

**PEMODELAN MARKOV SWITCHING VECTOR ERROR
CORRECTION MODEL (MS-VECM)
(Studi Kasus pada Tingkat Inflasi dan Suku Bunga)**

S K R I P S I

Oleh:
OKASHA IRFAN IZZUDIN
165090507111018



PROGRAM STUDI SARJANA STATISTIKA
JURUSAN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS BRAWIJAYA
MALANG
2020

**PEMODELAN MARKOV SWITCHING VECTOR ERROR
CORRECTION MODEL (MS-VECM)
(Studi Kasus pada Tingkat Inflasi dan Suku Bunga)**

S K R I P S I

Sebagai salah satu syarat untuk memperoleh gelar
Sarjana Statistika

Oleh:

**OKASHA IRFAN IZZUDIN
165090507111018**



**PROGRAM STUDI SARJANA STATISTIKA
JURUSAN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS BRAWIJAYA
MALANG
2020**



Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya


Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya



LEMBAR PENGESAHAN SKRIPSI
PEMODELAN MARKOV SWITCHING VECTOR ERROR
CORRECTION MODEL (MS-VECM)
(Studi Kasus pada Tingkat Inflasi dan Suku Bunga)

Oleh:

OKASHA IRFAN IZZUDIN
165090507111018

Setelah dipertahankan di depan Majelis Penguji
pada tanggal 6 Juli 2020
dan dinyatakan memenuhi syarat untuk memperoleh gelar
Sarjana Statistika


Dosen Pembimbing

Nurjannah, S.Si., M.Phil., Ph.D
NIP. 198009212005012001

Mengetahui,
Ketua Jurusan Statistika
Fakultas MIPA Universitas Brawijaya



Rahma Fitriani, S.Si., M.Sc., Ph.D
NIP. 197603281999032001



LEMBAR PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Okasha Irfan Izzudin

NIM : 165090507111018

Jurusan : Statistika

Judul Skripsi :

**PEMODELAN MARKOV SWITCHING VECTOR ERROR
CORRECTION MODEL (MS-VECM)**

(Studi Kasus pada Tingkat Inflasi dan Suku Bunga)

Dengan ini menyatakan bahwa :

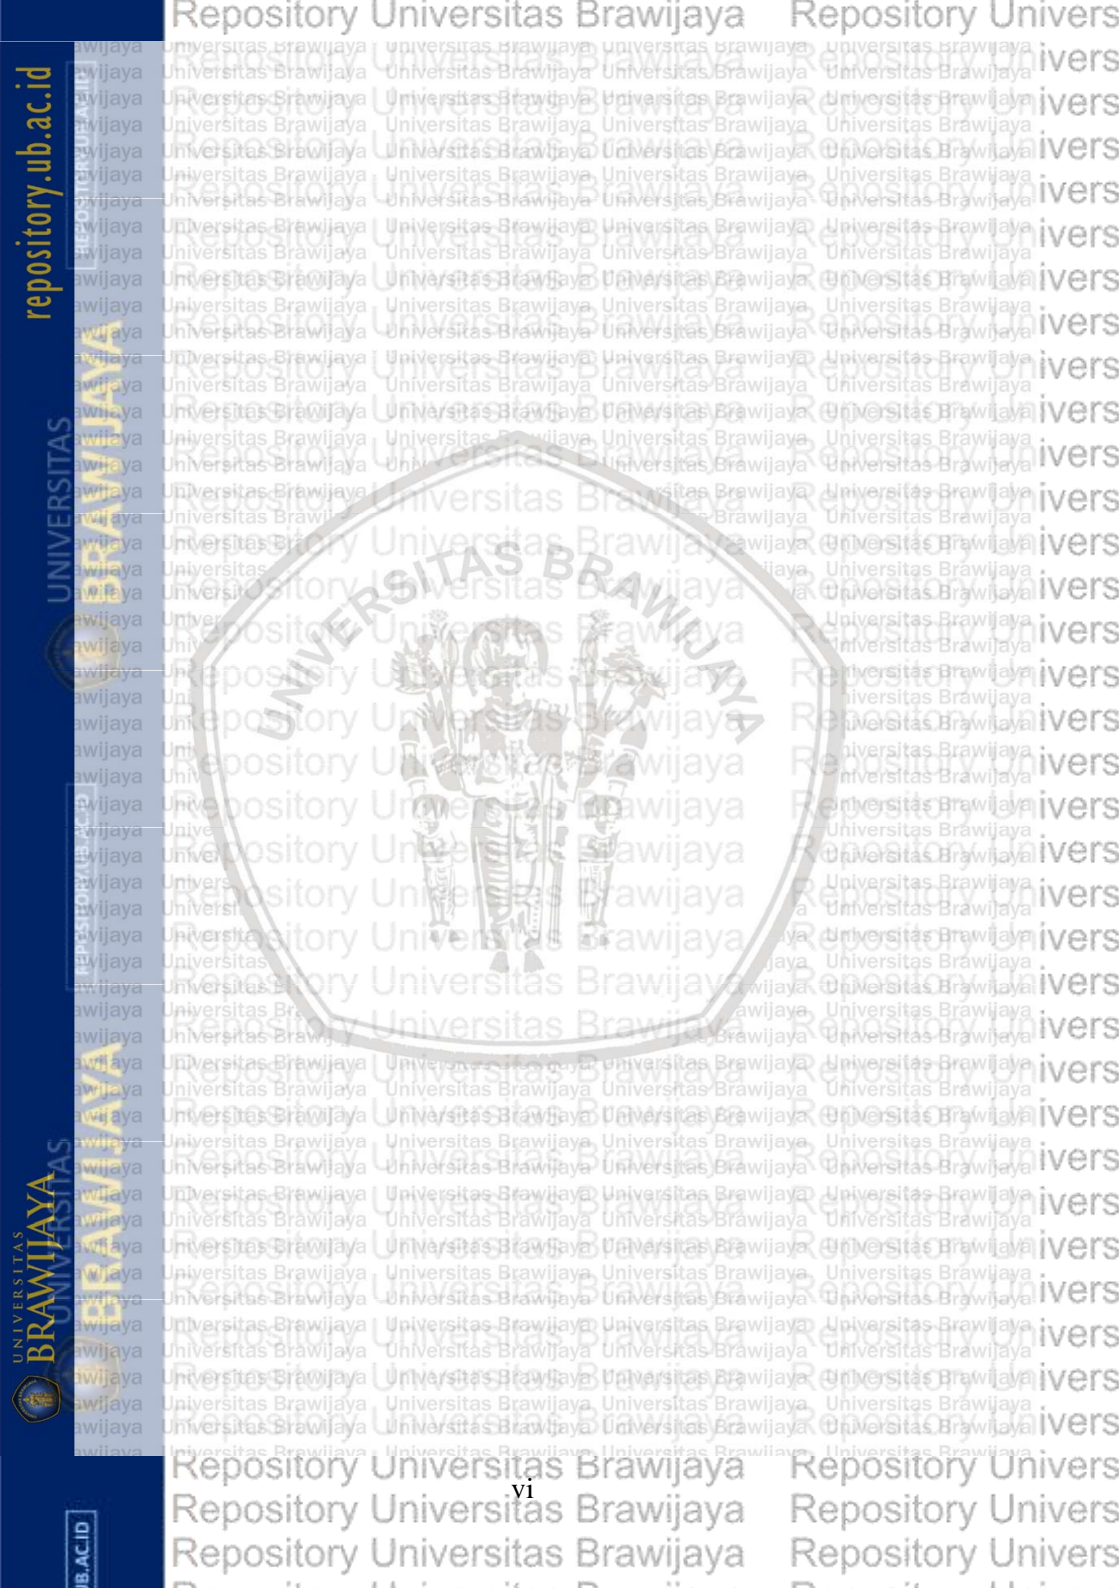
- 1. Isi dari Skripsi yang saya buat adalah benar-benar karya sendiri dan tidak menjiplak karya orang lain, selain nama-nama yang bermaksud di isi dan tertulis di daftar pustaka dalam Skripsi ini.**
- 2. Apabila dikemudian hari ternyata Skripsi yang saya tulis terbukti hasil jiplakan, maka saya akan bersedia menanggung segala risiko yang saya terima.**

Demikian pernyataan ini dibuat dengan segala kesadaran.

Malang, 6 Juli 2020

Yang menyatakan,

Okasha Irfan Izzudin
NIM. 165090507111018



repository.ub.ac.id

UNIVERSITAS BRAWIJAYA



UNIVERSITAS BRAWIJAYA

UNIVERSITAS BRAWIJAYA



UNIVERSITAS BRAWIJAYA

UNIVERSITAS BRAWIJAYA

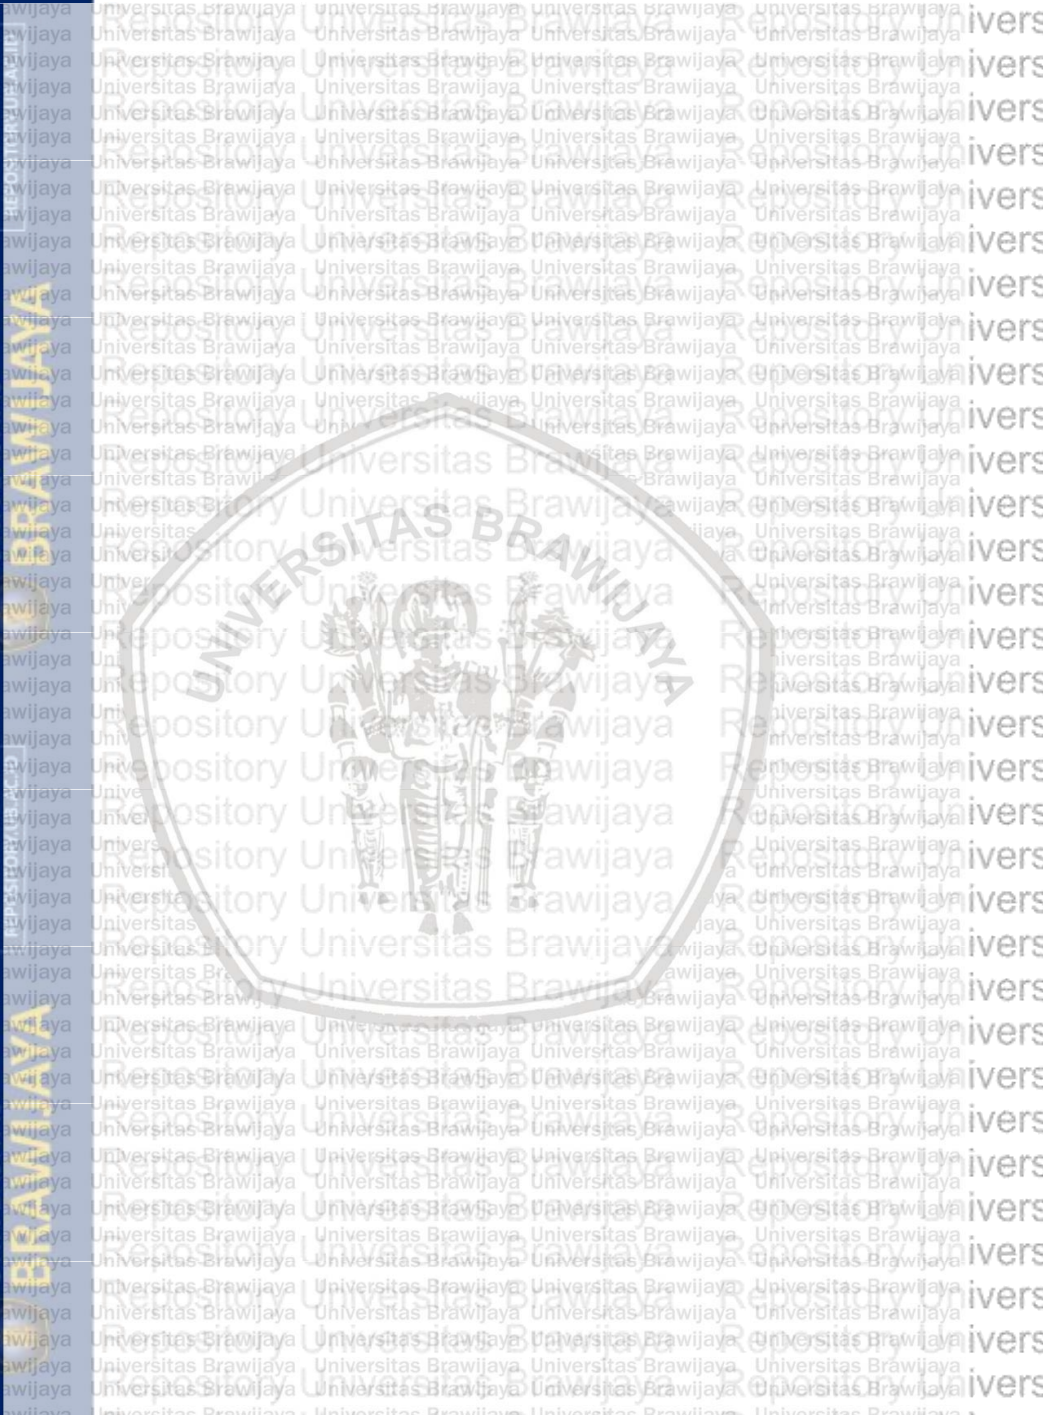


**PEMODELAN MARKOV SWITCHING VECTOR ERROR
CORRECTION MODEL (MS-VECM)
(Studi Kasus pada Tingkat Inflasi dan Suku Bunga)**

ABSTRAK

Tingkat inflasi dan tingkat suku bunga adalah variabel ekonomi makro yang berfluktuatif dikarenakan mengalami perubahan kondisi seiring berjalannya waktu. Perubahan kondisi tersebut dapat menyebabkan kondisi ekonomi menjadi baik atau tidak baik. Pada penelitian ini menggunakan gabungan metode *markov switching* dan *vector error correction model* (VECM). *Markov switching* menangkap perubahan kondisi yang terjadi dengan peluang transisi dan mentransformasikannya sehingga didapatkan *regime switching* (s_t). Sedangkan VECM digunakan sebagai pendekatan hubungan jangka panjang dan jangka pendek. Tujuan dari penelitian ini adalah memodelkan tingkat inflasi dan tingkat suku bunga dengan kondisi yang berbeda menggunakan metode *markov switching vector error correction model* (MS-VECM). Data yang digunakan pada penelitian ini adalah data sekunder tentang data tingkat inflasi dan tingkat suku bunga dari tahun 2005 sampai dengan tahun 2019. Berdasarkan hasil penelitian ini model terbaik yang didapatkan adalah model MS(2)-VECM(2) dan terdapat hubungan dua arah antar inflasi dan suku bunga.

Kata Kunci : MS-VECM, Inflasi, Suku Bunga



MARKOV SWITCHING VECTOR ERROR CORRECTION MODEL MODELING (MS-VECM) (Case Study on Inflation and Interest Rates)

ABSTRACT

Inflation rates and interest rates are macroeconomic variables that fluctuate due to changing conditions over time. Changes in these conditions can cause economic conditions to be good or not good. This research uses a combination of the Markov switching method and the vector error correction model (VECM). Markov switching captures the change in conditions that occur with transition opportunities and transforms them to obtain a switching regime (s_t). Whereas VECM is used as a long-term and short-term relationship approach. The purpose of this study is to model inflation rates and interest rates with different conditions using the markov switching vector error correction model (MS-VECM) method. The data used in this study are secondary data about inflation and interest rate data from 2005 to 2019. Based on the results of this study the best model obtained is the MS(2)-VECM(2) model and there is a two-way relationship between inflation and interest rates.

Keywords : MS-VECM, Inflation, Interest Rates



DAFTAR ISI

| | |
|--|-------------|
| Hal | |
| HALAMAN JUDUL | i |
| LEMBAR PENGESAHAN SKRIPSI | iii |
| LEMBAR PERNYATAAN | v |
| ABSTRAK | vii |
| ABSTRACT | ix |
| KATA PENGANTAR | xi |
| DAFTAR ISI | xiii |
| DAFTAR GAMBAR | xv |
| DAFTAR TABEL | xvii |
| DAFTAR LAMPIRAN | xix |
| BAB I PENDAHULUAN | 1 |
| 1.1. Latar Belakang | 1 |
| 1.2. Rumusan Masalah | 4 |
| 1.3. Tujuan Penelitian | 4 |
| 1.4. Manfaat Penelitian | 4 |
| 1.5. Batasan Masalah | 4 |
| BAB II TINJAUAN PUSTAKA | 5 |
| 2.1. Analisis Deret Waktu | 5 |
| 2.2. Stasioneritas | 6 |
| 2.2.1. Stasioneritas terhadap Ragam | 6 |
| 2.2.2. Stasioneritas terhadap Rata-rata | 7 |
| 2.3. Uji Kausalitas | 9 |
| 2.4. Uji Kointegrasi | 10 |
| 2.5. Uji Lag Optimum | 11 |
| 2.5.1. <i>Matrix Autocorrelation Function (MACF)</i> .. | 11 |
| 2.5.2. <i>Matrix Partial Autocorrelation Function</i> (MPACF) | 12 |
| 2.6. Model <i>Vector Autoregressive (VAR)</i> | 13 |
| 2.7. <i>Vector Error Correction Model (VECM)</i> | 13 |
| 2.7.1. Estimasi Parameter Model VECM | 15 |
| 2.7.2. Pengujian Signifikansi Parameter Model VECM | 16 |
| 2.8. <i>Markov Switching</i> | 17 |
| 2.9. <i>Markov Switching Vector Error Correction Model</i> (MS-VECM)..... | 19 |
| 2.9.1 <i>Filtering dan Smoothing</i> | 20 |
| 2.9.2 Estimasi Parameter Model MS-VECM..... | 21 |



| | | |
|--|---|-----------|
| 2.9.3 | Pengujian Signifikansi Parameter Model MS-VECM | 22 |
| 2.10. | Diagnostik Sisaan Model..... | 22 |
| 2.10.1. | Pengujian Sisaan Bersifat <i>White Noise</i> | 22 |
| 2.10.2. | Pengujian Normalitas Sisaan..... | 23 |
| 2.11. | Tinjauan Non Statistika | 24 |
| 2.11.1. | Tingkat Inflasi..... | 24 |
| 2.11.2. | Suku Bunga Kebijakan | 25 |
| 2.11.3. | Hubungan Tingkat Inflasi dan Suku Bunga Kebijakan..... | 25 |
| BAB III METODE PENELITIAN..... | | 27 |
| 3.1. | Sumber Data..... | 27 |
| 3.2. | Metode Penelitian..... | 27 |
| 3.3. | Diagram Alir | 28 |
| BAB IV HASIL DAN PEMBAHASAN | | 31 |
| 4.1. | Plot Data Deret Waktu..... | 31 |
| 4.1.1. | Plot Data Tingkat Inflasi | 31 |
| 4.1.2. | Plot Data Tingkat Suku Bunga..... | 32 |
| 4.2. | Pengujian Stasioneritas..... | 32 |
| 4.2.1. | Stasioneritas terhadap Ragam | 33 |
| 4.2.2. | Stasioneritas terhadap Rata-rata | 33 |
| 4.3. | Identifikasi <i>lag</i> VECM | 34 |
| 4.4. | Identifikasi Hubungan Kausalitas Granger | 36 |
| 4.5. | Identifikasi Hubungan Kointegrasi | 36 |
| 4.6. | Pendugaan dan Pengujian Signifikansi Parameter VECM | 37 |
| 4.7. | Pendugaan dan Pengujian Signifikansi Parameter Model MS(2)-VECM(2)..... | 39 |
| 4.8. | Pengujian Diagnostik Sisaan Model MS(2)-VECM(2) | 44 |
| 4.8.1. | Pengujian <i>White Noise</i> terhadap Sisaan Model MS(2)-VECM(2) | 44 |
| 4.8.2. | Pengujian Normalitas terhadap Sisaan Model MS(2)-VECM(2) | 45 |
| BAB V PENUTUP..... | | 47 |
| 5.1. | Kesimpulan..... | 47 |
| 5.2. | Saran..... | 47 |
| DAFTAR PUSTAKA | | 49 |
| LAMPIRAN..... | | 51 |



DAFTAR GAMBAR

Hal

Gambar 2.1. Jenis Pola Data..... 5

Gambar 3.1. Langkah-langkah Pembentukan Model MS-VECM ... 28

Gambar 4.1. Plot Data Tingkat Inflasi 31

Gambar 4.2. Plot Data Tingkat Suku Bunga..... 32

Gambar 4.3. Plot Mahalanobis 45





(Halaman ini sengaja dikosongkan)



DAFTAR TABEL

Hal

| | | |
|-------------|---|----|
| Tabel 2.1. | Nilai λ dan Transformasi..... | 7 |
| Tabel 4.1. | Pemeriksaan Stasioneritas terhadap Ragam | 33 |
| Tabel 4.2. | Hasil Uji Dickey-Fuller..... | 34 |
| Tabel 4.3. | Skema <i>Matrix Autocorrelation Function</i> | 35 |
| Tabel 4.4. | Skema <i>Matrix Partial Autocorrelation Function</i> | 35 |
| Tabel 4.5. | Pengujian Kausalitas Granger | 36 |
| Tabel 4.6. | Pengujian Kointegrasi | 36 |
| Tabel 4.7. | Hasil Estimasi Model VECM(2) Persamaan Inflasi | 37 |
| Tabel 4.8. | Hasil Estimasi Model VECM(2) Persamaan Suku Bunga..... | 37 |
| Tabel 4.9. | Hasil Estimasi Model MS(2)-VECM(2) Persamaan Inflasi | 40 |
| Tabel 4.10. | Hasil Estimasi Model MS(2)-VECM(2) Persamaan Suku Bunga..... | 40 |
| Tabel 4.11. | Hasil Uji Portmateau Model MS(2)-VECM(2) | 44 |



(Halaman ini sengaja dikosongkan)



DAFTAR LAMPIRAN

Hal

Lampiran 1. Data Tingkat Inflasi dan Tingkat Suku Bunga bulan Januari 2003 hingga bulan Desember 2019 51

Lampiran 2. Uji Stasioneritas terhadap Ragam dan Rata-rata 55

Lampiran 3. Skema MACF dan MPACF 57

Lampiran 4. Uji Kausalitas Granger 59


Lampiran 5. Uji Kointegrasi 61

Lampiran 6. Pendugaan dan Pengujian Signifikansi Parameter VECM(2) 63

Lampiran 7. Peluang Transisi 65

Lampiran 8. Pendugaan dan Pengujian Signifikansi Parameter MS(2)-VECM(2) 67

Lampiran 9. Diagnostik Sisaan Model 71





(Halaman ini sengaja dikosongkan)

BAB I PENDAHULUAN

1.1. Latar Belakang

Data deret waktu pada variabel-variabel ekonomi dan keuangan sifatnya berfluktuatif, membentuk pola asimetris, atau mempunyai varian residual yang tidak konstan. Analisis deret waktu bertujuan untuk meramalkan nilai suatu data di masa yang akan datang berdasarkan data di masa lampau. Analisis deret waktu dapat melibatkan hanya satu variabel (*univariate*) atau lebih dari satu variabel (*multivariate*). Model yang dapat digunakan pada analisis deret waktu *multivariate* diantaranya model *Autoregressive Integrated Moving Average* (ARIMAX), *Auto Distributed Lag* (ADL), *Vector Autoregressive* (VAR), dan *Vector Error Correction Model* (VECM).

Penelitian pada bidang ekonomi umumnya menggunakan istilah variabel endogen dan eksogen. Dikarenakan umumnya data pada bidang ekonomi sulit untuk didefinisikan sehingga pemecahan masalah hanya sampai jangka pendek. Pada bidang ekonomi umumnya juga dipengaruhi oleh banyak variabel, sehingga model deret waktu yang dapat memodelkannya adalah model deret waktu *multivariate*. Pemecahan masalah pada kasus seperti itu, salah satu penanganannya dapat menggunakan model VAR yang merupakan model *multivariate* pada variabel endogen yang bersifat stasioner, memiliki hubungan dua arah antar variabelnya endogennya, dan tidak saling berkointegrasi. Apabila data tidak stasioner maka dapat dilakukan transformasi dan *differencing*. Namun apabila model VAR memiliki variabel yang saling berkointegrasi maka dapat menggunakan model lain, yaitu model VECM. Dua atau lebih variabel dapat dikatakan berkointegrasi jika variabel-variabel tersebut belum stasioner dan kombinasi antar variabel-variabel tersebut menghasilkan sifat stasioner pada tingkat *first difference*.

Dengan adanya sifat kointegrasi, model VECM dapat menjelaskan efek jangka panjang. Dalam jangka panjang tentu juga rentan dengan adanya perubahan seperti perubahan tingkat ekonomi yang dapat disebabkan oleh banyak hal. Penyebabnya bisa jadi kondisi ekonomi, perang atau juga akibat perubahan kebijakan dari pemerintah. Kondisi tersebut menyebabkan data tidak linear dan dapat mengalami perubahan kondisi (*regime switching*) seiring berjalannya waktu. Model VECM sederhana hanya dapat menjelaskan efek jangka panjang dan kurang bisa menangkap perubahan-perubahan yang tidak



terduga. Sehingga model VECM sederhana tidak cocok digunakan dan diperlukan model lain yang tepat untuk menganalisa data deret waktu pada variabel-variabel yang mengalami perubahan kondisi.

Perubahan kondisi yang tidak teramati dapat diasumsikan merupakan proses stokastik yang membangkitkan variabel acak tidak teramati langsung yang mengikuti orde pertama rantai markov diskrit. Dengan menggunakan rantai markov maka dapat menangkap dinamika yang lebih kompleks dan peluang transisi dimana peluang tersebut merepresentasikan perubahan kondisi yang terjadi. Seiring berjalannya waktu dan dipengaruhi oleh beragam permasalahan ekonomi, dari peluang transisi tersebut dapat berkembang menjadi *markov switching*. Model *markov switching* memanfaatkan peluang transisi berdasarkan *state* yang terjadi. Gabungan dari dua model tersebut akan membentuk model baru yaitu *Markov Switching Vector Error Correction Model* (MS-VECM). Model MS-VECM dapat mengamati perubahan kondisi dari variabel-variabel yang tidak terjelaskan dan ingin diketahui peramalan jangka panjang. Untuk mengestimasi model *markov switching* tidak dapat dilakukan secara langsung dengan metode estimasi parameter pada umumnya karena terdapat *state* yang tidak diketahui nilainya, sehingga dilakukan estimasi *statenya* digunakan proses *filtering* dan *smoothing* kemudian mengkombinasikannya dengan metode estimasi parameter seperti metode *Maximum Likelihood Estimation* (MLE) untuk mengestimasi parameternya.

Inflasi merupakan suatu proses meningkatnya harga-harga secara umum dan terus-menerus berkaitan dengan mekanisme pasar yang dapat disebabkan oleh berbagai faktor (Boediono, 1994). Harga barang dan jasa akan mengalami kenaikan harga maka individu harus mengeluarkan biaya yang lebih banyak dalam jumlah yang tetap. Inflasi juga merupakan ukuran nilai mata uang, jika harga naik berarti nilai uang ketika inflasi akan turun dari sebelumnya. Inflasi menjadi indikator makroekonomi yang perlu dijaga tingkatannya agar tidak menjadi masalah dikemudian hari. Inflasi adalah kejadian dimana terjadi ketidakseimbangan antara *supply* dan *demand*, kejadian seperti inilah yang tidak dapat diprediksi dan menyebabkan adanya perubahan kondisi ekonomi menjadi baik atau tidak baik. Di Indonesia pernah terjadi perubahan inflasi sampai dengan 600% (hiperinflasi) pada tahun 1963-1965. Hal tersebut disebabkan karena pemerintah mencetak uang untuk membayar hutang dan mendanai proyek-proyek menengah.

Suku bunga menyatakan tingkat pembayaran atas pinjaman atau investasi lain, di atas perjanjian pembayaran kembali, yang dinyatakan dalam persentase tahunan (Dornbusch dkk, 2008). Bank Indonesia mengendalikan uang yang beredar dengan dua suku bunga, yaitu suku bunga Sertifikat Bank Indonesia (SBI) dan suku bunga patokan (*benchmark*) yang disebut dengan *BI Rate*. *BI Rate* adalah suku bunga kebijakan yang mencerminkan sikap kebijakan moneter yang diterapkan oleh Bank Indonesia dan diumumkan kepada publik. Namun, Bank Indonesia melakukan penguatan kerangka operasi moneter dengan mengimplementasikan suku bunga acuan atau suku bunga kebijakan baru yaitu *BI 7-day (Reverse) Repo Rate*. Pengendalian suku bunga mengikuti perubahan tingkat inflasi di Indonesia dan dalam rangka untuk menjaga agar kondisi ekonomi Indonesia tetap baik. Sehingga bisa dikatakan bahwa tingkat inflasi dan suku bunga saling mempengaruhi.

Clarida dkk (2003) melakukan penelitian dengan tujuan untuk memodelkan peramalan dari nilai tukar berdasarkan pada vektor *regime-switching*. Hasil dari penelitian ini adalah model secara signifikan mengungguli dari *random walk*. Sedangkan menurut Engel (1994), *Markov switching* untuk delapan nilai tukar pada frekuensi triwulan dan bulanan. Hasil dari penelitian ini adalah model *markov switching* lebih cocok dalam sampel pada triwulan dibanding bulanan. Tetapi, Engel menyatakan bahwa prediksi nilai tukar dengan *markov switching* tidak menghasilkan perkiraan yang lebih baik, dibandingkan dengan *random walk*.

Amaliya (2010) menyatakan bahwa suku bunga dan kurs secara bersama-sama mampu menjelaskan pengaruh pada inflasi. Secara individu suku bunga mempunyai pengaruh positif dan signifikan terhadap inflasi. Pada kenyataannya perubahan dari tingkat inflasi dan suku bunga di Indonesia mengalami perubahan beberapa kondisi contohnya ekonomi baik dan tidak baik sehingga terjadi fluktuasi. Perubahan kondisi tersebut dapat ditangkap melalui peluang perubahan dengan menggunakan *markov switching*. Adanya hubungan antar variabel serta adanya sifat kointegrasi antar kedua variabel dapat diakomodasi menggunakan metode *vector error correction model*. Sehingga penelitian ini akan menggunakan pemodelan *Markov Switching Vector Error Correction Model (MS-VECM)*.

1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan, dapat dirumuskan masalah dalam penelitian ini adalah:

- 1) Bagaimana pemodelan *Markov Switching Vector Error Correction Model* (MS-VECM) pada tingkat inflasi dan tingkat suku bunga dengan dua kondisi yang berbeda?
- 2) Bagaimana hubungan kausalitas tingkat inflasi dan tingkat suku bunga di Indonesia?

1.3. Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah:

- 1) Mendapat model *Markov Switching Vector Error Correction Model* (MS-VECM) pada tingkat inflasi dan tingkat suku bunga dengan dua kondisi yang berbeda.
- 2) Mengetahui hubungan kausalitas antara tingkat inflasi dan tingkat suku bunga.

1.4. Manfaat Penelitian

Manfaat yang diharapkan dari penelitian ini adalah:

- 1) Memberikan informasi mengenai model deret waktu menggunakan *Markov Switching Vector Error Correction Model* (MS-VECM) pada tingkat inflasi dan tingkat suku bunga dengan dua kondisi yang berbeda.
- 2) Memberikan informasi mengenai hasil analisis hubungan kausalitas antara tingkat inflasi dan tingkat suku bunga.

1.5. Batasan Masalah

Batasan masalah pada penelitian ini adalah:


- 1) Data yang digunakan adalah tingkat Inflasi dan Suku Bunga dari tahun Januari 2005 sampai dengan Desember 2019.
- 2) Pemodelan ini menggunakan 2 *state* atau *regime*, yaitu : kondisi ekonomi baik dan ekonomi tidak baik.

BAB II TINJAUAN PUSTAKA


2.1. Analisis Deret Waktu

Deret waktu adalah serangkaian data pengamatan yang disusun berdasarkan waktu. Menurut Wei (2006), deret waktu merupakan serangkaian observasi terhadap suatu variabel yang diambil secara beruntun berdasarkan interval waktu yang tetap. Data deret waktu merupakan proses stokastik, rangkaian data pengamatan deret waktu dinyatakan dengan variabel Y_t dimana t adalah indeks waktu urutan pengamatan. Analisis deret waktu adalah analisis yang dilakukan terhadap serangkaian data pengamatan yang disusun berdasarkan waktu.


Mengetahui jenis pola data deret waktu merupakan langkah penting yang dilakukan untuk memilih metode yang tepat untuk analisis deret waktu. Menurut Makridakis (1999), pola data dapat dibedakan menjadi empat jenis, yaitu seperti ditunjukkan pada Gambar 2.1.




(a) Pola Horizontal



(b) Pola Trend



(c) Pola Musiman



(d) Pola Siklis

Gambar 2.1. Jenis Pola Data

Pemilihan jenis pola data harus dipertimbangkan dengan baik karena digunakan untuk penentuan metode. Gambar 2.1 menjelaskan pola berikut:

- a Pola *Horizontal*, pola *horizontal* terjadi apabila nilai data bergerak di sekitar nilai rata-rata yang konstan atau dengan kata lain data sudah stasioner terhadap nilai rata-rata.
- b Pola *Trend*, pola *trend* terjadi apabila terdapat kecenderungan data naik atau turun pada jangka panjang.
- c Pola musiman, merupakan pola permintaan yang bergerak bebas dan muncul secara periodik dalam jangka pendek serta berulang.
- d Pola Siklis, merupakan pergerakan permintaan yang naik dan turun yang berulang dan terjadi dalam jangka panjang (lebih dari satu tahun).

Setelah mengetahui jenis dari pola data deret waktu, langkah selanjutnya adalah mengetahui sifat stasioneritas data deret waktu tersebut.

2.2. Stasioneritas

Asumsi harus dipenuhi dalam membuat suatu keputusan pada proses stokastik, salah satu asumsi yang harus dipenuhi adalah stasioneritas. Menurut Wei (2006), proses stasioner adalah ketika rata-rata $E(Y_t) = \mu$ dan ragam $var(Y_t) = E(Y_t - \mu)^2 = \sigma^2$ konstan. Suatu data deret waktu memiliki proses yang stasioner apabila data berada di sekitar rata-rata konstan dan tidak bergantung pada waktu serta ragam dari fluktuasi tersebut konstan dari waktu ke waktu. Asumsi stasioneritas terbagi menjadi dua, diantaranya stasioneritas ragam dan stasioneritas rata-rata.

2.2.1. Stasioneritas terhadap Ragam

Kestasioneran data deret waktu terhadap ragam dapat dilihat melalui nilai λ . Apabila nilai $\lambda = 1$, maka dapat dikatakan data sudah stasioner terhadap ragam. Data deret waktu yang tidak stasioner terhadap ragam dapat distasionerkan dengan cara transformasi *Box Cox* yaitu transformasi pangkat pada respon (Wei, 2006).

Transformasi *Box-Cox* merupakan transformasi pangkat pada variabel respon yang bertujuan untuk menormalkan data, melinearakan model regresi dan menghomogenkan varians. Transformasi *Box Cox* mempertimbangkan kelas transformasi λ berparameter tunggal, yaitu yang dipangkatkan pada variabel respon Y , sehingga diperoleh model transformasinya Y^λ dengan λ merupakan parameter yang harus diduga. Transformasi *Box Cox* hanya diberlakukan pada variabel respon Y yang bertanda positif (Draper & Smith, 1998). Prosedur utama yang dilakukan pada Transformasi *Box Cox* adalah menduga



parameter λ , yang dilakukan dengan mencari nilai W_i dan V_i melalui persamaan 2.1.

$$W_i = \begin{cases} \frac{Y^\lambda - 1}{\lambda}; & \lambda \neq 0 \\ \ln Y; & \lambda = 0 \end{cases} \quad (2.1)$$

$$V_i = \begin{cases} \frac{W_i}{Y_{geo}^{\lambda-1}}; & \lambda \neq 0 \\ Y_{geo} \ln Y; & \lambda = 0 \end{cases}$$

dengan

$$Y_{geo} = \sqrt[n]{Y_1 Y_2 \dots Y_n} = \left(\prod_{i=1}^n Y_i \right)^{\frac{1}{n}}$$

Selanjutnya meregresikan antara V_i dan X sehingga diperoleh nilai JKG dan nilai λ yang dipilih adalah λ yang menghasilkan nilai JKG terkecil. Setelah itu dilakukan transformasi pada variabel respon Y dengan nilai λ yang telah dipilih. Berikut merupakan beberapa nilai λ dan transformasi yang umum digunakan ditulis pada tabel 2.1. (Neter dkk, 1997):

Tabel 2.1. Nilai λ dan Transformasi

| λ | -2 | -1 | -0.5 | 0 | 0.5 | 1 | 2 |
|--------------|-------------------|-----------------|------------------------|------------|--------------|-------|---------|
| Transformasi | $\frac{1}{Y_t^2}$ | $\frac{1}{Y_t}$ | $\frac{1}{\sqrt{Y_t}}$ | $\ln(Y_t)$ | $\sqrt{Y_t}$ | Y_t | Y_t^2 |

2.2.2. Stasioneritas terhadap Rata-rata

Stasioneritas data deret waktu terhadap rata-rata dapat dilihat secara deskriptif melalui plot data. Data dapat dikatakan stasioner terhadap rata-rata apabila plot data memiliki pola *horizontal*. Sedangkan pada data yang memiliki pola *trend* atau musiman, maka dapat dikatakan data belum stasioner terhadap rata-rata. Stasioneritas data deret waktu terhadap rata-rata juga dapat diperiksa menggunakan uji akar unit Dickey-Fuller.

Uji ini pertama kali diperkenalkan oleh David Dickey dan Wayne Fuller. Menurut Gujarati (2003) uji akar unit dapat dipandang melalui model AR(1) sebagai berikut.

$$Y_t = \rho Y_{t-1} + u_t; \quad -1 \leq \rho \leq 1 \quad (2.2)$$

Jika nilai dari $\rho = 1$, maka variabel *random Z* memiliki akar unit. Jika suatu deret waktu memiliki akar unit, maka dapat dikatakan bahwa model tersebut adalah *random walk with drift*. Variabel dikatakan tidak stasioner ketika data bergerak secara *random walk with drift*. Untuk mengatasi permasalahan tersebut, kedua sisi pada persamaan 2.2 dikurangi Y_{t-1} sehingga menghasilkan persamaan seperti pada persamaan 2.3.

$$\begin{aligned}
 Y_t - Y_{t-1} &= \rho Y_{t-1} - Y_{t-1} + u_t \\
 Y_t - Y_{t-1} &= (\rho - 1)Y_{t-1} + u_t \quad (2.3) \\
 \nabla Y_t &= \delta Y_{t-1} + u_t
 \end{aligned}$$

Hipotesis yang digunakan dalam uji akar unit Dickey-Fuller sebagai berikut.

- $H_0 : \delta \geq 0$ yaitu terdapat akar unit atau Y_t tidak stasioner
- $H_1 : \delta < 0$ yaitu tidak terdapat akar unit atau Y_t stasioner

Statistik uji yang digunakan dalam uji akar unit Dickey-Fuller adalah statistik uji t seperti pada persamaan 2.3 (Makridakis, 1999).

$$t = \frac{\hat{\delta}}{se(\hat{\delta})} \quad (2.4)$$

dengan

$$\hat{\delta} = \frac{\sum_{t=1}^n Y_{t-1} Y_t}{\sum_{t=1}^n Y_{t-1}^2} \quad \hat{\sigma}_{Y_t}^2 = \frac{\sum_{t=1}^n (Y_t - \hat{\delta} Y_{t-1})^2}{n-1}$$

$$se(\hat{\delta}) = \sqrt{\frac{\hat{\sigma}_{Y_t}^2}{\sum_{t=1}^n Y_{t-1}^2}}$$

$t = 1, 2, \dots, n$

- $\hat{\delta}$: nilai penduga parameter *autoregressive*
- $\hat{\sigma}_{Y_t}^2$: penduga ragam data
- Y_t : obsevasi ke t
- $se(\hat{\delta})$: salah baku penduga $\hat{\delta}$
- n : banyak observasi yang digunakan

Statistik uji pada persamaan (2.4) mengikuti distribusi t dengan derajat bebas $n - 1$. Uji akar unit Dickey-Fuller merupakan uji akar unit yang menggunakan hipotesis satu arah. Kriteria penolakan H_0 adalah ketika nilai statistik uji lebih besar dari titik kritis $t_{\alpha-1}^n$ sehingga dapat

disimpulkan bahwa variabel stasioner. Apabila data tidak stasioner terhadap rata-rata maka harus dilakukan proses pembedaan (*differencing*) hingga stasioner.

2.3. Uji Kausalitas

Hubungan kausalitas adalah hubungan jangka pendek antara kelompok tertentu dengan menggunakan pendekatan ekonometrik dan mencakup hubungan timbal balik antar kelompok. Dalam bidang ekonomi, model regresi linier di mana variabel dependen diregresikan di atas variabel independen tidak dapat dipastikan mengandung pengertian bahwa variabel dependen secara kausal benar-benar ditentukan oleh variabel independen secara sepihak. Ada kemungkinan dalam suatu model persamaan tunggal, variabel dependen ditentukan oleh variabel independen, tetapi sebaliknya variabel independen juga ditentukan oleh variabel dependen sehingga dalam hal ini terdapat kausalitas dua arah (Arief, 1993). Uji kausalitas merupakan metode yang digunakan untuk menentukan hubungan kausalitas dalam sistem persamaan simultan. Hubungan kausalitas dapat terjadi antar dua variabel, jika suatu variabel dipengaruhi oleh variabel yang lain dengan menggunakan *lag*. Salah satu uji kausalitas adalah uji kausalitas Granger. Berikut langkah-langkah dalam pengujian kausalitas Granger.

- 1) Meregresikan $Y_{1,t}$ dengan seluruh *lag* $Y_{1,t}$ tanpa mengikutsertakan *lag* $Y_{2,t}$ sehingga didapatkan model *restricted regression* sebagai berikut.

$$Y_{1,t} = \sum_{i=1}^p \beta_i Y_{1,t-i} + u_{1,t} \quad (2.5)$$

$$Y_{2,t} = \sum_{i=1}^p \lambda_i Y_{2,t-i} + u_{2,t} \quad (2.6)$$

Akan didapatkan *restricted residual sum of square* (RSS_R).

- 2) Meregresikan $Y_{1,t}$ dengan *lag* $Y_{1,t}$ dan mengikutsertakan *lag* $Y_{2,t}$ sehingga didapatkan model *unrestricted regression* sebagai berikut.

$$Y_{1,t} = \sum_{j=1}^p \beta_j Y_{1,t-j} + \sum_{i=1}^p \alpha_i Y_{2,t-i} + u_{1,t} \quad (2.7)$$

$$Y_{2,t} = \sum_{j=1}^p \nu_j Y_{1,t-j} + \sum_{i=1}^p \lambda_i Y_{2,t-i} + u_{2,t} \quad (2.8)$$

Akan didapatkan *unrestricted residual sum of square* (RSS_U).

- 3) Melakukan hipotesis bahwa $Y_{2,t}$ merupakan penyebab kausalitas bagi $Y_{1,t}$ sebagai berikut.

$$H_0 : \alpha = 0 \quad \text{vs.} \quad H_1 : \alpha \neq 0$$

- 4) Menguji hipotesis menggunakan uji F.

$$F = \frac{(RSS_R - RSS_U) / p}{RSS_U / (n - k)} \sim F_{(p, n-k)} \quad (2.9)$$

dengan

p : panjang lag

n : banyak observasi yang digunakan

k : banyak parameter yang pada *unrestricted regression*

Apabila uji F yang dihasilkan lebih kecil dari $F_{(p, n-k)}$, maka diperoleh keputusan untuk menerima H_0 .

- 5) Mengulangi langkah a hingga d untuk menguji bahwa $Y_{1,t}$ merupakan penyebab kausalitas bagi $Y_{2,t}$, dengan hipotesis:

$$H_0 : \nu_j = 0 \quad \text{vs.} \quad H_1 : \nu_j \neq 0$$

Jika pada hasil pengujian kausalitas granger menunjukkan $F_{hitung} > F_{(p, n-k)}$ maka H_0 ditolak. Menurut Gujarati (2003), Ada beberapa kemungkinan yang dapat terjadi dari hasil uji kausalitas Granger, yaitu:

1. Y_2 mempengaruhi Y_1 atau *unidirectional causality form Y_2 to Y_1* ($Y_2 \rightarrow Y_1$).
2. Y_1 mempengaruhi Y_2 atau *unidirectional causality form Y_1 to Y_2* ($Y_1 \rightarrow Y_2$).
3. Y_1 dan Y_2 saling mempengaruhi atau *feedback* atau *bilateral causality* ($Y_1 \leftrightarrow Y_2$).
4. Y_1 dan Y_2 tidak saling mempengaruhi atau *independent* ($Y_1 // Y_2$).

2.4. Uji Kointegrasi

Uji kointegrasi merupakan uji yang dilakukan untuk menguji suatu integrasi keseimbangan pada jangka panjang hubungan antar variabel baik secara individual tidak stasioner namun kombinasi linier dari variabel tersebut stasioner. Uji kointegrasi diperlukan apabila stasioneritas data berada ditingkat *first difference*. Pada dasarnya uji kointegrasi ini digunakan sebagai alat untuk melihat keseimbangan suatu data pada jangka panjang diantara variabel-variabel yang diamati. Sebagai contoh, jika semua variabel dikumpulkan dalam

sebuah vektor $Y_t = (Y_{1t}, \dots, Y_{kt})'$ dengan fungsi ekuilibrium jangka panjang $\beta'Y_t = \beta_1Y_{1t} + \dots + \beta_kY_{kt}$, dengan $\beta = (\beta_1, \dots, \beta_k)'$. Secara umum, vektor Y_t dikatakan terkointegrasi pada order (d, b) dengan $Y_t \sim CI(d, b)$, jika semua komponen dari Y_t adalah $I(d)$ dan terdapat kombinasi linier $Z_t = \beta'Y_t$ dengan Z_t adalah $I(d-b)$. Sebagai contoh, jika Y_{1t} dan Y_{2t} tidak stasioner dan kombinasi linier $(Y_{1t} - \beta_1Y_{2t})$ adalah stasioner, maka dua variabel tersebut terkointegrasi.

Untuk menguji adanya kointegrasi dapat dilakukan dengan menggunakan metode uji *Trace test*, yaitu uji untuk mengukur jumlah vektor kointegrasi dalam data deret waktu dengan menggunakan pengujian rank kointegrasi. Hipotesis yang digunakan adalah sebagai berikut.

$$H_0 : r_j = 0 \text{ vs. } H_1 : r_j > 0$$

Statistik uji yang digunakan adalah sebagai berikut.

$$T_r(r) = -n \sum_{i=r+1}^m \ln(1 - \lambda_i) \quad (2.10)$$

dengan

$i = 1, 2, \dots, p$

$\hat{\lambda}$: estimasi dari *eigen value*

n : banyak observasi yang digunakan

r : rank kointegrasi

m : banyak variabel endogen

2.5. Uji Lag Optimum

Pada tahap identifikasi, proses pembentukan model VAR dilakukan melalui identifikasi plot *time series*, MACF (*Matrix Autocorrelation Function*), MPACF (*Matrix Partial Autocorrelation Function*). Setelah data diketahui stasioner melalui plot deret waktu, maka dilakukan analisis bentuk dari MACF dan MPACF.

2.5.1. Matrix Autocorrelation Function (MACF)

Diberikan suatu vektor deret waktu sebanyak t pengamatan Y_1, Y_2, \dots, Y_t matriks korelasi sampel dinyatakan sebagai berikut: (Wei, 2006):

$$\hat{\rho}_k = \left[\rho_{i,j}(k) \right] \quad (2.11)$$

dengan

ρ_k : korelasi variabel ke- i dan variabel ke- j pada lag k



$$\rho_{i,j}(k) = \frac{\sum_{t=1}^{n-k} (Y_{i,t} - \bar{Y}_i)(Y_{j,t+k} - \bar{Y}_j)}{\left[\sum_{t=1}^n (Y_{i,t} - \bar{Y}_i)^2 \sum_{t=1}^n (Y_{j,t} - \bar{Y}_j)^2 \right]^{1/2}} \quad (2.12)$$

Dengan matriks dan grafik semakin kompleks apabila dimensi dan vektornya semakin besar, sehingga menyulitkan dalam hal pengidentifikasian. Untuk mempermudah metode yang digunakan adalah dengan menggunakan simbol yang dinotasikan dengan (+), (-) dan (.) pada matriks korelasi sampel ke k .

- a Simbol (+) diartikan sebagai ρ_k lebih besar dari 2 kali standard error dan menunjukkan hubungan memiliki korelasi positif.
- b Simbol (-) diartikan sebagai ρ_k kurang dari -2 kali standard error dan menunjukkan hubungan memiliki korelasi negatif.
- c Simbol (.) diartikan sebagai ρ_k berada diantara ± 2 kali standard error dan menunjukkan tidak adanya korelasi.

2.5.2. Matrix Partial Autocorrelation Function (MPACF)

Fungsi matriks parsial korelasi sampel sangat diperlukan dalam model AR. Korelasi antara Y_t dan Y_{t+k} dapat diketahui setelah dependensi linier pada variabel $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$ dihilangkan. Persamaan matriks fungsi korelasi diri parsial (MPACF) dirumuskan sebagai berikut (Wei, 2006):

$$P(k) = \begin{cases} \Gamma'(1)[\Gamma'(0)]^{-1}, & k=1 \\ \left\{ \Gamma'(k) - \mathbf{c}'(k)[\mathbf{A}(k)^{-1}\mathbf{b}'(k)[\mathbf{A}(k)]^{-1}\mathbf{b}(k) \right\}, & k > 1 \end{cases} \quad (2.13)$$

Sedangkan untuk $k \geq 2$, nilai dari $\mathbf{A}(k), \mathbf{b}(k)$, dan $\mathbf{c}(k)$ adalah sebagai berikut:

$$\mathbf{A}(k) = \begin{bmatrix} \Gamma(0) & \Gamma'(1) & \dots & \Gamma'(k-2) \\ \Gamma(1) & \Gamma(0) & \dots & \Gamma'(k-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(k-2) & \Gamma(k-3) & \dots & \Gamma(0) \end{bmatrix}$$

$$\mathbf{b}(k) = \begin{bmatrix} \Gamma'(k-1) \\ \Gamma'(k-2) \\ \vdots \\ \Gamma'(1) \end{bmatrix}, \quad \mathbf{c}(k) = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(k-1) \end{bmatrix} \quad (2.13)$$

dimana $\Gamma(k)$ merupakan matriks kovarians *lag* ke- k

Nilai dari estimasi sampel $P(k)$ dapat dihitung dengan menggantikan sampel matriks kovarians $\Gamma(k)$ yang belum terungkap:

$$\bar{\Gamma}(k) = \frac{1}{T} \sum_{t=1}^{T-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})', k = 1, 2, \dots \quad (2.13)$$

dimana \bar{Y} sebagai vektor rata-rata sampel.

2.6. Model Vector Autoregressive (VAR)

Model VAR adalah suatu sistem persamaan yang memperlihatkan setiap variabel sebagai fungsi linier dari konstanta dan nilai *lag* dari variabel itu sendiri serta nilai *lag* dari variabel yang ada dalam sistem. Secara umum model VAR *lag* p untuk n variabel dapat diformulasikan sebagai berikut (Shochrul, R.A., dkk, 2011):

$$\begin{aligned} Y_t &= A_0 + A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_i Y_{t-i} + u_t \\ &= A_0 + \sum_{i=1}^p A_i Y_{t-i} + u_t \end{aligned} \quad (2.14)$$

dengan:

$t = 1, 2, \dots, n$

$i = 1, 2, \dots, p$

Y_t : vektor variabel endogen pada periode ke- t berukuran $m \times 1$

Y_{t-p} : vektor variabel endogen pada *time lag* ke- $(t-p)$ berukuran $m \times 1$

A_0 : vektor intersep berukuran $m \times 1$

A_i : matriks koefisien berukuran $m \times m$

u_t : vektor sisaan berukuran $m \times 1$

p : *lag* VAR

t : periode amatan

m : banyak variabel endogen

n : banyak observasi yang digunakan

Pada model VAR mempunyai kelebihan yaitu metode ini sederhana karena seluruh variabel merupakan variabel endogen, estimasi yang digunakan sederhana dimana metode kuadrat terkecil dapat diaplikasikan pada tiap-tiap persamaan. Data *time series* harus stasioner bersama dan independensi kesalahan (*error* tidak ada autokorelasi) untuk terbentuk model VAR.

2.7. Vector Error Correction Model (VECM)

Model VAR dapat diterapkan apabila semua variabel yang digunakan stasioner, akan tetapi apabila terdapat variabel endogen

yang tidak stasioner maka model yang digunakan dalam *Vector Error Correction Model* (VECM) dengan syarat terdapat satu atau lebih hubungan kointegrasi antar variabel. Robert dan Granger (1987) menggabungkan model kointegrasi dan *error correction model*, untuk membentuk VECM. Selama ada hubungan kointegrasi antara variabel, *error correction model* dapat diturunkan dari model lag *autoregressive distributed*. Setiap persamaan dalam model VAR adalah model lag *autoregressive distributed*. Oleh karena itu dapat dianggap bahwa VECM adalah model VAR dengan kendala kointegrasi. Menurut Enders (2004), variabel-variabel dalam VECM turunan pertama dalam model VAR yang dibedakan oleh *Error Correction Term* (ECT) atau dapat dikatakan bahwa VECM merupakan variabel yang terkointegrasi pada orde pertama $[I(1)]$. ECT adalah hubungan dinamis jangka pendek dari suatu variabel di dalam sistem dipengaruhi oleh penyimpangan dari keseimbangan jangka panjang.

Diasumsikan $Y_t = (Y_{1t}, Y_{2t}, \dots, Y_{mt})'$ sebagai stokastik *time series* k-dimensi, lalu model VAR sesuai dengan persamaan (2.14) dapat ditransformasi kointegrasi menjadi persamaan 2.15. (Zou, 2018).

$$\Delta Y_t = \prod Y_{t-1} + \sum_{i=1}^{p-1} \Gamma_i \Delta Y_{t-i} + u_t \quad (2.15)$$

dengan

$$\prod = \sum_{i=1}^p A_i - I,$$

$$\Gamma_i = -\sum_{j=i+1}^p A_j$$

Jika Y_t memiliki hubungan kointegrasi, lalu $\prod Y_{t-1} \sim I(0)$ maka dapat dituliskan sebagai berikut:

$$\begin{aligned} \Delta Y_t &= a(\beta' Y_{t-1} + c) + \sum_{i=1}^p a_i \Delta Y_{t-i} + u_t \\ &= aecm_{t-1} + \sum_{i=1}^p a_i \Delta Y_{t-i} + u_t \end{aligned} \quad (2.16)$$

dengan $\beta' Y_{t-1} + c = ecm_{t-1}$ adalah istilah *Error Correction Term* (ECT), yang mencerminkan hubungan ekuilibrium jangka panjang antar variabel.

Kondisi keseimbangan akan terpenuhi apabila nilai ECT sama dengan nol. Bentuk umum VECM dengan memasukan variabel perubahan sampai dengan lag ke- p atau model penyesuaian jangka pendek adalah sebagai berikut:

$$\begin{aligned} \Delta Y_{1t} &= a_{10} + a_{1ecm} ECM_{t-1} + \sum_{i=1}^p a_{11,i} \Delta Y_{1t-i} + \sum_{i=1}^p a_{12,i} \Delta Y_{2t-i} + u_{1,t} \\ &= a_{10} + a_{1ecm} (Y_{1t-1} - \beta_0 - \beta_1 Y_{2t-1} - \dots - \beta_m Y_{mt-1}) \\ &\quad + \sum_{i=1}^p a_{11,i} \Delta Y_{1t-i} + \sum_{i=1}^p a_{12,i} \Delta Y_{2t-i} + u_{1,t} \end{aligned} \quad (2.17)$$

$$\begin{aligned} \Delta Y_{2t} &= a_{20} + a_{2ecm} ECM_{t-1} + \sum_{i=1}^p a_{21,i} \Delta Y_{1t-i} + \sum_{i=1}^p a_{22,i} \Delta Y_{2t-i} + u_{2,t} \\ &= a_{20} + a_{2ecm} (Y_{1t-1} - \beta_0 - \beta_1 Y_{2t-1} - \dots - \beta_m Y_{mt-1}) \\ &\quad + \sum_{i=1}^p a_{21,i} \Delta Y_{1t-i} + \sum_{i=1}^p a_{22,i} \Delta Y_{2t-i} + u_{2,t} \end{aligned} \quad (2.18)$$

- dengan
- Y_{t-i} : variabel endogen dengan lag ke- i
 - a_{10} dan a_{20} : konstanta
 - a_{1ecm} dan a_{2ecm} : parameter variabel ECT
 - $a_{11,i}$ dan $a_{21,i}$: parameter dari perubahan variabel ke- 1
 - $a_{12,i}$ dan $a_{22,i}$: parameter dari perubahan variabel ke- 2

Dari model diatas, jika terdapat sebanyak m variabel endogen maka bentuk VECM dalah sebagai berikut:

$$\begin{bmatrix} \Delta Y_{1t} \\ \Delta Y_{2t} \\ \vdots \\ \Delta Y_{mt} \end{bmatrix} = \begin{bmatrix} a_{10} & a_{1ecm} & a_{11,1} & a_{12,1} & \dots & a_{11,p} & a_{12,p} \\ a_{20} & a_{2ecm} & a_{21,1} & a_{22,1} & \dots & a_{21,p} & a_{22,p} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ a_{m0} & a_{mecm} & a_{m1,1} & a_{m2,1} & \dots & a_{m1,p} & a_{m2,p} \end{bmatrix} \begin{bmatrix} 1 \\ \beta^T Y_{t-1} \\ \Delta Y_{1t-p} \\ \Delta Y_{2t-p} \\ \vdots \\ \Delta Y_{mt-p} \end{bmatrix} + \begin{bmatrix} u_{1,t} \\ u_{2,t} \\ \vdots \\ u_{m,t} \end{bmatrix}$$

2.7.1. Estimasi Parameter Model VECM

Estimasi parameter diatas dapat dilakukan dengan metode *Maximum Likelihood Estimator* (MLE), dengan asumsi bahwa error u_t adalah normal ($u_t \sim N(0, \Sigma)$). Fungsi kepadatan peluang dari u_t adalah:

$$f(u_t, \Sigma) = \frac{1}{(2\pi)^{\frac{1}{2}} |\Sigma|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} u_t^T \Sigma^{-1} u_t \right] \quad (2.19)$$

Bila terdapat data *series* sebanyak M dan panjang *lag* yang digunakan sampai dengan *lag* ke- p maka fungsi normal *likelihood* adalah:

$$\begin{aligned}
 L(u_t, \Sigma) &= \prod_{t=p+1}^M f(u_t, \Sigma) \\
 &= \prod_{t=p+1}^M \frac{1}{(2\pi)^{1/2} |\Sigma|^{1/2}} \exp\left[-\frac{1}{2} u_t^T \Sigma^{-1} u_t\right] \\
 &= (2\pi)^{-(M-p)/2} |\Sigma|^{-(M-p)/2} \exp\left[-\frac{1}{2} \sum_{t=p+1}^M u_t^T \Sigma^{-1} u_t\right] \quad (2.20)
 \end{aligned}$$

Jika n adalah $M - p$ maka persamaan dapat diubah menjadi:

$$L(u_t, \Sigma) = (2\pi)^{-n/2} |\Sigma|^{-n/2} \exp\left[-\frac{1}{2} \sum_{t=p+1}^M u_t^T \Sigma^{-1} u_t\right] \quad (2.21)$$

Untuk mempermudah melakukan estimasi parameter, maka fungsi di atas diubah ke dalam bentuk *natural logaritma* (\ln) menjadi fungsi *ln likelihood*. Berikut merupakan fungsi *ln likelihood* dari persamaan di atas.

$$\ln(u_t, \Sigma) = \frac{-n}{2} \ln(2\pi) - \frac{n}{2} \ln|\Sigma| - \frac{1}{2} \sum_{t=p+1}^M u_t^T \Sigma^{-1} u_t \quad (2.22)$$

dengan

$$u_t = \Delta y_t - A^T y_{t-1}$$

Estimasi matriks koefisien A dan Σ dapat diperoleh dengan menurunkan persamaan fungsi *likelihood* secara parsial terhadap parameter yang ingin diestimasi kemudian disamakan dengan nol, sehingga menjadi sebagai berikut:

$$A = \left(\sum_{t=p+1}^M (y_{t-1})(y_{t-1})'\right)^{-1} \left(\sum_{t=p+1}^M (y_{t-1})(\Delta y_t)'\right) \quad (2.23)$$

$$\Sigma = \frac{1}{n} \sum_{t=p+1}^M (\Delta y_t - A' y_{t-1})(\Delta y_t - A' y_{t-1})' \quad (2.24)$$

2.7.2. Pengujian Signifikansi Parameter Model VECM

Untuk menguji signifikansi antar variabel dan untuk melihat apakah variabel eksogen secara individu mempengaruhi variabel endogen adalah menggunakan uji t (Gujarati, 2003).

$$H_0 : a_i = 0 \quad \text{vs.} \quad H_1 : a_i \neq 0$$

Statistik uji t yang digunakan sebagai berikut.

$$t = \frac{a}{se(a)} \sim t_{n-p} \quad (2.25)$$

dengan



$$se(\mathbf{a}) = \sqrt{\frac{S^2 Y_t}{n}} \quad S^2 Y_t = \frac{\sum_{t=1}^T (Y_t - \bar{Y})^2}{n-1}$$

$i = 1, \dots, p$

\mathbf{a} : matriks penduga parameter

$se(\mathbf{a})$: salah baku penduga parameter

p : banyak parameter yang diduga

Kriteria pengujian yang digunakan adalah apabila $|t| > t_{(\alpha/2, n-p)}$, maka dapat diputuskan untuk menolak H_0 . Selain itu, kriteria pengujian yang dapat digunakan yaitu dengan membandingkan antara nilai- p dengan taraf nyata yang digunakan (α). Penolakan H_0 terjadi apabila nilai- $p < \alpha$ yang artinya parameter pada taraf nyata α dalam model tersebut signifikan.

2.8. Markov Switching

Perubahan (*switching*) dapat terjadi pada rata-rata, maupun rata-rata dan varian dengan $u_t \sim N(0, \sigma_{st}^2)$. Model dengan *switching* pada nilai rata-rata dan varian dapat dituliskan:

$$y_t = \mu_{st} + u_t \quad (2.26)$$

Variabel acak tidak teramati yang sering disebut dengan *state* atau *regime* disimbolkan dengan s_t , dengan $s_t \in \{1, 2, \dots, M\}$ dan M adalah banyaknya *state* (Hamilton, 1994). Sesuai dengan karakteristik rantai markov, bahwa peluang bersyarat kejadian yang sekarang tergantung pada kejadian sebelumnya (Shamshad dkk.2005). Sebuah proses stokastik memperlihatkan sifat-sifat markov jika $(P(X)_t = j | X_{t-1} = i) = (P(X)_t = j | X_{t-1} = i, X_{t-2} = k, \dots, M)$. Dengan kata lain peluang kejadian t tergantung pada waktu $t - 1$. Peluang bersyaratnya $P(X_{t=j} | X_{t-1} = i) = p_{ij}$ disebut peluang transisi 1-langkah. Matriks peluang transisi dapat dinotasikan sebagai berikut.

$$P = \begin{bmatrix} P_{00} & P_{01} & \dots & P_{0M} \\ P_{10} & P_{11} & \dots & P_{1M} \\ \vdots & \vdots & \ddots & \vdots \\ P_{M0} & P_{M1} & \dots & P_{MM} \end{bmatrix} \quad (2.27)$$

dengan $0 \leq p_{ij} \leq 1, \sum_{j=i}^M p_{ij} = 1$, untuk setiap $i = 1, 2, \dots, M$.



Dalam Touama (2015), probabilitas state pada waktu t dapat diperkirakan dari frekuensi relatif *state* M , jika f_{ij} adalah jumlah transisi dari keadaan i ke keadaan j dalam urutan data maka kemungkinan maksimum perkiraan probabilitas transisi dapat dirumuskan sebagai berikut.

$$P_{ij} = \frac{f_{ij}}{\sum_{i=0}^M f_{ij}}, j=1,2,\dots,n \quad (2.28)$$

Rantai markov orde pertama adalah rantai markov yang hanya bergantung pada satu nilai sebelumnya. Probabilitas transisi pada orde pertama atau 1-langkah dapat di modelkan sebagai berikut (Paranchych dan Beaulieu, 1996).

$$P[s_t = j | s_{t-1} = 1, s_{t-2} = k, \dots, M] = P[s_t = j | s_{t-1} = i] = p_{ij} \quad (2.29)$$

Rantai markov orde kedua atau orde tinggi adalah rantai markov yang bergantung pada dua atau lebih nilai yang sebelumnya. Probabilitas transisi pada orde kedua atau 2-langkah dapat di modelkan sebagai berikut (Paranchych dan Beaulieu, 1996).

$$P[s_t = j | s_{t-1} = i, s_{t-2} = k, \dots, M] = P[s_t = j | s_{t-1} = i, s_{t-2} = t_{t-2}] = p_{ij} \quad (2.30)$$

Proses markov akan menuju pada *steady state* (keseimbangan) artinya peluang keberadaan proses pada *state* tertentu, misal j , setelah sejumlah besar transisi akan cenderung ke nilai π_j , terlepas dari peluang distribusi *state* awal. π_j diinterpretasikan sebagai probabilitas stasioner. Menentukan peluang *steady state* dilakukan dengan menguraikan setiap peluang *state* tersebut dalam sebuah vektor kolom atau vektor keadaan. *Steady state* dapat ditentukan dengan peluang *state* awal, vektor *state* peluang berada pada *state* j setelah t -langkah ($\pi(t) = [\pi_j(t)]$) (Kao,2015).

$$\pi(t) = \pi(1).P, t = 1, 2, \dots, M \quad (2.31)$$

dengan $\pi_j(t) = P(s_t = j | \pi(1))$. Vektor peluang menunjukkan perilaku ketergantungan waktu dari rantai markov di bawah vektor peluang *state* awal $\pi(0)$, dengan

$$\pi(1) = [P_1^1 P_2^1 P_3^1] \quad (2.31)$$

dengan $P_i^1, i = 1,2,3$ menyatakan peluang pada *state* i dalam periode waktu tertentu.

2.9. Markov Switching Vector Error Correction Model (MS-VECM)

Chung-Ming Kuan (2002), menyatakan bahwa model *markov switching* merupakan salah satu dari model-model runtun waktu nonlinear yang terpopuler. Model *markov switching* digunakan untuk menganalisis data runtun waktu pada siklus bisnis bidang ekonomi dan finansial yang dapat mengalami perubahan kondisi (*regime switching*).

Salah satu kombinasi dari *markov switching* dengan model runtun waktu adalah *Markov Switching Vector Error Correction Model* (MS-VECM), yaitu kombinasi antara *markov switching* dengan *vector error correction model*. Misalkan Y_t adalah runtun waktu VECM orde r maka Andreas Thams (2007) menuliskan model MS(m)-VECM (r) sebagai berikut:

$$\Delta Y_t = a_0(s_t) + a_{ecm}(s_t)\beta'Y_{t-1} + \sum_{i=1}^p a_i(s_t)\Delta Y_{t-i} + u_t \quad (2.30)$$

dengan s_t sebagai *state* atau *regime*.

Langkah yang dilakukan adalah menentukan fungsi densitas untuk kemudian dibentuk menjadi fungsi *log-likelihood*. Untuk analisa yang sederhana, digunakan MS(m)-VECM(r). Fungsi densitas dari model tersebut dituliskan sebagai berikut:

$$f(y_t | s_t, s_{t-1}, \Omega_{t-1}; \theta) = \frac{1}{\sigma_s \sqrt{2\pi}} \exp \left[-\frac{(\Delta y_t - a(s_t)(\beta'Y_{t-1} + c) - a_1(s_t)\Delta Y_{t-1})^2}{2\sigma_s^2} \right] \quad (2.31)$$

dengan

$$\Omega_{t-1} = (y_{t-1}, y_{t-2}, \dots, y_{t-p})' : \text{populasi data pengamatan}$$

$$\theta = (a_0, a_{ecm}, a_i, p_{ij})' : \text{populasi parameter model MS(m)-VECM(r)}$$

Fungsi densitas y_t bergantung pada nilai s_t dan s_{t-1} , sedangkan kedua nilai tersebut nilainya tidak diketahui secara langsung melainkan diketahui berdasarkan karakteristik data pengamatan. Maka langkah pertama yang dilakukan adalah membentuk fungsi densitas bersama dari y_t , s_t dan s_{t-1} pada persamaan 2.32.

$$f(y_t, s_t, s_{t-1} | \Omega_{t-1}; \theta) = f(y_t | s_t, s_{t-1}, \Omega_{t-1}; \theta) \times P(s_t, s_{t-1} | \Omega_{t-1}; \theta) \quad (2.32)$$

Langkah selanjutnya adalah menghitung peluang nilai suatu *state* pada saat t berdasarkan informasi data pengamatan hingga saat $t-1$, dituliskan dengan:

$$P(s_t = j, s_{t-1} = i | \Omega_{t-1}) = P(s_t = j | s_{t-1} = i) \times P(s_{t-1} = i | \Omega_{t-1}) \quad (2.33)$$

Dengan nilai $P(s_t = j | s_{t-1} = i)$ merupakan probabilitas transisi dari rantai markov dengan 2 state. Fungsi densitas y_t diperoleh dengan menghitung kemudian menjumlahkan fungsi densitas bersama untuk setiap kemungkinan nilai s_t dan s_{t-1} sebagai berikut:

$$f(y_t | s_t, s_{t-1}, \Omega_{t-1}; \theta) = \sum_{j=1}^M \sum_{i=1}^M f(y_t, s_t = j, s_{t-1} = i | \Omega_{t-1}; \theta) \\ = \sum_{j=1}^M \sum_{i=1}^M f(y_t | s_t, s_{t-1}, \Omega_{t-1}; \theta) \times P(s_t = j, s_{t-1} = i | \Omega_{t-1}; \theta) \quad (2.34)$$

2.9.1 Filtering dan Smoothing

Proses *filtering* dijalankan untuk mendapatkan peluang nilai suatu state pada saat t berdasarkan data pengamatan hingga saat t . Proses ini dijalankan secara iteratif dari $t = 1, 2, \dots, T$. Hasil dari proses *filtering* adalah

$$P(s_t = j, s_{t-1} = i | \Omega_t; \theta) = \frac{f(y_t | s_t = j, s_{t-1} = i, \Omega_{t-1}; \theta) \times P(s_t = j, s_{t-1} = i | \Omega_{t-1}; \theta)}{\sum_{j=1}^M \sum_{i=1}^M f(y_t | s_t = j, s_{t-1} = i, \Omega_{t-1}; \theta) \times P(s_t = j, s_{t-1} = i | \Omega_{t-1}; \theta)} \quad (2.35)$$

Sehingga nilai *filtered state probability* suatu state dengan $i, j = 1, 2$ dapat dihitung dengan:

$$P(s_t = j | \Omega_t; \theta) = \sum_{i=1}^M P(s_t = j, s_{t-1} = i | \Omega_t; \theta) \quad (2.36)$$

Nilai yang digunakan untuk memulai proses *filtering* pada saat $t = 1$ adalah.

$$P(s_0 = j | \Omega_0; \theta) \begin{cases} P(s_0 = 1 | \Omega_0) = \pi_1 = \frac{1 - p_{22}}{2 - p_{22} - p_{11}} \\ P(s_0 = 2 | \Omega_0) = \pi_2 = \frac{1 - p_{11}}{2 - p_{22} - p_{11}} \end{cases} \quad (2.37)$$

Untuk mendapatkan nilai estimasi yang lebih baik, dilakukan proses *smoothing* di mana peluang nilai state dihitung berdasarkan informasi dari seluruh data pengamatan. Proses ini dijalankan secara iteratif dari $t = T - 1, T - 2, \dots, 1$. Hasil dari proses *smoothing* adalah nilai *smoothed state probabilities* yang dinotasikan dengan $P(s_t = j | \Omega_t; \theta)$. Berikut adalah persamaan yang dituliskan oleh Kim dan Nelson (1999) untuk proses *smoothing*:

$$P(s_t = j, s_{t+1} = k | \Omega_t; \theta) = \frac{P(s_{t+1} = k | \Omega_{t+1}; \theta) \times P(s_t = j | \Omega_t; \theta) \times P(s_{t+1} = k | s_t = j, \Omega_t; \theta)}{P(s_{t+1} = k | \Omega_t; \theta)} \quad (2.38)$$

Persaman diatas dihitung untuk setiap kemungkinan nilai k , kemudian diperoleh besarnya peluang s_t bernilai j berdasarkan pengamatan hingga $t = T$ dengan $j, k = 1, 2$ sebagai berikut:

$$P(s_t = j, s_{t+1} = k | \Omega_T; \theta) = \sum_{k=1}^M P(s_t = j, s_{t+1} = k | \Omega_T; \theta) \quad (2.39)$$

Peluang *smoothing* digunakan untuk menentukan nilai dari observasi pada waktu ke- t berada pada kondisi $s_t = m$ atau untuk mengklasifikasikan periode pada data pengamatan yang digunakan. Karena terdapat dua kemungkinan dimana $s_t = 1$ adalah kondisi ekonomi tidak baik dan $s_t = 2$ adalah kondisi ekonomi baik, maka $P(s_t = 1 | \Omega_T) \geq 0.5$ dinyatakan sebagai kondisi ekonomi baik dan $P(s_t = 1 | \Omega_T) < 0.5$ dinyatakan sebagai kondisi ekonomi tidak baik.

2.9.2 Estimasi Parameter Model MS-VECM

Setelah mendapatkan nilai peluang s_t melalui proses *filtering* dan *smoothing* maka dapat diperoleh fungsi densitas dari y_t sebagai berikut:

$$f(y_t | s_t, s_{t-1}, \Omega_T; \theta) = \sum_{k=1}^M \sum_{i=1}^M f(y_t | s_t, s_{t-1}, \Omega_T; \theta) \times P(s_t = j, s_{t+1} = k | \Omega_T; \theta) \quad (2.40)$$

Dengan demikian fungsi *likelihood* dan *log-likelihood* dituliskan sebagai berikut:

$$\begin{aligned} L(\theta) &= \prod_{t=1}^T f(y_t | s_t, s_{t-1}, \Omega_T; \theta) \\ \ln L(\theta) &= \sum_{t=1}^T \ln f(y_t | s_t, s_{t-1}, \Omega_T; \theta) \end{aligned} \quad (2.41)$$

Karena terdapat fungsi pembatas, yaitu π_1 dan π_2 pada awal proses *filtering*, Hamilton (1994) mendefinisikan fungsi Lagrange dari *log-likelihood* dengan:

$$J(\theta) = \ln L(\theta) + \lambda(1 - \pi_1 - \pi_2) \quad (2.42)$$

Untuk mendapatkan nilai maksimum sebagai estimator, persamaan (2.41) dideferensialkan terhadap masing-masing parameter dan disamadengankan dengan nol.

Selain dapat menangkap dinamika dan transisi kondisi, dengan model MS-VECM juga dapat dihitung durasi masing-masing *state*. Durasi dari *state j* dihitung dengan persamaan

$$E(D) = \frac{1}{1 - p_{jj}} \quad (2.43)$$

Untuk mendapatkan orde VECM yang tepat, estimasi parameter model MS(2)-VECM(r) dilakukan percobaan untuk model VECM dari orde 1 hingga 5.



2.9.3 Pengujian Signifikansi Parameter Model MS-VECM

Pengujian signifikansi parameter dilakukan secara parsial menggunakan uji t (Gujarati, 2003). Hipotesis yang digunakan dalam pengujian signifikansi parameter sebagai berikut.

$$H_0 : \theta = 0$$

vs.

$$H_1 : \theta \neq 0$$

Statistik uji t yang digunakan sebagai berikut.

$$t = \frac{\theta}{se(\theta)} \sim t_{n-p} \quad (2.44)$$

dengan

$$se(\theta) = \sqrt{\frac{S^2 \beta' y_i}{T}}$$

$$S^2 \beta' y_i = \frac{\sum_{t=1}^T (\beta' y_t - \bar{\beta' y})^2}{T-1}$$

$$i = 1, \dots, p$$

θ : matriks penduga parameter

$se(\theta)$: salah baku penduga parameter

p : banyak parameter yang diduga

Kriteria pengujian yang digunakan adalah apabila $|t| > t_{(\alpha/2, n-p)}$, maka dapat diputuskan untuk menolak H_0 . Selain itu, kriteria pengujian yang dapat digunakan yaitu dengan membandingkan antara nilai- p dengan taraf nyata yang digunakan (α). Penolakan H_0 terjadi apabila nilai- $p < \alpha$ yang artinya parameter pada taraf nyata α dalam model tersebut signifikan.

2.10. Diagnostik Sisaan Model

Pemeriksaan diagnostik sisaan model MS-VECM bertujuan untuk mengetahui kelayakan dan apakah asumsi yang mendasari model MS-VECM telah terpenuhi atau tidak. Dalam diagnostik sisaan model terdapat dua pengujian yaitu uji *white noise* sisaan dan uji normalitas sisaan.

2.10.1. Pengujian Sisaan Bersifat *White Noise*

Menurut Enders (2004), apabila sisaan tidak berautokorelasi (*white noise*), maka skema MACF tidak menunjukkan adanya pola tertentu dan tidak terdapat autokorelasi yang signifikan pada setiap *lag*. Untuk melihat *white noise* selain melalui korelogram dengan skema MACF dapat dilakukan dengan Uji Portmateau dengan hipotesis sebagai berikut:

$$H_0 : \Gamma(1) = \Gamma(2) = \dots = \Gamma(n) = 0 \quad \text{vs.}$$

$$H_1 : \Gamma(1) \neq \Gamma(2) \neq \dots \neq \Gamma(n) \neq 0, \quad 1 \leq i \leq n$$

Statistik uji yang digunakan adalah statistik uji Q dengan persamaan sebagai berikut.

$$Q_m = n^2 \sum_{j=1}^n \frac{1}{(n-i)} \text{tr} \left(\hat{\Gamma}'(i) \hat{\Gamma}^{-1}(0) \hat{\Gamma}(i) \hat{\Gamma}^{-1}(0) \right) \quad (2.45)$$

dengan

$$\hat{\Gamma}(i) = \frac{1}{n} \sum_{t=i+1}^n \mathbf{u}_t' \mathbf{u}_{t-i}$$

$i = 1, 2, \dots, p$

$\hat{\Gamma}(i)$: matriks kovarian sisaan

\mathbf{u}_t : vektor sisaan dari model

p : lag maksimum

m : banyak variabel endogen

n : banyak data deret waktu

Kaidah pengambilan keputusan dikatakan terima H_0 apabila statistik uji $Q_m < \chi^2_{(\alpha/2, n-p)}$ atau nilai- p lebih besar dari α yang berarti sisaan saling bebas, sehingga model layak digunakan. Untuk model yang tidak memenuhi asumsi *white noise*, maka harus dilakukan *overfitting* atau kembali ke tahap identifikasi model. *Overfitting* bertujuan untuk mendapatkan model lain yang sesuai pada *plotting* ACF dan PACF yang memungkinkan untuk peramalan. Model yang dihasilkan dari hasil *overfitting* dijadikan sebagai model yang terbaik diantara model-model yang signifikan.

2.10.2. Pengujian Normalitas Sisaan

Model dapat dikatakan layak apabila menghasilkan sisaan yang menyebar normal. Menurut Johnson dan Wichen (1992), pengujian normalitas multivariat dapat dilakukan dengan menggunakan nilai jarak Mahalanobis untuk pengamatan ke- i (d_i^2) dengan hipotesis sebagai berikut:

$$H_0 : \text{sisaan berdistribusi normal multivariat} \quad \text{vs.}$$

$$H_1 : \text{sisaan tidak berdistribusi normal multivariat}$$

Menurut Siegel (1998), statistik uji yang dapat digunakan dituliskan sebagai berikut:



$$r_Q = \frac{\sum_{t=1}^n (u_t - \bar{u})(q_t - \bar{q})}{\sqrt{\sum_{t=1}^n (u_t - \bar{u})^2} \sqrt{\sum_{t=1}^n (q_t - \bar{q})^2}} \quad (2.46)$$

dengan $q_t = Z\left(\frac{t-0.5}{T}\right)$, $u_t = d_t^2$; $d_t^2 = (Y_t - \bar{Y})' \Gamma(k)^{-1} (Y_{t+p} - \bar{Y})$

dengan

- x_t : vektor nilai amatan ke t
- \bar{x} : vektor nilai rata-rata masing variabel
- $\hat{\Gamma}(i)$: matriks kovarian sisaan

Jika $r_Q < r_{Q(\alpha, \gamma)}$ maka tolak H_0 . r_Q merupakan nilai korelasi antara nilai *quantile chi square* (q_t) dan jarak mahalnobis dari tiap variabel (d_t^2) dan $r_{Q(\alpha, \gamma)}$ adalah nilai tabel kritis uji koefisien korelasi Q-Q Plot.

2.11. Tinjauan Non Statistika

2.11.1. Tingkat Inflasi

Secara sederhana inflasi diartikan sebagai kenaikan harga secara umum dan terus menerus dalam jangka panjang waktu tertentu. Kenaikan harga dari satu atau dua barang saja dapat disebut inflasi kecuali bila kenaikan itu meluas (atau mengakibatkan kenaikan harga) pada barang lainnya. Kebalikan dari inflasi disebut deflasi (<http://bi.go.id>). Kenaikan harga barang dan jasa menyebabkan turunnya nilai uang. Dengan demikian, inflasi dapat diartikan sebagai penurunan nilai mata uang terhadap nilai barang dan jasa secara umum. Laju inflasi merupakan gambaran harga – harga. Harga yang membumbung tinggi merupakan gambaran dari inflasi yang tinggi. Kenaikan barang atau jasa yang hanya satu saja bukan merupakan inflasi, tetapi apabila kenaikan tersebut mengakibatkan barang dan jasa lain juga naik maka itu termasuk dari inflasi. Tidak dapat dikatakan bahwa terjadinya inflasi selalu berarti buruk, ada beberapa inflasi yang justru menjadi hal yang baik. Tingkat inflasi digolongkan menjadi 4 golongan, yaitu inflasi ringan apabila dibawah 10%, inflasi sedang apabila dalam rentang 10-30%, inflasi berat apabila dalam rentang 30%-100%, dan hiperinflasi apabila diatas 100%. Apabila inflasi berada pada golongan inflasi ringan maka dapat menjadi indikator bahwa di negara tersebut tidak mengalami kendala dalam peredaran uang maupun tingkat harga cenderung konstan. Kondisi paling baik untuk suatu negara adalah ketika inflasi berada dibawah

3% (id.wikipedia.org). Tujuannya adalah inflasi yang diukur dengan Indeks Harga Konsumen (IHK) akan melebihi pertumbuhan ekonomi yang mendasari jika diukur dengan jumlah Produk Domestik Bruto (PDB) yang kecil per tahun.

2.11.2. Suku Bunga Kebijakan

Bank Indonesia melakukan penguatan kerangka operasi moneter dengan mengimplementasikan suku bunga acuan atau suku bunga kebijakan baru yaitu BI 7-day (*Reverse*) Repo Rate. Fungsi dari BI 7-day (*Reverse*) adalah menjaga dan memelihara kestabilan nilai rupiah yang salah satunya tercemin dari tingkat inflasi yang rendah dan stabil (<http://bi.go.id>). Mekanisme dari perubahan BI 7-day (*Reverse*) sampai mempengaruhi inflasi tersebut sering disebut sebagai mekanisme transmisi kebijakan moneter. Suku bunga dapat dikatakan aman ketika inflasi berada pada kondisi yang baik. Mekanisme menggambarkan tindakan Bank Indonesia melalui perubahan-perubahan instrumen moneter, perubahan tersebut diantaranya suku bunga, jalur kredit, jalur nilai tukar dan jalur ekspektasi.

2.11.3. Hubungan Tingkat Inflasi dan Suku Bunga Kebijakan

Tingkat inflasi dan suku bunga merupakan beberapa indikator ekonomi makro karena perubahan dua hal tersebut dapat berpengaruh terhadap suatu negara. Karena ada perubahan tersebut juga, maka perubahan (*regime*) dapat diduga dengan matriks transisi lalu dimodelkan dengan MS-VECM. Tingkat inflasi dan suku bunga mempunyai hubungan timbal balik. Sebagai contoh suku bunga yang tinggi akan mengakibatkan kenaikan bunga pinjaman kredit bank, sehingga bagi peminjam dana untuk keperluan produksi akan meningkatkan pula harga jual produk. Suku bunga merupakan salah satu kebijakan moneter untuk menjaga tingkat inflasi. Apabila inflasi meningkat maka suku bunga juga akan meningkat.



(Halaman ini sengaja dikosongkan)

BAB III METODE PENELITIAN

3.1. Sumber Data

Penelitian yang dilakukan menggunakan data sekunder dari tingkat inflasi dan suku bunga. Data yang digunakan dalam penelitian ini diperoleh dari situs (bi.go.id). Data tingkat inflasi dan suku bunga merupakan variabel endogen. Data yang digunakan dalam penelitian ini adalah data tahun dimulai dari Januari 2005 sampai Desember 2019.

3.2. Metode Penelitian

Penelitian ini dilakukan dengan menggunakan studi literatur secara sistematis yang diperoleh dari buku-buku maupun media lain untuk mendapatkan informasi sebanyak mungkin untuk mendukung penulis skripsi ini. Analisis data dilakukan dengan menggunakan *software Eviews 10*.

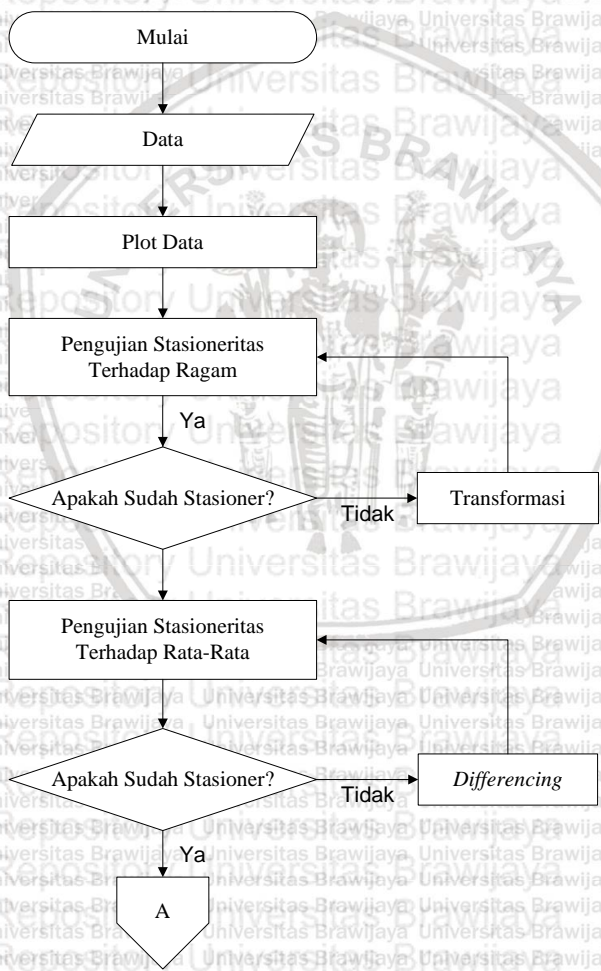
Adapun langkah-langkah yang dilakukan pada penelitian ini adalah sebagai berikut:

- 1) Menguji stasioneritas data Inflasi dan suku bunga.
 - a. Membuat plot *time series* dari data Inflasi dan suku bunga.
 - b. Melihat pola korelogram MPACF.
 - c. Menguji kestasioneritasan terhadap ragam dan rata-rata dengan uji *Augmented Dickey-Fuller* (ADF). Hal ini dilakukan dengan melihat nilai *p-value* dari uji ADF seperti pada persamaan (2.4).
 - d. Jika data tidak stasioner, maka dihitung nilai *returnnya* dengan cara transformasi data menggunakan logaritma (supaya data stasioner terhadap ragam) dan differensiasi data (supaya data stasioner terhadap rata-rata).
- 2) Menguji hubungan antar variabel endogen menggunakan uji Kausalitas Granger untuk mengetahui apakah terdapat hubungan dua arah antar variabel seperti pada persamaan (2.9).
- 3) Menguji suatu integrasi keseimbangan pada jangka panjang hubungan antar variabel menggunakan uji Kointegrasi seperti pada persamaan (2.10).
- 4) Menentukan peluang transisi dengan menggunakan *filtering* seperti pada persamaan (2.36) dan *smoothing* seperti pada persamaan (2.38).
- 5) Melakukan estimasi parameter untuk memperoleh orde yang sesuai. Estimasi model MS-VECM seperti pada persamaan (2.41).

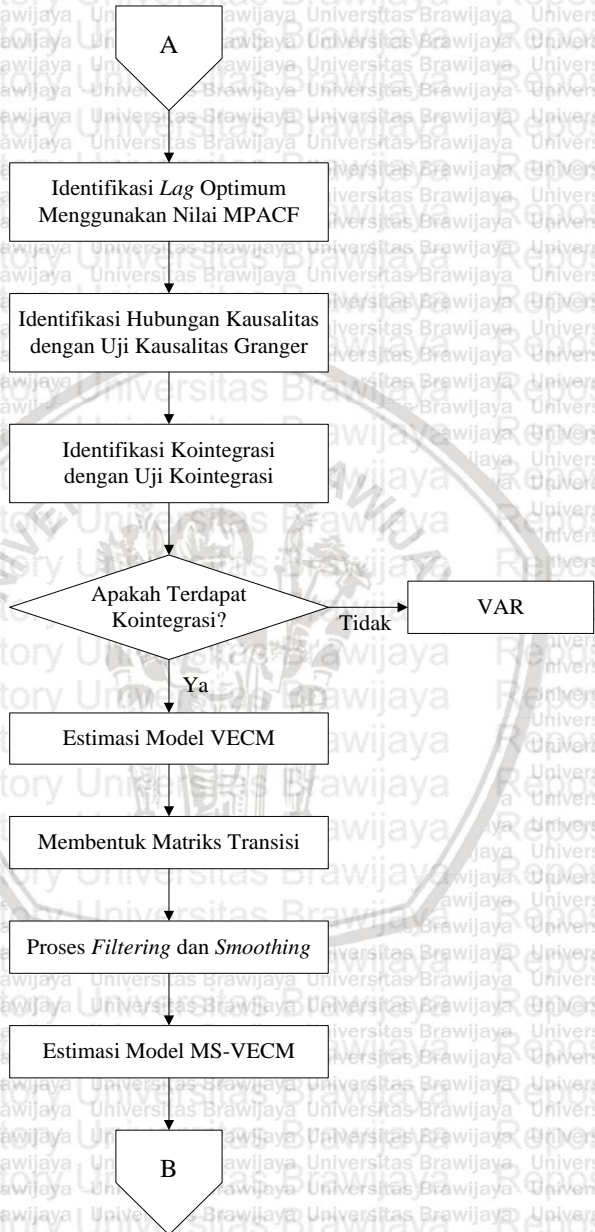
- 6) Melakukan uji signifikansi parameter model MS-VECM seperti pada persamaan (2.43).
- 7) Melakukan uji diagnostik sisaan *model* MS-VECM meliputi pemeriksaan *white noise* seperti pada persamaan (2.44) dan normalitas sisaan seperti pada persamaan (2.45).

3.3. Diagram Alir

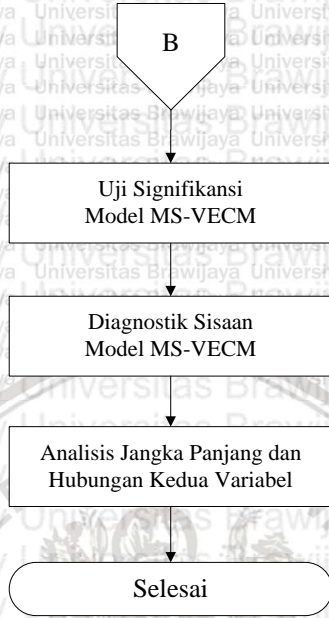
Prosedur pemodelan pada penelitian ini secara lengkap disajikan pada diagram alir Gambar 3.1.



Gambar 3.1. Langkah-langkah Pembentukan Model MS-VECM



Gambar 3.1. Lanjutan



Gambar 3.1. Lanjutan

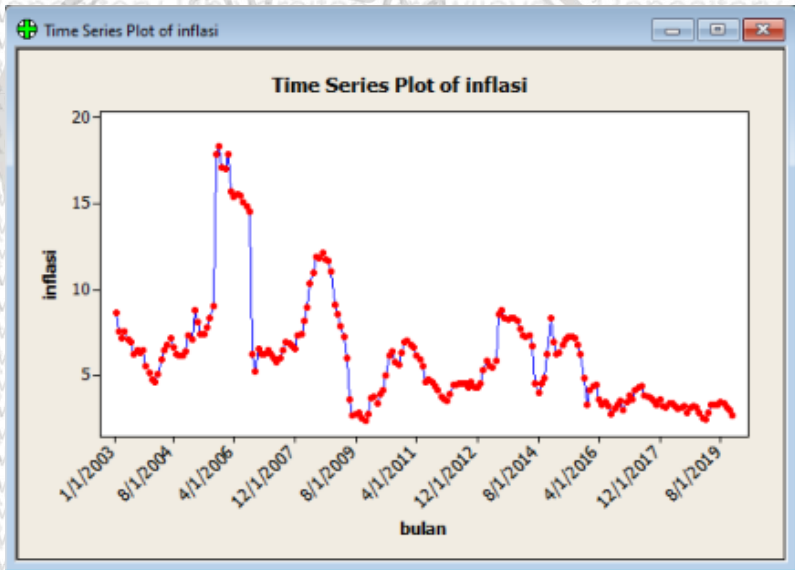
BAB IV HASIL DAN PEMBAHASAN

4.1. Plot Data Deret Waktu

Identifikasi pertama kali analisis data deret waktu adalah melihat plot data deret waktu. Hal ini bertujuan untuk mengetahui apakah pola data mempunyai pola *horizontal*, *trend*, musiman, atau siklis yang digunakan untuk analisis selanjutnya dan dapat diketahui apakah telah stasioner atau belum. Plot data juga dapat digunakan untuk menentukan metode yang tepat.

4.1.1. Plot Data Tingkat Inflasi

Plot data deret waktu dari data Tingkat Inflasi tahun 2003-2019 ditunjukkan pada Gambar 4.1.



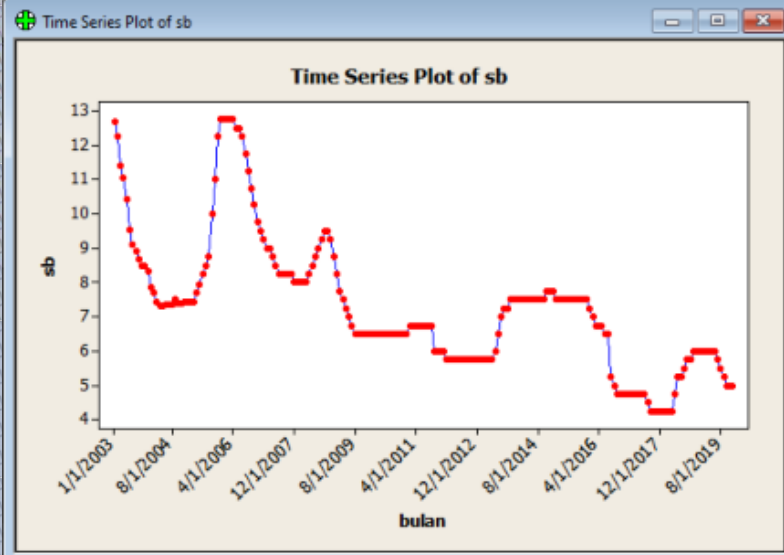
Gambar 4.1. Plot Data Tingkat Inflasi

Berdasarkan Gambar 4.1, dapat diketahui bahwa data tingkat inflasi mengalami peningkatan dan penurunan yang berfluktuatif dan tidak konstan terhadap suatu nilai tertentu sehingga mengindikasikan bahwa data tingkat inflasi berpola non linear. Tingkat inflasi tertinggi dalam periode Agustus 2004 sampai dengan April 2006 yang terjadi pada November 2005 sebesar 18.38%, hal tersebut disebabkan oleh krisis ekonomi yang terjadi di Indonesia. Sedangkan tingkat inflasi

terendah dalam periode Agustus 2009 sampai dengan April 2011 yang terjadi pada November 2009 sebesar 2.41%, hal tersebut disebabkan karena tekanan inflasi yang masih dapat dikendalikan.

4.1.2. Plot Data Tingkat Suku Bunga

Plot data deret waktu dari data Tingkat Suku Bunga tahun 2003-2019 ditunjukkan pada Gambar 4.2.



Gambar 4.2. Plot Data Tingkat Suku Bunga

Berdasarkan Gambar 4.2, dapat diketahui bahwa data tingkat suku bunga mengalami peningkatan dan penurunan yang berfluktuatif dan tidak konstan terhadap suatu nilai tertentu sehingga mengindikasikan bahwa data tingkat suku bunga berpola non linear. Tingkat suku bunga tertinggi dalam periode Agustus 2004 sampai dengan April 2006 yang terjadi pada Desember 2005 sebesar 12.75%, sedangkan tingkat suku bunga terendah dalam periode Agustus 2006 sampai dengan April 2019 yang terjadi berturut-turut pada September 2017 hingga April 2018 sebesar 4.25%. Perubahan yang terjadi pada suku bunga seiring dengan perubahan yang terjadi pada tingkat inflasi.

4.2. Pengujian Stasioneritas

Salah satu asumsi yang wajib dipenuhi pada data deret waktu adalah kestasioneritasan data atau data bersifat konstan sepanjang

waktu dan tidak terdapat perubahan nilai tengah dan ragam seiring perubahan waktu. Stasioneritas data deret waktu terbagi menjadi dua meliputi stasioneritas data deret waktu terhadap ragam dan stasioneritas data deret waktu terhadap rata-rata

4.2.1. Stasioneritas terhadap Ragam

Stasioneritas data deret waktu terhadap ragam dapat diuji dengan menduga nilai λ yang bersesuaian dengan Subbab 2.2.1. Data deret waktu dapat dikatakan stasioner terhadap ragam ketika nilai λ sama dengan satu. Plot nilai λ untuk masing-masing variabel tingkat inflasi dan tingkat suku bunga dapat dilihat pada Lampiran 2. Berikut merupakan tabel ringkasan dari kedua plot nilai λ masing-masing variabel.

Tabel 4.1. Pemeriksaan Stasioneritas terhadap Ragam

| Variabel | | Nilai λ | Kesimpulan |
|----------------------|------------|-----------------|-----------------|
| Sebelum Transformasi | Inflasi | -0.9106167 | Tidak Stasioner |
| | Suku Bunga | 0.9378815 | Tidak Stasioner |
| Setelah Transformasi | Inflasi | 1 | Stasioner |
| | Suku Bunga | 1 | Stasioner |

Berdasarkan Tabel 4.1, dapat diketahui bahwa sebelum ditransformasi, variabel tingkat inflasi dan tingkat suku bunga menghasilkan nilai λ tidak sama dengan 1 yang artinya data deret waktu tingkat inflasi dan tingkat suku bunga belum stasioner terhadap ragam. Setelah variabel tingkat inflasi dan tingkat suku bunga ditransformasi *boxcox* akan menghasilkan nilai λ sama dengan 1 yang artinya data sudah stasioner terhadap ragam.

4.2.2. Stasioneritas terhadap Rata-rata

Pengujian stasioneritas terhadap rata-rata dapat dilakukan dengan banyak pengujian, salah satunya menggunakan uji Dickey-Fuller. Uji akar unit Dickey-Fuller merupakan uji akar unit yang menggunakan hipotesis satu arah. Berdasarkan hipotesis pada Subbab 2.2.2., hipotesis yang digunakan adalah sebagai berikut.

$H_0 : \delta \geq 0$ yaitu terdapat akar unit atau Y_t tidak stasioner vs.

$H_1 : \delta < 0$ yaitu tidak terdapat akar unit atau Y_t stasioner

Hasil uji Dickey-Fuller secara lengkap dapat dilihat pada Lampiran 2. dan telah diringkas pada Tabel 4.2.

Tabel 4.2. Hasil Uji Dickey-Fuller

| Variabel | | Statistik Uji t | Nilai- p | Kesimpulan |
|-------------------|------------|-------------------|------------|-----------------|
| Level | Inflasi | -3.6647 | 0.02855 | Tidak Stasioner |
| | Suku Bunga | -3.693 | 0.0259 | Tidak Stasioner |
| Pembedaan Pertama | Inflasi | -5.6131 | 0.01 | Stasioner |
| | Suku Bunga | -4.4906 | 0.01 | Stasioner |

Berdasarkan Tabel 4.2, nilai- p yang dihasilkan oleh data inflasi sebesar 0.02855 yang berarti lebih besar dari taraf nyata (α) 1% sehingga cukup bukti untuk menerima H_0 dan dapat disimpulkan data inflasi tidak stasioner terhadap rata-rata. Oleh karena itu, dilakukan pembedaan pertama (*first differencing*) dan mendapatkan nilai- p sebesar 0.01 yang berarti lebih kecil sama dengan dari taraf nyata (α) 1% sehingga cukup bukti untuk menolak H_0 dan dapat disimpulkan data inflasi stasioner terhadap rata-rata pada pembedaan pertama.

Sedangkan nilai- p yang dihasilkan oleh data suku bunga sebesar 0.0259 yang berarti lebih besar dari taraf nyata (α) 1% sehingga cukup bukti untuk menerima H_0 dan dapat disimpulkan data suku bunga tidak stasioner terhadap rata-rata. Oleh karena itu, dilakukan pembedaan pertama (*first differencing*) dan mendapatkan nilai- p sebesar 0.01 yang berarti lebih kecil sama dengan dari taraf nyata (α) 1% sehingga cukup bukti untuk menolak H_0 dan dapat disimpulkan data suku bunga stasioner terhadap rata-rata pada pembedaan pertama.

4.3. Identifikasi lag VECM

Identifikasi orde p dapat dilakukan dengan memperhatikan skema *Matrix Autocorrelation Function* (MACF) dan *Matrix Partial Autocorrelation Function* (MPACF). Skema MACF dan MPACF secara lengkap disajikan dapat dilihat pada Lampiran 3. dan telah diringkas pada Tabel 4.3 dan Tabel 4.4.

Tabel 4.3. Skema *Matrix Autocorrelation Function*

| Lag | DINF | DSB |
|-----|----------|----------|
| 1 | 1.00000 | 0.20457 |
| 2 | 0.25998 | 0.27459 |
| 3 | -0.11666 | 0.18058 |
| 4 | -0.02715 | 0.12395 |
| 5 | 0.10488 | 0.10268 |
| 6 | 0.02050 | 0.04056 |
| 7 | -0.07617 | 0.07816 |
| 8 | -0.02089 | -0.00663 |
| 9 | 0.00863 | 0.15374 |
| 10 | -0.06731 | 0.06916 |
| 11 | -0.02583 | -0.01089 |

Tabel 4.4. Skema *Matrix Partial Autocorrelation Function*

| Lag | DINF | DSB |
|-----|----------|----------|
| 1 | 0.20457 | 1.00000 |
| 2 | 0.13608 | 0.65689 |
| 3 | 0.12381 | 0.52731 |
| 4 | 0.07196 | 0.37889 |
| 5 | 0.11933 | 0.27510 |
| 6 | 0.04772 | 0.20257 |
| 7 | 0.01231 | 0.14071 |
| 8 | -0.03280 | 0.10990 |
| 9 | -0.11628 | -0.03276 |
| 10 | -0.09124 | -0.05604 |
| 11 | -0.16741 | -0.08825 |

Pada skema MACF penelitian ini tidak dijelaskan secara lanjut mengenai *Vector Moving Average* (VMA(q)). Sehingga yang perlu diperhatikan hanya pada Tabel 4.4. Pada skema MPACF dapat dilihat bahwa nilai signifikansi pada *lag* ke 3 karena sampai dengan nilai *lag* 3 masih lebih besar dari 0,4. Panjang *log* optimum VECM didapatkan dari panjang *lag* optimum VAR dikurangi satu atau $p-1$ sehingga panjang *lag* VECM adalah 2 atau VECM(2).

4.4. Identifikasi Hubungan Kausalitas Granger

Uji kausalitas merupakan metode yang digunakan untuk menentukan hubungan kausalitas dalam sistem persamaan simultan. Penelitian ini menggunakan panjang *lag* yang diuji sama dengan 2. Hipotesis yang digunakan dapat dilihat pada Subbab 2.3 serta untuk hasil uji kausalitas Granger secara lengkap dapat dilihat pada Lampiran 4. dan telah diringkas pada Tabel 4.5.

Tabel 4.5. Pengujian Kausalitas Granger

| Hipotesis | Statistik Uji F | Nilai- <i>p</i> |
|---------------------------------------|-----------------|-----------------|
| Inflasi tidak mempengaruhi Suku bunga | 20.6457 | 0.0000 |
| Suku Bunga tidak mempengaruhi Inflasi | 15.3630 | 0.0001 |

Berdasarkan Tabel 4.5, didapatkan nilai-*p* yang dihasilkan oleh kedua hipotesis (0.000 dan 0.0001) memiliki nilai yang lebih kecil dari taraf nyata (α) 1% sehingga belum cukup bukti untuk menerima H_0 dan dapat dikatakan bahwa tingkat inflasi merupakan penyebab *granger* bagi tingkat suku bunga, begitupun sebaliknya. Dengan demikian, dapat disimpulkan bahwa terdapat hubungan dua arah antar inflasi dan suku bunga.

4.5. Identifikasi Hubungan Kointegrasi

Uji kointegrasi dilakukan untuk menguji suatu integrasi keseimbangan pada jangka panjang hubungan antar variabel, ditunjukkan dengan jumlah vektor kointegrasi dalam data deret waktu. Penelitian ini menggunakan panjang *lag* yang diuji sama dengan 2. Hipotesis yang digunakan dapat dilihat pada Subbab 2.4 serta untuk hasil uji kointegrasi secara lengkap dapat dilihat pada Lampiran 5. dan telah diringkas pada Tabel 4.6.

Tabel 4.6. Pengujian Kointegrasi

| Hipotesis Jumlah Kointegrasi | Statistik Uji | Nilai- <i>p</i> |
|------------------------------|---------------|-----------------|
| Tidak ada | 146.4432 | 0.0000 |
| Jumlah kointegrasi < 1 | 27.13118 | 0.0001 |

Berdasarkan Tabel 4.6, didapatkan nilai-*p* yang dihasilkan oleh kedua hipotesis (0.000 dan 0.0001) memiliki nilai yang lebih kecil dari taraf nyata (α) 1% sehingga belum cukup bukti untuk menerima H_0 dan dapat dikatakan bahwa tingkat inflasi dan tingkat

suku bunga merupakan memiliki hubungan jangka panjang. Dengan demikian, tingkat inflai dan tingkat suku bunga dapat dimodelkan dengan metode VECM.

4.6. Pendugaan dan Pengujian Signifikansi Parameter VECM

Pendugaan parameter model VECM dilakukan dengan metode *Maximum Likelihood Estimation* (MLE). Setelah melakukan pendugaan parameter model VECM(2), dilakukan pengujian signifikansi parameter model VECM(2) secara parsial menggunakan uji *t*. Hipotesis yang digunakan dapat dilihat pada Subbab 2.7.2. serta untuk pendugaan dan pengujian signifikansi parameter secara lengkap dapat dilihat pada Lampiran 6. dan telah diringkas pada Tabel 4.7.

Tabel 4.7. Hasil Estimasi Model VECM(2) Persamaan Inflasi

| Variabel | Koefisien | Nilai- <i>p</i> | Keputusan |
|----------------|-----------|-----------------|--------------|
| Jangka Pendek | | | |
| ECM(-1) | -1.142009 | 0.0000 | Tolak H_0 |
| D(DINF(-1)) | 0.243006 | 0.0191 | Terima H_0 |
| D(DINF(-2)) | -0.00906 | 0.9048 | Terima H_0 |
| D(DSB(-1)) | 0.302341 | 0.4031 | Terima H_0 |
| D(DSB(-2)) | 0.201883 | 0.5460 | Terima H_0 |
| Jangka Panjang | | | |
| DSB(-1) | -1.623372 | 0.0000 | Tolak H_0 |

Tabel 4.8. Hasil Estimasi Model VECM(2) Persamaan Suku Bunga

| Variabel | Koefisien | Nilai- <i>p</i> | Keputusan |
|----------------|-----------|-----------------|--------------|
| Jangka Pendek | | | |
| ECM(-1) | 0.033667 | 0.2225 | Terima H_0 |
| D(DINF(-1)) | 0.023599 | 0.2635 | Terima H_0 |
| D(DINF(-2)) | 0.015968 | 0.3020 | Terima H_0 |
| D(DSB(-1)) | -0.343018 | 0.0000 | Tolak H_0 |
| D(DSB(-2)) | -0.100723 | 0.1405 | Terima H_0 |
| Jangka Panjang | | | |
| DINF(-1) | -0.616002 | 0.9576 | Terima H_0 |

Apabila didapatkan nilai-*p* yang kurang dari dari taraf nyata (α) 1% maka belum cukup bukti untuk menerima H_0 dan dapat



disimpulkan bahwa parameter tersebut berpengaruh signifikan. Model VECM (2) dapat dituliskan pada persamaan 4.1.

$$\begin{bmatrix} \Delta Y_{1t} \\ \Delta Y_{2t} \end{bmatrix} = \begin{bmatrix} -0.0054 & -1.142 & 0.243 & -0.0091 & 0.3023 & 0.2019 \\ 0.0031 & 0.0336 & 0.0236 & 0.0159 & -0.343 & -0.1007 \end{bmatrix} \begin{bmatrix} 1 \\ ECM_{t-1} \\ \Delta Y_{1t-1} \\ \Delta Y_{1t-2} \\ \Delta Y_{2t-1} \\ \Delta Y_{2t-2} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix} \quad (4.1)$$

atau dalam bentuk persamaan non matriks dapat dimodelkan seperti persamaan (4.2) dan (4.3).

$$\Delta Y_{1t} = -0.0054 - 1.142ECM_{t-1} + 0.243\Delta Y_{1t-1} - 0.0091\Delta Y_{1t-2} + 0.3023\Delta Y_{2t-1} + 0.2019\Delta Y_{2t-2} + u_{1t} \quad (4.2)$$

$$\Delta Y_{2t} = 0.0031 + 0.0336ECM_{t-1} + 0.0236\Delta Y_{1t-1} + 0.0159\Delta Y_{1t-2} - 0.343\Delta Y_{2t-1} - 0.1007\Delta Y_{2t-2} + u_{2t} \quad (4.3)$$

a Tingkat Inflasi

- Dapat dijelaskan untuk laju perubahan, pendugaan parameter *error correction* berpengaruh negatif dan signifikan terhadap inflasi. Artinya, terdapat mekanisme penyesuaian dari jangka pendek ke jangka panjang sebesar 1.142%.
- Dapat dijelaskan untuk jangka pendek, inflasi *lag 2*, suku bunga *lag 1* dan suku bunga *lag 2* tidak berpengaruh signifikan terhadap inflasi.
- Dapat dijelaskan untuk jangka panjang, suku bunga *lag 1* berpengaruh negatif dan signifikan terhadap inflasi. Artinya, apabila terjadi kenaikan suku bunga 1% periode sebelumnya akan menyebabkan inflasi menurun sebesar 1.63%.

b Tingkat Suku Bunga

- Dapat dijelaskan untuk laju perubahan, pendugaan parameter *error correction* tidak berpengaruh signifikan terhadap suku bunga. Artinya, tidak terdapat mekanisme penyesuaian dari jangka pendek ke jangka panjang.
- Dapat dijelaskan untuk jangka pendek, inflasi *lag 2*, dan suku bunga *lag 2* tidak berpengaruh signifikan terhadap inflasi. Sedangkan suku bunga *lag 1* berpengaruh negatif dan signifikan terhadap suku bunga. Artinya, apabila terjadi kenaikan suku

bunga 1% periode sebelumnya akan menyebabkan suku bunga menurun sebesar 0.34%.

c. Dapat dijelaskan untuk jangka panjang, inflasi *lag* 1 tidak berpengaruh signifikan terhadap suku bunga.

4.7. **Pendugaan dan Pengujian Signifikansi Parameter Model MS(2)-VECM(2)**

Sebelum menduga nilai dari masing-masing parameter, dibutuhkan peluang transisi untuk menangkap efek perubahan jangka panjang yang tidak teramati. Pada penelitian ini peluang transisi dari perubahan kondisi yang terjadi adalah kondisi ekonomi baik dan tidak baik. Kondisi ekonomi tidak baik dilambangkan dengan indeks 1 sedangkan untuk kondisi ekonomi baik dilambangkan dengan indeks 2. Pada evIEWS, untuk mengestimasi peluang transisi secara default menggunakan multinomial logit. Setelah dilakukan iterasi sebanyak 11 kali maka didapatkan peluang transisi sebagai hasil pada persamaan

4.4.

$$\mathbf{P} = \begin{matrix} & \begin{matrix} 1 & 2 \end{matrix} \\ \begin{matrix} 1 \\ 2 \end{matrix} & \begin{bmatrix} 0.897 & 0.103 \\ 0.401 & 0.599 \end{bmatrix} \end{matrix} \quad (4.4)$$

Dari hasil peluang transisi dapat diketahui bahwa jika saat $t-1$ inflasi dan suku bunga dalam kondisi ekonomi tidak baik, maka peluang inflasi dan suku bunga saat t tetap dalam kondisi ekonomi tidak baik adalah $(p_{11}) = 0.897$, dan peluang inflasi dan suku bunga pada saat t berubah menjadi kondisi ekonomi baik adalah $(p_{12}) = 0.103$. Sedangkan jika saat $t-1$ inflasi dan suku bunga dalam kondisi ekonomi baik, maka peluang inflasi dan suku bunga saat t berubah menjadi kondisi ekonomi tidak baik adalah $(p_{21}) = 0.401$, dan peluang inflasi dan suku bunga pada saat t tetap dalam kondisi ekonomi baik adalah $(p_{22}) = 0.599$. Secara keseluruhan, rata-rata ekspektasi durasi dari ekonomi tidak baik adalah 9.7 bulan, sedangkan rata-rata ekspektasi durasi dari ekonomi baik adalah 2.5 bulan. Hal ini menunjukkan bahwa durasi kondisi ekonomi baik sedikit lebih pendek dibandingkan kondisi ekonomi tidak baik.

Setelah mendapatkan peluang transisi, dilakukan proses *filtering* dan *smoothing* untuk membagi model berdasarkan *regime*. Proses *filtering* digunakan untuk mendapatkan peluang nilai suatu *state*, sedangkan *smoothing* digunakan untuk mendapatkan nilai

estimasi yang lebih baik. Berdasarkan persamaan (2.36) dan (2.38) maka diperoleh seperti berikut.

$$\begin{aligned} \pi_1 &= 0.796 \\ \pi_2 &= 0.204 \end{aligned} \quad (4.5)$$

Dari peluang transisi yang diiterasi sebanyak 11 kali akan didapatkan nilai yang konvergen sehingga terdapat dua kemungkinan kondisi dimana $s_t = 1$ untuk kondisi ekonomi tidak baik dan $s_t = 2$ untuk kondisi ekonomi baik, maka $P(s_t = 1 | \Omega_T) \geq 0.5$ dinyatakan sebagai kondisi ekonomi baik dan $P(s_t = 1 | \Omega_T) < 0.5$ dinyatakan sebagai kondisi ekonomi tidak baik. Pendugaan parameter model MS-VECM dilakukan dengan metode *Maximum Likelihood Estimation* (MLE). Hipotesis yang digunakan dapat dilihat pada Subbab 2.9.3. serta untuk pendugaan dan pengujian signifikansi parameter secara lengkap dapat dilihat pada Lampiran 8. dan telah diringkas pada Tabel 4.9 dan Tabel 4.10.

Tabel 4.9. Hasil Estimasi Model MS(2)-VECM(2) Persamaan Inflasi

| Variabel | Regime (s_t) = 1 | | Regime (s_t) = 2 | |
|----------------|----------------------|---------|----------------------|---------|
| | Koefisien | Nilai-p | Koefisien | Nilai-p |
| Jangka Pendek | | | | |
| ECM(-1) | -0.033 | 0.6441 | 1.017 | 0.0000 |
| D(DINF(-1)) | 0.103 | 0.0001 | 0.120 | 0.0000 |
| D(DINF(-2)) | -0.023 | 0.8568 | -0.0006 | 0.9719 |
| D(DSB(-1)) | -0.75 | 0.5456 | 0.921 | 0.0000 |
| D(DSB(-2)) | 0.602 | 0.0022 | -0.014 | 0.8715 |
| Jangka Panjang | | | | |
| Variabel | Koefisien | | Nilai-p | |
| DSB(-1) | -1.623372 | | 0.0000 | |

Tabel 4.10. Hasil Estimasi Model MS(2)-VECM(2) Persamaan Suku Bunga

| Variabel | Regime (s_t) = 1 | | Regime (s_t) = 2 | |
|---------------|----------------------|---------|----------------------|---------|
| | Koefisien | Nilai-p | Koefisien | Nilai-p |
| Jangka Pendek | | | | |
| ECM(-1) | 0.010 | 0.2734 | -0.659 | 0.0000 |
| D(DINF(-1)) | 0.071 | 0.0000 | 0.062 | 0.0001 |
| D(DINF(-2)) | -0.00005 | 0.9960 | 0.092 | 0.3568 |

| | | | | |
|-----------------------|------------------|--------|----------------|--------|
| D(DSB(-1)) | 0.555 | 0.0000 | -0.058 | 0.4699 |
| D(DSB(-2)) | 0.013 | 0.8019 | 0.381 | 0.0021 |
| Jangka Panjang | | | | |
| Variabel | Koefisien | | Nilai-p | |
| DINF(-1) | -0.616002 | | 0.9576 | |

Apabila didapatkan nilai- p yang kurang dari dari taraf nyata (α) 1% maka belum cukup bukti untuk menerima H_0 dan dapat disimpulkan bahwa parameter tersebut berpengaruh signifikan. Berdasarkan Model VECM (2) dapat dituliskan sebagai berikut.

- Untuk *regime* (s_t) = 1

$$\begin{bmatrix} \Delta Y_{1t} \\ \Delta Y_{2t} \end{bmatrix} = \begin{bmatrix} -0.005 & -0.033 & 0.103 & -0.023 & -0.075 & 0.602 \\ 0.003 & 0.010 & 0.070 & -0.00005 & 0.555 & 0.013 \end{bmatrix} \begin{bmatrix} 1 \\ ECM_{t-1} \\ \Delta Y_{1t-1} \\ \Delta Y_{1t-2} \\ \Delta Y_{2t-1} \\ \Delta Y_{2t-2} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix} \quad (4.6)$$

atau dalam bentuk persamaan non matriks dapat dimodelkan seperti persamaan (4.7) dan (4.8).

$$\Delta Y_{1t} = -0.005 + 0.033ECM_{t-1} + 0.103\Delta Y_{1t-1} - 0.023\Delta Y_{1t-2} - 0.075\Delta Y_{2t-1} + 0.602\Delta Y_{2t-2} + u_{1t} \quad (4.7)$$

$$\Delta Y_{2t} = 0.003 + 0.01ECM_{t-1} + 0.071\Delta Y_{1t-1} - 0.00005\Delta Y_{1t-2} + 0.555\Delta Y_{2t-1} + 0.013\Delta Y_{2t-2} + u_{2t} \quad (4.8)$$

a. Tingkat Inflasi

- Dapat dijelaskan untuk laju perubahan, pendugaan parameter *error correction* tidak berpengaruh signifikan terhadap inflasi. Artinya, tidak terdapat mekanisme penyesuaian dari jangka pendek ke jangka panjang.
- Dapat dijelaskan untuk jangka pendek, inflasi *lag* 2 dan suku bunga *lag* 1 tidak berpengaruh signifikan terhadap inflasi. Sedangkan inflasi *lag* 1 dan suku bunga *lag* 2 berpengaruh positif dan signifikan terhadap inflasi. Artinya, apabila terjadi kenaikan inflasi 1% periode sebelumnya dan suku bunga dua periode sebelumnya akan menyebabkan inflasi naik sebesar 0.103% dan 0.602%.

iii. Dapat dijelaskan untuk jangka panjang, suku bunga *lag* 1 berpengaruh negatif dan signifikan terhadap inflasi. Artinya, apabila terjadi kenaikan suku bunga 1% periode sebelumnya akan menyebabkan inflasi menurun sebesar 1.63%.

b. Tingkat Suku Bunga

i. Dapat dijelaskan untuk laju perubahan, pendugaan parameter *error correction* tidak berpengaruh signifikan terhadap suku bunga. Artinya, tidak terdapat mekanisme penyesuaian dari jangka pendek ke jangka panjang.

ii. Dapat dijelaskan untuk jangka pendek, inflasi *lag* 2 dan suku bunga *lag* 2 tidak berpengaruh signifikan terhadap suku bunga. Sedangkan inflasi dan suku bunga *lag* 1 berpengaruh positif dan signifikan terhadap suku bunga. Artinya, apabila terjadi kenaikan inflasi dan suku bunga 1% periode sebelumnya akan menyebabkan suku bunga meningkat sebesar 0.071% dan 0.555%.

iii. Dapat dijelaskan untuk jangka panjang, inflasi *lag* 1 tidak berpengaruh signifikan terhadap suku bunga.

- Untuk *regime* (s_t) = 2

$$\begin{bmatrix} \Delta Y_{1t} \\ \Delta Y_{2t} \end{bmatrix} = \begin{bmatrix} -0.005 & 1.017 & 0.120 & -0.0006 & 0.921 & -0.014 \\ 0.003 & -0.659 & 0.062 & 0.092 & -0.058 & 0.381 \end{bmatrix} \begin{bmatrix} 1 \\ ECM_{t-1} \\ \Delta Y_{1t-1} \\ \Delta Y_{1t-2} \\ \Delta Y_{2t-1} \\ \Delta Y_{2t-2} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix} \quad (4.9)$$

atau dalam bentuk persamaan non matriks dapat dimodelkan seperti persamaan (4.10) dan (4.11).

$$\Delta Y_{1t} = -0.005 + 1.017ECM_{t-1} + 0.12\Delta Y_{1t-1} - 0.0006\Delta Y_{1t-2} + 0.921\Delta Y_{2t-1} - 0.014\Delta Y_{2t-2} + u_{1t} \quad (4.10)$$

$$\Delta Y_{2t} = 0.003 - 0.659ECM_{t-1} + 0.062\Delta Y_{1t-1} + 0.092\Delta Y_{1t-2} - 0.058\Delta Y_{2t-1} + 0.381\Delta Y_{2t-2} + u_{2t} \quad (4.11)$$

a. Tingkat Inflasi

- i. Dapat dijelaskan untuk laju perubahan, pendugaan parameter *error correction* bertanda positif dan signifikan terhadap inflasi. Artinya, nilai inflasi periode sebelumnya berada di bawah nilai *equilibriumnya* menyebabkan perbedaan antara tingkat inflasi dengan nilai keseimbangan sebesar cenderung naik 1.017 yang akan disesuaikan dalam waktu kurang dari 1 bulan.
 - ii. Dapat dijelaskan untuk jangka pendek, inflasi *lag 2* dan suku bunga *lag 2* tidak berpengaruh signifikan terhadap inflasi. Sedangkan inflasi *lag 1* dan suku bunga *lag 1* berpengaruh positif dan signifikan terhadap inflasi. Artinya, apabila terjadi kenaikan inflasi dan suku bunga 1% periode sebelumnya akan menyebabkan inflasi naik sebesar 0.12% dan 0.921%.
 - iii. Dapat dijelaskan untuk jangka panjang, suku bunga *lag 1* berpengaruh negatif dan signifikan terhadap inflasi. Artinya, apabila terjadi kenaikan suku bunga 1% periode sebelumnya akan menyebabkan inflasi menurun sebesar 1.63%.
- b. Tingkat Suku Bunga
- i. Dapat dijelaskan untuk laju perubahan, pendugaan parameter *error correction* bertanda negatif dan signifikan terhadap suku bunga. Artinya, nilai suku bunga periode sebelumnya berada di atas nilai *equilibriumnya* menyebabkan perbedaan antara tingkat suku bunga dengan nilai keseimbangannya cenderung turun sebesar 0.659 yang akan disesuaikan dalam waktu 1.5 bulan.
 - ii. Dapat dijelaskan untuk jangka pendek, inflasi *lag 2*, dan suku bunga *lag 1* tidak berpengaruh signifikan terhadap suku bunga. Sedangkan inflasi *lag 1* dan suku bunga *lag 2* berpengaruh positif dan signifikan terhadap suku bunga. Artinya, apabila terjadi kenaikan inflasi 1% periode sebelumnya dan suku bunga dua tahun sebelumnya akan menyebabkan suku bunga meningkat sebesar 0.062% dan 0.381%.
 - iii. Dapat dijelaskan untuk jangka panjang, inflasi *lag 1* tidak berpengaruh signifikan terhadap suku bunga.



4.8. Pengujian Diagnostik Sisaan Model MS(2)-VECM(2)

Pengujian diagnostik sisaan model meliputi pengujian asumsi *white noise* terhadap sisaan dan pengujian asumsi normalitas pada sisaan.

4.8.1. Pengujian *White Noise* terhadap Sisaan Model MS(2)-VECM(2)

Pengujian asumsi *white noise* sisaan menggunakan uji Portmateau. Tujuan dari pengujian ini adalah untuk mengetahui apakah model MS(2)-VECM(2) telah memenuhi asumsi *white noise* atau tidak. Hipotesis yang digunakan dapat dilihat pada Subbab 2.10.1. serta untuk hasil dari pengujian secara lengkap dapat dilihat pada Lampiran 9. dan telah diringkas pada Tabel 4.10.

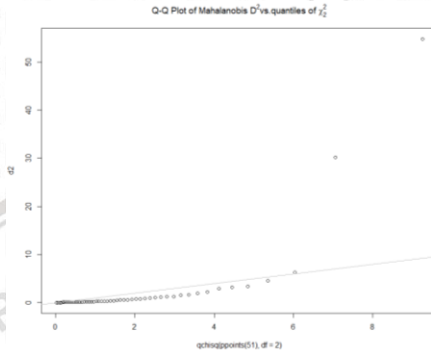
Tabel 4.11. Hasil Uji Portmateau Model MS(2)-VECM(2)

| Lag | Statistik Uji | Nilai- <i>p</i> |
|-----|---------------|-----------------|
| 1 | 1.566485 | 8.148028e-01 |
| 2 | 77.293666 | 1.710854e-13 |
| 3 | 109.985949 | 0.000000e+00 |
| 4 | 114.683199 | 1.110223e-16 |
| 5 | 115.392989 | 1.998401e-15 |
| 6 | 116.868429 | 3.497203e-14 |
| 7 | 121.916648 | 1.094680e-13 |
| 8 | 124.102125 | 8.784085e-13 |
| 9 | 128.894271 | 2.219447e-12 |
| 10 | 146.357987 | 4.840572e-14 |

Berdasarkan Tabel 4.11. dapat diketahui bahwa pada model MS(2)-VECM(2) memiliki nilai-*p* dari statistik uji Q lebih kecil dari taraf nyata (α) 1% maka tidak cukup bukti untuk menerima H_0 dan dapat disimpulkan bahwa model MS(2)-VECM(2) tidak memenuhi asumsi sisaan yang *white noise*. Karena asumsi *white noise* tidak terpenuhi maka akan berdampak adanya autokorelasi antar residual. Dampak dari tidak memenuhi asumsi *white noise* adalah estimator yang dihasilkan masih *unbiased* sehingga model belum bisa ditakan paling baik.

4.8.2. Pengujian Normalitas terhadap Sisaan Model MS(2)-VECM(2)

Pengujian normalitas sisaan model MS(2)-VECM(2) dilakukan dengan melihat Q-Q Plot dan didapatkan grafik seperti pada Gambar 4.3.



Gambar 4.3. Plot Mahalanobis

Berdasarkan Gambar 4.3. dapat diketahui bahwa Q-Q Plot menunjukkan bahwa titik-titik berada disekitar garis lurus diagonal dan beberapa titik menyimpang dari garis lurus diagonal (45°) sehingga menandakan adanya pencilan. Dari keseluruhan sampel yang digunakan dapat dikatakan bahwa sisaan mendekati dengan sebaran normal multivariat. Dengan demikian maka asumsi normalitas untuk nilai residual dalam model MS(2)-VECM(2) dalam penelitian ini dapat terpenuhi.



(Halaman ini sengaja dikosongkan)

BAB V PENUTUP

5.1. Kesimpulan

Berdasarkan hasil analisis yang telah dilakukan pada penelitian ini, maka dapat diambil kesimpulan sebagai berikut.

- 1) Model terbaik yang didapatkan adalah model MS(2)-VECM(2).
 - a. Pada saat kondisi ekonomi tidak baik ($s_t = 1$), Tingkat inflasi dipengaruhi oleh tingkat inflasi tahun sebelumnya dan tingkat suku bunga dua tahun sebelumnya. Sedangkan tingkat suku bunga dipengaruhi oleh tingkat inflasi tahun sebelumnya dan tingkat suku bunga tahun sebelumnya.
 - b. Pada saat kondisi ekonomi baik ($s_t = 2$), Tingkat inflasi dipengaruhi oleh *error correction* (adanya mekanisme penyesuaian jangka panjang), tingkat inflasi tahun sebelumnya dan tingkat suku bunga tahun sebelumnya. Sedangkan tingkat suku bunga dipengaruhi oleh *error correction* (adanya mekanisme penyesuaian jangka panjang), tingkat inflasi tahun sebelumnya dan tingkat suku bunga dua tahun sebelumnya.
- 2) Tingkat inflasi merupakan pengaruh bagi tingkat suku bunga dan suku bunga merupakan pengaruh bagi tingkat inflasi. Dengan demikian, dapat disimpulkan bahwa terdapat hubungan dua arah antar inflasi dan suku bunga (saling mempengaruhi).

5.2. Saran

Saran yang dapat diberikan untuk penelitian selanjutnya antara lain:

- 1) Dapat melakukan penanganan kasus terhadap model yang tidak memenuhi normalitas sisaan, seperti identifikasi *outlier* pada model dan dilanjutkan dengan pemodelan *outlier*.
- 2) Dapat menambahkan pemodelan variansi kalender karena asumsi *white noise* tidak terpenuhi.
- 3) Dapat menambahkan kondisi sehingga *regime* yang terbentuk dapat lebih dari dua.



Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

Repository Universitas Brawijaya

(Halaman ini sengaja dikosongkan)

DAFTAR PUSTAKA

- Ajija, S. R., Sari, D. W., Setianto, R. H., dan Primanti, M. R. (2011). *Cara cerdas menguasai Eviews*. Jakarta: Salemba Empat.
- Amaliya, A. (2010). *Pengaruh Tingkat Suku Bunga dan Kurs terhadap Inflasi di Indonesia*. Skripsi. Tidak diterbitkan. Fakultas Ilmu Ekonomi dan Bisnis. Universitas Islam Negeri Syarif Hidayatullah.
- Arief, Sritua. (1993). *Metodologi Penelitian Ekonomi*. Jakarta: Universitas Indonesia (UI Press).
- Bank Indonesia. (2018). <https://bi.go.id>.
- Boediono. (1994). *Ekonomi Makro*. Penerbit BPFE. Yogyakarta
- Box, G.E. dan Jenkins, G.M. (1976). *Time Series Analysis Forecasting and Control*. Holden Day, Inc., California.
- Clarida, R., Sarno, L., Taylor, M. dan Valente, G. (2003). *The Out of Sample Success of Term Structure Models as Exchange Rate Predictors: A Step Beyond*. Journal of International Economics 60: 61–83.
- Dornbusch, R., Fischer, S. dan Richard Starz. (2008). *Marko Ekonomi*. Terjemahan oleh : Roy Indra Mirazudin, SE. Jakarta: PT Media Global Edukasi
- Engel, C. (1994). *Can the Markov Switching Model Forecast Exchange Rates*. Journal of International Economics 36: 151–165.
- Kuan, C. M. (2002). *Lecture on the Markov Switching Model*. Taipei: Institute of Economics Academia Sinica.
- Draper, N. R. dan Smith, H. (1998). *Applied Regression Analysis*. Third ed. New York: John Wiley.
- Enders, W. (2004). *Applied econometrics Time Series*. Second Edition. New York: John Wiley & Sons.
- Engle, R. F. dan Granger, C. W. J. (1987). *Co-Integration and Error Correction: Representation, Estimation, and Testing*. *Econometrica*, Vol. 55, No. 2. pp. 251-276.
- Gujarati, D. (2003). *Basic Econometrics*. Forth Edition. Singapura: McGraw-Hill.
- Hamilton, J. D. (1989). *A New Approach to the Economic Analysis of Nonstationary Time Series and The Business Cycle*. Journal Econometrics. 57:357-384
- Hamilton, J. D. (1994). *Time Series Analysis*. Princeton University Press.

Johnson, R. A. dan Wichern, D. W. (1992). *Applied Multivariate Analysis, Third Edition*. Prentice Hall Inc. New Jersey.

Kim, C.J. dan Nelson C.R. (1999). *State Space Models with Regime Switching, Classical and Gibbs Sampling Approaches with Applications*. Cambridge, MA: MIT Press.

Makridakis, S., Wheelwright, S. C. dan McGee, V. E. (1999). *Metode dan aplikasi peramalan*. Jakarta: Binarupa Aksara.

Neter, J., Wasserman, W. dan Kutner, M. H. (1997). *Model Linier Terapan Buku I dan II: Analisis Regresi Linier Sederhana dan Analisis Regresi Ganda*, diterjemahkan oleh Bambang Sumantri. Bogor: Jurusan Statistika FMIPA IPB.

Thams, A. (2007). *Inflation Transmission in the EMU: A Markov-Switching VECM Analysis*. Free University of Berlin

Wei, W. W. (2006). *Deret Waktu Analisis*. In *The Oxford Handbook of Quantitative Methods in Psychology: vol 2*.

Zou, X. (2018). *VECM Model Analysis of Carbon Emissions, GDP, and International Crude Oil Prices*. *Discrete Dynamics in Nature and Society*.



LAMPIRAN

Lampiran 1. Data Tingkat Inflasi dan Tingkat Suku Bunga bulan Januari 2003 hingga bulan Desember 2019

| Periode | Inflasi (%) | Suku Bunga (%) |
|-----------|-------------|----------------|
| 1/1/2003 | 8.68 | 12.69 |
| 2/1/2003 | 7.6 | 12.24 |
| 3/1/2003 | 7.17 | 11.4 |
| 4/1/2003 | 7.62 | 11.06 |
| 5/1/2003 | 7.15 | 10.44 |
| 6/1/2003 | 6.98 | 9.53 |
| 7/1/2003 | 6.27 | 9.1 |
| 8/1/2003 | 6.51 | 8.91 |
| 9/1/2003 | 6.33 | 8.66 |
| 10/1/2003 | 6.48 | 8.48 |
| 11/1/2003 | 5.53 | 8.49 |
| 12/1/2003 | 5.16 | 8.31 |
| 1/1/2004 | 4.82 | 7.86 |
| 2/1/2004 | 4.6 | 7.7 |
| 3/1/2004 | 5.11 | 7.42 |
| 4/1/2004 | 5.92 | 7.33 |
| 5/1/2004 | 6.47 | 7.32 |
| 6/1/2004 | 6.83 | 7.34 |
| 7/1/2004 | 7.2 | 7.36 |
| 8/1/2004 | 6.67 | 7.37 |
| 9/1/2004 | 6.27 | 7.49 |
| 10/1/2004 | 6.22 | 7.41 |
| 11/1/2004 | 6.18 | 7.41 |
| 12/1/2004 | 6.4 | 7.43 |
| 1/1/2005 | 7.32 | 7.42 |
| 2/1/2005 | 7.15 | 7.43 |
| 3/1/2005 | 8.81 | 7.44 |
| 4/1/2005 | 8.12 | 7.7 |
| 5/1/2005 | 7.4 | 7.95 |
| 6/1/2005 | 7.42 | 8.25 |
| 7/1/2005 | 7.84 | 8.5 |

| Periode | Inflasi (%) | Suku Bunga (%) |
|-----------|-------------|----------------|
| 8/1/2005 | 8.33 | 8.75 |
| 9/1/2005 | 9.06 | 10 |
| 10/1/2005 | 17.89 | 11 |
| 11/1/2005 | 18.38 | 12.25 |
| 12/1/2005 | 17.11 | 12.75 |
| 1/1/2006 | 17.03 | 12.75 |
| 2/1/2006 | 17.92 | 12.75 |
| 3/1/2006 | 15.74 | 12.75 |
| 4/1/2006 | 15.4 | 12.75 |
| 5/1/2006 | 15.6 | 12.5 |
| 6/1/2006 | 15.53 | 12.5 |
| 7/1/2006 | 15.15 | 12.25 |
| 8/1/2006 | 14.9 | 11.75 |
| 9/1/2006 | 14.55 | 11.25 |
| 10/1/2006 | 6.29 | 10.75 |
| 11/1/2006 | 5.27 | 10.25 |
| 12/1/2006 | 6.6 | 9.75 |
| 1/1/2007 | 6.26 | 9.5 |
| 2/1/2007 | 6.3 | 9.25 |
| 3/1/2007 | 6.52 | 9 |
| 4/1/2007 | 6.29 | 9 |
| 5/1/2007 | 6.01 | 8.75 |
| 6/1/2007 | 5.77 | 8.5 |
| 7/1/2007 | 6.06 | 8.25 |
| 8/1/2007 | 6.51 | 8.25 |
| 9/1/2007 | 6.95 | 8.25 |
| 10/1/2007 | 6.88 | 8.25 |
| 11/1/2007 | 6.71 | 8.25 |
| 12/1/2007 | 6.59 | 8 |
| 1/1/2008 | 7.36 | 8 |
| 2/1/2008 | 7.4 | 8 |

Lampiran 1. (Lanjutan)

| Periode | Inflasi (%) | Suku Bunga (%) |
|-----------|-------------|----------------|
| 3/1/2008 | 8.17 | 8 |
| 4/1/2008 | 8.96 | 8 |
| 5/1/2008 | 10.38 | 8.25 |
| 6/1/2008 | 11.03 | 8.5 |
| 7/1/2008 | 11.9 | 8.75 |
| 8/1/2008 | 11.85 | 9 |
| 9/1/2008 | 12.14 | 9.25 |
| 10/1/2008 | 11.77 | 9.5 |
| 11/1/2008 | 11.68 | 9.5 |
| 12/1/2008 | 11.06 | 9.25 |
| 1/1/2009 | 9.17 | 8.75 |
| 2/1/2009 | 8.6 | 8.25 |
| 3/1/2009 | 7.92 | 7.75 |
| 4/1/2009 | 7.31 | 7.5 |
| 5/1/2009 | 6.04 | 7.25 |
| 6/1/2009 | 3.65 | 7 |
| 7/1/2009 | 2.71 | 6.75 |
| 8/1/2009 | 2.75 | 6.5 |
| 9/1/2009 | 2.83 | 6.5 |
| 10/1/2009 | 2.57 | 6.5 |
| 11/1/2009 | 2.41 | 6.5 |
| 12/1/2009 | 2.78 | 6.5 |
| 1/1/2010 | 3.72 | 6.5 |
| 2/1/2010 | 3.81 | 6.5 |
| 3/1/2010 | 3.43 | 6.5 |
| 4/1/2010 | 3.91 | 6.5 |
| 5/1/2010 | 4.16 | 6.5 |
| 6/1/2010 | 5.05 | 6.5 |
| 7/1/2010 | 6.22 | 6.5 |
| 8/1/2010 | 6.44 | 6.5 |
| 9/1/2010 | 5.8 | 6.5 |
| 10/1/2010 | 5.67 | 6.5 |
| 11/1/2010 | 6.33 | 6.5 |
| 12/1/2010 | 6.96 | 6.5 |

| Periode | Inflasi (%) | Suku Bunga (%) |
|-----------|-------------|----------------|
| 1/1/2011 | 7.02 | 6.5 |
| 2/1/2011 | 6.84 | 6.75 |
| 3/1/2011 | 6.65 | 6.75 |
| 4/1/2011 | 6.16 | 6.75 |
| 5/1/2011 | 5.98 | 6.75 |
| 6/1/2011 | 5.54 | 6.75 |
| 7/1/2011 | 4.61 | 6.75 |
| 8/1/2011 | 4.79 | 6.75 |
| 9/1/2011 | 4.61 | 6.75 |
| 10/1/2011 | 4.42 | 6 |
| 11/1/2011 | 4.15 | 6 |
| 12/1/2011 | 3.79 | 6 |
| 1/1/2012 | 3.65 | 6 |
| 2/1/2012 | 3.56 | 5.75 |
| 3/1/2012 | 3.97 | 5.75 |
| 4/1/2012 | 4.5 | 5.75 |
| 5/1/2012 | 4.45 | 5.75 |
| 6/1/2012 | 4.53 | 5.75 |
| 7/1/2012 | 4.56 | 5.75 |
| 8/1/2012 | 4.58 | 5.75 |
| 9/1/2012 | 4.31 | 5.75 |
| 10/1/2012 | 4.61 | 5.75 |
| 11/1/2012 | 4.32 | 5.75 |
| 12/1/2012 | 4.3 | 5.75 |
| 1/1/2013 | 4.57 | 5.75 |
| 2/1/2013 | 5.31 | 5.75 |
| 3/1/2013 | 5.9 | 5.75 |
| 4/1/2013 | 5.57 | 5.75 |
| 5/1/2013 | 5.47 | 5.75 |
| 6/1/2013 | 5.9 | 6 |
| 7/1/2013 | 8.61 | 6.5 |
| 8/1/2013 | 8.79 | 7 |
| 9/1/2013 | 8.4 | 7.25 |
| 10/1/2013 | 8.32 | 7.25 |


Lampiran 1. (Lanjutan)

| Periode | Inflasi (%) | Suku Bunga (%) |
|-----------|-------------|----------------|
| 11/1/2013 | 8.37 | 7.5 |
| 12/1/2013 | 8.38 | 7.5 |
| 1/1/2014 | 8.22 | 7.5 |
| 2/1/2014 | 7.75 | 7.5 |
| 3/1/2014 | 7.32 | 7.5 |
| 4/1/2014 | 7.25 | 7.5 |
| 5/1/2014 | 7.32 | 7.5 |
| 6/1/2014 | 6.7 | 7.5 |
| 7/1/2014 | 4.53 | 7.5 |
| 8/1/2014 | 3.99 | 7.5 |
| 9/1/2014 | 4.53 | 7.5 |
| 10/1/2014 | 4.83 | 7.5 |
| 11/1/2014 | 6.23 | 7.75 |
| 12/1/2014 | 8.36 | 7.75 |
| 1/1/2015 | 6.96 | 7.75 |
| 2/1/2015 | 6.29 | 7.5 |
| 3/1/2015 | 6.38 | 7.5 |
| 4/1/2015 | 6.79 | 7.5 |
| 5/1/2015 | 7.15 | 7.5 |
| 6/1/2015 | 7.26 | 7.5 |
| 7/1/2015 | 7.26 | 7.5 |
| 8/1/2015 | 7.18 | 7.5 |
| 9/1/2015 | 6.83 | 7.5 |
| 10/1/2015 | 6.25 | 7.5 |
| 11/1/2015 | 4.89 | 7.5 |
| 12/1/2015 | 3.35 | 7.5 |
| 1/1/2016 | 4.14 | 7.25 |
| 2/1/2016 | 4.42 | 7 |
| 3/1/2016 | 4.45 | 6.75 |
| 4/1/2016 | 3.6 | 6.75 |
| 5/1/2016 | 3.33 | 6.75 |
| 6/1/2016 | 3.45 | 6.5 |
| 7/1/2016 | 3.21 | 6.5 |
| 8/1/2016 | 2.79 | 5.25 |

| Periode | Inflasi (%) | Suku Bunga (%) |
|-----------|-------------|----------------|
| 9/1/2016 | 3.07 | 5 |
| 10/1/2016 | 3.31 | 4.75 |
| 11/1/2016 | 3.58 | 4.75 |
| 12/1/2016 | 3.02 | 4.75 |
| 1/1/2017 | 3.49 | 4.75 |
| 2/1/2017 | 3.83 | 4.75 |
| 3/1/2017 | 3.61 | 4.75 |
| 4/1/2017 | 4.17 | 4.75 |
| 5/1/2017 | 4.33 | 4.75 |
| 6/1/2017 | 4.37 | 4.75 |
| 7/1/2017 | 3.88 | 4.75 |
| 8/1/2017 | 3.82 | 4.5 |
| 9/1/2017 | 3.72 | 4.25 |
| 10/1/2017 | 3.58 | 4.25 |
| 11/1/2017 | 3.3 | 4.25 |
| 12/1/2017 | 3.61 | 4.25 |
| 1/1/2018 | 3.25 | 4.25 |
| 2/1/2018 | 3.18 | 4.25 |
| 3/1/2018 | 3.4 | 4.25 |
| 4/1/2018 | 3.41 | 4.25 |
| 5/1/2018 | 3.23 | 4.75 |
| 6/1/2018 | 3.12 | 5.25 |
| 7/1/2018 | 3.18 | 5.25 |
| 8/1/2018 | 3.2 | 5.5 |
| 9/1/2018 | 2.88 | 5.75 |
| 10/1/2018 | 3.16 | 5.75 |
| 11/1/2018 | 3.23 | 6 |
| 12/1/2018 | 3.13 | 6 |
| 1/1/2019 | 2.82 | 6 |
| 2/1/2019 | 2.57 | 6 |
| 3/1/2019 | 2.48 | 6 |
| 4/1/2019 | 2.83 | 6 |
| 5/1/2019 | 3.32 | 6 |
| 6/1/2019 | 3.28 | 6 |

Lampiran 1. (Lanjutan)

| Periode | Inflasi (%) | Suku Bunga (%) |
|-----------|-------------|----------------|
| 7/1/2019 | 3.32 | 5.75 |
| 8/1/2019 | 3.49 | 5.5 |
| 9/1/2019 | 3.39 | 5.25 |
| 10/1/2019 | 3.13 | 5 |
| 11/1/2019 | 3 | 5 |
| 12/1/2019 | 2.72 | 5 |



Lampiran 2. Uji Stasioneritas terhadap Ragam dan Rata-rata

```
> z = read.table(file = choose.files(), header = T, sep = ",")
> inf = Z$INFLASI
> sb = Z$SB
```

1. Tingkat Inflasi

```
> #Cek Stasioneritas Terhadap Ragam
> BoxCox.lambda(inf)
[1] -0.9106167
> inft = BoxCox(inf, -0.9106167)
> BoxCox.lambda(inft)
[1] 0.9127124
> #Cek Stasioneritas Terhadap Rata-rata
> adf.test(inft)
```

Augmented Dickey-Fuller Test

```
data: inft
Dickey-Fuller = -3.6647, Lag order = 5, p-value = 0.02855
alternative hypothesis: stationary
```

```
> diffinft<-diff(inft,differences=1)
> adf.test(diffinft)
```

Augmented Dickey-Fuller Test

```
data: diffinft
Dickey-Fuller = -5.6131, Lag order = 5, p-value = 0.01
alternative hypothesis: stationary
```

Lampiran 2. (Lanjutan)

2. Tingkat Suku Bunga

```
> #Cek Stasioneritas Terhadap Ragam
> BoxCox.lambda(sb)
[1] 0.9378815
> sbt = BoxCox(sb, 0.9378815)
> BoxCox.lambda(sbt)
[1] 1.004655
> #Cek Stasioneritas Terhadap Rata-rata
> adf.test(sbt)
```

Augmented Dickey-Fuller Test

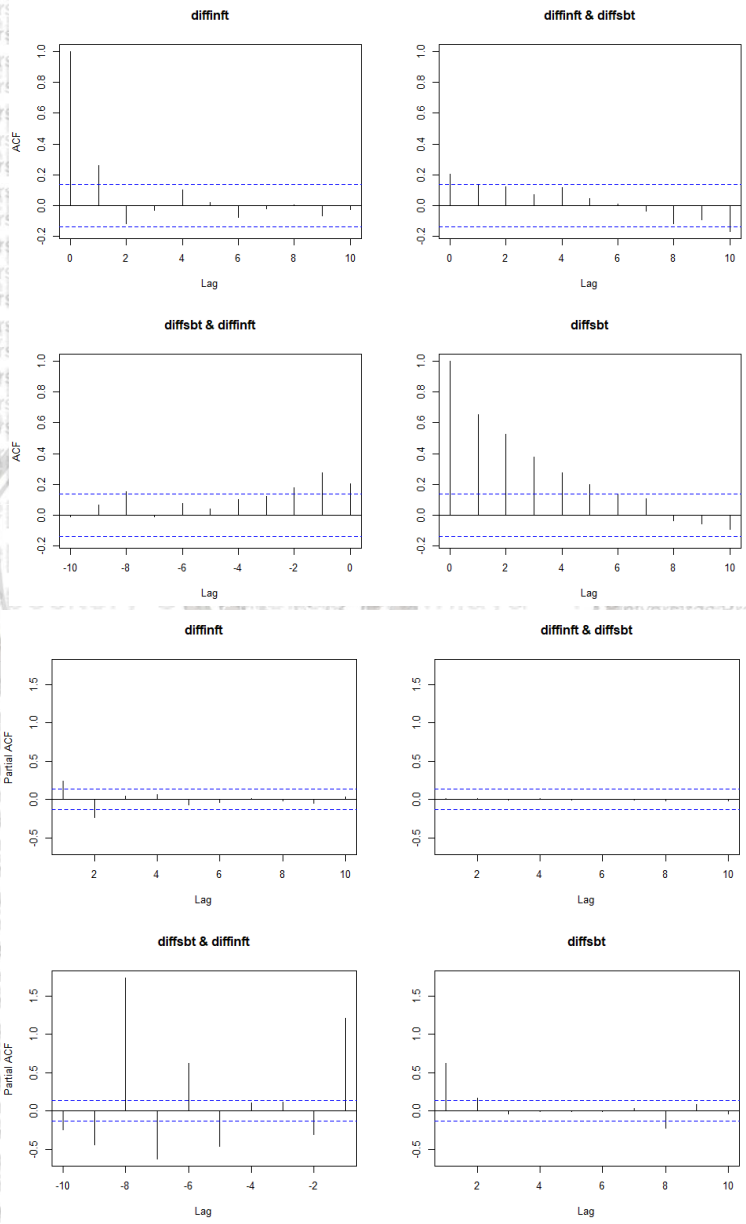
```
data: sbt
Dickey-Fuller = -3.6925, Lag order = 5, p-value = 0.02594
alternative hypothesis: stationary
```

```
> diffsbt<-diff(sbt,differences=1)
> adf.test(diffsbt)
```

Augmented Dickey-Fuller Test


```
data: diffsbt
Dickey-Fuller = -4.4882, Lag order = 5, p-value = 0.01
alternative hypothesis: stationary
```

Lampiran 3. Skema MACF dan MPACF





(Halaman ini sengaja dikosongkan)



Lampiran 4. Uji Kausalitas Granger


Pairwise Granger Causality Tests

Date: 04/28/20 Time: 02:19

Sample: 2003M01 2019M12

Lags: 1

| Null Hypothesis: | Obs | F-Statistic | Prob. |
|-------------------------------------|-----|-------------|--------|
| DINFLASI does not Granger Cause DSB | 202 | 20.6457 | 1.E-05 |
| DSB does not Granger Cause DINFLASI | | 15.3630 | 0.0001 |





(Halaman ini sengaja dikosongkan)

Lampiran 5. Uji Kointegrasi

Date: 04/28/20 Time: 02:21

Sample (adjusted): 2003M04 2019M12

Included observations: 201 after adjustments

Trend assumption: Linear deterministic trend (restricted)

Series: DINFLASI DSB

Lags interval (in first differences): 1 to 1

Unrestricted Cointegration Rank Test (Trace)

| Hypothesized No. of CE(s) | Eigenvalue | Trace Statistic |
|---------------------------|------------|-----------------|
| None * | 0.447660 | 146.4432 |
| At most 1 * | 0.126267 | 27.13118 |

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level

* denotes rejection of the hypothesis at the 0.05 level

**MacKinnon-Haug-Michelis (1999) p-values



(Halaman ini sengaja dikosongkan)

Lampiran 6. Pendugaan dan Pengujian Signifikansi Parameter VECM(2)

System: UNTITLED

Estimation Method: Least Squares

Date: 05/01/20 Time: 20:50

Sample: 2003M05 2019M12

Included observations: 200

Total system (balanced) observations 400

| | Coefficient | Std. Error | t-Statistic | Prob. |
|-------|-------------|------------|-------------|--------|
| C(1) | -1.142009 | 0.134985 | -8.460293 | 0.0000 |
| C(2) | 0.243006 | 0.103233 | 2.353957 | 0.0191 |
| C(3) | -0.009062 | 0.075679 | -0.119737 | 0.9048 |
| C(4) | 0.302341 | 0.361232 | 0.836973 | 0.4031 |
| C(5) | 0.201883 | 0.334089 | 0.604279 | 0.5460 |
| C(6) | -0.005449 | 0.069960 | -0.077888 | 0.9380 |
| C(7) | 0.033667 | 0.027557 | 1.221758 | 0.2225 |
| C(8) | 0.023599 | 0.021075 | 1.119771 | 0.2635 |
| C(9) | 0.015968 | 0.015450 | 1.033528 | 0.3020 |
| C(10) | -0.343018 | 0.073744 | -4.651481 | 0.0000 |
| C(11) | -0.100723 | 0.068203 | -1.476818 | 0.1405 |
| C(12) | 0.003141 | 0.014282 | 0.219893 | 0.8261 |

Determinant residual covariance 0.035442

$$\text{Equation: } D(\text{DINFLASI}) = C(1) * (\text{DINFLASI}(-1) - 1.62337214834 * \text{DSB}(-1) - 0.0310979087468) + C(2) * D(\text{DINFLASI}(-1)) + C(3) * D(\text{DINFLASI}(-2)) + C(4) * D(\text{DSB}(-1)) + C(5) * D(\text{DSB}(-2)) + C(6)$$

Observations: 200

| | | | |
|--------------------|----------|--------------------|-----------|
| R-squared | 0.483451 | Mean dependent var | -0.003650 |
| Adjusted R-squared | 0.470138 | S.D. dependent var | 1.358873 |
| S.E. of regression | 0.989146 | Sum squared resid | 189.8114 |
| Durbin-Watson stat | 1.997060 | | |

$$\text{Equation: } D(\text{DSB}) = C(7) * (\text{DINFLASI}(-1) - 1.62337214834 * \text{DSB}(-1) - 0.0310979087468) + C(8) * D(\text{DINFLASI}(-1)) + C(9) * D(\text{DINFLASI}(-2)) + C(10) * D(\text{DSB}(-1)) + C(11) * D(\text{DSB}(-2)) + C(12)$$

Observations: 200

| | | | |
|--------------------|----------|--------------------|----------|
| R-squared | 0.183293 | Mean dependent var | 0.001700 |
| Adjusted R-squared | 0.162244 | S.D. dependent var | 0.220618 |
| S.E. of regression | 0.201930 | Sum squared resid | 7.910480 |
| Durbin-Watson stat | 1.994996 | | |



(Halaman ini sengaja dikosongkan)

Lampiran 7. Peluang Transisi

Equation: MSVECM_INF

Date: 05/03/20 Time: 00:35

Transition summary: Constant Markov transition probabilities and expected durations

Sample (adjusted): 2003M04 2019M12


Included observations: 201 after adjustments

Constant transition probabilities:

$P(i, k) = P(s(t) = k \mid s(t-1) = i)$

(row = i / column = j)

| | 1 | 2 |
|---|----------|----------|
| 1 | 0.896872 | 0.103128 |
| 2 | 0.400633 | 0.599367 |





(Halaman ini sengaja dikosongkan)

Lampiran 8. Pendugaan dan Pengujian Signifikansi Parameter MS(2)-VECM(2)

Dependent Variable: DSB

Method: Simple Switching Regression (BFGS / Marquardt steps)

Date: 05/28/20 Time: 13:59

Sample (adjusted): 2003M04 2019M12

Included observations: 201 after adjustments

Number of states: 2

Standard errors & covariance computed using observed Hessian

Random search: 25 starting values with 10 iterations using 1 standard deviation (rng=kn, seed=1720983973)

Convergence achieved after 15 iterations

| Variable | Coefficient | Std. Error | z-Statistic | Prob. |
|-----------------|-------------|------------|-------------|--------|
| Regime 1 | | | | |
| ECM | 0.010396 | 0.009491 | 1.095333 | 0.2734 |
| DINFLASI(-1) | 0.069757 | 0.011178 | 6.240527 | 0.0000 |
| DINFLASI(-2) | -4.99E-05 | 0.010000 | -0.004989 | 0.9960 |
| DSB(-1) | 0.555460 | 0.068324 | 8.129774 | 0.0000 |
| DSB(-2) | 0.013120 | 0.052286 | 0.250936 | 0.8019 |
| Regime 2 | | | | |
| ECM | -0.658781 | 0.049323 | -13.35649 | 0.0000 |
| DINFLASI(-1) | 0.061999 | 0.016221 | 3.822290 | 0.0001 |
| DINFLASI(-2) | 0.092252 | 0.100118 | 0.921434 | 0.3568 |
| DSB(-1) | -0.057770 | 0.079943 | -0.722639 | 0.4699 |
| DSB(-2) | 0.380722 | 0.123893 | 3.072999 | 0.0021 |
| Common | | | | |
| LOG(SIGMA) | -2.189935 | 0.059994 | -36.50240 | 0.0000 |

Lampiran 8. (Lanjutan)

Probabilities Parameters

| | | | | |
|-----------------------|-----------|--------------------|----------|-----------|
| P1-C | 1.768649 | 0.326993 | 5.408831 | 0.0000 |
| Mean dependent var | -0.031841 | S.D. dependent var | | 0.267791 |
| S.E. of regression | 0.207328 | Sum squared resid | | 8.167146 |
| Durbin-Watson stat | 1.840542 | Log likelihood | | 114.8570 |
| Akaike info criterion | -1.023453 | Schwarz criterion | | -0.826241 |
| Hannan-Quinn criter. | -0.943652 | | | |

Dependent Variable: DINFLASI

Method: Simple Switching Regression (BFGS / Marquardt steps)

Date: 05/28/20 Time: 13:47

Sample (adjusted): 2003M04 2019M12

Included observations: 201 after adjustments

Number of states: 2

Standard errors & covariance computed using observed Hessian

Random search: 25 starting values with 10 iterations using 1 standard deviation (rng=kn, seed=62050926)


Convergence achieved after 16 iterations

| Variable | Coefficient | Std. Error | z-Statistic | Prob. |
|--------------|-------------|------------|-------------|--------|
| Regime 1 | | | | |
| ECM | -0.033099 | 0.071657 | -0.461913 | 0.6441 |
| DINFLASI(-1) | 0.103088 | 0.026172 | 3.938902 | 0.0001 |
| DINFLASI(-2) | -0.023500 | 0.130243 | -0.180435 | 0.8568 |
| DSB(-1) | -0.074684 | 0.123580 | -0.604341 | 0.5456 |
| DSB(-2) | 0.602318 | 0.197037 | 3.056869 | 0.0022 |
| Regime 2 | | | | |
| ECM | 1.017540 | 0.015301 | 66.50341 | 0.0000 |
| DINFLASI(-1) | 0.119712 | 0.017432 | 6.867450 | 0.0000 |
| DINFLASI(-2) | -0.000583 | 0.016571 | -0.035172 | 0.9719 |
| DSB(-1) | 0.920741 | 0.111078 | 8.289154 | 0.0000 |
| DSB(-2) | -0.013996 | 0.086525 | -0.161759 | 0.8715 |
| Common | | | | |
| LOG(SIGMA) | -1.713650 | 0.061323 | -27.94485 | 0.0000 |

Lampiran 8. (Lanjutan)


Probabilities Parameters

| P1-C | -1.596709 | 0.316098 | -5.051311 | 0.0000 |
|-----------------------|-----------|--------------------|-----------|----------|
| Mean dependent var | -0.022139 | S.D. dependent var | | 1.065557 |
| S.E. of regression | 0.340893 | Sum squared resid | | 22.07948 |
| Durbin-Watson stat | 1.849316 | Log likelihood | | 17.98910 |
| Akaike info criterion | -0.059593 | Schwarz criterion | | 0.137619 |
| Hannan-Quinn criter. | 0.020208 | | | |






(Halaman ini sengaja dikosongkan)



Lampiran 9. Diagnostik Sisaan Model

```
> #Uji Sisaan white Noise
> portes=BoxPierce(sisaan, lags=seq(10))
> portes
lags  statistic df      p-value
  1  1.566485  4 8.148028e-01
  2  77.293666  8 1.710854e-13
  3 109.985949 12 0.000000e+00
  4 114.683199 16 1.110223e-16
  5 115.392989 20 1.998401e-15
  6 116.868429 24 3.497203e-14
  7 121.916648 28 1.094680e-13
  8 124.102125 32 8.784085e-13
  9 128.894271 36 2.219447e-12
 10 146.357987 40 4.840572e-14
> #Uji Normalitas Sisaan
> sisaan=as.data.frame(sisaan)
> sx=cov(sisaan)
> me1=colMeans(sisaan)
> library(stats)
> d2=mahalanobis(sisaan,me1,sx)
> View(d2)
> plot=qqplot(qchisq(ppoints(51),df=2),d2,main=expression("Q-Q
Plot of Mahalanobis"*~D^2*~vs.quantiles of "~chi[2]^2))
> abline(0,1,col='grey')
```

Q-Q Plot of Mahalanobis D^2 vs. quantiles of χ^2_2





(Halaman ini sengaja dikosongkan)

