sa)    0.00779703  var(dl_isc_sa)   6.27847e-005
alpha(1)+beta(1)     0.688106  alpha_i+beta_i>=0,
alpha(1)+beta(1)<1
       Descriptive statistics for scaled residuals:
       Asymptotic test:  Chi^2(2) =  0.14253 [0.9312]
       Normality test:   Chi^2(2) =  0.48778 [0.7836]
       ARCH 1-2 test:    F(2,42)  =  0.37196 [0.6916]
       Portmanteau(12):  Chi^2(11)=   11.840 [0.3758]
```

Zdroj: Vlastní výpočet v GiveWin

Příloha 31: Odhad modelu ARCH(1) pro proměnnou *DL_ISC_SA* a období II/1997 – III/2010 (odhad úplného modelu v jednom kroku)

```
Modelling dl_isc_sa by restricted GARCH(0,1)
The estimation sample is: 1997 (4) to 2010 (3)

               Coefficient  Std.Error  robust-SE t-value t-prob
dl_isc_sa_1 Y     0.479077    0.08243     0.1033    4.64  0.000
Constant    X   0.00259148  0.0008255  0.0007957    3.26  0.002
alpha_0     H 1.46950e-005 5.250e-006 4.398e-006    3.34  0.002
alpha_1     H     0.765520     0.3479     0.3878    1.97  0.054

log-likelihood     196.82944  HMSE                  2.05566
mean(h_t)        4.15331e-005  var(h_t)         2.52842e-009
no. of observations        52  no. of parameters           4
AIC.T              -385.658879  AIC                -7.41651691
mean(dl_isc_sa)    0.00769087  var(dl_isc_sa)   6.06548e-005
alpha(1)+beta(1)      0.76552  alpha_i+beta_i>=0,
alpha(1)+beta(1)<1
```

Zdroj: Vlastní výpočet v GiveWin

Příloha 32: Odhad modelu ARCH(1) pro rezidua AR(1) procesu proměnné *DL_ISC_SA* a období II/1997 – I/2010

```
Modelling res_ar1 by restricted GARCH(0,1)
The estimation sample is: 1997 (3) to 2010 (1)

            Coefficient  Std.Error  robust-SE  t-value  t-prob
alpha_0  H  2.22420e-005 7.574e-006 4.598e-006     4.84   0.000
alpha_1  H      0.686066     0.3484     0.3334     2.06   0.045

log-likelihood     185.347985  HMSE                  2.18976
mean(h_t)        5.20803e-005  var(h_t)         2.38714e-009
no. of observations         51  no. of parameters           2
AIC.T              -366.695969  AIC                -7.19011704
mean(res_ar1)    -0.000632112  var(res_ar1)     4.22683e-005
alpha(1)+beta(1)     0.686066  alpha_i+beta_i>=0,
alpha(1)+beta(1)<1
```

Zdroj: Vlastní výpočet v GiveWin

Příloha 33: Odhad modelu AR(1) proměnné *DL_ISC_SA* pro období II/1997 – I/2010

```
The estimation sample is:  1997 (3) - 2010 (1)
The dependent variable is: dl_isc_sa

           Coefficient  Std.Error  t-value  t-prob
AR-1          0.758240     0.1100     6.90   0.000
Constant    0.00991352   0.003567     2.78   0.008

log-likelihood  183.789022
no. of observations     51  no. of parameters         3
AIC.T          -361.578045  AIC              -7.08976559
mean(dl_isc_sa) 0.00840993  var(dl_isc_sa)8.03358e-005
sigma           0.00653207  sigma^2        4.26679e-005

Descriptive statistics for residuals:
Normality test:   Chi^2(2) =   4.7454 [0.0932]
ARCH 1-1 test:    F(1,47)  =  0.45886 [0.5015]
Portmanteau(12):  Chi^2(11)=   11.454 [0.4061]
```

Zdroj: Vlastní výpočet v GiveWin

Příloha 34: Odhad modelu ARCH(1) pro rezidua AR(1) procesu proměnné *DL_ISC_SA* a období II/1997 – III/2010

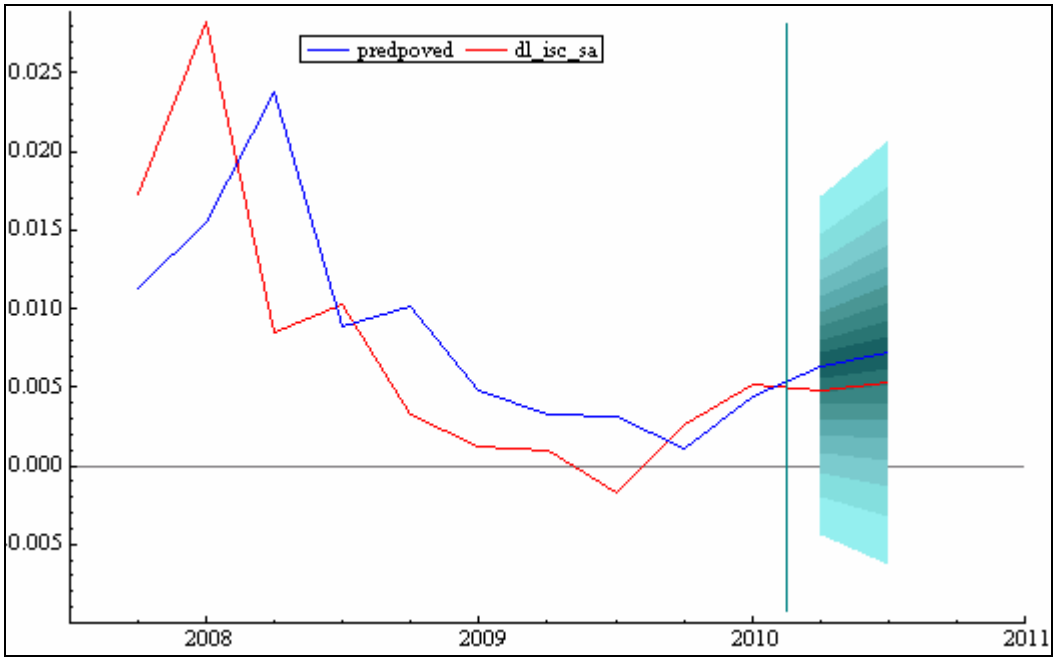
```
Modelling res_ar1_III/2010 by restricted GARCH(0,1)
The estimation sample is: 1997 (3) to 2010 (3)

            Coefficient  Std.Error  robust-SE  t-value  t-prob
alpha_0 H  1.75819e-005 6.314e-006 3.895e-006     4.51   0.000
alpha_1 H      0.883573     0.3813     0.3883     2.28   0.027

log-likelihood     194.248945  HMSE                    2.09566
mean(h_t)        5.45803e-005  var(h_t)          3.85671e-009
no. of observations         53  no. of parameters            2
AIC.T              -384.497889  AIC                -7.25467715
mean(res_ar1_III/2010) -0.000614391
var(res_ar1_III/2010)  4.0728e-005
alpha(1)+beta(1)      0.883573
alpha_i+beta_i>=0, alpha(1)+beta(1)<1
```

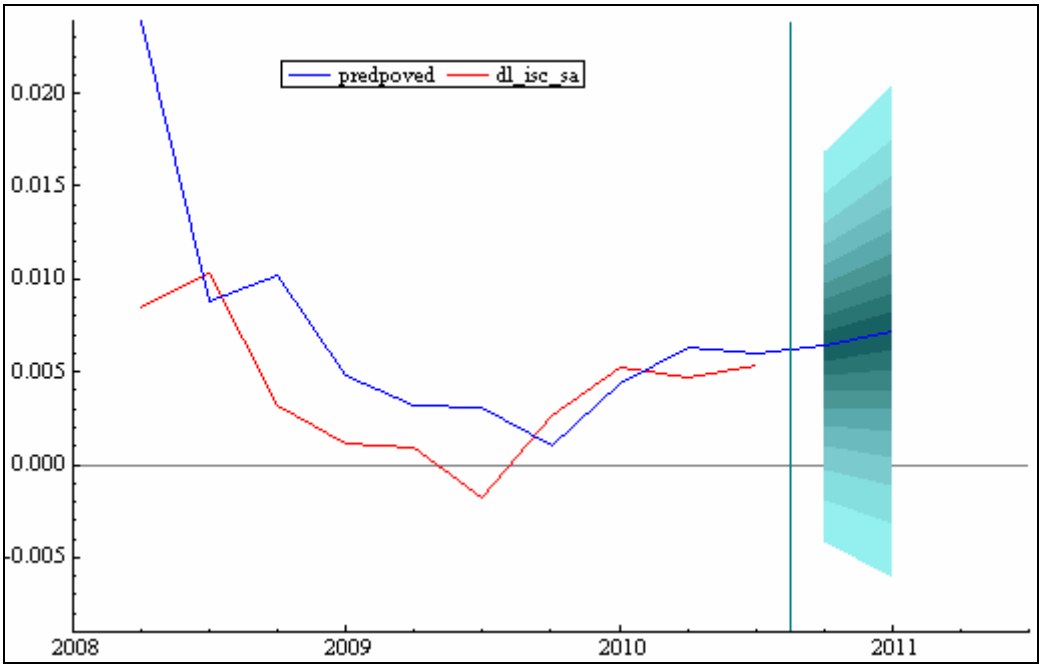
Zdroj: Vlastní výpočet v GiveWin

Příloha 35: Predikce ex post na období II/2010 a III/2010 na základě modelu AR(1) pro proměnnou *DL_ISC_SA*



Zdroj: Vlastní výpočet v GiveWin

Příloha 36: Predikce ex ante na období IV/2010 a I/2011 na základě modelu AR(1) pro proměnnou *DL_ISC_SA*



Zdroj: Vlastní výpočet v GiveWin