

**PERAMALAN VOLATILITAS DATA *RETURN* KURS RUPIAH  
TERHADAP DOLLAR DENGAN METODE *INTEGRATED  
GENERALIZED AUTOREGRESSIVE CONDITIONAL  
HETEROSCEDASTICITY (IGARCH)***

**(Skripsi)**

**Oleh**

**Beni Darmawan**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG  
2019**

## **ABSTRACT**

### **FORECASTING VOLATILITY OF RETURN DATA ON THE RUPIAH EXCHANGE RATE AGAINST THE DOLLAR USING THE INTEGRATED GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY (IGARCH) METHOD**

**By**

**Beni Darmawan**

The purpose of this study is to apply one of the ARCH / GARCH models, namely Integrated Generalized Autoregressive Conditional Heteroscedasticity (IGARCH) in predicting volatility in returning data on the Rupiah Rate against the US Dollar for the next five periods. In time series data, sometimes the behaviour of variance of the time series data are not constant or heteroschedasticity. One of the models to deal with this tipe of problem, we can use IGARCH model. IGARCH model can be used to forecast volatility. Based on the results of the analysis obtained the best model is MA ([24]) IGARCH (3,2) and with the results of the variance forecast obtained volatility for the next five periods which indicates that high volatility cannot be used. However, the estimated level of use of the IGARCH(3,2) model is relatively low.

**Keywords:** Heteroschedasticity, Volatility, IGARCH

## **ABSTRAK**

### **PERAMALAN VOLATILITAS DATA *RETURN* KURS RUPIAH TERHADAP DOLLAR DENGAN METODE *INTEGRATED GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY* (IGARCH)**

Oleh

**Beni Darmawan**

Tujuan dari penelitian ini adalah mengaplikasikan salah satu model ARCH/GARCH yaitu Integrated Generalized Autoregressive Conditional Heteroscedasticity (IGARCH) dalam meramalkan volatilitas pada data return Kurs Rupiah terhadap *US Dollar* untuk lima periode ke depan. Didalam data *time series*, terkadang didapat varians yang tidak konstan atau heteroschedasticity. Salah satu model untuk menyelesaikan kondisi ini adalah model IGARCH. Model IGARCH dapat digunakan untuk meramalkan volatilitas. Berdasarkan hasil analisis diperoleh bahwa model terbaik adalah MA([24]) IGARCH(3,2) dan dengan mengakarkan hasil ramalan variansnya diperoleh volatilitas untuk lima periode kedepan yang menunjukkan bahwa tidak terjadi volatilitas tinggi. Akan tetapi tingkat peramalan menggunakan model IGARCH relatif rendah.

**Kata Kunci** : Heteroskedastisitas, Volatilitas, IGARCH

**PERAMALAN VOLATILITAS DATA *RETURN* KURS RUPIAH  
TERHADAP DOLLAR DENGAN METODE *INTEGRATED  
GENERALIZED AUTOREGRESSIVE CONDITIONAL  
HETEROSCEDASTICITY (IGARCH)***

**Oleh  
Beni Darmawan**

**Skripsi**

Sebagai Salah Satu Syarat untuk Mencapai Gelar  
**SARJANA SAINS**

Pada  
Jurusan Matematika  
Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Lampung



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG  
2019**

Judul Skripsi : **PERAMALAN VOLATILITAS DATA  
RETURN KURS RUPIAH TERHADAP  
DOLLAR DENGAN METODE *INTEGRATED  
GENERALIZED AUTOREGRESSIVE  
CONDITIONAL HETEROSCEDASTICITY  
(IGARCH)***

Nama Mahasiswa : **Beni Darmawan**

Nomor Pokok Mahasiswa : 1517031153

Program Studi : Matematika

Fakultas : Matematika dan Ilmu Pengetahuan Alam



1. Komisi Pembimbing

**Drs. Nusyirwan, M.Si.**  
NIP. 196610101992051001

**Suharsono S., M.S., M.Sc., Ph.D.**  
NIP. 196205131936031003

2. Ketua Jurusan Matematika

**Prof. Dra. Wamiliana, M.A., Ph.D.**  
NIP. 196311081989022001



**MENGESAHKAN**

1. Tim Penguji

Ketua : **Drs. Nusyirwan, M.Si.** .....

Sekretaris : **Suharsono S., M.S., M.Sc., Ph.D.** .....

Penguji  
Bukan Pembimbing : **Drs. Rudi Ruswandi, M.Si.** .....



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



**Drs. Suratman, M.Sc.**  
NIP. 196406041990031002

Tanggal Lulus Ujian Skripsi : **19 Agustus 2019**

## PERNYATAAN SKRIPSI MAHASISWA

Yang bertandatangan di bawah ini :

Nama : Beni Darmawan  
Nomor Pokok Mahasiswa : 1517031153  
Jurusan : Matematika  
Judul Skripsi : Peramalan Volatilitas Data *Return* Kurs  
Rupiah Terhadap Dollar dengan Metode  
*Integrated Generalized Autoregressive  
Conditional Heteroscedasticity (IGARCH)*

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri. Semua hasil tulisan dalam skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila kemudian hari terbukti bahwa skripsi ini merupakan hasil salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai peraturan akademik yang berlaku.

Bandar Lampung, 21 Agustus 2019

Penulis



**Beni Darmawan**  
NPM.1517031153

## **RIWAYAT HIDUP**

Penulis bernama lengkap Beni Darmawan merupakan anak sulung dari pasangan Bapak Maska dan Ibu Siti Aminah yang dilahirkan di Desa Merbau Mataram, Kecamatan Merbau Mataram, Kabupaten Lampung Selatan, pada tanggal 10 Mei 1997.

Penulis telah menempuh pendidikan Sekolah Dasar di SDN 1 Merbau Mataram tahun 2003-2009, pendidikan Sekolah Menengah Pertama di SMPN 2 Merbau Mataram pada tahun 2009-2012, dan pendidikan Sekolah Menengah Atas di SMAN 1 Tanjung Bintang pada tahun 2012-2015. Pada tahun 2015, penulis melanjutkan pendidikan di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung melalui jalur SBMPTN.

Selama menjadi mahasiswa, penulis aktif di organisasi internal kampus, diantaranya aktif sebagai anggota muda di berbagai organisasi pada tahun 2016/2016, pengurus Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) sebagai anggota Biro Kesekretariatan pada tahun 2016, pengurus Rohani Islam (ROIS) FMIPA sebagai anggota bidang HUMAS pada tahun 2016, pengurus Badan Eksekutif Mahasiswa (BEM) FMIPA sebagai anggota Departemen Advokasi dan Kesejahteraan Mahasiswa (ADKESMA) pada tahun 2016, pengurus Bina Rohani Islam Mahasiswa (BIROHMAH) Universitas Lampung



sebagai staf Departemen Hubungan Masyarakat (HUMAS) pada tahun 2016, bergabung di Generasi Muda Matematika (GEMATIKA) periode 2015-2016, dan pengurus Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) sebagai anggota Bidang Eksternal periode 2016. pengurus Rohani Islam (ROIS) FMIPA sebagai anggota bidang Dana dan Usaha Pada tahun 2017, pengurus Bina Rohani Islam Mahasiswa (BIROHMAH) Universitas Lampung sebagai staf Departemen Hubungan Masyarakat (HUMAS) pada tahun 2017, pengurus Badan Eksekutif Mahasiswa (BEM) FMIPA sebagai anggota Departemen Hubungan Luar dan Pengabdian Masyarakat (HLPM) pada tahun 2017, pengurus Badan Eksekutif Mahasiswa (BEM) Universitas Lampung sebagai staf Kementerian Dalam Negeri (DAGRI) pada tahun 2017, pengurus Dewan Perwakilan Mahasiswa (DPM) dan Majelis Permusyawaratan Mahasiswa (MPM) Universitas Lampung di komisi 4 (hubungan luar) pada tahun 2018, pengurus Dewan Perwakilan Mahasiswa (DPM) dan Majelis Permusyawaratan Mahasiswa (MPM) Universitas Lampung di komisi 4 (hubungan luar) pada tahun 2019.

Adapun sebagai bentuk pengabdian mahasiswa dan menjalankan Tri Dharma Perguruan Tinggi, penulis pada bulan Januari sampai dengan Februari 2018 melaksanakan Kuliah Kerja Nyata (KKN) di Desa Way Nipah, Kecamatan Pematang Sawa, Kabupaten Tanggamus. Pada bulan Juli sampai dengan Agustus 2018 penulis melaksanakan Kuliah Praktik (KP) di Kantor Badan Pusat Statistik Provinsi Lampung.

## **KATA INSPIRASI**

“Hai orang-orang mukmin, jika kamu menolong (agama) Allah, niscaya Dia akan menolongmu dan meneguhkan kedudukanmu.”

(QS. Muhammad : 7)

*Believe*

(Beni Darmawan)

## **PERSEMBAHAN**

*Assalamu'alaikum warahmatullahi wabarakatuh*

*Alhamdulillahirabbil'alamin... Alhamdulillahirabbil'alamin...*

*Alhamdulillahirabbil'alamin...*

Segala puji dan syukur, Kupersembahkan karya sederhana ini kepada ayah dan ibuku tercinta yang telah mencurahkan kasih sayang dan dukungan yang tiada hentinya. Bapak Drs. Nusyirwan, M.Si., Bapak Suharsono S., M.S., M.Sc., Ph.D., Bapak Drs. Rudi Ruswandi, M.Si., selaku pembimbing dan pembahas yang memberikan pelajaran berharga dan bimbingan selama penyusunan skripsi saya.

Serta

Almamater tercinta Universitas Lampung,

Semoga karya ini bermanfaat bagi banyak orang.

Aamiin

Wassalamu'alaikum warahmatullahi wabarakatuh

## SANWACANA

Alhamdulillah, puji syukur penulis panjatkan kehadiran Allah SWT, karena berkat rahmat dan karunia-Nya sehingga Penulis dapat menyelesaikan skripsi ini. Sholawat serafim senantiasa tetap tercurah kepada nabi Muhammad SAW, tuntunan dan tauladan utama bagi seluruh umat manusia. Skripsi yang berjudul “Peramalan Volatilitas Data *Return* Kurs Rupiah Terhadap Dollar dengan Metode *Integrated Generalized Autoregressive Conditional Heteroscedasticity* (IGARCH)” adalah salah satu syarat untuk memperoleh gelar Sarjana Sains di Universitas Lampung.

Penulis menyadari bahwa skripsi ini tidak akan terwujud tanpa bantuan dan doa dari mereka yang senantiasa mendukung penulis. Oleh karena itu penulis ingin mengucapkan terimakasih kepada:

1. Bapak Drs. Nusyirwan, M.Si., selaku dosen pembimbing satu yang telah membimbing, mengarahkan, dan memotivasi penulis.
2. Bapak Suharsono S., M.S., M.Sc., Ph.D., selaku dosen pembimbing kedua yang telah memberikan pengarahan dalam proses penyusunan skripsi ini.
3. Bapak Drs. Rudi Ruswandi, M.Si., selaku penguji atas saran dan kritik yang diberikan untuk skripsi ini.



4. Bapak Drs. Tiryono Ruby, M.Sc., Ph.D., selaku dosen pembimbing akademik yang telah membimbing penulis selama mengikuti perkuliahan.
5. Ibu Prof. Dra. Wamiliana, M.A., Ph.D., selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Bapak Drs. Suratman, M.Sc., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Ayah dan Ibu tercinta yang selalu mendoakan penulis, selalu memberi dukungan, dan kasih sayang yang tulus kepada penulis.
8. Keluarga Besar Kerja Cerdas Berkarya Dewan Perwakilan Mahasiswa Universitas Lampung 2018 dan Keluarga Besar Cita Rasa Bersama Dewan Perwakilan Mahasiswa Universitas Lampung 2018
9. Teman-teman di Jurusan Matematika angkatan 2015, serta Keluarga Matematika
10. Kepada seluruh pihak yang telah memotivasi, membantu, dan kebersamai Saya dalam menjalani perkuliahan hingga terselesaikannya skripsi ini semoga mendapat balasan kebaikan dari Allah SWT.

Penulis menyadari bahwa skripsi ini memiliki ketidaksempurnaan. Semoga skripsi ini dapat memberikan manfaat bagi kita semua.

Bandar Lampung, 21 Agustus 2019  
Penulis,

**Beni Darmawan**  
NPM. 1517031153

## DAFTAR ISI

	Halaman
<b>DAFTAR TABEL</b> .....	xvi
<b>DAFTAR GAMBAR</b> .....	xvii
<b>I. PENDAHULUAN</b> .....	1
1.1 Latar Belakang.....	1
1.2 Tujuan Penelitian.....	3
1.3 Manfaat Penelitian.....	4
<b>II. TINJAUAN PUSTAKA</b> .....	5
2.1 Deret Waktu.....	5
2.1.1 Identifikasi Model.....	6
2.1.2 Estimasi Parameter Model.....	8
2.1.3 Verifikasi Model.....	9
2.1.4 Peramalan.....	10
2.2 Stasioneritas.....	12
2.2.1 Augment Dickey Fuller.....	13
2.3 Fungsi Autokorelasi dan Fungsi Autokorelasi Parsial.....	14
2.3.1 Fungsi Autokorelasi.....	15
2.3.2 Fungsi Autokorelasi Parsial.....	17
2.4 Model Deret Waktu.....	21
2.4.1 Model Autoregressive (AR).....	21
2.4.2 Model Moving Average (MA).....	22
2.4.3 Model Autoregressive Moving Average (ARMA).....	23
2.5 Model ARIMA.....	24
2.6 Model ARCH dan GARCH.....	24
2.6.1 Model ARCH.....	24
2.6.2 Model GARCH.....	25
2.7 Model IGARCH.....	26
2.8 Uji Lagrange Multiplier (LM).....	27
2.9 Return.....	27
2.10 Volatilitas.....	28

<b>III. METODOLOGI PENELITIAN</b> .....	31
3.1 Waktu dan Tempat Penelitian.....	31
3.2 Data Penelitian.....	31
3.3 Metode Penelitian.....	31
3.4 Digram Alir.....	33
<b>IV. HASIL DAN PEMBAHASAN</b> .....	34
4.1 Analisis Deskriptif.....	34
4.2 Identifikasi Plot Data.....	35
4.3 Uji Stasioneritas Data.....	35
4.4 Identifikasi Model.....	36
4.5 Estimasi Parameter.....	38
4.6 Verifikasi Model.....	39
4.6.1 Uji Independensi Residual.....	39
4.6.2 Uji Normalitas Residual.....	40
4.7 Identifikasi Efek ARCH.....	41
4.8 Estimasi Parameter Model ARCH-GARCH.....	42
4.9 Estimasi Parameter Model IGARCH.....	44
4.10 Peramalan Volatilitas.....	46
<b>V. KESIMPULAN</b> .....	49
<b>DAFTAR PUSTAKA</b> .....	50
<b>LAMPIRAN</b>	

## DAFTAR TABEL

Tabel	halaman
1. Pola ACF dan PACF.....	7
2. Nilai MAPE untuk Evaluasi Peramalan.....	12
3. Statistik Deskriptif Data.....	34
4. Uji Stasioneritas Augmented Dickey Fuller.....	36
5. Estimasi Parameter.....	38
6. Uji ARCH-LM.....	41
7. Estimasi Parameter Model ARCH-GARCH.....	42
8. Estimasi Parameter IGARCH.....	44
9. Peramalan Volatilitas.....	47



## DAFTAR GAMBAR

Gambar	halaman
1. Diagram Alir IGARCH.....	33
2. Plot Data Return.....	35
3. Korelogram ACF dan PACF.....	37
4. Korelegram MA ([24]).....	39
5. Output Uji Normalitas MA ([24]).....	40
6. Plot Peramalan Varians.....	47
7. Hasil Peramalan return kurs rupiah terhadap <i>US Dollar</i> .....	48

## **I. PENDAHULUAN**

### **1.1 Latar Belakang**

Kebutuhan manusia setiap tahunnya akan meningkat dan beragam, sedangkan produksi dalam negeri memiliki keterbatasan dalam meningkatkan jumlah jenis barang atau jasa. Hal ini mendorong terjadinya kegiatan perdagangan internasional baik berupa barang maupun jasa. Pembayaran dalam perdagangan internasional menggunakan valuta asing (valas). Pasar valuta asing memfasilitasi pertukaran valuta sedangkan tarif dari pertukaran mata uang disebut dengan kurs. Sebagaimana diketahui bahwa suatu bangsa tidak dapat mencukupi semua konsumsinya dari hasil produksinya sendiri, maka diperlukan pembelian barang atau jasa dari bangsa lain, dan ada pula beberapa komoditi yang hasilnya melebihi kebutuhan dalam negeri sehingga dapat dijual ke bangsa lain. Oleh karena itu suatu bangsa pasti memerlukan mata uang asing dalam transaksi internasionalnya. Kebutuhan akan uang asing yang kemudian disebut valas ini akan menimbulkan persoalan yang cukup pelik yaitu menentukan seberapa besar nilai tukar dari mata uang satu negara terhadap mata uang negara lain (Suprpto, 1984). Nilai tukar mata uang atau kurs suatu negara adalah jumlah satuan matauang domestik yang dapat dipertukarkan dengan satu unit mata uang negara lain. Mata uang selalu menghadapi kemungkinan penurunan kurs (depresiasi) terhadap mata uang lainnya, atau sebaliknya mengalami kenaikan nilai tukar

(apresiasi). Adanya penurunan dan kenaikan kurs ini membuat banyak orang memilih berinvestasi di valas karena sifatnya yang likuid atau dapat dijual kembali dengan cepat. Selain likuid, percepatan pergerakan kurs yang tinggi pada valas, menjadikan valas sebagai salah satu alternatif dalam berinvestasi.

*US Dollar (United States Dollar)* merupakan salah satu mata uang yang stabil dan kuat serta termasuk dalam salah satu mata uang yang paling banyak digunakan di dunia. Selain itu Indonesia dan Amerika banyak menjalin kerjasama dalam berbagai bidang yang membuat kedua negara ini banyak melakukan transaksi. Semakin banyak transaksi yang dilakukan semakin tinggi pula frekuensi peredaran mata uang di kedua negara tersebut. Hal ini membuat *US Dollar* dapat menjadi salah satu bentuk investasi valas yang bisa dipilih. Akan tetapi kegiatan investasi dalam bentuk apapun tidak dapat terhindar dari resiko, dengan negara Indonesia yang termasuk negara berkembang. Bekaert dan Harvey (1995) mengatakan volatilitas pasar saham di pasar negara-negara berkembang (*emerging market*) umumnya jauh lebih tinggi dari pada pasar negara-negara maju.

Volatilitas yang tinggi menggambarkan tingkat resiko yang dihadapi pemodal, karena mencerminkan fluktuasi pergerakan harga saham sehingga besar kemungkinan investasi saham yang dilakukan di Indonesia mempunyai peluang resiko yang tinggi. Sifat penting yang sering dimiliki oleh data runtun waktu di bidang keuangan khususnya untuk data return yaitu distribusi probabilitas dari return bersifat *fat tails* (ekor gemuk) dan *volatility clustering* atau sering disebut sebagai kasus heterokedastisitas. Model runtun waktu yang dapat digunakan

untuk memodelkan kondisi ini di antaranya pemodelan data time series dengan menggunakan metode *Autoregressive* (AR), *Moving Average* (MA), *Autoregressive Moving Average* (ARMA) menjadi kurang tepat untuk digunakan, maka diperlukan metode lain untuk mengatasi masalah keheterogenan variansi tersebut. Untuk mengatasi masalah tersebut, Engle pada tahun 1982 memperkenalkan model *Autoregressive Conditional Heteroscedasticity* (ARCH) yang kemudian pada tahun 1986, Bollerslev mengembangkannya menjadi model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH). Model ARCH/GARCH telah menjadi model yang banyak digunakan untuk meramalkan volatilitas. Akan tetapi model ARCH-GARCH tidak selalu dapat menangkap secara penuh adanya *unit root* dengan frekuensi tinggi, sehingga sangat sulit untuk memberikan keputusan kapan suatu pelaku saham akan memposisikan dirinya sebagai pembeli atau penjual. Selain itu model ARCH dan GARCH tidak mempertimbangkan *leverage effect* secara mendalam. Definisi *leverage effect* yaitu suatu keadaan *bad news* dan *good news* yang memberikan pengaruh asimetris terhadap volatilitas. Data dikatakan *bad news* ketika volatilitas mengalami penurunan sedangkan keadaan dikatakan *good news* ketika volatilitas mengalami kenaikan secara berkala. Francq dan Jakobian (2010) menemukan model *Integrated Generalized Autoregressive Conditional Heteroskedasticity* (IGARCH) yang dapat menutupi kelemahan model GARCH. Oleh karena itu penulis akan mengaplikasikan model *Integrated Generalized Autoregressive Conditional Heteroscedasticity* (IGARCH) dalam meramalkan volatilitas data return kurs Rupiah terhadap *US Dollar*.



## **1.2 Tujuan Penelitian**

Tujuan dari penelitian ini adalah mengaplikasikan salah satu model ARCH/GARCH yaitu IGARCH dalam meramalkan volatilitas pada data return kurs Rupiah terhadap *US Dollar*.

## **1.3 Manfaat Penelitian**

Penelitian ini memiliki manfaat sebagai berikut:

1. Menambah wawasan mengenai model IGARCH.
2. Mengaplikasikan model IGARCH dalam meramalkan volatilitas data return kurs Rupiah terhadap *US Dollar*.

## II. TINJAUAN PUSTAKA

### 2.1 Deret Waktu

Data deret waktu merupakan kumpulan nilai-nilai pengamatan dari suatu variabel yang diambil pada waktu yang berbeda. Data jenis ini dikumpulkan pada interval waktu tertentu, misalnya harian, mingguan, bulanan, dan tahunan. Secara umum terdapat empat macam pola data deret waktu, yaitu horizontal, trend, musiman, dan siklis. Pola data horizontal terjadi saat data observasi berfluktuasi di sekitaran suatu nilai konstan atau mean membentuk garis horizontal atau data ini juga disebut dengan data stasioner. Pola trend terjadi bilamana data pengamatan mengalami kenaikan atau penurunan selama periode jangka panjang, suatu data pengamatan yang mempunyai trend disebut data nonstationer. Pola data musiman terjadi jika suatu deret dipengaruhi oleh faktor musiman yang berulang dari periode ke periode berikutnya. Pola data siklis terjadi saat deret data dipengaruhi oleh fluktuasi ekonomi jangka panjang seperti yang berhubungan dengan siklus bisnis. Analisis deret waktu adalah analisis yang mempelajari hubungan timbal balik antar waktu. Tujuan dalam analisis deret waktu adalah untuk menemukan cara yang berguna atau model untuk mengekspresikan hubungan waktu yang terstruktur antara beberapa variabel atau peristiwa untuk kemudian kita dapat mengevaluasi hubungan ini atau melakukan peramalan dari satu atau lebih variabel (Gujarati dan Porter, 2009).

Analisis deret waktu dikenalkan pada tahun 1970 oleh Box dan Jenkins. Dasar pemikiran *time series* adalah pengamatan sekarang ( $Z_t$ ) tergantung pada 1 atau beberapa pengamatan sebelumnya ( $Z_{t-k}$ ). Ketidakstasioneran dalam suatu data *time series* meliputi varian dan rata-rata. Proses stasioneritas data dalam varian dapat dilakukan dengan transformasi BoxCox, sedangkan proses stasioneritas data dalam rata-rata dapat dilakukan dengan pembedaan (*differencing*). Secara umum tahapan pemodelan data deret waktu adalah (Aswi dan Sukarna,2006).

1. Identifikasi model
2. Estimasi Parameter
3. Verifikasi Model
4. Peramalan (*Forecasting*)

### 2.1.1 Identifikasi Model

Langkah pertama yang perlu dilakukan dalam membangun model adalah mendeteksi masalah stasioner data yang digunakan. Jika data tidak stasioner pada level, diperlukan proses diferensiasi untuk mendapatkan data yang stasioner (baik pada level maupun pada differens), langkah selanjutnya adalah mengidentifikasi model. Metode yang umum digunakan untuk pemilihan model melalui *correlogram Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Misalnya, jika dimiliki data deret waktu sebagai berikut  $Y_1, Y_1, \dots, Y_n$ , maka dapat dibangun pasangan nilai  $(Y_1, Y_{k+1}), (Y_2, Y_{k+2}), \dots, (Y_n, Y_{k+n})$  *autokorelation* untuk *lag k* (korelasi antara  $Y_t$  dengan  $Y_{t+k}$ ) dinyatakan sebagai  $\rho_k$ , yaitu :

$$\rho_K = \frac{\sum_{t=k+1}^T (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^T (Y_t - \bar{Y})^2} \quad (2.1)$$

dimana,  $\rho_K$  = koefisien autokorelasi untuk lag  $k$  dan  $\bar{Y}$  = rata-rata data deret waktu. Karena  $\rho_K$  merupakan fungsi dari  $k$ , maka hubungan autokorelasi dengan lagnya dinamakan fungsi autokorelasi (*autocorrelation function* = ACF). Fungsi autokorelasi pada dasarnya memberikan informasi bagaimana korelasi antara data-data ( $Y_t$ ) yang berdekatan. Selanjutnya, jika fungsi autokorelasi tersebut digambarkan dalam bentuk kurva, dikenal dengan istilah *correlogram* ACF.

PACF didefinisikan sebagai korelasi antara  $Y_t$  dan  $Y_{t+k}$  setelah menghilangkan pengaruh autokorelasi lag pendek dari korelasi yang diestimasi pada lag yang lebih panjang. Algoritma untuk menghitung PACF sebagai berikut,

$$\left\{ \begin{array}{l} \rho_1 \quad \text{untuk } k = 1 \\ \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-j} \rho_{k-j}} \quad \text{untuk } k > 1 \end{array} \right\}$$

Dimana,  $\phi_k$  : *partial autocorrelation* pada lag  $k$  dan  $\rho_k$  adalah *autocorrelation* pada lag  $k$ . Pemilihan modelnya dengan ACF maupun PACF secara grafis mengikuti ketentuan sebagai berikut,

Tabel 1. Pola ACF dan PACF

Model	ACF	PACF
AR (p)	Menurun secara eksponensial	Menurun drastis pada lag tertentu
MA (q)	Menurun drastis pada lag tertentu	Menurun secara eksponensial
ARMA (p,q)	Menurun secara eksponensial	Menurun secara eksponensial

### 2.1.2 Estimasi Parameter Model

Menurut Gujarati dan Porter (2009), metode *maximum likelihood* adalah suatu penaksir titik yang mempunyai sifat teoritis yang lebih kuat dibandingkan dengan metode penaksir kuadrat terkecil. Metode *maximum likelihood* merupakan salah satu cara untuk mengestimasi parameter yang tidak diketahui. Prosedur estimasi *maximum likelihood* menguji apakah estimasi maksimum yang tidak diketahui dari fungsi likelihood suatu sampel nilainya sudah memaksimumkan fungsi likelihood. Fungsi PDF (*Probability Density Function*) dari variabel acak  $y$  dengan parameter  $\beta$ , dinotasikan  $f(y|\beta)$ : Probabilitas sampel *random* dari *joint* PDF untuk  $y_1, y_2, \dots, y_n$  (dimana  $n$  saling bebas dan berdistribusi sama) dapat dihitung:

$$f(y_1, y_2, \dots, y_n | \beta) = \prod_{i=1}^n f(y_i | \beta) = l(\beta | y) \quad (2.2)$$

Metode *maximum likelihood* akan memilih nilai yang diketahui sedemikian hingga memaksimumkan nilai probabilitas dari gambaran sampel secara acak yang telah diperoleh secara aktual. Fungsi *log likelihood*-nya adalah :

$$L(\beta | y) = \ln l(\beta | y) = \sum_{i=1}^n \ln f(y_i | \beta) \quad (2.3)$$

Dalam banyak kasus, penggunaan diferensiasi akan lebih mudah bekerja pada logaritma natural dari  $l(x_1, x_2, \dots, x_n | \beta)$ , yaitu:

$$L(x_1, x_2, \dots, x_n | \beta) = \ln l(x_1, x_2, \dots, x_n | \beta) \quad (2.4)$$

Salah satu pemilihan model terbaik dari beberapa model yang sesuai dapat berdasarkan nilai AIC (*Akaike's Information Criterion*) dan SC (*Schwarz Criterion*). Jika model dibandingkan, maka model dengan nilai AIC terkecil merupakan model yang lebih baik. Kegunaan SC pada prinsipnya tidak berbeda

dengan AIC. Semakin kecil nilai AIC dan SC maka semakin baik sebuah model.

Model umum AIC dan SIC adalah sebagai berikut (Brooks, 2014).

$$AIC = \left( e^{\frac{2k}{n}} \right) \left( \frac{\sum e_t^2}{n} \right) = \left( e^{\frac{2k}{n}} \right) \left( \frac{SSE}{n} \right) \quad (2.5)$$

$$SC = \left( \frac{k}{n} \right) \left( \frac{\sum e_t^2}{n} \right) = \left( \frac{k}{n} \right) \left( \frac{SSE}{n} \right) \quad (2.6)$$

dengan,

$$SSE = \text{Sum Square Error} = \sum (e_t^2 = \sum (\hat{Z}_t - Z_t)^2)$$

k = jumlah parameter model

n = Jumlah observasi (sampel)

### 2.1.3 Verifikasi Model

Pemeriksaan diagnostik dilakukan dengan mengamati apakah residual dari model terestimasi merupakan proses *white noise* atau tidak. Model dikatakan memadai jika asumsi dari  $error(\epsilon_t)$  memenuhi proses *white noise* dan berdistribusi normal.

Uji kenormalan *error* digunakan untuk melihat apakah suatu proses *error* berdistribusi normal atau tidak. Uji kenormalan dapat dilakukan dengan uji *Kolmogorov Smirnov* dengan hipotesis

$H_0$  = residual berdistribusi normal

$H_1$  = residual tidak berdistribusi normal

dengan statistik uji

$D_{hitung} = |F_t - F_s| < D_{\alpha, n}$  maka terima  $H_0$ . Jika  $D_{hitung} > D_{tabel}$  maka tolak  $H_0$ .

dengan

$F_t$  = Probabilitas kumulatif normal ( $F_t=0,05 - Z_{tabel}$ ).

$F_s$  = Probabilitas kumulatif empiris (banyaknya angka sampai angka ke  $n_i$ /banyaknya seluruh angka pada data).

#### 2.1.4 Prediksi atau Peramalan

Tahap terakhir adalah melakukan prediksi atau peramalan berdasarkan model yang terpilih. Menurut Supranto (1984), peramalan adalah memperkirakan sesuatu pada waktu-waktu yang akan datang berdasarkan data masa lampau yang dianalisis secara ilmiah, khususnya menggunakan metode statistika. Menurut Assauri (1993), peramalan merupakan seni dan ilmu dalam memprediksikan kejadian yang mungkin dihadapi pada masa yang akan datang. Masalah dalam peramalan biasanya dibagi kedalam tiga istilah. Istilah pendek, sedang, dan panjang dalam peramalan. Istilah pendek menyangkut kejadian yang hanya beberapa waktu periode (hari, minggu, dan bulan) kedepannya. Lalu istilah sedang artinya peramalannya secara luas dari satu sampai dua tahun kedepannya. Istilah panjang sendiri dalam masalah peramalan dapat diperluas menjadi dua tahun atau lebih (Shewhart and Wilks, 2008). Dengan metode peramalan yang tepat, hasil peramalannya dapat dipercaya ketetapanannya. Oleh karena masing-masing metode peramalan berbeda-beda, maka penggunaannya harus hati-hati terutama dalam pemilihan metode dalam peramalan.

Pada kenyataannya tidak ada peramalan yang memiliki tingkat akurasi 100%, karena setiap peramalan pasti mengandung kesalahan. Oleh karena itu, untuk mengetahui metode peramalan dengan tingkat akurasi yang tinggi, maka dibutuhkan menghitung tingkat kesalahan dalam suatu peramalan. Semakin kecil

tingkat kesalahan yang dihasilkan, maka semakin baik peramalan tersebut. Standar umum pengukuran kesalahan peramalan yang digunakan adalah *Mean Absolute Error* (MAE) untuk akurasi, dan *Mean Absolute Percentage Error* (MAPE) untuk persentase akurasi (Brooks, 2014).

1. *Mean Absolute Error* (MAE)

$$\frac{\sum_{t=1}^n |A_t - P_t|}{n} \quad (2.7)$$

dimana,

$A_t$  = nilai aktual pada waktu ke-t

$P_t$  = nilai peramalan pada waktu ke-t

n = banyak data

2. *Mean Absolute Percentage Error* (MAPE)

$$\frac{\sum_{t=1}^n \left( \frac{A_t - P_t}{A_t} \right)}{n} \times 100\% \quad (2.8)$$

dimana,

$A_t$  = nilai aktual pada waktu ke-t

$P_t$  = nilai peramalan pada waktu ke-t

n = banyak data

Nilai MAPE digunakan untuk menganalisis kinerja proses peramalan seperti yang tertera pada Tabel 2 berikut.



Tabel 2. Nilai MAPE untuk Evaluasi Peramalan

Nilai MAPE	Akurasi Peramalan MAPE
10%	Tinggi
10% < MAPE 20%	Baik
20% < MAPE 50%	<i>Reasonable</i>
MAPE 50%	Rendah

## 2.2 Stasioneritas

Menurut Juanda dan Junaidi (2012), data deret waktu dikatakan stasioner jika memenuhi dua kriteria yaitu nilai tengah (rata-rata) dan ragamnya konstan dari waktu ke waktu. Secara statistik dinyatakan sebagai berikut, (rata-rata yang konstan) serta (ragam konstan). Berdasarkan nilai tengah dan ragamnya, terdapat dua jenis kestasioneran data:

1. Data stasioner pada nilai tengahnya, jika data berfluktuasi disekitar suatu nilai tengah yang tetap dari waktu ke waktu.
2. Data stasioner pada ragamnya, jika data berfluktuasi dengan ragam yang tetap dari waktu ke waktu.

Untuk mengatasi data yang tidak stasioner pada nilai tengahnya, dapat dilakukan proses pembedaan atau differensiasi terhadap deret data asli. Proses differensiasi adalah proses mencari perbedaan antara data satu periode dengan periode sebelumnya secara berurutan. Data yang dihasilkan disebut data differensiasi tingkat pertama. Selanjutnya, jika differensiasi pertama belum menghasilkan deret yang stasioner, dilakukan differensiasi tingkat berikutnya.

Mendifferensialkan data differensiasi tingkat pertama akan menghasilkan differensiasi tingkat kedua. Mendifferensiasikan data differensiasi tingkat kedua akan menghasilkan differensiasi tingkat ketiga, dan seterusnya. Untuk mengatasi data yang tidak stasioner pada ragamnya, umumnya dilakukan transformasi data asli ke bentuk logaritma natural atau akar kuadrat. Data yang tidak stasioner pada ragam juga dapat disebabkan oleh pengaruh musiman, sehingga setelah dihilangkan pengaruh musimnya dapat menjadi data stasioner. Selanjutnya, jika data tidak stasioner baik pada nilai tengah maupun ragamnya, dilakukan proses differensiasi dan transformasi  $Ln$  atau akar kuadrat. Menurut Muis (2008), terdapat dua cara untuk menguji suatu data bersifat stasioner atau tidak, yaitu dengan cara grafik berupa tampilan korelogram dengan nilai *Autocorrelation Function* (ACF), dan *Partial Autocorrelation Function* (PACF) beserta nilai statistiknya, atau secara kuantitatif berupa uji *Unit Root* dengan metode *Augmented Dickey-Fuller* (ADF) dengan uji hipotesis.

### 2.2.1 Augment Dickey Fuller

Untuk melihat kestasioneran data dapat diuji dengan menggunakan uji ADF.

Misalkan kita punya persamaan regresi :

$$\Delta Y_t = \phi Y_{t-1} + \sum_{j=1}^{p-1} \alpha_j^* \Delta Y_{t-j} + U_t \quad (2.9)$$

Dimana  $\phi$  adalah koefisien,  $Y_t$  adalah nilai variabel pada waktu ke- $t$ ,  $\alpha$  adalah suatu konstanta,  $u_t$  adalah residual pada waktu  $t$ ,  $\phi = \sum_{i=1}^p \alpha_i - 1$  dan

$\alpha_j^* = \sum_{j=1}^p \alpha_j$ . Uji statistik pada ADF berdasarkan pada t-statistic koefisien  $\phi$

dari estimasi metode kuadrat terkecil biasa.

Pada model ini hipotesis yang diuji adalah

$H_0 : \Phi = 0$  (data deret waktu tidak stasioner)

$H_1 : \Phi < 0$  (data deret waktu stasioner)

(Gujarati dan Porter, 2009)

### 2.3 Fungsi Autokorelasi dan Fungsi Autokorelasi Parsial

Dalam metode time series, alat utama untuk mengidentifikasi model dari data yang akan diramalkan menggunakan fungsi autokorelasi/*Autocorrelation Function* (ACF) dan fungsi autokorelasi parsial/*Partial Autocorrelation Function* (PACF).

#### 2.3.1 Fungsi Autokorelasi

Menurut Wei (2006) proses stasioner suatu data time series ( $X_t$ ) memiliki  $E(X_t) = \mu$  dan variansi  $\text{Var}(X_t) = E(X_t - \mu)^2 = \sigma^2$  yang konstan dan kovarian  $\text{Cov}(X_t, X_{t+k})$ , yang fungsinya hanya pada perbedaan waktu  $|t - (t+k)|$ . Maka dari itu, hasil tersebut dapat ditulis sebagai kovariansi antara  $X_t$  dan  $X_{t+k}$  sebagai berikut :

$$\gamma = \text{Cov}(X_t, X_{t+k}) = E(X_t - \mu)(X_{t+k} - \mu)$$

dan korelasi antara  $X_t$  dan  $X_{t+k}$  didefinisikan sebagai

$$\rho_k = \frac{\text{Cov}(X_t, X_{t+k})}{\sqrt{\text{Var}(X_t)\text{Var}(X_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2.10)$$

dimana notasi  $\text{Var}(X_t)$  dan  $\text{Var}(X_{t+k}) = \gamma_0$  Sebagai fungsi dari  $k$ ,  $\gamma_k$  disebut fungsi autokovarian dan  $\rho_k$  disebut fungsi autokorelasi (ACF). Dalam analisis

time series,  $\gamma_k$  dan  $\rho_k$  menggambarkan kovarian dan korelasi antara  $X_t$  dan  $X_{t-k}$  dari proses yang sama, hanya dipisahkan oleh *lag* ke- $k$ .

Fungsi autokovariansi  $\gamma_k$  dan fungsi autokorelasi  $\rho_k$  memiliki sifat-sifat sebagai berikut :

1.  $\gamma_0 = \text{Var}(X_t); \rho_0 = 1$
2.  $|\gamma_k| \leq \gamma_0; |\rho_k| \leq 1$
3.  $\gamma_k = \gamma_{-k}$  dan  $\rho_k = \rho_{-k}$  untuk semua  $k$ ,  $\gamma_k$  dan  $\rho_k$  adalah fungsi yang sama dan simetrik *lag*  $k = 0$ .

bukti

1. Dengan menggunakan definisi korelasi antara  $X_t$  dan  $X_{t-k}$ , akan dibuktikan

bahwa  $\gamma_0 = \text{Var}(X_t); \rho_0 = 1$ .

$$\rho_k = \frac{\text{Cov}(X_t, X_{t+k})}{\sqrt{\text{Var}(X_t)\text{Var}(X_{t+k})}} = \frac{\gamma_k}{\gamma_0}$$

diberikan  $k = 0$ , maka

$$\rho_0 = \frac{\text{Cov}(X_t, X_t)}{\sqrt{\text{Var}(X_t)\text{Var}(X_t)}}$$

$$\rho_0 = \frac{\text{Var}(X_t)}{\sqrt{\text{Var}^2(X_t)}}$$

$$\rho_0 = \frac{\text{Var}(X_t)}{\text{Var}(X_t)}$$

$$\rho_0 = \frac{\gamma_0}{\gamma_0}$$

$$\rho_0 = 1$$

Sifat kedua merupakan akibat dari persamaan autokorelasi kurang dari atau sama dengan 1 dalam nilai mutlak. 3.

2. Sifat tersebut diperoleh dari perbedaan waktu antara  $X_t$  dan  $X_{t+k}$

$$\gamma_k = \text{Cov}(X_t, X_{t+k}) = \text{Cov}(X_{t+k}, X_t) = \gamma_{-k}$$

Oleh sebab itu, fungsi autokorelasi sering hanya diplotkan untuk *lag nonnegatif*. Plot tersebut disebut korrelogram.

Menurut Pankratz (1991), penduga koefisien ( $r_k$ ) adalah dugaan dari koefisien autokorelasi secara teoritis yang bersangkutan ( $\rho_k$ ). Nilai  $r_k$  tidak sama persis dengan  $\rho_k$  yang berkorespondensi dikarenakan error sampling. Distribusi dari kemungkinan nilai-nilai disebut dengan distribusi sampel. Galat baku dari distribusi sampling adalah akar dari penduga variansinya.

Pengujian koefisien autokorelasi:

$H_0 : \rho_k = 0$  (Koefisien autokorelasi tidak berbeda secara signifikan)

$H_1 : \rho_k \neq 0$  (Koefisien autokorelasi berbeda secara signifikan)

Statistik uji :  $t = \frac{r_k}{SE(r_k)}$

$$r_k = \frac{\sum_{t=1}^{T-k} (X_t - \bar{X})(X_{t+k} - \bar{X})}{\sum_{t=1}^T (X_t - \bar{X})^2} \quad \text{dan} \quad SE(r_k) = \sqrt{\frac{1 + 3 \sum_{j=1}^{k-1} r_j^2}{T}} \approx \frac{1}{\sqrt{T}}$$

dengan

$SE(r_k)$  = standard error autokorelasi pada saat lag k

$r_k$  = autokorelasi pada saat lag k

k = time lag

T = jumlah observasi dalam data time series

Kriteria keputusan : tolak  $H_0$  jika nilai  $t_{\text{hitung}} > t_{/2,df}$  dengan derajat bebas  $df = T-1$ , T merupakan banyaknya data dan k adalah lag koefisien autokorelasi yang diuji.

### 2.3.2 Fungsi Autokorelasi Parsial

Autokorelasi parsial digunakan untuk mengukur tingkat keeratan antara  $X_t$  dan  $X_{t+k}$ , apabila pengaruh dari time lag 1, 2, 3, . . . , dan seterusnya sampai k-1 dianggap terpisah. Ada beberapa prosedur untuk menentukan bentuk PACF. Salah satunya akan dijelaskan sebagai berikut. Fungsi autokorelasi parsial dapat dinotasikan dengan:

$$\text{corr}(X_t, X_{t+k} | X_{t+1}, \dots, X_{t+k-1}) \quad (2.11)$$

Misalkan  $X_t$  adalah proses yang stasioner dengan  $E(X_t) = 0$ , selanjutnya  $X_{t+k}$  dapat dinyatakan sebagai model linear

$$X_{t+k} = \phi_{k1}X_{t+k-1} + \phi_{k2}X_{t+k-2} + \dots + \phi_{kk}X_t + \varepsilon_{t+k} \quad (2.12)$$

dengan  $\phi_{ki}$  adalah parameter regresi ke-i dan  $\varepsilon_{t+k}$  adalah nilai kesalahan yang tidak berkorelasi dengan  $X_{t+k-j}$  dengan  $j=1,2, \dots, k$ . Untuk mendapatkan nilai PACF, langkah pertama yang dilakukan adalah mengalikan persamaan (2.12) dengan  $X_{t+k-j}$  pada kedua ruas sehingga diperoleh :

$$X_{t+k-j}X_{t+k} = \phi_{k1}X_{t+k-1}X_{t+k-j} + \phi_{k2}X_{t+k-2}X_{t+k-j} + \dots + \phi_{kk}X_tX_{t+k-j} + \varepsilon_{t+k}X_{t+k-j}$$

selanjutnya nilai harapannya adalah

$$\begin{aligned} E(X_{t+k-j}X_{t+k}) &= E(\phi_{k1}X_{t+k-1}X_{t+k-j} + \phi_{k2}X_{t+k-2}X_{t+k-j} + \dots + \phi_{kk}X_tX_{t+k-j} + \varepsilon_{t+k}X_{t+k-j}) \\ &= \phi_{k1}E(X_{t+k-1}X_{t+k-j}) + \phi_{k2}E(X_{t+k-2}X_{t+k-j}) + \dots + \phi_{kk}E(X_tX_{t+k-j}) + \\ &\quad E(\varepsilon_{t+k}X_{t+k-j}) \end{aligned}$$

dimisalkan nilai  $E(X_{t+k-j}X_{t+k}) = \gamma_j$ ,  $j=0,1,\dots,k$  dan karena  $E(\varepsilon_{t+k}X_{t+k-j}) = 0$ , maka diperoleh

$$\gamma_j = \phi_{k1}\gamma_{j-1} + \phi_{k2}\gamma_{j-2} + \dots + \phi_{kk}\gamma_{j-k} \quad (2.13)$$

persamaan (2.13) dibagi dengan  $\gamma_0$

$$\frac{Y_j}{Y_0} = \phi_{k1} \frac{Y_{j-1}}{Y_0} + \phi_{k2} \frac{Y_{j-2}}{Y_0} + \dots + \phi_{kk} \frac{Y_{j-k}}{Y_0}$$

diperoleh

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kk}\rho_{j-k}, j = 1, 2, 3, \dots, k$$

untuk  $j = 1, 2, 3, \dots, k$  didapatkan sistem persamaan sebagai berikut :

$$\rho_1 = \phi_{k1}\rho_0 + \phi_{k2}\rho_1 + \dots + \phi_{kk}\rho_{k-1}$$

$$\rho_2 = \phi_{k1}\rho_1 + \phi_{k2}\rho_0 + \dots + \phi_{kk}\rho_{k-2}$$

⋮

$$\rho_k = \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \dots + \phi_{kk}\rho_0 \quad (2.14)$$

Sistem persamaan (2.14) dapat diselesaikan dengan menggunakan aturan Cramer. Persamaan (2.14) untuk  $j = 1, 2, 3, \dots, k$  digunakan untuk mencari nilai-nilai fungsi autokorelasi parsial lag  $k$  yaitu  $\phi_{k1}, \phi_{k2}, \dots, \phi_{kk}$ .

- a. Untuk lag pertama ( $k = 1$ ) dan ( $j = 1$ ) diperoleh sistem persamaan sebagai berikut :

$\rho_1 = \phi_{11}\rho_0$ , karena  $\rho_0 = 1$  sehingga  $\rho_1 = \phi_{11}$  yang berarti bahwa fungsi autokorelasi parsial pada lag pertama akan sama dengan fungsi autokorelasi pada lag pertama.

- b. Untuk lag kedua ( $k = 2$ ) dan ( $j = 1, 2$ ) diperoleh sistem persamaan

$$\rho_1 = \phi_{11}\rho_0 + \phi_{22}\rho_1$$

$$\rho_2 = \phi_{11}\rho_1 + \phi_{22}\rho_0 \quad (2.15)$$

Persamaan (2.15) jika ditulis dalam bentuk matriks akan menjadi

$$\begin{bmatrix} \rho_0 & \rho_1 \\ \rho_1 & \rho_0 \end{bmatrix} \begin{bmatrix} \phi_{11} \\ \phi_{22} \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \end{bmatrix}$$

$A = \begin{bmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{bmatrix}, A_2 = \begin{bmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{bmatrix}$ , dan dengan menggunakan aturan Cramer

diperoleh

$$\phi_{22} = \frac{\det(A_2)}{\det(A)} = \frac{\begin{bmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{bmatrix}}{\begin{bmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{bmatrix}}$$

c. Untuk lag ketiga ( $k = 3$ ) dan ( $j = 1, 2, 3$ ) diperoleh sistem persamaan

$$\rho_1 = \phi_{11}\rho_0 + \phi_{22}\rho_1 + \phi_{33}\rho_2$$

$$\rho_2 = \phi_{11}\rho_1 + \phi_{22}\rho_1 + \phi_{33}\rho_1$$

$$\rho_3 = \phi_{11}\rho_2 + \phi_{22}\rho_1 + \phi_{33}\rho_0 \quad (2.16)$$

Persamaan (2.16) jika ditulis dalam bentuk matriks akan menjadi

$$\begin{bmatrix} \rho_0 & \rho_1 & \rho_2 \\ \rho_1 & \rho_0 & \rho_1 \\ \rho_2 & \rho_1 & \rho_0 \end{bmatrix} \begin{bmatrix} \phi_{11} \\ \phi_{22} \\ \phi_{33} \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \rho_3 \end{bmatrix}$$

$$A = \begin{bmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{bmatrix}, A_3 = \begin{bmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & \rho_3 \end{bmatrix} \text{ dan dengan menggunakan aturan}$$

Cramer diperoleh

$$\phi_{33} = \frac{\det(A_3)}{\det(A)} = \frac{\begin{bmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & \rho_3 \end{bmatrix}}{\begin{bmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{bmatrix}}$$

d. Untuk lag ke  $j = 1, 2, 3, \dots, k$  diperoleh sistem persamaannya adalah

$$\rho_1 = \phi_{11}\rho_0 + \phi_{22}\rho_1 + \phi_{33}\rho_2 + \dots + \phi_{kk}\rho_{k-1}$$

$$\rho_2 = \phi_{11}\rho_1 + \phi_{22}\rho_0 + \phi_{33}\rho_1 + \dots + \phi_{kk}\rho_{k-2}$$

$$\rho_3 = \phi_{11}\rho_2 + \phi_{22}\rho_1 + \phi_{33}\rho_0 + \dots + \phi_{kk}\rho_{k-3}$$

⋮

$$\rho_k = \phi_{11}\rho_1 + \phi_{22}\rho_2 + \phi_{33}\rho_3 + \dots + \phi_{kk}\rho_{k-0} \quad (2.17)$$

Persamaan (2.17) jika dinyatakan dalam bentuk matriks menjadi



$$\begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_2 \\ \rho_2 & \rho_1 & 1 & \dots & \rho_3 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_k \end{bmatrix} \begin{bmatrix} \phi_{11} \\ \phi_{22} \\ \phi_{33} \\ \vdots \\ \phi_{kk} \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \rho_3 \\ \vdots \\ \rho_k \end{bmatrix}$$

dengan aturan Cramer diperoleh

$$A_k = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_2 \\ \rho_2 & \rho_1 & 1 & \dots & \rho_3 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_k \end{bmatrix}$$

nilai autokorelasi parsial lag k hasilnya adalah

$$\phi_{kk} = \frac{\det(A_k)}{\det(A)} = \frac{\begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_2 \\ \rho_2 & \rho_1 & 1 & \dots & \rho_3 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_k \end{bmatrix}}{\begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_2 \\ \rho_2 & \rho_1 & 1 & \dots & \rho_3 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & 1 \end{bmatrix}}$$

dengan  $\phi_{kk}$  disebut PACF antara  $X_t$  dan  $X_{t+k}$ .

Fungsi autokorelasi parsial (PACF) adalah himpunan dari  $\phi_{kk} \{ \phi_{kk} : k = 1, 2, \dots \}$

$$\phi_{kk} = \begin{cases} 1 & k = 0 \\ 0 & k \neq 0 \end{cases}$$

Fungsi  $\phi_{kk}$  menjadi notasi standar untuk autokorelasi parsial antara observasi  $X_t$  dan  $X_{t+k}$  dalam analisis time series. Fungsi  $\phi_{kk}$  akan bernilai nol untuk  $k > p$ .

Sifat ini dapat digunakan untuk identifikasi model AR dan MA, yaitu pada model *Autoregressive* berlaku ACF akan menurun secara bertahap menuju nol dan *Moving Average* berlaku ACF menuju ke-0 setelah lag ke-q sedangkan nilai PACF model AR yaitu  $\phi_{kk} = 0, k > p$  dan model MA yaitu  $\phi_{kk} = 0, k > q$

Hipotesis untuk menguji koefisien autokorelasi parsial adalah sebagai berikut

$$H_0 : \phi_{kk} = 0$$

$$H_1 : \phi_{kk} \neq 0$$

Taraf signifikansi :  $\alpha = 5\%$

$$\text{Statistik uji : } t_{\phi_{kk}} = \frac{\phi_{kk}}{SE(\phi_{kk})}$$

dengan

$$SE(\phi_{kk}) = \frac{1}{T}$$

Kriteria keputusan :

Tolak  $H_0$  jika  $t$  hitung  $> t_{\frac{\alpha}{2}, df}$ , dengan derajat bebas  $df = T - 1$ ,  $T$  adalah banyaknya data dan  $k$  adalah *lag* autokorelasi parsial yang akan diuji (Wei, 2006).

## 2.4 Model Deret Waktu

Dalam analisis deret waktu terdapat beberapa model yang sering digunakan diantaranya model *autoregressive* (AR), model *moving average* (MA), dan model *autoregressive moving average* (ARMA).

### 2.4.1 Model Autoregressive (AR)

Menurut Juanda dan Junaidi (2012), proses regresi diri (*autoregressive*), disingkat AR, adalah regresi deret  $Y_t$  terhadap amatan waktu lampau dirinya sendiri.  $Y_{t-k}$  untuk  $k = 1, 2, \dots, p$ . Bentuk persamaannya adalah

$$Z_t = \delta + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \alpha_t \quad (2.18)$$

dimana  $\alpha_t$  *white noise*

dengan:

$Z_t$  : nilai variabel pada waktu ke-t

$\alpha_t$  : nilai-nilai *error* pada waktu t

$\phi_p$  : koefisien regresi,  $p : 1, 2, \dots, p$

$p$  : orde AR

#### 2.4.2 Model Moving Average (MA)

Proses moving average pertama kali diperkenalkan oleh Slutsky. Model ini regresinya melibatkan selisih nilai variabel sekarang dengan nilai variabel sebelumnya. *Moving Average* (MA) merupakan nilai deret waktu pada waktu ke  $t$  yang dipengaruhi oleh unsur kesalahan terbobot pada masa lalu (Makridakis, dkk., 1992).

Model *moving average* disebut juga dengan model rata-rata bergerak yang mempunyai bentuk sebagai berikut:

$$Z_t = \mu + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.19)$$

dengan :

$Z_t$  = nilai variabel pada waktu ke-t

$a_t$  = kesalahan peramalan (galat)

$a_{t-q}$  = kesalahan peramalan masa lalu,  $q=1,2,3,\dots,q$

$\theta_q$  = konstanta dan koefisien model

$q$  = orde MA

Dari persamaan tersebut, terlihat bahwa  $Z_t$  merupakan rata-rata tertimbang dengan kesalahan sebanyak  $q$  periode ke belakang. Banyaknya kesalahan yang digunakan  $q$  pada persamaan ini menandai tingkat dari model *moving average*.

### 2.4.3 Model Autoregressive Moving Average (ARMA)

Menurut Wei (2006), membentuk model *Autoregressive Moving Average* (ARMA) yang merupakan bentuk model deret waktu yang mengidentifikasi persamaan regresinya berdasarkan nilai masa lalunya dan nilai galat masa lalunya. Misalkan diketahui  $Z_t$  merupakan deret waktu stasioner maka akan diperoleh model ARMA ( $p, q$ ) dengan bentuk umumnya sebagai berikut:

$$\begin{aligned} Z_t &= \delta + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.20) \\ &= \delta + \sum_{i=1}^p \phi_i Z_{t-i} - \sum_{i=1}^q \theta_i a_{t-i} + a_t \end{aligned}$$

Persamaan diatas dapat ditulis dengan *backshift operator* menjadi:

$$(1 - \phi_1 B + \phi_2 B^2 + \dots + \phi_p B^p) Z_t = (1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q) a_t$$

$$\text{atau } \Phi(B) Z_t = \delta + \Theta(B) a_t$$

dengan

$Z_t$  = nilai variabel pada waktu ke-t

$\phi_i$  = koefisien regresi ke-i,  $i=1,2,3,\dots,p$

$p$  = order AR

$q$  = orde MA

$\theta_i$  = parameter model MA ke-i,  $i=1,2,3,\dots,q$

$a_t$  = nilai error pada waktu ke-t

$\alpha_t, \alpha_{t-1}, \alpha_{t-2}, \dots, \alpha_{t-q}$  = error pada saat t, t-1, t-2, ... ,t-q dan  $\alpha_t$  diasumsi *White Noise* dan normal

## 2.5 Model ARIMA

Model AR, MA, atau ARMA dengan data yang stasioner melalui proses diferensiasi disebut model ARIMA. Suatu deret waktu ( $Z_t$ ) disebut mengikuti model ARIMA jika deret dengan diferensiasi ke-d ( $W_t = \Delta^d Z_t$ ) adalah proses ARMA (p,d,q). Dalam praktik biasanya  $d = 2$ . Misalnya  $Z_t$  suatu ARIMA (p,1,q), dengan  $W_t = Z_t - Z_{t-1}$  maka

$$W_t = \phi_0 + \phi_1 Z_t + \dots + \phi_p Z_{t-p} + e - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (2.21)$$

## 2.6 Model ARCH dan GARCH

Pada umumnya permodelan data deret waktu harus memenuhi asumsi varians yang konstan (homoskedastisitas). Namun pada kenyataannya, banyak data deret waktu memiliki varians yang tidak konstan (heteroskedastisitas), misalnya data-data keuangan. Untuk mengatasi masalah *heteroskedastisitas* tersebut, maka digunakan model ARCH (*Autoregressive Conditional Heteroscedasticity*) dan GARCH (*Generalized Autoregressive Conditional Heteroscedasticity*).

### 2.6.1 Model ARCH

*Conditional variance* dari residual  $\varepsilon_t$  yang dilambangkan dengan  $\sigma_t^2$ , dapat ditulis dengan

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \dots + \alpha_p \varepsilon_{t-p}^2 \quad (2.22)$$

Dimana *variance* residual bergantung pada *lag* ke  $p$  dari kuadrat residual, yang dikenal sebagai *Autoregressive Conditional Heteroscedastic* (ARCH). Secara lengkap Model ARCH dapat dituliskan sebagai berikut

$$W_t = \phi_0 + \sum_{i=1}^p \phi_i Z_{t-i} - \sum_{j=1}^q \theta_j e_{t-j} + \varepsilon_t$$

$$\varepsilon_t \sim N(0, \sigma^2)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \dots + \alpha_p \varepsilon_{t-p}^2$$

dengan merupakan persamaan conditional mean (Brooks, 2014).

### 2.6.2 Model GARCH

Model ini dikemukakan oleh Bollerslev pada tahun 1986 yang merupakan generalisasi dari model ARCH, yang dikenal dengan *Generalized Autoregressive Conditional Heterokedasticity* (GARCH). Pada model GARCH, varian residual ( $\sigma_t^2$ ) tidak hanya dipengaruhi oleh residual periode lalu ( $\varepsilon_{t-1}^2$ ) tetapi juga varian residual periode lalu ( $\sigma_{t-1}^2$ ). Bentuk umum model GARCH(p,q) (Tsay,2002) :

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (2.23)$$

dengan

$\alpha_t = \varepsilon_t \sigma_t$ .dimana  $\sigma_t$  adalah akar dari  $\sigma_t^2$  dan  $\varepsilon_t$  adalah proses *i.i.d* seringkali diasumsikan berdistribusi normal standar  $N(0,1)$ . Koefisien-koefisien dari model GARCH(p,q) bersifat  $\alpha_0 > 0, \alpha_i \geq 0$  untuk  $i = 1, 2, \dots, p, \beta_j \geq 0$  untuk  $j = 1, 2, \dots, q$  agar  $\sigma_t^2 > 0$  dan  $\sum_{i=1}^p \sum_{j=1}^q (\alpha_i + \beta_j) < 1$  agar model bersifat stasioner.

## 2.7 Model IGARCH

Saat mengestimasi model GARCH, sering ditemukan bahwa jumlah koefisien parameter selalu sama dengan atau mendekati satu Francq dan Zakoian (2010). Kasus tersebut mengindikasikan bahwa data yang akan digunakan untuk mengestimasi parameter mengalami permasalahan dalam hal kestasioneran. Engle dan Bollerslev (1986) melakukan pengembangan kembali terhadap model GARCH dengan memperkenalkan Integrated GARCH atau IGARCH. Integrated dimaksudkan bahwa kemungkinan terdapat masalah akar unit yang dapat mengakibatkan ketidakstasioneran. Oleh karena itu IGARCH memiliki solusi stasioner untuk variansi yang tak hingga. Sehingga IGARCH dapat digunakan apabila dalam data yang digunakan untuk peramalan mengalami permasalahan dalam hal kestasioneran, yaitu ketika jumlah koefisien GARCH sama dengan satu. Bentuk umum dari model IGARCH adalah

$$\sigma_t^2 = \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (2.24)$$

Dimana  $\sum_{i=1}^p \alpha_i + \sum_{j=1}^q \beta_j = 1$ ,  $\alpha_i \geq 0$  dan  $\beta_j \geq 0$ ,  $\alpha_i$  adalah koefisien residual dan  $\beta_j$  adalah koefisien ragam residual yang bertindak seperti proses akar unit sehingga akan tetap menjaga keutuhan model ragam bersyarat tersebut. Perbedaan utama antara IGARCH dan GARCH adalah dalam IGARCH konstanta  $\alpha_0$  dihilangkan dan jumlah koefisien ARCH dan GARCH sama dengan satu Francq dan Zakoian (2010).

## 2.8 Uji Lagrange-Multiplier (LM)

Engle menunjukkan bahwa seringkali data time series selain memiliki masalah autokorelasi juga memiliki masalah heteroskedastisitas. Pengujian yang dapat digunakan untuk mendeteksi keberadaan heteroskedastisitas atau keberadaan efek ARCH dapat menggunakan statistik uji *Lagrange-Multiplier* (LM) (Tsay,2002).

Hipotesis :

$H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_m = 0$  (tidak ada efek ARCH)

$H_1$  : minimal ada satu  $i$  dengan  $\alpha_i \neq 0, i = 1, 2, \dots, m$  (terdapat efek ARCH)

Taraf Signifikansi :  $\alpha$

Statistik Uji :  $LM = \frac{(SSR_0 - SSR_1)/m}{SSR_1/(n-2m-1)}$

dengan,

$m$  = banyaknya lag yang diuji

$SSR_0 = \sum_{m+1}^n (\alpha_t^2 - \bar{\omega})$ ,

$\bar{\omega}$  = rata-rata sampel dari  $\alpha_t^2$

$SSR_1 = \sum_{m+1}^n \hat{\varepsilon}_t^2$

$n$  = banyak data

Kriteria uji : Tolak  $H_0$  jika Probabilitas  $LM > \chi^2(m)$  atau p-value  $< \alpha$

yang menunjukkan bahwa terdapat efek ARCH atau masalah heteroskedastisitas.

## 2.9 Return

Return dari suatu aset adalah tingkat pengembalian atau hasil yang diperoleh akibat melakukan investasi (Halim,2003). Return mudah dipakai dibandingkan



nilai sebenarnya karena bentuknya memiliki sifat statistik yang baik (Tsay, 2002). Adapun rumus return adalah sebagai berikut :

$$r_t = \frac{(P_t - P_{t-1})}{P_{t-1}} \quad (2.25)$$

$r_t$  = selisih (untung atau rugi) dari harga saham sekarang relatif dengan harga periode yang lalu

$P_t$  = harga saham pada waktu ke-t

$P_{t-1}$  = harga saham pada waktu ke (t-1)

Pada pemodelan deret waktu diperlukan suatu kondisi stasioneritas terhadap rata-rata dan varian. Salah satu cara untuk membuat data menjadi stasioner terhadap rata-rata dan varian adalah transformasi data menjadi data return (Rosadi, 2012)

## 2.10 Volatilitas

Volatilitas adalah suatu ukuran yang menunjukkan seberapa besar harga dapat meningkat dalam suatu periode waktu tertentu. Volatilitas menjadi perhatian dan subjek studi penting dalam penelitian bidang keuangan. Volatilitas secara bahasa mengandung arti tidak stabil, suatu kondisi dimana data bergerak naik turun, kadang secara ekstrem. Salah satu aplikasi utama pemodelan volatilitas adalah digunakan untuk mengukur resiko. Volatilitas biasa diproksi oleh standar deviasi dari return yang memberikan implikasi penting dalam perhitungan resiko (Ariefianto, 2012).

Volatilitas mencerminkan tingkat risiko dari suatu aset investasi tetapi tidak sama dengan risiko. Risiko terkait dengan hasil yang tidak diinginkan sedangkan volatilitas mengukur dengan ketat ketidakpastian yang bisa disebabkan oleh hasil

yang positif. Pengukuran volatilitas bertujuan untuk mengetahui fluktuasi harga suatu aset dan mengestimasi kerugian yang akan diderita. Volatilitas dalam pasar keuangan menggambarkan fluktuasi nilai suatu instrumen dalam suatu jangka waktu tertentu. Nilai volatilitas yang tinggi menunjukkan bahwa terjadi fluktuasi pada suatu aset dengan range yang sangat lebar. Sedangkan volatilitas dikatakan rendah jika suatu aset tidak berfluktuasi atau jarang berubah dan cenderung konstan (sartono, dkk., 2017). Investasi dalam aset yang memiliki volatilitas tinggi akan cenderung menghadapi risiko yang lebih tinggi dibandingkan dengan investasi dalam aset yang memiliki volatilitas rendah. Semakin tinggi pergerakan harga, maka akan semakin besar juga potensi keuntungan yang bisa didapatkan. Disisi yang lain saat volatilitas harga sangat rendah, maka sangat kecil kemungkinan untuk mendapatkan hasil yang maksimal dari pergerakan harga.

Menurut Schwert dan W. Smith, Jr. (1992) terdapat lima jenis volatilitas dalam pasar keuangan, yaitu *future volatility*, *historical volatility*, *forecast volatility*, *implied volatility*, dan *seasonal volatility*.

a. *Future Volatility*

*Future Volatility* adalah apa yang hendak diketahui para pemain dalam pasar keuangan (trader). Volatilitas yang baik adalah yang mampu menggambarkan penyebaran harga di masa yang akan datang. Trader jarang membicarakan *future volatility* karena masa depan tidak mungkin diketahui.

b. *Historical Volatility*

*Historical Volatility* adalah dihitung berdasarkan pada harga – harga saham masa lalu, dengan anggapan bahwa perilaku harga saham di masa lalu dapat

mencerminkan perilaku saham di masa mendatang. Terdapat bermacam – macam pilihan dalam menghitung *historical volatility*, namun sebagian besar metode bergantung pada pemilihan dua parameter, yaitu periode historis dimana volatilitas akan dihitung, dan interval waktu antara perubahan harga.

c. *Forecast Volatility*

Seperti halnya terdapat jasa yang berusaha meramalkan pergerakan arah masa depan harga suatu kontrak, demikian juga terdapat jasa yang berusaha meramalkan volatilitas masa depan suatu kontrak.

d. *Implied Volatility*

*Implied Volatility* adalah volatilitas pasar yang dipandang lebih realistis dibandingkan dengan *historical volatility*. Untuk mendapatkan nilai volatilitas ini, dapat digunakan metode coba – coba maupun metode – metode ilmiah seperti interpolasi. Salah satu metode untuk estimasi *Implied Volatility* adalah metode interpolasi linier dengan menggunakan kesamaan segitiga sebangun.

e. *Seasonal Volatility*

Komoditas pertanian tertentu seperti jagung, kacang, dan kedelai sangat sensitif terhadap faktor – faktor volatilitas yang muncul dari kondisi cuaca musim yang jelek. Oleh karena itu, berdasarkan faktor – faktor tersebut seseorang harus menetapkan volatilitas yang tinggi pada masa – masa tersebut.

### **III. METODOLOGI PENELITIAN**

#### **3.1 Waktu dan Tempat Penelitian**

Penelitian ini dilakukan pada semester genap tahun akademik 2018/2019, bertempat di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

#### **3.2 Data Penelitian**

Data yang digunakan adalah data deret waktu sekunder yang diambil dari Bank Indonesia *Official Website* yaitu [www.bi.go.id](http://www.bi.go.id) untuk data nilai tukar rupiah terhadap *US Dollar* periode 1 Juni 2018 – 31 Mei 2019 dalam bentuk nilai retron, data lengkap di muat dalam lampiran 1.

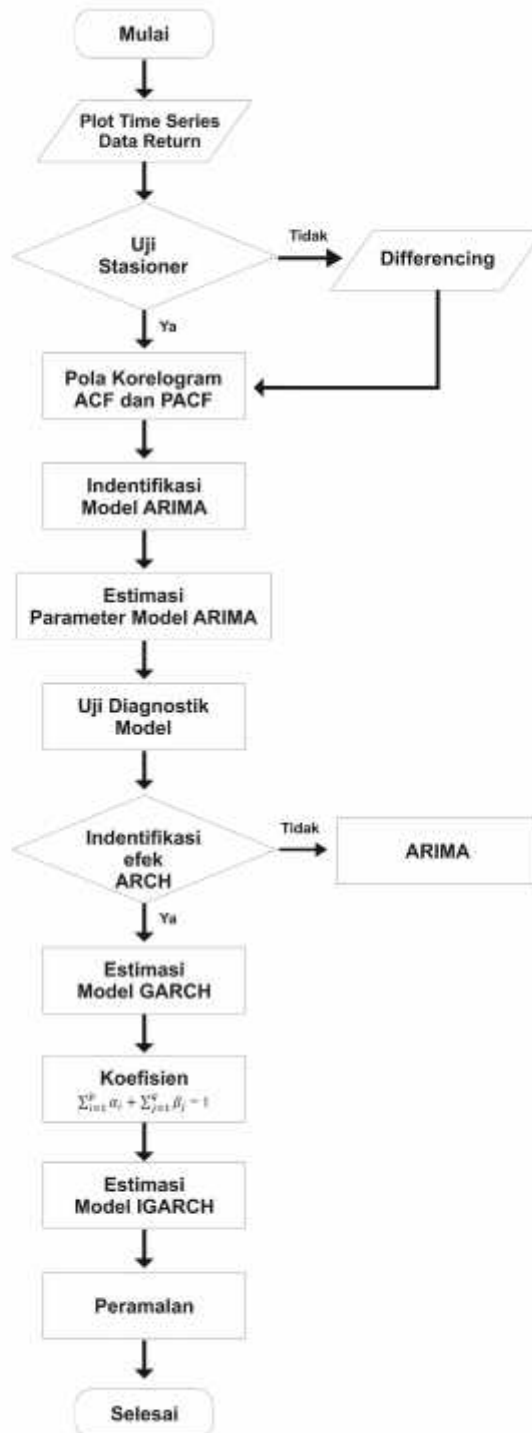
#### **3.3 Metode Penelitian**

Langkah-langkah yang dilakukan pada penelitian ini dalam mengkaji model IGARCH adalah sebagai berikut :

- a. Identifikasi data retron kurs Rupiah terhadap *US Dollar* dengan melihat plot *time series* .

- b. Memeriksa kestasioneran data retron kurs Rupiah terhadap *US Dollar* dengan hipotesis uji ADF. Jika data retron kurs Rupiah terhadap *US Dollar* tidak stasioner dilakukan proses differensi.
- c. Mengidentifikasi model dengan melihat gambar korelogram ACF dan PACF.
- d. Melakukan estimasi parameter model menggunakan metode *Maximum Likelihood Estimation* (MLE).
- e. Melakukan verifikasi model yaitu diagnostik check yang meliputi uji independensi residual dan uji normalitas model.
- f. Melakukan identifikasi efek ARCH dengan uji *Lagrange Multiplier* untuk mengetahui apakah ada efek ARCH dalam model.
- g. Estimasi parameter model GARCH menggunakan metode *Maximum Likelihood Estimation* (MLE) dan melihat nilai AIC dan SC terkecil.
- h. Apabila  $\sum_{i=1}^p \alpha_i + \sum_{j=1}^q \beta_j = 1$  maka dilakukan permodelan IGARCH
- i. Melakukan estimasi parameter model IGARCH menggunakan metode *Maximum Likelihood Estimation* (MLE) dan melihat nilai AIC dan SC terkecil.
- j. Melakukan peramalan volatilitas data return kurs Rupiah terhadap *US Dollar* menggunakan model IGARCH terbaik.

### 3.4 Diagram Alir



Gambar 1. Diagram Alir IGARCH

## V. KESIMPULAN

Berdasarkan hasil penelitian diperoleh model IGARCH(3,2) adalah model terbaik untuk peramalan volatilitas data return kurs Rupiah terhadap *US Dollar* dengan persamaan

$$\sigma_t^2 = 0.22774\varepsilon_{t-1}^2 + 0.043368\varepsilon_{t-2}^2 - 0.169449\varepsilon_{t-3}^2 - 0.075781\sigma_{t-1}^2 + 0.974122\sigma_{t-2}^2$$

Hasil peramalan dengan menggunakan model terbaik IGARCH(3,2) diperoleh ramalan varians selama lima periode kedepan, dengan mengakarkan hasil ramalan varians diperoleh nilai volatilitas pada lima periode kedepan yang menunjukkan nilai volatilitas yang tidak ekstrim serta tidak berfluktuasi yang signifikan yang berarti bahwa peluang risiko yang dihadapi tidak terlalu tinggi dan sangat kecil kemungkinan untuk mendapatkan hasil yang maksimal dari pergerakan harga dan sebaiknya digunakan oleh para trader jangka panjang dan cenderung konservatif. Akan tetapi tingkat peramalan menggunakan model IGARCH(3,2) relatif rendah, ini ditunjukkan dengan nilai *Mean Absolute Percentage Error* (MAPE)  $94,4675\% \geq 50\%$ .

## DAFTAR PUSTAKA

- Ariefianto, M.D. 2012. *Ekonometrika Esensi dan Aplikasi dengan Menggunakan EViews*. Erlangga, Jakarta.
- Assauri, S. 1998. *Manajemen Produksi dan Operasi*. Lembaga FEUI, Jakarta.
- Aswi dan Sukarna. 2006. *Analisis Deret Waktu Teori dan Aplikasi*. Andira Publisher, Makassar.
- Bekaert, Geert, and Harvey, Campbell. 1997. Emerging Equity Market Volatility. *Journal of Financial Economics*. **3**(1): 29-77.
- Brooks, C. 2014. *Introductory Econometrics for Finance* (3rd ed.). Cambridge University Press, New York.
- Engle, R.F. and Bollerslev, T. 1986. Modelling the Persistence of Conditional Variance. *Econometric Reviews*. **5**: 1-50.
- Febriana, Dian, Tarno, dan Sugito. 2014. Perhitungan Value at Risk Menggunakan Modelintegrated Generalized Autoregressive Conditional Heteroscedasticity (IGARCH). *Jurnal Gaussian*. **3**(4): 635-643.
- Francq, C. dan Zakoian, J.M. 2010. *Garch Models*. John Wiley and Sons, Ltd., United Kingdom.
- Gujarati, D.N. dan Porter, D.C. 2009. *Basic Econometrics*. Ed ke-5. McGraw-Hill Irwin, New York.
- Halim, A. 2003. *Analisis Investasi*. Jakarta, Salemba Empat.



- Juanda, B. dan Junaidi. 2012. *Ekonometrioka Deret Waktu Teori dan Aplikasi*. IPB PRESS, Bogor.
- Makridakis, S. Steven, C Wheelwright. Victor, E Mcgee. 1992. *Metode 123456789 dan Aplikasi Peramalan Jilid 2*. Jakarta: Erlangga.
- Muis, S. 2008. *Meramalkan Pergerakan Saham Menggunakan Pendekatan Model Arima, Indeks Tunggal dan Markowitz*. Graha Ilmu, Yogyakarta.
- Rosadi, D. 2012. *Ekonometrika & Analisis Runtun Waktu Terapan dengan EViews*. Andi Offset, Yogyakarta.
- Schwert, G.W., and Clifford W. Smith, Jr. 1992. *Empirical Research in Capital Market*. USA : McGraw – Hill.
- Shewhart, W.A. and Wilks, S.S. 2008. *Wiley Series in Probability and Statistics*. John Wiley & Sons, Inc., New York.
- Supranto. 1984. *Ekonomi*. Buku Dua Ghalia, Indonesia.
- Tsay, R.S. 2002. *Analysis of Financial Time Series*. John Wiley and Sons, Inc, Canada.
- Pankratz, A. 1991. *Forecasting with Dynamic Regression Models*. Willey Intersciences Publication, Canada.
- Wei, W.W. 2006. *Time Series Analysis : Univariate and Multivariate Methods*. Ed ke-2. Pearson, New York.