



TESIS - KS185411

**PEMODELAN VOLATILITAS *GROSS DOMESTIC PRODUCT*
MENGGUNAKAN *FRACTIONAL COINTEGRATION MODEL***

**AISYAH ABDULLAH
06211750012008**

**Dosen Pembimbing
Dr.rer.pol. Heri Kuswanto. M.Si
Dr.rer.pol. Dedy Dwi Prastyo. M.Si**

**Departemen Statistika
Fakultas Sains dan Analitika Data
Institut Teknologi Sepuluh Nopember
2020**



TESIS - KS185411

PEMODELAN VOLATILITAS GROSS DOMESTIC PRODUCT MENGGUNAKAN FRACTIONAL COINTEGRATION MODEL

AISYAH ABDULLAH
06211750012008

Dosen Pembimbing
Dr.rer.pol. Heri Kuswanto. M.Si
Dr.rer.pol. Dedy Dwi Prastyo. M.Si

Departemen Statistika
Fakultas Sains dan Analitika Data
Institut Teknologi Sepuluh Nopember
2020



THESIS - KS185411

MODELING THE VOLATILITY OF GROSS DOMESTIC PRODUCT USING THE FRACTIONAL COINTEGRATION MODEL

AISYAH ABDULLAH
06211750012008

Supervisor
Dr.rer.pol. Heri Kuswanto. M.Si
Dr.rer.pol. Dedy Dwi Prastyo. M.Si

Department of Statistics
Faculty of Science and Data Analytics
Institut Teknologi Sepuluh Nopember
2020

LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar

Magister Statistik (M.Stat)

di

Institut Teknologi Sepuluh Nopember

oleh

AISYAH ABDULLAH

NRP: 06211750012008

Tanggal Ujian : 23 Januari 2020

Periode Wisuda : Maret 2020

Disetujui oleh:

Pembimbing :

1. Dr.rer.pol. Heri Kuswanto, M.Si.
NIP: 19820326 200312 1 004

2. Dr.rer.pol. Dedy Dwi Prastyo, M.Si.
NIP: 19831204 200812 1 002

Pengaji :

1. R. Mohamad Atok, M.Si., Ph.D.
NIP: 19710915 199702 1 001

2. Dr. Agus Suharsono, MS.
NIP: 19580823 198403 1 003



Pemodelan Volatilitas Gross Domestic Product Menggunakan Fractional Cointegration Model

Nama Mahasiswa : Aisyah Abdullah

NRP : 06211750012008

Pembimbing : Dr. rer. pol. Heri Kuswanto. M.Si

Dr. rer. pol. Dedy Dwi Prastyo. M.Si

ABSTRAK

Pertumbuhan ekonomi adalah indeks kuantitatif untuk menentukan tingkat kemajuan ekonomi yang dapat diukur dengan *Gross Domestic Product* (GDP). Berbagai literatur bertujuan untuk memecahkan masalah mengenai pola pertumbuhan ekonomi serta mengenai faktor penentu dimana digunakan analisis model volatilitas. Beberapa indikator pertumbuhan ekonomi adalah *money supply*, *inflation*, *interest rate*, dan *exchange rate*. Indikator lain yang dapat mempengaruhi pertumbuhan ekonomi yaitu kebijakan yang diambil pemerintah. Salah satu kebijakan yang pengaruhnya banyak diperdebatkan yaitu *Inflation Targeting Framework* (ITF). Variabel ekonomi dicatat sebagai data *time series* dengan periode yang berbeda, oleh karena itu agregasi temporal diperlukan dalam analisis. Data *time series* ekonomi menunjukkan adanya *long memory* dan *structural break*, sehingga akan sulit menjelaskan data hanya dengan model yang umum. Oleh karena itu, baik model *long memory* dan *structural break* dipertimbangkan dalam model. Dalam analisis ini, residual dari kombinasi linear variabel-variabel ekonomi mengikuti proses *long memory* yang menunjukkan hubungan *cointegration* antara variabel-variabel tersebut. Penelitian ini memodelkan volatilitas GDP berdasarkan volatilitas *money supply*, *inflation*, *interest rate*, dan *exchange rate* di United Kingdom, Switzerland, Indonesia, Filipina, Jerman, Denmark, Malaysia, dan Singapura menggunakan model *Fractional Cointegration* dengan *long memory* dan *structural break*. Analisis menunjukkan bahwa *structural break* hanya ditemukan dalam volatilitas GDP United Kingdom, Indonesia, Malaysia, dan Singapura sementara sifat *long memory* ditemukan di hampir semua volatilitas variabel ekonomi. Selain itu, pada model *cointegration*, diperoleh residual yang stasioner dan persisten di semua negara.

Kata Kunci: GDP, Volatilitas, *Fractional Cointegration*, *Long Memory*, *Structural Break*

(Halaman ini sengaja dikosongkan)

Modeling the Volatility of Gross Domestic Product

Using the Fractional Cointegration Model

Name	:	Aisyah Abdullah
NRP	:	06211750012008
Supervisor	:	Dr. rer. pol. Heri Kuswanto. M.Si
		Dr. rer. pol. Dedy Dwi Prastyo. M.Si

ABSTRACT

Economic growth is a quantitative index to determine the level of economic progress that can be measured by gross domestic product (GDP). Various literatures aim to solve problems regarding patterns of economic growth as well as about the determinants wherein the analysis volatility models are used. Some indicators of economic growth are money supply, inflation, interest rates, and exchange rates. Another indicator that can influence economic growth is the policy taken by the government. One of the policies whose influence is much debated is the Inflation Targeting Framework (ITF). Economic variables are recorded as time series data with different periods, and hence temporal aggregation is required to analyze. Economic time series data showing the existence of long memory and structural breaks, which leads to the difficulty on explaining the data only with a general model. Therefore, both long memory models and structural break are proposed to be taken into account in the model. In this analysis, the residual from a linear combination of economic variables follows a long memory process indicating a cointegration relationship between these variables. This paper models GDP volatility based on money supply, inflation, interest rate and exchange rate volatility in United Kingdom, Switzerland, Indonesia, Philippines, Germany, Denmark, Malaysia, and Singapore using the Fractional Cointegration model with long memory and structural break. The analysis shows that structural break is only found in the volatility of GDP of Indonesia, Malaysia, and Singapore while the nature of long memory is found in almost all economic variables' volatility. Furthermore, we found the cointegration model, stationary and persistent noise in all countries.

Keyword: GDP, Volatility, Fractional Cointegration, Long Memory, Structural Break

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur kehadirat ALLAH SWT yang telah melimpahkan banyak hidayah, rahmat, serta karunia-Nya kepada penulis sehingga dapat menyelesaikan tesis yang berjudul “Pemodelan Volatilitas *Gross Domestic Product* Menggunakan *Fractional Cointegration Model*”. Sholawat serta salam tercurahkan kepada Nabi Muhammad SAW yang telah menjadi panutan dalam berbagai aspek. Dalam penyusunan tesis ini penulis telah banyak mendapatkan bantuan dan dorongan dari berbagai pihak, oleh karena itu penulis menyampaikan ucapan terima kasih kepada:

1. Kedua orang tua tercinta, Abdullah Umar bin Smeer dan Latifah Abdurrachman Babher serta adik-adik tersayang, Hannan Abdullah bin Smeer, Balgis Abdullah bin Smeer, dan Najwa Abdullah bin Smeer yang selalu memberi do'a, dorongan, dan dukungan pada penulis.
2. Dr. rer. pol. Heri Kuswanto. M.Si dan Dr. rer. pol. Dedy Dwi Prastyo. M.Si selaku pembimbing I dan pembimbing II yang dengan sabar telah memberikan penjelasan, pengarahan, saran, dan bimbingannya kepada penulis dari awal hingga akhir penyelesaian tesis ini.
3. R. Mohamad Atok, M.Si, Ph.D dan Dr. Agus Suharsono, MS selaku dosen penguji yang memberikan petunjuk dan pengarahan untuk memperbaiki tesis ini.
4. Teman-teman “S2 Statistika Institut Teknologi Sepuluh Nopember 2017 Angkatan Genap” dan keluarga besar “Statistika ITS” yang selalu ada untuk memberikan bantuan, dukungan, dan semangat kepada penulis.

Penulis menyadari bahwa tesis ini masih banyak memiliki kekurangan. Oleh karena itu, penulis sangat mengharapkan adanya kritik dan saran yang membangun agar menjadi lebih baik untuk masa yang akan datang.

Surabaya, Januari 2020

Penulis

(Halaman ini sengaja dikosongkan)

DAFTAR ISI

LEMBAR PENGESAHAN TESIS	i
ABSTRAK	iii
ABSTRACT	v
KATA PENGANTAR.....	vii
DAFTAR ISI.....	ix
DAFTAR TABEL	xi
DAFTAR GAMBAR.....	xii
DAFTAR LAMPIRAN	xiii
BAB 1 PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	6
1.5 Batasan Masalah	6
BAB 2 TINJAUAN PUSTAKA	
2.1 <i>Time Series</i>	7
2.1.1 <i>Autocorrelaton Function (ACF)</i>	7
2.1.2 <i>Partial Autocorrelation Function (PACF)</i>	8
2.1.3 Stasioneritas	9
2.1.4 Uji Kestasioneran dengan Uji Augmented Dickey Fuller (ADF)10	10
2.1.5 Model <i>Autoregressive Integrated Moving Average</i>	10
2.1.6 <i>Diagnostic Checking</i>	12
2.2 Volatilitas	15
2.2.1 Uji Efek Heteroskedastisitas dengan Uji Langrange	15
2.3 Agregasi Temporal	16
2.4 <i>Markov Switching</i>	17
2.4.1 Uji Perubahan <i>Regime</i> dengan Uji CUSUM.....	18
2.4.2 Estimasi Model <i>Markov Switching</i>	19
2.5 Model Regresi Probit	22
2.5.1 Uji Multikolinieritas dengan Nilai VIF.....	24
2.5.2 Estimasi Model Probit.....	24
2.5.3 Uji Signifikansi Parameter Model Probit.....	26
2.5.4 Ketepatan Klasifikasi	27
2.6 <i>Long Memory</i>	28
2.6.1 <i>Fractional Integration</i>	28
2.6.2 <i>Fractional Cointegration</i>	30
2.6.3 Uji <i>Cointegration</i> pada Model Menggunakan Uji ADF	30
2.6.4 Estimasi Parameter <i>Fractional Cointegration</i>	31

2.7 Kriteria Kenaikan Model	33
2.8 <i>Inflation Targeting Framework</i>	33
2.8.1 <i>Gross Domestic Product</i>	35
2.8.2 <i>Money Supply</i>	37
2.8.3 <i>Inflation</i>	38
2.8.4 <i>Interest Rate</i>	39
2.8.4 <i>Exchange Rate</i>	39
BAB 3 METODOLOGI PENELITIAN	
3.1 Sumber Data dan Variabel Penelitian	41
3.2 Struktur Data Penelitian	42
3.3 Langkah Analisis	42
3.3.1 Pemodelan Volatilitas dari Variabel <i>Money Supply</i> , <i>Inflation</i> , dan <i>Interest Rate</i> Terhadap Volatilitas <i>Gross Domestic Product</i> Menggunakan <i>Fractional Cointegration Model</i>	42
3.3.2 Evaluasi Penerapan <i>Inflation Targeting Framework</i> Terhadap <i>Gross Domestic Product</i>	44
3.4 Diagram Alir	44
BAB 4 ANALISIS DAN PEMBAHASAN	
4.1 Deskripsi Karakteristik Data.....	47
4.2 Pemodelan Volatilitas dari Variabel <i>Money Supply</i> , <i>Inflation</i> , <i>Interest</i> <i>Rate</i> , dan <i>Exchange Rate</i> Terhadap Volatilitas <i>Gross Domestic</i> <i>Product</i> Menggunakan <i>Fractional Cointegration Model</i>	55
4.2.1 Volatilitas dari Residual Pemodelan ARMA.....	55
4.2.2 Pemodelan <i>Markov Switching</i> untuk Volatilitas <i>GDP Growth</i> .	60
4.2.3 Klasifikasi Hasil <i>Markov Switching</i>	65
4.2.4 Penaksiran Parameter <i>Long Memory</i> dan Pemodelan <i>Cointegration</i>	72
4.3 Evaluasi Penerapan <i>Inflation Targeting Framework</i> Terhadap <i>Gross</i> <i>Domestic Product</i>	75
BAB 5 KESIMPULAN DAN SARAN	
5.1 Latar Belakang	77
5.2 Rumusan Masalah.....	77
DAFTAR PUSTAKA	79
LAMPIRAN	83

DAFTAR TABEL

Tabel 2.1 Transformasi Box-Cox	10
Tabel 2.2 Ketepatan Klasifikas	27
Tabel 3.1 Daftar Nama Negara	41
Tabel 3.2 Variabel Penelitian.....	41
Tabel 3.3 Struktur Data.....	42
Tabel 4.1 Karakteristik <i>GDP Growth</i>	48
Tabel 4.2 Karakteristik <i>Money Supply</i>	49
Tabel 4.3 Karakteristik <i>Inflation</i>	51
Tabel 4.4 Karakteristik <i>Interest Rate</i>	52
Tabel 4.5 Karakteristik <i>Exchange Rate</i>	54
Tabel 4.6 Kesimpulan Pengujian Ljung-Box dan Lagrange Multiplier.....	55
Tabel 4.7 Hasil Uji CUSUM Volatilitas <i>GDP Growth</i>	60
Tabel 4.8 Estimasi Parameter Model <i>Markov Switching</i> Volatilitas <i>GDP Growth</i>	61
Tabel 4.9 Model <i>Markov Switching</i> Volatilitas <i>GDP Growth</i> Terbaik.....	63
Tabel 4.10 Nilai VIF Variabel Prediktor Regresi Probit	66
Tabel 4.11 Estimasi Parameter Regresi Probit	66
Tabel 4.12 Model Regresi Probit	67
Tabel 4.13 Estimasi Parameter Regresi Probit <i>Stepwise</i>	68
Tabel 4.14 Model Regresi Probit	68
Tabel 4.15 Tabel Klasifikasi dan Perhitungan Nilai APPER	69
Tabel 4.16 Ketepatan Klasifikasi <i>Regime</i>	71
Tabel 4.17 Estimasi Parameter <i>Long Memory</i> Variabel	72
Tabel 4.18 Estimasi Parameter Model <i>Cointegration</i>	73
Tabel 4.19 Model <i>Cointegration</i>	74

(Halaman ini sengaja dikosongkan)

DAFTAR GAMBAR

Gambar 3.1 Diagram Alir	44
Gambar 3.1 Diagram Alir (Lanjutan)	45
Gambar 4.1 Plot <i>Time Series GDP Growth</i>	47
Gambar 4.2 Plot <i>Time Series Money Supply</i>	49
Gambar 4.3 Plot <i>Time Series Inflation</i>	50
Gambar 4.4 Plot <i>Time Series Interest Rate</i>	52
Gambar 4.5 Plot <i>Time Series Exchange Rate</i> Terhadap USD	53
Gambar 4.6a Plot <i>Time Series Volatilitas</i> (a) United Kingdom, (b) Switzerland, (c) Indonesia, dan (d) Filipina yang Menerapkan ITF	56
Gambar 4.6b Plot <i>Time Series Volatilitas</i> (e) Jerman, (f) Denmark, (g) Malaysia, dan (h) Singapura yang Tidak Menerapkan ITF	57
Gambar 4.7a Plot <i>Time Series Volatilitas Hasil Agregasi</i> (a) United Kingdom, (b) Switzerland, (c) Indonesia, dan (d) Filipina yang Menerapkan ITF	58
Gambar 4.7b Plot <i>Time Series Volatilitas Hasil Agregasi</i> (e) Jerman, (f) Denmark, (g) Malaysia, dan (h) Singapura yang Tidak Menerapkan ITF	59
Gambar 4.8a Plot ACF dan PACF Volatilitas <i>GDP Growth</i> Jerman	60
Gambar 4.8b Plot ACF dan PACF Volatilitas <i>GDP Growth</i> Malaysia.....	61
Gambar 4.8 Plot <i>Time Series Volatilitas GDP Growth</i> Berdasarkan <i>Regime</i>	65

(Halaman ini sengaja dikosongkan)

DAFTAR LAMPIRAN

Lampiran 1. Data Penelitian.....	83
Lampiran 2. Model ARMA Terbaik	85
Lampiran 3. Hasil Ljung-Box Test dan Lagrange Multiplier Test	88
Lampiran 4. Sintaks untuk Input Data	93
Lampiran 5. Sintaks Memperoleh Residual ARMA dan Memperoleh Deret Volatilitas	94
Lampiran 6. Sintaks Pengujian Normalitas, <i>White Noise</i> , dan Heterogenitas	96
Lampiran 7. Syntaks Agregasi Volatilitas	98
Lampiran 8. Sintaks Pengujian Perubahan pada <i>Mean</i>	100
Lampiran 9. Sintaks Pemodelan <i>Markov Switching</i>	101
Lampiran 10. Sintaks Pengklasifikasian <i>Regime</i>	103
Lampiran 11. Sintaks Regresi Probit	107
Lampiran 12. Sintaks Estimasi <i>Long Memory</i> Semua Variabel pada setiap <i>Regime</i>	108
Lampiran 13. Surat Izin Penggunaan Data	109

(Halaman ini sengaja dikosongkan)

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Masalah pertumbuhan ekonomi merupakan masalah klasik baik bagi negara maju maupun bagi negara berkembang. Pertumbuhan ekonomi adalah indeks kuantitatif yang mengukur tingkat kemajuan ekonomi negara serta faktor-faktor penting yang mempengaruhinya. Oleh karena itu, masalah yang terkait dengan pola pertumbuhan dan memahami faktor penentu pertumbuhan ekonomi adalah permasalahan mendasar dalam berbagai penelitian baik secara teoritis maupun empiris. Salah satu penelitian secara empiris yaitu penelitian yang dilakukan oleh Barcilar, Gupta, dan Jooste (2016) yang membahas mengenai persistensi pada *consumer price index inflation* di Afrika Selatan menggunakan model *Markov Switching – Autoregressive Fractional Integrated Moving Average* dan diperoleh kesimpulan bahwa pada data terdapat persistensi yang kuat baik pada *regime 1 (high inflation)* maupun pada *regime 2 (low inflation)*. Pada penelitian lain yaitu pada penelitian yang dilakukan oleh Bhattacharya (2011) yang membahas mengenai hubungan antar variabel *Gross Domestic Product* (GDP), *Money Supply*, *Inflation*, *Interest Rate*, dan *Exchange Rate* di United Kingdom menggunakan *Simultaneous Equation Model*. Penelitian ini menggunakan variabel *Gross Domestic Product* (GDP), *Money Supply*, *Inflation*, *Interest Rate*, dan *Exchange Rate* dan diperoleh kesimpulan yaitu jika terdapat kenaikan pada *money supply* dan *inflation* maka akan menyebabkan kenaikan pada GDP, sementara itu kenaikan pada *interest rate* dan *exchange rate* akan menyebabkan penurunan GDP. Kesimpulan tersebut digunakan untuk meningkatkan perekonomian dengan perbaikan kebijakan. Sedangkan pada penelitian yang dilakukan oleh Urbanovsky (2017) membahas mengenai kausalitas *Granger* pada variabel *Real Gross Domestic Product*, *Money Supply*, *Interest Rate*, dan *Price Level*. Penelitian ini menggunakan *Vector Autoregressive Model* dan diperoleh kesimpulan bahwa model uang diperoleh tidak dapat digunakan untuk

memprediksi namun dapat digunakan untuk mengetahui arah pengaruh variabel-variabel penelitian tersebut.

Tinggi atau rendahnya pertumbuhan ekonomi dapat diukur dengan menghitung GDP negara yang bersangkutan. Dapat mencapai pertumbuhan ekonomi yang tinggi dan stabil merupakan salah satu tujuan kebijakan ekonomi makro. Kebijakan ekonomi yang digunakan sebagai otoritas moneter untuk mengendalikan atau mengarahkan perekonomian pada kondisi yang baik atau kondisi yang diinginkan sehingga dapat mencapai tujuan ekonomi tertentu. Usaha dalam meningkatkan pertumbuhan ekonomi tersebut menjadi tanggung jawab besar bagi pembuat kebijakan ekonomi karena kebijakan yang akan diberlakukan akan berdampak pada pertumbuhan ekonomi sekaligus pada kesejahteraan masyarakat. Kebijakan moneter yang pada umumnya menempatkan beberapa indikator penting salah satunya yakni *money supply*, *inflation*, dan *interest rate*. Beberapa penelitian sebelumnya dapat membuktikan bahwa *money supply*, *inflation*, *interest rate*, dan *exchange rate* mampu mempengaruhi pertumbuhan ekonomi.

Dalam 15 tahun terakhir, beberapa negara maju dan berkembang telah mengikuti langkah yang telah ditempuh oleh Selandia Baru dalam mengimplementasikan salah satu kebijakan ekonomi yang dianggap dapat meningkatkan pertumbuhan ekonomi sekaligus menyelesaikan permasalahan yang timbul akibat rendahnya pertumbuhan ekonomi yaitu *Inflation Targeting Framework* (ITF). Penelitian dari beberapa negara menunjukkan adanya perubahan inflasi yang cukup besar, tetapi hal ini perlu diteliti lebih mendalam untuk mengetahui penyebab perubahan inflasi tersebut maupun dampaknya terhadap variabel ekonomi lainnya. Penerapan ITF telah menimbulkan beberapa perdebatan dikalangan akademisi, adanya perbedaan hasil penelitian empiris di lapangan termasuk salah satu penyebab timbulnya perdebatan tersebut. Pada penelitian yang dilakukan Batini dkk (2006), Mishkin dan Hebbel (2007), dan Svensson (2007) tidak ditemukan bukti bahwa ITF memberikan dampak yang negatif terhadap pertumbuhan ekonomi disuatu negara. Namun berdasarkan penelitian yang dilakukan oleh Goncalves dan Salles (2008) mengklaim manfaat potensial yang sangat besar yang didapatkan dari penerapan ITF. Penelitian

tersebut menemukan bahwa manfaat yang didapatkan dari penerapan ITF adalah rendahnya *inflation rate*, *interest rate*, dan meningkatnya pertumbuhan ekonomi. Penelitian penerapan ITF dengan hasil positif menuai kritik oleh beberapa penelitian empiris yang bertentangan. Hal itu dikuatkan dengan hasil penelitian Fouejieu (2013) yang menemukan selama terjadinya krisis tahun 2008/2009 tidak menemukan adanya perbedaan signifikan pertumbuhan GDP pada negara yang menerapkan ITF maupun yang tidak menerapkan ITF.

Terdapat dua pendekatan empiris yang biasanya dilakukan oleh para peneliti untuk melihat prestasi dari ITF yang pertama yaitu pendekatan ini mengevaluasi ITF dengan cara fokus terhadap perbandingan perilaku bank sentral yang mengadopsi ITF ataupun yang tidak menerapkan ITF, dan bagaimana bank sentral dari negara tersebut mengambil kebijakan dalam pelaksanaan ITF. Yang kedua yaitu pendekatan ini menfokuskan pada hasil makroekonomi (GDP) dari negara yang menerapkan ITF dan dibandingkan dengan negara yang tidak menerapkan kebijakna ITF. Penggunaan GDP dikarenakan GDP dapat mengukur perubahan pada pertumbuhan ekonomi suatu negara akibat diberlakukannya suatu kebijakan oleh pemerintah pada negara tersebut. Untuk mendapatkan informasi mengenai perubahan nilai pada variabel ekonomi, nilai volatilitas dari variabel tersebut dapat digunakan dalam analisis.

Berdasarkan paparan diatas, pada penelitian ini penting dilakukan analisa model volatilitas GDP berdasarkan volatilitas *money supply*, *inflation*, dan *interest rate* secara serentak yang dilakukan pada beberapa negara yang dipilih yaitu negara yang menerapkan ITF dan negara yang tidak menerapkan ITF dengan mengembangkan penelitian dari penelitian yang telah ada sebelumnya.

Banyak data ekonomi dicatat pada frekuensi yang berbeda. Sebagian besar data ekonomi dikumpulkan secara bulanan, triwulanan, atau tahunan. Metode yang paling umum untuk mendapatkan frekuensi data yang sama adalah agregasi temporal. Souza (2008) telah membuktikan secara teori bahwa prosedur agregasi memiliki sifat yang sama tentang *invariance* dari parameter *long memory*. Diketahui bahwa banyak dari data *time series* ekonomi menunjukkan adanya *long memory*, atau ketergantungan jangka panjang. Seperti yang ditunjukkan oleh Ding dkk. (1993), de Lima dan Crato (1993), dan Bollerslev dan Mikkelsen (1996)

bahwa volatilitas sebagian besar data *time series* keuangan menunjukkan persistensi yang kuat dan dapat digambarkan sebagai proses *long memory*. Termasuk pada data *money supply*, *inflation*, *interest rate*, *exchange rate*, dan *gross domestic product*. Dalam melakukan pemodelan, penting untuk membedakan antara *long memory* dan ketergantungan terhadap perubahan fluktuasi. Diebold dan Inoue (2001) menunjukkan bahwa dapat terjadi ketidak jelasan antara *long memory* dengan *Markov Switching*. Pada data ekonomi juga dapat diketahui bahwa tidak hanya mengandung *long memory* namun juga terdapat perubahan fluktuasi atau *trend*. Pertimbangan tersebut mengarahkan kita untuk menggabungkan *long memory* dan *structural break* ke dalam pemodelan. Engle dan Smith (1999) mencari hubungan antara *structural break* dan *long memory* menggunakan model sederhana dimana proses menghasilkan rata-rata dan *noise* yang stasioner. Model *long memory* diperkenalkan oleh Granger (1980), Granger dan Joyeux (1980), dan Hosking (1981) menunjukkan bahwa data *long memory* dapat dimodelkan dengan baik dengan model *Autoregressive Fractional Integrated Moving Average* (ARFIMA). Dalam menganalisis hubungan *long memory* antara variabel-variabel ekonomi, dapat diketahui bahwa residual dari kombinasi linear variabel-variabel tersebut dapat juga mengikuti proses *long memory*, sehingga terdapat hubungan *cointegration* pada variabel-variabel tersebut. Aloy (2010) menggunakan pendekatan *fractional integration* dan *fractional cointegration* dalam menganalisis data harian *Stock Market*, *Industrial Average*, dan *Exchange Rate* sehingga diperoleh kesimpulan bahwa pendekatan *fractional cointegration* perlu dilakukan untuk mengetahui hubungan variabel-variabel yang terdapat *long memory*. Sedangkan pada model *structural break*, Hamilton (1989) mengusulkan model *Markov Switching*. Pada penelitian yang dilakukan oleh Kuswanto dan Salamah (2009) telah dibahas mengenai penerapan *Regime Switching Long Memory Model* pada *stock return* Jerman dan diperoleh model yang akurat dalam mencakup *long memory* dan *regime switching* pada data *stock return*. Estimasi parameter pada pemodelan *structural break* pada parameter *mean* dan pada parameter *fractional integrated* juga dibahas pada penelitian yang dilakukan oleh Ozkan, Stengos, dan Yazgan (2016) dimana model tersebut diaplikasikan pada data simulasi dengan metode *Monte Carlo* dan diperoleh

kesimpulan bahwa pada beberapa data simulasi *structural break* terdapat pada parameter *mean* juga pada parameter *fractional integrated* sehingga diperlukan pengujian adanya proses *structural break* pada parameter *mean* maupun pada parameter *fractional integrated*.

Pada analisis atau pemodelan, pada penelitian ini akan digunakan model *Fractional Cointegration* dengan *Structural Break* dan *Long Memory*. Model *Fractional Cointegration* tersebut menyediakan pemodelan yang fleksibel untuk aplikasi ke banyak kasus. Seperti pada Beltratti dan Morana (2006), dalam penelitiannya membahas mengenai hubungan antara variabel *macroeconomic* dan *stock market* menggunakan *fractional cointegration* dengan *structural break long memory model*.

Berdasarkan paparan diatas, pada penelitian ini akan dianalisa model volatilitas *gross domestic product* berdasarkan volatilitas *money supply*, *inflation*, *interest rate*, dan *exchange rate* secara serentak yang dilakukan pada negara-negara dibenua Asia dan Eropa yang menerapkan ITF dan negara-negara dibenua Asia dan Eropa yang tidak menerapkan ITF dengan menggunakan model *Fractional Cointegration* dengan *Structural Break* dan *Long Memory*.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, dirumuskan permasalahan sebagai berikut yaitu bagaimana pemodelan volatilitas GDP berdasarkan volatilitas *money supply*, *inflation*, *interest rate*, dan *exchange rate* secara serentak yang dilakukan pada negara-negara dibenua Asia dan Eropa yang mengadopsi ITF yaitu United Kingdom, Switzerland, Indonesia, dan Filipina, dan pada negara-negara dibenua Asia dan Eropa yang tidak mengadopsi ITF yaitu Jerman, Denmark, Malaysia, dan Singapura menggunakan *Fractional Cointegration Model* dan bagaimana evaluasi penerapan ITF terhadap volatilitas GDP pada negara-negara dibenua Asia dan Eropa.

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah tersebut, maka tujuan penelitian yang ingin dicapai adalah sebagai berikut

1. Memperoleh model terbaik volatilitas GDP berdasarkan volatilitas *money supply*, *inflation*, *interest rate*, dan *exchange rate* secara serentak yang dilakukan pada negara-negara dibenua Asia dan Eropa yang menerapkan ITF yaitu United Kingdom, Switzerland, Indonesia, dan Filipina, dan pada negara-negara dibenua Asia dan Eropa yang tidak menerapkan ITF yaitu Jerman, Denmark, Malaysia, dan Singapura menggunakan *Fractional Cointegration Model*.
2. Mengevaluasi hasil penerapan *Inflation Targeting Framework* terhadap volatilitas GDP pada negara-negara dibenua Asia dan Eropa.

1.4 Manfaat Penelitian

Manfaat yang diharapkan pada penelitian ini adalah sebagai berikut

1. Diharapkan dapat memberikan bukti empiris yang akurat sebagai acuan pengambilan kebijakan dalam meningkatkan pertumbuhan ekonomi.
2. Diharapkan dapat memberikan sumbangsih terhadap perkembangan ilmu pengetahuan dan menambah wawasan pengetahuan dalam bidang statistika terutama dalam penerapan *Fractional Cointegration Model*.
3. Diharapkan dapat memperkuat pengetahuan penulis mengenai pemodelan variabel ekonomi menggunakan *Fractional Cointegration Model*.

1.5 Batasan Penelitian

Batasan pada penelitian ini yaitu sebagai berikut

1. Penelitian ini menggunakan data sekunder dari *website* OECD, CEIC, dan ARIC dimana hanya menganalisa empat negara yang menerapkan ITF yaitu United Kingdom, Switzerland, Indonesia, dan Filipina, dan empat negara yang tidak menerapkan ITF yaitu Jerman, Denmark, Malaysia, dan Singapura.
2. Penelitian ini menggunakan model *Fractional Cointegration* dengan *Markov Switching* dan *Long Memory*.
3. Penelitian ini menggunakan model ARMA pada pemodelan *mean* dan menggunakan tiga model dugaan pada pemodelan *Markov Switching* yaitu MS-AR(1), MS-AR(2), dan MS-AR(2).

BAB 2

TINJAUAN PUSTAKA

Pada bab ini akan disajikan tentang tinjauan pustaka yang digunakan dalam menyelesaikan masalah penelitian guna untuk mencapai tujuan penelitian.

2.1 *Time Series*

Time series merupakan serangkaian observasi terhadap suatu variabel yang diambil secara beruntun berdasarkan interval waktu yang tetap (Wei, 2006). Rangkaian data pengamatan *time series* dinyatakan dengan variabel Y_t dimana t adalah indeks waktu dari urutan pengamatan. Metode *time series* adalah metode peramalan dengan menggunakan analisa pola hubungan antara variabel yang akan dipekirakan dengan variabel waktu. Peramalan suatu data *time series* perlu memperhatikan tipe atau pola data. Secara umum terdapat empat macam pola data *time series*, yaitu horizontal, *trend*, musiman, dan siklis (Hanke dan Wichren, 2005). Pola horizontal merupakan kejadian yang tidak terduga dan bersifat acak, tetapi kemunculannya dapat mempengaruhi fluktuasi data *time series*. Pola *trend* merupakan kecenderungan arah data dalam jangka panjang, dapat berupa kenaikan maupun penurunan. Pola musiman merupakan fluktuasi dari data yang terjadi secara periodik dalam kurun waktu satu tahun, seperti triwulan, kuartalan, bulanan, mingguan, atau harian. Sedangkan pola siklis merupakan fluktuasi dari data untuk waktu yang lebih dari satu tahun.

2.1.1 *Autocorrelatlon Function (ACF)*

Covariance antara Y_t dan Y_{t+k} yang terpisah oleh k interval waktu disebut *autocovariance* pada lag k . Untuk semua proses Y_t yang stasioner terdapat nilai *mean* $E(Y_t) = \mu$, *variance* $Var(Y_t) = E(Y_t - \mu)^2 = \sigma^2$ dengan nilai-nilai tersebut konstan dan *covariance* antara Y_t dan Y_{t+k} dinyatakan sebagai berikut

$$\gamma_k = Cov(Y_t, Y_{t+k}) = E(Y_t - \mu)(Y_{t+k} - \mu) \quad (2.1)$$

Sedangkan *correlation* antara *time series* dengan *time series* itu sendiri dengan *time lag* 0, 1, 2, atau lebih periode disebut *autocorrelation*. *Autocorrelation* antara Y_t dan Y_{t+k} dinyatakan sebagai berikut

$$\rho_k = \text{Corr}(Y_t, Y_{t+k}) = \frac{\text{Cov}(Y_t, Y_{t+k})}{\sqrt{\text{Var}(Y_t)} \sqrt{\text{Var}(Y_{t+k})}} \quad (2.2)$$

Untuk keadaan yang stasioner $\text{Var}(Y_t) = \text{Var}(Y_{t+k}) = \gamma_0$ sehingga

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad (2.3)$$

Sebagai fungsi dari k , γ_k disebut *Autocovariance Function* dan ρ_k disebut *Autocorrelation Function* (ACF).

Sifat-sifat *autocovariance function* memenuhi syarat :

1. $\gamma_0 = \text{Var}(Y_t)$ dan $\rho_0 = 1$
2. $|\gamma_k| \leq \gamma_0$ dan $|\rho_k| \leq 1$
3. $\gamma_k = \gamma_{-k}$ dan $\rho_k = \rho_{-k}$

(Wei, 2005)

2.1.2 Partial Autocorrelation Function (PACF)

Partial autocorrelation digunakan untuk menunjukkan hubungan nilai satu variabel yang sama dengan menganggap pengaruh dari semua kelambatan waktu lain adalah konstan. *Partial autocorrelation* dapat mengukur tingkat keeratan antara Y_t dan Y_{t+k} apabila pengaruh dari *time lag* $1, 2, \dots, (k-1)$ dianggap terpisah. *Partial autocorrelation* antara Y_t dan Y_{t+k} dinyatakan sebagai berikut

$$\phi_{kk} = \text{Corr}(Y_t, Y_{t+k} | Y_{t+1}, \dots, Y_{t+k-1}), \quad j = 1, 2, \dots, k \quad (2.4)$$

persamaan diatas dapat dinyatakan sebagai

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{k-1,j} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.5)$$

$$\text{dengan } \hat{\rho}_k = \begin{cases} \hat{\rho}_1 & \text{jika } k=1 \\ \frac{\hat{\rho}_k - \sum_{j=1}^k \hat{\rho}_{k-1,j} \hat{\rho}_{k-j}}{1 - \sum_{j=1}^k \hat{\rho}_{k-1,j} \hat{\rho}_{k-j}} & \text{jika } k=2,3,\dots \end{cases}$$

Sebagai fungsi dari k , ϕ_{kk} disebut *Partial Autocorrelation Function* (PACF)

(Makridakis, 1999)

2.1.3 Stasioneritas

Stasioneritas mempunyai makna bahwa tidak terdapat pertumbuhan atau penurunan pada data secara drastis. Dengan kata lain, fluktuasi data berada di sekitar suatu nilai *mean* yang konstan, tidak tergantung pada waktu dan *variance* dari fluktuasi tersebut (Makridakis, dkk., 1999). Plot *time series* dapat digunakan untuk mengetahui suatu data telah stasioner atau belum. Demikian juga plot ACF juga dapat memperlihatkan kestasioneritasan suatu *time series*. *Time series* dikatakan stasioner dalam *mean* jika *meannya* tidak berubah dari waktu ke waktu atau data bersifat stabil. Untuk melihat apakah suatu data sudah stasioner dalam *mean* dapat digunakan alat bantu plot *time series* dan plot ACF. Apabila suatu *time series* tidak stasioner berdasarkan *mean* maka dapat diatasi dengan melakukan *differencing* (pembeda). *Differencing* merupakan pengurangan data tertentu dengan data sebelumnya. Menurut Makridakis, dkk (1999) notasi yang sangat bermanfaat dalam metode *differencing* adalah operator *shift* mundur (*backward shift*) yang disimbolkan dengan B . Secara umum apabila terdapat *differencing* orde d untuk mencapai stasioneritas ditulis sebagai berikut:

$$Y_t^d = (1 - B)^d Y_t \quad (2.6)$$

dengan $B^l Y_t = Y_{t-l}$.

Suatu *time series* dikatakan stasioner dalam *variance*, jika plot *time series* tidak memperlihatkan adanya perubahan *variance* yang jelas dari waktu ke waktu (Makridakis, 1999). Begitu pula sebaliknya jika *time series* menunjukkan terdapat variasi fluktuasi data pada grafik maka data tersebut termasuk dalam *time series* yang belum stasioner berdasarkan *variance*. Untuk melihat suatu data stasioner atau belum dalam *variance* dapat menggunakan plot *time series* dan plot ACF.

Untuk menstasionerkan data yang belum stasioner dalam *variance* dapat dilakukan dengan proses transformasi. Secara umum, untuk mencapai stasioneritas dalam *variance* dapat dilakukan dengan *power transformation* (λ) yaitu (Wei, 2006):

$$T(Y_t) = \begin{cases} \frac{Y_t^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln Y_t, & \lambda = 0 \end{cases} \quad (2.7)$$

dengan λ adalah parameter transformasi. Secara umum, berikut adalah nilai dari λ beserta pendekatan transformasi yang digunakan (Wei, 2006).

Tabel 2.1 Transformasi Box-Cox

Nilai λ	Transformasi
-1	$1/Y_t$
-0,5	$1/\sqrt{Y_t}$
0	$\ln Y_t$
0,5	$\sqrt{Y_t}$
1	Y_t (stasioner)

Sumber: Wei, 2006

2.1.4 Uji Kestasioneran dengan Uji Augmented Dickey Fuller (ADF)

Uji ini merupakan salah satu uji yang sering digunakan dalam pengujian stasioneritas data, yakni dengan melihat apakah terdapat *unit root* dalam model atau tidak. Pengujian dilakukan dengan menguji hipotesis $H_0: \rho = 0$ (terdapat *unit root*) dalam persamaan:

$$Y_t = \alpha + \delta t + \rho Y_{t-1} + \sum_{j=1}^k \phi_j Y_{t-j} + e_t \quad (2.8)$$

Hipotesis nol ditolak jika nilai statistik uji ADF memiliki nilai kurang lebih negatif dibandingkan dengan nilai daerah kritis. Jika hipotesis nol ditolak, data bersifat stasioner.

2.1.5 Model Autoregressive Integrated Moving Average (ARIMA)

ARIMA sering disebut juga metode *time series* Box-Jenkins. Sedangkan model ARIMA merupakan model yang secara penuh mengabaikan variabel

independen dalam membuat peramalan. ARIMA menggunakan nilai masa lalu dan sekarang dari variabel dependen untuk menghasilkan peramalan *short memory* yang akurat dan cocok digunakan jika observasi dari *time series* saling berhubungan satu sama lain. Model Box-Jenkins ARIMA dibagi dalam tiga kelompok yaitu model *Autoregressive* (AR), model *Moving Average* (MA) dan model *Autoregressive Moving Average* (ARMA) yang mempunyai karakteristik dari dua model pertama. Bentuk umum untuk model ARMA(p, q) dapat dituliskan sebagai berikut:

$$\begin{aligned} X_t &= \mu + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \\ X_t - \phi_1 X_{t-1} - \phi_2 X_{t-2} - \dots - \phi_p X_{t-p} &= \mu + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \\ (1 - \phi_1 B - \dots - \phi_p B^p) X_t &= \mu + (1 - \theta_1 B - \dots - \theta_q B^q) e_t \end{aligned} \quad (2.9)$$

dengan

$$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$$

$$\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$$

Maka model tersebut dapat dituliskan sebagai berikut:

$$\phi_p(B) X_t = \mu + \theta_q(B) e_t \quad (2.10)$$

Apabila nonstasioneritas ditambahkan pada campuran proses ARMA maka menjadi model umum ARIMA(p, d, q). Jika dilakukan proses pembedaan dengan orde ke- d yakni $X_t^d = (1 - B)^d X_t$ sehingga X_1, X_2, \dots menjadi *time series* stasioner, maka model ARMA(p, q) pada X_t dinamakan model ARIMA(p, d, q).

Suatu proses ARIMA dapat digambarkan dengan dimensi p, d, q dengan :

p : orde dari proses *autoregressive*

d : orde dari *differencing*

q : orde dari proses *moving average*

Bentuk umum model ARIMA(p, d, q) adalah sebagai berikut

$$\phi_p(B)(1 - B)^d X_t = \mu + \theta_q(B) e_t \quad (2.11)$$

Parameter d menunjukkan bahwa proses tidak stasioner. Jadi apabila parameter $d=0$ maka proses telah stasioner. Namun dalam praktiknya jarang diperlukan pemakaian nilai p, d, q selain 0, 1 atau 2.

(Box dan Jenkins, 1994)

2.1.6 Diagnostic Checking

Dalam pemodelan *time series*, perlu dilakukan pengujian kesesuaian model (*goodness of fit*) agar dapat memperoleh model terbaik. Pengujian meliputi pengujian signifikansi terhadap parameter model dengan Uji-t, pengujian *white noise* terhadap residual dengan uji Ljung-Box, dan pengujian normalitas terhadap residual dengan uji Kolmogorov-Smirnov.

Uji Signifikansi Parameter dengan Uji-t

Secara umum jika $\hat{\theta}$ adalah nilai taksiran parameter dari θ untuk suatu model *time series* tertentu, dan $se(\hat{\theta})$ adalah taksiran *std error* dari nilai $\hat{\theta}$, maka uji signifikansi parameter dapat dilakukan dengan tahapan berikut:

1. Hipotesis

$$H_0 : \hat{\theta} = 0$$

$$H_1 : \hat{\theta} \neq 0$$

2. Statistik uji

$$t = \frac{\hat{\theta}}{se(\hat{\theta})} \quad (2.12)$$

3. Keputusan

Tolak H_0 jika $|t| > t_{\alpha/2, v}$ dengan $v = n - n_p$

dengan

n : jumlah data

n_p : jumlah parameter

Uji White Noise dengan Uji Ljung-Box

Time series dikatakan mengalami proses *white noise* jika *autocorrelation* antara deret X_t dan X_{t-k} untuk semua lag k mendekati nol, nilai antar lag pada deret tersebut tidak berkorelasi satu sama lain. Menurut Wei (1990) suatu proses

a_t disebut suatu proses *white noise* jika a_t merupakan barisan variabel acak yang tidak berkorelasi dari suatu distribusi dengan *mean* konstan $E(a_t) = \mu_0$ yang biasa diasumsikan nol, *variance* konstan $Var(a_t) = \sigma_a^2$, dan $\gamma_k = Cov(a_t, a_{t+k}) = 0$ untuk semua $k \neq 0$. Oleh karena itu, suatu proses *white noise* a_t adalah stasioner dengan *Autocovariance Function*

$$\gamma_k = \begin{cases} \sigma_a^2, & k = 0 \\ 0, & k \neq 0 \end{cases} \quad (2.13)$$

Autocorrelation Function

$$\rho_k = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases} \quad (2.14)$$

dan *Partial Autocorrelation Function*

$$\phi_{kk} = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases} \quad (2.15)$$

Statistik Q Box-Pierce dikembangkan oleh Ljung-Box dan digunakan untuk mengetahui apakah *autocorrelation* residualnya berbeda nyata dari nol. Untuk mengetahui apakah suatu deret memenuhi proses *white noise* maka dapat dilakukan dengan tahapan berikut:

1. Hipotesis

$H_0 : \rho_1 = \dots = \rho_k = 0$ (tidak terdapat *autocorrelation* yang signifikan pada residual)

$H_1 : \exists \rho_i \neq 0$ (terdapat *autocorrelation* yang signifikan pada residual)

2. Statistik uji

$$Q = n(n+2) \sum_{k=1}^m \frac{r_k^2}{n-k} \quad (2.16)$$

dengan

n : banyaknya observasi dalam *time series*

k : *lag* waktu

m : banyaknya *lag* yang diuji

r_k : koefisien *autocorrelation* pada periode ke- k

3. Keputusan

Tolak H_0 jika $Q \geq \chi^2_{\alpha, df}$

Jika *autocorrelation* dihitung dari proses *white noise* maka statistik uji Q mempunyai distribusi χ^2 dengan *degree of freedom* m (banyaknya lag yang diuji), sedangkan untuk residual dari model peramalan statistik uji Q mempunyai distribusi χ^2 dengan *degree of freedomnya* m dikurangi banyaknya parameter yang diestimasi dalam model.

(Hanke and Wichern, 1992)

Uji Normalitas dengan Uji *Kolmogorov Smirnov*

Pengujian normalitas dilakukan pada residu model *time series* yang diperoleh. Pengujian dapat dilakukan dengan tahapan berikut:

1. Hipotesis

$$H_0 : F(x) = F_0(x) \text{ (residual berdistribusi normal)}$$

$$H_1 : F(x) \neq F_0(x) \text{ (residual tidak berdistribusi normal)}$$

2. Statistik uji

$$D = \text{Sup} |S(x) - F_0(x)| \quad (2.17)$$

dengan

$S(x)$: fungsi *cumulative probability* yang dihitung dari data sampel

$F_0(x)$: fungsi *cumulative probability* dari distribusi normal

Sup : nilai supremum untuk semua x dari $|S(x) - F_0(x)|$

3. Keputusan

Tolak H_0 jika $D > D_{(1-\alpha), n}$

dengan

n : jumlah sampel

(Daniel, 1989)

2.2 Volatilitas

Volatilitas *clustering* adalah periode dimana data akan menunjukkan guncangan besar untuk periode waktu tertentu kemudian diikuti oleh periode lain yang keadaannya relatif tenang (Gujarati, 2004). Dengan kata lain, terjadi volatilitas yang tinggi pada periode tertentu sedangkan terjadi volatilitas yang rendah pada periode lainnya. Oleh karena itu volatilitas dapat mengakibatkan adanya efek heteroskedastisitas atau variansi yang tidak konstan. Jika pada residu model ARMA terdapat efek heteroskedastisitas, maka diperlukan model yang dapat mengatasi adanya efek heteroskedastisitas.

Pada model ARMA, variansi bersyarat σ_t^2 digunakan sebagai fungsi dari residu di masa lalu. Diberikan ψ_t yaitu himpunan semua informasi untuk ε_t dari waktu lampau sampai dengan waktu t dimana ε_t adalah residu dari model ARMA(p,q) pada waktu t . Proses ε_t dapat dituliskan sebagai berikut

$$\varepsilon_t = \sigma_t u_t \quad (2.18)$$

dengan

$$\sigma_t^2 = E(\varepsilon_t^2 | \psi_{t-1})$$

$$u_t \sim N(0,1)$$

$$\varepsilon_t | \psi_{t-1} \sim N(0, \sigma_t^2)$$

2.2.1 Uji Efek Heteroskedastisitas dengan Uji Lagrange

Engle (1982), uji efek heteroskedastisitas dapat dilakukan menggunakan uji pengali Lagrange dengan tahapan sebagai berikut

1. Hipotesis

$H_0 : \beta_1 = \beta_2 = \dots = \beta_m = 0$ (tidak terdapat efek heteroskedastisitas sampai lag ke- m)

H_1 : paling sedikit terdapat satu $\beta_i \neq 0$ untuk $i = 1, 2, \dots, m$ (terdapat efek heteroskedastisitas sampai lag ke- m)

2. Statistik uji

$$\xi = TR^2 \quad (2.19)$$

dengan

T : ukuran sampel

R^2 : koefisien determinansi

3. Keputusan

Tolak H_0 jika $\xi > \chi_k^2$ atau

$p-value < \alpha$

2.3 Agregasi Temporal

Agregasi temporal adalah proses yang diamati pada frekuensi yang lebih kecil dari yang dihasilkan pada proses sebenarnya. Misalkan m menunjukkan tingkat agregasi. Jika variabel agregasi adalah *stock variable*, maka diamati setiap periode ke- m sementara jika itu adalah *flow variable*, maka jumlahan dari ke- m dan $m-1$ periode sebelumnya diamati setiap periode ke- m . Variabel agregasi tersebut dapat didefinisikan sebagai berikut

a. Jika X_t^* adalah *stock variable*, maka $X_t = X_{mt}^*, t = 1, 2, \dots, T$.

b. Jika X_t^* adalah *flow variable*, maka $X_t = \sum_{i=0}^{m-1} X_{mt-i}^* = \sum_{i=0}^{m-1} B^i X_{mt}^*, t = 1, 2, \dots, T_x$,

$$T_x = T_{x^*}/n$$

Perbedaan antara keduanya adalah pada filter *moving average*

$\sum_{i=0}^{m-1} B^i = (1 + B + \dots + B^{m-1})$ diterapkan untuk X_t^* . Agregasi temporal sebagaimana

didefinisikan termasuk dalam Definisi 1a menyebabkan fenomena lain, dikenal dalam literatur pemrosesan sinyal untuk *continuous-time processes* diamati pada *discrete-time intervals*. Efek fenomena lain yang timbul dari menggabungkan proses *discrete-time* yaitu misalkan X_t^* adalah proses *discrete-time* stasioner

dalam kovarian dengan fungsi kepadatan spectral $f_x(\omega)$ dan

$X_t = \sum_{i=0}^{m-1} X_{mt-i}^* = \sum_{i=0}^{m-1} B^i X_{mt}^*$, maka fungsi kepadatan spektral X_t , $f_x(\lambda)$ diberikan

oleh

$$f_x(\lambda) = 2\pi \sum_{i=\frac{m-1}{2}}^{\frac{m-1}{2}} \left[F_m \left(\frac{\lambda}{m} + \frac{2i\pi}{m} \right) f_{x^*} \left(\frac{\lambda}{m} + \frac{2i\pi}{m} \right) \right], \quad -\pi < \lambda < \pi \quad (2.20)$$

Bentuk lain untuk kerapatan spectral X_t variabel agregat adalah :

$$f_x(\lambda) = \frac{\sigma_\varepsilon^2}{2m\pi} \sum_{i=0}^{m-1} \left[\left| 1 - e^{-j(\lambda+i2\pi)/m} \right|^{-2d} W(e^{-j(\lambda+i2\pi)/m}) W(e^{j(\lambda+i2\pi)/m}) \right] \quad (2.21)$$

dengan

$$W(B)\varepsilon_t = \sum_{i=0}^{\infty} w_i \varepsilon_{t-i}$$

Kepadatan spektral di atas adalah sifat penting yang membangun invariance dari parameter *long memory* untuk agregasi. Oleh karena itu, dapat ditunjukkan sifat-sifat berikut

- a. Jika X_t^* memenuhi sifat *long memory* stasioner dengan $d < 0,5$ maka agregat prosesnya X_t juga memenuhi sifat yang sama dengan integrasi yang sama.
- b. Jika X_t^* adalah kovarians stasioner dan memenuhi persamaan estimator GPH dengan $d > 0$ dan memiliki fungsi spektral yang terbatas dan dengan turunan pertama terbatas di lingkungan kelipatan nol dari frekuensi Nyquist ($2\pi/n$), maka X_t juga memenuhi sifat serupa dengan X_t^* dengan d integrasi urutan yang sama.
- c. Jika X_t^* memenuhi sifat estimator GPH dengan $d < 0$ dan memiliki fungsi spektral yang positif dan terbatas dan dengan turunan pertama terbatas di lingkungan kelipatan nol dari frekuensi Nyquist, maka X_t memenuhi sifat yang sama dengan urutan yang sama integrasi d jika X_t^* adalah *flow variable* tapi tidak jika X_t^* adalah *stock variable*.

2.4 *Markov Switching*

Model *Markov Switching* merupakan salah satu metode dalam menangani adanya “lompatan” model dari *regime* satu ke *regime* lainnya. Konsep *Markov Switching* diperkenalkan oleh Hamilton (1989), merupakan salah satu dari model *regime switching* yang paling populer. Model ini terbukti efektif diterapkan pada

nonlinear dynamic yang biasanya terjadi pada *time series* finansial ekonomi. Beberapa penelitian tentang model *Markov Switching* antara lain dilakukan oleh Kim (1994) dan Hamilton (1994). Fitur utama dari model ini adalah untuk memungkinkan proses *switch* ke *regime* yang berbeda dengan *transition probability* tertentu.

$$y_t = \mu_{S_t} + \sigma_{S_t} \varepsilon_t \quad (2.22)$$

Persamaan (2.22) adalah model dasar *Markov Switching* (Timmerman, 2000), dimana $\varepsilon_t \sim N(0, \sigma_{S_t}^2)$ dan $S_t = 1, 2, \dots, k$ menunjukkan indikator *state* yang *unobserved* (tidak teramati), dimana k -*state* mengikuti proses *Markov Ergodik* yang mengikuti persamaan (2.23) berikut. Model ini telah digunakan oleh Engel dan Hamilton (1990).

$$\text{Prob}(S_{t+j} = j | S_t = i, S_{t-1} = k, \dots) = \text{Prob}(S_{t+j} = j | S_t = i) = P_{ij} \quad (2.23)$$

dengan $0 \leq P_{ij} \leq 1$, $\sum_{j=1}^k P_{ij} = 1$, dan $i, j = 1, 2, \dots, k$ yang menunjukkan terdapat k

kemungkinan *state* atau *regime* yang berbeda dan matriks transisinya sebagai berikut.

$$P = \begin{bmatrix} P_{11} & P_{12} & \cdots & P_{1k} \\ P_{21} & P_{22} & \cdots & P_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ P_{k1} & P_{k2} & \cdots & P_{kk} \end{bmatrix} \quad (2.24)$$

Probabilitas perubahan dari satu *regime* ke *regime* yang lain dalam proses *Markov* disebut *transition probability*, ditampilkan dengan matriks diatas. k adalah jumlah keadaan dalam proses dan P_{ij} adalah *transition probability* dari *regime* saat i ke *regime* j . Jika saat ini berada pada *regime* i maka baris i dari matriks di atas berisi angka-angka $P_{i1}, P_{i2}, \dots, P_{ik}$ merupakan probabilitas perubahan ke *regime* berikutnya.

2.4.1 Uji Perubahan *Regime* dengan Uji CUSUM

Cumulative Sum Test (*CUSUM Test*) adalah sebuah pengujian yang dikembangkan oleh E. S. Page untuk mendeteksi perubahan dengan mengacu pada distribusi probabilitas. *CUSUM Test* melibatkan perhitungan

dari *cumulative sum* (jumlah kumulatif) sehingga menghasilkan data yang berurutan. Sampel dari sebuah proses y_t diberi bobot w_t . Untuk mendeteksi perubahan ke arah positif, rumus yang digunakan adalah

$$\begin{aligned} S_0 &= 0 \\ S_{t+1} &= \max(0, S_t + y_t - w_t) \end{aligned} \quad (2.25)$$

Ketika nilai S melebihi suatu batas tertentu, mengindikasikan adanya perubahan di dalam nilai S tersebut. Untuk mendeteksi perubahan ke arah negatif, rumus yang digunakan adalah

$$\begin{aligned} S_0 &= 0 \\ S_{t+1} &= \min(0, S_t + y_t - w_t) \end{aligned} \quad (2.26)$$

Ketika nilai S lebih rendah dari batas negatif, mengindikasikan adanya perubahan di dalam nilai S tersebut.

2.4.2 Estimasi Model *Markov Switching*

Pada Persamaan (2.22) dapat melihat *spurious long memory* (Kuswanto dan Sibbertsen, 2008), walaupun proses ARMA merupakan proses *short memory* dengan ACF yang turun membentuk pola geometrik, namun proses ARMA tertentu memiliki ACF yang turun secara lambat mengikuti proses *long memory*.

$$\begin{aligned} \phi_{p,S_t}(B)Y_t &= a_t \text{ untuk } t = 1, 2, \dots, n \\ y_t &= \mu_{S_t} + \phi_{1,S_t}y_{t-1} + \phi_{2,S_t}y_{t-2} + \dots + \phi_{p,S_t}y_{t-p} + a_t \end{aligned} \quad (2.27)$$

Pada model *Markov Switching* dengan proses $\text{AR}(p)$ yang dijelaskan oleh Zivot dan Wang (2006), dimana $\mathbf{X}_t = (y_{t-1}, y_{t-2}, \dots, y_{t-p})$ dan Φ_{S_t} adalah vektor koefisien AR berukuran $p \times 1$. Umumnya, jika *states* $\mathbf{S} = (S_{p+1}, \dots, S_n)$ diketahui, parameter Θ model *Markov Switching AR*(p) yang tidak diketahui dan memuat intersep, maka koefisien AR dan varians residual pada *regime* yang berbeda dapat diestimasi dengan memaksimalkan fungsi *log-likelihood*.

$$L(\Theta | \mathbf{S}) = \sum_{t=p+1}^n \log f(y_t | \Omega_{t-1}, S_t) \quad (2.28)$$

dimana Ω_{t-1} menunjukkan semua informasi yang tersedia pada waktu $t-1$ dan memuat semua observasi \mathbf{X}_t untuk $j \leq t$, dan

$$f(y_t | \Omega_{t-1}, S_t) \propto \exp\left(-\frac{1}{2} \log \sigma_{S_t}^2 - \frac{\left[y_t - (\mu_{S_t} + \mathbf{X}_t \Phi_{S_t})\right]^2}{2\sigma_{S_t}^2}\right) \quad (2.29)$$

states \mathbf{S} biasanya tidak terobservasi (tidak teramati) dan harus disimpulkan dari data. Ketika \mathbf{S} diketahui, parameter model *Markov Switching AR(p)* diperluas dengan mengikutkan *transition probability* P . Dengan mengaplikasikan hukum probabilitas total, fungsi *log-likelihood* dapat ditulis seperti pada persamaan (2.30).

$$\begin{aligned} L(\Theta) &= \sum_{t=p+1}^n \log f(y_t | \Omega_{t-1}) \\ &= \sum_{t=p+1}^n \log \left\{ \sum_{j=1}^k f(y_t | \Omega_{t-1}, S_t = j) P(S_t = j | \Omega_{t-1}) \right\} \end{aligned} \quad (2.30)$$

dimana $f(y_t | \Omega_{t-1}, S_t = j)$ sesuai dengan (2.27), dan dengan teorema *Bayes* diperoleh probabilitas prediksi $P(S_t = j | \Omega_{t-1})$ dapat ditunjukkan akan menjadi

$$\begin{aligned} P(S_t = j | \Omega_{t-1}) &= \sum_{i=1}^k P(S_t = j | S_{t-1} = i, \Omega_{t-1}) P(S_{t-1} = i | \Omega_{t-1}) \\ &= \sum_{i=1}^k \frac{f(y_{t-1} | \Omega_{t-2}, S_{t-1} = i) P(S_{t-1} = i | \Omega_{t-2})}{\sum_{m=1}^k f(y_{t-1} | \Omega_{t-2}, S_{t-1} = m) P(S_{t-1} = m | \Omega_{t-2})} P_{ij} \end{aligned} \quad (2.31)$$

Sehingga estimasi dari inisial probabilitas pada setiap *state* $P(S_{p+1} = i | \Omega_{t-2})$ untuk $i = 1, 2, \dots, k$ dan fungsi *log-likelihood* model *Markov Switching AR(p)* dapat dihitung secara iterasi berdasarkan (2.28) dan (2.29), sedangkan parameter Θ yang tidak diketahui dapat disetimasi dengan menggunakan *Maximum Likelihood Estimation* (MLE). Sebagaimana ditunjukkan dalam Hamilton (1990), estimasi *transition probability* diberikan oleh

$$\hat{P}_{ij} = \frac{\sum_{t=2}^n P(s_t = j, s_{t-1} = i | \Omega_n)}{\sum_{t=2}^n P(s_{t-1} = i | \Omega_n)} \quad (2.32)$$

Pada pembagian pengamatan berdasarkan *regime*, digunakan probabilitas *filtering* yang mana dirumuskan perhitungannya dalam Seidl (2012) sebagai

$$\hat{\xi}_{t|t} = \sum_{t=2}^n P(s_t = j | \Omega_n) = \frac{P(s_t = j | \Omega_n) f(y_t | s_t = j, \Omega_n)}{f(y_t | \Omega_n)} \quad (2.33)$$

Filtering probability adalah probabilitas *regime* yang diberikan jika *regime* terjadi pada waktu t diketahui dan termasuk dalam informasi himpunan Ω_t . Hamilton (1990) menganggap s_t adalah suatu variabel yang tidak teramat atau *missing*, sehingga estimasi parameter dilakukan dengan cara melakukan optimasi pada fungsi *likelihood* menggunakan algoritma *Expectation Maximization* (EM).

Salah satu metode optimasi yang digunakan dalam memaksimalkan fungsi *likelihood* yang mengandung data *missing* adalah algoritma *Expectation Maximization* (EM), algoritma EM memiliki dua tahapan, yaitu tahap “E” (Ekspektasi) dan tahap “M” (Memaksimumkan). Dimisalkan terdapat data pengamatan y yang memiliki data *missing* x . Data y disebut sebagai *incomplete dataset*, sedangkan *complete dataset* diberikan oleh $z = (y, x)$ dengan fungsi probabilitas densitas yaitu

$$f(z | \Phi) = f(y, x | \Phi) = f(y/x, \Phi) f(x | \Phi) \quad (2.34)$$

Sehingga fungsi *complete data likelihood* diberikan

$$L(\Phi | y, x) = \prod_{i=1}^n f(y_i, x_i | \Phi) = \prod_{i=1}^n f(y_i / x_i, \Phi) f(x_i | \Phi) \quad (2.35)$$

Tahap “E” dalam algoritma EM adalah menghitung *complete data likelihood* $L(\Phi | y, x)$, yaitu menghitung ekspektasi dari data *missing* dengan diketahui data yang ada (tidak *missing*). Berikut diberikan langkah-langkah dalam algoritma EM secara iteratif.

1. Menentukan nilai awal parameter $\hat{\Phi}_m$; $m = 0$.
2. Tahap “E” dilakukan dengan menghitung *complete data likelihood* dengan cara substitusi $\hat{\Phi}_m$ pada fungsi Q yaitu

$$Q(\hat{\Phi}_m) = E(L(\hat{\Phi}_m | y, x) | y) \quad (2.36)$$

3. Tahap “M” dilakukan dengan mengacu pada kondisi berikut

$$\frac{\partial Q(\hat{\Phi}_m)}{\partial \hat{\Phi}_m} = 0 \quad (2.37)$$

untuk mendapatkan nilai parameter baru $\hat{\Phi}_{m+1}$.

4. Menghitung selisih mutlak dari $\hat{\Phi}_m$ dan $\hat{\Phi}_{m+1}$.
5. Mengulangi langkah 2 ssampai 4 jika diperoleh $|\hat{\Phi}_m - \hat{\Phi}_{m+1}| > e$ dengan e adalah bilangan yang berukuran sangat kecil.

Terdapat beberapa kasus dimana langkah 3 tidak diperoleh dalam bentuk *close form* maka optimisasi secara numerik dapat dilakukan pada tahap “M”.

2.5 Model Regresi Probit

Model probit adalah model yang digunakan untuk melihat hubungan antara variabel respon yang bersifat kualitatif dan variabel-variabel prediktor yang bersifat kualitatif maupun kuantitatif. Model probit biner adalah model probit yang variabel responnya terdiri dari dua kategori yang dinotasikan dengan 1 (satu) untuk menggambarkan kejadian sukses dan 0 (nol) untuk menggambarkan kejadian gagal.

Model probit disebut juga model normit karena model probit menggunakan pendekatan *Cumulative Distribution Function* (CDF) distribusi normal dimana pendekatan CDF digunakan untuk mengatasi kelemahan pada *linear probability mode* (LPM). Kelemahan tersebut adalah kemungkinan dari nilai Y_i keluar dari *range* varabel respon biner. Model probit menggunakan asumsi bahwa probabilitas kejadian sukses bergantung pada *latent* atau variabel yang tidak dapat diobservasi dan terdapat nilai kritis pada variabel yang tidak teramati.

Menurut Greene (2012), variabel respon kualitatif Y berasal dari variabel respon yang tidak teramati Y^* , dengan model sebagai berikut

$$y^* = \beta^T \mathbf{x} + \varepsilon \quad (2.38)$$

dengan β merupakan vektor koefisien parameter yang dilambangkan sebagai $\beta = [\beta_0 \ \ \beta_1 \ \ \cdots \ \ \beta_p]$ dengan ukuran $(p+1) \times 1$ dan $\mathbf{x} = [1 \ \ x_1 \ \ \cdots \ \ x_p]$

merupakan variabel prediktor berukuran $(p+1) \times 1$, p adalah banyaknya variabel prediktor. Adalah asumsi ε dalam model probit berasumsi normal standar atau dapat dinotasikan $\varepsilon \sim N(0,1)$. Sehingga dari asumsi ε berdistribusi normal standar diperoleh $E(Y^*) = \beta^T \mathbf{x}$ dan $Var(Y^*) = 1$. Jadi, *Probability Distribution Function* (PDF) dari Y^* adalah sebagai berikut

$$f(y^*) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}(y^* - \beta^T \mathbf{x})^2\right) \quad (2.39)$$

variabel Y^* tidak bisa diamati, sehingga dalam pengkategorian variabel respon Y digunakan *threshold* tertentu, sebagai contoh digunakan γ . Pengkategorian variabel Y adalah sebagai berikut

$$Y = 0 \text{ jika } y^* \leq \gamma \text{ dan}$$

$$Y = 1 \text{ jika } y^* > \gamma$$

maka probabilitas gagal atau $q(\mathbf{x})$ dinotasikan $P(Y=0)$ adalah

$$\begin{aligned} P(Y=0 | \mathbf{X}) &= P(Y^* \leq \gamma) \\ &= P(\beta^T \mathbf{x} + \varepsilon \leq \gamma) \\ &= P(\varepsilon \leq \gamma - \beta^T \mathbf{x}) \\ &= \Phi(\gamma - \beta^T \mathbf{x}) \\ &= q(\mathbf{x}) \end{aligned} \quad (2.40)$$

dan probabilitas sukses atau $p(\mathbf{x})$ dinotasikan $P(Y=1)$ adalah

$$\begin{aligned} P(Y=1 | \mathbf{X}) &= P(Y^* > \gamma) \\ &= 1 - P(Y^* \leq \gamma) \\ &= 1 - P(\beta^T \mathbf{x} + \varepsilon \leq \gamma) \\ &= 1 - P(\varepsilon \leq \gamma - \beta^T \mathbf{x}) \\ &= 1 - \Phi(\gamma - \beta^T \mathbf{x}) \\ &= 1 - q(\mathbf{x}) \end{aligned} \quad (2.41)$$

dari persamaan (2.40) dan persamaan (2.39) diperoleh $p(\mathbf{x}) = 1 - q(\mathbf{x})$ sebagai model probit.

2.5.1 Uji Multikolinieritas dengan Nilai VIF

Multikolinieritas adalah suatu kondisi dimana korelasi linier tinggi antara variabel prediktor dalam model regresi. Multikolinieritas dapat meningkatkan varians dari estimasi parameter dan menghasilkan model dengan variabel tidak signifikan tetapi nilai R^2 tinggi. *Variance Inflation Factor* (VIF) digunakan untuk mengukur derajat multikolinieritas dengan rumus berikut (O'Brien, 2007).

$$VIF = \left(1 - R_j^2\right)^{-1} \quad (2.42)$$

dengan

R_j^2 : proporsi variabilitas antara x_j dengan variabel prediktor lain

Jika diperoleh nilai VIF lebih dari 10 maka terindikasi adanya multikolinieritas.

2.5.2 Estimasi Model Probit

Metode *Maximum Likelihood Estimation* (MLE) digunakan untuk melakukan estimasi parameter model probit biner karena model probit diketahui distribusinya (Greene, 2012). Metode MLE dalam estimasi parameter memiliki prinsip memaksimalkan fungsi *likelihood*. Langkah-langkah estimasi parameter model probit biner adalah sebagai berikut

- Menentukan n sampel random, misalnya diberikan Y_1, Y_2, \dots, Y_n adalah variabel random yang saling *Independent Identically Distribution* (IID).
- Membuat fungsi *likelihood* sebagai berikut (Casella dan Berger, 2002)

$$\begin{aligned} L(y|\theta) &= L(y_1, y_2, \dots, y_n | \theta) \\ &= \prod_{i=1}^n p(y_i | \theta) \end{aligned} \quad (2.43)$$

Variabel random dalam model probit biner berdistribusi $Bernoulli(1, p)$ sehingga diperoleh fungsi *likelihoodnya* adalah sebagai berikut

$$L(\beta) = \prod_{i=1}^n [p(\mathbf{x}_i)]^{y_i} [q(\mathbf{x}_i)]^{1-y_i} \quad (2.44)$$

- Melakukan transformasi ln terhadap fungsi *likelihood* pada persamaan (2.44) sehingga diperoleh persamaan sebagai berikut

$$\begin{aligned}
\ln L(\beta) &= \ln B \\
&= \ln \left(\prod_{i=1}^n [p(\mathbf{x}_i)]^{y_i} [q(\mathbf{x}_i)]^{1-y_i} \right) \\
&= \ln \left(\prod_{i=1}^n [p(\mathbf{x}_i)]^{y_i} [1-p(\mathbf{x}_i)]^{1-y_i} \right) \\
&= \sum_{i=1}^n (y_i \ln p(\mathbf{x}_i) + (1-y_i) \ln [1-p(\mathbf{x}_i)])
\end{aligned} \tag{2.45}$$

d. Memaksimumkan persamaan (2.44) dengan menurunkan terhadap parameter β dan disamadengarkan nol untuk mendapatkan estimasi β

$$\begin{aligned}
\frac{\partial \ln B}{\partial \beta} &= \frac{\partial}{\partial \beta} \left(\sum_{i=1}^n (y_i \ln [1 - \Phi(\gamma - \beta^T \mathbf{x})] + (1-y_i) \ln [\Phi(\gamma - \beta^T \mathbf{x})]) \right) \\
&= \sum_{i=1}^n \mathbf{x}_i \phi(\gamma - \beta^T \mathbf{x}) \left(\frac{y_i}{1 - \Phi(\gamma - \beta^T \mathbf{x})} - \frac{y_i - 1}{\Phi(\gamma - \beta^T \mathbf{x})} \right) = 0
\end{aligned} \tag{2.46}$$

Berdasarkan metode MLE dihasilkan bentuk yang tidak *closed form* maka digunakan metode iterasi *Newton Raphson* dengan langkah sebagai berikut

- Menentukan vektor $\mathbf{g}(\beta)$ yang merupakan turunan pertama fungsi *likelihood* terhadap parameter β dengan ukuran vektor $(p+1) \times 1$

$$\mathbf{g}(\beta) = \left[\frac{\partial \ln L(\beta)}{\partial \beta} \right] \tag{2.47}$$

- Menentukan matriks $\mathbf{H}(\beta)$ yang merupakan turunan kedua dari fungsi *likelihood* terhadap parameter β dengan ukuran matriks $(p+1) \times (p+1)$

$$\mathbf{H}(\beta) = \left[\frac{\partial^2 \ln L(\beta)}{\partial \beta \partial \beta^T} \right] \tag{2.48}$$

- Iterasi dilakukan dari $m=0$ sehingga pada saat iterasi ke- m diperoleh

$$\beta^{(m)} = \beta^{(m-1)} - \left(\left(\frac{\partial^2 \ln L(\beta)}{\partial \beta \partial \beta^T} \right)^{-1} \frac{\partial \ln L(\beta)}{\partial \beta} \right) \tag{2.49}$$

- Jika sudah konvergen atau $\|\beta^{(m)} - \beta^{(m-1)}\| \leq \delta$ dengan δ adalah bilangan yang sangat kecil, maka proses iterasi akan berhenti.

2.5.3 Uji Signifikansi Parameter Model Probit

Pengujian signifikansi parameter digunakan untuk menentukan variabel-variabel prediktor yang berpengaruh yang berpengaruh atau memiliki hubungan yang nyata (signifikan) dengan variabel respon dengan model probit biner. Langkah pertama dalam pengujian statistik adalah menentukan hipotesis penelitian. Pengujian signifikansi parameter dalam model probit biner dilakukan dalam dua bentuk pengujian sebagai berikut

- Pengujian signifikansi parameter secara serentak/simultan

Pengujian signifikansi parameter secara serentak adalah pengujian yang dilakukan untuk melihat pengaruh variabel prediktor secara keseluruhan. Adapun pengujian tersebut dapat dilakukan dengan tahapan sebagai berikut

- Hipotesis

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0$$

$$H_1 : \text{Paling sedikit ada satu } \beta_l \neq 0, \text{ dengan } l = 1, 2, \dots, p$$

- Statistik uji

$$G^2 = 2 \left[\ln L(\hat{\Omega}) - \ln L(\hat{\omega}) \right] \quad (2.50)$$

Statistik uji G^2 disebut juga *Likelihood Ratio Test* dengan

$L(\hat{\Omega}) = \prod_{i=1}^n [1 - \Phi(\gamma - \boldsymbol{\beta}^T \mathbf{x})]^{y_i} [\Phi(\gamma - \boldsymbol{\beta}^T \mathbf{x})]^{1-y_i}$ adalah fungsi *likelihood*

dibawah populasi dan $L(\hat{\omega}) = \prod_{i=1}^n [1 - \Phi(\gamma - \boldsymbol{\beta}_0)]^{y_i} [\Phi(\gamma - \boldsymbol{\beta}_0)]^{1-y_i}$ adalah

fungsii *likelihood* dibawah H_0 .

- Keputusan

Tolak H_0 jika $G^2 > \chi^2_{\alpha, df}$ atau

Tolak H_0 jika $p-value < \alpha$

dengan α adalah *degree of freedom* (df) yaitu banyaknya parameter.

- Pengujian signifikansi parameter secara parsial

Pengujian signifikansi parameter secara parsial adalah pengujian yang dilakukan untuk melihat pengaruh variabel prediktor secara parsial. Adapun pengujian tersebut dilakukan dengan tahapan sebagai berikut

1. Hipotesis

$$H_0 : \beta_l = 0$$

$$H_1 : \beta_l \neq 0 ; l = 1, 2, \dots, p$$

2. Statistik uji

$$W = \frac{\hat{\beta}_l}{se(\hat{\beta}_l)} \quad (2.51)$$

3. Keputusan

Tolak H_0 jika $|W| > Z_{\alpha/2}$ atau

Tolak H_0 jika $p-value < \alpha$

dengan α adalah *degree of freedom* (df) yaitu banyaknya parameter.

2.5.4 Ketepatan klasifikasi

Prosedur klasifikasi adalah suatu evaluasi untuk melihat peluang kesalahan klasifikasi yang dilakukan oleh suatu fungsi klasifikasi dengan menggunakan ukuran *Apparent Error Rate* (APPER), yaitu nilai proporsi sampel yang salah atau tidak tepat diklasifikasikan oleh fungsi klasifikasi.

Tabel 2.2 Ketepatan Klasifikasi

Hasil Observasi	Prediksi	
	y_1	y_2
y_1	n_{11}	n_{12}
y_2	n_{21}	n_{22}

Keterangan :

y_i : variabel respon, $i = (1, 2, \dots)$

$n_{ij} (i = j)$: jumlah subjek dari y_i yang tepat diklasifikasikan sebagai y_i

$n_{ij} (i \neq j)$: jumlah subjek dari y_i yang salah diklasifikasikan sebagai y_i

Nilai APPER dan ketepatan klasifikasi diperoleh dengan persamaan berikut.

$$\text{APPER} = \frac{n_{12} + n_{21}}{n_{11} + n_{12} + n_{21} + n_{22}} \quad (2.52)$$

$$\text{Ketepatan Klasifikasi} = 100\% - (\text{APPER} \times 100\%) \quad (2.53)$$

2.6 Long Memory

Konsep *long memory* diperkenalkan oleh Granger dan Joyeux (1980). Untuk banyak proses *time series*, Granger dan Joyeux menyimpulkan bahwa *Spectral Density Function* dari proses diferensiasi dibedakan menjad *over* diferensiasi ketika level deret menunjukkan ketergantungan *long memory* yang tidak konsisten dengan stasioneritas *Autoregressive Moving Average* dinamis. Pendekatannya menggunakan *fractional differencing* yang menghasilkan serangkaian *Autoregressive Moving Average* stasioner. *Long memory* ditandai dengan ACF yang turun lambat secara hiperbolik untuk *lag* yang semakin besar. Sebaliknya ACF dari proses *short memory* turun secara eksponensial (Iglesias, Jorquera, dan Parma, 2005).

2.6.1 Fractional Integration

Didefinisikan proses berikut

$$(1-B)^d Y_t = \varepsilon_t \quad (2.54)$$

dengan $|B| \leq 1$ dan $\varepsilon_t \sim \text{whitenoise}(0, \sigma_\varepsilon^2)$. Jika proses tersebut stasioner maka dapat dituliskan sebagai berikut

$$Y_t = (1-B)^{-d} \varepsilon_t \quad (2.55)$$

Dari serangkaian ekspansi *taylor*, kita memiliki rumus binomial umum

$$(1-B)^{-d} = \sum_{j=0}^{\infty} \binom{-d}{j} (-B^j) = \sum_{j=0}^{\infty} \psi_j B^j \quad (2.56)$$

$$Y_t = \sum_{j=0}^{\infty} \psi_j B^j \varepsilon_t \quad (2.57)$$

dengan $\psi_j = \frac{\Gamma(j+d)}{\Gamma(j+1)\Gamma(d)}$ dan $\Gamma(x) = \sqrt{2\pi} e^{-x} x^{x-\frac{1}{2}}$, $x \rightarrow \infty$

Kita peroleh

$$\psi_j = \frac{\Gamma(j+d)}{\Gamma(j+1)\Gamma(d)} \approx \frac{1}{\Gamma(d)} \frac{\sqrt{2\pi} e^{-j-d} (j+d)^{j+d-\frac{1}{2}}}{\sqrt{2\pi} e^{-j-1} (j+1)^{j+1-\frac{1}{2}}} \approx \frac{1}{\Gamma(d) j^{1-d}} \quad (2.58)$$

$\{\psi_j\}$ adalah *square summable* jika dan hanya jika $2(1-d) > 1$, $d < 0,5$. Dengan cara yang sama dapat diketahui bahwa proses *invertible* jika dan hanya jika

$d > -0,5$. Dengan demikian pada persamaan (2.10) adalah proses stasioner dan *invertible* jika dan hanya jika $-0,5 < d < 0,5$ yang disebut sebagai *Fractional Integration* (Wei, 2006).

Menurut Hosking (1981), karakteristik deret dengan *Fractional Integration* untuk berbagai nilai d adalah :

1. $-0,5 < d < 0,5$ menyatakan proses *long memory* yang tidak stasioner
2. $0 < d < 0,5$ menyatakan proses *long memory* yang stationer dengan adanya ketergantungan positif antar pengamatan yang terpisah jauh yang ditunjukkan dengan *autocorrelation* positif dan turun lambat dan mempunyai representasi *Moving Average* orde tak hingga
3. $-0,5 < d < 0$ menyatakan proses *short memory* yang stasioner dengan adanya ketergantungan negatif yang ditandai dengan *autocorrelation* negatif dan turun lambat serta mempunyai representasi *Autoregressive* orde tak hingga
4. $d = 0$ menyatakan proses *short memory*

Pada deret *noise fractional integrated*, terdapat *Spectral Density Function* sebagai berikut

$$f(\omega) = \frac{\sigma^2}{2\pi} \left(2 \sin\left(\frac{\omega}{2}\right) \right)^{-2d}, \quad -\pi \leq \omega \leq \pi \quad (2.59)$$

Sehingga diperoleh *Autocovariance Function* dan *Autocorrelation Function* sebagai berikut

$$\gamma_k = (-1)^k \sigma^2 \frac{\Gamma(1-2d)}{\Gamma(k-d+1)\Gamma(1-d-k)} \quad (2.60)$$

$$\rho_k = \frac{\Gamma(1-d)\Gamma(k+d)}{\Gamma(k-d+1)\Gamma(d)} \sim c(k)^{2d-1} \quad (2.61)$$

Selain itu fungsi *long memory* dapat dilihat berdasarkan plot periodogram. Bentuk periodogram sebagai berikut

$$I_z(\omega_j) = \frac{1}{2\pi} \left\{ \gamma_0 + 2 \sum_{t=1}^{T-1} \gamma_t \cos(t\omega_j) \right\}, \quad \omega_j \in (-\pi, \pi) \quad (2.62)$$

2.6.2 Fractional Cointegration

Konsep *Fractional Cointegration* diperkenalkan oleh Granger (1980) yaitu dimana terdapat deret y_t dan x_{it} dengan $i=1,2,\dots,p$ yang merupakan proses $I(d)$ sehingga kombinasi linear dari deret y_t dan x_{it} dapat dituliskan sebagai berikut

$$y_t = \beta_1 x_{1t} + \beta_2 x_{2t} + \dots + \beta_p x_{pt} + u_t \quad (2.63)$$

Jika u_t merupakan proses $I(d-b)$ dengan $b > 0$ dan $0 < b < d$ maka disebut *Fractional Cointegration* dimana menunjukkan bahwa deret y_t dan x_{it} memiliki sifat *long memory* pada periode waktu yang tidak berjauhan. Analisis pada model ini yaitu menggunakan analisis pada model *Fractional Integrated* yang dilakukan pada deret u_t yaitu residu hasil kombinasi linear dari deret y_t dan x_{it} .

(Maddala dan Kim, 1998)

2.6.3 Uji Cointegration pada Model Menggunakan Uji ADF

Lebih dari satu deret dikatakan *cointegrated* yaitu jika residual dari kombinasi linear deret-deret tersebut merupakan proses *long memory*. Berdasarkan persamaan (2.64), residual dari kombinasi linear dari $(p+1)$ deret dapat dituliskan sebagai berikut

$$u_t = y_t - \beta_1 x_{1t} + \beta_2 x_{2t} + \dots + \beta_p x_{pt} \quad (2.64)$$

dimana vektor $\tilde{\beta}' = [1 \ \beta_1 \ \dots \ \beta_p]$ merupakan vektor *cointegration* yang selanjutnya akan diestimasi. Dalam Maddala dan Kim (1998), deret $y_t, x_{1t}, \dots, x_{pt}$ memiliki hubungan *cointegration* maka u_t tidak memiliki akar *unit root*, dan sebaliknya. Maka pengujian adanya hubungan *cointegration* dapat dilakukan dengan melakukan uji adanya *unit root* pada u_t yaitu dengan menggunakan Uji *Augmented Dickey Fuller* (ADF). Uji ADF dilakukan dengan hipotesis sebagai berikut

$H_0: \rho = 0$ (terdapat *unit root* dan tidak terdapat hubungan *cointegration*)

$H_1: \rho \neq 0$ (tidak terdapat *unit root* dan terdapat hubungan *cointegration*)

Selanjutnya pengujian dilakukan sesuai subbab 2.1.4.

2.6.4 Estimasi Parameter *Fractional Cointegration*

Pada estimasi vektor *cointegration* pada persamaan (2.64), Aloy (2010) menggunakan metode *least square* sehingga diperoleh estimator dari β yaitu $\hat{\beta}$ sebagai berikut

$$\hat{\beta} = \left(\sum_{t=1}^T x_t x_t' \right)^{-1} \sum_{t=1}^T x_t y_t \quad (2.65)$$

Sehingga diperoleh

$$\hat{u}_t = y_t - \hat{\beta}_1 x_{1t} + \hat{\beta}_2 x_{2t} + \dots + \hat{\beta}_p x_{pt} \quad (2.66)$$

Selanjutnya dilakukan estimasi parameter *fractional integration* pada \hat{u}_t .

Pada proses ARFIMA pada persamaan (2.66), dengan menjadikan $W_t = (1-B)^d u_t$ serta menjadikan $f_w(\omega)$ dan $f_u(\omega)$ sebagai *spectral density function* dari W_t dan u_t , kemudian

$$f_u(\omega) = |1 - e^{-i\omega}|^{-2d} f_w(\omega) \quad (2.67)$$

dimana $f_u(\omega) \rightarrow \infty$ ketika $\omega \rightarrow \infty$ dan

$$f_w(\omega) = \frac{\sigma_\alpha^2}{2\pi} \left| \frac{\theta_q(e^{-iw})}{\phi_p(e^{-iw})} \right|^2 \quad (2.68)$$

adalah *spectral density* dari model ARMA(p, q).

Dengan mengambil logaritma natural dari kedua sisi (2.68), diperoleh

$$\begin{aligned} \ln f_u(\omega) &= d \ln |1 - e^{-i\omega}|^{-2} + \ln f_w(\omega) \\ &= \ln f_w(0) + \ln |1 - e^{-i\omega}|^{-2} + \ln \left(\frac{f_w(\omega)}{f_w(0)} \right) \end{aligned} \quad (2.69)$$

dengan mengganti ω dengan frekuensi Fourier, yaitu $\omega_j = 2\pi j/T$, $j = 1, \dots, [T/2]$, dan menambahkan $\ln I_u(\omega_j)$, periodogram dari u_t , dimana

$$I_u(\omega_j) = \frac{1}{2\pi T} \left| \sum_{t=1}^T u_t \exp(i\omega_j t) \right|^2 \quad (2.70)$$

sehingga pada edua sisi (2.70) menjadi

$$\ln f_u(\omega) = \ln f_w(0) + \ln |1 - e^{-i\omega j}|^{-2} + \ln \left(\frac{f_w(\omega)}{\ln f_w(0)} \right) + \ln \left(\frac{I_u(\omega_j)}{\ln f_u(\omega_j)} \right) \quad (2.71)$$

untuk ω_j dekat dengan nol, untuk $j=1,\dots,m \ll (T/2)$ sedemikian hingga

$m/T \rightarrow 0$ maka $T \rightarrow \infty$, diperoleh $\ln(f_w(\omega_j)/f_w(0)) \approx 0$. Sehingga

$$u_j = c + dZ_j + e_j \quad j=1,\dots,m \quad (2.72)$$

dimana $u_j = \ln I_u(\omega_j)$, $c = \ln f_w(0)$, $Z_j = \ln |1 - e^{-i\omega j}|^{-2}$, dan

$e_j = \ln(I_u(\omega_j)/f_u(\omega_j))$. Deret $(I_u(\omega_j)/f_u(\omega_j))$ dan Karena itu e_j adalah secara aproksimasi merupakan variabel random yang IID untuk perhitungan, karena

$$\begin{aligned} |1 - e^{-i\omega j}|^2 &= \left| \frac{2ie^{-\frac{i\omega}{2}} \left(e^{\frac{i\omega}{2}} - e^{-\frac{i\omega}{2}} \right)}{2i} \right|^2 \\ &= \left[2 \sin\left(\frac{\omega}{2}\right) \right]^2 \end{aligned} \quad (2.73)$$

diperoleh

$$Z_j = \ln \left| \frac{1}{4 \left[\sin\left(\frac{\omega_j}{2}\right) \right]^2} \right| \quad (2.74)$$

Estimator *least square* untuk d diberikan oleh

$$\hat{d} = \frac{\sum_{j=1}^m (Z_j - \bar{Z})(Y_j - \bar{Y})}{\sum_{j=1}^m (Z_j - \bar{Z})^2} \quad (2.75)$$

dengan $\hat{d} \xrightarrow{d} N\left(d, \frac{\pi^2}{6 \sum_{j=1}^m (Z_j - \bar{Z})^2}\right)$ sehingga diperoleh selang kepercayaan sebesar $(1-\alpha)\%$ untuk d sebagai berikut

$$\hat{d} \pm Z_{(1-\alpha)} \sqrt{\frac{\pi^2}{6 \sum_{j=1}^m (Z_j - \bar{Z})^2}} \quad (2.76)$$

2.7 Kriteria Kebaikan Model

Berdasarkan hasil pemodelan beberapa model yang telah dibentuk, terdapat banyak kemungkinan model untuk menggambarkan proses yang terjadi dalam data. Oleh sebab itu, selanjutnya dilakukan pemilihan model terbaik dari kemungkinan-kemungkinan model yang terbentuk. Terdapat banyak metode untuk menentukan model terbaik. Berdasarkan residual data *in sample*, dalam menentukan model terbaik salah satu di antaranya dapat menggunakan nilai minimum dari AIC (*Akaike's Information Criterion*) yang dijelaskan sebagai berikut (Wei, 2006).

$$AIC(M) = n \ln \hat{\sigma}_a^2 + 2M \quad (2.77)$$

dengan M adalah jumlah parameter di dalam model yang dan n adalah jumlah data sampel. AIC sesuai jika digunakan sebagai kriteria kebaikan model dengan jumlah *sample* yang besar. Kelebihan dari AIC yaitu dapat menjelaskan kecocokan model terhadap data yang digunakan untuk membuat model dan data pada masa depan (*forecast*) sehingga AIC baik digunakan untuk tujuan *forecasting*. Burnham dan Anderson (2004) dan Vrieze (2012) telah membuktikan kelebihan penggunaan AIC sebagai kriteria kebaikan model dibandingkan dengan kriteria lain melalui studi simulasi.

2.8 Inflation Targeting Framework

Inflation Targeting Framework atau lebih dikenal sebagai ITF merupakan salah satu strategi kebijakan moneter yang ditandai dengan pengumuman kepada

publik mengenai target kuantitatif (kisaran target) dari tingkat inflasi yang hendak dicapai dalam beberapa periode ke depan, serta adanya pernyataan secara eksplisit bahwa inflasi yang rendah dan stabil merupakan tujuan jangka panjang yang utama dari kebijakan moneter. Keutamaan dari ITF adalah adanya komunikasi kepada masyarakat mengenai rencana dan tujuan dari kebijakan moneter, dan bahkan untuk beberapa negara, komunikasi juga menyangkut mengenai mekanisme dalam mencapai tujuan dari kebijakan moneter itu sendiri juga dilakukan. ITF merupakan kerangka kerja kebijakan moneter yang relatif baru digunakan dan pada awalnya lebih banyak diadopsi oleh negara-negara berbasis industri. Selandia Baru menjadi negara yang pertama kali menerapkan kerangka kerja kebijakan moneter ini pada tahun 1990. Dalam perkembangannya, ITF semakin mendapatkan perhatian dari negara-negara lain yang menghadapi masalah dalam penerapan kebijakan moneter. Untuk saat ini, tidak kurang dari 42 negara, baik negara maju maupun negara berkembang telah menerapkan ITF sebagai strategi kebijakan mereka.

Sebagaimana kerangka kebijakan moneter lainnya, ITF mempunyai keunggulan dan kelemahan serta akan memberikan hasil yang optimal apabila diterapkan pada kondisi yang tepat. Keunggulan dari penerapan ITF antara lain sebagai berikut.

1. Sukses dalam membantu negara menurunkan inflasi
2. Tidak tergantung pada kestabilan hubungan antara uang dan inflasi.
3. Kebijakan moneter lebih fokus
4. Mengarahkan tugas bank sentral dalam jangka panjang.
5. Komunikasi, transparansi, dan akuntabilitas diperkuat secara bersama-sama
6. Membantu dalam menurunkan dan mengarahkan ekspektasi inflasi dan lebih baik dalam mengatasi kejutan inflasi.
7. Membantu dalam menurunkan volatilitas output dalam jangka menengah
8. Teruji terhadap kejutan ekonomi yang kurang menguntungkan
9. Kebijakan moneter relatif fleksibel dalam mengakomodasi kejutan inflasi sementara yang tidak mengganggu pencapaian sasaran inflasi jangka menengah

10. Independensi bank sentral dalam melaksanakan kebijakan moneter diperkuat

Selain keunggulan-keunggulan yang dimiliki, penerapan ITF juga memiliki beberapa kelemahan sebagai berikut.

1. Penggunaan tingkat inflasi sebagai target akan membuat kebijakan moneter menjadi terlalu kaku (*rigid*).
2. Tingkat inflasi tidak mudah untuk dikontrol.
3. Penerapan ITF tidak dapat mencegah adanya dominasi sektor fiskal.
4. Penerapan ITF mensyaratkan adanya nilai tukar yang fleksibel, dan sehingga memicu terjadinya ketidakstabilan sistem keuangan pada negara-negara yang baru berkembang.
5. Sinyal yang tidak langsung terhadap pencapaian target.
6. Goncangan (*shock*) pada harga-harga yang akan menyebabkan tingkat inflasi meningkat.
7. Kebijakan moneter melalui ITF baru dapat dirasakan hasilnya setelah ada *lag* yang cukup lama dan bervariasi dengan dipengaruhi oleh kondisi ekonomi yang dihadapi.
8. Kestabilan harga dan pertumbuhan ekonomi juga dipengaruhi oleh kebijakan fiskal dan mekanisme pembentukan harga.

Variabel-variable ekonomi yang diketahui dipengaruhi oleh diberlakukannya kebijakan *Inflation Targeting Framework* adalah sebagai berikut

2.8.1 Gross Domestic Product

Dalam perekonomian suatu negara terdapat suatu indikator yang digunakan untuk menilai apakah perekonomian berlangsung dengan baik atau buruk. Indikator dalam menilai perekonomian tersebut harus dapat digunakan untuk mengetahui total pendapatan yang diperoleh semua orang dalam perekonomian. Beberapa indikator tersebut yaitu *Gross Domestic Product* (GDP), *Gross National Product* (GNP), *Net National Product* (NNP), dan lain-lain. GDP mempunyai fungsi sebagai alat pengukur jumlah *output* produksi yang ada di dalam negeri baik itu produksi yang dihasilkan warga negara tersebut maupun warga negara asing. Sementara GNP mempunyai fungsi sebagai alat pengukur jumlah *output* produksi perekonomian nasional yang dimiliki warga negara

tersebut baik yang berada dalam negeri atau luar negeri. Sedangkan NNP mempunyai fungsi sebagai alat pengukur jumlah *output* produksi perekonomian nasional tanpa memperhitungkan modal sehingga umumnya NNP bersifat taksiran. Indikator yang pas dan sesuai dalam melakukan pengukuran pertumbuhan ekonomi sekaligus dalam mengevaluasi suatu kebijakan yang diberlakukan di suatu negara adalah *Gross Domestic Product* (GDP). Pengertian dari GDP adalah nilai pasar dari semua barang dan jasa akhir yang diproduksi dalam sebuah negara pada suatu periode. GDP merupakan statistika perekonomian yang paling diperhatikan karena dianggap sebagai ukuran tunggal terbaik mengenai kesejahteraan masyarakat. Hal yang mendasarinya karena GDP mengukur dua hal pada saat bersamaan: total pendapatan semua orang dalam perekonomian dan total pembelanjaan negara untuk membeli barang dan jasa hasil dari perekonomian. Alasan GDP dapat melakukan pengukuran total pendapatan dan pengeluaran dikarenakan untuk suatu perekonomian secara keseluruhan, pendapatan pasti sama dengan pengeluaran (Mankiw, 2006). Kita dapat menghitung GDP perekonomian dengan menggunakan salah satu dari dua cara: menambahkan semua pengeluaran rumah tangga atau menambahkan semua pendapatan (upah, sewa dan keuntungan) yang dibayar perusahaan. Dalam hal pengukuran, GDP mencoba menjadi ukuran yang meliputi banyak hal, termasuk di dalamnya adalah barang-barang yang diproduksi dalam perekonomian dan dijual secara legal di pasaran. GDP mengukur nilai produksi dalam batas geografis sebuah negara. GDP mengukur nilai produksi yang terjadi sepanjang suatu interval waktu. GDP mengukur aliran pendapatan dan pengeluaran dalam perekonomian selama interval tersebut.

Pada bahasan yang terakhir, yaitu hubungan GDP dengan kesejahteraan dapat dijelaskan sebagai berikut. GDP dapat mengukur total pendapatan maupun total pengeluaran perekonomian untuk barang dan jasa. Jadi, GDP per orang (kapita) memberi tahu kita pendapatan dan pengeluaran dari rata – rata seseorang dalam perekonomian. Karena kebanyakan orang lebih memilih pendapatan dan pengeluaran yang lebih tinggi, GDP per orang (kapita) sepertinya merupakan ukuran kesejahteraan rata – rata perorangan yang cukup alamiah. Pada akhirnya,

kita dapat menyimpulkan bahwa GDP merupakan ukuran kesejahteraan yang baik untuk berbagai tujuan, namun tidak untuk semua tujuan (Mankiw, 2006).

2.8.2 Money Supply

Money supply bergantung pada basis moneter, rasio deposito-cadangan dan rasio deposito-uang kartal. Kenaikan basis moneter memicu kenaikan proporsional *money supply*. Penurunan rasio deposito-cadangan atau rasio deposito-uang kartal meningkatkan pengganda uang dalam *money supply*. Uang adalah persediaan aset digunakan untuk transaksi, daya beli dan mempengaruhi harga barang. Uang dalam arti sempit (*narrow money*) adalah uang kartal ditambah uang giral (dilambangkan dengan M1), yang bersifat likuid.

$$M1 = C + DD \quad (2.78)$$

dengan

C : uang kartal yaitu uang kertas dan uang logam (*currency*)

DD : uang giral yaitu saldo rekening koran atau giro (*demand deposits*)

Perluasan dari M1 disebut uang dalam arti luas (*broad money*) yaitu M1 ditambah deposito berjangka dan saldo tabungan masyarakat dilambangkan sebagai M2.

$$M2 = M1 + TD + SD \quad (2.79)$$

dengan

TD : deposito berjangka (*time deposits*)

SD : saldo tabungan (*savings deposits*)

Uang sebagai penyimpan nilai, unit hitung dan media pertukaran. Penyimpan nilai (*store of value*) diharapkan membelanjakan uang mendapatkan barang dan jasa. Sebagai unit hitung (*unit of account*) ukuran penetapan harga. Media pertukaran (*medium of exchange*) untuk membeli barang dan jasa. Bank sentral mengendalikan *money supply* dengan mengubah basis moneter maupun rasio deposito-cadangan. Instrumen pengendalian yaitu operasi pasar terbuka (*open market operations*) membeli dan menjual obligasi pemerintah, persyaratan cadangan (*reserve requirements*) menuntut bank memiliki cadangan minimum dan tingkat diskonto (*discount rate*) yakni tingkat bunga pinjaman bank sentral (Mankiw, 2007).

2.8.3 Inflation

Inflation merupakan suatu keadaan ekonomi dimana tingkat harga dan biaya umum naik. *Inflation* juga merupakan keadaan ekonomi yang tidak lepas dari adanya gejolak ekonomi yang sedang terjadi disuatu negara (Junaiddin, 2008). Keadaan ekonomi yang ditandai dengan kenaikan harga secara cepat sehingga berdampak luas pada menurunya daya beli masyarakat (Ahmad, 2012). Menurut Irham (2012) berdasarkan skala penilaian *inflation*, ada empat kategori yang biasa dipakai :

- a. *Creeping inflation* : kondisi dimana skala *inflation* $<10\%$ per tahun
- b. *Moderate inflation* : kondisi dimana skala *inflation* $10-30\%$ per tahun
- c. *High inflation* : kondisi dimana skala *inflation* $30-100\%$ per tahun
- d. *Hyper inflation* : kondisi dimana skala *inflation* $>100\%$ per tahun

Menurut Afran dan Bambang (2008) *inflation* dapat didefinisikan sangat sederhana sebagai kenaikan dalam tingkatan harga rata-rata untuk semua barang dan jasa-jasa yang dihasilkan dalam suatu perekonomian. Efek *inflation* terhadap pendapatan sifatnya tidak merata, ada yang dirugikan dan ada pula yang diuntungkan dengan adanya *inflasi*. Seseorang yang memperoleh pendapatan tetap akan dirugikan oleh adanya *inflasi*. Sebaliknya, pihak-pihak yang mendapat keuntungan dengan adanya *inflation* adalah mereka yang memperoleh kenaikan pendapatan dengan persentase yang lebih besar dari laju *inflation*. *Inflation* dapat pula mengubah pola alokasi faktor-faktor produksi. Perubahan ini dapat terjadi melalui kenaikan permintaan akan berbagai macam barang yang kemudian dapat mendorong terjadinya perubahan dalam produksi beberapa barang tertentu sehingga mengakibatkan alokasi faktor produksi menjadi tidak efisien. *Inflation* yang tinggi tingkatnya tidak akan menggalakkan perkembangan ekonomi. Biaya yang terus menerus naik menyebabkan kegiatan produktif sangat tidak menguntungkan. Maka pemilik modal biasanya lebih suka menggunakan uangnya untuk tujuan spekulasi. Antara lain tujuan ini dicapai dengan pembeli harta-harta tetap seperti tanah, rumah dan bangunan. Efek dari *inflation* tersebut akan berpengaruh pada pertumbuhan ekonomi.

2.8.4 Interest Rate

Interest adalah pembayaran yang dilakukan untuk penggunaan uang. *Interest* adalah jumlah *interest* yang dibayarkan per unit waktu yang disebut sebagai persentase dari jumlah yang dipinjamkan. Dengan kata lain, orang harus membayar kesempatan untuk meminjam uang. Biaya peminjaman uang, diukur dalam dollar per tahun per dollar yang dipinjam, adalah *interest* (Samuelson dan Nordhaus, 2004). Menurut Case dan Fair (2004), *interest rate* adalah pembayaran *interest* tahunan atas suatu pinjaman yang dinyatakan sebagai persentase pinjaman. Besarnya sama dengan jumlah *interest* yang diterima per tahun dibagi jumlah pinjaman. *Interest rate* sangat berpengaruh dalam aktifitas perekonomian suatu negara. *Interest rate* dapat berpengaruh terhadap tingkat investasi, *money supply*, *inflation*, *obligation*, yang pada akhirnya akan berpengaruh pada pertumbuhan ekonomi negara tersebut. Selain itu *interest rate* merupakan faktor yang penting dalam perekonomian suatu negara karena sangat berpengaruh terhadap tingkat kesehatan perekonomian negara tersebut. Hal ini tidak hanya mempengaruhi keinginan konsumen untuk membelanjakan ataupun menabungkan uangnya, tetapi juga mempengaruhi dunia usaha dalam mengambil keputusan. Oleh karena itu *interest rate* mempunyai pengaruh yang sangat luas tidak hanya pada sektor moneter tetapi juga pada sektor riil, sektor ketenagakerjaan, bahkan sektor internasional. Secara teoritis terdapat dua jalur utama mekanisme transmisi kebijakan moneter, yaitu melalui *money supply* (*quantity targeting*) dan jalur harga melalui *interest rate* (*price targeting*). Dalam kenyataannya terdapat banyak macam *interest rate*. *Interest rate* berbeda terutama dalam hal karakteristik dari pinjaman atau peminjam. Pinjaman dibedakan atas jangka waktu atau jatuh temponya. Sekuritas jangka panjang banyak yang memiliki *interest rate* lebih tinggi dari jangka pendek karena pemberi pinjaman mau mengorbankan akses cepat ke dana mereka hanya jika mereka dapat meningkatkan penghasilan mereka.

2.8.5 Exchange Rate

Mata uang yang dipergunakan mempunyai harga tertentu dalam mata uang negara lain untuk dapat digunakan dalam kegiatan ekonomi. Harga tersebut menggambarkan berapa banyak suatu mata uang harus dipertukarkan untuk memeroleh satu unit mata uang lain. Istilah dari rasio pertukaran ini adalah

exchange rate. *Exchange rate* merupakan suatu perbandingan antar nilai tukar mata uang suatu negara dibandingkan dengan mata uang negara lain atau tingkat harga yang disepakati penduduk kedua negara untuk melakukan perdagangan (Saunders, 2000). Sedangkan menurut Madura (2006), *exchange rate* merupakan harga mata uang suatu negara dinyatakan dalam mata uang negara lain. *Exchange rate* dibedakan menjadi dua yakni :

1. *Nominal exchange rate* yaitu harga relatif dari mata uang satu negara dengan negara lain.
2. *Real exchange rate* yaitu kurs nominal yang disesuaikan dengan tingkat harga atau rasio harga internasional dengan harga domestik.

$$RER = e \times \left(\frac{P}{P^*} \right) \quad (2.80)$$

dengan

RER : *real exchange rate*

e : *nominal exchange rate*

P : tingkat harga domestik

*P** : tingkat harga luar negeri

Exchange rate dapat dijadikan alat untuk mengukur kondisi perekonomian suatu negara. Pertumbuhan nilai mata uang yang stabil menunjukkan bahwa negara tersebut memiliki kondisi ekonomi yang relatif baik (Salvatore, 1997). Perbedaan *exchange rate* suatu negara pada prinsipnya ditentukan oleh besarnya permintaan dan penawaran mata uang tersebut. *Exchange rate* merupakan salah satu komponen yang sangat penting dalam perekonomian terbuka, mengingat pengaruhnya yang besar bagi neraca transaksi berjalan maupun bagi variabel-variabel makroekonomi lainnya. Perubahan nilai tukar ini merupakan salah satu sumber ketidakpastian makroekonomi yang dampaknya dapat memengaruhi baik negara maupun perusahaan. Oleh karena besarnya dampak dari fluktuasi *exchange rate* terhadap perekonomian, maka diperlukan suatu manajemen *exchange rate* yang baik sehingga fluktuasi dapat diprediksi sehingga perekonomian dapat berjalan dengan stabil. Apabila terjadi kegagalan pada manajemen *exchange rate*, maka hal tersebut dapat mengakibatkan gangguan terhadap kestabilan perekonomian.

BAB 3

METODOLOGI PENELITIAN

Pada bab ini akan disajikan tentang sumber data penelitian, variabel-variabel yang diteliti serta langkah-langkah dalam menyelesaikan masalah penelitian guna untuk mencapai tujuan penelitian.

3.1 Sumber Data dan Variabel Penelitian

Data yang digunakan adalah data sekunder mengenai perekonomian beberapa negara yang diperoleh dari OECD (*Organisation for Economic Co-operation and Development*) pada website www.oecd.org, CEIC (*Census and Economic Information Center*) pada website www.ceicdata.com, dan ARIC (*Asia Regional Integration Center*) pada website www.aric.adb.org dengan periode kuartalan untuk variabel GDP *growth* dan bulanan untuk variabel lain dan dengan kisaran periode yang sama pada setiap negara yaitu dari bulan Januari 1998 sampai bulan Maret 2019. Daftar nama negara yang diteliti adalah sebagai berikut

Tabel 3.1 Daftar Nama Negara

Negara	Benua	Kebijakan	Inisial
United Kingdom	Eropa	ITF	GBR
Switzerland	Eropa	ITF	CHE
Indonesia	Asia	ITF	IDN
Filipina	Asia	ITF	PHL
Jerman	Eropa	Non ITF	DEU
Denmark	Eropa	Non ITF	DNK
Malaysia	Asia	Non ITF	MYS
Singapura	Asia	Non ITF	SGP

Sumber: Wikipedia, 2019

Variabel penelitian yang akan diigunakan dalam penelitian adalah sebagai berikut

Tabel 3.2 Variabel Penelitian

Variabel	Nama Variabel	Satuan
y_t	<i>Gross Domestic Product</i>	<i>Annual Growth Rate (%)</i> pada kuartal ke- t
x_{1t}	<i>Money Supply</i>	Triliun USD pada bulan ke- t

Variabel	Nama Variabel	Satuan
x_{2t}	<i>Inflation</i>	Annual Growth Rate (%) pada bulan ke- t
x_{3t}	<i>Interest Rate</i>	Annual Growth Rate (%) pada bulan ke- t
x_{4t}	<i>Exchange Rate</i>	Mata uang nasional / USD pada bulan ke- t

3.2 Struktur Data Penelitian

Struktur data pada penelitian ini adalah sebagai berikut

Tabel 3.3 Struktur Data

t	y_t	x_{1t}	x_{2t}	x_{3t}	x_{4t}
1	y_1	x_{11}	x_{21}	x_{31}	x_{41}
2	y_2	x_{12}	x_{22}	x_{32}	x_{42}
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
T	y_T	x_{1T}	x_{2T}	x_{3T}	x_{4T}

3.3 Langkah Analisis

Langkah yang akan dilakukan pada penelitian ini adalah sebagai berikut

3.3.1 Pemodelan Volatilitas dari Variabel *Money Supply, Inflation, Interest Rate, dan Exchange Rate* Terhadap Volatilitas *Gross Domestic Product* Menggunakan *Fractional Cointegration Model*

1. Membuat dan menginterpretasikan *time series plot* dan karakteristik data pada masing-masing variabel
2. Memodelkan masing-masing variabel dengan model ARMA sesuai dengan persamaan (2.10) dan mendefinisikan deret *error* $\varepsilon_t^{(y_t)}$ dan $\varepsilon_t^{(x_i)}$ serta deret $\varepsilon_t^{2(y_i)}$ dan $\varepsilon_t^{2(x_i)}$ dengan $i=1,2,3,4$ sesuai persamaan (2.18)
3. Menguji heteroskedastisitas pada deret $\varepsilon_t^{2(y_i)}$ dan $\varepsilon_t^{2(x_i)}$ dengan $i=1,2,3,4$ dengan uji LM sesuai dengan pengujian pada subbab 2.2.1
4. Melakukan agregasi pada $\varepsilon_t^{2(x_i)}$ dengan $i=1,2,3,4$ yaitu dengan menghitung rata-rata per 3 bulan sehingga menjadi data kuartalan
5. Menguji adanya perubahan fluktuasi menggunakan CUSUM Test pada deret volatilitas $\varepsilon_t^{2(y_i)}$ dengan dua *regime* sesuai dengan subbab 2.4.1

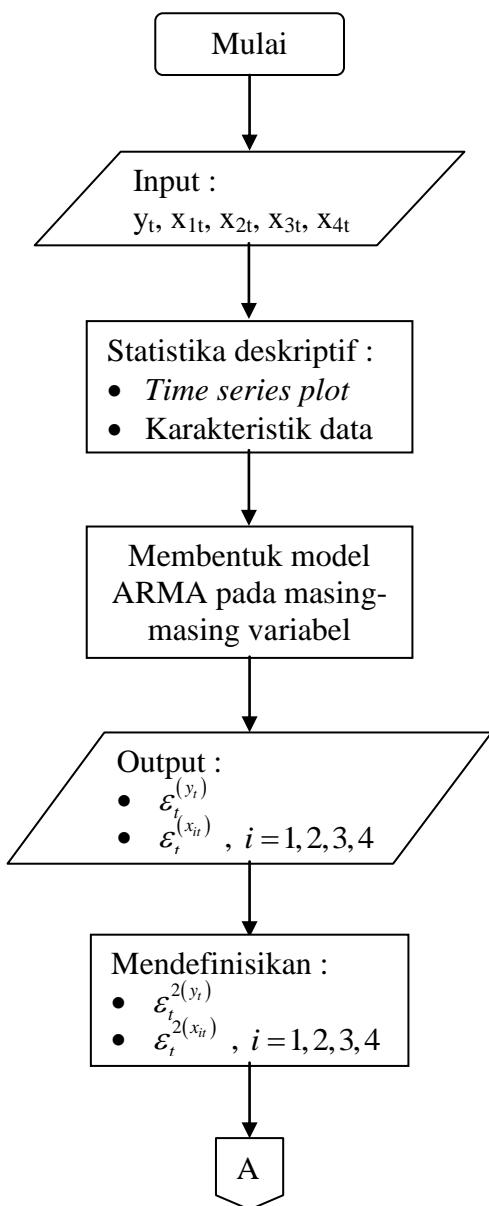
6. Mengestimasi *transition probability* pada *regime* 1 dan *regime* 2 sesuai dengan persamaan (2.32) dan *filtering probability* pada setiap t sesuai dengan persamaan (2.33)
7. Mengestimasi parameter model *Markov Switching* sesuai dengan subbab **2.4.2**
8. Membentuk model *Markov Switching* berdasarkan estimasi yang diperoleh
9. Mengklasifikasikan $\varepsilon_t^{2(y_t)}$ ke *regime* 1 atau *regime* 2 berdasarkan *filtering probability*
10. Membentuk vektor y_t^* yang berisi kategori *regime* dari $\varepsilon_t^{2(y_t)}$ yang bersesuaian pada waktu ke- t
11. Meregresikan y_t^* terhadap deret volatilitas $\varepsilon_t^{2(x_i)}$ dengan $i=1,2,3,4$ menggunakan Model Regresi Probit sesuai dengan persamaan (2.38)
12. Menentukan ketepatan klasifikasi y_t^* terhadap hasil estimasi Model Regresi Probit sesuai dengan subbab **2.5.3**
13. Menguji adanya *Long Memory* pada deret $\varepsilon_t^{2(y_i)}$ dan $\varepsilon_t^{2(x_i)}$ dengan $i=1,2,3,4$ dengan mengestimasi parameter d sesuai dengan subbab **2.6.5**
14. Membentuk persamaan *cointegration* pada deret $\varepsilon_t^{2(y_i)}$ dan $\varepsilon_t^{2(x_i)}$ dengan $i=1,2,3,4$ sesuai persamaan (2.63)
15. Mengestimasi parameter *cointegration* dan mendefinisikan deret residu u_t dari model *cointegration*
16. Mengestimasi parameter *Long Memory* pada deret u_t sesuai dengan subbab **2.6.5**
17. Membentuk model *Fractional Cointegration* dengan *Markov Switching* dan *Autoregressive Moving Average*
18. Melakukan *diagnostic checking* pada model yang telah terbentuk sesuai dengan subbab **2.1.6** dan menghitung kriteria kebaikan model menggunakan AIC sesuai dengan subbab **2.7**
19. Menginterpretasikan model yang telah terbentuk

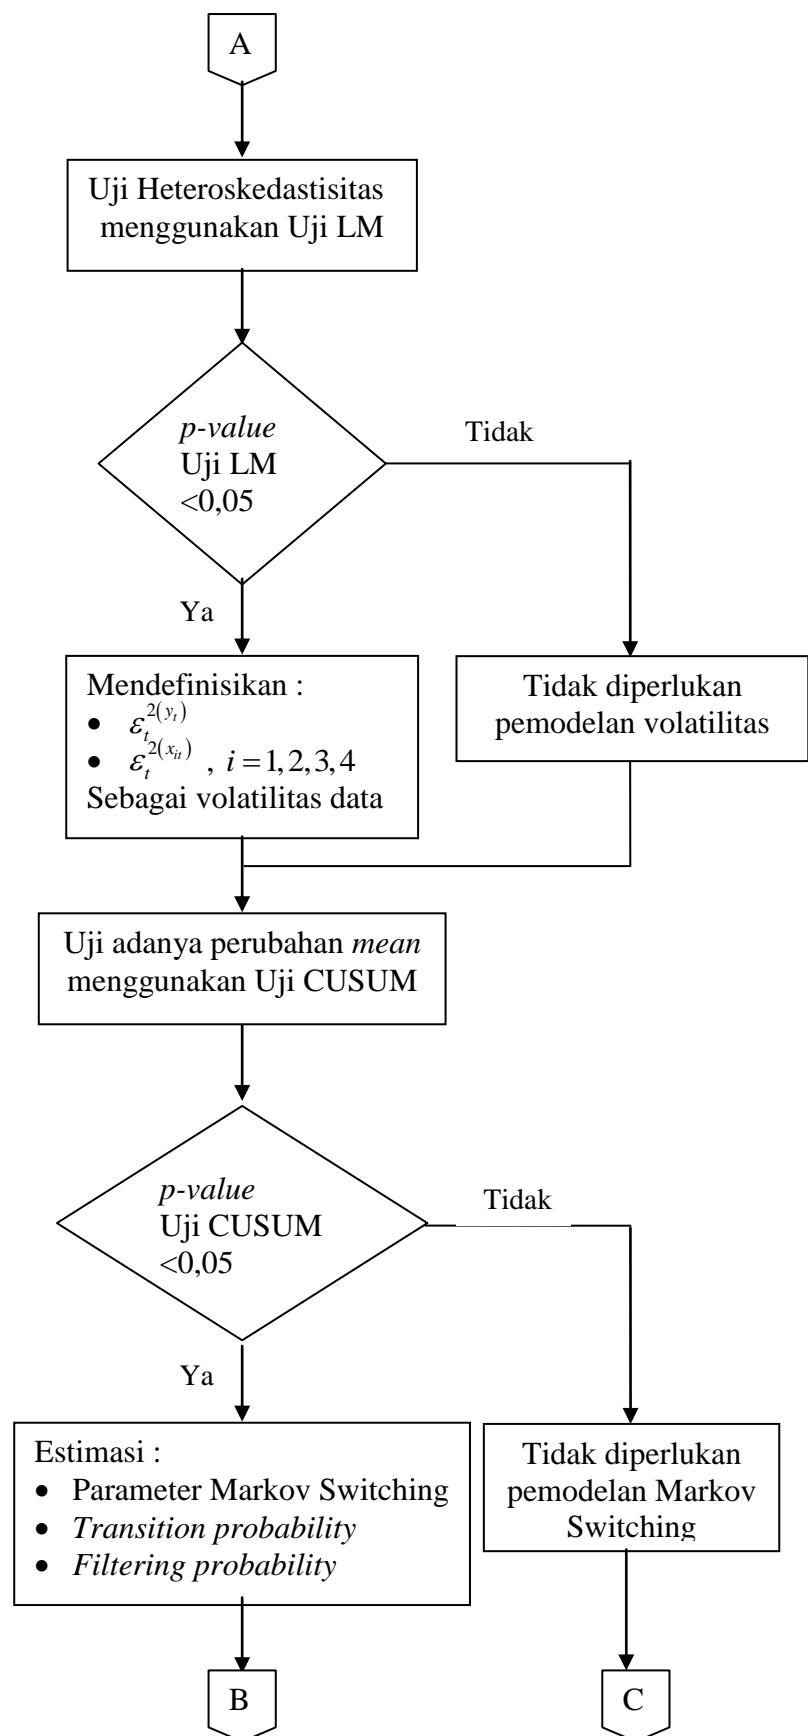
3.3.2 Evaluasi Penerapan *Inflation Targeting Framework* Terhadap *Gross Domestic Product*

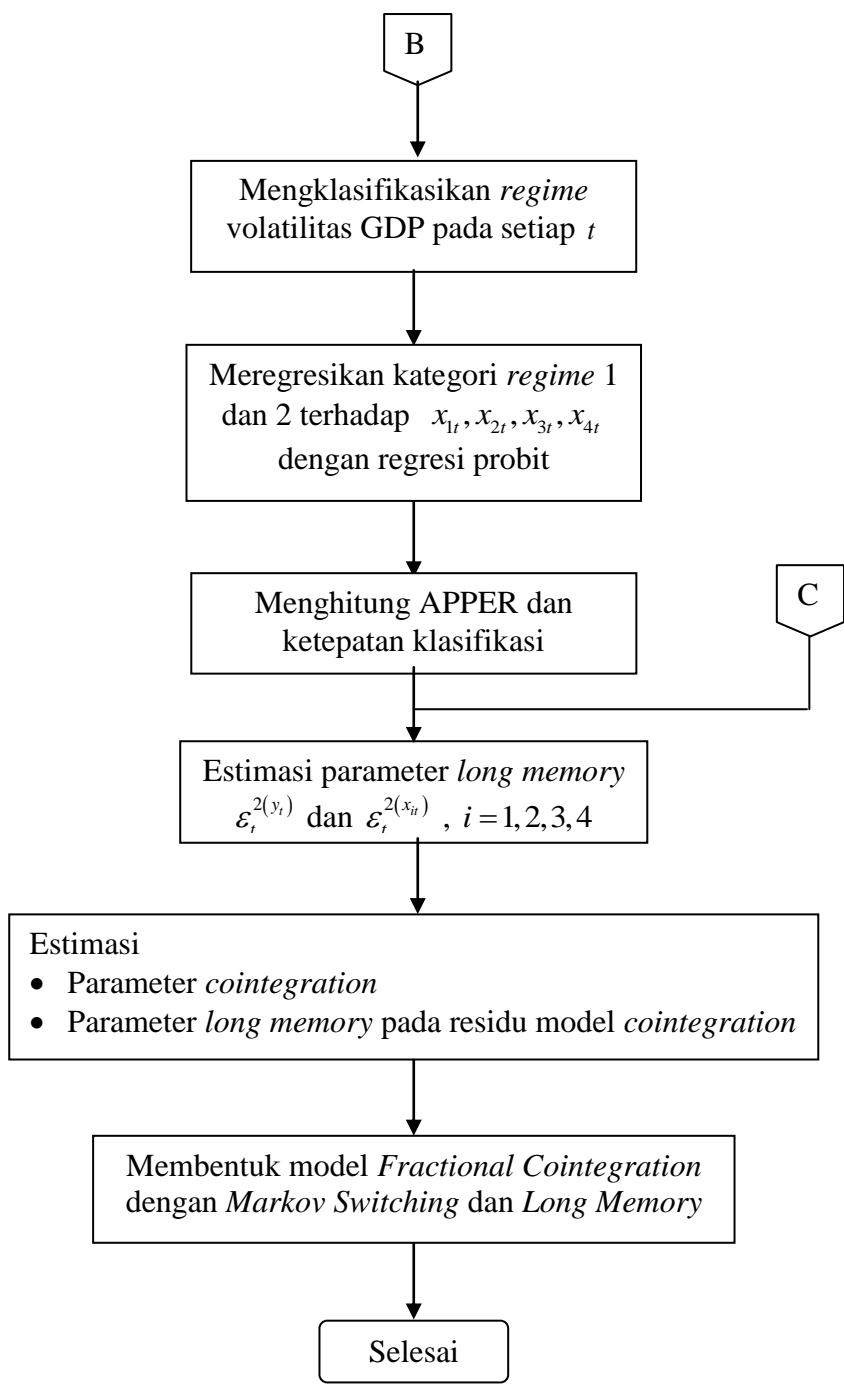
Mengevaluasi hasil interpretasi yang diperoleh dari subbab 3.3.1 mengenai hasil penerapan ITF terhadap volatilitas GDP *growth* berdasarkan volatilitas *money supply*, *inflation*, *interest rate*, dan *exchange rate* menggunakan *Fractional Cointegration Model*.

3.4 Diagram Alir

Tahapan analisis pada penelitian ini disajikan pada Gambar 3.1 berikut







Gambar 3.1 Diagram Alir

BAB 4

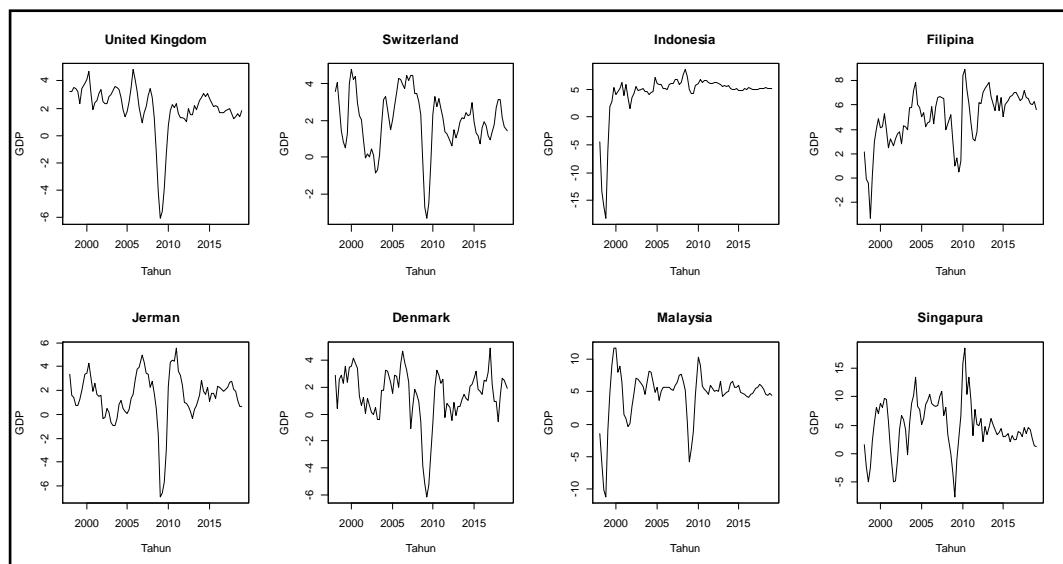
ANALISIS DAN PEMBAHASAN

Pada bab ini akan disajikan hasil analisis dan pembahasan untuk menyelesaikan masalah penelitian guna untuk mencapai tujuan penelitian. Data pada penelitian ini dianalisis menggunakan model *Fractional Cointegration*.

Analisis didahului dengan dekripsi karakteristik dari data yang digunakan pada penelitian ini.

4.1 Deskripsi Karakteristik Data

Pada Gambar 4.1 dan Tabel 4.1 berikut disajikan karakteristik data GDP *growth* pada setiap negara.



Gambar 4.1 Plot Time Series GDP growth

Plot *time series* pada Gambar 4.1 memperlihatkan tidak adanya *trend* naik maupun turun pada data GDP *growth* tetapi dapat dilihat terdapat fluktuasi yang tinggi kecuali pada data GDP *growth* Indonesia. Oleh karena tingginya fluktuasi, berdasarkan Gambar 4.1 dapat disimpulkan bahwa data GDP *growth* tidak stasioner dalam varians. Selain itu, terdapat kesamaan pola pada plot GDP *growth* dari 8 negara tersebut dimana GDP *growth* mengalami penurunan dan kenaikan hampir pada periode yang sama. Seperti pada 2007 sampai 2010 GDP *growth*

mangalami penurunan ekstrim yang selanjutnya diikuti dengan kenaikan pada nilai sebelum terjadi penurunan. Hal tersebut mungkin disebabkan oleh krisis ekonomi United States yang diakibatkan oleh kerugian *mortgage market* pada tahun 2007 yang mempengaruhi perekonomian dunia. Kemudian pada tahun 2010, untuk mengatasi krisis tersebut Bank Sentral menghimpun dana untuk mengatasi kerugian dan mengembalikan keadaan ekonomi. Pada negara Asia, penurunan ekstrim juga terjadi pada periode tahun 1998 sampai 1999 sebagai akibat dari krisis ekonomi besar di Asia tenggara yang diawali dengan depresiasi baht Thailand.

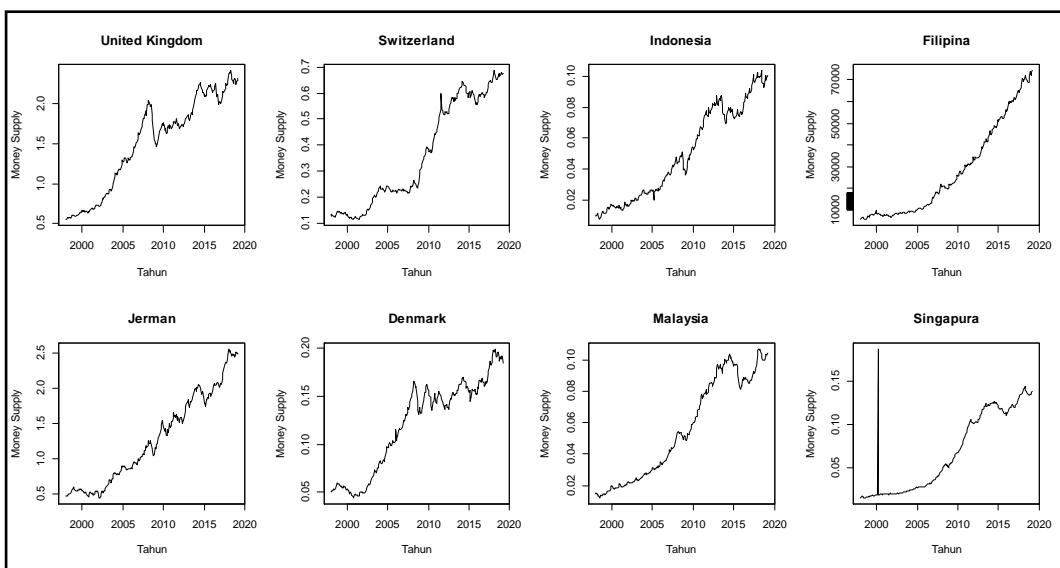
Tabel 4.1 Karakteristik GDP *Growth*

	GBR	CHE	IDN	PHL	DEU	DNK	MYS	SGP
Mean	1,995	1,958	4,288	4,969	1,456	1,415	4,545	4,930
Std Dev	1,863	1,635	4,353	2,202	2,164	2,051	3,872	4,583
Min	-6,083	-3,339	-18,258	-3,379	-6,933	-6,168	-11,182	-7,712
Max	4,809	4,735	8,470	8,913	5,570	4,945	11,687	18,641
Skew	-2,550	-0,741	-3,957	-1,137	-1,593	-1,528	-1,960	-0,067
Kurt	8,120	1,034	16,225	1,752	4,721	3,491	5,378	0,946

Sumber: *Output Software R*, 2019

Karakteristik pada Tabel 4.1 menunjukkan bahwa GDP *growth* di negara Eropa relatif lebih rendah dari pada di negara Asia. Selain itu, pertumbuhan GDP *growth* di negara Eropa memiliki keragaman dan rentang data yang juga lebih rendah dari negara Asia. Hal ini disebabkan oleh negara-negara di Eropa yang memiliki GDP *growth* yang tinggi dan stabil sehingga tidak banyak terjadi perubahan dan menyebabkan GDP *growth* relatif rendah. Sementara pada negara-negara Asia memiliki GDP *growth* yang lebih rendah dan banyak mengalami perubahan sehingga GDP *growth* negara Asia relatif tinggi. Selanjutnya, dari nilai *skewness* dapat disimpulkan bahwa pertumbuhan GDP *growth* cenderung meningkat dari waktu ke waktu dan tidak berdistribusi normal kecuali di Switzerland dan Singapura. Sedangkan dari nilai *kurtosis* dapat disimpulkan bahwa pertumbuhan GDP *growth* cenderung homogen.

Berikut pada Gambar 4.2 dan Tabel 4.2 disajikan karakteristik data *money supply* pada masing-masing negara.



Gambar 4.2 Plot Time Series Money Supply

Dapat terlihat jelas pada Gambar 4.2 bahwa pada plot *money supply* pada semua negara terdapat *trend* naik dan tidak terdapat fluktuasi yang tinggi. Hal ini menunjukkan bahwa *money supply* pada semua negara mengalami kenaikan yang berlanjut seiring waktu. Kenaikan dan penurunan pada *money supply* yang stabil menunjukkan bahwa data *money supply* stasioner dalam varians tetapi nonstasioner dalam *mean*. Namun pada periode 2014 sampai 2018 terlihat adanya fluktuasi yang lebih tinggi dan kenaikan nilai yang lebih rendah dari periode sebelumnya. Adanya perubahan fluktuasi dan kenaikan nilai tersebut mungkin disebabkan oleh efek dari krisis ekonomi United States sebelumnya. Beberapa literatur menyatakan efek dari krisis ekonomi akan mulai mempengaruhi *money supply* dalam waktu yang lama.

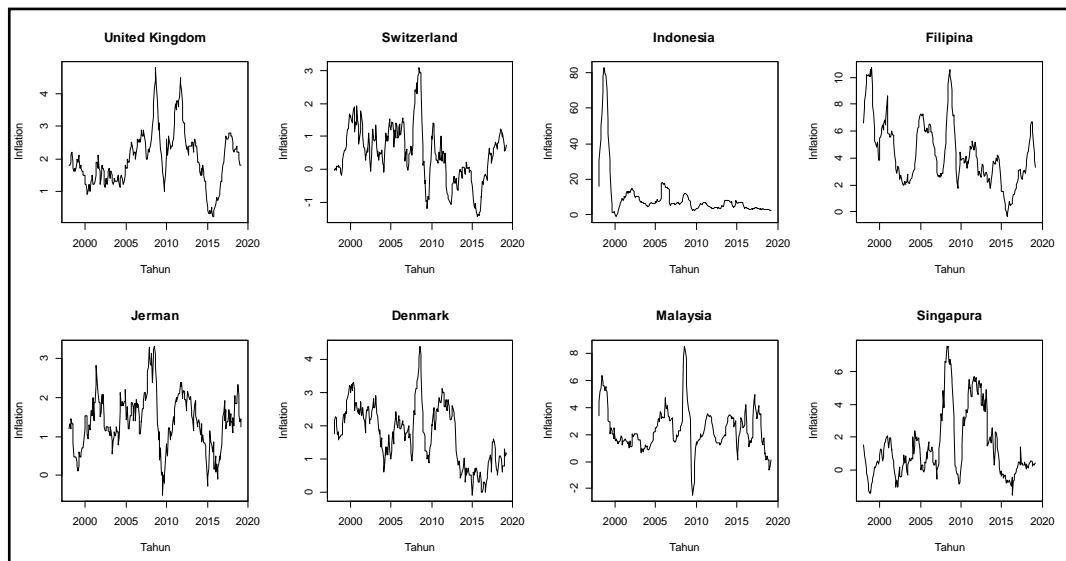
Tabel 4.2 Karakteristik *Money Supply*

	GBR	CHE	IDN	PHL	DEU	DNK	MYS	SGP
Mean	1,508	0,361	0,050	0,028	1,285	0,120	0,056	0,067
Std Dev	0,582	0,200	0,030	0,021	0,639	0,047	0,032	0,046
Min	0,550	0,113	0,008	0,005	0,449	0,044	0,012	0,015
Max	2,410	0,686	0,103	0,074	2,561	0,199	0,107	0,188
Skew	-0,311	0,259	0,216	0,745	0,338	-0,319	0,161	0,324
Kurt	-1,291	-1,600	-1,448	-0,803	-1,152	-1,326	-1,575	-1,513

Sumber: *Output Software R*, 2019

Pada Tabel 4.2 menunjukkan bahwa United Kingdom memiliki rata-rata *money supply* yang paling tinggi dari semua negara. Rata-rata *money supply* pada negara-negara Eropa lebih tinggi dari negara-negara di Asia. Tingginya *money supply* menandakan perekonomian yang baik. Sedangkan Jerman memiliki keragaman dan rentang data yang tertinggi dibandingkan dengan negara lain. Selanjutnya, dari nilai *skewness* diketahui *money supply* United Kingdom dan Denmark cenderung meningkat dari waktu ke waktu sementara untuk negara lain cenderung menurun dari waktu ke waktu. Hal tersebut tidak sesuai dengan Gambar 4.2 yang menunjukkan data *money supply* disemua negara memiliki *trend* naik. Kesimpulan lain yaitu bahwa *money supply* berdistribusi normal di semua negara namun disimpulkan pula bahwa *money supply* cenderung heterogen berdasarkan nilai *kurtosis*.

Pada Gambar 4.3 dan Tabel 4.3 ditunjukkan karakteristik data *inflation* pada masing-masing negara.



Gambar 4.3 Plot Time Series Inflation

Sama halnya dengan *GDP growth*, pada plot *inflation* juga terdapat adanya fluktuasi yang tinggi. Hal tersebut memperkuat adanya hubungan saling mempengaruhi antara *GDP growth* dan *inflation*. Pada Gambar 4.3 masih dapat dilihat adanya *trend* naik dan turun pada plot dimana naik turunnya data *inflation*

terjadi pada periode yang singkat kecuali pada *inflation* Indonesia. Fluktuasi yang tinggi pada data *inflation* diikuti dengan kesimpulan bahwa *inflation* pada semua negara tidak stasioner. Pada periode 2008 sampai 2009 terjadi kenaikan kenilai *inflation* yang tertinggi selama periode penelitian yang kemudian diikuti dengan penurunan yang besar ke nilai *inflation* rendah. Krisis ekonomi pada United States yang mengakibatkan turunnya GDP *growth* mungkin menjadi sebab terjadi kenaikan *inflation*. Sementara itu, pulihnya perekonomian yang ditandai dengan naiknya GDP *growth* mengakibatkan penurunan *inflation*. Hal tersebut terjadi pada semua negara kecuali pada *inflation* Indonesia dimana kenaikan dan penurunan yang besar terjadi pada periode 1998 sampai 1999.

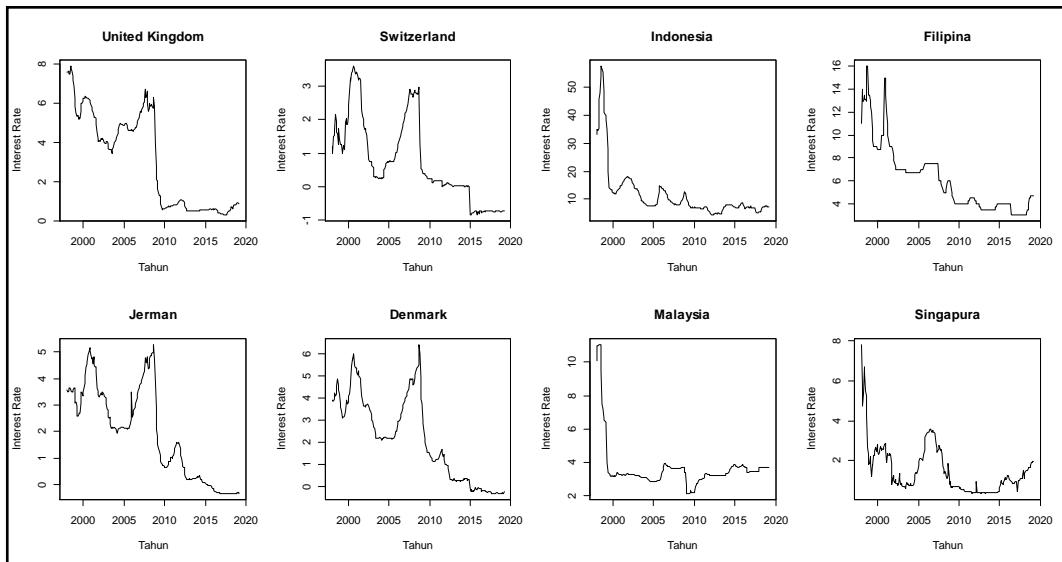
Tabel 4.3 Karakteristik *Inflation*

	GBR	CHE	IDN	PHL	DEU	DNK	MYS	SGP
Mean	1,992	0,491	9,962	4,397	1,393	1,750	2,384	1,424
Std Dev	0,850	0,881	13,659	2,358	0,708	0,912	1,598	2,065
Min	0,200	-1,444	-1,164	-0,373	-0,503	-0,101	-2,480	-1,565
Max	4,800	3,075	82,393	10,698	3,323	4,388	8,522	7,572
Skew	0,534	0,209	3,798	0,676	0,083	0,074	0,782	1,148
Kurt	0,655	0,306	14,951	0,133	0,196	-0,650	2,790	0,488

Sumber: *Output Software R*, 2019

Dapat dilihat pada Tabel 4.3, sesuai dengan plot, karakteristik *inflation* menunjukkan karakter yang sama dengan GDP *growth*. Negara-negara di Asia memiliki *inflation* yang lebih tinggi dibandingkan negara-negara di Eropa. Tingginya *inflation* akan mengakibatkan rendahnya GDP *growth* dan juga sebaliknya. *Inflation* Indonesia memiliki keragaman dan rentang data yang tinggi sementara di negara lain memiliki keragaman dan rentang data yang relatif rendah. Dan dilihat dari nilai *skewness*, *inflation* cenderung menurun dari waktu ke waktu namun berdistribusi normal kecuali di Indonesia. Sedangkan dilihat dari nilai *kurtosis* diketahui bahwa *inflation* cenderung homogen kecuali di Denmark namun hal ini kurang sesuai jika dibandingkan dengan plot pada Gambar 4.3 dimana pada plot terlihat bahwa *inflation* cenderung heterogen di semua negara kecuali di Indonesia.

Selanjutnya pada Gambar 4.4 dan Tabel 4.4 disajikan karakteristik data *interest rate* pada masing-masing negara.



Gambar 4.4 Plot Time Series Interest Rate

Dilihat berdasarkan Gambar 4.4, jika dibandingkan pada januari 1998 dengan maret 2019 *interest rate* telah mengalami penurunan besar dan selama periode tersebut tidak terdapat fluktuasi yang tinggi pada data. Berdasarkan penurunan yang terjadi dapat dikatakan bahwa *interest rate* tidak stasioner dalam *mean*. Terdapat perbedaan pada plot *interest rate* negara Eropa dan Asia. Pada negara Eropa pada periode 2008 sampai 2009 terjadi penurunan *interest rate* yang besar yang dapat juga disebabkan oleh krisis ekonomi United States. Sedangkan pada negara Asia penurunan yang besar terjadi pada periode 1998 sampai 1999 yang disebabkan oleh krisis ekonomi di Asia.

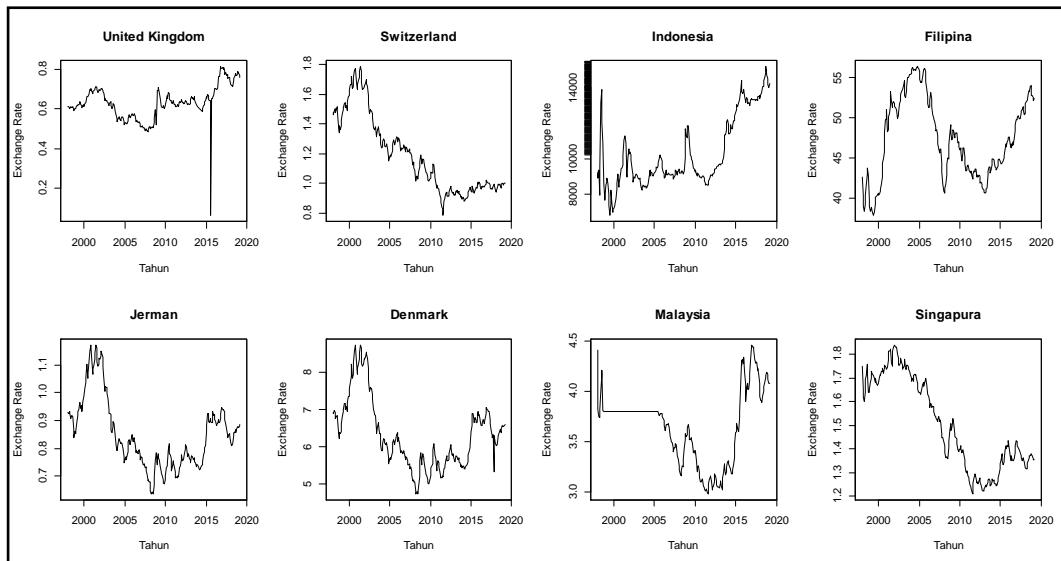
Tabel 4.4 Karakteristik *Interest Rate*

	GBR	CHE	IDN	PHL	DEU	DNK	MYS	SGP
Mean	3,044	0,750	11,434	6,158	1,908	2,163	3,604	1,503
Std Dev	2,421	1,237	9,354	2,929	1,735	1,899	1,458	1,223
Min	0,277	-0,854	4,206	3,000	-0,331	-0,318	2,110	0,349
Max	7,867	3,585	57,579	16,000	5,277	6,422	11,060	7,813
Skew	0,219	0,673	3,129	1,228	0,215	0,232	3,970	1,889
Kurt	-1,549	-0,553	10,299	1,148	-1,291	-1,202	16,657	4,905

Sumber: *Output Software R*, 2019

Karakteristik yang disajikan pada Tabel 4.4 menunjukkan bahwa rata-rata *interest rate* tertinggi yaitu di Indonesia dan rata-rata terendah di Switzerland. Selain memiliki rata-rata tertinggi, Indonesia juga memiliki keragaman dan rentang data yang tinggi. Hal ini berkaitan dengan *inflation* Indonesia yang juga tertinggi di antara semua negara sehingga menunjukkan keterkaitan antara *inflation* dan *interest rate*. Selanjutnya, disimpulkan berdasarkan nilai *skewness*, *interest rate* cenderung menurun dari waktu ke waktu yang didukung dengan plot pada Gambar 4.4. Selain itu, pada negara Eropa *interest rate* disimpulkan cenderung berdistribusi normal namun heterogen. Sedangkan pada negara Asia dari nilai *kurtosis* disimpulkan bahwa *money supply* tidak berdistribusi normal tetapi homogen.

Gambar 4.5 dan Tabel 4.5 berikut ditunjukkan karakteristik data *exchange rate* mata uang terhadap USD pada masing-masing negara.



Gambar 4.5 Plot *Time Series Exchange Rate* Terhadap USD

Trend naik turun dan fluktuasi yang tinggi terlihat pada plot *exchange rate* pada Gambar 4.5. Seperti pada plot *GDP growth*, naik turunnya *exchange rate* dari semua negara terlihat memiliki pola yang sama. Sehingga dapat disimpulkan bahwa *exchange rate* tidak stasioner dalam *mean*. Jika dibandingkan dengan nilai pada januari 1998, *exchange rate* United Kingdom, Indonesia, Filipina dan

Malaysia pada maret 2019 telah mengalami peningkatan yang besar. Sedangkan *exchange rate* Switzerland dan Singapura mengalami penurunan yang besar. Sementara *exchange rate* Jerman dan Denmark berada pada nilai yang tidak jauh berbeda.

Tabel 4.5 Karakteristik *Exchange Rate*

	GBR	CHE	IDN	PHL	DEU	DNK	MYS	SGP
Mean	0,630	1,187	10298,671	47,450	0,849	6,322	3,654	1,503
Std Dev	0,083	0,258	1975,675	4,997	0,125	0,931	0,364	0,192
Min	0,062	0,780	6805,972	37,839	0,635	4,734	2,982	1,209
Max	0,811	1,786	15178,870	56,341	1,173	8,740	4,457	1,839
Skew	-0,998	0,704	0,777	0,083	0,798	0,803	-0,061	0,146
Kurt	7,507	-0,683	-0,634	-1,072	0,068	0,068	-0,674	-1,457

Sumber: *Output Software R*, 2019

Tabel 4.5 menunjukkan karakteristik *exchange rate* dimana rata-rata *exchange rate* beragam antar negara. Pada masing-masing *exchange rate* di negara selain Indonesia dan Filipina memiliki keragaman dan rentang data yang relatif rendah sedangkan Indonesia dan Filipina memiliki keragaman dan rentang data yang tinggi. Rata-rata yang beragam dan keragaman pada masing-masing *exchange rate* tersebut disebabkan oleh perbedaan nominal mata uang tiap negara. Pada nilai *skewness* disimpulkan bahwa *exchange rate* pada United Kingdom dan Malaysia cenderung menguat dari waktu ke waktu sementara untuk negara lain cenderung melemah dari waktu ke waktu namun kesimpulan ini tidak sesuai dengan kesimpulan dari Gambar 4.5. Selain itu, dapat diketahui berdasarkan nilai *skewness* bahwa *exchange rate* cenderung berdistribusi normal kecuali di United Kingdom. Sedangkan dari nilai *kurtosis* dapat disimpulkan bahwa *exchange rate* cenderung heterogen kecuali di United Kingdom, Jerman, dan Denmark yang juga bertentangan dengan plot pada Gambar 4.5 yang menunjukkan keheterogenan pada plot Jerman dan Denmark.

Hasil analisis disajikan secara lengkap pada subbab-subbab berikut.

4.2 Pemodelan Volatilitas dari Variabel *Money Supply, Inflation, Interest Rate, dan Exchange Rate* Terhadap Volatilitas *Gross Domestic Product* Menggunakan *Fractional Cointegration Model*

Pemodelan menggunakan *fractional cointegration* dilakukan dengan mengikuti langkah pada subbab-subbab berikut.

4.2.1 Volatilitas dari Residual Pemodelan ARMA

Langkah pertama analisis yaitu dengan memodelkan ARMA pada semua data. Model ARMA terbaik dipilih berdasarkan signifikansi parameter, kenormalan residual, dan nilai AIC yang minimum. Model terbaik yang dipilih untuk setiap variabel dapat dilihat pada Lampiran 2. Selanjutnya dilakukan uji *white noise* dengan uji Ljung-Box dan uji heteroskedastisitas dengan uji LM pada residual model ARMA terbaik. Hasil uji Ljung-Box dan uji LM dapat dilihat pada Lampiran 3 sedangkan kesimpulan pengujian disajikan pada Tabel 4.6 berikut.

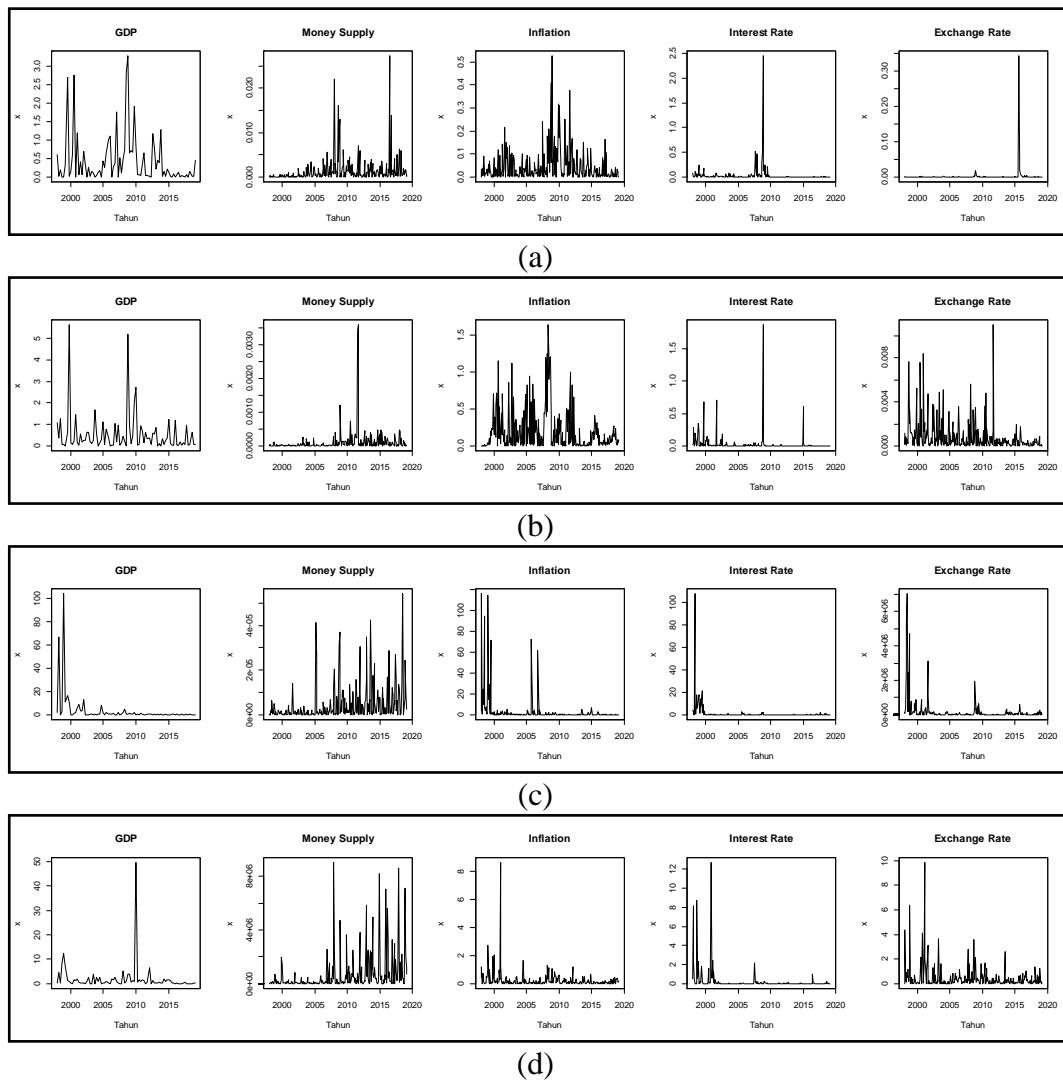
Tabel 4.6 Kesimpulan Pengujian Ljung-Box dan Lagrange Multiplier

Negara	Uji Ljung-Box				
	GDP Growth	Money Supply	Inflation	Interest Rate	Exchange Rate
GBR	Tidak	Tidak	Tidak	Tidak	<i>WhiteNoise</i>
CHE	Tidak	<i>WhiteNoise</i>	Tidak	Tidak	<i>WhiteNoise</i>
IDN	Tidak	Tidak	Tidak	Tidak	Tidak
PHL	<i>WhiteNoise</i>	Tidak	Tidak	<i>WhiteNoise</i>	<i>WhiteNoise</i>
DEU	Tidak	Tidak	Tidak	Tidak	<i>WhiteNoise</i>
DNK	Tidak	<i>WhiteNoise</i>	Tidak	Tidak	<i>WhiteNoise</i>
MYS	Tidak	Tidak	Tidak	Tidak	Tidak
SGP	Tidak	<i>WhiteNoise</i>	Tidak	Tidak	Tidak
Uji LM					
Negara	GDP Growth	Money Supply	Inflation	Interest Rate	Exchange Rate
	Heterogen	Heterogen	Heterogen	Heterogen	Heterogen
GBR	Heterogen	Heterogen	Heterogen	Heterogen	Heterogen
CHE	Heterogen	Heterogen	Heterogen	Heterogen	Heterogen
IDN	Heterogen	Heterogen	Heterogen	Heterogen	Heterogen
PHL	Heterogen	Heterogen	Heterogen	Heterogen	Heterogen
DEU	Heterogen	Heterogen	Heterogen	Heterogen	Heterogen
DNK	Heterogen	Heterogen	Heterogen	Heterogen	Heterogen
MYS	Heterogen	Heterogen	Heterogen	Heterogen	Heterogen
SGP	Heterogen	Heterogen	Heterogen	Heterogen	Heterogen

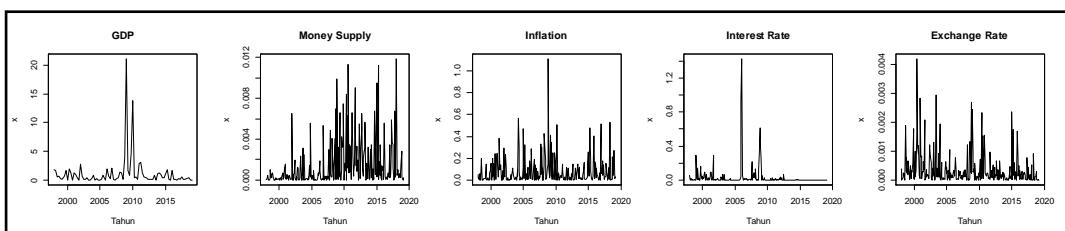
Sumber: *Output Software R*, 2019

Berdasarkan hasil uji Ljung-Box pada Tabel 4.6 dapat diketahui bahwa residual dari beberapa variabel merupakan proses yang *white noise* namun sebagian besar

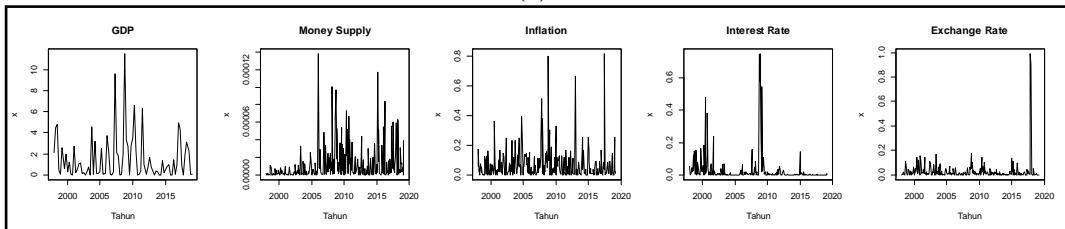
variabel bukan merupakan proses yang *white noise* sedangkan berdasarkan hasil uji LM dapat diketahui bahwa model ARMA terbaik memiliki residual yang mengandung efek heteroskedastisitas. Model yang sesuai untuk mengatasi efek heteroskedastisitas ini yaitu model volatilitas. Sehingga langkah selanjutnya yaitu memperoleh deret volatilitas untuk setiap variabel berdasarkan model ARMA terbaik, yaitu dengan mengkuadratkan deret residual model ARMA. Keheterogenan dari residual model ARMA dapat dibuktikan dengan plot dari deret volatilitas yang diperoleh yang ditunjukkan pada Gambar 4.6 berikut.



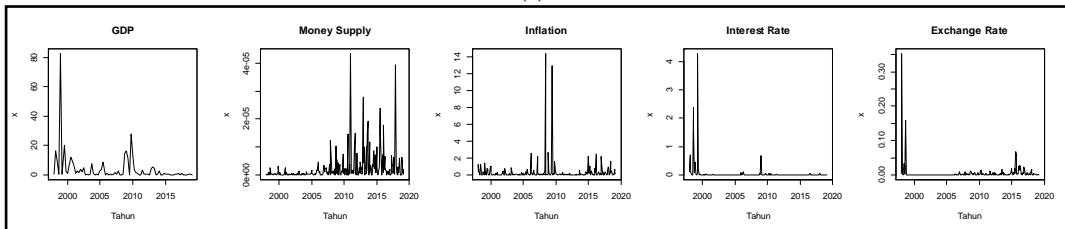
Gambar 4.6a Plot *Time Series* Volatilitas (a) United Kingdom, (b) Switzerland, (c) Indonesia, dan (d) Filipina yang Menerapkan ITF



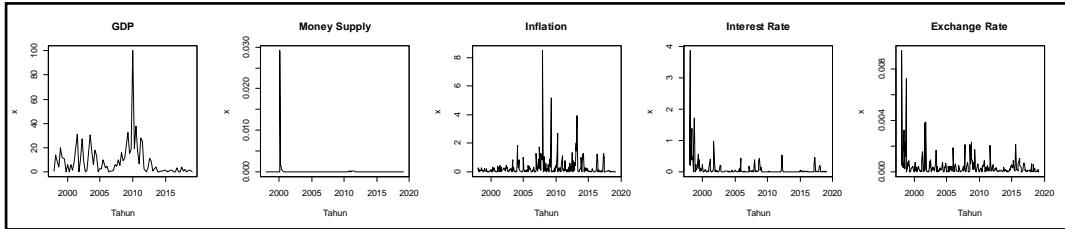
(e)



(f)



(g)



(h)

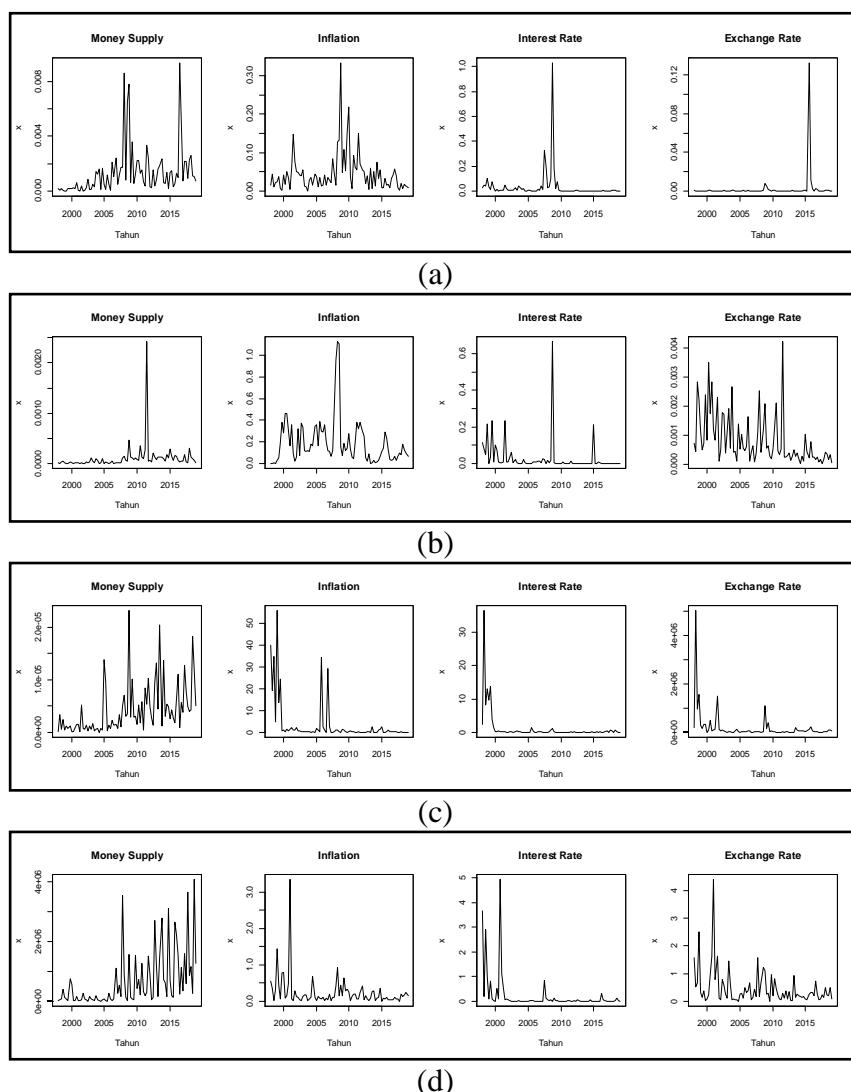
Gambar 4.6b Plot *Time Series* Volatilitas (e) Jerman, (f) Denmark, (g) Malaysia, dan (h) Singapura yang Tidak Menerapkan ITF

Plot *time series* dari beberapa variabel pada Gambar 4.6 memperlihatkan keheterogenan pada data namun pada beberapa variabel lain tidak menunjukkan adanya keheterogenan pada data. Selain itu, tidak terlihat adanya perbedaan pola pada data negara yang menerapkan ITF dan tidak menerapkan ITF. Selanjutnya volatilitas tersebut akan digunakan pada analisis selanjutnya. Pada volatilitas *money supply*, *inflation*, *interest rate*, dan *exchange rate* dilakukan agregasi temporal untuk memperoleh frekuensi variabel yang sama antara volatilitas *GDP growth* dan volatilitas variabel lain. Volatilitas *GDP growth* memiliki frekuensi 3 bulanan sedangkan volatilitas variabel lain memiliki frekuensi bulanan, sehingga

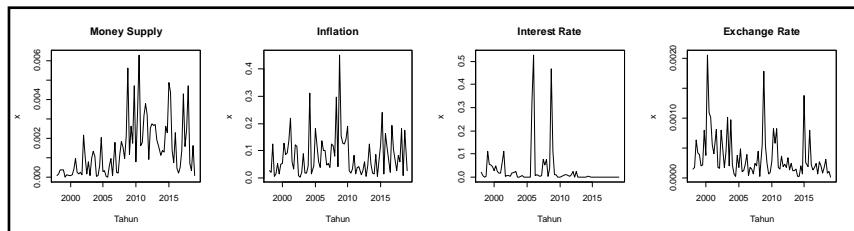
agregasi dilakukan dengan menghitung rata-rata volatilitas *money supply*, *inflation*, *interest rate*, dan *exchange rate* pada setiap 3 bulan. Agregasi yang dilakukan sesuai dengan persamaan (4.1) berikut.

$$\varepsilon_t^{2(x_{it})} = \frac{1}{3} \sum_{t_0=(3t-2)}^{3t} \varepsilon_{t_0}^{2(x_{t_0})} \text{ dengan } t_0 = 1, 2, \dots, T \text{ dan } t = 1, 2, \dots, \frac{T}{3} \quad (4.1)$$

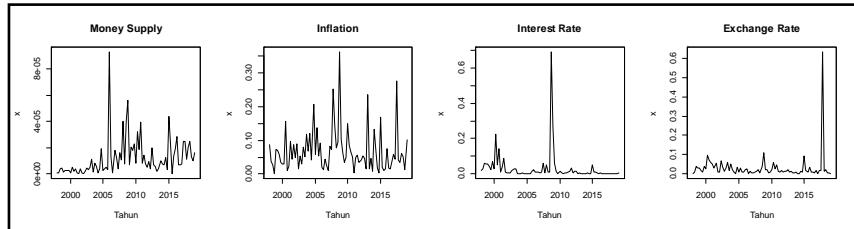
Setelah proses agregasi tersebut, diperoleh data volatilitas *GDP growth*, *money supply*, *inflation*, *interest rate*, dan *exchange rate* dengan frekuensi 3 bulanan. Plot dari deret volatilitas yang diperoleh dapat dilihat pada Gambar 4.7 berikut.



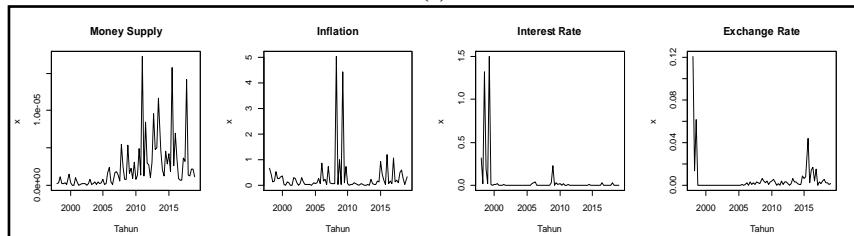
Gambar 4.7a Plot *Time Series Volatilitas Hasil Agregasi* (a) United Kingdom, (b) Switzerland, (c) Indonesia, dan (d) Filipina yang Menerapkan ITF



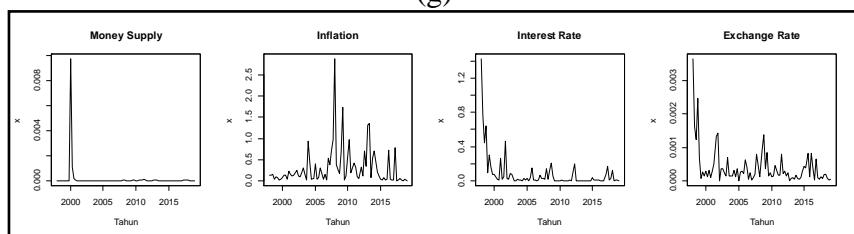
(e)



(f)



(g)



(h)

Gambar 4.7b Plot *Time Series* Volatilitas Hasil Agregasi (e) Jerman, (f) Denmark, (g) Malaysia, dan (h) Singapura yang Tidak Menerapkan ITF

Setelah dilakukan agregasi, dapat dilihat pada Gambar 4.7 beberapa data menunjukkan masih adanya fluktuasi yang tinggi. Namun, fluktuasi yang terjadi pada data setalah diagregasi lebih rendah dibandingkan dengan sebelum diagregasi seperti pada *money supply* Denmark. Sedangkan beberapa data lainnya setelah di agregasi menunjukkan adanya fluktuasi yang rendah namun masih terdapat nilai-nilai ekstrim pada data.

4.2.2 Pemodelan *Markov Switching* untuk Volatilitas GDP Growth

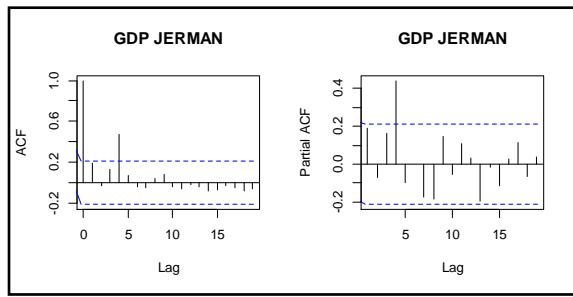
Langkah selanjutnya dilakukan pengujian adanya perubahan *regime* atau perubahan *mean* pada volatilitas GDP *growth* setiap negara dengan uji CUSUM. Hasil uji CUSUM disajikan pada Tabel 4.7 berikut.

Tabel 4.7 Hasil Uji CUSUM Volatilitas GDP Growth

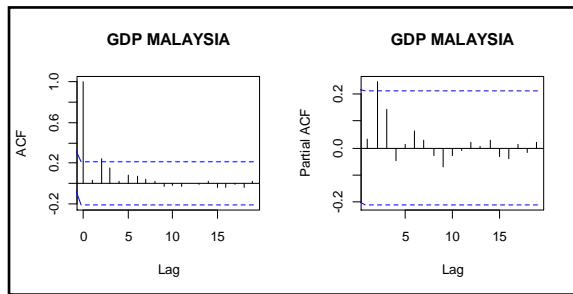
Negara	Uji CUSUM	
	p-value	Kesimpulan
GBR	0,0363	Terdapat perubahan pada <i>mean</i>
CHE	0,3297	Tidak terdapat perubahan pada <i>mean</i>
IDN	0,0025	Terdapat perubahan pada <i>mean</i>
PHL	0,5500	Tidak terdapat perubahan pada <i>mean</i>
DEU	0,4023	Tidak terdapat perubahan pada <i>mean</i>
DNK	0,4985	Tidak terdapat perubahan pada <i>mean</i>
MYS	0,0460	Terdapat perubahan pada <i>mean</i>
SGP	0,0020	Terdapat perubahan pada <i>mean</i>

Sumber: *Output Software R*, 2019

Kesimpulan dari hasil uji CUSUM pada Tabel 4.7 dengan nilai $\alpha = 0,05$ dapat diketahui bahwa terdapat perubahan pada *mean* volatilitas GDP *growth* United Kingdom, Indonesia, Malaysia, dan Singapura sedangkan dapat diketahui pula tidak terdapat perubahan pada *mean* volatilitas GDP *growth* Switzerland, Filipina, Jerman, dan Denmark. Dari kesimpulan yang diperoleh tersebut dapat dilihat bahwa tiga dari empat volatilitas GDP *growth* dari negara di Asia terdapat perubahan pada *mean* sebaliknya, tiga dari empat volatilitas GDP dari negara di Eropa tidak terdapat perubahan pada *mean*. Sedangkan berdasarkan penerapan ITF, dapat dilihat adanya perubahan pada *mean* volatilitas GDP *growth* tidak terkait apakah negara tersebut menerapkan ITF atau tidak. Berikut diberikan contoh plot ACF dan PACF dari dua negara yaitu Jerman dan Malaysia untuk menunjukkan *autocorrelation function* dari volatilitas GDP *growth*.



Gambar 4.8a Plot ACF dan PACF Volatilitas GDP *Growth* Jerman



Gambar 4.8b Plot ACF dan PACF Volatilitas GDP *Growth* Malaysia

Pada plot terlihat bahwa ACF dan PACF Jerman memiliki pola *cut off* yang signifikan pada *lag* 4. Begitu juga pada ACF dan PACF Malaysia yang juga memiliki pola *cut off* yang signifikan pada *lag* 2.

Perubahan pada *mean* volatilitas GDP *growth* tersebut dapat diartikan bahwa terdapat perubahan struktur atau pergeseran nilai pada volatilitas GDP *growth* yang selanjutnya dikelompokkan ke dua kondisi yaitu resesi dan ekspansi. Pada penelitian ini, tidak adanya perubahan pada *mean* volatilitas GDP *growth* tetap dimodelkan dengan menggunakan model *Markov Switching*. Pemodelan *Markov Switching* pada penelitian ini dilakukan dengan menggunakan jumlah *regime* sebanyak dua, dimana *regime* 1 menunjukkan kondisi resesi dan *regime* 2 menunjukkan kondisi ekspansi pada volatilitas GDP *growth*. Pemodelan menggunakan model *Markov Switching* pada volatilitas GDP *growth* dibatasi menggunakan tiga model dugaan yaitu model MS-AR(1), MS-AR(2), dan MS-AR(3). Hasil estimasi parameter pada tiga model *Markov Switching* dugaan dari volatilitas GDP *growth* disajikan pada Tabel 4.8 berikut.

Tabel 4.8 Estimasi Parameter Model *Markov Switching* Volatilitas GDP Growth

Negara	Model	Regime	Parameter					AIC
			μ_i	$\phi_{1,i}$	$\phi_{2,i}$	$\phi_{3,i}$	p_{ii}	
GBR	MS-AR(1)	1	0,0628*	-0,0235			0,7445	47,36
		2	0,6700*	0,3725*			0,6732	
	MS-AR(2)	1	0,0359*	-0,035*	0,2192*		0,7684	59,86
		2	0,6381*	0,6411*	-0,1248		0,6499	
	MS-AR(3)	1	0,9390*	0,6828*	0,1526	-0,6044	0,4264	72,07
		2	0,0629*	-0,0198	0,1060*	0,1086*	0,7901	
CHE	MS-AR(1)	1	1,1171*	0,0376			0,3707	112,22
		2	0,1235*	-0,0043			0,5676	
	MS-AR(2)	1	1,2715*	0,0224	-0,4402		0,3550	110,99
		2	0,1306*	-0,0053	-0,0165		0,5706	
	MS-AR(3)	1	1,4215*	-0,0088	-0,5171	-0,2257	0,3449	108,79
		2	0,1193*	-0,0027	-0,0166	0,0294	0,5858	
IDN	MS-AR(1)	1	0,3598*	0,0994*			0,9322	305,12
		2	19,472*	-0,2088			0,7537	
	MS-AR(2)	1	0,1693*	0,1008*	0,1431*		0,8766	291,15
		2	9,1172	-0,1133	-0,1684		0,7480	
	MS-AR(3)	1	0,2686*	0,1037*	-0,098*	0,0972*	0,9048	230,46
		2	0,8269*	0,0898	0,0591*	1,5124*	0,6986	
PHL	MS-AR(1)	1	0,6844*	0,0001			0,8948	305,20
		2	9,8808*	-0,1319			0,4118	
	MS-AR(2)	1	10,706*	-0,1640	-0,0405		0,3218	294,35
		2	0,6209*	0,0002	0,0309*		0,9055	
	MS-AR(3)	1	13,3883	-0,0227	-0,4776	-1,3140	0,4332	293,60
		2	0,6266*	0,0006	0,0304*	0,0032	0,9078	
DEU	MS-AR(1)	1	0,4681*	0,0443			0,9261	214,35
		2	1,7170*	2,9879			0,3701	
	MS-AR(2)	1	0,4350	3,1278*	0,9457		0,2352	211,89
		2	0,3254*	0,0497*	0,0127		0,8245	
	MS-AR(3)	1	0,3404*	0,0531*	-0,0322	0,1938*	0,9159	216,14
		2	1,7118	3,0363*	-0,1177	-0,1628	0,3531	
DNK	MS-AR(1)	1	0,1276*	-0,0197			0,4456	264,64
		2	2,4097*	0,0622			0,6085	
	MS-AR(2)	1	0,1612*	-0,0186	-0,022*		0,4438	258,40
		2	2,5021*	0,0810	-0,1091		0,5976	
	MS-AR(3)	1	2,8188*	0,0339	-0,0997	-0,2511	0,5645	255,51
		2	0,1642*	-0,0175	-0,0208	-0,0028	0,4430	
MYS	MS-AR(1)	1	0,2955*	0,0596			0,7780	402,22
		2	10,609*	-0,1178			0,6693	
	MS-AR(2)	1	0,3402	0,0053	0,2309*		0,8826	434,14
		2	13,193*	-0,2896	-0,0189		0,7364	
	MS-AR(3)	1	0,2783	0,0035	0,2301*	0,0072	0,8759	425,04
		2	8,0887	-0,2669	-0,0826	1,1960*	0,7156	

Negara	Model	Regime	Parameter					AIC
			μ_i	$\phi_{1,i}$	$\phi_{2,i}$	$\phi_{3,i}$	p_{ii}	
SGP	MS-AR(1)	1	1,1594*	0,0089			0,8488	564,57
		2	12,728*	0,1747			0,8982	
	MS-AR(2)	1	0,4451	0,1262*	0,3486*		0,8652	568,11
		2	10,399*	0,4345	-0,2116		0,9219	
	MS-AR(3)	1	0,6839	0,1929*	-0,137*	0,1179*	0,8112	547,23
		2	4,9803	0,1778*	0,0218*	0,7230*	0,8605	

*parameter signifikan dengan $\alpha < 0,05$

Sumber: *Output Software R*, 2019

Dari hasil estimasi parameter model dugaan *Markov Switching* pada setiap negara diketahui bahwa tidak ada model yang keseluruhan parameternya signifikan. Olah karena itu, model terbaik dari hasil estimasi pada Tabel 4.8 dipilih berdasarkan nilai AIC yang paling kecil dan model dengan estimasi parameter *autoregressive* yang memenuhi syarat ($0 < |\phi_i| < 1$) baik pada model *regime* 1 maupun pada model *regime* 2. Sehingga diperoleh model *Markov Switching* terbaik untuk volatilitas GDP *growth* di setiap negara. Sesuai dengan persamaan (2.22) model terbaik tersebut dapat dituliskan seperti pada Tabel 4.9 berikut.

Tabel 4.9 Model *Markov Switching* Volatilitas GDP Growth Terbaik

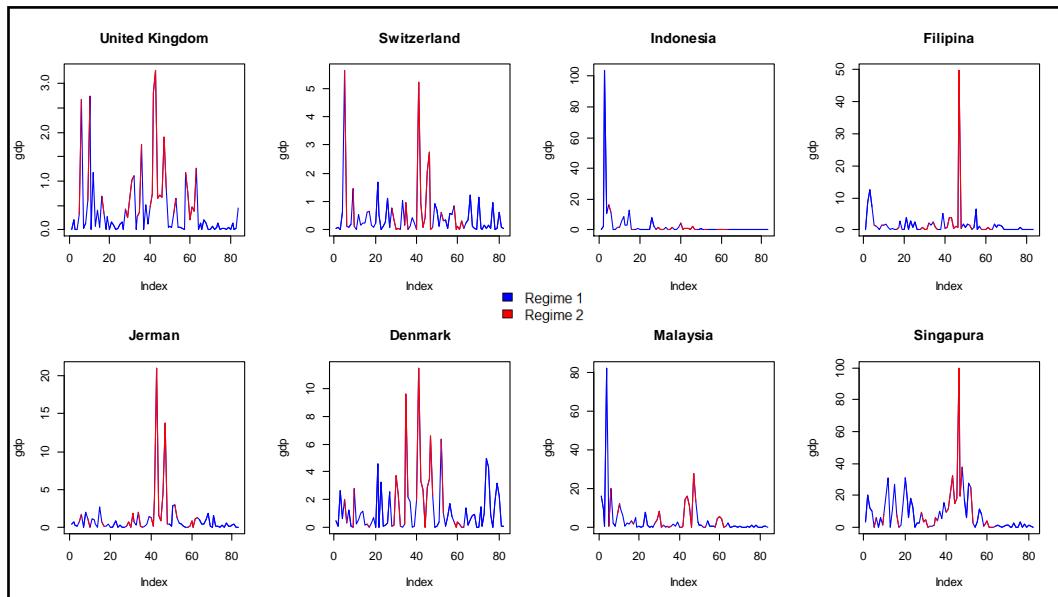
Negara	Persamaan	P
GBR MS-AR(1)	$y_t = \begin{cases} 0,0628 - 0,0235 y_{t-1} + a_{1t} & \text{untuk } S_t=1 \\ 0,6700 + 0,3725 y_{t-1} + a_{2t} & \text{untuk } S_t=2 \end{cases}$	$\mathbf{P} = \begin{bmatrix} 0,7445 & 0,3268 \\ 0,2555 & 0,6732 \end{bmatrix}$
CHE MS-AR(3)	$y_t = \begin{cases} 1,4215 - 0,0088 y_{t-1} - 0,5171 y_{t-2} - 0,2257 y_{t-3} + a_{1t} & \text{untuk } S_t=1 \\ 0,1193 - 0,0027 y_{t-1} - 0,0166 y_{t-2} + 0,0294 y_{t-3} + a_{2t} & \text{untuk } S_t=2 \end{cases}$	$\mathbf{P} = \begin{bmatrix} 0,3449 & 0,4142 \\ 0,6551 & 0,5858 \end{bmatrix}$
IDN MS-AR(2)	$y_t = \begin{cases} 0,1693 + 0,1008 y_{t-1} + 0,1434 y_{t-2} + a_{1t} & \text{untuk } S_t=1 \\ 9,1172 - 0,1133 y_{t-1} - 0,1684 y_{t-2} + a_{2t} & \text{untuk } S_t=2 \end{cases}$	$\mathbf{P} = \begin{bmatrix} 0,8766 & 0,2520 \\ 0,1234 & 0,7480 \end{bmatrix}$
PHL MS-AR(2)	$y_t = \begin{cases} 10,7056 - 0,1640 y_{t-1} - 0,0405 y_{t-2} + a_{1t} & \text{untuk } S_t=1 \\ 0,6209 + 0,0002 y_{t-1} + 0,0309 y_{t-2} + a_{2t} & \text{untuk } S_t=2 \end{cases}$	$\mathbf{P} = \begin{bmatrix} 0,3218 & 0,0945 \\ 0,6782 & 0,9055 \end{bmatrix}$
DEU MS-AR(2)	$y_t = \begin{cases} 0,4350 + 3,1278 y_{t-1} + 0,9457 y_{t-2} + a_{1t} & \text{untuk } S_t=1 \\ 0,3254 + 0,0497 y_{t-1} + 0,0127 y_{t-2} + a_{2t} & \text{untuk } S_t=2 \end{cases}$	$\mathbf{P} = \begin{bmatrix} 0,2352 & 0,1755 \\ 0,7648 & 0,8245 \end{bmatrix}$
DNK MS-AR(3)	$y_t = \begin{cases} 2,8188 + 0,0339 y_{t-1} - 0,0997 y_{t-2} - 0,2511 y_{t-3} + a_{1t} & \text{untuk } S_t=1 \\ 0,1642 - 0,0175 y_{t-1} - 0,0208 y_{t-2} - 0,0028 y_{t-3} + a_{2t} & \text{untuk } S_t=2 \end{cases}$	$\mathbf{P} = \begin{bmatrix} 0,5645 & 0,5570 \\ 0,4355 & 0,4430 \end{bmatrix}$
MYS MS-AR(1)	$y_t = \begin{cases} 0,2955 + 0,0596 y_{t-1} + a_{1t} & \text{untuk } S_t=1 \\ 10,6091 - 0,1178 y_{t-1} + a_{2t} & \text{untuk } S_t=2 \end{cases}$	$\mathbf{P} = \begin{bmatrix} 0,7780 & 0,3307 \\ 0,2220 & 0,6693 \end{bmatrix}$
SGP MS-AR(3)	$y_t = \begin{cases} 0,6839 + 0,1929 y_{t-1} - 0,1369 y_{t-2} + 0,1179 y_{t-3} + a_{1t} & \text{untuk } S_t=1 \\ 4,9803 + 0,1778 y_{t-1} + 0,0218 y_{t-2} + 0,7230 y_{t-3} + a_{2t} & \text{untuk } S_t=2 \end{cases}$	$\mathbf{P} = \begin{bmatrix} 0,8112 & 0,1395 \\ 0,1888 & 0,8605 \end{bmatrix}$

Sumber: *Output Software R*, 2019

Pada volatilitas GDP *growth* Switzerland, Denmark, dan Malaysia dipilih MS-AR(3) sebagai model terbaik dimana artinya volatilitas GDP *growth* pada bulan ini dipengaruhi oleh volatilitas GDP *growth* 3 bulan sebelumnya. Seperti pada Switzerland, dapat dilihat bahwa volatilitas GDP *growth* pada *regime* 1 dipengaruhi oleh volatilitas GDP *growth* satu bulan sebelumnya sebesar 0,0088, volatilitas GDP *growth* dua bulan sebelumnya sebesar 0,5171, dan volatilitas GDP *growth* tiga bulan sebelumnya sebesar 0,2257, sedangkan pada volatilitas GDP *growth* pada *regime* 2 dipengaruhi oleh volatilitas GDP *growth* satu bulan sebelumnya sebesar 0,0027, volatilitas GDP *growth* dua bulan sebelumnya sebesar 0,0166, dan volatilitas GDP *growth* tiga bulan sebelumnya sebesar -0,0294. Dan dari matriks transisi yang terbentuk diketahui bahwa apabila awalnya volatilitas GDP *growth* berada di *regime* 1, maka volatilitas GDP *growth* pada bulan selanjutnya akan tetap di *regime* 1 dengan probabilitas sebesar 0,3449 dan akan berpindah ke *regime* 2 dengan probabilitas sebesar 0,6551, begitu pula jika volatilitas GDP *growth* berada di *regime* 2, maka volatilitas GDP *growth* pada bulan selanjutnya akan tetap di *regime* 2 dengan probabilitas sebesar 0,5858 dan akan berpindah ke *regime* 1 dengan probabilitas sebesar 0,4142. Sedangkan volatilitas GDP *growth* Indonesia, Filipina, dan Jerman model terbaik yang terpilih yaitu MS-AR(2) dimana volatilitas GDP *growth* dipengaruhi volatilitas dua bulan sebelumnya. Pada volatilitas GDP *growth* United Kingdom dan Malaysia model terbaik yang terpilih yaitu MS-AR(1) yang artinya volatilitas GDP *growth* dipengaruhi oleh volatilitas GDP *growth* satu bulan sebelumnya. Selanjutnya, berdasarkan matriks *transition probability* yang diperoleh dapat dilihat bahwa pada keadaan resesi volatilitas GDP *growth* Switzerland, Filipina, dan Jerman memiliki probabilitas yang kecil ($P_{ii} < 0,5$) untuk tetap pada keadaan resesi. Hal ini merupakan hal yang baik bagi perekonomian karena volatilitas GDP *growth* negara tersebut akan cenderung berada pada keadaan resesi dalam waktu singkat dan berpindah ke keadaan ekspansi. Selain itu, probabilitas volatilitas GDP *growth* Denmark tetap pada keadaan ekspansi juga kecil ($P_{ii} < 0,5$) yang berarti volatilitas GDP *growth* Denmark akan cenderung berpindah dari keadaan ekspansi ke keadaan resesi. Sehingga untuk mempertahankan volatilitas

GDP *growth* pada keadaan ekspansi diperlukan peningkatan variabel ekonomi lain.

Pada Gambar 4.8 disajikan plot dari volatilitas GDP *growth* berdasarkan *regime*.



Gambar 4.8 Plot Time Series Volatilitas GDP Growth Berdasarkan *Regime*

Hasil pengklasifikasian *regime* menggunakan model *Markov Switching* ditunjukkan pada Gambar 4.8 dimana volatilitas GDP *growth* setiap negara diplotkan sesuai dengan warna sesuai *regime*. Plot berwarna biru menunjukkan bahwa volatilitas berada pada *regime* 1 yaitu pada keadaan resesi sedangkan plot berwarna merah menunjukkan bahwa volatilitas berada pada *regime* 2 yaitu pada keadaan ekspansi. Terlihat pada Gambar 4.8, volatilitas GDP *growth* Filipina dan Jerman yang diklasifikasikan ke *regime* 1 memiliki jumlah yang paling sedikit. Hal tersebut dapat dikarenakan adanya data ekstrim ataupun model *Markov Switching* yang kurang sesuai.

4.2.3 Klasifikasi Hasil *Markov Switching*

Analisis selanjutnya yaitu pemodelan regresi probit. Pada pemodelan ini variabel respon yang digunakan adalah klasifikasi *regime* volatilitas GDP *growth* yang diperoleh dari analisis sebelumnya dan variabel prediktor yang digunakan adalah volatilitas *money supply*, *inflation*, *interest rate*, dan *exchange rate*.

Pemodelan dilakukan untuk mengetahui apakan variabel prediktor tersebut berpengaruh terhadap klasifikasi *regime* volatilitas GDP *growth* dan untuk mengetahui besarnya peluang volatilitas GDP *growth* berada pada *regime* 1 dan *regime* 2 berdasarkan volatilitas *money supply*, *inflation*, *interest rate*, dan *exchange rate*. Sebelum dilakukan pemodelan regresi probit tersebut, terlebih dahulu dilakukan pengujian multikolinieritas atau pengujian adanya hubungan secara linier antar variabel prediktor. Dalam pengujian multikolinieritas dapat dikatakan terjadi masalah multikolinieritas apabila nilai VIF lebih dari 10. Berdasarkan hasil perhitungan diperoleh nilai VIF sebagai berikut.

Tabel 4.10 Nilai VIF Variabel Prediktor Regresi Probit

Negara	Variabel			
	<i>Money Supply</i>	<i>Inflation</i>	<i>Interest Rate</i>	<i>Exchange Rate</i>
GBR	1,0562	1,0485	1,0458	1,0567
CHE	1,0187	1,1601	1,1642	1,3070
IDN	1,2180	1,6827	1,8365	1,3701
PHL	1,0261	1,9192	1,2073	2,1624
DEU	1,1180	1,0372	1,0911	1,0057
DNK	1,0271	1,0137	1,0552	1,0483
MYS	1,1058	1,0106	1,3752	1,4548
SGP	1,0569	1,0231	1,0359	1,0022

Sumber: *Output Software R*, 2019

Hasil perhitungan nilai VIF pada Tabel 4.10 menunjukkan bahwa nilai VIF dari semua variabel di setiap negara kurang dari 10 sehingga dapat disimpulkan bahwa tidak terjadi masalah multikolinieritas atau tidak ada hubungan secara linier antar variabel prediktor sehingga analisis regresi probit dapat dilakukan. Hasil estimasi parameter regresi probit disajikan pada Tabel 4.11 berikut.

Tabel 4.11 Estimasi Parameter Regresi Probit

Negara	Variabel				
	β_0	β_1	β_2	β_3	β_4
GBR	-0,4763*	-34,6035	7,2461	3,8807	-102,0718
CHE	0,7191*	-1172,8960	0,0862	-4,3927	-98,3467
IDN	-0,4121	-101943,1141*	0,0011	-0,0198	0,0002*
PHL	1,3179*	108294,4391	-0,5549	-0,0014	0,0333
DEU	2,2472*	-261,5861*	-5,4028*	-5,4966*	-444,1338

Negara	Variabel				
	β_0	β_1	β_2	β_3	β_4
DNK	0,4403	-22319,4433	-3,1925	-6,8424	2,6205
MYS	-0,3159	-22810,5046	0,0428	3,6535	-36,4609
SGP	-0,9163*	7359,4834	0,4221	3,4833	1767,2738*

*parameter signifikan dengan $\alpha < 0,05$

Sumber: *Output Software R*, 2019

Hasil estimasi regresi probit pada Tabel 4.11 menunjukkan bahwa banyak parameter regresi probit yang tidak signifikan. Hal ini akan menyebabkan prediksi *regime* tidak sesuai dengan *regime* sesungguhnya. Selanjutnya hasil estimasi tersebut dimasukkan ke model sesuai dengan persamaan (2.40) dan persamaan (2.41) dan disajikan pada Tabel 4.12 berikut.

Tabel 4.12 Model Regresi Probit

Negara	Model
GBR	$P(Y = 0 \mathbf{X}) = \Phi(-0,4763 - 34,6035x_1 + 0,72461x_2 + 3,8807x_3 - 102,0718x_4)$
	$P(Y = 1 \mathbf{X}) = 1 - \Phi(-0,4763 - 34,6035x_1 + 0,72461x_2 + 3,8807x_3 - 102,0718x_4)$
CHE	$P(Y = 0 \mathbf{X}) = \Phi(0,7191 - 1172,8960x_1 + 0,0862x_2 - 4,3930x_3 - 98,3467x_4)$
	$P(Y = 1 \mathbf{X}) = 1 - \Phi(0,7191 - 1172,8960x_1 + 0,0862x_2 - 4,3930x_3 - 98,3467x_4)$
IDN	$P(Y = 0 \mathbf{X}) = \Phi(-0,4121 - 101943,1141x_1 + 0,0011x_2 - 0,0198x_3 + 0,0002x_4)$
	$P(Y = 1 \mathbf{X}) = 1 - \Phi(-0,4121 - 101943,1141x_1 + 0,0011x_2 - 0,0198x_3 + 0,0002x_4)$
PHL	$P(Y = 0 \mathbf{X}) = \Phi(1,3179 + 108294,4391x_1 - 0,5549x_2 - 0,0014x_3 + 0,0333x_4)$
	$P(Y = 1 \mathbf{X}) = 1 - \Phi(1,3179 + 108294,4391x_1 - 0,5549x_2 - 0,0014x_3 + 0,0333x_4)$
DEU	$P(Y = 0 \mathbf{X}) = \Phi(2,2472 - 261,5861x_1 - 5,4028x_2 - 5,4966x_3 - 444,1338x_4)$
	$P(Y = 1 \mathbf{X}) = 1 - \Phi(2,2472 - 261,5861x_1 - 5,4028x_2 - 5,4966x_3 - 444,1338x_4)$
DNK	$P(Y = 0 \mathbf{X}) = \Phi(0,4403 - 22319,4433x_1 - 3,1925x_2 - 6,8424x_3 + 2,6205x_4)$
	$P(Y = 1 \mathbf{X}) = 1 - \Phi(0,4403 - 22319,4433x_1 - 3,1925x_2 - 6,8424x_3 + 2,6205x_4)$
MYS	$P(Y = 0 \mathbf{X}) = \Phi(-0,3159 - 22810,5046x_1 + 0,0428x_2 + 3,6535x_3 - 36,4609x_4)$
	$P(Y = 1 \mathbf{X}) = 1 - \Phi(-0,3159 - 22810,5046x_1 + 0,0428x_2 + 3,6535x_3 - 36,4609x_4)$
SGP	$P(Y = 0 \mathbf{X}) = \Phi(-0,9163 + 7359,4834x_1 + 0,4221x_2 + 3,4833x_3 + 1767,2728x_4)$
	$P(Y = 1 \mathbf{X}) = 1 - \Phi(-0,9163 + 7359,4834x_1 + 0,4221x_2 + 3,4833x_3 + 1767,2728x_4)$

Sumber: *Output Software R*, 2019

Hasil estimasi pada Tabel 4.12 menunjukkan model prediksi probabilitas volatilitas GDP *growth* berada pada *regime* 1 dan *regime* 2 berdasarkan nilai volatilitas *money supply*, *inflation*, *interest rate*, dan *exchange rate*. Misalkan United Kingdom memiliki volatilitas *money supply* sebesar 0,0014, volatilitas

inflation sebesar 0,0420, volatilitas *interest rate* sebesar 0,0006, dan volatilitas *exchange rate* sebesar 0,0002, maka probabilitas volatilitas GDP *growth* United Kingdom berada pada *regime* 1 sebesar 0,4057 dan probabilitas volatilitas GDP *growth* United Kingdom berada pada *regime* 2 sebesar 0,5943. Dari hasil perhitungan tersebut diketahui probabilitas volatilitas GDP *growth* United Kingdom berada pada *regime* 2 lebih besar dari pada di *regime* 2, sehingga pada kasus tersebut volatilitas GDP *growth* United Kingdom berada pada *regime* 2 yaitu pada keadaan ekspansi. Pada estimasi parameter dan model regresi probit yang diperoleh sebelumnya telah diketahui bahwa parameter yang terbentuk tidak semuanya signifikan, maka selanjutnya akan dilakukan pemodelan regresi probit dengan metode *stepwise* untuk memperoleh model dengan parameter yang signifikan seluruhnya. Hasil estimasi metode *stepwise* disajikan pada Tabel 4.13.

Tabel 4.13 Estimasi Parameter Regresi Probit *Stepwise*

Negara	Variabel				
	β_0	β_1	β_2	β_3	β_4
GBR	-0,5313	-	8,0159	-	-
IDN	-0,4197	-100180,6421	-	-	0,0002
DEU	1,1357	-	-	-4,6965	-
SGP	-0,4902	-	-	-	1702,7104

Sumber: *Output Software R*, 2019

Selanjutnya hasil estimasi parameter pada Tabel 4.13 dimasukkan ke model sesuai dengan persamaan (2.40) dan persamaan (2.41) dan disajikan pada Tabel 4.14.

Tabel 4.14 Model Regresi Probit

Negara	Model
GBR	$P(Y=0 \mathbf{X}) = \Phi(0,5313 - 8,0519x_2)$
	$P(Y=1 \mathbf{X}) = 1 - \Phi(0,5313 - 8,0519x_2)$
IDN	$P(Y=0 \mathbf{X}) = \Phi(0,4191 + 100180,6421x_1 + 0,0002x_4)$
	$P(Y=1 \mathbf{X}) = 1 - \Phi(0,4191 + 100180,6421x_1 + 0,0002x_4)$
DEU	$P(Y=0 \mathbf{X}) = \Phi(-1,1357 + 4,6965x_3)$
	$P(Y=1 \mathbf{X}) = 1 - \Phi(-1,1357 + 4,6965x_3)$
SGP	$P(Y=0 \mathbf{X}) = \Phi(0,4902 - 1702,7104x_4)$
	$P(Y=1 \mathbf{X}) = 1 - \Phi(0,4902 - 1702,7104x_4)$

Sumber: *Output Software R*, 2019

Dari hasil metode *stepwise*, Switzerland, Filipina, Denmark, dan Malaysia tidak memiliki model dengan keseluruhan parameter yang signifikan. Sedangkan untuk United Kingdom dapat dilihat pada model yang terbentuk, *regime* volatilitas GDP *growth* dipengaruhi signifikan oleh *inflation*. Sementara pada model Indonesia terdapat 2 variabel yang berpengaruh signifikan terhadap *regime* volatilitas GDP *growth* yaitu *money supply* dan *exchange rate*. sedangkan variabel yang berpengaruh signifikan pada Jerman dan Singapura berturut-turut yaitu *interest rate* dan *exchange rate*.

Kebaikan model regresi probit diukur dari ketepatan klasifikasi dengan menghitung nilai APPER berdasarkan tabel klasifikasi sesuai dengan persamaan (2.52) seperti pada Tabel 4.15 berikut.

Tabel 4.15 Tabel Klasifikasi dan Perhitungan Nilai APPER

Negara	APPER sebelum <i>stepwise</i>			APPER setelah <i>stepwise</i>				
	Obsevasi	Prediksi		Total	Obsevasi	Prediksi		Total
		1	2			1	2	
GBR	1	40	8	48		43	5	48
	2	27	9	36		28	8	36
	Total	67	17	84		61	13	84
		$APPER = \frac{27+8}{84} = 0,4167$				$APPER = \frac{28+5}{84} = 0,3929$		
CHE	Obsevasi	Prediksi		Total		Prediksi		Total
		1	2			1	2	
	1	5	22	27		5	22	27
	2	1	54	55		1	54	55
IDN	Total	6	76	82		Stepwise menghasilkan semua prediktor tidak signifikan		
		$APPER = \frac{1+22}{82} = 0,2805$						
	Obsevasi	Prediksi		Total		Prediksi		Total
		1	2			1	2	
	1	58	1	59		58	1	59
	2	18	6	24		18	6	24
	Total	76	7	83		76	7	83
		$APPER = \frac{18+1}{83} = 0,2289$				$APPER = \frac{18+1}{83} = 0,2289$		

	Negara	APPER sebelum <i>stepwise</i>	APPER setelah <i>stepwise</i>																																				
PHL		<table border="1"> <thead> <tr> <th rowspan="2">Obsevasi</th> <th colspan="2">Prediksi</th> <th rowspan="2">Total</th> </tr> <tr> <th>1</th> <th>2</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>0</td> <td>9</td> <td>9</td> </tr> <tr> <td>2</td> <td>1</td> <td>73</td> <td>74</td> </tr> <tr> <td>Total</td> <td>1</td> <td>82</td> <td>83</td> </tr> </tbody> </table> $APPER = \frac{1+9}{83} = 0,1205$	Obsevasi	Prediksi		Total	1	2	1	0	9	9	2	1	73	74	Total	1	82	83	<i>Stepwise</i> menghasilkan semua prediktor tidak signifikan																		
Obsevasi	Prediksi			Total																																			
	1	2																																					
1	0	9	9																																				
2	1	73	74																																				
Total	1	82	83																																				
DEU		<table border="1"> <thead> <tr> <th rowspan="2">Obsevasi</th> <th colspan="2">Prediksi</th> <th rowspan="2">Total</th> </tr> <tr> <th>1</th> <th>2</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>3</td> <td>11</td> <td>14</td> </tr> <tr> <td>2</td> <td>1</td> <td>68</td> <td>69</td> </tr> <tr> <td>Total</td> <td>4</td> <td>79</td> <td>83</td> </tr> </tbody> </table> $APPER = \frac{1+11}{83} = 0,1446$	Obsevasi	Prediksi		Total	1	2	1	3	11	14	2	1	68	69	Total	4	79	83	<table border="1"> <thead> <tr> <th rowspan="2">Obsevasi</th> <th colspan="2">Prediksi</th> <th rowspan="2">Total</th> </tr> <tr> <th>1</th> <th>2</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>2</td> <td>12</td> <td>14</td> </tr> <tr> <td>2</td> <td>1</td> <td>68</td> <td>69</td> </tr> <tr> <td>Total</td> <td>3</td> <td>80</td> <td>83</td> </tr> </tbody> </table> $APPER = \frac{1+12}{83} = 0,1566$	Obsevasi	Prediksi		Total	1	2	1	2	12	14	2	1	68	69	Total	3	80	83
Obsevasi	Prediksi			Total																																			
	1	2																																					
1	3	11	14																																				
2	1	68	69																																				
Total	4	79	83																																				
Obsevasi	Prediksi		Total																																				
	1	2																																					
1	2	12	14																																				
2	1	68	69																																				
Total	3	80	83																																				
DNK		<table border="1"> <thead> <tr> <th rowspan="2">Obsevasi</th> <th colspan="2">Prediksi</th> <th rowspan="2">Total</th> </tr> <tr> <th>1</th> <th>2</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>26</td> <td>18</td> <td>44</td> </tr> <tr> <td>2</td> <td>14</td> <td>24</td> <td>38</td> </tr> <tr> <td>Total</td> <td>40</td> <td>42</td> <td>82</td> </tr> </tbody> </table> $APPER = \frac{14+18}{82} = 0,3902$	Obsevasi	Prediksi		Total	1	2	1	26	18	44	2	14	24	38	Total	40	42	82	<i>Stepwise</i> menghasilkan semua prediktor tidak signifikan																		
Obsevasi	Prediksi			Total																																			
	1	2																																					
1	26	18	44																																				
2	14	24	38																																				
Total	40	42	82																																				
MYS		<table border="1"> <thead> <tr> <th rowspan="2">Obsevasi</th> <th colspan="2">Prediksi</th> <th rowspan="2">Total</th> </tr> <tr> <th>1</th> <th>2</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>53</td> <td>1</td> <td>54</td> </tr> <tr> <td>2</td> <td>27</td> <td>3</td> <td>30</td> </tr> <tr> <td>Total</td> <td>80</td> <td>4</td> <td>84</td> </tr> </tbody> </table> $APPER = \frac{27+1}{84} = 0,3333$	Obsevasi	Prediksi		Total	1	2	1	53	1	54	2	27	3	30	Total	80	4	84	<i>Stepwise</i> menghasilkan semua prediktor tidak signifikan																		
Obsevasi	Prediksi			Total																																			
	1	2																																					
1	53	1	54																																				
2	27	3	30																																				
Total	80	4	84																																				
SGP		<table border="1"> <thead> <tr> <th rowspan="2">Obsevasi</th> <th colspan="2">Prediksi</th> <th rowspan="2">Total</th> </tr> <tr> <th>1</th> <th>2</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>27</td> <td>13</td> <td>40</td> </tr> <tr> <td>2</td> <td>18</td> <td>24</td> <td>42</td> </tr> <tr> <td>Total</td> <td>45</td> <td>37</td> <td>82</td> </tr> </tbody> </table> $APPER = \frac{18+13}{82} = 0,3780$	Obsevasi	Prediksi		Total	1	2	1	27	13	40	2	18	24	42	Total	45	37	82	<table border="1"> <thead> <tr> <th rowspan="2">Obsevasi</th> <th colspan="2">Prediksi</th> <th rowspan="2">Total</th> </tr> <tr> <th>1</th> <th>2</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>30</td> <td>10</td> <td>40</td> </tr> <tr> <td>2</td> <td>19</td> <td>23</td> <td>42</td> </tr> <tr> <td>Total</td> <td>49</td> <td>33</td> <td>82</td> </tr> </tbody> </table> $APPER = \frac{19+10}{82} = 0,3537$	Obsevasi	Prediksi		Total	1	2	1	30	10	40	2	19	23	42	Total	49	33	82
Obsevasi	Prediksi			Total																																			
	1	2																																					
1	27	13	40																																				
2	18	24	42																																				
Total	45	37	82																																				
Obsevasi	Prediksi		Total																																				
	1	2																																					
1	30	10	40																																				
2	19	23	42																																				
Total	49	33	82																																				

Sumber: *Output Software R*, 2019

Nilai perhitungan APPER pada Tabel 4.11 menunjukkan proporsi sampel yang salah atau tidak tepat diklasifikasikan oleh model. Sehingga kesimpulan dari nilai APPER tersebut adalah proporsi kesalahan klasifikasi pada volatilitas GDP *growth* United Kingdom sebesar 0,4167, proporsi kesalahan klasifikasi pada

volatilitas GDP *growth* Switzerland sebesar 0,2805, proporsi kesalahan klasifikasi pada volatilitas GDP *growth* Indonesia sebesar 0,2289, proporsi kesalahan klasifikasi pada volatilitas GDP *growth* Filipina sebesar 0,1205, proporsi kesalahan klasifikasi pada volatilitas GDP *growth* Jerman sebesar 0,1446, proporsi kesalahan klasifikasi pada volatilitas GDP *growth* Denmark sebesar 0,3902, proporsi kesalahan klasifikasi pada volatilitas GDP *growth* Malaysia sebesar 0,3333, proporsi kesalahan klasifikasi pada volatilitas GDP *growth* Singapura sebesar 0,3780. Proporsi kesalahan klasifikasi tertinggi yaitu pada volatilitas GDP *growth* United Kingdom sedangkan yang terendah pada volatilitas GDP *growth* Filipina. Hasil perhitungan APPER pada Tabel 4.11 tersebut selanjutnya digunakan untuk menghitung presentase ketepatan klasifikasi sesuai persamaan (2.53) yang disajikan pada Tabel 4.16 berikut.

Tabel 4.16 Ketepatan Klasifikasi *Regime*

Negara	Sebelum Stepwise		Setelah Stepwise	
	APPER	Ketepatan Klasifikasi	APPER	Ketepatan Klasifikasi
GBR	0,4167	58,33%	0,3929	60,71%
CHE	0,2805	71,95%	-	-
IDN	0,2289	77,11%	0,2289	77,11%
PHL	0,1205	87,95%	-	-
DEU	0,1446	85,54%	0,1566	84,34%
DNK	0,3902	60,98%	-	-
MYS	0,3333	66,67%	-	-
SGP	0,3780	62,20%	0,3537	64,63%

Sumber: *Output Software R*, 2019

Pada presentase ketepatan klasifikasi pada Tabel 4.16, dapat dilihat bahwa hasil ketepatan klasifikasi setelah dilakukan metode *stepwise* tidak jauh berbeda dibandingkan dengan sebelum dilakukan metode *stepwise*. Artinya dengan digunakannya variabel dengan korelasi tertinggi tidak menghasilkan klasifikasi yang mendekati klasifikasi yang sebenarnya. Hasil tersebut mungkin disebabkan oleh volatilitas *money supply*, *inflation*, *interest rate*, dan *exchange rate* kurang dapat digunakan untuk mengklasifikasikan volatilitas GDP *growth*. Sementara itu, berdasarkan Tabel 4.16 dapat diketahui bahwa United Kingdom memiliki ketepatan klasifikasi sebesar 58,33%, Switzerland memiliki ketepatan klasifikasi

sebesar 71,95%, Indonesia memiliki ketepatan klasifikasi sebesar 77,11%, Filipina memiliki ketepatan klasifikasi sebesar 87,95%, Jerman memiliki ketepatan klasifikasi sebesar 85,54%, Denmark memiliki ketepatan klasifikasi sebesar 60,98%, Malaysia memiliki ketepatan klasifikasi sebesar 66,67%, Singapura memiliki ketepatan klasifikasi sebesar 62,20%. Presentase ketepatan klasifikasi tertinggi yaitu pada model regresi probit Filipina sedangkan yang terendah yaitu pada model regresi probit United Kingdom. Ketepatan klasifikasi ke *regime* hasil pemodelan *Markov Switching* disimpulkan tidak terkait apakah negara tersebut menerapkan ITF atau tidak. Hasil perhitungan diatas menunjukkan bahwa pemodelan regresi probit pada volatilitas GDP *growth* tidak menghasilkan pengklasifikasian *regime* yang sesuai. Kesimpulan tersebut dibuktikan dengan besarnya nilai APPER dan kecilnya presentase ketepatan klasifikasi. Pengklasifikasian volatilitas GDP *growth* pada setiap negara dengan menggunakan regresi probit yang tidak sesuai tersebut dapat juga disebabkan oleh parameter model *Markov Switching* yang tidak signifikan sehingga menghasilkan klasifikasi *regime* yang kurang tepat.

4.2.4 Penaksiran Parameter *Long Memory* dan Pemodelan *Cointegration*

Selanjutnya dilakukan estimasi parameter *long memory* pada volatilitas GDP *growth* dan variabel agregasi dari volatilitas *money supply*, *inflation*, *interest rate*, dan *exchange rate*. Estimasi dilakukan menggunakan estimasi *exact local Whittle*. Hasil estimasi disajikan pada Tabel 4.17 berikut.

Tabel 4.17 Estimasi Parameter *Long Memory* Variabel

Negara	Regime	GDP Growth	Money Supply	Inflation	Interest Rate	Exchange Rate
GBR	1	0,3582	0,5038	0,3945	0,3182	0,2499
	2	0,6980	0,3368	0,8232	0,3726	0,7995
CHE	1	0,4007	0,3739	0,0526	0,5673	0,4068
	2	0,5444	0,5958	0,7802	0,2145	0,5874
IDN	1	0,3120	0,5963	0,9974	0,2938	0,1749
	2	0,4034	0,7511	0,9331	0,5122	0,1535
PHL	1	0,5046	-0,4999	-0,0162	0,5309	-0,0095
	2	0,2244	0,5434	0,5153	0,7903	0,3455
DEU	1	0,2433	0,6968	0,6771	0,5632	0,6909
	2	0,7857	0,5457	0,1776	0,2922	0,3024

Negara	Regime	GDP Growth	Money Supply	Inflation	Interest Rate	Exchange Rate
DNK	1	0,6399	0,8390	0,5660	0,2427	-0,4049
	2	0,5352	0,5748	-0,3347	-0,0970	-0,4183
MYS	1	0,4944	0,7513	-0,2064	0,1085	0,1980
	2	0,5361	0,7610	0,3008	0,4146	0,1382
SGP	1	0,3763	0,1206	0,6064	0,1397	0,8575
	2	0,7493	0,3322	0,4340	0,6023	0,5779

Sumber: *Output Software R*, 2019

Hasil estimasi parameter *long memory* (d) pada volatilitas GDP *growth* pada saat resesi menunjukkan bahwa United Kingdom, Switzerland, Indonesia, Jerman, Malaysia, dan Singapura memiliki nilai d yang terletak antara $0 < d < 0,5$ yang menyatakan proses berkorelasi panjang stasioner dengan adanya ketergantungan positif antar volatilitas GDP *growth* yang terpisah jauh, sedangkan Filipina dan Denmark memiliki nilai d yang terletak antara $0,5 < d < 1$ yang menyatakan proses berkorelasi panjang nonstasioner dengan adanya ketergantungan positif antar volatilitas GDP *growth* yang terpisah jauh. Selain itu hasil estimasi volatilitas GDP *growth* pada saat ekspansi menunjukkan bahwa Indonesia dan Filipina memiliki nilai d yang terletak antara $0 < d < 0,5$ yang menyatakan proses berkorelasi panjang stasioner dengan adanya ketergantungan positif antar volatilitas GDP *growth* yang terpisah jauh, sedangkan United Kingdom, Switzerland, Jerman, Denmark, Malaysia, dan Singapura memiliki nilai d yang terletak antara $0,5 < d < 1$ yang menyatakan proses berkorelasi panjang nonstasioner dengan adanya ketergantungan positif antar volatilitas GDP *growth* yang terpisah jauh. Dapat dilihat bahwa pada keadaan resesi volatilitas GDP *growth* cenderung memiliki nilai d yang menyatakan proses *long memory* stasioner dan pada keadaan ekspansi volatilitas GDP *growth* cenderung memiliki nilai d yang menyatakan proses *long memory* nonstasioner. Sama seperti volatilitas GDP *growth*, pada volatilitas variabel lain banyak terdapat indikasi *long memory* nonstasioner pada data. Hal tersebut mengakibatkan periode jangka panjang yang mempengaruhi data sulit dijelaskan. Untuk mengatasi hal tersebut dapat dilakukan *cointegration* pada variabel. Pemodelan *cointegration* dilakukan

dengan mengestimasi parameter *cointegration* dan parameter *long memory* pada residual model *cointegration*. Hasil estimasi disajikan pada Tabel 4.18 berikut.

Tabel 4.18 Estimasi Parameter Model *Cointegration*

Negara	Regime	Variabel				
		Money Supply	Inflation	Interest Rate	Exchange Rate	Residual
		β_1	β_2	β_3	β_4	d
GBR	1	-0,5512	4,2250	5,8782	-13,1127	0,1218
	2	0,6814	-9,9888	5,8252	0,8551	0,3077
CHE	1	-0,0042	-0,6415	-11,6091	-0,2465	0,4304
	2	-0,0015	1,4897	1,5947	0,0309	0,3307
IDN	1	$0,49 \times 10^{-6}$	-0,1823	2,2496	$0,32 \times 10^{-4}$	0,4234
	2	$-0,54 \times 10^{-5}$	-1,6814	4,7572	$-0,54 \times 10^{-5}$	0,0896
PHL	1	$-0,01 \times 10^{-4}$	-10,2423	0,3330	3,0599	0,4999
	2	$-0,06 \times 10^{-4}$	27,1451	-33,5914	18,3222	0,1670
DEU	1	-0,2209	3,8313	12,6459	-0,0165	0,0318
	2	0,0269	30,3999	4,7041	0,0600	0,2295
DNK	1	0,0007	-7,2366	-1,5028	10,9890	0,0177
	2	0,0171	-43,9153	47,2147	32,7340	0,3957
MYS	1	-0,0327	1,2871	28,0826	-122,5699	0,3004
	2	-0,0046	128,5876	43,7091	-120,8222	0,1510
SGP	1	-0,7571	33,8756	137,5434	-0,7477	0,1979
	2	0,0155	35,0394	5,9160	-0,0178	0,3731

Sumber: *Output Software R*, 2019

Dari estimasi parameter *cointegration* dan parameter *long memory* residual pada Tabel 4.18 dibentuk model *cointegration* sesuai dengan persamaan (2.64) yang disajikan pada Tabel 4.19 berikut.

Tabel 4.19 Model *Cointegration*

Negara	Persamaan
GBR	$y_t = \begin{cases} -0,5512x_{1t} + 4,2250x_{2t} + 5,8782x_{3t} - 13,1127x_{4t} + u_{1t} & \text{dengan } u_{1t} = (1-B)^{-0,1218} \varepsilon_{1t} \\ 0,6814x_{1t} - 9,9888x_{2t} + 5,8252x_{3t} + 0,8551x_{4t} + u_{2t} & \text{dengan } u_{2t} = (1-B)^{-0,3077} \varepsilon_{2t} \end{cases}$
CHE	$y_t = \begin{cases} -0,0042x_{1t} - 0,6415x_{2t} - 11,6091x_{3t} - 0,2465x_{4t} + u_{1t} & \text{dengan } u_{1t} = (1-B)^{-0,4304} \varepsilon_{1t} \\ -0,0015x_{1t} + 1,4897x_{2t} + 1,5947x_{3t} + 0,0309x_{4t} + u_{2t} & \text{dengan } u_{2t} = (1-B)^{-0,3307} \varepsilon_{2t} \end{cases}$
IDN	$y_t = \begin{cases} (0,49 \times 10^{-6})x_{1t} - 0,1823x_{2t} + 2,2496x_{3t} + (0,32 \times 10^{-4})x_{4t} + u_{1t} & \text{dengan } u_{1t} = (1-B)^{-0,4234} \varepsilon_{1t} \\ -(0,54 \times 10^{-5})x_{1t} - 1,6814x_{2t} + 4,7572x_{3t} - (0,54 \times 10^{-5})x_{4t} + u_{2t} & \text{dengan } u_{2t} = (1-B)^{-0,0896} \varepsilon_{2t} \end{cases}$
PHL	$y_t = \begin{cases} (-0,01 \times 10^{-4})x_{1t} - 10,2423x_{2t} + 0,3330x_{3t} + 3,0599x_{4t} + u_{1t} & \text{dengan } u_{1t} = (1-B)^{-0,4999} \varepsilon_{1t} \\ (-0,06 \times 10^{-4})x_{1t} + 27,1451x_{2t} - 33,5914x_{3t} + 18,3222x_{4t} + u_{2t} & \text{dengan } u_{2t} = (1-B)^{-0,1670} \varepsilon_{2t} \end{cases}$
DEU	$y_t = \begin{cases} -0,2209x_{1t} + 3,8381x_{2t} + 12,6459x_{3t} - 0,0165x_{4t} + u_{1t} & \text{dengan } u_{1t} = (1-B)^{-0,0318} \varepsilon_{1t} \\ 0,0269x_{1t} + 30,3999x_{2t} + 4,7041x_{3t} + 0,0600x_{4t} + u_{2t} & \text{dengan } u_{2t} = (1-B)^{-0,2295} \varepsilon_{2t} \end{cases}$

Negara	Persamaan
DNK	$y_t = \begin{cases} 0,0007x_{1t} - 7,2366x_{2t} - 1,5028x_{3t} + 10,9890x_{4t} + u_{1t} \\ 0,0171x_{1t} - 43,9153x_{2t} + 47,2147x_{3t} + 32,7340x_{4t} + u_{2t} \end{cases}$ dengan $u_{1t} = (1-B)^{-0,0177} \varepsilon_{1t}$ $u_{2t} = (1-B)^{-0,3957} \varepsilon_{2t}$
MYS	$y_t = \begin{cases} -0,0327x_{1t} + 1,2871x_{2t} + 28,0826x_{3t} - 122,5699x_{4t} + u_{1t} \\ -0,0046x_{1t} + 128,5876x_{2t} + 43,7091x_{3t} - 120,8222x_{4t} + u_{2t} \end{cases}$ dengan $u_{1t} = (1-B)^{-0,3004} \varepsilon_{1t}$ $u_{2t} = (1-B)^{-0,1510} \varepsilon_{2t}$
SGP	$y_t = \begin{cases} -0,7571x_{1t} + 33,8756x_{2t} + 137,5434x_{3t} - 0,7477x_{4t} + u_{1t} \\ 0,0155x_{1t} + 35,0394x_{2t} + 5,9160x_{3t} - 0,0178x_{4t} + u_{2t} \end{cases}$ dengan $u_{1t} = (1-B)^{-0,1979} \varepsilon_{1t}$ $u_{2t} = (1-B)^{-0,3731} \varepsilon_{2t}$

Sumber: *Output Software R*, 2019

Model pada Tabel 4.19 menunjukkan bahwa residual model *cointegration* pada setiap *regime* di semua negara merupakan proses *long memory* yang stasioner ditandai dengan $0 < d < 0,5$ dimana berarti proses berkorelasi panjang stasioner dengan adanya ketergantungan positif antar residual yang terpisah jauh sehingga dapat disimpulkan bahwa terdapat hubungan *cointegration* pada variabel ekonomi tersebut. Dari kesimpulan tersebut dapat diartikan bahwa volatilitas GDP *growth*, *money supply*, *inflation*, *interest rate*, dan *exchange rate* pada setiap *regime* di semua negara merupakan proses *long memory* dengan periode yang berdekatan antar masing-masing variabel.

4.3 Evaluasi Penerapan *Inflation Targeting Framework* Terhadap *Gross Domestic Product*

Berdasarkan teori ekonomi dan beberapa penelitian sebelumnya dari berbagai negara, telah diketahui bahwa volatilitas *money supply*, *inflation*, *interest rate*, dan *exchange rate* berpengaruh secara signifikan terhadap volatilitas GDP *growth*. Dan berdasarkan model *cointegration* yang diperoleh pada penelitian ini, pada saat resesi, perubahan pada volatilitas *inflation*, *interest rate*, dan *exchange rate* akan menyebabkan perubahan yang relatif besar pada volatilitas GDP *growth* dari negara yang menerapkan ITF di Eropa (United Kingdom dan Switzerland) dan negara yang tidak menerapkan ITF di Eropa (Jerman dan Denmark). Sedangkan perubahan pada volatilitas *money supply* akan menyebabkan perubahan yang relatif kecil pada volatilitas GDP *growth* dari negara yang menerapkan ITF di Eropa maupun negara yang tidak menerapkan ITF di Eropa.

Sementara itu pada saat ekspansi, perubahan pada volatilitas *inflation* dan *interest rate* akan menyebabkan perubahan yang relatif besar pada volatilitas GDP

growth dari negara yang menerapkan ITF di Eropa dan perubahan pada volatilitas *inflation*, *interest rate*, dan *exchange rate* akan menyebabkan perubahan yang relatif besar pada volatilitas GDP *growth* dari negara yang tidak menerapkan ITF di Eropa. Sedangkan perubahan pada volatilitas *money supply* dan *exchange rate* akan menyebabkan perubahan yang relatif kecil pada volatilitas GDP *growth* dari negara yang menerapkan ITF di Eropa dan perubahan pada volatilitas *money supply* akan menyebabkan perubahan yang relatif kecil pada volatilitas GDP *growth* dari negara yang tidak menerapkan ITF di Eropa.

Selanjutnya pada saat resesi, perubahan pada volatilitas *inflation* dan *interest rate* akan menyebabkan perubahan yang relatif besar pada volatilitas GDP *growth* dari negara yang menerapkan ITF di Asia (Indonesia dan Filipina) dan perubahan pada volatilitas *inflation*, *interest rate*, dan *exchange rate* akan menyebabkan perubahan yang relatif besar pada volatilitas GDP *growth* dari negara yang tidak menerapkan ITF di Asia (Malaysia dan Singapura). Sedangkan perubahan pada volatilitas *money supply* dan *exchange rate* akan menyebabkan perubahan yang relatif kecil pada volatilitas GDP *growth* dari negara yang menerapkan ITF di Asia dan perubahan pada volatilitas *money supply* akan menyebabkan perubahan yang relatif kecil pada volatilitas GDP *growth* dari negara yang tidak menerapkan ITF di Asia.

Sementara itu pada saat ekspansi, perubahan pada volatilitas *inflation*, *interest rate*, dan *exchange rate* akan menyebabkan perubahan yang relatif besar pada volatilitas GDP dari negara yang menerapkan ITF di Asia dan negara yang tidak menerapkan ITF di Asia. Sedangkan perubahan pada volatilitas *money supply* akan menyebabkan perubahan yang relatif kecil pada volatilitas GDP *growth* dari negara yang menerapkan ITF di Asia maupun negara yang tidak menerapkan ITF di Asia.

BAB 5

KESIMPULAN DAN SARAN

Kesimpulan dan saran pada penelitian ini akan diuraikan pada subbab berikut.

5.1 Kesimpulan

Penelitian ini menunjukkan bahwa terdapat perubahan pada *mean* atau *structural break* pada volatilitas GDP di United Kingdom, Indonesia, Malaysia, dan Singapura. Berdasarkan penerapan ITF, adanya perubahan pada *mean* volatilitas GDP *growth* tidak terkait apakah negara tersebut menerapkan ITF atau tidak. Selanjutnya pada ketepatan klasifikasi ke *regime* hasil pemodelan *Markov Switching* disimpulkan tidak terkait apakah negara tersebut menerapkan ITF atau tidak. Selain itu, berdasarkan estimasi parameter *fractional integration* dapat dideteksi bahwa volatilitas GDP, *money supply*, *inflation*, *interest rate*, dan *exchange rate* pada masing-masing *regime* di semua negara merupakan proses *long memory* baik *long memory* stasioner maupun *long memory* nonstasioner. Selanjutnya, model *cointegration* volatilitas pada setiap *regime* di semua negara menghasilkan residual yang merupakan proses *long memory* stasioner. Hasil empiris ini menyimpulkan bahwa terdapat hubungan *cointegration* antara volatilitas GDP, *money supply*, *inflation*, *interest rate*, dan *exchange rate* pada setiap *regime* di semua negara. Model *cointegration* dengan *long memory* dan *structural break* dapat digunakan sebagai alternatif dalam pemodelan volatilitas variabel ekonomi.

5.2 Saran

Saran yang dapat diberikan berdasarkan hasil penelitian ini untuk penelitian di masa depan yaitu untuk pengembangkan penelitian dengan tujuan *forecast* sehingga dapat dijadikan dasar tindakan preventif dalam menghadapi masalah ekonomi. Selain itu, hasil dari penelitian ini dapat memberikan referensi

yang lebih baik bagi para pembuat kebijakan yang mengendalikan volatilitas GDP *growth* negara sebagai rencana dalam jangka panjang.

DAFTAR PUSTAKA

- Aloy, M., Boutahar, M., Gente, K., dan Peguin-Feissolle, A. (2010), “Fractional Integration and Cointegration in Stock Prices and Exchange Rates”, HAL.
- Balcilar, M., Gupta, R., dan Jooste, C. (2016), “Analyzing South Africa’s Inflation Persistence Using an ARFIMA Model with Markov-Switching Fractional Differencing Parameter”, *The Journal of Developing Areas*, Vol. 50, No. 1, hal. 47-57.
- Batini, N., Breuer, P., Kochhar, K., dan Roger, S. (2006), “Inflation Targeting and the IMF”, *IMF Board Paper SM/06/33*.
- Beltratti, A. dan Morana, C. (2006), “Breaks and Persistency: Macroeconomic Causes of Stock Market Volatility”, *Journal of Econometrics*, Vol. 131, hal. 151–177.
- Bhattarai, K. (2011), “Impact of exchange rate and money supply on growth, inflation and interest rates in the UK”, *International Journal of Monetary Economics and Finance*, Vol. 4, No. 4, hal. 355-371.
- Bollerslev, T. dan Mikkelsen, H. O. (1996), “Modeling and Pricing Long Memory in Stock Market Volatility”, *Journal of Econometrics*, Vol. 73, hal. 151-184.
- Box, G.E. dan Jenkins, G.M. (1994), *Time Series Analysis: Forecasting and Control*, 3rd Edition, Prentice Hall, Englewood Cliffs.
- Casella, G. dan Berger, R.L. (2002), *Statistical Inference*, 2nd Edition, Duxbury Press, California.
- Daniel, W. W. (1989), *Statistika Nonparametrik Terapan*, PT Gramedia Pustaka Utama, Jakarta.
- de Lima, P.J.F. dan Crato, N. (1993), “Long-Range Dependence in the Conditional Variance of Stock Returns”, *Proceedings of the Business and Economic Statistics Section Joint Statistical Meetings*, San Francisco.
- Diebold, F. dan Inoue,A. (2001), “Long Memory and Regime Switching”, *Journal of Econometrics*, Vol. 105, hal. 131–159.
- Ding, Z., Granger, C., dan Engle, R.F. (1993), “A Long Memory Property of Stock Market Returns and a New Model”. *Journal Empirical Finance*, Vol. 1, hal. 83-106.
- Engle, R. (1982), “Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation”, *Econometrica*, Vol. 50, hal. 987-1007.

- Engle, R.F. dan Smith, A.D. (1999), "Stochastic Permanent Breaks", *Review of Economics and Statistics*, Vol. 81, hal. 553– 574.
- Fouejeiu, A. (2012), *Coping with the Recent Financial Crisis, did Inflation Targeting Make Any Difference?*, Faculté de Droit, d'Economie et de Gestion, France.
- Goncalves, C. E. S. dan Salles, J. M. (2008), "Inflation Targeting in Emerging Economies: What do the Data Say?", *Journal of Development Economics*, Vol. 85, No. 1, hal. 312-318.
- Granger, C.W. (1980), "Testing for Causality: A Personal Viewpoint", *Journal of Economic Dynamics and Control*, hal. 329-352.
- Granger, C.W.J. dan Joyeux, R. (1980), "An Introduction to Long Memory Time Series Models and Fractional Differencing", *Journal of Time Series Analysis*, Vol. 1, hal. 15–39.
- Greene, W. H. (2012), *Econometrics Analysis*, 7th Edition, Prentice Hall, Boston.
- Gujarati, D. N. (2004). *Basic Econometrics*, 4th Edition, McGraw-Hill Inc, Singapore.
- Hamilton, J. D. (1994), *Time Series Analysis*, Princeton University Press, New Jersey.
- Hamilton, J.D. (1989), "A New Approach to the Economic Analysis of Nonstationary Time Series and the Business Cycle", *Econometrica*, Vol. 57, hal. 357-384.
- Hanke, J. E. dan Wichern, D. W. (2005), *Business Forecasting*, 8th Edition. Pearson Education Inc, New Jersey.
- Hanke, J. E. dan Wichern. D. W. (1992), *Business Forecasting*, 8th Edition, Pearson Education Inc, New Jersey.
- He, Y. (2017), "A Study on the Relationship Between Money Supply and Macroeconomic Variables in China", *Mediterranean Journal of Social Sciences*, Vol. 8, No. 6.
- Hosking, J. R. M. (1981), "Fractional Differencing", *Biometrika*, Vol. 68, hal. 165-176.
- Iglesias, P., Jorquera, H., dan Palma, W. (2005), "Data Analysis Using Regression Model with Missing Observations and Long-Memory, An Application Study", *Journal of Computational Statistics and Data Analysis*, Vol. 50, hal. 2028–2043.
- Junaiddin, Z. (2009), *Pengantar Teori Ekonomi Makro*, GP Press, Jakarta.

- Kim, C. J. (1994), "Dynamic Linear Models with Markov-Switching", *Journal of Econometrics*, Vol. 60, hal. 1-22.
- Kuswanto, H. dan Sibbertsen, P. (2008), "A Study on Spurious Long Memory in Nonlinear Time Series Models", *Applied Mathematical Science*, Vol. 2, No. 55, hal. 2713-2734.
- Kuswanto, H. dan Salamah, M. (2009), "Regime Switching Long Memory Model for German Stock Returns", *European Journal of Economics, Finance and Administrative Sciences*.
- Maddala, G.S. dan Kim, I.M. (1998), *Unit Roots, Cointegration and Structural Change*, Cambridge University Press, Cambridge.
- Madura, J. (2006), *Manajemen Keuangan Internasional*, Jilid 2, Edisi Ke-4, Erlangga, Jakarta.
- Makridakis, S., Wheel, W.S.C., dan Victor, E. M. (1999), *Metode dan Aplikasi Peramalan*, Binarupa Aksara, Jakarta.
- Mankiw, G. N. (2006), *Principles of Economics. Pengantar Ekonomi Makro*, Edisi Ke-3, Salemba Empat, Jakarta.
- Mankiw, G. N. (2007), *Makroekonomi*, Erlangga, Jakarta.
- Mishkin, F. S. dan Hebbel, K. S. (2007), "Does Inflation Targeting Make a Difference?", *The National Bureau of Economic Research*, No. 12876.
- Ozkan, H., Stengos, T., dan Yazgan, E. (2016), "Markov Regime Switching in Mean and in Fractional Integration Parameter", *Communications in Statistics – Simulation and Computation*, Vol. 0, No. 0, hal. 1-8.
- Salvatore, D. (1997), *Ekonomi Internasional*, Edisi Ke-5, Erlangga, Jakarta
- Saunders, A. (2000), *Financial Institution Management : A Modern Perspective*, 3rd Edition, Mc. Graw Hill, United States.
- Souza, L. R. (2008), "Spectral Properties of Temporally Aggregated Long Memory Process", *Brazilian Journal of Probability and Statistics*, Vol. 22(2), hal. 135-155.
- Sowell, F. (1992), "Maximum Likelihood Estimation of Stationary Univariate Fractionally Integrated Models", *Journal of Econometrics*, Vol. 53, hal. 165–188.
- Svensson, L. E. O. (2007), *Optimal Inflation Targeting: Further Developments of Inflation Targeting in Monetary Policy Under Inflation Targeting*, Banco Central de Chile, Chile.

Timmermann, A. (2000), "Moments of Markov Switching Models", *Journal of Econometrics*, Vol. 96, hal. 75-111.

Urbanovsky, T. (2017), "Granger Causalities Between Interest Rate, Price Level, Money Supply and Real Gdp in the Czech Republic", *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, Vol. 65, No. 1, hal. 745–757.

Wei, W.W.S. (1990), *Time Series Analysis: Univariate and Multivariate Methods*, Addison-Wesley Publishing Co., USA.

Wei, W.W.S. (2006), *Time Series Analysis Univariate and Multivariate Methods*, 2nd Edition, Temple University, New York.

Zivot, E. dan Wang, J. (2006), "Modelling Financial Time Series Models with S-PLUS", Springer.

LAMPIRAN

Lampiran 1. Data Penelitian

a. GDP

<i>Time</i>	GBR	CHE	IDN	PHL	DEU	DNK	MYS	SGP
1998-Q1	3.208	3.561	-4.489	2.127	3.335	2.946	-1.535	1.514
1998-Q2	3.232	4.045	-13.342	-0.121	1.603	0.443	-5.924	-2.422
1998-Q3	3.494	2.720	-16.000	-0.475	1.457	2.578	-10.167	-5.024
1998-Q4	3.428	1.445	-18.258	-3.379	0.718	2.921	-11.182	-2.565
1999-Q1	3.228	0.816	-6.132	0.260	0.723	2.311	-0.990	2.203
1999-Q2	2.364	0.528	1.794	2.938	1.255	3.622	4.792	5.439
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2018-Q3	1.567	2.149	5.167	6.021	1.165	2.651	4.423	2.558
2018-Q4	1.387	1.671	5.183	6.260	0.645	2.553	4.738	1.299
2019-Q1	1.829	1.426	5.065	5.591	0.695	1.914	4.485	1.15

b. Money Supply

<i>Time</i>	GBR	CHE	IDN	PHL	DEU	DNK	MYS	SGP
1998-01	0.550	0.128	0.010	5768.313	0.475	0.051	0.015	0.015
1998-02	0.558	0.134	0.010	6014.802	0.483	0.051	0.015	0.016
1998-03	0.575	0.130	0.010	6194.390	0.476	0.051	0.015	0.016
1998-04	0.580	0.128	0.012	6528.320	0.498	0.052	0.014	0.016
1998-05	0.574	0.128	0.011	6502.439	0.501	0.053	0.013	0.016
1998-06	0.583	0.126	0.008	6218.282	0.501	0.053	0.013	0.015
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2019-01	2.276	0.678	0.097	72289.191	2.505	0.191	0.104	0.135
2019-02	2.292	0.673	0.099	73362.563	2.499	0.191	0.104	0.138
2019-03	2.314	0.677	0.100	74207.743	2.485	0.185	0.105	0.138

c. Inflation

<i>Time</i>	GBR	CHE	IDN	PHL	DEU	DNK	MYS	SGP
1998-01	1.800	0.015	16.294	6.612	1.209	1.734	3.386	1.519
1998-02	1.800	-0.037	29.975	7.743	1.329	2.129	4.452	0.935
1998-03	1.900	0.033	36.757	8.183	1.208	2.276	5.181	0.912
1998-04	2.100	-0.023	42.628	8.674	1.451	2.220	5.428	0.507
1998-05	2.200	0.082	49.650	9.641	1.327	2.009	5.409	0.065
1998-06	1.900	0.101	56.678	10.178	1.325	1.711	6.378	-0.192
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2019-01	1.800	0.560	2.824	4.382	1.373	1.287	-0.660	0.269
2019-02	1.800	0.579	2.570	3.829	1.466	1.082	-0.412	0.315
2019-03	1.800	0.729	2.482	3.290	1.263	1.180	0.115	0.407

Lampiran 1. Data Penelitian (Lanjutan)

d. Interest Rate

Time	GBR	CHE	IDN	PHL	DEU	DNK	MYS	SGP
1998-01	7.563	1.188	33.045	11.000	3.570	3.898	10.090	7.813
1998-02	7.563	1.000	35.000	14.000	3.510	3.868	11.010	5.750
1998-03	7.613	1.484	34.750	13.000	3.520	3.884	10.990	4.734
1998-04	7.496	1.531	35.500	13.000	3.630	3.980	11.040	5.313
1998-05	7.500	1.688	45.727	13.500	3.630	4.213	11.050	6.688
1998-06	7.867	2.156	47.909	13.100	3.560	4.113	11.060	6.406
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2019-01	0.912	-0.713	7.394	4.750	-0.312	-0.305	3.690	1.891
2019-02	0.852	-0.716	7.319	4.750	-0.313	-0.318	3.690	1.953
2019-03	0.848	-0.712	7.209	4.750	-0.315	-0.215	3.690	1.944

e. Exchange Rate

Time	GBR	CHE	IDN	PHL	DEU	DNK	MYS	SGP
1998-01	0.612	1.475	9261.900	42.661	0.929	6.919	4.409	1.748
1998-02	0.609	1.463	8901.250	40.414	0.927	6.909	3.815	1.651
1998-03	0.602	1.490	9385.273	39.004	0.934	6.966	3.746	1.619
1998-04	0.598	1.505	7967.237	38.442	0.927	6.917	3.738	1.601
1998-05	0.610	1.479	9557.588	39.279	0.908	6.766	3.820	1.637
1998-06	0.606	1.495	13176.864	40.399	0.917	6.829	4.001	1.694
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2019-01	0.775	0.990	14163.136	52.468	0.876	6.539	4.116	1.356
2019-02	0.768	1.001	14035.211	52.190	0.881	6.575	4.076	1.354
2019-03	0.759	1.001	14211.000	52.413	0.885	6.606	4.077	1.354

Lampiran 2. Model ARMA Terbaik

Negara	Variabel	Signifikansi Parameter			Nomalitas		AIC	
		Koefisien	t	Kesimpulan	p-value	Kesimpulan		
GBR	y_t	ϕ_1	0,9010	19,1280	Signifikan	0,0999	Normal	181,08
		θ_1	0,6310	5,0080				
		θ_2	0,2310	1,9961				
	x_{1t}	ϕ_1	0,9997	>99,99	Signifikan	0,0000	Tidak Normal	-950,52
		θ_1	0,1156	2,0322				
	x_{2t}	ϕ_1	0,9924	>99,99	Signifikan	0,5063	Normal	-56,09
		θ_1	0,1839	3,1782				
	x_{3t}	ϕ_1	0,9985	>99,99	Signifikan	0,0000	Tidak Normal	-138,29
		θ_1	0,5016	9,7416				
	x_{4t}	ϕ_1	0,9997	>99,99	Signifikan	0,0000	Tidak Normal	-831,27
		θ_1	-0,6077	-11,7893				
CHE	y_t	ϕ_1	0,8852	17,5204	Signifikan	0,9302	Normal	196,32
		θ_1	0,6511	5,6615				
	x_{1t}	ϕ_1	0,9998	>99,99	Signifikan	0,0000	Tidak Normal	-1605,2
	x_{2t}	θ_1	0,9610	32,2893	Signifikan	0,5187	Normal	314,48
		θ_2	0,8171	15,3471				
	x_{3t}	ϕ_1	0,9881	>99,99	Signifikan	0,0000	Tidak Normal	-176,56
		θ_1	0,2447	3,9935				
	x_{4t}	ϕ_1	0,9996	>99,99	Signifikan	0,2525	Normal	-1073,6
		θ_1	0,1990	3,2363				
IDN	y_t	ϕ_1	0,8480	14,1980	Signifikan	0,0000	Tidak Normal	356,88
		θ_1	0,4194	4,2634				
		θ_2	0,3898	3,0858				
	x_{1t}	ϕ_1	0,9996	>99,99	Signifikan	0,0000	Tidak Normal	-2420,8
	x_{2t}	ϕ_1	0,9697	69,6699	Signifikan	0,0000	Tidak Normal	1058,5
		θ_1	0,7556	12,3260				
		θ_2	0,3379	6,0347				
	x_{3t}	ϕ_1	0,9926	>99,99	Signifikan	0,0000	Tidak Normal	780,49
		θ_1	0,3631	7,6818				
		θ_2	0,6508	11,0141				
PHL	x_{4t}	ϕ_1	0,9986	>99,99	Signifikan	0,0000	Tidak Normal	3828,0
		θ_1	0,4266	7,3058				
	y_t	ϕ_1	0,9646	40,1250	Signifikan	0,0097	Tidak Normal	300,43
	x_{1t}	ϕ_1	0,9999	>99,99	Signifikan	0,0000	Tidak Normal	4154,5
	x_{2t}	ϕ_1	0,9909	>99,99	Signifikan	0,0096	Tidak Normal	366,27
		θ_1	0,3767	6,8065				

Lampiran 2. Model ARMA Terbaik (Lanjutan)

Negara	Variabel	Signifikansi Parameter			Nomalitas		AIC	
		Koefisien	T	Kesimpulan	p-value	Kesimpulan		
PHL	x_{3t}	ϕ_1	0,4705	4,2585	Signifikan	0,0000	Tidak Normal	
		ϕ_2	0,5254	4,7511				
		θ_1	0,8242	11,8482				
	x_{4t}	ϕ_1	0,9999	>99,99	Signifikan	0,0102	Tidak Normal	
		θ_1	0,3973	7,0351				
	y_t	ϕ_1	0,3960	3,9169	Signifikan	0,1745	Normal	
DEU		ϕ_2	0,3962	3,9092				
		θ_1	0,9999	15,3097				
x_{1t}	ϕ_1	0,9998	>99,99	Signifikan	0,0170	Tidak Normal		
x_{2t}	ϕ_1	0,2858	2,1804	Signifikan	0,1142	Normal		
	ϕ_2	0,6880	5,3614					
	θ_1	0,5579	3,8128					
x_{3t}	ϕ_1	0,9957	>99,99	Signifikan	0,0000	Tidak Normal		
	θ_1	0,2520	3,8608					
	θ_2	0,1223	2,1500					
x_{4t}	ϕ_1	0,9996	>99,99	Signifikan	0,2705	Normal		
	θ_1	0,3216	5,6394					
DNK	y_t	ϕ_1	0,8694	16,7139	Signifikan	0,3005	Normal	
	x_{1t}	ϕ_1	0,9997	>99,99	Signifikan	0,0001	Tidak Normal	
	x_{2t}	ϕ_1	0,9900	>99,99	Signifikan	0,0031	Normal	
	x_{3t}	ϕ_1	0,9958	>99,99	Signifikan	0,0000	Tidak Normal	
		θ_1	0,3983	6,4152				
		θ_2	0,1240	2,2686				
	x_{4t}	ϕ_1	0,0003	2,2040	Signifikan	0,0168	Tidak Normal	
		ϕ_2	0,9997	>99,99				
		θ_1	0,9999	>99,99				
MYS	y_t	ϕ_1	0,8629	16,0897	Signifikan	0,0009	Tidak Normal	
		θ_1	0,5291	5,8329				
	x_{1t}	ϕ_1	0,9999	>99,99	Signifikan	0,0001	Tidak Normal	
		θ_1	0,1680	2,9421				
	x_{2t}	ϕ_1	0,9667	63,8751	Signifikan	0,0000	Tidak Normal	
		θ_1	0,3024	5,4828				
	x_{3t}	ϕ_1	0,9989	>99,99	Signifikan	0,0000	Tidak Normal	
		θ_1	0,4702	8,0313				
	x_{4t}	ϕ_1	0,9999	>99,99	Signifikan	0,0000	Tidak Normal	

Lampiran 2. Model ARMA Terbaik (Lanjutan)

Negara	Variabel	Signifikansi Parameter			Nomalitas		AIC
		Koefisien	t	Kesimpulan	p-value	Kesimpulan	
SGP	y_t	ϕ_1	0,8881	19,3664	Signifikan	0,2474	Normal 431,53
	x_{1t}	ϕ_1	0,9995	>99,99	Signifikan	0,0000	Tidak Normal -1524,8
		θ_1	-0,7487	-20,6487			
	x_{2t}	ϕ_1	0,9731	75,4230	Signifikan	0,0000	Tidak Normal 424,13
	x_{3t}	ϕ_1	0,9969	>99,99	Signifikan	0,0000	Tidak Normal 92,38
		θ_1	0,2991	4,5979			
	x_{4t}	ϕ_1	0,9999	>99,99	Signifikan	0,0279	Tidak Normal -1254,6

Lampiran 3. Hasil Ljung-Box Test dan Lagrange Multiplier Test

Negara	Variabel	Ljung-Box Test			Lagrange-Multiplier Test		
		Lag	p-value	Kesimpulan	Lag	p-value	Kesimpulan
GBR	y_t	4	0,0000	Tidak White Noise	4	0,,0002	Heterogen
		8	0,0000		8	0,7488	
		12	0,0001		12	0,9992	
		16	0,0001		16	1,0000	
		20	0,0001		20	1,0000	
		24	0,0001		24	1,0000	
	x_{1t}	4	0,0000	Tidak White Noise	4	0,0000	Heterogen
		8	0,0026		8	0,0000	
		12	0,0011		12	0,0001	
		16	0,0056		16	0,0531	
		20	0,0096		20	0,5082	
		24	0,0053		24	0,9155	
	x_{2t}	4	0,2359	Tidak White Noise	4	0,0000	Heterogen
		8	0,5291		8	0,0017	
		12	0,0000		12	0,2837	
		16	0,0001		16	0,9282	
		20	0,0000		20	0,9985	
		24	0,0000		24	1,0000	
	x_{3t}	4	0,0088	Tidak White Noise	4	0,0000	Heterogen
		8	0,0099		8	0,0000	
		12	0,0121		12	0,0000	
		16	0,0407		16	0,0000	
		20	0,0367		20	0,0018	
		24	0,0679		24	0,0745	
	x_{4t}	4	0,8122	White Noise	4	0,0000	Heterogen
		8	0,8952		8	0,0000	
		12	0,9849		12	0,0000	
		16	0,9974		16	0,0000	
		20	0,9999		20	0,0000	
		24	1,0000		24	0,0000	
CHE	y_t	4	0,0030	Tidak White Noise	4	0,0000	Heterogen
		8	0,0037		8	0,1065	
		12	0,0105		12	0,9687	
		16	0,0154		16	0,9998	
		20	0,0075		20	1,0000	
		24	0,0074		24	1,0000	
	x_{1t}	4	0,2356	White Noise	4	0,0000	Heterogen
		8	0,1557		8	0,0000	
		12	0,1200		12	0,0005	
		16	0,1115		16	0,0962	
		20	0,1624		20	0,5987	
		24	0,2280		24	0,9618	
	x_{2t}	4	0,0000	Tidak White Noise	4	0,0042	Heterogen
		8	0,0000		8	0,6425	
		12	0,0000		12	0,9929	
		16	0,0000		16	1,0000	
		20	0,0000		20	1,0000	
		24	0,0000		24	1,0000	

Lampiran 3. Hasil Ljung-Box Test dan Lagrange Multiplier Test (Lanjutan)

Negara	Variabel	Ljung-Box Test			Lagrange-Multiplier Test		
		Lag	p-value	Kesimpulan	Lag	p-value	Kesimpulan
CHE	x_{3t}	4	0,1056	Tidak White Noise	4	0,0000	Heterogen
		8	0,1256		8	0,0000	
		12	0,0258		12	0,0000	
		16	0,0859		16	0,0000	
		20	0,1232		20	0,0000	
		24	0,1877		24	0,0000	
	x_{4t}	4	0,5809	White Noise	4	0,0000	Heterogen
		8	0,1998		8	0,0000	
		12	0,1270		12	0,0004	
		16	0,2053		16	0,1113	
		20	0,1259		20	0,6773	
		24	0,1184		24	0,9623	
IDN	y_t	4	0,0043	Tidak White Noise	4	0,0000	Heterogen
		8	0,0930		8	0,4852	
		12	0,1151		12	0,9952	
		16	0,1241		16	1,0000	
		20	0,3255		20	1,0000	
		24	0,4928		24	1,0000	
	x_{1t}	4	0,4553	Tidak White Noise	4	0,0000	Heterogen
		8	0,0038		8	0,0000	
		12	0,0000		12	0,0080	
		16	0,0000		16	0,4628	
		20	0,0000		20	0,9208	
		24	0,0000		24	0,9973	
PHL	x_{2t}	4	0,0000	Tidak White Noise	4	0,0000	Heterogen
		8	0,0000		8	0,0000	
		12	0,0000		12	0,0040	
		16	0,0000		16	0,2958	
		20	0,0000		20	0,0233	
		24	0,0000		24	0,5905	
	x_{3t}	4	0,0000	Tidak White Noise	4	0,0000	Heterogen
		8	0,0000		8	0,4635	
		12	0,0000		12	0,9879	
		16	0,0000		16	1,0000	
		20	0,0000		20	1,0000	
		24	0,0000		24	0,6914	
	x_{4t}	4	0,0113	Tidak White Noise	4	0,0000	Heterogen
		8	0,0013		8	0,0001	
		12	0,0025		12	0,0000	
		16	0,0010		16	0,0173	
		20	0,0022		20	0,3649	
		24	0,0057		24	0,7510	
	y_t	4	0,0886	White Noise	4	0,0000	Heterogen
		8	0,0669		8	0,0000	
		12	0,1943		12	0,0003	
		16	0,3866		16	0,1040	
		20	0,5925		20	0,7859	
		24	0,5220		24	0,9936	

Lampiran 3. Hasil Ljung-Box Test dan Lagrange Multiplier Test (Lanjutan)

Negara	Variabel	Ljung-Box Test			Lagrange-Multiplier Test		
		Lag	p-value	Kesimpulan	Lag	p-value	Kesimpulan
PHL	x_{1t}	4	0,2109	Tidak White Noise	4	0,0000	Heterogen
		8	0,5251		8	0,0000	
		12	0,0000		12	0,0001	
		16	0,0000		16	0,9786	
		20	0,0000		20	0,9998	
		24	0,0000		24	1,0000	
	x_{2t}	4	0,0005	Tidak White Noise	4	0,0000	Heterogen
		8	0,0039		8	0,0000	
		12	0,0000		12	0,0000	
		16	0,0000		16	0,0000	
		20	0,0000		20	0,0050	
		24	0,0000		24	0,3978	
DEU	x_{3t}	4	0,1175	White Noise	4	0,0000	Heterogen
		8	0,2320		8	0,0000	
		12	0,2017		12	0,0000	
		16	0,1469		16	0,0000	
		20	0,1085		20	0,0000	
		24	0,1109		24	0,0004	
	x_{4t}	4	0,1139	White Noise	4	0,0000	Heterogen
		8	0,1905		8	0,0000	
		12	0,3204		12	0,0000	
		16	0,4116		16	0,0222	
		20	0,2153		20	0,3969	
		24	0,3577		24	0,9217	
DEU	y_t	4	0,0002	Tidak White Noise	4	0,0002	Heterogen
		8	0,0004		8	0,3945	
		12	0,0019		12	0,9722	
		16	0,0035		16	0,9999	
		20	0,0063		20	1,0000	
		24	0,0109		24	1,0000	
	x_{1t}	4	0,1944	Tidak White Noise	4	0,0000	Heterogen
		8	0,0226		8	0,0004	
		12	0,0132		12	0,1234	
		16	0,0025		16	0,8345	
		20	0,0009		20	0,9937	
		24	0,0010		24	1,0000	
DEU	x_{2t}	4	0,2766	Tidak White Noise	4	0,0000	Heterogen
		8	0,6960		8	0,0000	
		12	0,0000		12	0,0177	
		16	0,0000		16	0,6315	
		20	0,0000		20	0,9756	
		24	0,0000		24	0,9996	
	x_{3t}	4	0,0001	Tidak White Noise	4	0,0000	Heterogen
		8	0,0015		8	0,0000	
		12	0,0086		12	0,0008	
		16	0,0049		16	0,1165	
		20	0,0019		20	0,6489	
		24	0,0034		24	0,9586	

Lampiran 3. Hasil Ljung-Box Test dan Lagrange Multiplier Test (Lanjutan)

Negara	Variabel	Ljung-Box Test			Lagrange-Multiplier Test		
		Lag	p-value	Kesimpulan	Lag	p-value	Kesimpulan
DEU	x_{4t}	4	0,7024	White Noise	4	0,0000	Heterogen
		8	0,7972		8	0,0000	
		12	0,8540		12	0,0207	
		16	0,9105		16	0,3789	
		20	0,8077		20	0,9046	
		24	0,8405		24	0,9980	
DNK	y_t	4	0,0029	Tidak White Noise	4	0,0007	Heterogen
		8	0,0128		8	0,8533	
		12	0,0056		12	0,9993	
		16	0,0159		16	1,0000	
		20	0,0522		20	1,0000	
		24	0,0700		24	1,0000	
	x_{1t}	4	0,2222	White Noise	4	0,0000	Heterogen
		8	0,2211		8	0,0000	
		12	0,2963		12	0,0009	
		16	0,3424		16	0,1231	
		20	0,0924		20	0,6964	
		24	0,2093		24	0,9817	
MYS	x_{2t}	4	0,2793	Tidak White Noise	4	0,0000	Heterogen
		8	0,4108		8	0,0000	
		12	0,0000		12	0,0060	
		16	0,0000		16	0,4041	
		20	0,0000		20	0,8881	
		24	0,0002		24	0,9964	
	x_{3t}	4	0,0013	Tidak White Noise	4	0,0000	Heterogen
		8	0,0257		8	0,0000	
		12	0,0663		12	0,0002	
		16	0,0260		16	0,0605	
		20	0,0111		20	0,5302	
		24	0,0230		24	0,9171	
	x_{4t}	4	0,2608	White Noise	4	0,0000	Heterogen
		8	0,7431		8	0,0000	
		12	0,6972		12	0,0006	
		16	0,8596		16	0,0749	
		20	0,6313		20	0,5256	
		24	0,7426		24	0,9273	
	y_t	4	0,0047	Tidak White Noise	4	0,0000	Heterogen
		8	0,0089		8	0,3155	
		12	0,0492		12	0,9635	
		16	0,1673		16	0,9997	
		20	0,3028		20	1,0000	
		24	0,3293		24	1,0000	
	x_{1t}	4	0,3809	Tidak White Noise	4	0,0000	Heterogen
		8	0,6647		8	0,0000	
		12	0,0045		12	0,0000	
		16	0,0031		16	0,0101	
		20	0,0067		20	0,2362	
		24	0,0004		24	0,9931	

Lampiran 3. Hasil Ljung-Box Test dan Lagrange Multiplier Test (Lanjutan)

Negara	Variabel	Ljung-Box Test			Lagrange-Multiplier Test		
		Lag	p-value	Kesimpulan	Lag	p-value	Kesimpulan
MYS	x_{2t}	4	0,3122	Tidak White Noise	4	0,0000	Heterogen
		8	0,0138		8	0,0000	
		12	0,0000		12	0,0000	
		16	0,0000		16	0,0023	
		20	0,0000		20	0,1271	
		24	0,0000		24	0,5885	
	x_{3t}	4	0,0600	Tidak White Noise	4	0,0000	Heterogen
		8	0,0000		8	0,0000	
		12	0,0001		12	0,0000	
		16	0,0000		16	0,0466	
		20	0,0002		20	0,0000	
		24	0,0014		24	0,0000	
SGP	x_{4t}	4	0,0003	Tidak White Noise	4	0,0000	Heterogen
		8	0,0010		8	0,0385	
		12	0,0099		12	0,0088	
		16	0,0398		16	0,5689	
		20	0,1164		20	9,9764	
		24	0,1539		24	0,9996	
	y_t	4	0,0000	Tidak White Noise	4	0,0108	Heterogen
		8	0,0002		8	0,6659	
		12	0,0003		12	0,9955	
		16	0,0004		16	1,0000	
		20	0,0019		20	1,0000	
		24	0,0051		24	1,0000	
	x_{1t}	4	0,4153	White Noise	4	0,0000	Heterogen
		8	0,9389		8	0,0000	
		12	0,9974		12	0,0000	
		16	0,9999		16	0,0000	
		20	1,0000		20	0,0000	
		24	1,0000		24	0,0000	
	x_{2t}	4	0,0062	Tidak White Noise	4	0,0000	Heterogen
		8	0,0003		8	0,0000	
		12	0,0000		12	0,0000	
		16	0,0000		16	0,0222	
		20	0,0000		20	0,3935	
		24	0,0000		24	0,8741	
	x_{3t}	4	0,0467	Tidak White Noise	4	0,0000	Heterogen
		8	0,0421		8	0,0000	
		12	0,0109		12	0,0036	
		16	0,0294		16	0,1863	
		20	0,0547		20	0,3069	
		24	0,0940		24	0,8402	
	x_{4t}	4	0,0000	Tidak White Noise	4	0,0000	Heterogen
		8	0,0001		8	0,0000	
		12	0,0020		12	0,0072	
		16	0,0071		16	0,2909	
		20	0,0152		20	0,8423	
		24	0,0100		24	0,9892	

Lampiran 4. Sintaks untuk Input Data

```
#PACKAGE
Library(xlsx)

#MENDEFINISIKAN DATA
datagdp<-read.xlsx("D:/data program.xlsx",1) #Data GDP
gdpuk<-datagdp[,2] #Data GDP United Kingdom
gdpsw<-datagdp[,3] #Data GDP Switzerland
gdpin<-datagdp[,4] #Data GDP Indonesia
gdpph<-datagdp[,5] #Data GDP Filipina
gdprjr<-datagdp[,6] #Data GDP Jerman
gdprdn<-datagdp[,7] #Data GDP Denmark
gdprml<-datagdp[,8] #Data GDP Malaysia
gdprsg<-datagdp[,9] #Data GDP Singapura

datams<-read.xlsx("D:/data program.xlsx",2) #Data Money Supply
msuk<-datams[,2] #Data Money Supply United Kingdom
mssw<-datams[,3] #Data Money Supply Switzerland
msin<-datams[,4] #Data Money Supply Indonesia
msph<-datams[,5] #Data Money Supply Filipina
msjr<-datams[,6] #Data Money Supply Jerman
msdn<-datams[,7] #Data Money Supply Denmark
msml<-datams[,8] #Data Money Supply Malaysia
mssg<-datams[,9] #Data Money Supply Singapura

datainf<-read.xlsx("D:/data program.xlsx",3) #Data Inflation
infuk<-datainf[,2] #Data Inflation United Kingdom
infsw<-datainf[,3] #Data Inflation Switzerland
infin<-datainf[,4] #Data Inflation Indonesia
infph<-datainf[,5] #Data Inflation Filipina
infjr<-datainf[,6] #Data Inflation Jerman
infdn<-datainf[,7] #Data Inflation Denmark
infml<-datainf[,8] #Data Inflation Malaysia
infsg<-datainf[,9] #Data Inflation Singapura

datainr<-read.xlsx("D:/data program.xlsx",4) #Data Interest Rate
inruk<-datainr[,2] #Data Interest Rate United Kingdom
inrsw<-datainr[,3] #Data Interest Rate Switzerland
inrin<-datainr[,4] #Data Interest Rate Indonesia
inrph<-datainr[,5] #Data Interest Rate Filipina
inrjr<-datainr[,6] #Data Interest Rate Jerman
inrdn<-datainr[,7] #Data Interest Rate Denmark
inrml<-datainr[,8] #Data Interest Rate Malaysia
inrsg<-datainr[,9] #Data Interest Rate Singapura

dataexr<-read.xlsx("D:/data program.xlsx",5) #Data Exchange Rate
exruk<-dataexr[,2] #Data Exchange Rate United Kingdom
exrsw<-dataexr[,3] #Data Exchange Rate Switzerland
exrin<-dataexr[,4] #Data Exchange Rate Indonesia
exrph<-dataexr[,5] #Data Exchange Rate Filipina
exrjr<-dataexr[,6] #Data Exchange Rate Jerman
exrdn<-dataexr[,7] #Data Exchange Rate Denmark
exrml<-dataexr[,8] #Data Exchange Rate Malaysia
exrsg<-dataexr[,9] #Data Exchange Rate Singapura
```

Lampiran 5. Sintaks Memperoleh Residual ARMA dan Memperoleh Deret Volatilitas

```
#PACKAGE
library(forecast)

#RESIDUAL DAN VOLATILITAS
#Residual Variabel United Kingdom
rgdpuk<-residuals(Arima(gdpuk,order=c(1,0,2),include.mean=FALSE))
rmsuk<-residuals(Arima(msuk,order=c(1,0,1),include.mean=FALSE))
rinfuk<-residuals(Arima(infuk,order=c(1,0,1),include.mean=FALSE))
rinruk<-residuals(Arima(inruk,order=c(1,0,1),include.mean=FALSE))
rexruk<-residuals(Arima(exruk,order=c(1,0,1),include.mean=FALSE))
#Volatilitas Variabel United Kingdom
rgdpuk2<-rgdpuk^2
rmsuk2<-rmsuk^2
rinfuk2<-rinfuk^2
rinruk2<-rinruk^2
rexruk2<-rexruk^2

#Residual Variabel Switzerland
rgdpsw<-residuals(Arima(gdpsw,order=c(1,0,1),include.mean=FALSE))
rmssw<-residuals(Arima(mssw,order=c(1,0,0),include.mean=FALSE))
rinfsw<-residuals(Arima(infsw,order=c(0,0,2),include.mean=FALSE))
rinrsw<-residuals(Arima(inrsw,order=c(1,0,1),include.mean=FALSE))
rexrsw<-residuals(Arima(exrsw,order=c(1,0,1),include.mean=FALSE))
#Volatilitas Variabel Switzerland
rgdpsw2<-rgdpsw^2
rmssw2<-rmssw^2
rinfsw2<-rinfsw^2
rinrsw2<-rinrsw^2
rexrsw2<-rexrsw^2

#Residual Variabel Indonesia
rgdpin<-residuals(Arima(gdpin,order=c(1,0,2),include.mean=FALSE))
rmsin<-residuals(Arima(msin,order=c(1,0,0),include.mean=FALSE))
rinfin<-residuals(Arima(infin,order=c(1,0,2),include.mean=FALSE))
rinrin<-residuals(Arima(inrin,order=c(1,0,2),include.mean=FALSE))
rexrin<-residuals(Arima(exrin,order=c(1,0,1),include.mean=FALSE))
#Volatilitas Variabel Indonesia
rgdpin2<-rgdpin^2
rmsin2<-rmsin^2
rinfin2<-rinfin^2
rinrin2<-rinrin^2
rexrin2<-rexrin^2

#Residual Variabel Filipina
rgdpph<-residuals(Arima(gdpph,order=c(1,0,0),include.mean=FALSE))
rmsph<-residuals(Arima(msph,order=c(1,0,0),include.mean=FALSE))
rinfph<-residuals(Arima(infph,order=c(1,0,1),include.mean=FALSE))
rinrph<-residuals(Arima(inrph,order=c(2,0,1),include.mean=FALSE))
rexrph<-residuals(Arima(exrph,order=c(1,0,1),include.mean=FALSE))
#Volatilitas Variabel Filipina
rgdpph2<-rgdpph^2
rmsph2<-rmsph^2
rinfph2<-rinfph^2
```

Lampiran 5. Sintaks Memperoleh Residual ARMA dan Memperoleh Deret Volatilitas (Lanjutan)

```
rinrph2<-rinrph^2
rexrph2<-rexrph^2

#Residual Variabel Jerman
rgdpjr<-residuals(Arima(gdpjr,order=c(1,0,1),include.mean=FALSE))
rmsjr<-residuals(Arima(msjr,order=c(1,0,0),include.mean=FALSE))
rinfjr<-residuals(Arima(infjr,order=c(2,0,1),include.mean=FALSE))
rinrjr<-residuals(Arima(inrjr,order=c(1,0,2),include.mean=FALSE))
rexrjr<-residuals(Arima(exrjr,order=c(1,0,1),include.mean=FALSE))
#Volatilitas Variabel Jerman
rgdpjr2<-rgdpjr^2
rmsjr2<-rmsjr^2
rinfjr2<-rinfjr^2
rinrjr2<-rinrjr^2
rexrjr2<-rexrjr^2

#Residual Variabel Denmark
rgdpdn<-residuals(Arima(gdpdn,order=c(1,0,0),include.mean=FALSE))
rmsdn<-residuals(Arima(msdn,order=c(1,0,0),include.mean=FALSE))
rinfdn<-residuals(Arima(infdn,order=c(1,0,0),include.mean=FALSE))
rinrdn<-residuals(Arima(inrdn,order=c(1,0,2),include.mean=FALSE))
rexrdn<-residuals(Arima(exrdn,order=c(2,0,1),include.mean=FALSE))
#Volatilitas Variabel Denmark
rgdpdn2<-rgdpdn^2
rmsdn2<-rmsdn^2
rinfdn2<-rinfdn^2
rinrdn2<-rinrdn^2
rexrdn2<-rexrdn^2

#Residual Variabel Malaysia
rgdpml<-residuals(Arima(gdpml,order=c(1,0,1),include.mean=FALSE))
rmsml<-residuals(Arima(msml,order=c(1,0,1),include.mean=FALSE))
rinfml<-residuals(Arima(infml,order=c(1,0,1),include.mean=FALSE))
rinrml<-residuals(Arima(inrml,order=c(1,0,1),include.mean=FALSE))
rexrml<-residuals(Arima(exrml,order=c(1,0,0),include.mean=FALSE))
#Volatilities Variabel Malaysia
rgdpml2<-rgdpml^2
rmsml2<-rmsml^2
rinfml2<-rinfml^2
rinrml2<-rinrml^2
rexrml2<-rexrml^2

#Residual Variabel Singapura
rgdpsg<-residuals(Arima(gdpsg,order=c(1,0,0),include.mean=FALSE))
rmssg<-residuals(Arima(mssg,order=c(1,0,1),include.mean=FALSE))
rinfsg<-residuals(Arima(infsg,order=c(1,0,0),include.mean=FALSE))
rinrsg<-residuals(Arima(inrsg,order=c(1,0,1),include.mean=FALSE))
rexrsg<-residuals(Arima(exrsg,order=c(1,0,0),include.mean=FALSE))
#Volatilitas Variabel Singapura
rgdpsg2<-rgdpsg^2
rmssg2<-rmssg^2
rinfsg2<-rinfsg^2
rinrsg2<-rinrsg^2
rexrsg2<-rexrsg^2
```

Lampiran 6. Sintaks Pengujian Normalitas, *White Noise*, dan Heterogenitas

```

#PACKAGE
library(stats)
library(aTSA)
library(nortest)

#PENGUJIAN NORMALITAS, WHITE NOISE, DAN HETEROGENITAS
Uji<-function(marma)
{
r<-residuals(marma)

#Uji Normalitas
N<-lillie.test(r)$p.value
cat("Pengujian Normalitas","\n")
cat("p-value           : ",N,"\n")
If (N>=0.05)
{
  cat("Kesimpulan      : ","Residual Berdistribusi Normal","\n")
}
If (N<=0.05)
{
  cat("Kesimpulan      : ","Residual Tidak Berdistribusi
Normal","\n")
}

#Uji Ljung-Box
L1=Box.test(r,lag=4,type="Ljung")$p.value
L2=Box.test(r,lag=8,type="Ljung")$p.value
L3=Box.test(r,lag=12,type="Ljung")$p.value
L4=Box.test(r,lag=16,type="Ljung")$p.value
L5=Box.test(r,lag=20,type="Ljung")$p.value
L6=Box.test(r,lag=24,type="Ljung")$p.value
L<-min(L1,L2,L3,L4,L5,L6)
cat("Pengujian White Noise","\n")
cat("Lag      ","p-value","\n")
cat("  4        ",L1,"\n")
cat("  8        ",L2,"\n")
cat(" 12       ",L3,"\n")
cat(" 16       ",L4,"\n")
cat(" 20       ",L5,"\n")
cat(" 24       ",L6,"\n")
If (L>=0.05)
{
  cat("Kesimpulan      : ","Residual White Noise","\n")
}
If (L<=0.05)
{
  cat("Kesimpulan      : ","Residual Tidak White Noise ","\n")
}

#Uji Heterogenitas
H0<-arch.test(m,output=FALSE)
H<-min(H0[,5])
cat("Pengujian Heteroskedastisitas","\n")
cat("Lag      ","p-value","\n")
cat("  4        ", H0[1,5],"\n")

```

Lampiran 6. Sintaks Pengujian Normalitas, *White Noise*, dan Heterogenitas
(Lanjutan)

```
cat(" 8      ", H0[2,5], "\n")
cat(" 12     ", H0[3,5], "\n")
cat(" 16     ", H0[4,5], "\n")
cat(" 20     ", H0[5,5], "\n")
cat(" 24     ", H0[6,5], "\n")
If (H>=0.05)
{
  cat("Kesimpulan : ", "Residual Homogen", "\n")
}
If (H<=0.05)
{
  cat("Kesimpulan : ", "Residual Heterogen ", "\n")
}
```

Lampiran 7. Syntaks Agregasi Volatilitas

```
#AGREGASI
agr<-function(deret)
{
  r0<-matrix(deret,85,3,byrow=TRUE)
  r<-rep(0,85)
  for (i in 1:85)
  {
    r[i]<-sum(r0[i,])/3
  }
  return(r)
}

#AGREGASI VARIABEL
#Agregasi Variabel United Kingdom
rmsuk2<-agr(rmsuk2)
rinfuk2<-agr(rinfuk2)
rinruk2<-agr(rinruk2)
rexruk2<-agr(rexruk2)

#Agregasi Variabel Switzerland
rmssw2<-agr(rmssw2)
rinfsw2<-agr(rinfsw2)
rinrsw2<-agr(rinrsw2)
rexrsw2<-agr(rexrsw2)

#Agregasi Variabel Indonesia
rmsin2<-agr(rmsin2)
rinfin2<-agr(rinfin2)
rinrin2<-agr(rinrin2)
rexrin2<-agr(rexrin2)

#Agregasi Variabel Filipina
rmsph2<-agr(rmsph2)
rinfph2<-agr(rinfph2)
rinrph2<-agr(rinrph2)
rexrph2<-agr(rexrph2)

#Agregasi Variabel Jerman
rmsjr2<-agr(rmsjr2)
rinfjr2<-agr(rinfjr2)
rinrjr2<-agr(rinrjr2)
rexrjr2<-agr(rexrjr2)

#Agregasi Variabel Denmark
rmsdn2<-agr(rmsdn2)
rinfdn2<-agr(rinfdn2)
rinrdn2<-agr(rinrdn2)
rexrdn2<-agr(rexrdn2)

#Agregasi Variabel Malaysia
rmsml2<-agr(rmsml2)
rinfml2<-agr(rinfml2)
rinrml2<-agr(rinrml2)
rexrml2<-agr(rexrml2)
```

Lampiran 7. Syntaks Agregasi Volatilitas (Lanjutan)

```
#Agregasi Variabel Singapura
rmssg2<-agr(rmssg2)
rinfsg2<-agr(rinfsg2)
rinrsg2<-agr(rinrsg2)
rexrsg2<-agr(rexrsg2)

#MENDEFINISIKAN DATA SETELAH AGREGASI
datar2uk<-cbind(rgdpu2,rmsuk2,rinfuk2,rinruk2,rexruk2)      #Data
United Kingdom Setelah Agregasi
datar2sw<-cbind(rgdpsw2,rmssw2,rinfsw2,rinrsw2,rexrsw2)      #Data
Switzerland Setelah Agregasi
datar2in<-cbind(rgdpin2,rmsin2,rinfin2,rinrin2,rexrin2)      #Data
Indonesia Setelah Agregasi
datar2ph<-cbind(rgdpph2,rmsp2,rinfph2,rinrph2,rexrph2)      #Data
Filipina Setelah Agregasi
datar2jr<-cbind(rgdpjr2,rmsjr2,rinfjr2,rinrjr2,rexrjr2)      #Data
Jerman Setelah Agregasi
datar2dn<-cbind(rgdpdn2,rmsdn2,rinfdn2,rinrdn2,rexrdn2)      #Data
Denmark Setelah Agregasi
datar2ml<-cbind(rgdpml2,rmsml2,rinfml2,rinrml2,rexrml2)      #Data
Malaysia Setelah Agregasi
datar2sg<-cbind(rgdpsg2,rmssg2,rinfsg2,rinrsg2,rexrsg2)      #Data
Singapura Setelah Agregasi
```

Lampiran 8. Sintaks Pengujian Perubahan pada *Mean*

```
#PACKAGE
library(CPAT)

#Pengujian CUSUM
Cus<-function(volatilitasgdp)
{
c0<-volatilitasgdp
#Uji CUSUM
C<-round(CUSUM.test(c0)$p.value,4)
cat("Pengujian Perubahan pada Mean","\n")
cat("p-value           : ",C ,"\n")
If (C>=0.05)
{
  cat("Kesimpulan Volatilitas","\n")
}
If (N<=0.05)
{
  cat("Kesimpulan Volatilitas","\n")
}
```

Lampiran 9. Sintaks Pemodelan *Markov Switching*

```
#PACKAGE
library(MSwM)

# PEMODELAN MARKOV SWITCHING
#Pemodelan United Kingdom
model=lm(rgdpu2~1)
mod=msmFit(model,k=2,p=1,sw=rep(TRUE,3)) #Pemodelan MS-AR(1)
summary(mod)
mod=msmFit(model,k=2,p=2,sw=rep(TRUE,4)) #Pemodelan MS-AR(2)
summary(mod)
mod=msmFit(model,k=2,p=3,sw=rep(TRUE,5)) #Pemodelan MS-AR(3)
summary(mod)

#Pemodelan Switzerland
model=lm(rgdpsw2~1)
mod=msmFit(model,k=2,p=1,sw=rep(TRUE,3)) #Pemodelan MS-AR(1)
summary(mod)
mod=msmFit(model,k=2,p=2,sw=rep(TRUE,4)) #Pemodelan MS-AR(2)
summary(mod)
mod=msmFit(model,k=2,p=3,sw=rep(TRUE,5)) #Pemodelan MS-AR(3)
summary(mod)

#Pemodelan Indonesia
model=lm(rgdpin2~1)
mod=msmFit(model,k=2,p=1,sw=rep(TRUE,3)) #Pemodelan MS-AR(1)
summary(mod)
mod=msmFit(model,k=2,p=2,sw=rep(TRUE,4)) #Pemodelan MS-AR(2)
summary(mod)
mod=msmFit(model,k=2,p=3,sw=rep(TRUE,5)) #Pemodelan MS-AR(3)
summary(mod)

#Pemodelan Filipina
model=lm(rgdpph2~1)
mod=msmFit(model,k=2,p=1,sw=rep(TRUE,3)) #Pemodelan MS-AR(1)
summary(mod)
mod=msmFit(model,k=2,p=2,sw=rep(TRUE,4)) #Pemodelan MS-AR(2)
summary(mod)
mod=msmFit(model,k=2,p=3,sw=rep(TRUE,5)) #Pemodelan MS-AR(3)
summary(mod)

#Pemodelan Jerman
model=lm(rgdpjr~1)
mod=msmFit(model,k=2,p=1,sw=rep(TRUE,3)) #Pemodelan MS-AR(1)
summary(mod)
mod=msmFit(model,k=2,p=2,sw=rep(TRUE,4)) #Pemodelan MS-AR(2)
summary(mod)
mod=msmFit(model,k=2,p=3,sw=rep(TRUE,5)) #Pemodelan MS-AR(3)
summary(mod)

#Pemodelan Denmark
model=lm(rgdpdn2~1)
mod=msmFit(model,k=2,p=1,sw=rep(TRUE,3)) #Pemodelan MS-AR(1)
summary(mod)
mod=msmFit(model,k=2,p=2,sw=rep(TRUE,4)) #Pemodelan MS-AR(2)
summary(mod)
```

Lampiran 9. Sintaks Pemodelan *Markov Switching* (Lanjutan)

```
mod=msmFit(model,k=2,p=3,sw=rep(TRUE,5)) #Pemodelan MS-AR(3)
summary(mod)

#Pemodelan Malaysia
model=lm(rgdpml2~1)
mod=msmFit(model,k=2,p=1,sw=rep(TRUE,3)) #Pemodelan MS-AR(1)
summary(mod)
mod=msmFit(model,k=2,p=2,sw=rep(TRUE,4)) #Pemodelan MS-AR(2)
summary(mod)
mod=msmFit(model,k=2,p=3,sw=rep(TRUE,5)) #Pemodelan MS-AR(3)
summary(mod)

#Pemodelan Singapura
model=lm(rgdpsg2~1)
mod=msmFit(model,k=2,p=1,sw=rep(TRUE,3)) #Pemodelan MS-AR(1)
summary(mod)
mod=msmFit(model,k=2,p=2,sw=rep(TRUE,4)) #Pemodelan MS-AR(2)
summary(mod)
mod=msmFit(model,k=2,p=3,sw=rep(TRUE,5)) #Pemodelan MS-AR(3)
summary(mod)
```

Lampiran 10. Sintaks Pengklasifikasian *Regime*

```
#KLASIFIKASI REGIME MARKOV SWITCHING
#Klasifikasi Regime United Kingdom
model=lm(rgdruk2~1)
mod=msmFit(model,k=2,p=1,sw=rep(TRUE,3))
n<-nrow(mod@Fit@filtProb)
yuk<-rep(0,n)
for (i in 1:n)
{
  if (mod@Fit@filtProb[i,1]<=0.5) yuk[i]<-1
}
datar2uk1<-matrix(0,1,5)
for (i in 1:n)
{
  if (yuk[i]==0) datar2uk1<-rbind(datar2uk1,datar2uk[i,])
}
datar2uk1<-datar2uk1[-1,]
datar2uk2<-matrix(0,1,5)
for (i in 1:n)
{
  if (yuk[i]==1) datar2uk2<-rbind(datar2uk2,datar2uk[i,])
}
datar2uk2<-datar2uk2[-1,]

#Klasifikasi Regime Switzerland
model=lm(rgdpsw2~1)
mod=msmFit(model,k=2,p=3,sw=rep(TRUE,5))
n<-nrow(mod@Fit@filtProb)
ysw<-rep(0,n)
for (i in 1:n)
{
  if (mod@Fit@filtProb[i,1]<=0.5) ysw[i]<-1
}
datar2sw1<-matrix(0,1,5)
for (i in 1:n)
{
  if (ysw[i]==0) datar2sw1<-rbind(datar2sw1,datar2sw[i,])
}
datar2sw1<-datar2sw1[-1,]
datar2sw2<-matrix(0,1,5)
for (i in 1:n)
{
  if (ysw[i]==1) datar2sw2<-rbind(datar2sw2,datar2sw[i,])
}
datar2sw2<-datar2sw2[-1,]

#Klasifikasi Regime Indonesia
model=lm(rgdpin2~1)
mod=msmFit(model,k=2,p=2,sw=rep(TRUE,4))
n<-nrow(mod@Fit@filtProb)
yin<-rep(0,n)
for (i in 1:n)
{
  if (mod@Fit@filtProb[i,1]<=0.5) yin[i]<-1
}
datar2in1<-matrix(0,1,5)
```

Lampiran 10. Sintaks Pengklasifikasian *Regime* (Lanjutan)

```

for (i in 1:n)
{
  if (yin[i]==0) datar2in1<-rbind(datar2in1,datar2in[i,])
}
datar2in1<-datar2in1[-1,]
datar2in2<-matrix(0,1,5)
for (i in 1:n)
{
  if (yin[i]==1) datar2in2<-rbind(datar2in2,datar2in[i,])
}
datar2in2<-datar2in2[-1,]

#Klasifikasi Regime Filipina
model=lm(rgdpph2~1)
mod=msmFit(model,k=2,p=2,sw=rep(TRUE,4))
n<-nrow(mod@Fit@filtProb)
yph<-rep(0,n)
for (i in 1:n)
{
  if (mod@Fit@filtProb[i,1]<=0.5) yph[i]<-1
}
datar2ph1<-matrix(0,1,5)
for (i in 1:n)
{
  if (yph[i]==0) datar2ph1<-rbind(datar2ph1,datar2ph[i,])
}
datar2ph1<-datar2ph1[-1,]
datar2ph2<-matrix(0,1,5)
for (i in 1:n)
{
  if (yph[i]==1) datar2ph2<-rbind(datar2ph2,datar2ph[i,])
}
datar2ph2<-datar2ph2[-1,]

#Klasifikasi Regime Jerman
model=lm(rgdpjr2~1)
mod=msmFit(model,k=2,p=2,sw=rep(TRUE,4))
n<-nrow(mod@Fit@filtProb)
yjr<-rep(0,n)
for (i in 1:n)
{
  if (mod@Fit@filtProb[i,1]<=0.5) yjr[i]<-1
}
datar2jrl1<-matrix(0,1,5)
for (i in 1:n)
{
  if (yjr[i]==0) datar2jrl1<-rbind(datar2jrl1,datar2jr[i,])
}
datar2jrl1<-datar2jrl1[-1,]
datar2jr2<-matrix(0,1,5)
for (i in 1:n)
{
  if (yjr[i]==1) datar2jr2<-rbind(datar2jr2,datar2jr[i,])
}
datar2jr2<-datar2jr2[-1,]

```

Lampiran 10. Sintaks Pengklasifikasian *Regime* (Lanjutan)

```
#Klasifikasi Regime Denmark
model=lm(rgdpdn2~1)
mod=msmFit(model,k=2,p=3,sw=rep(TRUE,5))
n<-nrow(mod@Fit@filtProb)
ydn<-rep(0,n)
for (i in 1:n)
{
  if (mod@Fit@filtProb[i,1]<=0.5) ydn[i]<-1
}
datar2dn1<-matrix(0,1,5)
for (i in 1:n)
{
  if (ydn[i]==0) datar2dn1<-rbind(datar2dn1,datar2dn[i,])
}
datar2dn1<-datar2dn1[-1,]
datar2dn2<-matrix(0,1,5)
for (i in 1:n)
{
  if (ydn[i]==1) datar2dn2<-rbind(datar2dn2,datar2dn[i,])
}
datar2dn2<-datar2dn2[-1,]

#Klasifikasi Regime Malaysia
model=lm(rgdpml2~1)
mod=msmFit(model,k=2,p=1,sw=rep(TRUE,3))
n<-nrow(mod@Fit@filtProb)
yml<-rep(0,n)
for (i in 1:n)
{
  if (mod@Fit@filtProb[i,1]<=0.5) yml[i]<-1
}
datar2ml1<-matrix(0,1,5)
for (i in 1:n)
{
  if (yml[i]==0) datar2ml1<-rbind(datar2ml1,datar2ml[i,])
}
datar2ml1<-datar2ml1[-1,]
datar2ml2<-matrix(0,1,5)
for (i in 1:n)
{
  if (yml[i]==1) datar2ml2<-rbind(datar2ml2,datar2ml[i,])
}
datar2ml2<-datar2ml2[-1,]

#Klasifikasi Regime Singapura
model=lm(rgdpsg2~1)
mod=msmFit(model,k=2,p=3,sw=rep(TRUE,5))
n<-nrow(mod@Fit@filtProb)
ysg<-rep(0,n)
for (i in 1:n)
{
  if (mod@Fit@filtProb[i,1]<=0.5) ysg[i]<-1
}
datar2sg1<-matrix(0,1,5)
for (i in 1:n)
```

Lampiran 10. Sintaks Pengklasifikasian *Regime* (Lanjutan)

```
{  
  if (ysg[i]==0) datar2sg1<-rbind(datar2sg1,datar2sg[i,])  
}  
datar2sg1<-datar2sg1[-1,]  
datar2sg2<-matrix(0,1,5)  
for (i in 1:n)  
{  
  if (ysg[i]==1) datar2sg2<-rbind(datar2sg2,datar2sg[i,])  
}  
datar2sg2<-datar2sg2[-1,]
```

Lampiran 11. Sintaks Regresi Probit

```
#Regresi Probit United Kingdom
puk<-
glm(yuk~rmsuk2[2:85]+rinfuk2[2:85]+rinruk2[2:85]+rexruk2[2:85],family=binomial(link="probit"))
summary(puk)
vif(puk)

#Regresi Probit Switzerland
psw<-
glm(ysw~rmssw2[4:85]+rinfsw2[4:85]+rinrsw2[4:85]+rexrsw2[4:85],family=binomial(link="probit"))
summary(psw)
vif(psw)

#Regresi Probit Indonesia
pin<-
glm(yin~rmsin2[3:85]+rinfin2[3:85]+rinrin2[3:85]+rexrin2[3:85],family=binomial(link="probit"))
summary(pin)
vif(pin)

#Regresi Probit Filipina
pph<-
glm(ypf~rmsph2[3:85]+rinfph2[3:85]+rinrph2[3:85]+rexrph2[3:85],family=binomial(link="probit"))
summary(pph)
vif(pph)

#Regresi Probit Jerman
pjz<-
glm(yjr~rmsjr2[3:85]+rinfjr2[3:85]+rinrjr2[3:85]+rexrjr2[3:85],family=binomial(link="probit"))
summary(pjz)
vif(pjz)

#Regresi Probit Denmark
pdn<-
glm(ydn~rmsdn2[4:85]+rinfdn2[4:85]+rinrdn2[4:85]+rexrdn2[4:85],family=binomial(link="probit"))
summary(pdn)
vif(pdn)

#Regresi Probit Malaysia
pml<-
glm(yml~rmsml2[2:85]+rinfml2[2:85]+rinrml2[2:85]+rexrml2[2:85],family=binomial(link="probit"))
summary(pml)
vif(pml)

#Regresi Probit Singapura
psg<-
glm(ysg~rmssg2[4:85]+rinfsg2[4:85]+rinrsg2[4:85]+rexrsg2[4:85],family=binomial(link="probit"))
summary(psg)
vif(psg)
```

Lampiran 12. Sintaks Estimasi *Long Memory* Semua Variabel pada setiap *Regime*

```
#PACKAGE
library(LongMemoryTS)

#Estimasi Parameter d pada setiap Negara disetiap Regime
dv<-function(variabelnegaratiapregime,m)
{
deret<-variabelnegaratiapregime #Matriks Volatilitas Variabel
Suatu Negara pada Satu Regime
T<-nrow(deret)
D<-c(0,5)
D[1]<-ELW(deret[,1],m=floor(1+T^m1))$d #Parameter d Volatilitas
GDP
D[2]<-ELW(deret[,2],m=floor(1+T^m1))$d #Parameter d Volatilitas
Money Supply
D[3]<-ELW(deret[,3],m=floor(1+T^m1))$d #Parameter d Volatilitas
Inflation
D[4]<-ELW(deret[,4],m=floor(1+T^m1))$d #Parameter d Volatilitas
Interest Rate
D[5]<-ELW(deret[,5],m=floor(1+T^m1))$d #Parameter d Volatilitas
Exchange Rate
}

#Estimasi Koefisien Cointegration pada setiap Negara disetiap
Regime
kc<-function(variabelnegaratiapregime,m)
{
deret<-variabelnegaratiapregime #Matriks Volatilitas Variabel
Suatu Negara pada Satu Regime
T<-nrow(deret)
m0<-m1<-m2<-m3<-floor(T^m)
B<-
as.numeric(FMNBLs(deret[,2:5],deret[,1],m0=m0,m1=m1,m2=m2,m3=m3))

#Koefisien Model Cointegration
B<-round(B,4)
}
#Estimasi Parameter d pada Residual Model Cointegration setiap
Negara disetiap Regime
dr<-function(B, variabelnegaratiapregime,m)
{
deret<-variabelnegaratiapregime #Matriks Volatilitas Variabel
Suatu Negara pada Satu Regime
T<-nrow(deret)
d0<-deret[,1]-
(deret[,2]*B[1]+deret[,3]*B[2]+deret[,4]*B[3]+deret[,5]*B[4])
D<- ELW(c0,m=floor(1+T^m))$d #Parameter d Residual Cointegration
}
```

Lampiran 13. Surat Izin Penggunaan Data

SURAT PERNYATAAN

Saya yang bertandatangan dibawah ini, mahasiswa Departemen Statistika FSAD ITS.

Nama : Aisyah Abdullah
NRP : 06211750012008
Program : Magister

Menyatakan bahwa data yang digunakan dalam Tesis ini merupakan data sekunder yang diambil dari publikasi lainnya yaitu:

Sumber:

1. www.oecd.org
2. www.ceicdata.com
3. www.aric.adb.org

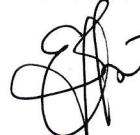
Keterangan:

1. Data GDP United Kingdom, Switzerland, Jerman, dan Denmark kuartal 1 tahun 1998 sampai kuartal 1 tahun 2019
2. Data *money supply, inflation, interest rate, dan exchange rate* Januari 1998 sampai Maret 2019
3. Data GDP Indonesia, Filipina, Malaysia, dan Singapura kuartal 1 tahun 1998 sampai kuartal 1 tahun 2019

Surat ini dibuat dengan sebenar-benarnya. Apabila ada pemalsuan data maka saya siap menerima sanksi dengan aturan yang berlaku.

Surabaya, 30 Januari 2020

Mahasiswa

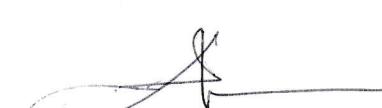


Aisyah Abdullah

NRP. 06211750012008

Mengetahui

Pembimbing I



Dr. rer. pol. Heri Kuswanto, M.Si.
NIP: 19820326 200312 1 004

Pembimbing II



Dr. rer. pol. Dedy Dwi Prastyo, M.Si.
NIP: 19831204 200812 1 002

BIOGRAFI PENULIS



Penulis bernama lengkap Aisyah Abdullah, lahir pada tanggal 3 Oktober 1995 di Jombang, Jawa Timur. Penulis merupakan anak pertama dari empat bersaudara dari pasangan Abdullah bin Umar bin Smeer dan Latifah Abdurrahman Babher. Pebulis telah menempuh pendidikan formal di TK Al-Irsyad Surabaya (1999-2001), SD Al-Irsyad Surabaya (2001-2007), SMP Al-Irsyad Surabaya (2007-2010), SMA Al-Irsyad Surabaya (2010-2013). Pada tahun 2013 penulis melanjutkan studi jenjang Strata-1 di Jurusan Statistika Fakultas Sains dan Teknologi Universitas Airlangga dan lulus pada tahun 2017. Pada tahun 2017 semester genap, penulis melanjutkan studi jenjang Strata-2 di Jurusan Statistika Fakultas Sains dan Analitika Data Institut Teknologi Sepuluh Nopember. Penulis menyadari masih banyak kesalahan dan kekurangan dalam Tesis ini, bagi pembaca yang memiliki kritik, saran, dan ingin berdiskusi lebih lanjut tentang Tesis ini bisa menghubungi penulis melalui email aisyahbinsmeer39@gmail.com.