



TUGAS AKHIR - KM184801

**PENERAPAN MODEL EXPONENTIAL GENERALIZED
AUTOREGRESSIVE CONDITIONAL
HETEROSCEDASTICITY (EGARCH) UNTUK PERAMALAN
VOLATILITAS HARGA SAHAM**

**Andita Agustin Puspitasari
NRP 06111740000030**

Dosen Pembimbing

Dra. Laksmi Prita Wardhani, M.Si

**DEPARTEMEN MATEMATIKA
Fakultas Sains Dan Analitika Data
Institut Teknologi Sepuluh Nopember
Surabaya 2022**



TUGAS AKHIR - KM184801

**PENERAPAN MODEL EXPONENTIAL
GENERALIZED AUTOREGRESSIVE
HETEROSCEDASTICITY UNTUK PERAMALAN
VOLATILITAS HARGA SAHAM**

**Andita Agustin Puspitasari
NRP 0611174000030**

**Dosen Pembimbing
Dra. Laksmi Prita Wardhani, M.Si**

**DEPARTEMEN MATEMATIKA
Fakultas Sains Dan Analitika Data
Institut Teknologi Sepuluh Nopember
Surabaya 2022**



FINAL PROJECT - KM184801

**APPLICATION OF THE EXPONENTIAL GENERALIZED
AUTOREGRESSIVE CONDITIONAL
HETEROSCEDASTICITY (EGARCH) MODEL FOR
FORECASTING STOCK PRICE VOLATILITY**

**Andita Agustin Puspitasari
NRP 0611174000030**

**Supervisor
Dra. Laksmi Prita Wardhani, M.Si**

**DEPARTMENT OF MATHEMATICS
Faculty Of Science And Data Analytics
Sepuluh Nopember Institute of Technology
Surabaya 2022**

Halaman ini sengaja dikosongkan

LEMBAR PENGESAHAN

**PENERAPAN MODEL EXPONENTIAL GENERALIZED
AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY (EGARCH)
UNTUK PERAMALAN VOLATILITAS HARGA SAHAM**

**APPLICATION OF THE EXPONENTIAL GENERALIZED
AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY (EGARCH)
MODEL FOR FORECASTING STOCK PRICE VOLATILITY**

TUGAS AKHIR

Diajukan untuk memenuhi salah satu syarat
Untuk memperoleh gelar Sarjana Matematika
Pada bidang studi Matematika Terapan
Program Studi S-1 Departemen Matematika
Fakultas Sains dan Analitika Data
Institut Teknologi Sepuluh Nopember Surabaya

Oleh :
Andita Agustin Puspitasari
NRP. 0611174000030

Menyetujui,

Dosen Pembimbing I



Dra. Laksni Prita Wardhani, M.Si
NIP. 19611208 198803 2 001

Mengetahui,

Kepala Departemen Matematika

FSAD ITS



Subhan, Ph.D

NIP. 19710513 199702 1 001
Surabaya, 07 Februari 2022

Halaman ini sengaja dikosongkan

***PENERAPAN MODEL EXPONENTIAL GENERALIZED
AUTOREGRESSIVE CONDITIONAL
HETEROSCEDASTICITY (EGARCH) UNTUK PERAMALAN
VOLATILITAS HARGA SAHAM***

Nama Mahasiswa : **Andita Agustin Puspitasari**
NRP : **0611174000030**
Departemen : **Matematika**
Dosen Pembimbing : **Dra. Laksmi Prita Wardhani,
M.Si**

ABSTRAK

Kegiatan berinvestasi, seperti investasi saham tentunya tidak terlepas dengan dua hal yang penting yaitu, resiko serta return. Return merupakan tingkat keuntungan yang diperoleh para investor dari hasil investasi saham yang dilakukan. Tujuan dari investor adalah ingin mendapat return yang tinggi, akan tetapi return yang tinggi pasti disertai oleh resiko yang tinggi. Terdapat komponen yang penting pada kegiatan investasi yaitu volatilitas yang merupakan varians dari return. Data finansial pada umumnya memiliki kecenderungan volatilitas, sehingga diperlukan model untuk mengakomodasi volatilitas pada data finansial. Model yang dapat mengakomodasi volatilitas antara lain, ARCH-GARCH, dan EGARCH. Model ARCH dan GARCH tidak dapat mewakili sifat asimetris pada data finansial, sehingga salah satu model yang dapat mewakili sifat asimetris adalah EGARCH. Pada penelitian Tugas Akhir ini, data yang digunakan adalah data return dari harga penutupan harga saham PT. Indofarma Tbk (INAF) yang merupakan perusahaan yang bergerak di bidang farmasi yang mengalami peningkatan sejak

pada tahun 2020 yang disebabkan adanya pandemik global yaitu Covid-19. Hasil dari penelitian data return dari harga penutupan harga saham PT. Indofarma Tbk (INAF) dapat didekati dengan model ARIMA (0,1,1). Model ARIMA (0,1,1) memiliki unsur heterokedastisitas, sehingga dilakukan identifikasi model ARCH-GARCH, dan EGARCH. Karena model ARIMA (0,1,1) terdapat efek asimetris sehingga diperoleh model terbaik yaitu EGARCH (1,1) yang dapat mewakili efek asimetris. Model EGARCH (1,1) digunakan untuk meramalkan volatilitas return dari harga penutupan saham PT. Indofarma Tbk (INAF) dalam periode 01 Oktober 2020 hingga 01 September 2021. Hasil peramalan volatilitas menunjukkan bahwa terdapat kenaikan volatilitas return dari harga penutupan saham PT. Indofarma Tbk (INAF).

Kata kunci : ARIMA, EGARCH, Asimetris, Volatilitas

Halaman ini sengaja dikosongkan

**APPLICATION OF THE EXPONENTIAL GENERALIZED
AUTOREGRESSIVE CONDITIONAL
HETEROSCEDASTICITY (EGARCH) MODEL FOR
FOECASTING STOCK PRICE VOLATILITY**

Name of Student : **Andita Agustin Puspitasari**
NRP : **0611174000030**
Department : **Mathematics**
Supervisor : **Dra. Laksmi Prita Wardhani,
M.Si**

ABSTRACT

Investing activities, such as stock investment, are certainly inseparable from two important things, namely, risk and return. Return is the level of profit obtained by investors from the results of stock investments made. The goal of investors is to get a high return, but a high return must be accompanied by a high risk. There is an important component in investment activities, namely volatility which is the variance of return. Financial data in general has a tendency to volatility, so a model is needed to accommodate volatility in financial data. Models that can accommodate volatility include ARCH-GARCH, and EGARCH. The ARCH and GARCH models cannot represent asymmetric properties in financial data, so one of the models that can represent asymmetric properties is EGARCH. In this final project, the data used is the return data from the closing price of PT. Indofarma Tbk (INAF), which is a company engaged in the pharmaceutical sector, which has experienced an increase since

2020 due to the global pandemic, namely Covid-19. The results of the research on return data from the closing price of the stock price of PT. Indofarma Tbk (INAF) can be approached with the ARIMA model (0,1,1). The ARIMA model (0,1,1) has an element of heteroscedasticity, so the identification of the ARCH-GARCH and EGARCH models is carried out. Because the ARIMA model (0,1,1) has an asymmetric effect, the best model is obtained, namely EGARCH (1,1) which can represent the asymmetric effect. The EGARCH (1,1) model is used to predict the return volatility of the closing price of PT. Indofarma Tbk (INAF) in the period 01 October 2020 to 01 September 2021. The results of volatility forecasting show that there is an increase in return volatility from the closing price of PT. Indofarma Tbk (INAF).

Keywords : ARIMA, EGARCH, Asymmetric, Volatility

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Puji syukur penulis ucapkan kehadiran Allah SWT atas limpahan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan Tugas Akhir dengan judul “**Penerapan Model *Exponential Generalized Autoregressive Heteroscedasticity (EGARCH)* Untuk Peramalan Volatilitas Harga Saham**” dengan baik dan tepat waktu.

Keberhasilan penyusunan Tugas Akhir ini tidak terlepas dari bantuan, bimbingan, dan dukungan dari berbagai pihak. Untuk itu, pada kesempatan ini penulis menyampaikan ucapan terima kasih kepada:

1. Allah SWT yang selalu memberikan ilmu, pertolongan, kemudahan dan segala hal dalam setiap langkah penulis dalam menyelesaikan Tugas Akhir ini.
2. Nabi Muhammad SAW, semoga shalawat serta salam tetap tercurahkan kepada Beliau dan kita semua dapat mendapatkan safaat Beliau di hari akhir nanti.
3. Bapak Subchan, Ph.D selaku Kepala Departemen Matematika Institut Teknologi Sepuluh Nopember yang selalu memberikan arahan dan bimbingan selama perkuliahan hingga terselesaikannya Tugas Akhir ini,
4. Ibu Dr. Dwi Ratna Sulistyaningrum, MT selaku Sekretaris Departemen Bidang Akademik dan selaku dosen wali saya yang selalu memberikan dukungan dan senantiasa mengingatkan penulis untuk menyelesaikan Tugas Akhir ini.
5. Ibu Dra. Laksmi Prita Wardhani, M.Si selaku dosen pembimbing yang telah memberikan arahan dengan penuh kesabaran kepada penulis selama penyusunan Tugas Akhir ini.
6. Ibu Dr. Valeriana Lukitosari, S.Si, MT, Ibu Endah Rokhmah, M.P.,Ph.D, Ibu Dra. Nur Asiyah, M.Si. selaku dosen penguji Tugas Akhir yang telah memberikan kritik

dan saran yang bersifat membangun dalam menyelesaikan Tugas Akhir ini.

7. Bapak/Ibu dosen pengajar yang telah memberikan ilmu dan pengalaman yang bermanfaat kepada penulis, serta segenap karyawan dan keluarga besar Departemen Matematika Institut Teknologi Sepuluh Nopember atas segala dukungan dan bantuannya.
8. Teristimewa untuk orang tua tercinta yaitu Bapak Samsul Huda dan Ibu Deni Wahuningsih, serta keluarga besar yang selalu mendoakan, mendukung, dan memberi semangat penulis dalam menyelesaikan Tugas Akhir ini.
9. Partner terbaik Davin Rahmat Wiranata H. yang selalu mendoakan, memberi semangat, memberi motivasi kepada penulis dalam menyelesaikan Tugas Akhir.
10. Diri sendiri yang sudah berjuang menyelesaikan Tugas Akhir ini.
11. Teristimewa untuk rekan – rekan seperjuangan, Matematika Institut Teknologi Sepuluh Nopember Angkatan 2017 yang telah mengisi hari-hari penulis dengan penuh keceriaan.

Penulis menyadari bahwa dalam penulisan Tugas Akhir ini masih terdapat kekurangan. Oleh karena itu, penulis mengharapkan saran dan kritik dari pembaca. Semoga Tugas Akhir ini dapat memberikan manfaat bagi pihak yang berkepentingan.

Surabaya, 11 Desember 2021

Penulis

Halaman ini sengaja dikosongkan

DAFTAR ISI

	Halaman
HALAMAN JUDUL.....	iii
<i>TITLE PAGE</i>	v
LEMBAR PENGESAHAN.....	vii
ABSTRAK.....	ix
ABSTRACT.....	xii
KATA PENGANTAR.....	xvi
DAFTAR ISI.....	xviii
DAFTAR GAMBAR.....	xxii
DAFTAR TABEL.....	xxiv
DAFTAR SIMBOL.....	xxvi
DAFTAR LAMPIRAN.....	xxvii
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	4
1.2. Rumusan Masalah.....	6
1.3. Batasan Masalah.....	6
1.4. Tujuan.....	7
1.5. Manfaat.....	7
1.6. Sistematika Penulisan.....	8
BAB II TINJAUAN PUSTAKA.....	11
2.1. Penelitian Terdahulu.....	11
2.2. Pengertian Saham.....	12
2.3. <i>Data Return</i>	12
2.4. Stasioneritas.....	13
2.4.1. Stasioneritas Dalam Varian.....	13
2.4.1. Stasioneritas Dalam <i>Mean</i>	17
2.5. Fungsi Autokorelasi Dan Fungsi Autokorelasi Parsial.....	16

2.6.	Identifikasi Model ARIMA	20
2.7.	Estimasi Dan Pengujian Model ARIMA	22
2.8.	Uji Diagnostik Model ARIMA.....	24
2.9.	Uji Heterokedastisitas	26
2.10.	Identifikasi Model Varian	27
2.11.	Estimasi Dan Pengujian Model Varian	30
2.12.	Kriteria Pemilihan Model Terbaik.....	34
 BAB III METODE PENELITIAN		 37
3.1.	Jenis Dan Sumber Data	37
3.1.2.	Sumber Data	37
3.2.	Tahap Penelitian.....	37
3.2.1.	Studi Literatur	37
3.2.2.	Pengolahan Data	38
3.2.3.	Analisis Dan Hasil Kesimpulan	39
3.3.	Diagram Alir	39
 BAB IV ANALISIS DAN PEMBAHASAN.....		 43
4.1.	Statistika Deskriptif.....	43
4.2.	Identifikasi Data.....	43
4.2.1.	Uji Stasioneritas	46
4.2.2.	Plot ACF Dan PACF.....	49
4.3.	Estimasi Parameter	54
4.4.	Uji Diagnostik	62
4.5.	Uji Heterokedastisitas	66
4.6.	Identifikasi Model ARCH-GARCH, Dan EGARCH	67
4.7.	Peramalan Volatilitas	73
4.8.	Analisis	74

BAB V KESIMPULAN DAN SARAN	75
5.1. Kesimpulan	75
5.2. Saran	76
DAFTAR PUSTAKA	77
LAMPIRAN	79
BIODATA PENULIS	125

Halaman ini sengaja dikosongkan

DAFTAR GAMBAR

	Halaman
Gambar 1.1	Plot Time Series Harga Penutupan Saham PT. Indofarma Tbk (INAF.JK) 4
Gambar 1.2	Plot Time Series Harga Penutupan Saham PT. Kimia Farma Tbk (KAEF.JK)..... 5
Gambar 1.3	Plot Time Series Harga Penutupan Saham PT. Kalbe Farma Tbk (KLBF.JK) 5
Gambar 3.1	Diagram Alir 41
Gambar 4. 1	Plot data Harga Penutupan Saham Box-Cox PT Indofarma Tbk. 43
Gambar 4. 2	Plot data <i>Return</i> Harga Penutupan Saham Box-Cox PT Indofarma Tbk. 44
Gambar 4. 3	Plot Box-Cox <i>Return</i> Harga Penutupan Saham PT Indofarma Tbk. 46
Gambar 4. 4	Plot Transformasi Box-Cox <i>Return</i> Harga Penutupan Saham PT Indofarma Tbk 47
Gambar 4. 5	Plot Trend Analisis <i>Return</i> Harga Penutupan Saham PT Indofarma Tbk 48
Gambar 4. 6	Plot Trend Analisis Setelah Differencing <i>Return</i> Harga Penutupan Saham PT Indofarma Tbk 49
Gambar 4. 7	Plot PACF <i>Return</i> Harga Penutupan Saham PT Indofarma Tbk 53
Gambar 4. 8	Plot ACF Return Harga Penutupan Saham PT Indofarma Tbk 53

Halaman ini sengaja dikosongkan

DAFTAR TABEL

	Halaman
Tabel 2.1	Transformasi Box Cox 15
Tabel 2.2	Karakteristik dari ACF dan PACF Pada Model ARIMA 21
Tabel 4.1	Statistika Deskriptif Data <i>Return</i> Harga Pentupan Saham Tahun 2014-2021 45
Tabel 4.2	Estimasi Parameter Model ARIMA([1,2],1,[1,3]). 54
Tabel 4.3	<i>Overfitting</i> Model ARIMA 57
Tabel 4.4	Uji Signifikansi <i>Overfitting</i> Model ARIMA 62
Tabel 4.5	Uji Signifikansi, Uji <i>White Noise</i> , Uji Normalitas 66
Tabel 4.6	Estimasi Parameter Model ARCH (1)..... 68
Tabel 4.7	Estimasi Parameter <i>Overfitting</i> Model Varian .. 71
Tabel 4.8	Hasil <i>Overfitting</i> 72
Tabel 4.9	Hasil Peramalan Volatilitas..... 73

Halaman ini sengaja dikosongkan

DAFTAR SIMBOL

Simbol	Makna/Arti Simbol
$r(t)$	nilai <i>return</i> pada period eke-t
R_t	Nilai saham pada periode ke t
R_{t-1}	Nilai saham pada periode ke t-1
B	“ <i>Backshift</i> ”
Z_t	Nilai variabel Z pada waktu ke – t
Z_{t-1}	Nilai variabel Z pada waktu ke (t-1)
$\hat{\rho}_k$	Koefisien autokorelasi pada lag ke-k
\bar{Z}	Nilai rata – rata (<i>mean</i>) Z
n	Jumlah data
t	Waktu pengamatan t = 1,2,3,...
$\hat{\Phi}_{k,k}$	Autokorelasi parsial pada lag k
Φ_p	Parameter <i>autoregressive</i>
α_t	Error ke t
d	Orde differencing
ε	Residual
ξ	<i>Leverage effect</i> atau efek asimetris

Halaman ini sengaja dikosongkan

DAFTAR LAMPIRAN

	Halaman
Lampiran 1. Data Penutupan Harga Saham 2014-2021.....	79
Lampiran 2. Data <i>Return</i> Penutupan Harga Saham 2014-2021	83
Lampiran 3. Estimasi Parameter <i>Overfitting</i> Model ARIMA	87
Lampiran 4. Correlogram Q-Statistik Uji <i>White Noise</i>	101
Lampiran 5. Histogram Uji Normalitas	105
Lampiran 6. Heterokedastisitas	107
Lampiran 7. Correlogram Residual Kuadrat.....	111
Lampiran 8. Model Varian	112
Lampiran 9. Plot Peramalan Volatilitas.....	116
Lampiran 10. Estimasi λ Pada Box Cox.....	117
Lampiran 11. Source Code Box Cox.....	120

Halaman ini sengaja dikosongkan

BAB I

PENDAHULUAN

Pada bab ini dijelaskan tentang latar belakang, rumusan masalah, batasan masalah, tujuan penelitian, dan manfaat penelitian dalam Tugas Akhir ini.

1.1. Latar Belakang Masalah

Pasar modal merupakan sarana bertemunya suatu perusahaan ataupun institusi lain (misalnya pemerintah) yang membutuhkan dana dari masyarakat untuk melakukan pengembangan usaha, ekspansi, penambahan modal kerja dan sebagainya. Proses mendapatkan dana, perusahaan maupun institusi tersebut telah menerbitkan saham atau surat utang, dan investor yang memberi dana untuk perusahaan atau institusi tersebut dengan cara membeli instrumen tersebut di pasar modal baik secara langsung ataupun dalam bentuk reksa dana [1]. Berkembangnya pasar modal di Indonesia menunjukkan bahwa masyarakat Indonesia semakin tinggi dalam melakukan investasi. Kegiatan berinvestasi, seperti investasi saham tentunya tidak terlepas dengan dua hal yang penting yaitu, resiko serta *return*. *Return* merupakan tingkat keuntungan yang diperoleh para *investor* dari hasil investasi saham yang dilakukan. Tujuan dari investor adalah ingin mendapat return yang tinggi, akan tetapi return yang tinggi pasti disertai oleh resiko yang tinggi [2]. Terdapat komponen yang penting pada kegiatan investasi yaitu volatilitas yang merupakan varians dari *return*. Volatilitas berperan penting dalam manajemen resiko dan pembentukan harga saham[3].

Data finansial seperti indeks harga saham, suku bunga, dan kurs mata uang termasuk data deret waktu (*time series*) [4].


Data deret waktu (*time series*) adalah sekumpulan data yang berupa angka yang didapat dalam suatu periode waktu tertentu seperti, harian, mingguan, bulanan atau tahunan. Pada data deret waktu finansial memiliki varians yang tidak konstan, hal tersebut dikarenakan data finansial berfluktuasi dengan cepat dari waktu ke waktu. Sehingga fluktuasi tersebut dapat ditunjukkan dengan melihat volatilitas data deret waktu yang terdapat di data finansial. Karena data finansial pada umumnya memiliki volatilitas yang tinggi, maka hal tersebut menyebabkan prediksi pergerakan dari volatilitas sulit [5]. Sebagian besar data deret waktu (*time series*) yang berkaitan dengan data ekonomi dan keuangan memiliki sifat heteroskedastis (varians tidak konstan). Oleh karena itu, perlu dilakukan pemodelan deret waktu untuk mengakomodasi data yang memiliki varians tidak konstan atau heteroskedastisitas [6].

Robert Engle (1982) memperkenalkan *Autoregressive Conditional Heteroscedasticity* (ARCH) untuk memodelkan perubahan volatilitas yang terdapat pada data finansial. Akan tetapi data finansial mempunyai volatilitas yang tinggi maka model ARCH membutuhkan orde yang tinggi untuk memodelkan variannya. Sehingga di tahun 1986 model ARCH disempurnakan oleh Bollerslev menjadi model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH). Model GARCH mempunyai respon volatilitas yang simetris terhadap adanya guncangan positif (*good news*) dan guncangan negatif (*bad news*). Oleh karena itu model GARCH dinilai mampu menyediakan kerangka kerja yang sangat fleksibel dalam mengakomodasi adanya sifat volatilitas terhadap data *time series* finansial. Model *Autoregressive Conditional Heteroscedasticity* (ARCH) dan perluasannya yaitu model *Generalized Autoregressive*


Conditional Heteroscedasticity (GARCH) dikembangkan menjadi model *Exponential Generalized Autoregressive Conditional Heteroscedasticity* (EGARCH) oleh Nelson pada tahun 1991. Nelson menunjukkan bahwa dengan adanya fungsi varians kondisional simetris dinilai tidak cocok dalam memodelkan volatilitas saham atau pengembalian, karena tidak bisa mewakili efek asimetris (*leverage effect*) yang merupakan korelasi negatif antara volatilitas dengan *return*. Model EGARCH banyak digunakan pada harga saham, karena harga saham di Bursa Efek Indonesia dapat berubah-ubah di setiap waktu, sehingga hal tersebut membuat harga saham memiliki sifat heteroskedastik.

Penelitian yang menggunakan model *Exponential Generalized Autoregressive Conditional Heteroscedasticity* (EGARCH), diantaranya adalah Siti Rahayu Ningsih,dkk [5] yang menerapkan model EGARCH dan THRESHOLD GARCH (TGARCH) untuk meramalkan volatilitas saham LQ-45, dan didapatkan model terbaik yaitu model EGARCH (2,1), sehingga hasil peramalan volatilitas indeks saham mengalami peningkatan dari periode pertama hingga periode ke empat belas yang menunjukkan bahwa indeks saham LQ-45 mempunyai volatilitas tinggi. Penelitian yang terkait juga dilakukan oleh Vicky Ananda [7] dengan menerapkan metode GJR-GARCH dan EGARCH pada analisis volatilitas indeks saham syariah Indonesia dengan studi kasus PT. Kimia Farma Tbk, dan diperoleh hasil yaitu model terbaik yang digunakan untuk mengakomodasi sifat asimetris terhadap volatilitas Index Saham Syariah Indonesia adalah model EGARCH (1,7). Berdasarkan latar belakang diatas serta penelitian-penelitian sebelumnya, maka dilakukan penelitian untuk meramalkan volatilitas *return* saham PT. Indofarma Tbk (INAF) dengan menggunakan metode Egarch.


Saham PT. Indofarma Tbk (INAF) bukan termasuk kedalam daftar saham LQ-45, saham LQ-45 merupakan salah satu indeks di Bursa Efek Indonesia (BEI), di mana indeks tersebut dihasilkan dari perhitungan 45 emiten dengan seleksi kriteria seperti penilaian atas likuiditas [8]. Penelitian ini dilakukan terhadap harga saham PT. Indofarma Tbk, dikarenakan pada Jumat (28/8/2020), saham anak usaha PT Bio Farma (Persero) ini ditutup minus 1,81%. Penguatan saham INAF terjadi juga bersamaan dengan saham PT Kimia Farma Tbk (KAEF), sama-sama mendapatkan sentimen vaksin corona. Kasus Covid-19 ini yang mengerek saham-saham khususnya berkaitan dengan kesehatan, yakni farmasi. Pergerakan saham sektor farmasi menuai euforia dari optimisme penemuan vaksin Covid-19 dan membuat emiten farmasi mampu menguat [9].



Gambar 1.1 Time Series Plot Harga Penutupan Saham PT. Indofarma Tbk (INAF.JK)



Gambar 1.2 Time Series Plot Harga Penutupan Saham PT. Kimia Farma Tbk (KAEF.JK)



Gambar 1.3 Time Series Plot Harga Penutupan Saham PT. Kalbe Farma Tbk (KLBF.JK)

Perbandingan dari Gambar 1.1, Gambar 1.2, dan Gambar 1.3 menunjukkan bahwa Gambar 1.1 yaitu harga penutupan saham PT. Indofarma Tbk jauh lebih meningkat di tahun 2020 daripada harga penutupan saham PT. Kimia Farma Tbk dan PT. Kalbe Farma.

1.2. Rumusan Masalah

Berdasarkan latar belakang tersebut, dibahas rumusan masalah pada Tugas Akhir ini adalah sebagai berikut :

1. Bagaimana volatilitas pada *return* harga saham ?
2. Bagaimana model EGARCH terbaik volatilitas *return* harga saham berdasarkan kriteria pemilihan model dengan melihat nilai AIC dan SBC ?
3. Bagaimana penerapan model EGARCH untuk hasil peramalan volatilitas *return* harga saham ?

1.3. Batasan Masalah

Batasan masalah pada Tugas Akhir ini sebagai berikut :

1. Data yang digunakan untuk Tugas Akhir ini adalah PT. Indofarma Tbk.
2. Data yang digunakan adalah data bulanan *closing price* 01 Oktober 2014 sampai dengan 01 September 2021 yang diakses melalui www.finance.yahoo.com.
3. Model asimetri yang digunakan pada Tugas Akhir ini adalah model *Exponential Generalized Autoregressive Conditional Heteroscedasticity* (EGARCH).
4. Stasioneritas memakai data *log-return* dengan batasan nilai positif.

1.4. Tujuan

Tujuan dalam Tugas Akhir ini adalah :

1. Mendapatkan volatilitas *return* pada harga saham.
2. Mendapatkan model EGARCH terbaik berdasarkan kriteria pemilihan model dengan melihat nilai AIC dan SBC.
3. Mendapatkan peramalan volatilitas *return* harga saham dengan menerapkan model *Exponential Generalized Autoregressive Conditional Heteroscedasticity* (EGARCH).

1.5. Manfaat

Manfaat yang bisa diperoleh dari Tugas Akhir ini adalah :

1. Bagi peneliti, Tugas Akhir ini dapat menambah wawasan tentang penerapan model EGARCH dalam melakukan prediksi volatilitas *return* harga saham.
2. Peramalan yang tepat dapat digunakan sebagai *leading indicator*, dimana dengan adanya *leading indicator* dapat memberikan peluang dalam memperoleh keuntungan yang sangat besar, tetapi tentu disertai oleh adanya resiko yang tinggi.
3. Memberikan suatu kontribusi di bidang keuangan pada ilmu matematika terapan
4. Penelitian ini dapat memudahkan para investor serta pelaku bisnis saham dalam mengambil suatu keputusan untuk melakukan investasi.

1.6. Sistematika Penulisan

Sistematika penulisan pada Tugas Akhir disusun menjadi enam bab, yaitu :

1. BAB I PENDAHULUAN

Bab ini berisi tentang gambaran umum dari penulisan Tugas Akhir yang meliputi latar belakang, rumusan masalah, batasan masalah, dan sistematika penulisan.

2. BAB II TINJAUAN PUSTAKA

Bab ini berisi tentang teori yang mendukung dari penelitian Tugas Akhir yang meliputi penelitian terdahulu, pengertian saham, data *return*, stasioneritas, fungsi autokorelasi dan fungsi autokorelasi parsial, identifikasi model ARIMA, estimasi dan pengujian model ARIMA, uji diagnostik model ARIMA, uji heterokedastisitas, identifikasi model varian, estimasi dan pengujian model varian, dan kriteria pemilihan model terbaik.

3. BAB III METODE PENELITIAN

Bab ini berisi tentang langkah – langkah dan metode yang digunakan dalam menyelesaikan penelitian Tugas Akhir ini.

4. BAB IV ANALISIS DAN PEMBAHASAN

Bab ini berisi tentang pembahasan hasil penelitian Tugas Akhir dari setiap langkah – langkah yang terdapat pada bab 3. Proses mengerjakan dimulai dari menentukan statistika deskriptif pada data *return* harga saham PT Indofarma Tbk (INAF), uji stasioneritas terhadap *mean* dan varian menggunakan Transformasi Box-Cox dan *differencing*. Apabila data sudah stasioner terhadap *mean* dan varian, maka akan dilakukan proses

analisis model ARIMA dengan melakukan estimasi dan pengujian model ARIMA, dan uji diagnostik. Selanjutnya, dilakukan uji heterokedastisitas terhadap model ARIMA terbaik, jika terdapat efek heterokedastisitas maka dilanjutkan analisis model ARCH-GARCH, dan EGARCH. Pemilihan model terbaik ditentukan dari nilai AIC dan SBC yang terkecil. Langkah selanjutnya dilakukan peramalan terhadap model *varian* terbaik.

5. BAB V KESIMPULAN DAN SARAN

Bab ini berisi tentang kesimpulan penelitian Tugas Akhir yang didapatkan dari hasil pembahasan, dan saran yang diberikan untuk penelitian berikutnya.

BAB II

TINJAUAN PUSTAKA

Pada bab ini berisi tentang teori dasar pendukung dijelaskan terkait penelitian terdahulu, pengertian saham, data *return*, stasioneritas, fungsi autokorelasi dan fungsi autokorelasi parsial, estimasi dan pengujian model ARIMA, uji diagnostik model ARIMA, uji heterokedastisitas, identifikasi model varian, estimasi dan pengujian model varian, dan kriteria pemilihan model terbaik.

2.1. Penelitian Terdahulu

Berdasarkan penelitian – penelitian terdahulu, Model *Exponential Generalized Autoregressive Conditional Heteroscedasticity* (EGARCH) pada tahun 2017, S.R. Ningsih, I.W. Sumarjaya, dan K. Sari [5] yang melakukan penelitian tentang “Peramalan Volatilitas Saham Menggunakan Model Exponential Garch Dan Threshold Garch”, dari penelitian tersebut diperoleh hasil model terbaik yaitu model EGARCH (2,1) serta hasil peramalan volatilitas indeks saham mengalami peningkatan dari periode pertama hingga periode ke empat belas yang menunjukkan bahwa indeks saham LQ-45 mempunyai volatilitas tinggi. Penelitian yang terkait juga dilakukan oleh V.A. Inlistya [7] , pada tahun (2017) dengan melakukan penelitian tentang “ Perbandingan Metode Antara GJR-GARCH dan EGARCH Pada Analisis Volatilitas Indeks Saham Syariah Indonesia” dengan studi kasus PT. Kimia Farma Tbk, sehingga diperoleh hasil yaitu model terbaik yang digunakan untuk mengakomodasi sifat asimetris terhadap volatilitas Index Saham Syariah Indonesia adalah model EGARCH (1,7).

Penelitian Tugas Akhir tentang “Penerapan Model *Exponential Generalized Autoregressive Conditional Heteroscedasticity* (EGARCH) Untuk Peramalan Volatilitas Harga Saham” merupakan penelitian yang diperoleh dari pengembangan dari penelitian – penelitian sebelumnya. Penelitian ini berbeda dengan penelitian sebelumnya, penelitian ini melakukan perhitungan *return* harga penutupan saham PT Indofarma Tbk dan melakukan peramalan pada perusahaan tersebut dengan menggunakan EGARCH.

2.2. Pengertian Saham

Saham merupakan salah satu dari banyaknya instrument pasar modal yang menjadi tanda atas kepemilikan seseorang di sebuah perusahaan atau perseroan terbatas [10]. Kata saham terdapat didalam Undang – Undang No. 8 Tahun 1995 tentang pasar modal, dimana didalam undang – undang tersebut menjelaskan bahwa saham adalah salah satu jenis efek atau sebuah surat berharga.

2.3. Data Return

Return $r(t)$ merupakan keuntungan yang dihasilkan oleh perusahaan, institusi, maupun individu yang berasal dari hasil kebijakan investasi yang dilakukannya, sedangkan perhitungan *return* $r(t)$ merupakan kombinasi perhitungan *logaritma* dengan differensi. *Return* $r(t)$ didefinisikan sebagai berikut [3].

$$r(t) = \ln\left(\frac{R_t}{R_{t-1}}\right) = \ln|R_t| - \ln|R_{t-1}| \quad (2.1)$$

dengan,

$r(t)$: nilai *return* pada period eke-t

R_t : nilai saham pada periode ke t

R_{t-1} : nilai saham pada periode ke $t - 1$

2.4. Stasioneritas

Uji stasioneritas merupakan pengujian penting sebelum menganalisis atau mendapatkan model ARIMA. Stasioneritas dalam *time series* merupakan karakteristik statistik pada data yang mendekati nilai rata – rata serta mengalami fluktuasi di daerah atau disekitar rata-rata dari waktu ke waktu. Asumsi stasioner menjadi asumsi yang harus dipenuhi dalam memodelkan data *time series*. Sebuah data disebut dengan data yang stasioner apabila pola data tersebut berada disekitar *mean* dan *varian* yang konstan [11].

2.4.1 Stasioneritas Dalam Varian

Langkah pertama dalam melakukan transformasi Box-Cox adalah dengan mencari nilai λ optimal. Pada dasarnya, untuk mencari λ optimal dapat menggunakan aturan log-likelihood seperti pada (Lampiran 10), yakni dengan mencari nilai λ yang memiliki nilai log-likelihood terbesar (memaksimumkan fungsi log-likelihood), tetapi seiring berjalannya waktu, solusi yang dipaparkan ini dapat diatasi dengan teori *statistical process control* yaitu dengan memanfaatkan *isigma* dan *moving range* (meminimumkan *isigma*). Pertama, penentuan batas bawah dan batas atas pengujian nilai λ secara manual. Dalam kasus ini akan diuji dengan $-1 \leq \lambda \leq 2$. Berikutnya adalah mentransformasi data *time series* dengan rumus *modified box-cox transformation* yakni dengan transformasi *box-cox* geomean [12].

$$Z(\lambda) = \frac{Z_t^\lambda - 1}{\lambda GM^{\lambda-1}}, \text{ untuk } \lambda \neq 0$$

$$Z(\lambda) = GM \log(Z), \text{ untuk } \lambda = 0$$

$$GM = (Z_1 Z_2 Z_3 \dots Z_n)^{\frac{1}{n}} \Rightarrow \text{rata - rata Geometri } Z_i$$

Berikutnya adalah dengan mencari *moving range* untuk masing-masing λ dengan menghitung :

$$mr_j = |data(t + 1) - data t|, \text{ untuk } t = 1, 2, \dots, \text{ banyak data}$$

Langkah selanjutnya adalah dengan mencari nilai *isigma* untuk masing-masing *moving range* λ dengan rumus:

$$\sigma_t = \frac{\overline{R}_t}{1.128}, \text{ untuk } i \text{ adalah nilai lambda, } \overline{R}_i = \text{rata-rata } mr_i$$

Nilai λ optimal ditentukan dengan mengambil nilai λ_i dimana memiliki nilai *isigma* paling minimum. Transformasi data dengan transformasi Box-Cox adalah tahap terakhir dengan menggunakan nilai λ optimal yang sudah diestimasi pada tahapan sebelumnya. Rumus transformasi Box-Cox adalah:

$$Z(\lambda) = \frac{Z_t^\lambda - 1}{\lambda}, \text{ untuk } \lambda \neq 0 \quad (2.2)$$

$$Z(\lambda) = \log Z_t, \text{ untuk } \lambda = 0 \quad (2.3)$$

Untuk memeriksa apakah data transformasi sudah stasioner dalam varians adalah dengan memeriksa nilai λ optimal pada data hasil transformasi. Bila nilai λ adalah 1 maka data sudah stasioner terhadap varians. Pada umumnya aturan

transformasi *Box-Cox* serta nilai λ dapat dilihat pada Tabel 2.1 dibawah ini :

Tabel 2.1. Transformasi *Box-Cox*

Estimasi λ	Transformasi
-1	$\frac{1}{Z_t}$
-0,5	$\frac{1}{\sqrt{Z_t}}$
0	$\ln(Z_t)$
0,5	$\sqrt{Z_t}$
1	Z_t (Tidak terdapat transformasi)

2.4.2 Stasioneritasn Dalam *Mean*

Selanjutnya, jika sebuah data *time series* sudah stasioner terhadap varian, maka langkah selanjutnya yaitu melakukan uji stasioneritas dalam *mean*. Data *time series* dikatakan stasioner dalam *mean* jika fluktuasi data *time series* terletak di sekitar nilai rata-rata yang konstan, atau dengan kata lain $E(Z_t) = E(Z_{t+k}) = \mu$ untuk semua t [11]. Apabila data tidak stasioner terhadap *mean* maka dapat dibatasi dengan melakukan *differencing*. Sebuah proses dari *differencing* merupakan selisih antara data ke t dengan data ke $(t - 1)$

$$X_t = (1 - B)^d Z_t \quad (2.4)$$

Dengan

$$B^d(Z_t) = Z_{t-d}$$

Keterangan:

B : “backshift”

Z_t : data yang akan di *differencing* pada waktu t

X_t : data hasil *differencing* orde d

d : orde pembeda (*differencing*)

Operator *backward shift* atau *shift* mundur sangat tepat untuk mendeskripsikan proses *differencing*. Notasi B yang dipasang pada Z_t memiliki efek untuk menggeser data mundur satu periode [11]. Jika data *time series* tidak stasioner terhadap *mean*, maka data *time series* dapat dibuat mendekati stasioner, yaitu dengan melakukan proses *differencing* orde pertama dari data.

2.5. Fungsi Autokorelasi Dan Fungsi Autokorelasi Parsial

Fungsi autokorelasi (ACF) adalah sebuah fungsi yang digunakan untuk mengidentifikasi model *time series* dan melihat adanya kestasioneran data dalam *mean*. Fungsi ACF pada proses Z_t merupakan proses stokastik $\{Z_t: t = 0, \pm 0, \pm 1, \pm 2, \dots\}$, $\mu = E[Z_t]$, dan $Var(Z_t) = E(Z_t - \mu)^2 = \sigma_t^2$ yang konstan, oleh karena itu dapat ditulis kovarian antara Z_t dan Z_{t+k} dapat ditulis sebagai :

$$\begin{aligned} cov(Z_t, Z_{t+k}) &= \gamma_k = E[(Z_t - \mu_t)(Z_{t+k} - \mu_{t+k})] \\ &= E[(Z_t Z_{t+k} - \mu_t Z_{t+k} - \mu_t Z_t + \mu_t \mu_{t+k})] \\ &= E[Z_t Z_{t+k}] - E[\mu_t Z_{t+k}] - E[\mu_t Z_t] + E[\mu_t \mu_{t+k}] \\ &= E[Z_t Z_{t+k}] - \mu_t E[Z_{t+k}] - \mu_{t+k} E[Z_t] + \mu_t \mu_{t+k} \\ &= E[Z_t Z_{t+k}] - \mu_t \mu_{t+k} \end{aligned}$$

Dan korelasi antara Z_t dan Z_{t+k} adalah:

$$\hat{\rho}_k = corr(Z_t, Z_{t+k})$$

untuk $s, t = 0, \pm 1, \pm 2, \dots$

dimana

$$\hat{\rho}_k = \text{corr}(Z_t, Z_{t+k}) = \frac{\text{cov}(Z_t, Z_{t+k})}{\sqrt{\text{Var}(Z_t)(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0}$$

dengan $\text{Var}(Z_t) = \text{Var}(Z_{t+k}) = \gamma_0$

Fungsi autokorelasi untuk lag $1, 2, 3, \dots, k$ dapat dituliskan menjadi:

$$\hat{\rho}_k = \sum_{t=1}^{n-k} \frac{(Z_t - \mu)(Z_{t+k} - \mu)}{\sum_{t=1}^{n-k} (Z_t - \mu)^2} \quad (2.5)$$

Koefisien autokorelasi yang telah didapatkan dapat dilihat apakah signifikan atau tidak signifikan dengan menggunakan *correlogram*. *Correlogram* merupakan plot antara lag k yang berhubungan dengan selang kepercayaan. Selang kepercayaan pada ACF dapat dihitung dengan menggunakan persamaan dibawah ini :

$$\text{selang kepercayaan ACF} = 0 \pm t_{n-1} \left(\frac{\alpha}{2} \right) \times SE(\rho_k) \quad (2.6)$$

dengan

$$SE(\rho_k) = \sqrt{\frac{1}{n}} \quad (2.7)$$

dengan,

$\hat{\rho}_k$: koefisien autokorelasi pada lag ke- k

Z_t : data *time series* pada waktu t

\bar{Z} : nilai rata – rata (*mean*)

n : jumlah data *time series*

t_{n-1} : nilai table t dengan indeks $n - 1$

t : waktu pengamatan $t = 1, 2, 3, \dots$

α : taraf signifikan

$SE(\rho_k)$: standard error autokorelasi pada lag k

Fungsi autokorelasi parsial (PACF) dapat digunakan untuk menjadi pengukur tingkat kerataan Z_t dan Z_{t+k} jika terdapat pengaruh dari lag $t + 1, t + 2, \dots, t + k - 1$ yang dianggap terpisah. Fungsi PACF dapat dinotasikan sebagai berikut :

$$\phi_{kk} = \text{corr}(Z_t, Z_{t+k} | Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1})$$

Misalkan Z_t merupakan proses yang stasioner dengan $E[Z_t] = 0$, selanjutnya Z_{t+k} dinyatakan sebagai model linier :

$$Z_{t+k} = \phi_{k1}Z_{t+k-1} + \phi_{k2}Z_{t+k-2} + \dots + \phi_{kk}Z_t + \varepsilon_{t+k} \quad (2.8)$$

ϕ_{ki} merupakan parameter regresi ke- i dan ε_{t+k} merupakan nilai kesalahan yang tidak berkorelasi dengan Z_{t+k-j} , dimana $j = 1, 2, 3, \dots, k$. Selanjutnya untuk mendapatkan nilai PACF, maka persamaan (2.13) dikalikan dengan Z_{t+k-j} pada kedua ruas, sehingga didapatkan :

$$\begin{aligned} Z_{t+k}Z_{t+k-j} &= \phi_{k1}Z_{t+k-1}Z_{t+k-j} + \phi_{k2}Z_{t+k-2}Z_{t+k-j} \\ &+ \dots + \phi_{kk}Z_tZ_{t+k-j} + \varepsilon_{t+k}Z_{t+k-j} \end{aligned} \quad (2.9)$$

Selanjutnya, nilai ekspektasi dari persamaan (2.9) adalah

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

Misalkan nilai $E(Z_{t+k-1}Z_{t+k-j}) = \gamma_j, j = 0, 1, 2, \dots, k$ dan karena $\varepsilon_{t+k}E(Z_{t+k-j}) = 0$, maka diperoleh

$$\gamma_j = \phi_{k1} \gamma_{j-1} + \phi_{k2} \gamma_{j-2} + \dots + \phi_{kk} \gamma_{j-k} \quad (2.10)$$

Persamaan (2.10) dibagi dengan γ_0

$$\frac{\gamma_j}{\gamma_0} = \phi_{k1} \frac{\gamma_{j-1}}{\gamma_0} + \phi_{k2} \frac{\gamma_{j-2}}{\gamma_0} + \dots + \phi_{kk} \frac{\gamma_{j-k}}{\gamma_0}$$

Diperoleh

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

Misalkan diberikan $\rho_0 = 1$, untuk $j = 1, 2, 3, \dots, k$, sehingga diperoleh persamaan dibawah ini :

$$\begin{aligned} \rho_1 &= \phi_{k1} \rho_0 + \phi_{k2} \rho_1 + \dots + \phi_{kk} \rho_{k-1} \\ \rho_2 &= \phi_{k1} \rho_1 + \phi_{k2} \rho_0 + \dots + \phi_{kk} \rho_{k-2} \\ &\vdots \\ \rho_k &= \phi_{k1} \rho_{k-1} + \phi_{k2} \rho_{k-2} + \dots + \phi_{kk} \rho_0 \end{aligned} \quad (2.11)$$

Sehingga bentuk dari persamaan PACF adalah sebagai berikut :

$$\phi_{k+1, k+1} = \frac{\rho_k - \sum_{j=1}^k \phi_{kj} \rho_{k+1-j}}{1 - \sum_{j=1}^k \phi_{kj} \rho_{kj}} \quad (2.12)$$

dan

$$\phi_{k+1, j} = \phi_{kj} - \phi_{k+1, k+1} \phi_{k+ j-1}$$

Koefisien autokorelasi yang telah didapatkan dapat dilihat apakah signifikan atau tidak signifikan dengan menggunakan *correlogram*. *Correlogram* merupakan plot antara lag k yang berhubungan dengan selang kepercayaan. Selang kepercayaan

pada ACF dapat dihitung dengan menggunakan persamaan dibawah ini :

$$\text{selang kepercayaan PACF} = 0 \pm t_{n-1} \left(\frac{\alpha}{2} \right) \times SE(\phi_{kk})$$

dengan

$$SE(\rho_k) = \sqrt{\frac{1}{n}}$$

Keterangan :

ρ_k : autokorelasi pada lag k

$\phi_{k,k}$: autokorelasi parsial pada lag k

n : jumlah data *time series*

t_{n-1} : nilai table t dengan indeks $n - 1$

t : waktu pengamatan $t = 1, 2, 3, \dots$

α : taraf signifikan

$SE(\phi_k)$: standard error autokorelasi parsial pada lag k

2.6. Identifikasi Model ARIMA

Model ARIMA adalah salah satu model yang digunakan dalam memodelkan *mean*. Identifikasi terhadap *time series* dibuat plot *time series* data data deret waktu , hal ini bertujuan untuk mengetahui stasioneritas dari data tersebut. Dengan adanya plot ACF dan PACF dari data *time series* yang sudah stasioner, maka dapat diduga model yang cocok untuk data *time series* tersebut. Terdapat pedoman atau petunjuk yang digunakan dalam menduga model ARIMA yang diberikan [13], hal tersebut dapat dilihat melalui Tabel 2.2 dibawah ini :

Tabel 2.2 Karakteristik dari ACF dan PACF pada model ARMA:

Model	ACF	PACF
AR (p)	<i>Dies down</i> (turun secara eksponensial)	<i>Cuts off after lag p</i> (terputus setelah lag p)
MA (q)	<i>Cuts off after lag q</i> (terputus setelah lag q)	<i>Dies down</i> (turun secara eksponensial)
ARMA (p,q)	<i>Cuts off after lag q</i> (terputus setelah lag q)	<i>Cuts off after lag q</i> (terputus setelah lag q)

Berikut adalah pembagian seta penjelasan dari model *mean*, antara lain :

1. Model *autoregressive* (AR)

Secara umum bentuk dari model *autoregressive* orde p atau dapat dituliskan ($AR(p)$) adalah sebagai berikut [13] :

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t \quad (2.13)$$

dengan :

Z_t : variabel respon waktu ke t

Z_{t-p} : observasi ke $t - k$

ϕ_1, ϕ_2, ϕ_p : parameter *autoregressive*

ε_t : error ke t .

2. Model *Moving Average*

Secara umum bentuk dari model *Moving Average* (MA) orde q atau dapat dituliskan ($MA(q)$) adalah sebagai berikut [13]:

$$Z_t = \varepsilon_t - \theta_1\varepsilon_{t-1} - \theta_2\varepsilon_{t-2} - \dots - \theta_q\varepsilon_{t-q} \quad (2.14)$$

dengan,

Z_t : variabel respon waktu ke- t

$\theta_1, \theta_2, \theta_3$: parameter *moving average*

ε_{t-q} : error ke $(t - q)$.

3. Model *Autoregressive Integrated Moving Average*

Secara umum bentuk dari model *Autoregressive Integrated Moving Average* (ARIMA) orde p, q, d atau dapat dituliskan (*ARIMA* (p, q, d)) adalah sebagai berikut [13]:

$$\phi_p(B)(1 - B)^d Z_t = \theta_0 + \theta_q(B)\varepsilon_t \quad (2.15)$$

dengan,

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

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

B : *operator backward shift*

d : *orde differencing* .

2.7. Estimasi Dan Pengujian Model ARIMA

Metode *Least-Square* merupakan metode yang digunakan untuk estimasi parameter di dalam model *mean* serta digunakan untuk mencari nilai parameter yang bisa meminimalkan kuadrat kesalahan (selisih antara nilai actual dan peramalan). Misalkan model AR (1) adalah :

$$Z_t = \phi_1 Z_{t-1} + \varepsilon_t \quad (2.16)$$

Selanjutnya kedua ruas dikurangi oleh μ , dimana μ diartikan sebagai selisih dari nilai aktual dan peramalan, maka diperoleh :

$$Z_t - \mu = \phi_1(Z_{t-1} - \mu) + \varepsilon_t$$

Sehingga diperoleh model *Least-Square* untuk AR (1) adalah sebagai berikut :

$$S(\phi, \mu) = \sum_{t=q}^n \varepsilon_t^2 = \sum_{t=2}^n [(Z_{t-1} - \mu) - \phi(Z_{t-1} - \mu)]^2 \quad (2.17)$$

Kemudian persamaan (2.10) diturunkan sama dengan 0 terhadap ϕ dan μ . Hasil turunan dari $S(\phi, \mu)$ terhadap μ adalah :

$$\frac{\partial S}{\partial \mu} = \sum_{t=2}^n 2[(Z_{t-1} - \mu) - \phi(Z_{t-1} - \mu)](-1 + \phi) = 0$$

Diperoleh hasil nilai estimasi parameter μ yang berasal dari model AR (1) adalah :

$$\mu = \frac{\sum_{t=2}^n Z_t - \phi \sum_{t=2}^n Z_{t-1}}{(n-1)(1-\phi)}$$

Hasil dari turunan $S(\phi, \mu)$ terhadap ϕ adalah :

$$\frac{\partial S}{\partial \phi} = -2 \sum_{t=2}^n [(Z_t - \mu) - \phi(Z_{t-1} - \mu)](Z_{t-1} - \mu) = 0$$

Sehingga diperoleh hasil estimasi ϕ dari model AR (1) yaitu :

$$\phi = \frac{\sum_{t=2}^n (Z_t - \mu)(Z_{t-1} - \mu)}{\sum_{t=2}^n (Z_{t-1} - \mu)^2}$$

Apabila nilai estimasi setiap parameter sudah didapatkan, maka langkah selanjutnya adalah melakukan pengujian signifikansi untuk melihat apakah model tersebut cocok atau tidak untuk digunakan. Uji t digunakan untuk pengujian terhadap signifikansi parameter, sebab ϕ dan θ adalah parameter model *Box-Jenkins*, sedangkan $\hat{\phi}$ dan $\hat{\theta}$ merupakan estimasi parameternya. Standar deviasi $\hat{\phi}$ adalah standar error taksiran ϕ , dan standar deviasi $\hat{\theta}$ merupakan standar eror taksiran. Berikut adalah langkah – langkah uji signifikansi parameter :

Hipotesa :

H_0 : estimasi parameter = 0 (parameter model tidak signifikan)

H_1 : estimasi parameter \neq 0 (parameter model signifikan)

Uji statistik :

$$t_{hitung} = \frac{\text{estimasi parameter}}{\text{st. deviasi parameter}}, \text{st. deviasi parameter} \neq 0 \quad (2.18)$$

Kriteria dalam pengujian :

Dengan memakai nilai $p\text{-value} = 0,05$ ($\alpha = 0,05$), apabila nilai $t_{hitung} > t_{\frac{\alpha}{2}, (n-p-1)}$ maka H_0 ditolak, hal ini terjadi karena model parameter signifikan.

2.8. Uji Diagnostik Model ARIMA

Setelah pengujian signifikansi estimasi parameter maka akan dilakukan pengujian diagnostik yang bertujuan untuk membuktikan kelayakan model. Asumsi yang dipenuhi yaitu residual harus memiliki *white noise* dan berdistribusi normal. Residual dianggap bersifat *white noise* yaitu apabila tidak

terdapat pola residual. Pengujian asumsi residual *white noise* dilakukan dengan memakai Uji- *Ljung-Box*. Sedangkan pengujian asumsi distribusi normal dilakukan dengan memakai *Jarque Bera*

1. Uji Asumsi *White Noise*

Proses pengujian *White Noise* digunakan untuk memeriksa model dalam pengujian ARIMA. Proses *White Noise* dapat diperiksa menggunakan *Ljung-Box* dengan hipotesis sebagai berikut [13] :

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0$$

$$H_1 : \text{minimal terdapat satu } \rho_j \neq 0, \text{ dengan } j = 1, 2, \dots, k$$

Uji Statistik :

$$Q = n(n + 2) \sum_{k=1}^n \frac{\widehat{\rho}_k^2}{n - k}, n > k \quad (2.19)$$

dengan,

k : lag maksimum

n : jumlah observasi

$\widehat{\rho}_k$: autokorelasi residual untuk lag ke- k

Kriterian pengujian :

Dengan memakai $p\text{-value} = 0,05$ ($\alpha = 0,05$) , apabila nilai $Q < X^2_{(\alpha; k-p-q)}$ maka H_0 gagal ditolak, hal ini dikarenakan residual *white noise*.

2. Uji Distribusi Normal

Jarque Bera adalah salah satu dari pengujian normalitas data melalui pendekatan grafik *skewness* dan *kurtosis*. Langkah – langkah dalam melakukan pengujian asumsi distribusi normal memakai uji *Jarque Bera* adalah sebagai berikut :

Hipotesa :

H_0 : residual berdistribusi normal

H_1 : residual tidak berdistribusi normal

Uji Statistik :

$$JB = n \left(\frac{S^2}{6} + \frac{(k-3)^2}{24} \right) \quad (2.20)$$

dengan,

s : nilai *skewness kurtosis*

k : nilai *kurtosis*

Kriteria uji:

Dengan menggunakan taraf pengujian signifikansi p -value = 0,05 ($\alpha = 0,05$), menolak H_0 jika $JB > X^2_{(\alpha,(m))}$

3. *Overfitting*

Salah satu dari prosedur diagnostik cek yang dikemukakan Box Jenkins adalah *overfitting*. Pada tahap *Overfitting* akan dilakukan perluasan terhadap model yang telah diperoleh pada tahap identifikasi [14]. *Overfitting* terhadap model dapat dipilih dengan cara melakukan pemilihan model dengan orde lebih yang rendah atau kombinasi dari orde pada model yang telah diidentifikasi sebelumnya. Model yang telah dihasilkan dari proses *overfitting* dapat dijadikan sebagai model alternatif yang selanjutnya akan dicari model terbaik diantara model-model yang signifikan [11].

2.9. Uji Heterokedastisitas

Proses analisis model ARCH, GARCH, dan EGARCH dapat dilakukan setelah melakukan identifikasi adanya unsur

heterokedastisitas dalam data *time series*. Uji *White* dapat dilakukan untuk mengidentifikasi unsur heterokedastisitas.

Hipotesa :

H_0 : Tidak ada unsur heterokedastisitas (homokedastisitas)

H_1 : Ada unsur heterokedastisitas

Statistik uji :

$$x^2 = nR^2 \quad (2.21)$$

dengan :

n = jumlah observasi yang digunakan

R^2 = koefisien determinasi

Kriteria pengujian :

Menggunakan $p\text{-value} = 0,05$ ($\alpha = 0,05$), apabila nilai $x^2 > x^2_{(\alpha,(m))}$, sehingga terdapat penolakan H_0 artinya ada unsur heterokedastisitas.

2.10. Identifikasi Model Varian

Terdapat beberapa model varian, diantaranya adalah ARCH, GARCH, dan EGARCH. Model (ARCH) atau *Autoregressive Conditional Heterokedastic* diperkenalkan oleh Engle pada tahun 1982, dimana ARCH digunakan untuk memodelkan perubahan volatilitas yang terdapat pada data finansial. Model ARCH merupakan teknik pemodelan yang dilakukan jika ada heterokedastisitas di dalam data deret waktu, selain itu model ARCH merupakan sebuah kasus residual model ARIMA Box-Jenkins yang telah memenuhi asumsi dasar *white noise*, akan tetapi di dalam kuadrat residualnya menunjukkan

adanya perubahan varian [15]. Pada umumnya model ARCH (q) adalah sebagai berikut :

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

dimana ,

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

dimana $\alpha_0 > 0; \alpha_1, \alpha_2, \dots, \alpha_p$

dengan ,

ε = residual.

Model ARCH membutuhkan orde yang tinggi untuk memodelkan variannya sehingga, pada tahun 1986 model ARCH disempurnakan oleh Bollerslev menjadi model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH). Model GARCH mempunyai respon volatilitas yang simetris terhadap adanya guncangan positif (*good news*) dan guncangan negatif (*bad news*). Bentuk umum dari model GARCH (p,q) :

$$\begin{aligned} \sigma_t^2 &= \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \dots + \alpha_p \varepsilon_{t-p}^2 + \beta_1 \sigma_{t-1}^2 + \\ &\quad \beta_2 \sigma_{t-2}^2 + \dots + \beta_q \sigma_{t-q}^2 \\ \sigma_t^2 &= \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \end{aligned} \quad (2.23)$$

dimana :

$$\alpha_0 > 0 ; \alpha_1, \alpha_2, \dots, \alpha_p \geq 0 ; \beta_0 > 0 ; \beta_1, \beta_2, \dots, \beta_q \geq 0$$

Model *Autoregressive Conditional Heteroscedasticity* (ARCH) dan perluasannya yaitu model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH)

dikembangkan menjadi model *Exponential Generalized Autoregressive Conditional Heteroscedasticity* (EGARCH) oleh Nelson pada tahun 1991, hal ini dikarenakan pada model ARCH-GARCH terdapat batasan untuk menghasilkan estimasi parameter yang positif. Nelson menunjukkan bahwa dengan adanya fungsi varians kondisional simetris dinilai tidak cocok dalam memodelkan volatilitas saham atau pengembalian, karena tidak bisa mewakili efek asimetris (*leverage effect*) yang merupakan korelasi negatif antara volatilitas dengan *return*. Asimetri terhadap volatilitas terjadi pada saat pergerakan downward di dalam pasar modal diikuti oleh volatilitas yang lebih tinggi daripada pergerakan upward dari arah yang sama. Untuk memeriksa adanya efek asimetris maka dilakukan dengan cara melihat korelasi silang. Adanya efek asimetris ditandai dengan korelasi yang hasilnya tidak sama dengan nol. Pada model EGARCH (p, q) persamaan *conditional variance* secara umum dinyatakan dalam persamaan sebagai berikut [16] :

$$\log(\sigma_t^2) = \alpha_0 + \sum_{i=1}^p \beta_i \log(\hat{\sigma}_{t-i}^2) + \sum_{j=1}^q \alpha_j \left(\frac{|\varepsilon_{t-j}|}{\hat{\sigma}_{t-j}} + \sqrt{\frac{2}{\pi}} \right) + \xi \left(\frac{\varepsilon_{t-1}}{\hat{\sigma}_{t-1}} \right) \quad (2.24)$$

dengan,

α_j : parameter ARCH

β_i : parameter GARCH

ξ : parameter *leverage effect*

Menurut Nelson (1991) model EGARCH mempunyai kelebihan dibandingkan model ARCH-GARCH, yaitu parameter-parameter pada model EGARCH tidak dibatasi untuk memperoleh varians yang positif.

2.11. Estimasi Dan Pengujian Model Varian

Estimasi model varian EGARCH dapat menggunakan *Maksimum Likelihood Estimation* (MLE). Diberikan $\varepsilon_t \sim N(0, \sigma_t^2)$ dan $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ dimana n merupakan sampel acak dari distribusi independen identik (IID) dari $f(\varepsilon_t; \theta)$ dengan $\theta = 0, \sigma_t^2$. Fungsi *likelihood* untuk sampel berukuran T adalah sebagai berikut :

$$f(\varepsilon_t, \dots, \varepsilon_{t-1}, \varepsilon_T; \gamma) = \left(\prod_{t=q+1}^T f(\varepsilon_t | I_{t-1}; \gamma) \right) f(\varepsilon_t, \dots, \varepsilon_q; \gamma)$$

$$f(\varepsilon_t, \dots, \varepsilon_{t-1}, \varepsilon_T; \gamma) = \left(\prod_{t=q+1}^T (2\pi\sigma_t^2)^{-\frac{1}{2}} \exp\left(\frac{-\varepsilon_t^2}{2\sigma_t^2}\right) \right) f(\varepsilon_t, \dots, \varepsilon_q; \gamma) \quad (2.25)$$

Jika L_t adalah fungsi *log likelihood* untuk t dari sampel berukuran T maka :

$$L_t = \ln \left[\left(\prod_{t=q+1}^T (2\pi\sigma_t^2)^{-\frac{1}{2}} \exp\left(\frac{-\varepsilon_t^2}{2\sigma_t^2}\right) \right) f(\varepsilon_t, \dots, \varepsilon_q; \gamma) \right]$$

$$L_t = -\frac{1}{2} \ln(2\pi) - \frac{1}{2} \sum_{t=q+1}^T \ln(\sigma_t^2) - \sum_{t=q+1}^T \ln \frac{\varepsilon_t^2}{2\sigma_t^2} + \ln f(\varepsilon_t, \dots, \varepsilon_q; \gamma) \quad (2.26)$$

$\ln f(\varepsilon_t, \dots, \varepsilon_q; \gamma)$ akan diabaikan karena sangat rumit, maka bentuk *log likelihood* menjadi :

$$L_t = -\ln(2\pi) - \frac{1}{2} \left(\sum_{t=q+1}^T \left(\ln(\sigma_t^2) + \frac{\varepsilon_t^2}{2\sigma_t^2} \right) \right) \quad (2.27)$$

Persamaan (2.27) merupakan persamaan *maximum likelihood* ARCH (P). Dari persamaan (2.27) maka bentuk persamaan *maximum likelihood* untuk ARCH(1) adalah sebagai berikut :

$$L_t = -\ln(2\pi) - \frac{1}{2} \left(\sum_{t=q+1}^T \left(\ln(\alpha_0 + \alpha_1 \varepsilon^2_{t-1}) + \frac{\varepsilon_t^2}{\alpha_0 + \alpha_1 \varepsilon^2_{t-1}} \right) \right) \quad (2.28)$$

Dalam mendapatkan persamaan *maximum likelihood* dari model ARCH (1) maka persamaan (2.28) akan diturunkan terhadap parameter α_0 dan α_1 , akan diperoleh sebagai berikut :

$$\begin{aligned} \frac{\partial \ln L_t}{\partial \alpha_0} &= -\ln(2\pi) - \frac{1}{2} \left(\sum_{t=1}^T \left(\ln(\alpha_0 + \alpha_1 \varepsilon^2_{t-1}) + \frac{\varepsilon_t^2}{\alpha_0 + \alpha_1 \varepsilon^2_{t-1}} \right) \right) \\ &= -\frac{1}{2} \sum_{t=1}^T \left(\frac{1}{\alpha_0 + \alpha_1 \varepsilon^2_{t-1}} + (-1) \varepsilon_t^2 (\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^{-1} \right) \\ &= -\frac{1}{2} \sum_{t=1}^T \left(\frac{1}{\alpha_0 + \alpha_1 \varepsilon^2_{t-1}} - \varepsilon_t^2 (\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^{-2} \right) \\ &= -\frac{1}{2} \sum_{t=1}^T \left(\frac{1}{\alpha_0 + \alpha_1 \varepsilon^2_{t-1}} - \frac{\varepsilon_t^2}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} \right) \quad (2.29) \end{aligned}$$

Persamaan (2.29) akan dijadikan ke dalam bentuk $\frac{\partial \ln L_t}{\partial \alpha_0} = 0$, maka akan membentuk persamaan *maximum likelihood* sebagai berikut :

$$\begin{aligned} -\frac{1}{2} \sum_{t=1}^T \left(\frac{1}{\alpha_0 + \alpha_1 \varepsilon^2_{t-1}} - \frac{\varepsilon_t^2}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} \right) &= 0 \\ -\frac{1}{2} \sum_{t=1}^T \left(\frac{\alpha_0 + \alpha_1 \varepsilon^2_{t-1}}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} - \frac{\varepsilon_t^2}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} \right) &= 0 \end{aligned}$$

$$\begin{aligned}
& -\frac{1}{2} \sum_{t=1}^T \left(\frac{\alpha_0 + \alpha_1 \varepsilon^2_{t-1} - \varepsilon_t^2}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} \right) = 0 \\
& \sum_{t=1}^T \left(-\frac{\alpha_0 + \alpha_1 \varepsilon^2_{t-1} - \varepsilon_t^2}{2(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} \right) = 0 \\
& \sum_{t=1}^T (-\alpha_0 - \alpha_1 \varepsilon^2_{t-1} + \varepsilon_t^2) = 0 \\
& \sum_{t=1}^T \alpha_0 = \sum_{t=1}^T (\alpha_1 \varepsilon_t^2 + \varepsilon^2_{t-1}) \tag{2.30}
\end{aligned}$$

Selanjutnya akan dilakukan proses differensial parsialkan persamaan (2.29) terhadap parameter α_1 , diperoleh :

$$\begin{aligned}
\frac{\partial \ln L_t}{\partial \alpha_1} &= -\ln(2\pi) - \frac{1}{2} \left(\sum_{t=1}^T \left(\ln(\alpha_0 + \alpha_1 \varepsilon^2_{t-1}) + \frac{\varepsilon_t^2}{\alpha_0 + \alpha_1 \varepsilon^2_{t-1}} \right) \right) \\
&= -\frac{1}{2} \sum_{t=1}^T \left(\frac{\varepsilon^2_{t-1}}{\alpha_0 + \alpha_1 \varepsilon^2_{t-1}} + (-1) \varepsilon_t^2 \varepsilon^2_{t-1} (\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^{-1} \right) \\
&= -\frac{1}{2} \sum_{t=1}^T \left(\frac{\varepsilon^2_{t-1}}{\alpha_0 + \alpha_1 \varepsilon^2_{t-1}} - \frac{\varepsilon_t^2 \varepsilon^2_{t-1}}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} \right) \\
&= -\frac{1}{2} \sum_{t=1}^T \left(\frac{\alpha_0 + \alpha_1 \varepsilon^2_{t-1} (\varepsilon^2_{t-1})}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} - \frac{(\varepsilon_t^2) \varepsilon^2_{t-1}}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} \right) \\
\frac{\partial \ln L_t}{\partial \alpha_1} &= -\frac{1}{2} \sum_{t=1}^T \left(\frac{\alpha_0 + \alpha_1 \varepsilon^4_{t-1} (\varepsilon_t^2) \varepsilon^2_{t-1}}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} \right) \tag{2.31}
\end{aligned}$$

Persamaan (2.31) akan diturunkan terhadap parameter α_1 , maka diperoleh :

$$\frac{\partial \ln L_t}{\partial \alpha_1} = -\ln(2\pi) - \frac{1}{2} \left(\sum_{t=1}^T \left(\ln(\alpha_0 + \alpha_1 \varepsilon^2_{t-1}) + \frac{\varepsilon_t^2}{\alpha_0 + \alpha_1 \varepsilon^2_{t-1}} \right) \right)$$

$$\frac{\partial \ln L_t}{\partial \alpha_1} = -\frac{1}{2} \left(\sum_{t=1}^T \left(\frac{\varepsilon_t^2}{\alpha_0 + \alpha_1 \varepsilon^2_{t-1}} - \frac{\varepsilon_t^2 \varepsilon^2_{t-1}}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} \right) \right) \quad (2.32)$$

Persamaan (2.32) akan dijadikan ke dalam bentuk $\frac{\partial \ln L_t}{\partial \alpha_1} = 0$, maka akan membentuk persamaan *maximum likelihood* sebagai berikut :

$$-\frac{1}{2} \sum_{t=1}^T \left(\frac{\varepsilon_t^2}{\alpha_0 + \alpha_1 \varepsilon^2_{t-1}} - \frac{\varepsilon_t^2 \varepsilon^2_{t-1}}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} \right) = 0$$

$$-\frac{1}{2} \sum_{t=1}^T \left(\frac{\alpha_0 + \alpha_1 \varepsilon^2_{t-1} (\varepsilon_t^2)}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} - \frac{\varepsilon_t^2 \varepsilon^2_{t-1}}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} \right) = 0$$

$$-\frac{1}{2} \sum_{t=1}^T \left(\frac{\alpha_0 + \alpha_1 \varepsilon^4_{t-1} - \varepsilon_t^2 \varepsilon^2_{t-1}}{(\alpha_0 + \alpha_1 \varepsilon^2_{t-1})^2} \right) = 0$$

$$\sum_{t=1}^T (\alpha_0 + \alpha_1 \varepsilon^4_{t-1} - \varepsilon_t^2 \varepsilon^2_{t-1}) = 0$$

$$\sum_{t=1}^T \alpha_1 = \frac{\sum_{t=1}^T (\varepsilon_t^2 - \alpha_0)}{\sum_{t=1}^T \varepsilon^2_{t-1}} \quad (2.33)$$

Misalkan α_i merupakan estimasi parameter dari model varian seperti ARCH, GARCH, dan EGARCH. Maka akan dilakukan uji signifikansi parameter adalah sebagai berikut:

Hipotesa :

$H_0 : \alpha_i = 0$, artinya tidak signifikan atau tidak masuk model

$H_0 : \alpha_i \neq 0$, signifikan dengan $i = 1, 2, 3, \dots, p$

Uji statistik :

$$t_{ratio} = \frac{\hat{\alpha}_i}{S_d(\alpha_i)}$$

Kriteria pengujian :

H_0 akan ditolak jika $|t_{ratio}| > t_{(\frac{\alpha}{2}, n-p-1)}$ dengan n merupakan jumlah dari data dan p adalah banyaknya parameter, yang berarti parameter tersebut signifikan dan masuk dalam model.

2.12. Kriteria Pemilihan Model Terbaik

Dalam kriteria pemilihan sebuah model terbaik sangat diperlukan, hal ini bertujuan untuk pengecekan ketepatan suatu model *time series*. Menguji residual adalah salah satu kriteria dalam pemilihan model terbaik, dimana harus termuat asumsi *white noise*. Selanjutnya akan digunakan uji Chi-Square untuk pengujian data *time series* apakah data tersebut memenuhi asumsi *white noise* atau tidak. Dalam seleksi pemilihan model terbaik dapat dilakukan dengan melihat nilai AIC (*Akaike Information Criterion*) dan SBC (*Schwart Bayesian Criterion*) yang paling minimum [17].

1. AIC (*Akaike Information Criterion*)

$$AIC = n \ln \hat{\sigma}_\alpha^2 + 2M \quad (2.34)$$

dengan,

M : Banyaknya parameter yang diestimasi

n : banyak pengamatan

$\hat{\sigma}_\alpha^2$: estimasi dari σ_t^2 .

2. SBC (Schwart Bayesian Criterion)

$$SBC = n \ln \hat{\sigma}_\alpha^2 + M \ln n \quad (2.35)$$

dengan,

M : Banyaknya parameter yang diestimasi

n : banyak pengamatan

$\hat{\sigma}_\alpha^2$: estimasi dari σ_t^2 .

BAB III

METODE PENELITIAN

Pada bab ini dijelaskan tentang metode yang digunakan dalam penelitian Tugas Akhir, hal ini bertujuan supaya proses pengerjaan dapat terstruktur dengan baik dan mencapai tujuan yang telah dicantumkan. Penjabaran dari bab ini diantaranya adalah jenis data dan sumber data, serta tahap penelitian .

3.1. Jenis Dan Sumber Data

3.1.1 Jenis Data

Jenis data yang digunakan dalam penelitian Tugas Akhir ini adalah data sekunder yaitu data harga penutupan saham PT. Indofarma Tbk. (INAF) periode 01 Oktober 2014 sampai dengan 01 September 2021. Data penutupan saham PT. Indofarma Tbk. (INAF) dilakukan proses perhitungan *return* dengan menggunakan persamaan (2.1), sehingga data *return* saham yang sudah diperoleh digunakan untuk mencari model terbaik berdasarkan ketentuan uji signifikansi dan diagnostik.

3.1.2 Sumber Data

Data harga saham yang diperoleh berasal dari *website* www.finance.yahoo.com. Data yang didapatkan yaitu data harga penutupan saham (bulanan) periode 01 Oktober 2014 – 01 September 2021.

3.2 Tahap Penelitian

Berikut disajikan tahapan dalam penyelesaian Tugas Akhir :

3.2.1 Studi Literatur

Dalam tahapan ini dilakukan proses pengumpulan teori – teori yang menjadi pendukung dalam proses pengerjaan Tugas

Akhir. Studi literatur yang digunakan adalah bersumber dari hasil penelitian terdahulu, jurnal, *e-book*, dan *paper* internasional.

3.2.2 Pengolahan Data

Pada tahap ini dilakukan proses pengolahan data dari perusahaan PT. Indofarma Tbk. Proses pengolahan data dilakukan dengan menggunakan bantuan *software* Minitab, dan Eviews. Tahapan yang dilakukan dalam proses pengolahan data antara lain, yaitu :

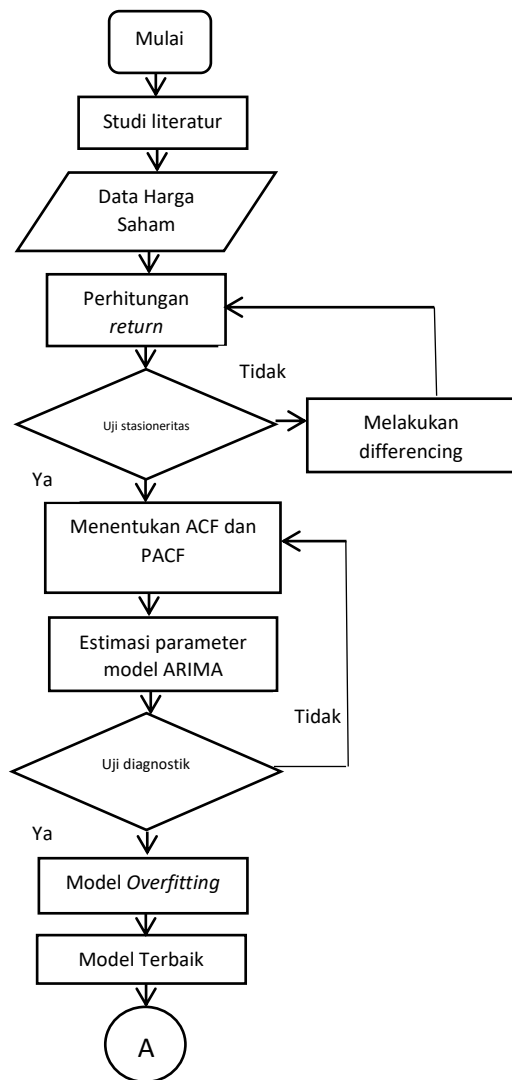
1. Data penutupan harga saham diolah menjadi data *return* dengan menggunakan rumus *log-return*.
2. Data harus stasioner dalam *mean* dan *varian*.
3. Analisis plot ACF dan PACF.
4. Pendugaan model sementara berdasarkan lag yang keluar dari plot ACF dan PACF.
5. Estimasi parameter dugaan model sementara.
6. Uji diagnostik yang meliputi uji *white noise* dan uji normalitas.
7. Uji heterokedastisitas model yang telah memenuhi uji signifikansi dan diagnostic.
8. Jika terdapat unsur heterokedastisitas, maka dilakukan identifikasi model ARCH-GARCH, dan EGARCH.
9. Peramalan *return* penutupan harga saham PT Indofarma Tbk (INAF) periode Oktober 2020 – September 2021.


3.2.3 Analisis dan Hasil Kesimpulan

Analisis hasil dan kesimpulan dilakukan untuk membahas hasil yang diperoleh dari pengolahan data yaitu menemukan model yang dapat mengakomodasi sifat volatilitas pada data dan melakukan peramalan. Kemudian langkah Selanjutnya adalah menarik kesimpulan dari Tugas Akhir ini yaitu model ARCH, GARCH, dan EGARCH yang paling sesuai untuk obyek penelitian serta saran untuk pengembangan Tugas Akhir selanjutnya.

3.3 Diagram Alir

Berikut disajikan diagram alir dari proses pengerjaan Tugas Akhir pada Gambar 3.1 :






Gambar 3.1 Diagram Alir

BAB IV ANALISIS DAN PEMBAHASAN

Pada bab ini dilakukan pembahasan dan analisis terkait langkah–langkah dalam melakukan pembentukan model volatilitas saham yang berasal dari *return* harga penutupan saham dengan menerapkan model EGARCH.

4.1 Analisis Statistika Deskriptif

Dalam melakukan analisis data, langkah pertama yang dilakukan adalah melakukan plot data harga penutupan saham PT. Indofarma Tbk (INAF.JK) dari periode 01 Oktober 2014 sampai dengan 01 September 2020. Plot data ditunjukkan pada gambar 4.1.

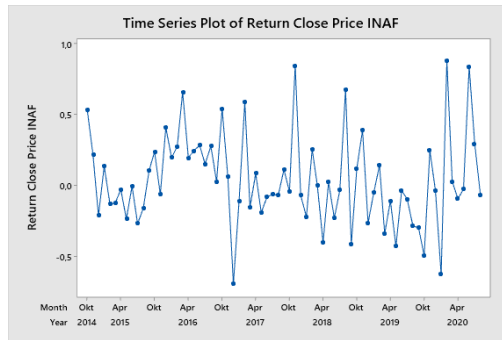


Gambar 4.1 Plot Data Harga Penutupan Saham
PT. Indofarma Tbk (INAF.JK)

Berdasarkan pada data harga penutupan saham PT. Indofarma Tbk (INAF.JK), data harga saham pertama dan data saham kedua dari PT. Indofarma Tbk (INAF.JK) secara berturut-turut adalah 1670 dan 2850, sehingga dengan perhitungan menggunakan persamaan (2.1) diperoleh *return* pada periode pertama adalah :

$$r(t) = \ln\left(\frac{2850}{1670}\right) = 0,534495368$$

dengan menggunakan cara yang sama dapat dilakukan perhitungan $r(t)$ untuk $t = 2,3, \dots, 72$ dari banyaknya data in sample harga penutupan saham PT. Indofarma Tbk (INAF.JK). *Return* harga penutupan saham PT. Indofarma Tbk (INAF.JK) periode 01 Oktober 2014 sampai dengan 01 September 2021 ditunjukkan pada Gambar 4.2.



Gambar 4.2 Plot Data *Return* Harga Penutupan Saham PT. Indofarma Tbk (INAF.JK)

Berdasarkan 4.2 terlihat bahwa pergerakan data *return* penutupan harga saham PT. Indofarma Tbk (INAF.JK) berfluktuasi dari waktu ke waktu, hal ini dikatakan dalam teori keuangan sebagai peristiwa volatility clustering, yaitu kondisi dimana pergerakan data deret waktu (time series) cenderung naik atau turun secara drastis dan tiba-tiba dalam suatu kondisi atau kejadian tertentu.

Selanjutnya dilakukan analisis statistika deskriptif untuk mendapatkan nilai *mean*, standard deviasi, nilai maximum dan

minimum. Statistika deskriptif merupakan kegiatan untuk pengumpulan dan pengolahan data yang menghasilkan ukuran-ukuran statistik antara lain, frekuensi, pemusatan data, penyebaran data, dan sebagainya. Hal ini bertujuan untuk mempermudah dalam memahami data dan juga dapat diringkas dalam bentuk tabel. Berikut ini disajikan Tabel 4.1 yang merupakan tabel statistika deskriptif dari *return* harga penutupan saham PT Indofarma Tbk (INAF.JK).

Tabel 4.1. Statistika Deskriptif Data *Return* Penutupan Harga Saham Tahun 2014-2021

Statistika Deskriptif				
Data	Mean	Std. Deviasi	Max	Min
<i>Return</i>	0,040008213	0,3270255	0,87992	-0,69315

Tabel 4.1 menunjukkan *mean*, *standard deviasi*, data terbesar (max), dan data terkecil (min) pada data *return* PT. Indofarma Tbk. Nilai maximum untuk *return* harga penutupan saham PT. Indofarma Tbk berada pada 01 Maret 2020 sebesar 0,87992, hal ini berarti nilai *return* harga penutupan saham PT. Indofarma Tbk (INAF.JK) pada bulan ke t lebih besar dibandingkan bulan $t-1$. Nilai minimum *return* dari harga penutupan saham PT. Indofarma Tbk (INAF.JK) berada pada 01 Februari 2020 sebesar -0,69315, hal ini menunjukkan bahwa nilai *return* pada waktu ke t lebih kecil daripada waktu ke $t-1$. Selisih perhitungan dari nilai maximum dengan nilai minimum pada data *return* harga penutupan saham PT. Indofarma Tbk (INAF.JK)

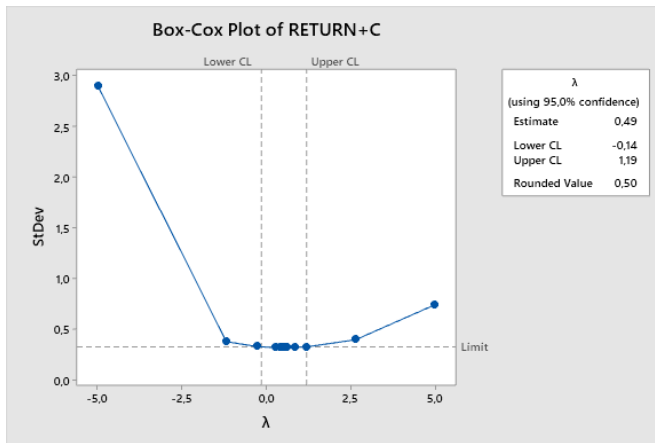
adalah sebesar 1,57307 yang mengindikasikan adanya volatilitas yang cukup tinggi pada kumpulan data tersebut.

4.2 Identifikasi Data

Proses identifikasi data meliputi dua hal yaitu uji stasioneritas serta melakukan plot *time series* ACF dan PACF.

4.2.1 Uji Stasioneritas


Langkah awal dalam menentukan model ARIMA adalah dengan melakukan uji stasioneritas pada data *return*. Data *return* dikatakan stasioner apabila memenuhi kondisi stasioner terhadap *varian* dan *mean*. Pertama yang dilihat adalah kondisi stasioneritas pada *varian*.



Gambar 4.3 Plot Box-Cox *Return* Harga Penutupan Saham PT Indofarma Tbk.

Pada Gambar 4.3 ditunjukkan hubungan antar nilai lambda dengan nilai standard deviasi, dengan nilai lambda yang ditampilkan dari -5 sampai dengan 5 terlihat bahwa nilai lambda


terbaik berada diantara batas *Lower CL* dan *Upper CL* yang berupa garis vertikal , hal ini dikarenakan nilai standar deviasinya semakin kecil. Nilai lambda yang yang baik berada pada -0,14 (*Lower CL*) sampai dengan 1,19 (*Upper CL*) dimana nilai lambda terbaik menunjukkan 0,49, akan tetapi nilai lambda yang dipakai sebaiknya dapat dimengerti, sehingga diambil nilai *rounded value* sebesar 0,5 , dimana *rounded value* 0,5 belum stasioner terhadap varian sehingga, dilakukan transformasi Box-Cox $Z_1 = \sqrt{Z_1} = Z_1^{0,5}$. Setelah proses transformasi Box-Cox dilakukan maka didapatkan nilai *rounded value* sama dengan 1, yang ditunjukkan oleh Gambar 4.4. Apabila nilai dari *rounded value* sama dengan 1, maka hal tersebut menunjukkan bahwa data *return* sudah stasioner terhadap varian.



Gambar 4.4 Plot Transformasi Box-Cox *Return* Harga Penutupan Saham PT Indofarma Tbk.

Setelah dilihat kestasioneran data *return* terhadap varians, maka selanjutnya akan dilihat apakah data *return* penutupan harga

saham telah stasioner terhadap *mean* . Stasioner terhadap *mean* dapat dilihat dengan cara melakukan plot trend analysis pada Gambar 4.5.



Gambar 4.5 Plot Trend Analysis *Return* Harga Penutupan Saham PT Indofarma Tbk.

Gambar 4.5 menunjukkan bahwa data *return* harga penutupan saham belum stasioner dalam *mean*. Selain itu dapat dilihat bahwa data juga tidak berfluktuasi disekitar nilai tengah serta *trend* tidak mengikuti sumbu horizontal. Sehingga dapat diperoleh kesimpulan bahwa data *return* harga penutupan saham pada PT Indofarma Tbk. tidak stasioner terhadap *mean*. Ketidakstasioneran terhadap *mean* dapat diatasi dengan melakukan proses *differencing* orde pertama dengan menggunakan rumus *differencing* orde 1 pada persamaan (2.9) yaitu :


$$X_1 = (1 - B)^1 Z_t = X_t - B^1 Z_t = Z_t - Z_{t-1}$$

dengan :

B : “backshift”

Z_t : data yang akan di *differencing* pada waktu t

X_t : data hasil *differencing* orde d



Gambar 4.6 Plot Trend Analysis Setelah Differencing *Return* Harga Penutupan Saham PT Indofarma Tbk.

Gambar 4.6 menunjukkan bahwa data *return* harga penutupan saham PT Indofarma Tbk. Telah memiliki pola yang teratur dan tidak terlalu fluktuatif. Secara visual telah terlihat bahwa data sudah stasioner terhadap mean yang ditandai dengan pola data yang fluktuasi disekitaran nilai tengah serta garis trend sudah mendekati sumbu horizontal.

4.2.2 Plot ACF dan PACF

Berikut ini adalah perhitungan dari ACF dan PACF pada lag ke-1 adalah sebagai berikut :

1. Fungsi Autokorelasi (ACF)

Berikut ini adalah perhitungan ACF dan selang kepercayaan ACF :

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Z_t - \mu)(Z_{t+k} - \mu)}{\sum_{t=1}^{n-k} (Z_t - \mu)^2}$$

$$\hat{\rho}_1 = \frac{(Z_1 - \mu)(Z_2 - \mu) + \dots + (Z_{69} - \mu)(Z_{70} - \mu)}{(Z_1 - \mu)^2 + (Z_2 - \mu)^2 + \dots + (Z_{69} - \mu)^2 + (Z_{70} - \mu)^2}$$

$$\hat{\rho}_1 = \frac{-1,718865932}{3,661981905}$$

$$\hat{\rho}_1 = -0,469381329$$

⋮

Dst

$$\text{selang kepercayaan ACF} = 0 \pm t_{69} \left(\frac{0,05}{2} \right) \times SE(\rho_1)$$

$$\text{selang kepercayaan ACF} = 0 \pm 1,994 \left(\frac{0,05}{2} \right) \times \sqrt{\frac{1}{70}}$$

$$\text{selang kepercayaan ACF} = -0,23833$$

2. Fungsi Autokorelasi Parsial (PACF)

Berikut ini adalah perhitungan ACF dan selang kepercayaan ACF :

$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^k \phi_{kj} \rho_{k+1-j}}{1 - \sum_{j=1}^k \phi_{kj} \rho_{kj}}$$

$$\phi_{11} = \frac{\rho_k - \sum_{j=1}^k \phi_{1-1} \rho_{1-1}}{1 - \sum_{j=1}^k \phi_{1-1} \rho_{1-1}}$$

$$\begin{aligned} \phi_{11} &= \rho_1 \\ \phi_{11} &= -0,469381329 \\ &\vdots \\ &\text{Dst} \\ \text{selang kepercayaan ACF} &= 0 \pm t_{69} \left(\frac{0,05}{2} \right) \times SE(\rho_1) \\ \text{selang kepercayaan ACF} &= 0 \pm 1,994 \left(\frac{0,05}{2} \right) \times \sqrt{\frac{1}{70}} \\ \text{selang kepercayaan ACF} &= -0,23833 \end{aligned}$$

Identifikasi model ARIMA bertujuan untuk mencari dugaan model yang sesuai setelah proses stasioneritas. Proses identifikasi model ARIMA dilakukan dengan plot *time series* PACF dan ACF yang ditunjukkan oleh Gambar 4.7 dan 4.8, dalam menentukan model ARIMA, lag yang keluar dari plot PACF menentukan model AR, sedangkan untuk lag yang keluar dari plot ACF menentukan model MA. Pada Gambar 4.7 terlihat bahwa plot PACF keluar pada lag ke-1, 2, dan 12. Sedangkan pada Gambar 4.8 terlihat bahwa plot ACF keluar pada lag ke-1, dan 3. Gambar 4.7 dan 4.8 menunjukkan model sementara untuk data *Return* harga penutupan saham periode 01 Oktober 2014 sampai dengan 01 September 2020 adalah ARIMA ([1,2], 1, [1,3]), ARIMA ([1,12], 1, [1,3]), dan ARIMA ([2,12] 1, [1,3]). Berikut adalah bentuk model ARIMA sementara yang diperoleh dari plot ACF dan PACF :

1. Model ARIMA ([1,2],1,[1,3])

$$(1 - \phi_1 B - \dots - \phi_p B^p)Z_t = (1 - \theta_1 B - \dots - \theta_q B^q)\varepsilon_t$$

$$(1 - \phi_1 B - \phi_2 B^2)Z_t = (1 - \theta_1 B - \theta_3 B^3)\varepsilon_t$$

$$Z_t(1) - \phi_1 B(Z_t) - \phi_2 B^2(Z_t) = \varepsilon_t(1) - \theta_1 B(\varepsilon_t) - \theta_3 B^3(\varepsilon_t)$$

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_3 \varepsilon_{t-3}$$

2. Model ARIMA ([1,12],1,[1,3])

$$(1 - \phi_1 B - \dots - \phi_p B^p)Z_t = (1 - \theta_1 B - \dots - \theta_q B^q)\varepsilon_t$$

$$(1 - \phi_1 B - \phi_{12} B^{12})Z_t = (1 - \theta_1 B - \theta_3 B^3)\varepsilon_t$$

$$Z_t(1) - \phi_1 B(Z_t) - \phi_{12} B^{12}(Z_t) = \varepsilon_t(1) - \theta_1 B(\varepsilon_t) - \theta_3 B^3(\varepsilon_t)$$

$$Z_t = \phi_1 Z_{t-1} + \phi_{12} Z_{t-12} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_3 \varepsilon_{t-3}$$


3. Model ARIMA ([2,12],1,[1,3])

$$(1 - \phi_1 B - \dots - \phi_p B^p)Z_t = (1 - \theta_1 B - \dots - \theta_q B^q)\varepsilon_t$$


$$(1 - \phi_2 B^2 - \phi_{12} B^{12})Z_t = (1 - \theta_1 B - \theta_3 B^3)\varepsilon_t$$

$$Z_t(1) - \phi_2 B^2(Z_t) - \phi_{12} B^{12}(Z_t) = \varepsilon_t(1) - \theta_1 B(\varepsilon_t) - \theta_3 B^3(\varepsilon_t)$$

$$Z_t = \phi_2 Z_{t-2} + \phi_{12} Z_{t-12} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_3 \varepsilon_{t-3}$$



Gambar 4.7 Plot PACF *Return* Harga Penutupan Saham PT Indofarma Tbk.



Gambar 4.8 Plot ACF *Return* Harga Penutupan Saham PT Indofarma Tbk.

4.3 Estimasi Parameter

Setelah mendapatkan dugaan model sementara, maka dilakukan proses estimasi parameter dan uji signifikansi terhadap salah satu model dugaan, sebagai contoh yaitu model ARIMA ([1,2], 1, [1,3]) dengan menggunakan metode *Least – Square*. Hasil estimasi parameter dapat dilihat melalui Tabel 4.2.

Tabel 4.2: Estimasi Parameter Model ARIMA ([1,2],1,[1,3])

Uji Signifikansi Model ARIMA ([1,2],1,[1,3])					
Parameter	Koefisien	SE	t-stat	p-value	Signifikan / tidak
ϕ_1	-0,458272	0,212545	-2,15612	0,0348	Signifikan
ϕ_2	-0,422842	0,227927	-1,855167	0,0681	Tidak Signifikan
θ_1	-0,472575	0,235828	-2,003896	0,0493	Signifikan
θ_3	0,080079	0,189404	0,422791	0,6738	Tidak Signifikan

Langkah selanjutnya dilakukan uji signifikansi parameter pada Model ARIMA ([1,2],1,[1,3]) dengan menggunakan uji-t yang bertujuan untuk melihat kecocokkan data yang ada.

Hipotesis:

$H_0 : \phi = 0$ (parameter model tidak signifikan)

$H_0 : \phi \neq 0$ ((parameter model signifikan)

1. Uji Parameter ϕ_1

Statistik Uji

$$t_{hitung} = \frac{\widehat{\phi}_1}{st. dev (\theta_1)} = \frac{-0,458272}{0,212545} = -2,15612$$

$$t_{tabel} = t_{(0,025;70)} = 1,994$$

Kriteria Pengujian

Taraf signifikan $\alpha = 0,05$

Tolak H_0 jika $|t_{hitung}| > t_{tabel}$

Keputusan

Tolak H_0 sebab $|t_{hitung}| = 2,15612 > t_{tabel} = 1,994$
yang berarti **parameter ϕ_1 signifikan** .

2. Uji Parameter ϕ_2

Statistik Uji

$$t_{hitung} = \frac{\widehat{\phi}_2}{st. dev (\theta_1)} = \frac{-0,422842}{0,227927} = -1,855167$$

$$t_{tabel} = t_{(0,025;70)} = 1,994$$

Kriteria Pengujian

Taraf signifikan $\alpha = 0,05$

Tolak H_0 jika $|t_{hitung}| > t_{tabel}$

Keputusan

Tolak H_0 sebab $|t_{hitung}| = 1,855167 < t_{tabel} = 1,994$
Yang berarti **parameter ϕ_2 tidak signifikan** .

3. Uji Parameter θ_1

Statistik Uji

$$t_{hitung} = \frac{\widehat{\theta}}{st. dev (\theta_1)} = \frac{-0,472575}{0,235828} = -2,003896$$

$$t_{tabel} = t_{(0,025;70)} = 1,994$$

Kriteria Pengujian

Taraf signifikan $\alpha = 0,05$

Tolak H_0 jika $|t_{hitung}| > t_{tabel}$

Keputusan

Tolak H_0 sebab $|t_{hitung}| = 2,003896 > t_{tabel} = 1,994$

Yang berarti **parameter θ_1 signifikan** .

4. Uji Parameter θ_3

Statistik Uji

$$t_{hitung} = \frac{\hat{\theta}}{st. dev (\theta_3)} = \frac{0,080079}{0,189404} = 0,422791$$

$$t_{tabel} = t_{(0,025;70)} = 1,994$$

Kriteria Pengujian

Taraf signifikan $\alpha = 0,05$

Tolak H_0 jika $|t_{hitung}| > t_{tabel}$

Keputusan

Tolak H_0 sebab $|t_{hitung}| = 0,422791 < t_{tabel} = 1,994$

yang berarti **parameter θ_3 tidak signifikan** .

Berdasarkan hasil uji signifikansi ARIMA ([1,2], 1, [1,3]) diperoleh hasil bahwa model ARIMA ([1,2], 1, [1,3]) bukan model yang tepat untuk dilakukan peramalan, hal ini dikarenakan terdapat parameter model ARIMA ([1,2],1,[1,3]) yang tidak signifikan, sehingga dilakukan proses *overfitting* yang disajikan di dalam Tabel 4.3.

Tabel 4.3 *Overfitting* Model ARIMA

Model	Lag Pada Plot PACF	Lag Pada Plot ACF	Model ARIMA
1	1	1	(1,1,1)
2	1	3	(1,1,3)
3	2	1	(2,1,1)
4	2	3	(2,1,3)
5	12	1	(12,1,1)
6	12	3	(12,1,3)
7	1	0	(1,1,0)
8	2	0	(2,1,0)
9.	12	0	(12,1,0)
10.	0	1	(0,1,1)
11.	0	3	(0,1,3)

Berdasarkan Tabel 4.3 semua model *overfitting* akan dilakukan proses estimasi parameter yang sama dengan estimasi parameter model ARIMA ([1,2], 1, [1,3]). Berikut ini disajikan bentuk model dari proses *overfitting* sebelum dilakukan estimasi.

1. Model ARIMA (1,1,1)

$$(1 - \phi_1 B - \dots - \phi_p B^p) Z_t = (1 - \theta_1 B - \dots - \theta_q B^q) \varepsilon_t$$

$$(1 - \phi_1 B) Z_t = (1 - \theta_1 B) \varepsilon_t$$

$$Z_t(1) - \phi_1 B(Z_t) = \varepsilon_t(1) - \theta_1 B(\varepsilon_t)$$

$$Z_t = \phi_1 Z_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

2. Model ARIMA (1,1,3)

$$(1 - \phi_1 B - \dots - \phi_p B^p)Z_t = (1 - \theta_1 B - \dots - \theta_q B^q)\varepsilon_t$$

$$(1 - \phi_1 B)Z_t = (1 - \theta_3 B^3)\varepsilon_t$$

$$Z_t(1) - \phi_1 B(Z_t) = \varepsilon_t(1) - \theta_3 B^3(\varepsilon_t)$$

$$Z_t = \phi_1 Z_{t-1} + \varepsilon_t - \theta_3 \varepsilon_{t-3}$$

3. Model ARIMA (2,1,1)

$$(1 - \phi_1 B - \dots - \phi_p B^p)Z_t = (1 - \theta_1 B - \dots - \theta_q B^q)\varepsilon_t$$

$$(1 - \phi_2 B^2)Z_t = (1 - \theta_1 B)\varepsilon_t$$

$$Z_t(1) - \phi_2 B^2(Z_t) = \varepsilon_t(1) - \theta_1 B(\varepsilon_t)$$

$$Z_t = \phi_2 Z_{t-2} + \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

4. Model ARIMA (2,1,3)

$$(1 - \phi_1 B - \dots - \phi_p B^p)Z_t = (1 - \theta_1 B - \dots - \theta_q B^q)\varepsilon_t$$

$$(1 - \phi_2 B^2)Z_t = (1 - \theta_3 B^3)\varepsilon_t$$

$$Z_t(1) - \phi_2 B^2(Z_t) = \varepsilon_t(1) - \theta_3 B^3(\varepsilon_t)$$

$$Z_t = \phi_2 Z_{t-2} + \varepsilon_t - \theta_3 \varepsilon_{t-3}$$

5. Model ARIMA (12,1,1)

$$(1 - \phi_1 B - \dots - \phi_p B^p)Z_t = (1 - \theta_1 B - \dots - \theta_q B^q)\varepsilon_t$$

$$(1 - \phi_{12} B^{12})Z_t = (1 - \theta_1 B)\varepsilon_t$$

$$Z_t(1) - \phi_{12} B^{12}(Z_t) = \varepsilon_t(1) - \theta_1 B(\varepsilon_t)$$

$$Z_t = \phi_{12} Z_{t-12} + \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

6. Model ARIMA (12,1,3)

$$(1 - \phi_1 B - \dots - \phi_p B^p) Z_t = (1 - \theta_1 B - \dots - \theta_q B^q) \varepsilon_t$$

$$(1 - \phi_{12} B^{12}) Z_t = (1 - \theta_3 B^3) \varepsilon_t$$

$$Z_t(1) - \phi_{12} B^{12}(Z_t) = \varepsilon_t(1) - \theta_3 B^3(\varepsilon_t)$$

$$Z_t = \phi_{12} Z_{t-12} + \varepsilon_t - \theta_3 \varepsilon_{t-3}$$

7. Model ARIMA (1,1,0)

$$(1 - \phi_p B - \dots - \phi_p B^p) Z_t = (1 - \theta_q B - \dots - \theta_q B^q) \varepsilon_t$$

$$(1 - \phi_1 B) Z_t = (1 - \theta_0 B^0) \varepsilon_t$$

$$Z_t(1) - \phi_1 B(Z_t) = \varepsilon_t(1) - \theta_0 B^0(\varepsilon_t)$$

$$Z_t = \phi_1 Z_{t-1} + \varepsilon_t$$

8. Model ARIMA (2,1,0)

$$(1 - \phi_p B - \dots - \phi_p B^p) Z_t = (1 - \theta_q B - \dots - \theta_q B^q) \varepsilon_t$$

$$(1 - \phi_2 B^2) Z_t = (1 - \theta_0 B^0) \varepsilon_t$$

$$Z_t(1) - \phi_2 B^2(Z_t) = \varepsilon_t(1) - \theta_0 B^0(\varepsilon_t)$$

$$Z_t = \phi_2 Z_{t-2} + \varepsilon_t$$

9. Model ARIMA (12,1,0)

$$(1 - \phi_p B - \dots - \phi_p B^p) Z_t = (1 - \theta_q B - \dots - \theta_q B^q) \varepsilon_t$$

$$(1 - \phi_{12} B^{12}) Z_t = (1 - \theta_0 B^0) \varepsilon_t$$

$$Z_t(1) - \phi_{12} B^{12}(Z_t) = \varepsilon_t(1) - \theta_0 B^0(\varepsilon_t)$$

$$Z_t = \phi_{12} Z_{t-12} + \varepsilon_t$$

10. Model ARIMA (0,1,1)

$$(1 - \phi_p B - \dots - \phi_p B^p)Z_t = (1 - \theta_q B - \dots - \theta_q B^q)\varepsilon_t$$

$$(1 - \phi_0 B^0)Z_t = (1 - \theta_1 B)\varepsilon_t$$

$$Z_t(1) - \phi_0 B^0(Z_t) = \varepsilon_t(1) - \theta_1 B(\varepsilon_t)$$

$$Z_t = \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

11. Model ARIMA (0,1,3)

$$(1 - \phi_p B - \dots - \phi_p B^p)Z_t = (1 - \theta_q B - \dots - \theta_q B^q)\varepsilon_t$$

$$(1 - \phi_0 B^0)Z_t = (1 - \theta_3 B^3)\varepsilon_t$$

$$Z_t(1) - \phi_0 B^0(Z_t) = \varepsilon_t(1) - \theta_3 B^3(\varepsilon_t)$$

$$Z_t = \varepsilon_t - \theta_3 \varepsilon_{t-3}$$

Setelah dilakukan pembentukan model dari hasil *overfitting* model ARIMA maka dilakukan proses estimasi parameter yang sama dengan model ARIMA ([1,2],1,[1,3]), selanjutnya dilakukan uji signifikansi dari 11 model ARIMA yang disajikan dalam bentuk Tabel 4.4. Berdasarkan dari Tabel 4.4 Model ARIMA yang mempunyai parameter signifikan adalah

1. Model ARIMA (1,1,3)

$$(1 - \phi_p B - \dots - \phi_p B^p)Z_t = (1 - \theta_q B - \dots - \theta_q B^q)\varepsilon_t$$

$$(1 - \phi_1 B)Z_t = (1 - \theta_3 B^3)\varepsilon_t$$

$$Z_t(1) - \phi_1 B(Z_t) = \varepsilon_t(1) - \theta_3 B^3(\varepsilon_t)$$

$$Z_t = \phi_1 Z_{t-1} + \varepsilon_t - \theta_3 \varepsilon_{t-3}$$

2. ARIMA (1,1,0)

$$(1 - \phi_p B - \dots - \phi_p B^p)Z_t = (1 - \theta_q B - \dots - \theta_q B^q)\varepsilon_t$$

$$(1 - \phi_1 B)Z_t = (1 - \theta_0 B^0)\varepsilon_t$$

$$Z_t(1) - \phi_1 B(Z_t) = \varepsilon_t(1) - \theta_0 B^0(\varepsilon_t)$$

$$Z_t = \phi_1 Z_{t-1} + \varepsilon_t$$

3. ARIMA (0,1,1)

$$(1 - \phi_p B - \dots - \phi_p B^p)Z_t = (1 - \theta_q B - \dots - \theta_q B^q)\varepsilon_t$$

$$(1 - \phi_0 B^0)Z_t = (1 - \theta_1 B)\varepsilon_t$$

$$Z_t(1) - \phi_0 B^0(Z_t) = \varepsilon_t(1) - \theta_1 B(\varepsilon_t)$$

$$Z_t = \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

4. ARIMA (0,1,3).

$$(1 - \phi_p B - \dots - \phi_p B^p)Z_t = (1 - \theta_q B - \dots - \theta_q B^q)\varepsilon_t$$

$$(1 - \phi_0 B^0)Z_t = (1 - \theta_3 B^3)\varepsilon_t$$

$$Z_t(1) - \phi_0 B^0(Z_t) = \varepsilon_t(1) - \theta_3 B^3(\varepsilon_t)$$

$$Z_t = \varepsilon_t - \theta_3 \varepsilon_{t-3}$$

Tabel 4.4: Uji Signifikansi *Overfitting* Model ARIMA

Model ARIMA	Parameter	P-Value	Uji Signifikansi
ARIMA (1,1,1)	ϕ_1	0,8999	Tidak Signifikan
	θ_1	0	
ARIMA (1,1,3)	ϕ_1	0	Signifikan
	θ_3	0,0008	
ARIMA (2,1,1)	ϕ_2	0,5483	Tidak Signifikan
	θ_1	0	
ARIMA (2,1,3)	ϕ_2	0,5229	Tidak Signifikan
	θ_3	0,0028	
ARIMA (12,1,1)	ϕ_{12}	0,9291	Tidak Signifikan
	θ_1	0	
ARIMA (12,1,3)	ϕ_{12}	0,4323	Tidak Signifikan
	θ_3	0	
ARIMA (1,1,0)	ϕ_1	0	Signifikan
ARIMA (2,1,0)	ϕ_2	0,1011	Tidak Signifikan
ARIMA (12,1,0)	ϕ_{12}	0,7363	Tidak Signifikan
ARIMA (0,1,1)	θ_1	0	Signifikan
ARIMA (0,1,3)	θ_3	0,0005	Signifikan

4.4 Uji Diagnostik

Setelah melakukan pengujian parameter signifikansi, langkah selanjutnya yaitu melakukan uji diagnostic terhadap model ARIMA yang memiliki parameter signifikan. Uji diagnostik terdiri dari uji *white-noise* dan uji distribusi normal. Model ARIMA dikatakan sebagai model ARIMA terbaik apabila memenuhi syarat *white-noise* dan berdistribusi normal. Perhitungan uji *white noise* menggunakan uji *Ljung Box*, sedangkan uji normalitas menggunakan *Jarque Bera*. Berikut adalah uji *white-noise* untuk model ARIMA (0,1,1) dengan menggunakan uji *Ljung Box*, yaitu :

Hipotesis :

$H_0 = \rho_1 = \rho_2 = \dots = \rho_{12} = 0$ (residual bersifat *white-noise*)

H_1 : minimal ada satu $\rho_i \neq 0$, dengan $i = 1,2,3,\dots,12$ (residual tidak bersifat *white-noise*)

Statistik uji

Untuk $k=12$, maka :

$$Q = n(n + 2) \sum_{k=1}^{12} \frac{\rho_k^2}{n - k}$$

$$Q = 70(70 + 2) \left(\frac{(-0,021)^2}{72 - 1} + \frac{(-0,067)^2}{72 - 2} + \frac{(0,336)^2}{72 - 3} \right. \\ \left. + \frac{(0,04)^2}{72 - 4} + \frac{(0,038)^2}{72 - 5} + \frac{(-0,006)^2}{72 - 6} \right. \\ \left. + \frac{(-0,067)^2}{72 - 7} + \frac{(0,025)^2}{72 - 8} + \frac{(-0,109)^2}{72 - 9} \right. \\ \left. + \frac{(-0,173)^2}{72 - 10} + \frac{(-0,166)^2}{72 - 11} + \frac{(-0,03)^2}{72 - 12} \right)$$

$$Q = 70(72)(0,003014757)$$

$$Q = 15,19437546$$

Tabel distribusi *Chi-Square* diperoleh :

$$X^2_{(0,05;12-1-0)} = X^2_{(0,05;11)} = 19,67513757$$

Kriteria pengujian :

Dengan menggunakan taraf pengujian signifikansi $\alpha = 0,05$

Menolak H_0 jika $Q > X^2_{(0,05;11)}$

Keputusan :

Tidak Menolak H_0 sebab

$$Q = 15,19437546 < X^2_{(0,05;11)} = 19,67513757$$

Artinya **residual model ARIMA (0,1,1) bersifat *white noise*.**

Selanjutnya akan dilakukan uji normalitas terhadap model ARIMA (0,1,1) dengan menggunakan histogram normality test yang terdapat pada (Lampiran 4) yang bertujuan untuk melihat nilai *p-value* beserta *Jarque Bera*. *Jarque Bera* adalah salah satu dari pengujian normalitas data melalui pendekatan grafik *skewness* dan *kurtosis*.

Berdasarkan (Lampiran 4) diperoleh nilai *skewness* sebesar 0,102833 dan nilai *kurtosis* sebesar 3,860595. Nilai tersebut akan digunakan untuk melakukan perhitungan nilai uji statistik terhadap rumus *Jarque Bera*.

Hipotesis :

H_0 : residual berdistribusi normal

H_1 : residual tidak berdistribusi normal

Statistik Uji :

$$JB = n \left(\frac{S^2}{6} + \frac{(k-3)^2}{24} \right)$$

$$JB = 70 \left(\frac{(0,10283)^2}{6} + \frac{(0,8606)^2}{24} \right)$$

$$JB = 2,316145$$

Tabel distribusi *Chi-Square* diperoleh :

$$x^2_{(0,05;11)} = 19,67513757$$

Kriteria pengujian :

Dengan menggunakan taraf pengujian signifikansi $\alpha = 0,05$

Menolak H_0 jika $JB > x^2_{(0,05;11)}$

Keputusan

Tidak menolak H_0 sebab

$$JB = 2,316145 < x^2_{(0,05;11)} = 19,67513757$$

artinya **residual model ARIMA (0,1,1) berdistribusi normal.**

Dengan melakukan perhitungan yang sama yaitu uji *white noise* dan uji normalitas *Jarque Bera* juga diterapkan terhadap model ARIMA yang telah signifikan. Hasil dari uji *white noise* dan uji normalitas *Jarque Bera* disajikan dalam Tabel 4.5. Berdasarkan Tabel 4.9, model ARIMA (0,1,1) merupakan model terbaik, hal ini dikarenakan model ARIMA (0,1,1) memenuhi kriteri uji signifikansi , uji *white noise*, dan uji normalitas.

Tabel 4.5 Uji Signifikansi, Uji White Noise, Uji Normalitas

Model	Uji Signifikan	Uji White Noise	Uji Normalitas
ARIMA (1,1,0)	Signifikan	Tidak White Noise	Normal
ARIMA (0,1,1)	Signifikan	White Noise	Normal
ARIMA (0,1,3)	Signifikan	Tidak White Noise	Normal
ARIMA (1,1,3)	Signifikan	Tidak White Noise	Normal

4.5 Uji Heterokedastisitas

Setelah mendapatkan model ARIMA terbaik melalui proses *overfitting* maka selanjutnya dilakukan uji Heterokedastisitas terhadap model ARIMA (0,1,1). Dalam proses pengujian heterokedastisitas dilakukan dengan menggunakan uji *White*, sehingga diperoleh :

Hipotesis :

$H_0 = \rho_1 = \rho_2 = \dots = \rho_{12} = 0$ (bersifat heterokedastisitas)

H_1 : minimal ada satu $\rho_i \neq 0$, dengan $i = 1,2,3,\dots,16$ (tidak bersifat heterokedastisitas)

Statistik uji

Untuk $k=16$, maka :

$$\begin{aligned}
 x^2 &= nR^2 \\
 &= 70(0,793367) \\
 &= 55,53569
 \end{aligned}$$

Tabel distribusi *Chi-Square* diperoleh :

$$x^2_{(0,05;3)} = 7,814727903$$

Kriteria pengujian :

Dengan menggunakan taraf pengujian signifikansi $\alpha = 0,05$

Menolak H_0 jika $x^2 > x^2_{(\alpha,(m))}$

Keputusan

Tidak Menolak H_0 sebab

$$x^2 = 55,53569 > X^2_{(0,05;3)} = 7,814727903$$

Artinya **residual kuadrat model ARIMA (0,1,1) terdapat heterokedastisitas.**

4.6 Identifikasi Model ARCH-GARCH, dan EGARCH

Terdapat unsur heterokedastisitas terhadap model ARIMA (0,1,1) maka diperlukan model ARCH-GARCH, dan EGARCH, hal ini bertujuan untuk mengatasi unsur heterokedastisitas. Model ARCH-GARCH dapat dibentuk melalui plot ACF dan PACF dari residual kuadrat yang dapat dilihat pada (Lampiran 5). Berdasarkan plot ACF dan PACF maka akan dihasilkan dugaan model *varian* sementara.

Berdasarkan pada (Lampiran 5) tidak terdapat lag yang keluar dari batas plot ACF dan PACF, sehingga akan dilakukan pengambilan dugaan model ARCH (1) sesuai dengan persamaan

(16) dengan menggunakan model *mean* terbaik yaitu ARIMA (0,1,1) adalah sebagai berikut :

$$(1 - \phi_p B - \dots - \phi_p B^p)Z_t = (1 - \theta_q B - \dots - \theta_q B^q)\varepsilon_t$$

$$(1 - \phi_0 B^0)Z_t = (1 - \theta_1 B)\varepsilon_t$$

$$Z_t(1) - \phi_0 B^0(Z_t) = \varepsilon_t(1) - \theta_1 B(\varepsilon_t)$$

$$Z_t = \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

Bentuk Umum model ARCH

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

Setelah memperoleh dugaan model sementara, maka langkah selanjutnya adalah melakukan estimasi parameter terhadap model ARCH (1) dengan bantuan *software Eviews*. Estimasi parameter bertujuan untuk uji signifikansi terhadap dugaan sementara model *varian*.

Tabel 4.6 Estimasi Parameter Model ARCH (1)

Uji Signifikansi Model ARCH (1)				
Parameter	Koefisien	SE	t-stat	p-value
α_0	0,034388	0,007242	4,74809	0
α_1	0,142105	0,228543	0,621786	0,5341

Berdasarkan Tabel 4.6 akan dilakukan uji signifikansi parameter pada Model ARCH (1) dengan menggunakan uji-t yang bertujuan untuk melihat kecocokan data yang ada. Hipotesis yang diberikan adalah, sebagai berikut :

1. Uji Signifikansi Parameter α_0

$H_0 : \widehat{\alpha}_0 = 0$ (parameter model tidak signifikan)

$H_1 : \widehat{\alpha}_0 \neq 0$ ((parameter model signifikan)

Statistik Uji

$$t_{hitung} = \frac{\widehat{\alpha}_0}{st. dev (\alpha_0)} = \frac{0,034388}{0,007242} = 4,74809$$

$$t_{tabel} = t_{(0,025;70)} = 1,994$$

Kriteria Pengujian

Taraf signifikan $\alpha = 0,05$

Tolak H_0 jika $|t_{hitung}| > t_{tabel}$

Keputusan

Tolak H_0 sebab $|t_{hitung}| = 4,74809 > t_{tabel} = 1,994$

Yang berarti **parameter α_0 signifikan** .

2. Uji Signifikansi Parameter α_1

$H_0 : \widehat{\alpha}_0 = 0$ (parameter model tidak signifikan)

$H_1 : \widehat{\alpha}_0 \neq 0$ ((parameter model signifikan)

Statistik Uji

$$t_{hitung} = \frac{\widehat{\alpha}_1}{st. dev (\alpha_1)} = \frac{0,142105}{0,228543} = 0,621786$$

$$t_{tabel} = t_{(0,025;70)} = 1,994$$

Kriteria Pengujian

Taraf signifikan $\alpha = 0,05$

Tolak H_0 jika $|t_{hitung}| > t_{tabel}$

Keputusan

Tolak H_0 sebab $|t_{hitung}| = 0,621786 < t_{tabel} = 1,994$

Yang berarti **parameter α_1 tidak signifikan** .

Tabel 4.6 dan uji signifikansi parameter model ARCH (1) menunjukkan bahwa model ARCH (1) tidak memenuhi uji signifikansi, sehingga dilakukan tahapan *overfitting* untuk melakukan uji signifikansi terhadap model *varian* yang lain. Bentuk umum dari model *varian* yang lain dengan menggunakan model ARIMA (0,1,1) yaitu :

1. Model GARCH

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon^2_{t-1} + \alpha_2 \varepsilon^2_{t-2} + \dots + \alpha_p \varepsilon^2_{t-p} + \beta_1 \sigma^2_{t-1} + \beta_2 \sigma^2_{t-2} + \dots + \beta_q \sigma^2_{t-q}$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon^2_{t-i} + \sum_{j=1}^q \beta_j \sigma^2_{t-j}$$

2. Model EGARCH

$$\log(\sigma_t^2) = \alpha_0 + \sum_{i=1}^p \beta_i \log(\hat{\sigma}^2_{t-i}) + \sum_{i=1}^q \alpha_j \left(\frac{|\varepsilon_{t-j}|}{\hat{\sigma}_{t-j}} + \sqrt{\frac{2}{\pi}} \right) + \xi \left(\frac{\varepsilon_{t-1}}{\hat{\sigma}_{t-1}} \right)$$

Berikut Tabel 4.7 yang memuat hasil estimasi parameter dari model *varian* yang lain.

Tabel 4.7 Estimasi Parameter *Overfitting* Model Varian

ARCH (1)	Parameter	Koefisien	SE	t-stat	p-value
	α_0	0,034388	0,007242	4,74809	0
	α_1	0,142105	0,228543	0,621786	0,5341
GARCH (1,1)	Parameter	Koefisien	SE	t-stat	p-value
	α_0	0,000219	0,001524	0,143872	0,8856
	α_1	-0,157427	0,10006	-1,57332	0,1156
	β_1	1,160759	0,173867	6,676147	0
GARCH (2,2)	Parameter	Koefisien	SE	t-stat	p-value
	α_0	7,76E-05	0,002051	0,037828	0,9698
	α_1	-0,238396	0,136457	-1,747035	0,0806
	α_2	0,017979	0,185027	0,097171	0,9226
	β_1	0,745935	0,880972	0,846718	0,3972
	β_2	0,498021	0,982617	0,506832	0,6123
EGARCH (1,1)	Parameter	Koefisien	SE	t-stat	p-value
	α_0	-1,497037	0,55835	-2,68118	0,0073
	α_1	-1,033455	0,323291	-3,196669	0,0014
	β_1	-0,288627	0,11662	-2,47495	0,0133
	ξ	0,390803	0,175934	2,221298	0,0263

Tahap *overfitting* dilakukan dengan melakukan perbandingan dari beberapa model yang telah menjadi dugaan model dengan melihat syarat yaitu parameter yang signifikan dan memiliki nilai AIC dan SBC yang sangat kecil. Hasil dari tahap *overfitting* adalah model *varian* yang terbaik serta dapat mewardahi sifat volatilitas. Berikut adalah hasil *overfitting* yang disajikan dalam Tabel 4.8.

Tabel 4.8. Hasil *Overfitting*

Model	Uji Sigifikansi	AIC	SBC
ARCH (1)	Tidak Signifikan	-0,63179	-0,535426
GARCH (1,1)	Tidak Signifikan	-0,948374	-0,819889
GARCH (2,2)	Tidak Signifikan	-0,917035	-0,724307
EGARCH (1,1)	Signifikan	-0,808315	-0,647709

Berdasarkan Tabel 4.8 diperoleh model *varian* terbaik yaitu model EGARCH (1,1), karena model EGARCH (1,1) telah memenuhi uji signifikansi parameter, selain itu model EGARCH (1,1) menunjukkan bahwa terdapat *lefferage effect* atau efek asimetris yang tidak sama dengan nol atau dapat dituliskan $\xi \neq 0$ pada data *return* harga penutupan saham PT. Indofarma Tbk (INAF.JK) dan memiliki nilai AIC dan SBC sebesar -0,808315 dan -0,647709 . Berdasarkan persamaan (2.24) diperoleh model EGARCH (1,1) dengan model *mean* terbaik yaitu model ARIMA (0,1,1) adalah sebagai berikut :

$$(1 - \phi_p B - \dots - \phi_p B^p) Z_t = (1 - \theta_q B - \dots - \theta_q B^q) \varepsilon_t$$

$$(1 - \phi_0 B^0) Z_t = (1 - \theta_1 B) \varepsilon_t$$

$$Z_t(1) - \phi_0 B^0(Z_t) = \varepsilon_t(1) - \theta_1 B(\varepsilon_t)$$

$$Z_t = \varepsilon_t - \theta_1 \varepsilon_{t-1}$$

$$Z_t = \varepsilon_t - (-0,97336) \varepsilon_{t-1}$$

Sehingga dari proses estimasi parameter menggunakan *software Eviews* dapat terbentuk model EGARCH (1,1) adalah

$$\log(\sigma_t^2) = \alpha_0 + \sum_{i=1}^p \beta_i \log(\hat{\sigma}_{t-i}^2) + \sum_{i=1}^q \alpha_j \left(\frac{|\varepsilon_{t-j}|}{\hat{\sigma}_{t-j}^2} + \sqrt{\frac{2}{\pi}} \right) + \xi \left(\frac{\varepsilon_{t-1}}{\hat{\sigma}_{t-1}^2} \right)$$

$$\log(\sigma_t^2) = -1,497037 - 0,288627 \log(\hat{\sigma}_{t-i}^2) - 1,033455 \left(\frac{|\varepsilon_{t-j}|}{\hat{\sigma}_{t-j}} + \sqrt{\frac{2}{\pi}} \right) + 0,390803 \left(\frac{\varepsilon_{t-1}}{\hat{\sigma}_{t-1}} \right)$$

4.7 Peramalan Volatilitas

Hasil peramalan volatilitas dari *return* penutupan harga saham untuk periode 01 Oktober 2020 – 01 September 2021 dengan menggunakan model EGARCH (1,1) ditunjukkan pada Tabel 4.9.

Tabel 4.9 Hasil Peramalan Volatilitas

No.	Bulan	Hasil Peramalan
1	01 Oktober 2020	0.06608
2	01 November 2020	0.07555
3	01 Desember 2020	0.08405
4	01 Januari 2021	0.09148
5	01 Februari 2021	0.09787
6	01 Maret 2021	0.10327
7	01 April 2021	0.10778
8	01 Mei 2021	0.11150
9	01 Juni 2021	0.11456
10	01 Juli 2021	0.11706
11	01 Agustus 2021	0.11908
12	01 September 2021	0.12072

Berdasarkan hasil peramalan yang disajikan dalam Tabel 4.9 diketahui bahwa nilai volatilitas pada periode pertama sebesar 0.06608 yang menunjukkan bahwa volatilitas *return* mengalami kenaikan dari bulan 01 Oktober 2020 sampai dengan 01 September 2021.

4.8 Analisis

Data harga saham penutupan PT. Indofarma Tbk. (INAF) yang telah diolah menjadi data *return* dengan menggunakan perhitungan log *return*, dimana *return* merupakan keuntungan yang diperoleh dari PT.Indofarma Tbk. Data *return* harga penutupan saham PT. Indofarma Tbk telah stasioner terhadap varian, hal ini ditunjukkan dengan nilai *rounded value* sebesar 0,50 atau sama dengan 1, selain memenuhi stasioner terhadap varian, *return* harga penutupan saha, PT. Indofarma Tbk juga memenuhi stasioneritas terhadap *mean*, hal ini ditunjukkan dengan plot *trend analysis* yang memiliki pola teratur disekitaran nilai tengah serta garis *trend* sudah mendekati sumbu horizontal. Identifikasi plot ACF dan PACF dari *return* harga penutupan harga saham PT. Indofarma Tbk. bertujuan untuk pendugaan sementara model ARIMA, model ARIMA yang memenuhi uji signifikansi dan uji diagnostik adalah ARIMA ([0],[1],[1]), akan tetapi model ARIMA (0,1,1) memiliki unsur heterokedastisitas setelah dilakukan uji *White*, sehingga dilakukan identifikasi model varian yaitu ARCH-GARCH, dan EGARCH. Model ARCH dan GARCH tidak memenuhi uji signifikansi terhadap model ARIMA (0,1,1), hal ini disebabkan terdapat efek asimetris volatilitas yaitu ξ yang dapat dilihat pada Tabel 4.7 pada model ARIMA (0,1,1) sehingga model yang tepat dan memenuhi uji signifikansi untuk mengatasi heterokedastisitas serta efek asimetris adalah model EGARCH (1,1). Model EGARCH (1,1) digunakan untuk meramalkan volatilitas pada *return* harga penutupan saham PT. Indofarma Tbk. (INAF) selama dua belas bulan kedepan , dan berdasarkan hasil peramalan yang disajikan dalam Tabel 4.9 didapatkan hasil peramalan volatilitas yang meningkat pada periode tersebut.

BAB V

KESIMPULAN DAN SARAN

Pada bab ini dibahas mengenai kesimpulan dari pembahasan dan analisis yang telah dilakukan sebelumnya, dan juga saran yang dapat diberikan oleh penulis kepada pembaca untuk pengembangan Tugas Akhir selanjutnya.

5.1. Kesimpulan

Berdasarkan pembahasan dan juga analisis yang telah dilakukan, diperoleh kesimpulan sebagai berikut :

1. Plot data *return* harga penutupan saham PT. Indofarma Tbk (INAF.JK) menunjukkan pergerakan data *return* yang berfluktuasi dari waktu ke waktu, sehingga data *return* PT. Indofarma Tbk (INAF.JK) mengalami peristiwa *volatility clustering* yang ditandai dengan data cenderung naik dan turun secara drastis.
2. Hasil pengolahan data *return* penutupan harga saham PT. Indofarma Tbk. (INAF) dengan menggunakan model *mean* dan varian diperoleh model terbaik yaitu :

$$Z_t = \varepsilon_t - (-0,97336) \varepsilon_{t-1}$$

$$\log(\sigma_t^2) = -1,497037 - 0,288627 \log(\hat{\sigma}_{t-1}^2) - 1,033455 \left(\frac{|\varepsilon_{t-1}|}{\hat{\sigma}_{t-1}^2} + \sqrt{\frac{2}{\pi}} \right) + 0,390803 \left(\frac{\varepsilon_{t-1}}{\hat{\sigma}_{t-1}^2} \right)$$

3. Penerapan model EGARCH dengan menggunakan model terbaik yaitu model EGARCH (1,1) menunjukkan bahwa terdapat *lefferage effect* atau efek asimetris yang tidak sama dengan nol atau dapat dituliskan $\xi \neq 0$ pada data *return* harga penutupan saham PT. Indofarma Tbk

(INAF.JK), oleh karena itu model EGARCH (1,1) digunakan untuk meramalkan volatilitas *return* harga saham PT Indofarma Tbk (INAF.JK), sehingga diperoleh hasil peramalan volatilitas pada data *return* harga penutupan saham PT. Indofarma Tbk. (INAF) mengalami kenaikan pada satu tahun kedepan.

5.2. Saran

Pada Tugas Akhir ini penelitian hanya dilakukan dengan model asimetris EGARCH, dalam penelitian selanjutnya sebaiknya dapat digunakan model asimetris yang lain seperti TGARCH, GJR-GARCH, dan sebagainya.

DAFTAR PUSTAKA

- [1] P. B. E. Indonesia, “Belajar Pasar Modal.” <https://www.idx.co.id/investor/belajar-pasar-modal/> (accessed Sep. 04, 2021).
- [2] Mackinlay, A.C. (1997). “Finance” . Vol. 35, no. 1, pp. 13–39.
- [3] Natasha, Azaria. (2015) . “Analisis Volatilitas Saham Perusahaan Dengan Metode EGARCH”. Tugas Akhir. ITS.
- [4] Dadan, Megawati, *dkk.* (2020). “Pemodelan Dan Peramalan Volatilitas Saham Menggunakan Model Integrated Generalized Autoregressive Conditional Heteroscedasticity” .*Bimaster :Buletin Ilmiah Matematika, Statistika dan Terapannya*, vol. 9, no. 1, pp. 145–152.
- [5] Siti, I Wayan, *dkk.* (2019). “Peramalan Volatilitas Saham Menggunakan Model Exponential Garch Dan Threshold Garch,” *E-Jurnal Mat.*, vol. 8, no. 4, p. 309, doi: 10.24843/mtk.2019.v08.i04.p270.
- [6] Abdul, Dominicc, *dkk.* (2019) . “Modeling and Forecasting of Ghana’s Inflation Volatility” . *American Journal of Industrial and Business Management*, vol. 09, no. 04, pp. 930–949, 2019, doi: 10.4236/ajibm,94064.
- [7] Inlistya, A. (2019) . “Perbandingan Metode Antara GJR-GARCH Dan EGARCH Pada Analisis Volatilitas INDEKS Saham Syariah Indonesia”. Tugas Akhir. ITS
- [8] Ellen, M. 15 September 2016. “Mengenal LQ 45,” <https://finance.detik.com/bursa-dan-valas/d-3298411/mengenal-lq-45> (accessed Jan. 31, 2022).
- [9] Tahir, S. “Catat! Ini Dia 5 Saham Tercuan Sejak Pandemi

Covid-19”

<https://www.cnbcindonesia.com/market/20200830233429-17-183132/catat-ini-dia-5-saham-tercuan-sejak-pandemi-covid-19>.

- [10] Buckley, Petter, *dkk.* (2018) . “A retrospective and agenda for future research on Chinese outward foreign direct investment,” *Journal of International Business Studies*, vol. 49, no. 1, pp. 4–23, doi: 10.1057/s41267-017-0129-1.
- [11] Box, Gwilym, *dkk.* *Time Series Analysis Forecasting and Control*.
- [12] Wijayanto, R. (2019). “Laporan Box Cox”. Tugas Kuliah ITS.
- [13] Wei, W. (1991). “Time Series Analysis: Univariate and Multivariate Methods”. *Technometrics*, vol. 33, no. 1. p. 108, doi: 10.2307/1269015.
- [14] Pramujati, W. (2020). “Aplikasi Model Binomial Negatif Generalized Seasonal Autoregressive Integrated Moving Average (GSARIMA) Pada Peramalan Jumlah Penderita Penyakit Infeksi Saluran Pernapasan Akut (ISPA)”. Tugas Akhir. ITS.
- [15] Tsay, R. (2010). *Analysis of financial time series*.
- [16] Engle, Victor. (1993). “On the Relation between the Expected Value and the Volatility of the Nominal Excess Return on Stocks,” *J. Finance*, vol. 4, no. 5, pp. 1749–1778, doi: 10.1111/j.1540-6261.1993.tb05127.x.
- [17] David, Buckley. (2004) .“Model selection and model averaging in phylogenetics: Advantages of akaike information criterion and bayesian approaches over likelihood ratio tests,” *Syst. Biol.*, vol. 53, no. 5, pp. 793–808, doi: 10.1080/10635150490522304.

LAMPIRAN 1**Lampiran 1. Data Penutupan Harga Saham 2014-2021**

Date	Close
01/10/2014	1670
01/11/2014	2850
01/12/2014	3550
01/01/2015	2870
01/02/2015	3290
01/03/2015	2890
01/04/2015	2550
01/05/2015	2480
01/06/2015	1960
01/07/2015	1950
01/08/2015	1490
01/09/2015	1270
01/10/2015	1410
01/11/2015	1790
01/12/2015	1680
01/01/2016	2530
01/02/2016	3080
01/03/2016	4060
01/04/2016	7850

Date	Close
01/05/2016	9550
01/06/2016	12200
01/07/2016	16200
01/08/2016	18850
01/09/2016	24900
01/10/2016	25600
01/11/2016	44000
01/12/2016	46800
01/01/2017	23400
01/02/2017	21000
01/03/2017	37800
01/04/2017	32400
01/05/2017	35300
01/06/2017	29200
01/07/2017	26900
01/08/2017	25300
01/09/2017	23600
01/10/2017	26400
01/11/2017	25300
01/12/2017	59000
01/01/2018	55000
01/02/2018	44100
01/03/2018	57000
01/04/2018	57000
01/05/2018	38100
01/06/2018	39000
01/07/2018	31000

Date	Close
01/08/2018	30000
01/09/2018	59000
01/10/2018	39000
01/11/2018	44000
01/12/2018	65000
01/01/2019	49900
01/02/2019	47500
01/03/2019	54750
01/04/2019	39000
01/05/2019	35000
01/06/2019	22800
01/07/2019	22000
01/08/2019	20000
01/09/2019	15050
01/10/2019	11150
01/11/2019	6800
01/12/2019	8700
01/01/2020	8400
01/02/2020	4480
01/03/2020	10800
01/04/2020	11100
01/05/2020	10100
01/06/2020	9850
01/07/2020	22800
01/08/2020	30600
01/09/2020	28600

Date	Close
01/10/2020	31400
01/11/2020	31600
01/12/2020	40300
01/01/2021	30000
01/02/2021	32900
01/03/2021	24600
01/04/2021	22900
01/05/2021	22800
01/06/2021	31100
01/07/2021	26500
01/08/2021	23400
01/09/2021	22800

Lampiran 2. Data *Return* Penutupan Harga Saham 2014-2021

Date	Close	Return
01/10/2014	1670	
01/11/2014	2850	0,534495368
01/12/2014	3550	0,219628609
01/01/2015	2870	-0,212635574
01/02/2015	3290	0,136575535
01/03/2015	2890	-0,129631063
01/04/2015	2550	-0,125163143
01/05/2015	2480	-0,027834799
01/06/2015	1960	-0,235314087
01/07/2015	1950	-0,005115101
01/08/2015	1490	-0,269053253
01/09/2015	1270	-0,159759219
01/10/2015	1410	0,104572804
01/11/2015	1790	0,238625915
01/12/2015	1680	-0,063421826
01/01/2016	2530	0,409425509
01/02/2016	3080	0,196710294
01/03/2016	4060	0,276253377
01/04/2016	7850	0,659330558
01/05/2016	9550	0,196027623
01/06/2016	12200	0,244894797
01/07/2016	16200	0,28357529
01/08/2016	18850	0,151501672
01/09/2016	24900	0,27835489

Date	Close	Return
01/10/2016	25600	0,027724548
01/11/2016	44000	0,541597282
01/12/2016	46800	0,061693569
01/01/2017	23400	-0,693147181
01/02/2017	21000	-0,108213585
01/03/2017	37800	0,587786665
01/04/2017	32400	-0,15415068
01/05/2017	35300	0,085724541
01/06/2017	29200	-0,189714255
01/07/2017	26900	-0,082042423
01/08/2017	25300	-0,061321891
01/09/2017	23600	-0,069557684
01/10/2017	26400	0,112117298
01/11/2017	25300	-0,042559614
01/12/2017	59000	0,846733048
01/01/2018	55000	-0,070204259
01/02/2018	44100	-0,220873403
01/03/2018	57000	0,256591485
01/04/2018	57000	0
01/05/2018	38100	-0,402836986
01/06/2018	39000	0,023347364
01/07/2018	31000	-0,229574442
01/08/2018	30000	-0,032789823
01/09/2018	59000	0,676340062
01/10/2018	39000	-0,413975798
01/11/2018	44000	0,120627988
01/12/2018	65000	0,390197636
01/01/2019	49900	-0,264366267

Date	Close	Log Return
01/02/2019	47500	-0,049291292
01/03/2019	54750	0,142047658
01/04/2019	39000	-0,339215723
01/05/2019	35000	-0,108213585
01/06/2019	22800	-0,428587526
01/07/2019	22000	-0,035718083
01/08/2019	20000	-0,09531018
01/09/2019	15050	-0,284354282
01/10/2019	11150	-0,299938493
01/11/2019	6800	-0,494516886
01/12/2019	8700	0,246400413
01/01/2020	8400	-0,03509132
01/02/2020	4480	-0,628608659
01/03/2020	10800	0,879923088
01/04/2020	11100	0,027398974
01/05/2020	10100	-0,094409684
01/06/2020	9850	-0,025063969
01/07/2020	22800	0,839289081
01/08/2020	30600	0,294239473
01/09/2020	28600	-0,067593291
01/10/2020	31400	0,093401175
01/11/2020	31600	0,006349228
01/12/2020	40300	0,243194348
01/01/2021	30000	-0,295154087
01/02/2021	32900	0,092275276
01/03/2021	24600	-0,290726215
01/04/2021	22900	-0,071609532
01/05/2021	22800	-0,004376375

Date	Close	Return
01/06/2021	31100	0,310447283
01/07/2021	26500	-0,160063086
01/08/2021	23400	-0,124408711
01/09/2021	22800	-0,025975486

Lampiran 3. Estimasi Parameter *Overfitting* Model ARIMA

1. Model ARIMA ([1,2],1,[1,3])

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 12/19/21 Time: 21:40

Sample: 2014M12 2020M09

Included observations: 70

Convergence achieved after 28 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.458272	0.212545	-2.156120	0.0348
AR(2)	-0.422842	0.227927	-1.855167	0.0681
MA(1)	-0.472575	0.235828	-2.003896	0.0493
MA(3)	0.080079	0.189404	0.422791	0.6738
SIGMASQ	0.024478	0.003775	6.484981	0.0000
R-squared	0.532101	Mean dependent var		-0.003902
Adjusted R-squared	0.503307	S.D. dependent var		0.230374
S.E. of regression	0.162359	Akaike info criterion		-0.709588
Sum squared resid	1.713437	Schwarz criterion		-0.548981
Log likelihood	29.83558	Hannan-Quinn criter.		-0.645793
Durbin-Watson stat	1.956148			
Inverted AR Roots	-.23+.61i	-.23-.61i		
Inverted MA Roots	.40-.31i	.40+.31i	-.32	

2. Model ARIMA ([1,11],1,[1,3])

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 12/19/21 Time: 21:45

Sample: 2014M12 2020M09

Included observations: 70

Convergence achieved after 36 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.081447	0.165842	-0.491115	0.6250
AR(11)	-0.131593	0.113455	-1.159865	0.2503
MA(1)	-0.851202	0.109442	-7.777618	0.0000
MA(3)	0.282764	0.095399	2.963999	0.0042
SIGMASQ	0.025194	0.003622	6.955978	0.0000
R-squared	0.518411	Mean dependent var		-0.003902
Adjusted R-squared	0.488774	S.D. dependent var		0.230374
S.E. of regression	0.164718	Akaike info criterion		-0.678561
Sum squared resid	1.763572	Schwarz criterion		-0.517954
Log likelihood	28.74962	Hannan-Quinn criter.		-0.614766
Durbin-Watson stat	1.997239			
Inverted AR Roots	.79-.23i .11-.82i -.71-.45i	.79+.23i .11+.82i -.71+.45i	.54+.63i -.35+.76i -.84	.54-.63i -.35-.76i
Inverted MA Roots	.66-.42i	.66+.42i	-.46	

3. Model ARIMA ([2,11],1,[1,3])

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 12/19/21 Time: 21:51

Sample: 2014M12 2020M09

Included observations: 70

Convergence achieved after 25 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	-0.092014	0.161703	-0.569030	0.5713
AR(11)	-0.127697	0.118711	-1.075690	0.2860
MA(1)	-0.852832	0.142181	-5.998212	0.0000
MA(3)	0.282925	0.097845	2.891561	0.0052
SIGMASQ	0.025135	0.003646	6.894161	0.0000
R-squared	0.519542	Mean dependent var		-0.003902
Adjusted R-squared	0.489975	S.D. dependent var		0.230374
S.E. of regression	0.164524	Akaike info criterion		-0.680804
Sum squared resid	1.759430	Schwarz criterion		-0.520197
Log likelihood	28.82813	Hannan-Quinn criter.		-0.617009
Durbin-Watson stat	2.128984			
Inverted AR Roots	.79+.24i	.79-.24i	.54-.63i	.54+.63i
	.12+.83i	.12-.83i	-.34+.76i	-.34-.76i
	-.69+.45i	-.69-.45i	-.82	
Inverted MA Roots	.66-.42i	.66+.42i	-.46	

4. Model ARIMA (1,1,1)

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 10/26/21 Time: 07:36

Sample: 2014M12 2020M09

Included observations: 70

Convergence achieved after 45 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.019147	0.151597	-0.126302	0.8999
MA(1)	-0.961431	0.041940	-22.92370	0.0000
SIGMASQ	0.026668	0.004123	6.467447	0.0000
R-squared	0.490223	Mean dependent var		-0.003902
Adjusted R-squared	0.475006	S.D. dependent var		0.230374
S.E. of regression	0.166921	Akaike info criterion		-0.663329
Sum squared resid	1.866793	Schwarz criterion		-0.566965
Log likelihood	26.21652	Hannan-Quinn criter.		-0.625052
Durbin-Watson stat	1.984926			
Inverted AR Roots	-.02			
Inverted MA Roots	.96			

5. Model ARIMA (1,1,3)

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 10/26/21 Time: 07:39

Sample: 2014M12 2020M09

Included observations: 70

Convergence achieved after 10 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.469020	0.106150	-4.418465	0.0000
MA(3)	0.382844	0.109103	3.509010	0.0008
SIGMASQ	0.034983	0.004937	7.086490	0.0000
R-squared	0.331284	Mean dependent var		-0.003902
Adjusted R-squared	0.311322	S.D. dependent var		0.230374
S.E. of regression	0.191180	Akaike info criterion		-0.420104
Sum squared resid	2.448828	Schwarz criterion		-0.323740
Log likelihood	17.70365	Hannan-Quinn criter.		-0.381827
Durbin-Watson stat	2.337249			
Inverted AR Roots	-.47			
Inverted MA Roots	.36+.63i	.36-.63i	-.73	

6. Model ARIMA (2,1,1)

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 10/26/21 Time: 07:41

Sample: 2014M12 2020M09

Included observations: 70

Convergence achieved after 70 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	-0.086813	0.143888	-0.603340	0.5483
MA(1)	-0.946791	0.039984	-23.67954	0.0000
SIGMASQ	0.026579	0.004399	6.042443	0.0000
R-squared	0.491940	Mean dependent var		-0.003902
Adjusted R-squared	0.476774	S.D. dependent var		0.230374
S.E. of regression	0.166640	Akaike info criterion		-0.669313
Sum squared resid	1.860507	Schwarz criterion		-0.572949
Log likelihood	26.42596	Hannan-Quinn criter.		-0.631036
Durbin-Watson stat	1.993434			
Inverted AR Roots	-.00+.29i	-.00-.29i		
Inverted MA Roots	.95			

7. Model ARIMA (2,1,3)

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 10/26/21 Time: 07:43

Sample: 2014M12 2020M09

Included observations: 70

Convergence achieved after 9 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	-0.089314	0.139049	-0.642319	0.5229
MA(3)	0.354619	0.114409	3.099582	0.0028
SIGMASQ	0.044708	0.007608	5.876271	0.0000
R-squared	0.145395	Mean dependent var		-0.003902
Adjusted R-squared	0.119884	S.D. dependent var		0.230374
S.E. of regression	0.216124	Akaike info criterion		-0.178024
Sum squared resid	3.129549	Schwarz criterion		-0.081660
Log likelihood	9.230838	Hannan-Quinn criter.		-0.139747
Durbin-Watson stat	3.018078			
Inverted AR Roots	-.00+.30i	-.00-.30i		
Inverted MA Roots	.35-.61i	.35+.61i	-.71	

8. Model ARIMA (12,1,1)

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 11/20/21 Time: 05:25

Sample: 2014M11 2020M08

Included observations: 70

Convergence achieved after 46 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(12)	0.017479	0.195611	0.089356	0.9291
MA(1)	-0.966608	0.036775	-26.28417	0.0000
SIGMASQ	0.026640	0.004327	6.156693	0.0000
R-squared	0.490763	Mean dependent var		-0.003902
Adjusted R-squared	0.475561	S.D. dependent var		0.230374
S.E. of regression	0.166833	Akaike info criterion		-0.663232
Sum squared resid	1.864818	Schwarz criterion		-0.566868
Log likelihood	26.21312	Hannan-Quinn criter.		-0.624955
Durbin-Watson stat	2.010209			
Inverted AR Roots	.71	.62+.36i	.62-.36i	.36-.62i
	.36+.62i	.00-.71i	-.00+.71i	-.36+.62i
	-.36-.62i	-.62+.36i	-.62-.36i	-.71
Inverted MA Roots	.97			

9. Model ARIMA (12,1,3)

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 11/20/21 Time: 05:25

Sample: 2014M11 2020M08

Included observations: 70

Convergence achieved after 46 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(12)	0.017479	0.195611	0.089356	0.9291
MA(1)	-0.966608	0.036775	-26.28417	0.0000
SIGMASQ	0.026640	0.004327	6.156693	0.0000
R-squared	0.490763	Mean dependent var		-0.003902
Adjusted R-squared	0.475561	S.D. dependent var		0.230374
S.E. of regression	0.166833	Akaike info criterion		-0.663232
Sum squared resid	1.864818	Schwarz criterion		-0.566868
Log likelihood	26.21312	Hannan-Quinn criter.		-0.624955
Durbin-Watson stat	2.010209			
Inverted AR Roots	.71	.62+.36i	.62-.36i	.36-.62i
	.36+.62i	.00-.71i	-.00+.71i	-.36+.62i
	-.36-.62i	-.62+.36i	-.62-.36i	-.71
Inverted MA Roots	.97			

10. Model ARIMA (1,1,0)

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 10/26/21 Time: 07:02

Sample: 2014M12 2020M09

Included observations: 70

Convergence achieved after 8 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.468707	0.096534	-4.855336	0.0000
SIGMASQ	0.040656	0.005607	7.251026	0.0000
R-squared	0.222852	Mean dependent var		-0.003902
Adjusted R-squared	0.211423	S.D. dependent var		0.230374
S.E. of regression	0.204576	Akaike info criterion		-0.304051
Sum squared resid	2.845904	Schwarz criterion		-0.239808
Log likelihood	12.64178	Hannan-Quinn criter.		-0.278533
Durbin-Watson stat	2.515515			
Inverted AR Roots	-0.47			

11. Model ARIMA (2,1,0)

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 10/26/21 Time: 07:09

Sample: 2014M12 2020M09

Included observations: 70

Convergence achieved after 9 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	-0.218953	0.131736	-1.662067	0.1011
SIGMASQ	0.049775	0.007603	6.547035	0.0000
R-squared	0.048535	Mean dependent var		-0.003902
Adjusted R-squared	0.034543	S.D. dependent var		0.230374
S.E. of regression	0.226360	Akaike info criterion		-0.103820
Sum squared resid	3.484246	Schwarz criterion		-0.039577
Log likelihood	5.633700	Hannan-Quinn criter.		-0.078302
Durbin-Watson stat	3.089743			
Inverted AR Roots	-0.0+ .47i	-0.0- .47i		

12. Model ARIMA (12,1,0)

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 11/19/21 Time: 21:54

Sample: 2014M11 2020M08

Included observations: 70

Convergence achieved after 10 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(12)	0.050701	0.149961	0.338093	0.7363
SIGMASQ	0.052202	0.007704	6.776270	0.0000
R-squared	0.002141	Mean dependent var		-0.003902
Adjusted R-squared	-0.012534	S.D. dependent var		0.230374
S.E. of regression	0.231813	Akaike info criterion		-0.057173
Sum squared resid	3.654142	Schwarz criterion		0.007070
Log likelihood	4.001044	Hannan-Quinn criter.		-0.031655
Durbin-Watson stat	2.941374			
Inverted AR Roots	.78	.68+.39i	.68-.39i	.39+.68i
	.39-.68i	.00+.78i	-.00-.78i	-.39+.68i
	-.39-.68i	-.68-.39i	-.68+.39i	-.78

13. Model ARIMA (0,1,1)

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 10/26/21 Time: 07:19

Sample: 2014M12 2020M09

Included observations: 70

Convergence achieved after 42 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	-0.964700	0.036626	-26.33888	0.0000
SIGMASQ	0.026659	0.004104	6.495067	0.0000
R-squared	0.490409	Mean dependent var		-0.003902
Adjusted R-squared	0.482915	S.D. dependent var		0.230374
S.E. of regression	0.165659	Akaike info criterion		-0.691582
Sum squared resid	1.866114	Schwarz criterion		-0.627339
Log likelihood	26.20537	Hannan-Quinn criter.		-0.666064
Durbin-Watson stat	2.015356			
Inverted MA Roots	.96			

14. Model ARIMA (0,1,3)

Dependent Variable: D(TRANS1)

Method: ARMA Maximum Likelihood (OPG - BHHH)

Date: 10/26/21 Time: 07:20

Sample: 2014M12 2020M09

Included observations: 70

Convergence achieved after 5 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(3)	0.387541	0.106560	3.636853	0.0005
SIGMASQ	0.044959	0.007405	6.071582	0.0000
R-squared	0.140596	Mean dependent var		-0.003902
Adjusted R-squared	0.127957	S.D. dependent var		0.230374
S.E. of regression	0.215131	Akaike info criterion		-0.200012
Sum squared resid	3.147123	Schwarz criterion		-0.135769
Log likelihood	9.000424	Hannan-Quinn criter.		-0.174494
Durbin-Watson stat	2.927997			
Inverted MA Roots	.36+.63i	.36-.63i	-.73	

Lampiran 4. Correlogram Q – Statistik Uji *White Noise*





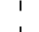
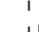
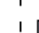

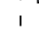
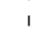


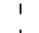
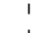


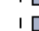

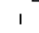





1. Model ARIMA (1,1,0)

Date: 11/20/21 Time: 08:54

Sample: 2014M10 2020M09

Included observations: 70

Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.273	-0.273	5.4625	
		2 -0.418	-0.533	18.421	0.000
		3 0.329	0.012	26.546	0.000
		4 -0.007	-0.133	26.550	0.000
		5 -0.053	0.132	26.770	0.000
		6 -0.019	-0.082	26.798	0.000
		7 -0.033	-0.017	26.886	0.000
		8 0.091	-0.005	27.562	0.000
		9 -0.014	0.026	27.579	0.001
		10 -0.111	-0.077	28.621	0.001
		11 -0.102	-0.275	29.503	0.001
		12 0.128	-0.110	30.927	0.001



















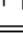
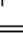




2. Model ARIMA (0,1,1)

Date: 11/20/21 Time: 08:56

Sample: 2014M10 2020M09

Included observations: 70

Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.021	-0.021	0.0333	
		2 -0.067	-0.068	0.3678	0.544
		3 0.336	0.335	8.8726	0.012
		4 0.040	0.048	8.9925	0.029
		5 0.038	0.092	9.1033	0.059
		6 -0.006	-0.127	9.1060	0.105
		7 -0.067	-0.103	9.4649	0.149
		8 0.025	-0.039	9.5138	0.218
		9 -0.109	-0.097	10.495	0.232
		10 -0.173	-0.138	13.019	0.162
		11 -0.166	-0.210	15.374	0.119
		12 -0.030	0.011	15.451	0.163

























3. Model ARIMA (0,1,3)

Date: 11/20/21 Time: 08:58

Sample: 2014M10 2020M09

Included observations: 70

Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.468	-0.468	15.994	
		2	-0.072	-0.373	16.383	0.000
		3	0.032	-0.281	16.461	0.000
		4	0.015	-0.214	16.478	0.001
		5	0.007	-0.154	16.482	0.002
		6	0.008	-0.094	16.487	0.006
		7	-0.021	-0.083	16.521	0.011
		8	0.089	0.083	17.162	0.016
		9	-0.075	0.065	17.629	0.024
		10	-0.041	-0.008	17.772	0.038
		11	-0.046	-0.173	17.951	0.056
		12	0.088	-0.156	18.626	0.068

























4. Model ARIMA (1,1,3)

Date: 11/20/21 Time: 09:00

Sample: 2014M10 2020M09


Included observations: 70

Q-statistic probabilities adjusted for 2 ARMA terms


Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.180	-0.180	2.3760	
		2	-0.376	-0.422	12.833	
		3	0.029	-0.181	12.894	0.000
		4	0.045	-0.200	13.051	0.001
		5	0.022	-0.100	13.088	0.004
		6	0.000	-0.086	13.088	0.011
		7	0.032	0.004	13.169	0.022
		8	0.074	0.110	13.617	0.034
		9	-0.085	0.016	14.220	0.047
		10	-0.129	-0.085	15.622	0.048
		11	-0.047	-0.200	15.813	0.071
		12	0.175	-0.027	18.484	0.047

Lampiran 5. Histogram Uji Normalitas


1. Model ARIMA (1,1,0)




2. Model ARIMA (0,1,1)



3. Model ARIMA (0,1,3)



4. Model ARIMA (1,1,3)



Lampiran 6. Heterokedastisitas

1. Model ARIMA (0,1,1)

EViews - [Equation: UNTITLED Workfile: PEMODELAN DENGAN EIEWS:Untitled\]

File	Edit	Object	View	Proc	Quick	Options	Add-ins	Window	Help
View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids

Heteroskedasticity Test: White

F-statistic	84.46921	Prob. F(3,66)	0.0000
Obs*R-squared	55.53572	Prob. Chi-Square(3)	0.0000
Scaled explained SS	73.28464	Prob. Chi-Square(3)	0.0000

Test Equation:

Dependent Variable: RESID*2

Method: Least Squares

Date: 01/04/22 Time: 16:18

Sample: 2014M12 2020M09

Included observations: 70

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.013391	0.002642	5.068335	0.0000
GRADF_01*2	0.000325	6.75E-05	4.815101	0.0000
GRADF_01*GRADF_02	2.20E-05	1.18E-05	1.870006	0.0659
GRADF_02*2	1.03E-05	9.97E-07	10.35001	0.0000

R-squared	0.793367	Mean dependent var	0.026659
Adjusted R-squared	0.783975	S.D. dependent var	0.044904
S.E. of regression	0.020871	Akaike info criterion	-4.845477
Sum squared resid	0.028749	Schwarz criterion	-4.716992
Log likelihood	173.5917	Hannan-Quinn criter.	-4.794442
F-statistic	84.46921	Durbin-Watson stat	2.337071
Prob(F-statistic)	0.000000		

2. Model ARIMA (1,1,0)

W | |

EViews - [Equation: UNTITLED] Workfile: PEMODELAN DENGAN EIEWS::Untitled]

File Edit Object View Proc Quick Options Add-ins Window Help

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Heteroskedasticity Test: White

F-statistic	88.08049	Prob. F(3,66)	0.0000
Obs*R-squared	56.01024	Prob. Chi-Square(3)	0.0000
Scaled explained SS	79.84648	Prob. Chi-Square(3)	0.0000

Test Equation:
 Dependent Variable: RESID^2
 Method: Least Squares
 Date: 01/04/22 Time: 16:27
 Sample: 2014M12 2020M09
 Included observations: 70

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.018733	0.004132	4.533670	0.0000
GRADF_01^2	0.004037	0.001503	2.685846	0.0091
GRADF_01*GRADF_02	0.000109	5.18E-05	2.103941	0.0392
GRADF_02^2	3.39E-05	4.79E-06	7.077223	0.0000

R-squared	0.800146	Mean dependent var	0.040656
Adjusted R-squared	0.791062	S.D. dependent var	0.071178
S.E. of regression	0.032535	Akaike info criterion	-3.957542
Sum squared resid	0.069864	Schwarz criterion	-3.829057
Log likelihood	142.5140	Hannan-Quinn criter.	-3.906506
F-statistic	88.08049	Durbin-Watson stat	2.143649
Prob(F-statistic)	0.000000		

3. Model ARIMA (0,1,3)

EViews - [Equation: UNTITLED Workfile: PEMODELAN DENGAN EIEWS:Untitled\]

File	Edit	Object	View	Proc	Quick	Options	Add-ins	Window	Help
View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids

Heteroskedasticity Test: White

F-statistic	65.62883	Prob. F(3,66)	0.0000
Obs*R-squared	52.42587	Prob. Chi-Square(3)	0.0000
Scaled explained SS	55.23805	Prob. Chi-Square(3)	0.0000

Test Equation:

Dependent Variable: RESID^2

Method: Least Squares

Date: 01/04/22 Time: 16:29

Sample: 2014M12 2020M09

Included observations: 70

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.023066	0.004460	5.171860	0.0000
GRADF_01^2	0.001073	0.002241	0.478933	0.6336
GRADF_01*GRADF_02	-0.000322	0.000104	-3.100458	0.0028
GRADF_02^2	7.94E-05	1.22E-05	6.521796	0.0000
R-squared	0.748941	Mean dependent var		0.044959
Adjusted R-squared	0.737529	S.D. dependent var		0.067669
S.E. of regression	0.034668	Akaike info criterion		-3.830544
Sum squared resid	0.079324	Schwarz criterion		-3.702059
Log likelihood	138.0690	Hannan-Quinn criter.		-3.779508
F-statistic	65.62883	Durbin-Watson stat		1.754193
Prob(F-statistic)	0.000000			

4. Model ARIMA (1,1,3)

EViews - [Equation: UNTITLED Workfile: PEMODELAN DENGAN EIEWS:Untitled\]

File	Edit	Object	View	Proc	Quick	Options	Add-ins	Window	Help
View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids

Heteroskedasticity Test: White

F-statistic	89.28613	Prob. F(6,63)	0.0000
Obs*R-squared	62.63425	Prob. Chi-Square(6)	0.0000
Scaled explained SS	88.84476	Prob. Chi-Square(6)	0.0000

Test Equation:

Dependent Variable: RESID^2

Method: Least Squares

Date: 01/04/22 Time: 16:31

Sample: 2014M12 2020M09

Included observations: 70

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.009478	0.002840	3.337331	0.0014
GRADF_01^2	0.005416	0.001666	3.251441	0.0018
GRADF_01*GRADF_02	0.006750	0.001373	4.917217	0.0000
GRADF_01*GRADF_03	-0.000232	6.98E-05	-3.331203	0.0014
GRADF_02^2	0.002825	0.000774	3.650946	0.0005
GRADF_02*GRADF_03	-2.41E-05	6.47E-05	-0.372891	0.7105
GRADF_03^2	2.80E-05	3.96E-06	7.079353	0.0000
R-squared	0.894775	Mean dependent var	0.034983	
Adjusted R-squared	0.884754	S.D. dependent var	0.062006	
S.E. of regression	0.021050	Akaike info criterion	-4.789218	
Sum squared resid	0.027915	Schwarz criterion	-4.564368	
Log likelihood	174.6226	Hannan-Quinn criter.	-4.699905	
F-statistic	89.28613	Durbin-Watson stat	1.924633	
Prob(F-statistic)	0.000000			

Lampiran 7. Correlogram Residual Kuadrat

1. Model ARIMA (0,1,1)

Correlogram of Residuals Squared						
Date: 11/20/21 Time: 09:39						
Sample: 2014M10 2020M09						
Included observations: 70						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.046	-0.046	0.1517	0.697
		2	-0.042	-0.044	0.2844	0.867
		3	-0.069	-0.073	0.6407	0.887
		4	0.068	0.060	0.9945	0.911
		5	0.109	0.110	1.9104	0.861
		6	-0.169	-0.161	4.1537	0.656
		7	-0.125	-0.128	5.3953	0.612
		8	-0.015	-0.028	5.4133	0.713
		9	0.132	0.094	6.8630	0.651
		10	-0.051	-0.051	7.0841	0.717
		11	0.117	0.175	8.2626	0.690
		12	-0.092	-0.074	9.0010	0.703
		13	0.030	-0.030	9.0783	0.767
		14	-0.031	-0.066	9.1661	0.820
		15	-0.091	-0.083	9.9172	0.825

Lampiran 8. Model Varian**1. ARCH (1)**

Dependent Variable: D(TRANS1)				
Method: ML ARCH - Normal distribution (OPG - BHHH / Marquardt steps)				
Date: 12/19/21 Time: 22:11				
Sample (adjusted): 2014M12 2020M09				
Included observations: 70 after adjustments				
Failure to improve likelihood (non-zero gradients) after 71 iterations				
Coefficient covariance computed using outer product of gradients				
MA Backcast: 2014M11				
Presample variance: backcast (parameter = 0.7)				
GARCH = C(2) + C(3)*RESID(-1)^2				
Variable	Coefficient	Std. Error	z-Statistic	Prob.
MA(1)	-0.883612	0.109418	-8.075591	0.0000
Variance Equation				
C	0.034388	0.007242	4.748090	0.0000
RESID(-1)^2	0.142105	0.228543	0.621786	0.5341
R-squared	0.487248	Mean dependent var		-0.003902
Adjusted R-squared	0.487248	S.D. dependent var		0.230374
S.E. of regression	0.164963	Akaike info criterion		-0.631790
Sum squared resid	1.877690	Schwarz criterion		-0.535426
Log likelihood	25.11265	Hannan-Quinn criter.		-0.593513
Durbin-Watson stat	2.181542			
Inverted MA Roots	.88			

2. GARCH (1,1)

Dependent Variable: D(TRANS1)
 Method: ML ARCH - Normal distribution (OPG - BHHH / Marquardt steps)
 Date: 12/19/21 Time: 22:13
 Sample (adjusted): 2014M12 2020M09
 Included observations: 70 after adjustments
 Failure to improve likelihood (non-zero gradients) after 110 iterations
 Coefficient covariance computed using outer product of gradients
 MA Backcast: 2014M11
 Presample variance: backcast (parameter = 0.7)
 GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
MA(1)	-0.944414	0.047592	-19.84412	0.0000
Variance Equation				
C	0.034014	0.037570	0.905345	0.3653
RESID(-1)^2	0.087576	0.148793	0.588572	0.5561
GARCH(-1)	-0.251439	1.240167	-0.202746	0.8393
R-squared	0.499061	Mean dependent var		-0.003902
Adjusted R-squared	0.499061	S.D. dependent var		0.230374
S.E. of regression	0.163052	Akaike info criterion		-0.669320
Sum squared resid	1.834431	Schwarz criterion		-0.540834
Log likelihood	27.42619	Hannan-Quinn criter.		-0.618284
Durbin-Watson stat	2.100779			
Inverted MA Roots	.94			

3. GARCH (2.2)

Dependent Variable: D(TRANS1)
 Method: ML ARCH - Normal distribution (OPG - BHHH / Marquardt steps)
 Date: 12/19/21 Time: 22:17
 Sample (adjusted): 2014M12 2020M09
 Included observations: 70 after adjustments
 Failure to improve likelihood (non-zero gradients) after 55 iterations
 Coefficient covariance computed using outer product of gradients
 MA Backcast: 2014M11
 Presample variance: backcast (parameter = 0.7)
 GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*RESID(-2)^2 + C(5)*GARCH(-1)
 + C(6)*GARCH(-2)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
MA(1)	-0.883884	0.095028	-9.301330	0.0000
Variance Equation				
C	0.035584	0.049800	0.714530	0.4749
RESID(-1)^2	0.094542	0.168475	0.561163	0.5747
RESID(-2)^2	-0.067329	0.162551	-0.414203	0.6787
GARCH(-1)	0.095263	1.621200	0.058761	0.9531
GARCH(-2)	-0.259046	0.921153	-0.281219	0.7785
R-squared	0.487298	Mean dependent var		-0.003902
Adjusted R-squared	0.487298	S.D. dependent var		0.230374
S.E. of regression	0.164955	Akaike info criterion		-0.588562
Sum squared resid	1.877505	Schwarz criterion		-0.395834
Log likelihood	26.59967	Hannan-Quinn criter.		-0.512008
Durbin-Watson stat	2.181159			
Inverted MA Roots	.88			


4. EGARCH (1,1)

Dependent Variable: D(TRANS1)
 Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)
 Date: 01/25/22 Time: 20:51
 Sample (adjusted): 2014M12 2020M09
 Included observations: 70 after adjustments
 Convergence achieved after 36 iterations
 Coefficient covariance computed using outer product of gradients
 MA Backcast: 2014M11

Presample variance: backcast (parameter = 0.7)

LOG(GARCH) = C(2) + C(3)*ABS(RESID(-1))/@SQRT(GARCH(-1))) + C(4)
 *RESID(-1)/@SQRT(GARCH(-1)) + C(5)*LOG(GARCH(-1))

Variable	Coefficient	Std. Error	z-Statistic	Prob.
MA(1)	-0.973336	0.011499	-84.64315	0.0000
Variance Equation				
C(2)	-1.497037	0.558350	-2.681180	0.0073
C(3)	-1.033455	0.323291	-3.196669	0.0014
C(4)	-0.288627	0.116620	-2.474950	0.0133
C(5)	0.390803	0.175934	2.221298	0.0263
R-squared	0.506275	Mean dependent var		-0.003902
Adjusted R-squared	0.506275	S.D. dependent var		0.230374
S.E. of regression	0.161874	Akaike info criterion		-0.808315
Sum squared resid	1.808011	Schwarz criterion		-0.647709
Log likelihood	33.29104	Hannan-Quinn criter.		-0.744520
Durbin-Watson stat	2.070618			
Inverted MA Roots	.97			

Lampiran 9. Plot Peramalan Volatilitas

Lampiran 10. Estimasi λ Pada Box-Cox

Diberikan fungsi log-likelihood

$$\begin{aligned} I(\lambda|y, X, \tilde{B}(\lambda), \hat{\sigma}^2(\lambda)) \\ = -\frac{n}{2} \log(\hat{\sigma}^2(\lambda)) - \frac{n}{2} \log(2\pi) + (\lambda \\ - 1) \sum \log(y_i) \end{aligned}$$

Untuk memaksimumkan fungsi log-likelihood, maka akan dicari turunan pertama dari fungsi di atas dan sama dengan nol.

$$\begin{aligned} \frac{\partial [I(\lambda|y, X, \tilde{B}(\lambda), \hat{\sigma}^2(\lambda))]}{\partial \lambda} \\ = \frac{\partial}{\partial \lambda} \left[-\frac{n}{2} \log(\hat{\sigma}^2(\lambda)) - \frac{n}{2} \log(2\pi) + (\lambda \\ - 1) \sum \log(y_i) \right] = 0 \end{aligned}$$

Karena derivatif bisa saling bebas antar operasi biner, sehingga memenuhi:

$$\frac{\partial}{\partial \lambda} \left[-\frac{n}{2} \log(\hat{\sigma}^2(\lambda)) \right] \dots \dots (1)$$

$$\frac{\partial}{\partial \lambda} \left[-\frac{n}{2} \log(2\pi) \right] \dots \dots (2)$$

$$\frac{\partial}{\partial \lambda} \left[(\lambda - 1) \sum \log(y_i) \right] \dots \dots (3)$$

Untuk persamaan (1) didapat:

$$\begin{aligned}\frac{\partial}{\partial \lambda} \left[-\frac{n}{2} \log(\hat{\sigma}^2(\lambda)) \right] &= -\frac{n}{2} \frac{\partial}{\partial \lambda} [\log(\hat{\sigma}^2(\lambda))] \\ &= -\frac{n}{2} \left(\frac{1}{\hat{\sigma}^2(\lambda)} \right) \left(\frac{1}{\ln 10} \right) \frac{\partial}{\partial \lambda} [\hat{\sigma}^2(\lambda)]\end{aligned}$$

Untuk persamaan (2) didapat:

$$\frac{\partial}{\partial \lambda} \left[-\frac{n}{2} \log(2\pi) \right] = 0$$

Dan, untuk persamaan (3) didapat:

$$\frac{\partial}{\partial \lambda} \left[(\lambda - 1) \sum \log(y_i) \right] = \sum \log(y_i)$$

Sehingga didapat:

$$-\frac{n}{2} \left(\frac{1}{\hat{\sigma}^2(\lambda)} \right) \left(\frac{1}{\ln 10} \right) \frac{\partial}{\partial \lambda} [\hat{\sigma}^2(\lambda)] + \sum \log(y_i) = 0$$

$$\left(\frac{1}{\hat{\sigma}^2(\lambda)} \right) \frac{\partial}{\partial \lambda} [\hat{\sigma}^2(\lambda)] = \frac{2}{n} \left(\sum \log(y_i) \right) (\ln 10)$$

Namun, persamaan di atas sulit diselesaikan secara analitik untuk mendapatkan nilai λ . Sehingga perlu dilakukan pencarian nilai optimum λ secara numerik dengan mengambil nilai uji coba *batas bawah* $< \lambda <$ *batas atas* dengan menggunakan aturan metode numerik.

Bila hasil diturunkan dua kali maka akan didapat:

$$\frac{\partial}{\partial \lambda} \left[\left(\frac{1}{\hat{\sigma}^2(\lambda)} \right) \right] \frac{\partial}{\partial \lambda} [\hat{\sigma}^2(\lambda)] + \left(\frac{1}{\hat{\sigma}^2(\lambda)} \right) \frac{\partial}{\partial \lambda} [\hat{\sigma}^2(\lambda)] = 0$$

$$\frac{\partial}{\partial \lambda} \left[\left(\frac{1}{\hat{\sigma}^2(\lambda)} \right) \right] \frac{\partial}{\partial \lambda} [\hat{\sigma}^2(\lambda)] = - \left(\frac{1}{\hat{\sigma}^2(\lambda)} \right) \frac{\partial}{\partial \lambda} [\hat{\sigma}^2(\lambda)]$$

$$\frac{\frac{\partial}{\partial \lambda} [\hat{\sigma}^2(\lambda)]}{\frac{\partial^2}{\partial \lambda^2} [\hat{\sigma}^2(\lambda)]} = - \frac{\left(\frac{1}{\hat{\sigma}^2(\lambda)} \right)}{\frac{\partial}{\partial \lambda} \left(\frac{1}{\hat{\sigma}^2(\lambda)} \right)}$$

Turunan kedua dari fungsi juga sulit untuk diselesaikan secara analitis.

Lampiran 11. Source Code Box-Cox

```
clear;
clc;
close all;
data=xlsread('return+C.xlsx');
%data=xlsread('return+C.xlsx');
bub = -5; %minimum uji
step= 0.1; %langkah uji
bua = 5; %maksimum uji

rata1=mean(data); %mencari rata2
std1 =std(data); %mencari std deviasi
up =rata1+(3*std1);
low =rata1-(3*std1);

%plot time series
plot(data);
hold on;
plot(1:length(data),rata1*ones([1
length(data)]),'linewidth',2);
hold on;
plot(1:length(data),up*ones([1
length(data)]),'linewidth',2);
hold on;
plot(1:length(data),low*ones([1
length(data)]),'linewidth',2);
grid on;
xlabel('data ke-')
ylabel('data return')
title('Plot time series data return')
%Plot moving range
count=1;
for i=1: (length(data)-1)
    move(count)=abs(data(i)-data(i+1));
    count=count+1;
end
```

```

rata2=mean(move); %mencari rata-rata
std2=std(move); %mencari standar deviasi
up1=rata2+(3*std2);
low1=rata2-(3*std2);

figure
plot(move);
hold on;
plot(1:length(move),rata2*ones([1
length(move)]),'linewidth',2);
hold on;
plot(1:length(move),up1*ones([1
length(move)]),'linewidth',2);
hold on;
plot(1:length(move),low1*ones([1
length(move)]),'linewidth',2);
grid on;

xlabel('data ke-')
ylabel('data moving range')
title('Plot X-Chart (Moving Range)
Transformation')

%mencari geomean
geo = geomean(data);

%transformasi modified
figure
kos=1;
for i=bub:step:bua

    if(i==0)
        for j=1:length(data)

C(j)=geo*log(data(j))/log(exp(1));
        end

```

```

plot(C)
    hold on;
    xlabel('Data ke')
    ylabel('Data Hasil Transformasi
GEOM')
    title('Transformasi dengan Modified
Box-Cox')
    else
        for j=1:length(data)
            C(j)=((data(j)^i)-1)/(i*(geo^(i-
1)))));
        end
        plot(C)
        hold on;
        xlabel('Data ke')
        ylabel('Data Hasil Transformasi
GEOM')
        title('Transformasi dengan Modified
Box-Cox')
        end
        count1=1;
        for i=1:(length(C)-1)
            move1(count1)=abs(C(i)-C(i+1));
            count1=count1+1;
        end
        ratamove=mean(move1);
        sigma(kos)=ratamove/1.128;
        kos=kos+1;
    end
    x=[bub:step:buah];
    min=sigma(1);
    node=x(1);
    for i=2:length(sigma)
        if(sigma(i) <= sigma(i-1))
            min=sigma(i);
            node=x(i);
        end
    end
end

```



```

ratasig = mean(sigma);
figure
plot(x,sigma,'linewidth',1.5)
hold on
plot(node,min,'.','MarkerSize',20)
hold on
plot(bub:step:bua,min*ones([1
length(sigma)]),'linewidth',1.5);
hold on
Z=['Estimasi Optimal Lambda:
',num2str(node)];
title(Z)
xlabel('Lambda')
ylabel('StDev')
grid on
%Hasil Trans
if (node==0)
    data1=log(data)/(log(exp(1)));
else
    data1=data.^node;
end
figure
plot(1:length(data1),data1)
xlabel('data ke-')
ylabel('data hasil transformasi')
title('Plot Box-Cox Transformation')
%UJI HASIL TRANSFORMASI
%HASIL TRANSFORMADI
% Mencari geomean geo=geomean(data1);
% transformasi modified
kos=1;
for i=bub:step:bua
    if(i==0)
        for j=1:length(data1)
            C(j)=geo*log(data1(j))/log(exp(1));
        end
    else

```

```

for j=1:length(data1)
    C(j)=((data1(j)^i)-1)/(i*(geo^(i-1)));
    end
end
count1=1;
for i=1:(length(C)-1)
    move1(count1)=abs(C(i)-C(i+1));
    count1=count1+1;
end
ratamove=mean(move1);
sigma(kos)=ratamove/1.128;
kos=kos+1;
end
x=[bub:step:bua];
min=sigma(1);
node=x(1);
for i=2:length(sigma)
    if(sigma(i) <= sigma(i-1))
        min=sigma(i);
    end
node = x(i);
end
end
ratasig = mean(sigma);
figure
plot(x,sigma,'linewidth',1.5)
hold on
plot(node,min,'.', 'MarkerSize',20)
hold on
plot(bub:step:bua,min*ones([1
length(sigma)]),'linewidth',1.5);
hold on;
Z = ['Estimasi Optimal Lambda Hasil
Transformasi:', num2str(node)];
title(Z)
xlabel('Lambda')
ylabel('StDev/isigma')
grid on;

```

BIODATA PENULIS



Penulis bernama lengkap Andita Agustin Puspitasari atau biasa dipanggil Andita. Lahir di Sidoarjo, 06 Agustus 1999 dan tinggal di Sidoarjo. Jenjang Pendidikan formal yang ditempuh yaitu TK Nurul Huda (2003-2005), MI Roudlotul Ihsan (2005-2011), SMPN 1 Taman (2011-2014), SMA Muhammadiyah 1 Taman (2014-2017). Pada tahun 2017 penulis diterima di Departemen Matematika

Institut Teknologi Sepuluh Nopember melalui jalur Seleksi Nasional Masuk Perguruan Tinggi Negeri atau biasa disebut jalur SNMPTN. Penulis juga aktif di Lembaga Dakwah Jurusan Ibnu Muqhlah Matematika Institut Teknologi Sepuluh Nopember sebagai staff syi'ar. Penulis juga pernah menjadi penanggungjawab sie-soal dalam lomba yang diadakan oleh Ibnu Muqhlah ITS. Penulis selain menjadi mahasiswa juga bergelut dibidang usaha kuliner dan juga sebagai guru privat PAUD, TK, SD, SMP, dan SMA.

Selama di Departemen Matematika, penulis mengambil bidang studi matematika terapan. Apabila ingin memberikan kritik, saran, dan diskusi lebih lanjut terkait Buku Tugas Akhir ini, dapat menghubungi email **anditagustin@gmail.com**.

