

SIMULASI MODEL GARCH MENGGUNAKAN PROGRAM R

(Skripsi)

Oleh

FATURAHMAN ALHAFIZ

1817031082



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2023**

ABSTRACT

THE SIMULATION OF GARCH MODEL USING R PROGRAM

By

FATURAHMAN ALHAFIZ

The GARCH model is a time series model that can accommodate heteroscedasticity. The available data that meet the assumption of heteroscedasticity are limited, therefore simulation data can be used to obtain data that meet the assumption of heteroscedasticity. Monte Carlo simulation is a sampling method to a machine or computer using random numbers whose distribution is known. The purpose of this study was to find out the best GARCH model and to know the results of forecasting using the GARCH model with simulation data for the next 30 periods. The results of the study show the results of forecasting for the next 30 days, from 1 March 2022 to 11 April 2022 the simulation data has decreased

Keywords: GARCH, time series, heteroscedasticity, simulation data, Monte Carlo Simulation, forecasting

ABSTRAK

SIMULASI MODEL GARCH MENGGUNAKAN PROGRAM R

Oleh

FATURAHMAN ALHAFIZ

Model GARCH merupakan suatu model deret waktu yang dapat mengakomodasi sifat heteroskedastik. Data yang memenuhi asumsi heteroskedastisitas yang tersedia terbatas, oleh karena itu dapat digunakan data simulasi untuk memperoleh data yang memenuhi asumsi heteroskedastisitas. Simulasi Monte Carlo adalah metode pengambilan sampel ke mesin atau komputer dengan menggunakan bilangan-bilangan acak yang telah diketahui distribusinya. Tujuan penelitian ini untuk mengetahui model GARCH terbaik serta mengetahui hasil peramalan menggunakan model GARCH dengan data simulasi untuk 30 periode selanjutnya. Hasil penelitian menampilkan hasil peramalan selama 30 hari ke depan yaitu periode 1 Maret 2022 sampai dengan 11 April 2022 pada data simulasi mengalami penurunan.

Kata Kunci: GARCH, deret waktu, heteroskedastisitas, data simulasi, Simulasi Monte Carlo, peramalan

SIMULASI MODEL GARCH MENGGUNAKAN PROGRAM R

Oleh

FATURAHMAN ALHAFIZ

Skripsi

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

Pada

**Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2023**

Judul Skripsi : **SIMULASI MODEL GARCH MENGGUNAKAN PROGRAM R**

Nama Mahasiswa : **Faturahman Alhafiz**

Nomor Pokok Mahasiswa : **1817031082**

Jurusan : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**



1. Komisi Pembimbing


Drs. Nusyirwan, M.Si.
NIP. 196610101992031028


Dr. Notiragayu, M.Si.
NIP. 197311092000122001

2. Ketua Jurusan Matematika


Dr. Aang Nuryaman, S.Si., M.Si.
NIP. 197403162005011001

MENGESAHKAN

1. **Tim Penguji**

Ketua

: Drs. Nusyirwan, M.Si.



Sekretaris

: Dr. Notiragayu, M.Si.



Penguji

Bukan Pembimbing

: Dian Kurniasari, S.Si., M.Sc.



2. **Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam**



Dr. Eng. Satripto Dwi Yuwono, S.Si., M.T.

NIP. 19740705 200003 1 001

Tanggal Lulus Ujian Skripsi : 9 Februari 2023

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini :

Nama Mahasiswa : Faturahman Alhafiz

Nomor Pokok Mahasiswa : 1817031082

Jurusan : Matematika

Judul Skripsi : **SIMULASI MODEL GARCH MENGGUNAKAN PROGRAM R**

Dengan ini menyatakan bahwa penelitian ini adalah hasil pekerjaan saya sendiri dan apabila kemudian hari terbukti bahwa skripsi ini merupakan salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 9 Februari 2023



Penulis,

Faturahman Alhafiz

RIWAYAT HIDUP

Penulis bernama lengkap Faturahman Alhafiz, dilahirkan pada tanggal 9 Juni 2000 di Bandar Lampung. Penulis merupakan putra kedua dari Bapak Bugi Supriadi dan Ibu Dwi Heni Rulisati.

Penulis mengawali pendidikan di Taman Kanak-Kanak (TK) Al-Azhar 16 pada tahun 2005-2006. Kemudian menempuh pendidikan Sekolah Dasar (SD) di SD Al-Kautsar pada tahun 2006 – 2012. Kemudian melanjutkan ke Sekolah Menengah Pertama (SMP) di SMPN 22 Bandar Lampung pada tahun 2012-2015. Selanjutnya belajar pada jenjang Sekolah Menengah Kejuruan (SMK) di SMK-SMTI Bandar Lampung pada tahun 2015-2018. Pada tahun 2018 penulis terdaftar sebagai mahasiswa Program Studi S1 Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

Pada Tahun 2021 penulis melaksanakan Kuliah Kerja Nyata (KKN) di Kelurahan Pesawahan, Kecamatan Teluk Betung Selatan, sebagai bentuk pengabdian kepada masyarakat. Pada tahun yang sama penulis juga melaksanakan Kuliah Kerja Praktik (KP) di Lembaga Penjaminan Mutu Pendidikan (LPMP) sebagai bentuk aplikasi bidang ilmu di dunia kerja.

KATA INSPIRASI

*“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya”
(Q.S Al-Baqarah: 286)*

*“Karena sesungguhnya sesudah kesulitan itu ada kemudahan”
(Q.S Al-Insyirah: 5)*

*“Dan bersabarlah kamu, sesungguhnya janji Allah adalah benar”
(Q.S Ar-Rum: 60)*

*I wanna thank me, I wanna thank me for believing in me
I wanna thank me for doing all this hard work
I wanna thank me for, for never quitting
I wanna thank me for just being me at all times*

*Just because someone stumbles and loses their path,
doesn't mean they're lost forever*

Rest at the end, not in the middle

PERSEMBAHAN

Alhamdulillah, puji syukur kepada Allah SWT yang telah memberikan petunjuk dan kekuatan juga memberikan penerangan dalam ilmu pengetahuan. Hanya karena-Nya lah skripsi ini bisa penulis selesaikan dengan rasa syukur dan bahagia. Dengan segala kerendahan hati, penulis persembahkan karya sederhana ini kepada:

Orang Tua Tercinta

Sebagai tanda terima kasih karena selalu mencurahkan doa, tenaga, pikiran, dan dukungannya untuk keberhasilan penulis dalam menuntut ilmu serta menjadi penyemangat terbaik sehingga penulis bisa menyelesaikan skripsi ini.

Dosen Pembimbing dan Pembahas

Yang senantiasa memberikan bimbingan, arahan, dan ilmu yang bermanfaat bagi penulis.

Almamater Tercinta, Universitas Lampung

SANWACANA

Segala puji dan syukur penulis ucapkan kepada Allah SWT atas segala nikmat dan karunia-Nya yang tak terhingga sehingga penulis dapat menyelesaikan skripsi yang berjudul "*Simulasi Model GARCH Menggunakan Program R*". Dalam penulisan skripsi ini tidak dapat terselesaikan tanpa adanya bimbingan, bantuan dan dukungan dari berbagai pihak. Sehingga, dalam kesempatan ini penulis mengucapkan terimakasih kepada:

1. Bapak Drs. Nusyirwan, M.Si., selaku dosen pembimbing I yang senantiasa membimbing dengan sabar, memberi masukan serta saran dan mendukung penulis dalam menyelesaikan skripsi ini.
2. Ibu Dr. Notiragayu S.Si., M.Si., selaku dosen pembimbing II atas kesediaannya memberikan bimbingan, pengarahan, serta saran sehingga penulis dapat menyelesaikan skripsi ini.
3. Ibu Dian Kurniasari S.Si., M.Sc., selaku dosen penguji yang telah memberikan kritik dan saran yang membangun sehingga skripsi ini dapat terselesaikan.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Bapak Dr. Eng. Suropto Dwi Yuwono, S.Si., M.T., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

6. Seluruh dosen, staff, karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Teruntuk kedua orang tuaku tercinta, Bapak Bugi Supriadi dan Ibu Dwi Heni Rulisati terimakasih atas doa, dukungan, pengorbanan, cinta kasih, perhatian, demi kesuksesan penulis semoga dikemudian hari dapat membahagiakan dan menjadi kebanggan kalian.
8. Teruntuk sahabat kuliahku, Ferdy, Bang Desfan, Isad, Farrel, Afriandy, Faqih, Syahrul, Nurlela, Aniisah, Hanifah, Sherlina, terima kasih atas pengalaman serta dukungan terhadap penulis dari sejak awal perkuliahan hingga selesai.
9. Semua pihak yang tidak dapat disebutkan satu persatu yang telah membantu penulis dalam menyelesaikan skripsi ini.

Penulis menyadari bahwa masih banyak kekurangan dalam penulisan skripsi ini. Oleh karena itu, penulis mengharapkan masukan serta saran untuk dijadikan pelajaran kedepannya.

Bandar Lampung, 9 Februari 2023

Penulis,

Faturahman Alhafiz

DAFTAR ISI

Halaman

DAFTAR TABEL	iii
DAFTAR GAMBAR.....	iv
I. PENDAHULUAN	1
1.1 Latar Belakang dan Masalah.....	1
1.2 Tujuan Penelitian	2
1.3 Manfaat Penelitian	2
II. TINJAUAN PUSTAKA.....	3
2.1 Simulasi Monte Carlo	3
2.2 Deret Waktu	4
2.3 Stasioner.....	5
2.4 Uji Akar Unit	6
2.5 Model <i>Autoregressive</i> (AR).....	6
2.6 Model <i>Moving Average</i> (MA)	7
2.7 Model <i>Autoregressive Moving Average</i> (ARMA).....	8
2.8 Model <i>Autoregressive Integrated Moving Average</i> (ARIMA).....	9
2.9 <i>Autocorrelation Function</i>	10
2.10 <i>Partial Autocorrelation Function</i>	11
2.11 <i>Maximum Likelihood Estimation</i>	11
2.12 Heteroskedastisitas.....	12
2.13 Uji Efek ARCH.....	14
2.14 Model <i>Autoregressive Conditional Heteroskedasticity</i> (ARCH)	14
2.15 Model <i>Generalized Autoregressive Conditional Heteroskedasticity</i> (GARCH).....	15
2.16 <i>Akaike Information Criterion</i>	17
III. METODOLOGI PENELITIAN	19
3.1 Waktu dan Tempat Penelitian.....	19
3.2 Data Penelitian	19
3.3 Metode Penelitian	20

IV. HASIL DAN PEMBAHASAN	22
4.1 Simulasi Data	22
4.2 Plot Data.....	25
4.3 Uji Stasioneritas Data	26
4.4 Identifikasi Model ARIMA.....	28
4.5 Estimasi Model ARIMA	29
4.6 Identifikasi Model GARCH.....	31
4.7 Estimasi Model GARCH	32
4.8 Peramalan.....	33
V. KESIMPULAN	34
DAFTAR PUSTAKA.....	35
LAMPIRAN	

DAFTAR TABEL

Tabel	Halaman
3.1 Data Harga Saham Microsoft.....	20
4.1 Sintaks Simulasi Data	22
4.2 <i>Output</i> Uji ARCH-LM Sebelum Transformasi Data	23
4.3 <i>Output</i> Uji ARCH-LM Setelah Transformasi Data	24
4.4 <i>Output</i> Uji ADF	27
4.5. <i>Output</i> Model ARIMA dan Nilai AIC	29
4.6. Nilai Dugaan Parameter ARIMA (1,0,1).....	31
4.7. <i>Output</i> Model GARCH dan Nilai AIC	32
4.8. Nilai Dugaan Parameter GARCH (1,1)	32

DAFTAR GAMBAR

Gambar	Halaman
4.1. Plot Deret Waktu Data Simulasi	25
4.2. Plot ACF Data Simulasi.....	26
4.3. Plot ACF dan PACF Data Simulasi	28
4.4. Plot Hasil Peramalan.....	33

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH) diusulkan oleh Bollerslev (1986) sebagai bentuk umum dari model *Autoregressive Conditional Heteroscedasticity* (ARCH). Engle (1982) memperkenalkan model *Autoregressive Conditional Heteroscedasticity*, yaitu model deret waktu yang dapat menangani heteroskedastisitas. Proses *Autoregressive Conditional Heteroscedasticity* tidak memiliki korelasi, rata-rata nol, dan ragam tak bersyarat konstan, ragam bersyarat tidak konstan di waktu lampau. Engle (1982), telah berhasil melakukan penelitian tentang perkiraan ragam dari inflasi United Kingdom dengan menggunakan model ARCH.

Data yang memenuhi asumsi heteroskedastisitas yang tersedia terbatas, oleh karena itu dapat digunakan data simulasi untuk memperoleh data yang memenuhi asumsi heteroskedastisitas. Simulasi Monte Carlo adalah metode pengambilan sampel ke mesin atau komputer dengan menggunakan bilangan-bilangan acak (*random numbers*). Dalam simulasi Monte Carlo, bilangan-bilangan acak dibangkitkan dari variabel acak yang distribusinya diketahui. Hasilnya, simulasi

Monte Carlo mensimulasikan kondisi lapangan secara numerik, memberikan kesan bahwa data dapat diperoleh dari lapangan (Tjong, 2001).

Nainggolan, dkk. (2018), menerapkan ARCH-GARCH untuk menganalisis volatilitas harga eceran komoditas beberapa bahan pangan utama di Kota Manado dan Kalengkongan, dkk. (2020), melakukan analisis volatilitas harga bawang putih di Kota Manado menggunakan model GARCH. Berdasarkan uraian di atas maka penelitian akan dilakukan adalah analisis model GARCH menggunakan data simulasi.

1.2 Tujuan Penelitian

Penelitian ini memiliki tujuan:

1. Mengetahui nilai dugaan parameter model GARCH terbaik dari data simulasi.
2. Mengetahui model GARCH terbaik dari data simulasi.
3. Mengetahui hasil peramalan menggunakan model GARCH dengan data simulasi untuk 30 periode selanjutnya.

1.3 Manfaat Penelitian

Manfaat dari penelitian ini adalah menambah wawasan keilmuan tentang simulasi data untuk menerapkan model GARCH dan langkah-langkah peramalan menggunakan model GARCH.

II. TINJAUAN PUSTAKA

2.1 Simulasi Monte Carlo

Menurut Brandimarte (2014), istilah Monte Carlo biasanya dikaitkan dengan proses pemodelan dan simulasi sistem yang dipengaruhi oleh keacakan: skenario acak dihasilkan dan statistik yang relevan dikumpulkan untuk menilai, misalnya kinerja kebijakan keputusan atau nilai aset.

Simulasi Monte Carlo adalah metode pengambilan sampel ke mesin atau komputer dengan menggunakan bilangan-bilangan acak (*random numbers*). Prinsip kerja dari simulasi Monte Carlo adalah membangkitkan bilangan-bilangan acak dari suatu variabel acak yang telah diketahui distribusinya. Oleh karena itu, dengan simulasi Monte Carlo seolah-olah dapat diperoleh data dari lapangan, atau dengan perkataan lain simulasi Monte Carlo meniru kondisi lapangan secara numerik. Simulasi Monte Carlo merupakan alat rekayasa yang ampuh untuk menyelesaikan berbagai persoalan rumit di dalam bidang peluang dan statistika (Tjong, 2001).

Dalam simulasi Monte Carlo sebuah model dibangun berdasarkan sistem yang sebenarnya. Distribusi peluang, juga dikenal sebagai *Probability Density Function*

(PDF) dari setiap variabel, menunjukkan bahwa nilai setiap variabel memiliki probabilitas yang berbeda dalam model. Metode Monte Carlo menyimulasikan sistem tersebut berulang-ulang kali, ratusan bahkan sampai ribuan kali tergantung sistem yang ditinjau dengan cara memilih sebuah bilangan acak untuk setiap variabel dari distribusi peluangnya (Fadjar, 2008).

2.2 Deret Waktu

Menurut Box, dkk. (2015), deret waktu adalah pengamatan yang diambil secara berurutan dalam waktu. Pengurutan juga dapat dibawa ke dimensi lain seperti ruang. Deret waktu terjadi di berbagai bidang (Wei, 2006). Peramalan adalah proses memperkirakan hasil masa depan menggunakan nilai-nilai dari masa lalu. Bidang finansial dan keuangan saat ini sedang mengembangkan penelitian mengenai peramalan (Faustina, dkk., 2017).

Analisis deret waktu adalah metode peramalan kuantitatif yang mempertimbangkan waktu. Dalam metode ini, data dikumpulkan secara teratur berdasarkan urutan waktu untuk mengidentifikasi pola pada data yang dikumpulkan sebelumnya secara teratur. Ada dua bagian teknik peramalan deret waktu. Pertama, model peramalan matematika statistik seperti *moving average*, *exponential smoothing*, regresi, dan ARIMA. Kedua, model peramalan berbasis kecerdasan buatan seperti klasifikasi, *hybrid*, *neural network*, dan algoritma genetika (Faustina, dkk., 2017).

2.3 Stasioner

Untuk membuat inferensia statistik tentang struktur proses stokastik berdasarkan proses yang telah diobservasi, biasanya harus membuat beberapa penyederhanaan asumsi tentang struktur itu. Asumsi yang paling penting adalah stasioner (Cryer & Chan, 2008). Terdapat dua jenis stasioner, yaitu stasioner kuat dan stasioner lemah. Proses stokastik $\{y_t\}$ dikatakan stasioner kuat (*strickly stationary*) jika distribusi gabungan dari $y_{t_1}, y_{t_2}, \dots, y_{t_n}$ sama dengan distribusi gabungan dari $y_{t_1-k}, y_{t_2-k}, \dots, y_{t_n-k}$, untuk semua t_1, t_2, \dots, t_n dan semua lag waktu k (Kalengkongan, dkk., 2020). $\{y_t\}$ adalah stasioner lemah jika $E(y_t) = \mu$, konstan dan $Cov(y_t, y_{t-l})$, yang hanya bergantung pada l . Menurut Montgomery, Jennings, & Kulahci (2015), ketika $n = 0$ asumsi stasioner berarti bahwa distribusi peluang y_t adalah sama untuk semua periode waktu dan dapat ditulis sebagai $f(y)$.

Stasioner menyiratkan syarat keseimbangan statistik atau stabilitas dalam data. Akibatnya, deret waktu memiliki rata-rata konstan yang didefinisikan dengan $\mu_y = E(y) = \int_{-\infty}^{\infty} y f(y) dy$ dan ragam konstan didefinisikan sebagai $\sigma_y^2 = Var(y) = \int_{-\infty}^{\infty} (y - \mu_y)^2 f(y) dy$ (Montgomery, Jennings, & Kulahci, 2015). Model stasioner mengasumsikan bahwa proses tetap dalam keseimbangan statistik dengan sifat probabilistik yang tidak berubah dari waktu ke waktu, khususnya rata-rata konstan dan ragam konstan. Namun, peramalan telah menjadi sangat penting dalam industri, bisnis, dan ekonomi, di mana banyak data deret waktu sering lebih baik direpresentasikan sebagai tidak stasioner dan karena tidak

memiliki rata-rata konstan dari waktu ke waktu (Box, dkk., 2015). Data dalam kehidupan nyata seringkali tidak stasioner. Untuk data yang tidak stasioner, perlu dilakukan pembedaan (*differencing*) atau transformasi karena data deret waktu pada peramalan *Autoregressive Integrated Moving Average* (ARIMA) ragam dan rata-ratanya stasioner (Kalengkongan, dkk., 2020).

2.4 Uji Akar Unit

Dickey & Fuller (1979) memperkenalkan uji akar unit, yang merupakan uji yang sangat populer. Uji akar unit biasanya digunakan untuk menentukan apakah data stasioner atau tidak. Uji *Augmented Dickey Fuller* (ADF) adalah uji akar unit yang paling umum dan banyak digunakan. Hipotesis pengujian *Augmented Dickey Fuller* adalah H_0 : Data tidak stasioner. H_1 : Data stasioner. Hasil uji akar unit didapat dengan membandingkan *p-value* dengan taraf signifikansi (α). Jika nilai *p-value* $< \alpha$ maka tolak H_0 , artinya data stasioner dan jika *p-value* $> \alpha$ maka tidak tolak H_0 , artinya data tidak stasioner (Kanal, dkk., 2018).

2.5 Model *Autoregressive* (AR)

Menurut Cryer & Chan (2008), proses *autoregressive* seperti namanya adalah regresi pada diri sendiri. Menurut Ratnasari, dkk. (2014), bentuk umum model *autoregressive* orde ke- p atau $AR(p)$ adalah:

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (2.1)$$

dengan,

y_t : nilai data pada waktu ke- t

ϕ : parameter model *autoregressive*

p : orde model *autoregressive*

ε_t : nilai galat pada waktu ke- t

2.6 Model *Moving Average* (MA)

Menurut Ratnasari, dkk. (2014), bentuk umum model *moving average* orde ke- q atau MA(q) adalah:

$$y_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.2)$$

dengan,

y_t : nilai data pada waktu ke- t

θ : parameter model *moving average*

q : orde model *moving average*

ε_t : nilai galat pada waktu ke- t

Proses *moving average* orde ke- q selalu stasioner terlepas dari nilai bobotnya (Montgomery, dkk., 2015). Istilah *moving average* muncul dari fakta bahwa y_t diperoleh dengan menerapkan bobot $1, -\theta_1, -\theta_2, \dots, -\theta_q$ ke variabel $\varepsilon_t, \varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$ dan kemudian memindahkan bobot dan menerapkannya ke $\varepsilon_{t+1}, \varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-q+1}$ untuk mendapatkan y_{t+1} dan seterusnya (Cryer & Chan, 2008).

2.7 Model *Autoregressive Moving Average* (ARMA)

Sebuah proses stasioner dapat direpresentasikan dengan sebuah bentuk *moving average* atau bentuk *autoregressive*. Masalah dengan kedua model ini yaitu terlalu banyak parameter karena model dengan orde yang tinggi seringkali membutuhkan perkiraan yang baik. Oleh karena itu, dalam membangun model perlu menyertakan *autoregressive* dan *moving average* dalam sebuah model. Menurut Tsay (2010), model *Autoregressive Moving Average* atau ARMA(p, q) menggabungkan ide-ide model *autoregressive* dan *moving average* sehingga jumlah parameter yang digunakan tetap kecil (Wei, 2006). Menurut Cryer & Chan (2008), jika diasumsikan bahwa deret waktu campuran antara *autoregressive* dan *moving average* maka diperoleh model deret ARMA(p, q) waktu yang secara umum dapat ditulis sebagai:

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} \dots - \theta_q \varepsilon_{t-q} \quad (2.3)$$

dengan,

y_t : nilai pada waktu ke- t

ϕ : parameter model *autoregressive*

p : orde model *autoregressive*

θ : parameter model *moving average*

q : orde model *moving average*

ε_t : galat

Dalam praktiknya, seringkali benar bahwa representasi yang memadai dari deret waktu stasioner yang benar-benar terjadi dapat diperoleh dengan model

autoregressive, moving average, atau campuran, di mana p dan q tidak lebih besar dari 2 dan seringkali kurang dari 2 (Box, dkk., 2015).

2.8 Model *Autoregressive Integrated Moving Average* (ARIMA)

Kalengkongan, dkk. (2020) menyatakan bahwa, model deret waktu biasanya digunakan dengan asumsi data deret waktu stasioner. Namun, mengingat sejumlah besar data deret waktu yang digunakan dalam ekonomi tidak stasioner, *differencing* digunakan untuk membuat data stasioner. *Differencing* dapat digunakan untuk mereduksi deret waktu tidak stasioner menjadi deret waktu stasioner. Ketidakstasioneran deret ini karena ragamnya yang berubah dari waktu ke waktu. Sebuah deret waktu tidak stasioner dapat direduksi menjadi sebuah deret waktu stasioner dengan menggunakan orde *differencing* yang tepat. Model *Autoregressive Moving Average* berguna dalam menjelaskan deret waktu stasioner. Model *Autoregressive Integrated Moving Average* berguna dalam menjelaskan deret waktu tidak stasioner (Wei, 2006).

Menurut Ping, dkk. (2013), model *Autoregressive Integrated Moving Average* atau $ARIMA(p,d,q)$ ditulis sebagai:

$$\phi_p(B)(1 - B)^d y_t = \delta + \theta_q(B)\varepsilon_t \quad (2.4)$$

dengan,

$\phi_p(B)$: parameter AR orde- p

δ : konstanta

$\theta_q(B)$: parameter MA orde- q

$(1 - B)^d$: differencing ke-d

ε_t : galat pada waktu t

Dalam kebanyakan aplikasi, *differencing* pertama ($d = 1$) dan terkadang *differencing* kedua ($d = 2$) cukup untuk mencapai stasioneritas. Namun, terkadang transformasi selain *differencing* berguna dalam mereduksi deret waktu tidak stasioner menjadi stasioner (Montgomery, dkk., 2015).

2.9 Autocorrelation Function

Menurut Tsay (2010), untuk deret waktu stasioner lemah y_t . Ketika korelasi linier antara y_t dan nilai masa lalunya y_{t-i} , konsep korelasi digeneralisasikan ke autokorelasi. Koefisien korelasi antara y_t dan y_{t-k} disebut autokorelasi lag- k dari y_t dan biasanya dilambangkan dengan ρ_k , yang menurut asumsi stasioner lemah adalah fungsi dari k saja. Secara khusus, didefinisikan:

$$\rho_k = \frac{\text{Cov}(y_t, y_{t-k})}{\sqrt{\text{Var}(y_t)\text{Var}(y_{t-k})}} = \frac{\text{Cov}(y_t, y_{t-k})}{\text{Var}(y_t)} \quad (2.5)$$

dengan,

ρ_k : koefisien autokorelasi pada lag ke- l

y_t : nilai data pada waktu ke- t

y_{t-k} : nilai data pada waktu ke- $(t - k)$

di mana $\text{Var}(y_t) = \text{Var}(y_{t-k})$ untuk deret stasioner lemah yang digunakan. Dari definisi, didapat $\rho_0 = 1$, $\rho_k = \rho_{-k}$ dan $-1 \leq \rho_k \leq 1$.

2.10 *Partial Autocorrelation Function*

Autocorrelation Function (ACF) adalah alat yang sangat baik dalam mengidentifikasi orde proses MA(q), karena diharapkan untuk *cut-off* setelah lag q . Namun, *Autocorrelation Function* tidak begitu berguna dalam identifikasi orde proses AR(p) yang kemungkinan besar akan memiliki *tail-off*. Oleh karena itu perilaku tersebut, sementara menunjukkan bahwa proses mungkin memiliki struktur AR, gagal untuk memberikan informasi lebih lanjut tentang orde struktur tersebut. Untuk itu, digunakan *Partial Autocorrelation Function* (PACF) dari deret waktu (Montgomery, dkk., 2015). Menurut Cryer & Chan (2008), fungsi tersebut dapat didefinisikan sebagai korelasi antara y_t dan y_{t-k} setelah menghilangkan efek dari $y_{t-1}, y_{t-2}, y_{t-3}, \dots, y_{t-k+1}$. Koefisien ini disebut autokorelasi parsial pada lag k dan akan dilambangkan dengan ϕ_{kk} . Secara khusus, didefinisikan:

$$\omega_{kk} = \text{Corr}(y_t, y_{t-k} | y_{t-1}, y_{t-2}, \dots, y_{t-k+1}) \quad (2.6)$$

dengan,

ω_{kk} : koefisien autokorelasi parsial pada lag ke- k

y_t : nilai data pada waktu ke- t

y_{t-k} : nilai data pada waktu ke- $(t - k)$

2.11 *Maximum Likelihood Estimation*

Misalkan X_1, X_2, \dots, X_n menyatakan sampel acak pada variabel acak X dengan PDF $f(x; \theta)$, di mana θ merupakan parameter yang tidak diketahui. Parameter θ

terlibat dalam distribusi bersama dari sampel acak $\prod_{i=1}^n f(x_i; \theta)$ dan ini dilihat sebagai fungsi dari θ , kemudian ditulis sebagai $L(\theta) = L(\theta; x_1, x_2, \dots, x_n) = \prod_{i=1}^n f(x_i; \theta)$. Ini disebut fungsi kemungkinan dari sampel acak. Pendugaan yang sering digunakan adalah nilai θ yang memberikan nilai maksimum $L(\theta)$. Jika unik, ini disebut *maximum likelihood estimator* (penduga kemungkinan maksimum), dan dinyatakan sebagai $\hat{\theta}$.

Dalam praktiknya, lebih mudah untuk bekerja dengan *log-likelihood*, yaitu fungsi $\ln L(\theta)$. Karena log adalah fungsi yang naik, nilai yang memaksimalkan $\ln L(\theta)$ sama dengan nilai yang memaksimalkan $L(\theta)$. *Probability Density Function* adalah fungsi yang dapat diturunkan terhadap θ , dan diselesaikan persamaan:

$$\frac{\partial \ln L(\theta)}{\partial \theta} = 0 \quad (2.7)$$

dengan,

$L(\theta)$: *maximum likelihood function*

θ : parameter yang diduga

Penduga titik dari θ adalah $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$, di mana $\hat{\theta}$ memaksimalkan fungsi $L(\theta)$. $\hat{\theta}$ disebut *Maximum Likelihood Estimator* (MLE) dari θ (Hogg, dkk., 2013).

2.12 Heteroskedastisitas

Dalam sebagian besar model regresi, faktor galat bermasalah ketika asumsi-asumsi residual dilanggar. Ragam dari suatu data deret waktu dapat bersifat

heteroskedastik, yang berarti nilai ragam berubah-ubah terhadap waktu (Priyono, dkk., 2020). Suatu keadaan dikatakan heteroskedastisitas, jika suatu data memiliki ragam galat yang tidak konstan untuk setiap pengamatan atau dengan kata lain melanggar asumsi $Var \varepsilon_t = \sigma^2$ (Kanal, dkk., 2018).

Sifat heteroskedastik yang ditunjukkan oleh adanya ketidakstasioneran dalam ragam, telah menyebabkan suatu fenomena di mana ragam akan tetap tinggi untuk beberapa periode atau sebaliknya akan tetap rendah untuk beberapa periode. Kemungkinan hasil peramalan yang jauh berbeda dari hasil sebenarnya sangat tinggi ketika sifat ini diabaikan dan tidak dilibatkan dalam model (Dharmawan, 2015).

Autoregressive (AR), *Moving Average* (MA), dan kombinasi dari dua model *Autoregressive Moving Average* (ARMA) adalah model deret waktu dari Box-Jenkins yang biasanya digunakan untuk pemodelan deret waktu univariat. Asumsi homoskedastik (ragam sama setiap waktu) adalah asumsi yang digunakan untuk galat dalam model ini. Namun, jika berkaitan dengan data keuangan seperti harga saham, tingkat inflasi, dan sebagainya, ini tidak tepat. Faktanya, data deret waktu dengan ragam galat (suku gangguan) tidak konstan sering dijumpai, seperti nilai rata-rata laju inflasi (Kalengkongan, dkk., 2020). Salah satu model yang populer dan dapat digunakan untuk memodelkan ragam yang tidak konstan tersebut yaitu model *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH), yang dikembangkan oleh Bollerslev (1986) (Priyono, dkk., 2020).

2.13 Uji Efek ARCH

Uji *Autoregressive Conditional Heteroskedasticity-Lagrange Multiplier* (ARCH-LM) dikembangkan oleh Engle untuk mengidentifikasi masalah heteroskedastisitas dalam deret waktu. Gagasan utama uji ini adalah bahwa residual kuadrat periode sebelumnya memengaruhi ragam residual, yang bukan hanya fungsi dari variabel independen (Kanal, dkk., 2018). Heteroskedastisitas bersyarat, atau efek ARCH, dapat dideteksi menggunakan residual kuadrat. Hipotesis pengujian *Autoregressive Conditional Heteroskedasticity-Lagrange Multiplier* (ARCH-LM) adalah H_0 : Tidak terdapat efek ARCH. H_1 : Terdapat efek ARCH. Hasil uji ARCH-LM didapat dengan membandingkan *p-value* dengan taraf signifikansi (α). Jika nilai *p-value* $< \alpha$ maka tolak H_0 , artinya terdapat efek ARCH dan jika *p-value* $> \alpha$ maka tidak tolak H_0 , artinya tidak terdapat efek ARCH (Tsay, 2010).

2.14 Model *Autoregressive Conditional Heteroskedasticity* (ARCH)

Pemodelan data deret waktu secara umum harus mengikuti asumsi homokedastisitas (ragam konstan). Namun, data deret waktu dalam sektor keuangan sangat tinggi volatilitasnya. Heteroskedastisitas menampilkan pergerakan ragam yang tidak konstan (Ratnasari, dkk., 2014). Model ARCH dikembangkan oleh Engle pada tahun 1982 digunakan untuk mengatasi masalah

heteroskedastisitas. Menurut Tsay (2010), secara khusus, model ARCH(m) mengasumsikan bahwa:

$$\sigma_t^2 = \omega + \alpha_1 a_{t-1}^2 + \alpha_2 a_{t-2}^2 + \dots + \alpha_m a_{t-m}^2 \quad (2.8)$$

dengan,

σ_t^2 : ragam residual pada waktu ke- t

ω : konstanta

α_m : parameter ke- m model ARCH

a_{t-m}^2 : residual kuadrat pada waktu ke- $(t - m)$

2.15 Model *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH)

Menurut Wei (2006), salah satu asumsi utama analisis regresi dan model regresi dengan galat autokorelasi adalah bahwa ragam dari galat adalah konstan. Dalam banyak praktik aplikasinya, asumsi ini mungkin tidak realistis. Karena itu sebuah model menggabungkan peluang sebuah ragam galat tidak konstan disebut model heteroskedastisitas. Dalam praktiknya, ragam biasanya tidak diketahui oleh karena itu model-model untuk menjelaskan heteroskedastisitas diperlukan. Engle (1982) adalah orang pertama yang memperkenalkan model *Autoregressive Conditional Heteroskedasticity*, yang dikembangkan untuk mengatasi masalah adanya ragam dalam data keuangan (Faustina, dkk., 2017).

Selanjutnya metode ini dikembangkan menjadi GARCH oleh Bollerslev (1986). Model *Generalized Autoregressive Conditional Heteroskedasticity* dikembangkan sebagai generalisasi dari model ARCH. Menurut Kanal, dkk. (2018), dengan

memilih model yang lebih sederhana daripada model ARCH, model ini dibangun untuk memastikan bahwa ragamnya selalu positif. Model *Generalized Autoregressive Conditional Heteroskedasticity* mengasumsikan bahwa ragam dari data fluktuasi dipengaruhi sejumlah s data fluktuasi sebelumnya dan sejumlah m data ragam sebelumnya atau ditulis $GARCH(m, s)$. Bentuk umum model $GARCH(m, s)$ adalah:

$$\sigma_t^2 = \omega + \alpha_1 a_{t-1}^2 + \dots + \alpha_m a_{t-m}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_s \sigma_{t-s}^2 \quad (2.9)$$

dengan,

σ_t^2 : ragam residual pada waktu ke- t

ω : konstanta

α_m : parameter ke- m model ARCH

a_{t-m}^2 : residual kuadrat pada waktu ke- $(t - m)$

β_s : parameter ke- s model GARCH

σ_{t-s}^2 : ragam residual pada waktu ke- $(t - s)$

Ketika $s = 0$, maka model tersebut tereduksi menjadi model $ARCH(m)$ (Wei, 2006). Ragam terdiri dari tiga komponen dalam model GARCH. Ragam konstan adalah komponen pertama, diikuti oleh ragam selama periode sebelumnya (suku ARCH) dan ragam selama periode sebelumnya (suku GARCH) (Kalengkongan, dkk., 2020).

Menurut Dharmawan (2015), penerapan model ragam bersyarat atau GARCH diharapkan dapat menyelesaikan masalah heteroskedastisitas. Model *Generalized Autoregressive Conditional Heteroskedasticity* lebih mudah dikembangkan karena

model GARCH merupakan bentuk yang lebih umum dari model ARCH. Dalam sebuah proses GARCH, ragam galat bisa dimodelkan dengan sebuah proses ARMA. Kelebihan lain dari GARCH adalah bahwa model ini dapat menghilangkan kurtosis yang berlebihan secara efektif (Franses & Van Dijk, 1996).

Model *Generalized Autoregressive Conditional Heteroskedasticity* di sisi lain, memiliki kemampuan untuk memodelkan ragam tak bersyarat yang berubah terhadap waktu. Model ini menggunakan ragam masa lalu dan peramalan ragam masa lalu untuk meramalkan ragam masa depan (Ping, dkk., 2013). Menurut Faustina, dkk. (2017), kelebihan model GARCH dibandingkan dengan metode deret waktu yang lain adalah:

1. Model ini tidak menganggap heteroskedastisitas sebagai masalah, melainkan memanfaatkannya untuk membuat model.
2. Selain membuat peramalan berdasarkan variabel y , model ini juga membuat peramalan berdasarkan ragam.

2.16 Akaike Information Criterion

Akaike Information Criterion (AIC) adalah kriteria pemilihan model yang mendapatkan perhatian luas di komunitas statistik, dan terus menjadi salah satu alat pemilihan model yang paling banyak dikenal dan digunakan dalam praktik statistik. Kriteria tersebut diperkenalkan oleh Hirotugu Akaike (1973) dalam makalahnya yang berjudul "*Information Theory and an Extension of the*

Maximum Likelihood Principle". Kerangka kemungkinan maksimum tradisional, seperti yang diterapkan pada pemodelan statistik, memberikan paradigma yang meyakinkan untuk menduga parameter yang tidak diketahui dari model yang memiliki dimensi dan struktur tertentu. Akaike memperluas paradigma ini dengan mempertimbangkan pengaturan di mana ukuran dan struktur model juga tidak diketahui, dan oleh karena itu harus ditentukan dari data. Dengan demikian, Akaike mengusulkan dan mengembangkan kerangka kerja di mana pendugaan dan pemilihan model dapat dicapai secara bersamaan. Menurut Hu (2017), model "terbaik" adalah yang memiliki nilai AIC minimum dan ditulis sebagai:

$$AIC = -2 \ln L(y|\hat{\theta}) + 2k \quad (2.10)$$

dengan,

$L(y|\hat{\theta})$: fungsi likelihood dari $\hat{\theta}$

$\hat{\theta}$: penduga kemungkinan maksimum dari θ

k : jumlah parameter yang diduga

Dalam *Akaike Information Criterion*, statistik berdasarkan log-likelihood $-2 \ln L(y|\hat{\theta})$, disebut dengan *goodness-of-fit term*. Statistik ini mencerminkan kesesuaian model $f(y|\hat{\theta})$ dengan data yang digunakan dalam y . Koreksi bias $2k$ disebut dengan *penalty term*. Model yang terlalu sederhana untuk mencirikan data yang ada akan sering menghasilkan *goodness-of-fit term* yang besar namun *penalty term* yang kecil. Di sisi lain, model yang sesuai dengan data, namun dengan parameter yang tidak perlu, akan sering menghasilkan *goodness-of-fit term* yang kecil namun *penalty term* yang besar (Cavanaugh & Neath, 2019).

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester genap tahun ajaran 2021/2022 di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

3.2 Data Penelitian

Data yang digunakan dalam penelitian ini adalah data simulasi yang memiliki efek heteroskedastisitas sebanyak 1000 data yang dibangkitkan menggunakan program R. Data yang memiliki efek heteroskedastisitas didapatkan dari transformasi data homogen yang sebelumnya dibangkitkan dimana nilai parameter ϕ_1 dan θ_1 diperoleh dari pendugaan parameter model ARIMA(1,0,1) return harga saham Microsoft Corporation (MSFT) 1 Maret 2018 sampai dengan 28 Februari 2022. Data harga saham Microsoft Corporation (MSFT) diakses menggunakan program R dengan perintah `getSymbols("MSFT", from = "2018-03-01", to = "2022-02-28")`.

Tabel 3.1. Data Harga Saham Microsoft

<i>Date</i>	<i>Open</i>	<i>High</i>	<i>Low</i>	<i>Close</i>	<i>Volume</i>
01/03/2018	23.47	23.79	23.02	23.35	12042400
02/03/2018	23.23	23.63	23.08	23.57	10112600
...
25/02/2022	34.00	34.69	33.23	34.45	13405800
28/02/2022	34.29	34.67	33.53	34.36	19162900

3.3 Metode Penelitian

Penelitian ini dilakukan dengan mempelajari buku-buku teks penunjang dan karya ilmiah yang disajikan dalam bentuk jurnal. Adapun langkah-langkah dalam penelitian ini adalah sebagai berikut:

1. Membangkitkan data sebanyak 1000 dengan $\phi_1 = -0.5028$ dan $\theta_1 = 0.4046$ berdasarkan nilai dugaan parameter model ARIMA(1,0,1) *return* harga saham Microsoft Corporation (MSFT) 1 Maret 2018 sampai dengan 28 Februari 2022 kemudian mengidentifikasi efek ARCH dengan uji *Autoregressive Conditional Heteroskedasticity-Lagrange Multiplier* (ARCH-LM).
2. Melakukan transformasi kuadrat pada jika hasil data yang dibangkitkan tidak memiliki efek ARCH kemudian mengidentifikasi kembali efek ARCH dengan uji ARCH-LM.
3. Membuat plot data simulasi yang telah dibangkitkan.
4. Melakukan pemeriksaan stasioneritas data dengan melihat plot *Autocorrelation Function* (ACF) dan hasil uji *Augmented Dickey Fuller* (ADF).

5. Mengidentifikasi model ARIMA dengan melihat lag yang signifikan pada plot *Autocorrelation Function* (ACF) dan plot *Partial Autocorrelation Function* (PACF).
6. Menduga parameter model *Autoregressive Integrated Moving Average* (ARIMA) menggunakan metode *Maximum Likelihood Estimation* (MLE) pada program R.
7. Mengidentifikasi model *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) terbaik dengan melihat nilai *Akaike Information Criterion* (AIC) paling kecil.
8. Menduga parameter model GARCH menggunakan metode *Maximum Likelihood Estimation* (MLE) pada program R.
9. Melakukan peramalan nilai 30 periode selanjutnya menggunakan model GARCH terbaik.

V. KESIMPULAN

Berdasarkan hasil analisa yang telah dilakukan, maka diperoleh kesimpulan sebagai berikut:

1. Pendugaan parameter ω , α_1 , dan β_1 model GARCH(1,1) untuk data simulasi diperoleh $\hat{\omega} = 4.56677$, $\hat{\alpha}_1 = 0.27427$, dan $\hat{\beta}_1 = 0.14406$.
2. Model GARCH terbaik untuk data simulasi adalah GARCH(1,1) :
$$\sigma_t^2 = 4.56677 + 0.27427a_{t-1}^2 + 0.14406\sigma_{t-1}^2$$
3. Hasil peramalan selama 30 hari ke depan yaitu periode 1 Maret 2022 sampai dengan 11 April 2022 pada data simulasi mengalami penurunan.

DAFTAR PUSTAKA

- Akaike, H. 1973. Maximum likelihood identification of Gaussian autoregressive moving average models. *Biometrika*. **60**(2): 255-265.
- Bollerslev, T. 1986. Generalized autoregressive conditional heteroskedasticity. *Journal of econometrics*. **31**(3): 307-327.
- Box, G.E., Jenkins, G.M., Reinsel, G.C., & Ljung, G.M. 2016. *Time series analysis: forecasting and control*. 5th Edition. John Wiley & Sons, New Jersey.
- Brandimarte, P. 2014. *Handbook in Monte Carlo Simulation: applications in financial engineering, risk management, and economics*. John Wiley & Sons, New Jersey.
- Cavanaugh, J.E. & Neath, A.A. 2019. The Akaike information criterion: Background, derivation, properties, application, interpretation, and refinements. *Wiley Interdisciplinary Reviews: Computational Statistics*. **11**(3): 1460.
- Cryer, J.D. & Chan, K.S. 2008. *Time series analysis: with applications in R*. 2nd Edition. Springer, New York.
- Dharmawan, K. 2015. Estimasi nilai avar menggunakan model gjr dan model garch. *Jurnal Matematika*. **5**(2): 117-127.
- Dickey, D.A., & Fuller, W.A. 1979. Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American statistical association*. **74**(366a): 427-431.

- Engle, R.F. 1982. Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Journal of the econometric society*. 987-1007.
- Fadjar, A. 2008. Aplikasi Simulasi Monte Carlo Dalam Estimasi Biaya Proyek. *SMARTek*. 6(4).
- Faustina, R.S., Agoestanto, A., & Hendikawati, P. 2017. Model Hybrid ARIMA-GARCH Untuk Estimasi Volatilitas Harga Emas Menggunakan Software R. *UNNES Journal of Mathematics*. 6(1): 11-24.
- Franses, P.H. & Van Dijk, D. 1996. Forecasting stock market volatility using (non-linear) Garch models. *Journal of Forecasting*. 15(3): 229-235.
- Hogg, R.V., McKean, J.W & Craig, A.T. 1995. *Introduction to mathematical statistics*. 7th Edition. Englewood Hills, New Jersey.
- Hu, S. 2017. Akaike information criterion. *Center for Research in Scientific Computation*. 93.
- Kalengkongan, C. S., Langi, Y.A., & Nainggolan, N. 2020. Analisis Volatilitas Harga Bawang Putih Di Kota Manado Menggunakan Model GARCH. *d'CARTESIAN*. 9(1): 43-49.
- Kanal, F.A., Manurung, T., & Prang, J.D. 2018. Penerapan Model GARCH (Generalized Autoregressive Conditional Heteroscedasticity) dalam Menghitung Nilai Beta Saham Indeks Pefindo25. *Jurnal Ilmiah Sains*. 18(2): 67-74.
- Montgomery, D.C., Jennings, C.L., & Kulahci, M. 2008. *Introduction to time series analysis and forecasting*. John Wiley & Sons, New Jersey.
- Nainggolan, W., Nainggolan, N., & Komalig, H.A. 2018. Analisis Volatilitas Harga Eceran Komoditas Beberapa Pangan Utama di Kota Manado Menggunakan Model ARCH. *Jurnal MIPA*. 7(2): 6-11.
- Ping, P.Y., Miswan, N. H., & Ahmad, M. H. 2013. Forecasting Malaysian gold using GARCH model. *Applied Mathematical Sciences*. 7(58): 2879-2884.

- Priyono, A., Nugroho, D.B., & Susanto, B. 2020. Pemodelan volatilitas return indeks saham menggunakan model GARCH (1, 1) berdistribusi skew-normal, hlm. 46-51. Prosiding Seminar Nasional Matematika, Salatiga.
- Ratnasari, D.H., Tarno, T., & Yasin, H. 2014. Peramalan Volatilitas Menggunakan Model Generalized Autoregressive Conditional Heteroscedasticity in Mean (Garch-m)(Studi Kasus Pada Return Harga Saham PT. Wijaya Karya). *Jurnal Gaussian*. 3(4): 655-662.
- Tjong, W.F. 2001. Aplikasi Statistik Ekstrim dan Simulasi Monte Carlo Dalam Penentuan Beban Rencana Pada Struktur Dengan Umur Guna Tertentu. *Civil Engineering Dimension*. 3(2): 84-88.
- Tsay, R.S. 2010. *Analysis of financial time series*. 3rd Edition. John Wiley & Sons, New Jersey.
- Wei, W.W.S. 2006. *Time Series Analysis: Univariate and Multivariate Methods*. 2nd Edition. Pearson Addison Wesley, Boston.