

**ANALISIS VOLATILITAS DAN PERAMALAN *RETURN* MATA UANG
DIGITAL (*CRYPTOCURRENCY*) DI DUNIA DENGAN METODE
*DYNAMIC CONDITIONAL CORRELATION GENERALIZED
AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY*
(DCC-GARCH)**

(Skripsi)

Oleh

AHMAD HANAFI



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

ABSTRACT

VOLATILITY ANALYSIS AND FORECASTING CRYPTOCURRENCY RETURN IN THE WORLD USING DYNAMIC CONDITIONAL CORRELATION GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY(DCC-GARCH)

By

AHMAD HANAFI

The Dynamic Conditional Correlation Generalized Autoregressive Conditional Heteroscedasticity (DCC-GARCH) is one of the multivariate time series method that can be used if residual which produced by a model still had heteroscedasticity. This research had a purpose to do volatility analysis and forecasting using return cryptocurrency in the world data, which is bitcoin, etherum, and tether. Before applying the DCC-GARCH method, the Vector Autoregressive (VAR) method must be applied first to get the residual data that will be used on DCC-GARCH model. Based on the lowest value of AIC, SBC, HQC, and FPEC, the best model for VAR model is VAR(3). The model that be used on this research is VAR(3) – DCC GARCH (1,1). A high volatility and variation movement is happening on return bitcoin, the volatility of return etherum also had a variation movement although in some of period the movement is tend to constant, meanwhile the volatility is kinda low and had a constant movement is happening on return tether. Forecasting the next 7 days ahead on bitcoin return had increasing value in average around 0,086%, meanwhile on etherum return and tether return the value is tend to decreasing around 0,66% and 0,0028%.

Key words: Multivariate Time Series, Volatility, Forecasting, Vector Autoregressive (VAR), DCC-GARCH, Cryptocurrency.

ABSTRAK

ANALISIS VOLATILITAS DAN PERAMALAN *RETURN* MATA UANG DIGITAL (*CRYPTOCURRENCY*) DI DUNIA DENGAN METODE *DYNAMIC CONDITIONAL CORRELATION GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY* (DCC-GARCH)

Oleh

AHMAD HANAFI

Metode *Dynamic Conditional Correlation Generalized Autoregressive Conditional Heteroscedasticity* (DCC-GARCH) merupakan salah satu metode deret waktu multivariat yang dapat diterapkan apabila residual yang dihasilkan oleh suatu model masih mengandung heteroskedastisitas. Penelitian ini bertujuan untuk melakukan analisis volatilitas dan peramalan pada *return* mata uang digital (*cryptocurrency*) di dunia yaitu bitcoin, etherum, dan tether. Sebelum diterapkannya metode DCC-GARCH, akan diterapkan terlebih dahulu metode *Vector Autoregressive* (VAR) untuk mendapatkan nilai *residual* yang akan digunakan dalam model DCC-GARCH. Berdasarkan nilai AIC, HQC, SBC, dan FPE terkecil, model VAR terbaiknya adalah model VAR(3). Model terbaik dalam penelitian ini yaitu model VAR(3) – DCC GARCH (1,1). Tingkat volatilitas yang tinggi dan pergerakannya bervariasi terdapat pada *return* bitcoin, volatilitas *return* etherum juga pergerakannya cukup bervariasi walaupun pada beberapa periode terdapat pergerakan yang cenderung konstan, sedangkan tingkat volatilitas yang rendah dan pergerakannya cenderung konstan yaitu *return* tether. Peramalan nilai 7 hari kedepan pada *return* bitcoin mengalami kenaikan rata-rata sebesar 0,086%, sedangkan pada *return* etherum dan *return* tether nilainya turun sekitar 0,66% dan 0,0028%.

Kata kunci: Deret Waktu Multivariat, Volatilitas, Peramalan, *Vector Autoregressive* (VAR), DCC-GARCH, *Cryptocurrency*

**ANALISIS VOLATILITAS DAN PERAMALAN *RETURN* MATA UANG
DIGITAL (*CRYPTOCURRENCY*) DI DUNIA DENGAN METODE
*DYNAMIC CONDITIONAL CORRELATION GENERALIZED
AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY*
(DCC-GARCH)**

Oleh
AHMAD HANAFI
2017031001

Skripsi

Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA MATEMATIKA

Pada

Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

Judul Skripsi : **ANALISIS VOLATILITAS DAN PERAMALAN RETURN MATA UANG DIGITAL (CRYPTOCURRENCY) DI DUNIA DENGAN METODE DYNAMIC CONDITIONAL CORRELATION GENERALIZED AUTOREGRESSIVE CONDITIONAL HETEROSCEDASTICITY (DCC-GARCH)**

Nama Mahasiswa : **Ahmad Hanafi**
Nomor Pokok Mahasiswa : **2017031001**
Jurusan : **Matematika**
Fakultas : **Matematika dan Ilmu Pengetahuan Alam**



MENYETUJUI

1. Komisi Pembimbing

Dr. Khoirin Nisa, S.Si., M.Si.
NIP. 19740726 200003 2 001

Dra. Dorrah Aziz, M.Si.
NIP. 19610128 198811 2 001

2. Ketua Jurusan Matematika

Dr. Aang Nuryaman, S.Si., M.Si.
NIP. 19740316 200501 1 001

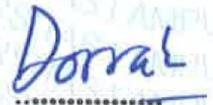
MENGESAHKAN

1. Tim Penguji

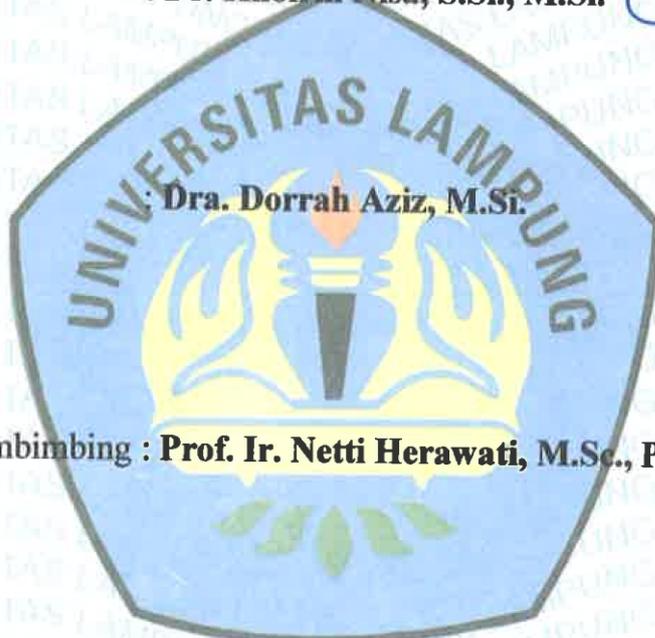
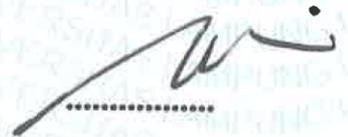
Ketua : **Dr. Khoirin Nisa, S.Si., M.Si.**



Sekretaris : **Dra. Dorrah Aziz, M.Si.**

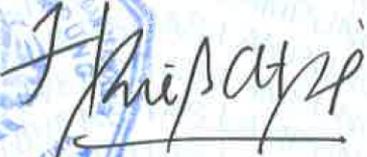


Penguji
Bukan Pembimbing : **Prof. Ir. Netti Herawati, M.Sc., Ph.D.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam




Dr. Eng. Heri Satria, S.Si, M.Si.
NIP. 19711001 200501 1 002

Tanggal Lulus Ujian Skripsi: **17 April 2024**

PERNYATAAN SKRIPSI MAHASISWA

Saya yang bertanda tangan di bawah ini:

Nama : **Ahmad Hanafi**
Nomor Pokok Mahasiswa : **2017031001**
Jurusan : **Matematika**
Judul Skripsi : **Analisis Volatilitas dan Peramalan *Return*
Mata Uang Digital (*Cryptocurrency*) Di Dunia
Dengan Metode *Dynamic Conditional
Correlation Generalized Autoregressive
Conditional Heteroscedasticity (DCC-GARCH)***

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri dan semua tulisan yang tertuang dalam skripsi ini telah mengikuti kaidah karya penulisan ilmiah Universitas Lampung.

Bandar Lampung, 17 April 2024

Penulis



Ahmad Hanafi
NPM. 2017031001

RIWAYAT HIDUP

Penulis bernama lengkap Ahmad Hanafi, anak pertama dari dua bersaudara dari pasangan Bapak Abdul Wahid dan Ibu Renita. Penulis lahir di Tanjung Gading, Bandar Lampung pada tanggal 7 September 2002.

Penulis menyelesaikan pendidikan di Sekolah Dasar Negeri 1 Tanjung Gading pada tahun 2014, Sekolah Menengah Pertama Negeri 12 Bandar Lampung pada tahun 2017, dan Sekolah Menengah Atas Negeri 10 Bandar Lampung pada tahun 2020. Pada tahun 2020, penulis diterima sebagai mahasiswa S1 di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur Seleksi Nasional Masuk Perguruan Tinggi Negeri (SNMPTN).

Selama kuliah, penulis tergabung sebagai anggota unit kegiatan mahasiswa (UKM) Koperasi Mahasiswa Universitas Lampung pada bulan Maret 2021, dan English Society (ESo) Universitas Lampung Divisi Scrabble pada bulan Juli 2021 hingga penulis menyelesaikan masa studi S1.

Penulis mengaplikasikan bidang ilmu yang diperoleh dan mengaplikasikannya ke dalam dunia kerja dengan melaksanakan Kerja Praktik (KP) pada bulan Januari hingga Februari 2023 selama 40 hari di Dinas Ketahanan Pangan, Tanaman Pangan, dan Hortikultura Provinsi Lampung. Penulis juga melakukan pengabdian kepada masyarakat melalui Kuliah Kerja Nyata (KKN) yang dilaksanakan pada bulan Juli 2023 hingga Agustus 2023 selama 40 hari di Desa Agung Timur, Kecamatan Kalirejo, Lampung Tengah.

PERSEMBAHAN

Dengan mengucapkan puji dan syukur atas kehadiran Allah SWT, atas rahmat dan hidayah-Nya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya. Dengan penuh ketulusan dan rasa syukur saya persembahkan rasa terimakasih kepada:

Orang Tua Tercinta

Terimakasih saya ucapkan sebesar-besarnya kepada orang tua tercinta atas segala doa, dukungan, kasih sayang yang telah kalian berikan.

Adik-adik Tersayang

Terimakasih telah menjadi motivasi selama ini agar terus dapat bertahan dan menyelesaikan skripsi dengan baik.

Dosen Pembimbing dan Pembahas

Terimakasih Ibu dosen atas segala arahan, masukan, dan ilmu yang bermanfaat yang telah diberikan.

Orang Tersayang

Terimakasih untuk semua sahabat dan keluarga tersayang yang selalu memotivasi, memberi dukungan, dan menyemangati penulis.

Penulis

Terimakasih karena telah bertahan sejauh ini dan tidak pernah menyerah dalam melalui berbagai macam rintangan dan cobaan yang ada selama ini.

Almamater Tercinta, Universitas Lampung

KATA INSPIRASI

“Tuhanmu lebih Mengetahui apa yang ada dalam hatimu”
(Q.S. Al-Isra : 25)

“Bahwa sesungguhnya bersama kesulitan ada kemudahan”
(Q.S. Al-Insyirah : 5)

“Dan hanya kepada Tuhanmulah hendaknya kamu berharap”
(Q.S. Al-Insyirah : 8)

*“Hate has 4 letters but so does love, enemies has 7 letters but so does friends,
lying has 5 letters but so does truth, failure has 7 letters but so does success, cry
has 3 letters but so does joy, and negativity has 10 letters but so does positivity,
you always have a choice, so choose a better side of it.”*
(Zack Tyree)

“Life is not a problem to be solved, but a reality to be experienced.”
(Soren Kierkegaard)

“You define your own life, dont let other people write your script.”
(Oprah Winfrey)

“Be gentle to yourself, life is cruel enough.”
(Penulis)

SANWACANA

Puji syukur kehadiran Allah SWT, atas segala rahmat dan karunianya sehingga penulis dapat menyelesaikan skripsi dengan judul “Analisis Volatilitas dan Peramalan *Return* Mata Uang Digital (*Cryptocurrency*) Di Dunia Dengan Metode *Dynamic Conditional Correlation Generalized Autoregressive Conditional Heteroscedasticity (DCC-GARCH)*”.

Dalam menyelesaikan skripsi ini, penulis mendapat dukungan, bimbingan dan bantuan dari beberapa pihak. Oleh karena itu, penulis berterima kasih kepada :

1. Ibu Dr. Khoirin Nisa, S.Si., M.Si. selaku dosen pembimbing satu yang senantiasa memberikan arahan, bantuan, dan saran kepada penulis dalam menyusun skripsi.
2. Ibu Dra. Dorrah Aziz, M.Si. selaku dosen pembimbing kedua yang memberikan saran, solusi, serta pembelajaran yang bermanfaat bagi penulis.
3. Ibu Prof. Ir. Netti Herawati, M.Sc., Ph.D. selaku dosen pembahas yang telah memberikan evaluasi, arahan, dan saran dalam perbaikan skripsi.
4. Ibu Prof. Dra. Wamiliana, MA., Ph.D. selaku dosen pembimbing akademik yang telah memberikan bimbingan dan saran kepada penulis selama perkuliahan.
5. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku dekan Fakultas Matematika dan Ilmu Pengetahuan Alam
7. Seluruh dosen, staf dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam.

8. Orang tua tercinta yang selalu mendoakan, memberi dukungan, serta memotivasi penulis dalam menyelesaikan skripsi ini.
9. Adik-adik tersayang yang selalu memotivasi penulis dalam penyusunan skripsi ini.
10. Muhtarom, Fegy, Anisa, Hilal, Sisil, Yulian, dan Winda, terimakasih telah menjadi sahabat terbaik yang selalu membantu, memberi motivasi, menjadi tempat keluh kesah, serta selalu ada selama perkuliahan dan penyelesaian skripsi ini.
11. Zeny, Florene, Alya, dan Amin yang selalu mendengarkan keluh kesah, serta selalu menyemangati dan memotivasi penulis dalam penyelesaian skripsi ini.
12. Maul, Riri, Meylisa, Anisa, dan Wina terimakasih telah selalu ada dan memotivasi penulis dalam menyelesaikan skripsi ini.
13. Agis, Arif, Nurul, Prisca, Sephira, Tama, dan Rahmat terimakasih telah menjadi bagian dari perjalanan kuliah penulis, berbagi cerita, dan memotivasi penulis dalam menyelesaikan skripsi ini.
14. Citra, Maya, Azzura, dan Nadia sebagai teman seperjuangan yang selalu memberikan dukungan dan menjadi bagian dalam perjalanan penyusunan skripsi ini.
15. Seluruh pihak yang telah membantu penulis dalam perkuliahan dan penyusunan skripsi.
16. Dan yang terakhir terimakasih kepada diri sendiri, Ahmad Hanafi yang telah bertahan dan berjuang selama ini, terimakasih karena tidak pernah menyerah dan selalu berusaha selama perkuliahan ini dan selama proses penyusunan skripsi ini selesai.

Penulis menyadari skripsi ini masih jauh dari kata sempurna dan masih terdapat banyak kekurangan baik dalam penyajian maupun teknik penulisan. Oleh sebab itu, saran dan kritikan yang membangun senantiasa penulis harapkan demi menyempurnakan skripsi ini.

Bandar Lampung, 17 April 2024

Penulis

Ahmad Hanafi
NPM. 2017031001

DAFTAR ISI

Halaman

DAFTAR TABEL	xvi
DAFTAR GAMBAR	xvi
I. PENDAHULUAN	1
1.1 Latar Belakang dan Masalah	1
1.2 Tujuan Penelitian	3
1.3 Manfaat Penelitian	4
II. TINJAUAN PUSTAKA	5
2.1 Konsep Matriks.....	5
2.1.1 Matriks	5
2.1.2 Matriks Kovarian.....	6
2.1.3 Matriks Korelasi.....	6
2.2 Konsep Deret Waktu.....	7
2.2.1 Analisis Deret Waktu	7
2.2.2 Analisis Deret Waktu Multivariat	9
2.2.3 Stasioneritas dan Uji ADF.....	9
2.2.4 <i>Autocorrelation Function</i> (ACF)	10
2.2.5 <i>Partial Autocorrelation Function</i> (PACF).....	11
2.3 <i>Vector Autoregressive</i> (VAR).....	11
2.3.1 Model <i>Autoregressive</i> (AR)	11
2.3.2 Model <i>Vector Autoregressive</i> (VAR).....	12
2.3.3 Penduga Parameter Model VAR	13
2.3.4 Diagnostik Model VAR	14
2.4 Uji <i>Lagrange Multiplier</i>	15
2.5 Model <i>Generalized Autoregressive Conditional Heteroscedasticity</i>	16
2.6 Model <i>Multivariate GARCH</i> (M-GARCH)	17
2.7 Model <i>Dynamic Conditional Correlation</i> (DCC)-GARCH	18
2.8 Kriteria Informasi Pemilihan Model Multivariat.....	21
2.9 Evaluasi Model	22
2.10 <i>Data Return</i>	23

III. METODOLOGI PENELITIAN.....	25
3.1 Waktu dan Tempat Penelitian.....	25
3.2 Data Penelitian.....	25
3.3 Metode Penelitian	25
IV. HASIL DAN PEMBAHASAN.....	27
4.1 Analisis Deskriptif Data	27
4.2 Transformasi Data <i>Return</i>	29
4.3 Uji Stasioneritas Data	32
4.4 Estimasi Parameter Model VAR.....	33
4.5 Pendugaan Parameter dan Uji Signifikansi Parameter dan Model VAR.....	34
4.6 Diagnostik Model VAR.....	38
4.7 Uji Efek <i>Autoregressive Conditional Heteroscedasticity</i> (ARCH).....	39
4.8 Pendugaan Parameter Model DCC-GARCH.....	40
4.9 Analisis Volatilitas.....	42
4.10 Evaluasi Model	44
4.11 Peramalan	49
V. KESIMPULAN.....	52
DAFTAR PUSTAKA	53
LAMPIRAN.....	56

DAFTAR TABEL

Tabel	Halaman
1. <i>Range</i> Nilai MAPE	23
2. Karakteristik Data	27
3. Uji ADF Variabel <i>Return</i> Bitcoin, Ethereum, dan Tether	32
4. Kriteria Informasi Model VAR.....	34
5. Pendugaan Parameter Model VAR(3)	35
6. Uji Signifikansi Model VAR Secara Simultan	36
7. Uji Portmanteau <i>Q</i>	38
8. Uji Efek ARCH.....	39
9. Parameter DCC-GARCH (1,1)	40
10. Nilai MAE, MSE, dan MAPE.....	46
11. Peramalan <i>Return</i> Mata Uang Digital (<i>Cryptocurrency</i>).....	49

DAFTAR GAMBAR

Gambar	Halaman
1. Plot Data Harian Penutupan Bitcoin	28
2. Plot Data Harian Penutupan Ethereum	28
3. Plot Data Harian Penutupan Tether.....	29
4. Plot Data <i>Return</i> Penutupan Harian Bitcoin	31
5. Plot Data <i>Return</i> Penutupan Hariam Ethereum	31
6. Plot Data <i>Return</i> Penutupan Harian Tether.....	31
7. Volatilitas <i>Return</i> Bitcoin	42
8. Volatilitas <i>Return</i> Ethereum	42
9. Volatilitas <i>Return</i> Tether.....	43
10. Plot Perbandingan Data Aktual dan Prediksi <i>Return</i> Bitcoin	45
11. Plot Perbandingan Data Aktual dan Prediksi <i>Return</i> Ethereum	45
12. Plot Perbandingan Data Aktual dan Prediksi <i>Return</i> Tether.....	46
13. Plot Korelasi <i>Residual Return</i> Bitcoin dan <i>Return</i> Ethereum.....	47
14. Plot Korelasi <i>Residual Return</i> Bitcoin dan <i>Return</i> Tether	48
15. Plot Korelasi <i>Residual Return</i> Ethereum dan <i>Return</i> Tether	48
16. Plot Data Aktual, Prediksi, dan Peramalan <i>Return</i> Bitcoin	50
17. Plot Data Aktual, Prediksi, dan Peramalan <i>Return</i> Ethereum	50
18. Plot Data Aktual, Prediksi, dan Peramalan <i>Return</i> Tether.....	50

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Analisis deret waktu adalah suatu metode untuk menganalisis data yang terkumpulkan secara berurutan dalam periode waktu tertentu (Chatfield, 2013). Analisis deret waktu dapat membantu seorang peneliti untuk mendapatkan hasil dari penelitiannya yaitu berupa *output* peramalan suatu data deret waktu dalam periode waktu tertentu. Pola data dalam analisis deret waktu terbagi menjadi empat yaitu pola *trend*, musiman, siklis, dan *horizontal*. Model yang merupakan konsep penting dalam analisis deret waktu adalah model *Autoregressive* (AR) dan *Moving Average* (MA). Model-model analisis deret waktu lain akan terbentuk dengan melibatkan model AR ataupun model MA. Analisis deret waktu yang hanya membutuhkan satu variabel saja untuk dianalisis merupakan analisis deret waktu univariat.

Analisis deret waktu yang melibatkan lebih dari satu variabel adalah analisis deret waktu multivariat. Deret waktu multivariat tidak hanya bergantung pada komponen k saja, tetapi terhadap waktu t juga (Wei, 2019). Model multivariat yang cukup terkenal dan sering digunakan oleh banyak peneliti salah satunya adalah model *Vector Autoregressive* (VAR). Model VAR merupakan model yang dikembangkan oleh Christopher Sims pada tahun 1980. Tujuan dari penggunaan model VAR adalah untuk menganalisis hubungan dan interaksi dalam beberapa data deret waktu. Keunggulan model VAR antara lain yaitu bentuk modelnya cukup sederhana, semua variabel dalam model VAR dianggap sebagai variabel

endogen, dan akurasi peramalannya lebih baik daripada model dengan persamaan simultan yang kompleks (Gujarati, 2004).

Data multivariat yang telah dilakukan analisis dengan model VAR tetapi masih memiliki efek heteroskedastisitas, maka estimasi model yang dibentuk masih belum baik untuk dilakukan suatu peramalan. *Multivariate Generalized Autoregressive Conditional Heteroscedasticity* (M-GARCH) merupakan solusi untuk mengatasi permasalahan heteroskedastisitas tersebut. Model M-GARCH merupakan pengembangan dari model GARCH univariat yang dikembangkan oleh Bollerslev pada tahun 1986. Model M-GARCH dalam praktiknya, sangat sering digunakan untuk menganalisis tingkat volatilitas pada data-data multivariat di bidang finansial seperti saham, nilai tukar mata uang, dan mata uang digital (*cryptocurrency*). Selain menganalisis tingkat volatilitas suatu data multivariat, tentunya model M-GARCH juga digunakan untuk melakukan peramalan. Model M-GARCH terbagi lagi secara garis besar menjadi empat kategori antara lain: model dari matriks kondisional varian, model faktor, model dari kondisional varians dan korelasi, dan model dari pendekatan nonparametrik dan semiparametrik. Beberapa model M-GARCH dari empat model tersebut yaitu model *Vector Error Correction* (VEC), model *Baba-Engle-Kraft-Kroner* (BEKK), model *Constant Conditional Correlation* (CCC), model *Generalized Orthogonal* (GO), model *Full Factor* (FF), dan model *Dynamic Conditional Correlation* (DCC).

Umumnya dalam data multivariat akan ada korelasi antar variabel-variabelnya. Data multivariat yang memiliki matriks korelasi kondisional yang konstan dapat dimodelkan dengan model CCC-GARCH. Kelebihan model CCC-GARCH yaitu sangat efektif dalam mengurangi jumlah parameter sehingga dalam modelnya, matriks korelasi kondisional diasumsikan konstan sepanjang waktu (Franke, *et al.*, 2019). Tingkat volatilitas yang bervariasi dan tidak konstan menjadi salah satu kelemahan dari model tersebut.

Model DCC GARCH merupakan model yang dikembangkan oleh Engle dan Sheppard pada tahun 2001. Model tersebut merupakan pengembangan dari model CCC-GARCH dimana memiliki asumsi bahwa matriks korelasi kondisionalnya bergantung dan berubah-ubah sepanjang waktu. DCC-GARCH merupakan model yang cukup baik dalam memodelkan analisis deret waktu multivariat yang memiliki tingkat fluktuasi dan volatilitas yang berubah-ubah sepanjang waktu.

Joyo dan Lefen (2019) menerapkan model DCC-GARCH untuk melakukan analisis pergerakan bursa efek dan mitra dagang di Pakistan . Pada tahun 2022, Yatie melakukan penelitian menggunakan model DCC-GARCH untuk menganalisis kegagalan aset seperti emas, bitcoin, dan etherum pada masa perang Ukraina dan Russia. Model DCC-GARCH juga telah diterapkan oleh Kyriazis, *et al.*, (2019) dalam melakukan estimasi tingkat volatilitas pada mata uang digital (*cryptocurrency*) pada kondisi dimana pasar saham sedang turun.

Berdasarkan beberapa penelitian di atas, maka penulis ingin mengeksplorasi lebih lanjut mengenai model DCC-GARCH. Penelitian ini akan dilakukan untuk melakukan analisis volatilitas dan melakukan peramalan mengenai beberapa data harian mata uang digital (*cryptocurrency*) pada periode 15 Agustus 2022 hingga 20 Oktober 2023. Mata uang digital (*cryptocurrency*) tersebut yaitu bitcoin, etherum, dan tether.

1.2 Tujuan Penelitian

Penelitian ini bertujuan untuk menerapkan model DCC-GARCH pada data *return* harian mata uang digital (*cryptocurrency*) untuk mendapatkan model terbaik yang dapat digunakan untuk melakukan peramalan beberapa periode ke depan serta untuk mengetahui tingkat volatilitas masing-masing nilai mata uang digital (*cryptocurrency*).

1.3 Manfaat Penelitian

Adapun manfaat penelitian ini sebagai berikut :

1. Menambah pengetahuan penulis agar dapat mengembangkan ilmu yang diperoleh selama mengikuti perkuliahan di Jurusan Matematika Universitas Lampung.
2. Mengetahui tahapan analisis menggunakan metode DCC-GARCH.
3. Memberikan informasi kepada pembaca mengenai tingkat volatilitas beberapa mata uang digital (*cryptocurrency*).
4. Menambah wawasan bagi para pembaca mengenai model-model yang ada pada analisis deret waktu seperti DCC-GARCH.
5. Sebagai tambahan sumber referensi bagi para pembaca untuk melakukan penelitian lebih lanjut menggunakan metode DCC-GARCH.

II. TINJAUAN PUSTAKA

2.1 Konsep Matriks

2.1.1 Matriks

Matriks adalah susunan bilangan-bilangan (objek matematika lainnya) yang tersusun dalam bentuk persegi panjang dan diapit oleh tanda kurung “()” atau kurung siku “[]”. Bilangan-bilangan (objek matematika lainnya) yang berada dalam susunan tersebut dinamakan entri (elemen). Matriks umumnya berukuran $m \times n$ dimana m adalah banyaknya baris dan n adalah banyaknya kolom.

Matriks A berukuran $m \times n$ biasanya dituliskan dalam bentuk sebagai berikut:

$$A = \begin{bmatrix} a_{11} & \dots & a_{1n} \\ \vdots & \dots & \vdots \\ a_{m1} & \dots & a_{mn} \end{bmatrix}$$

Operasi-operasi yang ada pada matriks cukup beragam yaitu penjumlahan, perkalian, pembagian, pengurangan, dll. Istilah-istilah yang ada pada matriks antara lain yaitu determinan, transpose, invers, dll.

2.1.2 Matriks Kovarian

Matriks kovarian didefinisikan sebagai bentuk matriks dimana diagonal sebelah kanan merupakan nilai variansnya dan diagonal lainnya merupakan nilai kovariansnya. Bentuk umum dari matriks kovarian dapat dituliskan sebagai berikut:

$$\mathbf{A} = \begin{bmatrix} \text{Var}(x_1) & \cdots & \text{Cov}(x_1, x_n) \\ \vdots & \ddots & \vdots \\ \text{Cov}(x_n, x_1) & \cdots & \text{Var}(x_n) \end{bmatrix}$$

dimana:

1. Untuk suatu populasi

$$\text{Var}(x_n) = \frac{\sum_1^n (x_i - \mu)^2}{n} \quad (2.1)$$

$$\text{Cov}(x_1, x_n) = \frac{\sum_1^n (x_1 - \mu_{x_1})(x_i - \mu_{x_n})}{n} \quad (2.2)$$

2. Untuk suatu sampel

$$\text{Var}(x_n) = \frac{\sum_1^n (x_i - \bar{x})^2}{n-1} \quad (2.3)$$

$$\text{Cov}(x_1, x_n) = \frac{\sum_1^n (x_1 - \bar{x}_1)(x_i - \bar{x}_n)}{n-1} \quad (2.4)$$

Keterangan:

μ : rata-rata dari suatu populasi

\bar{x} : rata-rata dari suatu sampel

n : banyaknya pengamatan atau observasi

x_i : banyaknya observasi pada variabel x_n

2.1.3 Matriks Korelasi

Misalkan y merupakan sebuah vektor acak berukuran $n \times 1$, dan matriks kovarian yang dinotasikan dengan V . Maka, korelasi matriks dari y dinotasikan dengan $R[\rho_{ij}]$ dimana ρ_{ij} dapat ditulis sebagai berikut:

$$\rho_{ij} = \frac{v_{ij}}{\sqrt{v_{ii}v_{jj}}} \quad (2.5)$$

Matriks korelasi dari A berukuran $m \times n$ dapat ditulis sebagai berikut:

$$A = \begin{bmatrix} 1 & \rho_{12} & \cdots & \rho_{1n} \\ \rho_{21} & 1 & \cdots & \rho_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{m1} & \rho_{m2} & \cdots & 1 \end{bmatrix}$$

2.2 Konsep Deret Waktu

2.2.1 Analisis Deret Waktu

Analisis deret waktu adalah suatu metode untuk menganalisis data yang terkumpulkan secara berurutan dalam periode waktu tertentu (Chatfield, 2013). Data yang terkumpulkan dalam analisis deret waktu merupakan data yang terekam dalam suatu interval pada periode waktu tertentu. Menurut Wei (2013), beberapa konsep penting dalam analisis deret waktu yaitu proses stasioneritas, fungsi autokorelasi (ACF), parsial fungsi autokorelasi (PACF), *white noise* dan proses Gaussian, serta proses *Autoregressive* (AR) serta *Moving Average* (MA).

Menurut Chatfield (1984) ada beberapa tujuan dari analisis deret waktu yaitu :

1. Penggambaran (*description*)

Hal yang pertama dilakukan dalam menganalisis data deret waktu biasanya adalah memplot data dan kemudian mencari beberapa ukuran-ukuran deskriptif sederhana dari deret tersebut. Dengan melihat plot kita bisa memperhatikan ada atau tidaknya komponen-komponen tren (*trend*), musiman (*seasonal*), dan komponen siklis (*cyclic*).

2. Pemaparan (*explanation*)

Apabila pengamatan diambil pada dua atau lebih peubah, maka variasi dalam deret waktu bisa digunakan untuk menjelaskan variasi dalam deret waktu lain. Model regresi berganda dan sistem-sistem linear akan berguna dalam tahap ini.

3. Prediksi (*prediction*)

Dengan ketersediaan data deret waktu maka kita bisa meramalkan atau memprediksi nilai-nilai data untuk masa depan. Prediksi atau peramalan ini berhubungan erat dengan pengawasan karena suatu tindakan akan dilakukan oleh suatu perusahaan apabila terjadi sesuatu di luar dari prediksi targetnya.

4. Pengawasan (*control*)

Jika analisis deret waktu telah menunjukkan mutu dari proses produksi maka analisis digunakan untuk melakukan pengawasan terhadap proses. Dalam kendali mutu statistika, observasi diplot dalam diagram kontrol, kemudian pengawas akan mempelajari diagram tersebut.

Menurut Purwanto & Hanief (2020), langkah penting memilih suatu metode dalam analisis deret waktu yang tepat adalah dengan mempertimbangkan jenis pola data, sehingga dengan metode yang paling tepat dengan pola data tersebut dapat diuji.

Pola data dibedakan menjadi empat, yaitu:

1. Pola *trend* (T), yaitu terjadi apabila terdapat kenaikan atau penurunan jangka panjang dalam data.
2. Pola siklis, yaitu pola data yang terjadi apabila datanya dipengaruhi oleh frekuensi ekonomi jangka panjang dan berhubungan dengan siklus bisnis.
3. Pola musiman, yaitu pola data deret waktu yang terjadi apabila suatu deret dipengaruhi oleh faktor musiman. Faktor musiman ini dikarenakan ada permintaan yang dipengaruhi oleh musim sehingga interval pengulangan data ini adalah satu tahun.
4. Pola *horizontal*, yaitu pola data deret waktu yang terjadi apabila nilai data fluktuatif di sekitar nilai rata-rata yang konstan.

2.2.2 Analisis Deret Waktu Multivariat

Analisis deret waktu multivariat merupakan metode pengembangan dari metode analisis deret waktu univariat. Analisis deret waktu multivariat dalam penerapannya membutuhkan minimal 2 variabel data deret waktu untuk dilakukan analisis secara bersamaan. Himpunan deret waktu $Z_{k,t} = [Z_{1,t}, Z_{2,t}, Z_{3,t}, \dots, Z_{k,t}]$ dimana $k = 1, 2, \dots, K$, dan $t = 1, 2, \dots, T$ merupakan deret waktu multivariat. Deret waktu multivariat tidak hanya bergantung pada komponen k saja, tetapi terhadap waktu t juga (Wei, 2019).

2.2.3 Stasioneritas dan Uji ADF

Analisis deret waktu memiliki asumsi yang harus dipenuhi untuk melakukan analisis lebih lanjut yaitu stasioneritas. Stasioneritas merupakan suatu keadaan jika proses pembangkitan yang mendasari suatu deret berkala didasarkan pada nilai tengah konstan dan nilai varians konstan. Dalam suatu data kemungkinan data tersebut tidak stasioner, hal ini dikarenakan nilai rata-rata (*mean*) tidak konstan atau variannya tidak konstan sehingga untuk menghilangkan ketidakstasioneran terhadap *mean*, maka data tersebut dapat dibuat lebih mendekati stasioner dengan cara melakukan penggunaan metode pembedaan atau *differencing*. Stasioneritas dibagi menjadi dua, yaitu stasioner dalam rata-rata dan stasioner dalam ragam.

Menurut Wei (2006), stasioner dalam rata-rata adalah fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak bergantung pada waktu dan varian dari fluktuasi tersebut. Dari bentuk plot data seringkali dapat diketahui bahwa data tersebut tidak stasioner atau tidak stasioner. Sedangkan uji lain untuk melihat kestasioneran data terhadap rata-rata dapat menggunakan uji ADF. Uji ADF juga

dikenal dengan *unit root test*. Pada uji ADF, diasumsikan bahwa *residual* bersifat independent, dengan rata-rata nol, dan tidak ada korelasi antar *residual*.

Adapun persamaan ADF sebagai berikut:

$$\begin{aligned} Z_t &= \rho Z_{t-1} + \varepsilon_t \\ Z_t - Z_{t-1} &= \rho Z_{t-1} - Z_{t-1} + \varepsilon_t \\ \Delta Z_t &= (\rho - 1)Z_{t-1} + \varepsilon_t \\ \Delta Z_t &= \delta Z_{t-1} + \varepsilon_t \end{aligned} \tag{2.6}$$

Hipotesis pada uji ADF sebagai berikut:

$H_0 : \delta = 0$ (data tidak stasioner dalam rata-rata)

$H_1 : \delta \neq 0$ (data stasioner dalam rata-rata)

Apabila uji terhadap δ menghasilkan nilai *p-value* $< \alpha$ maka tolak H_0 , yang berarti bahwa data tidak mengandung akar unit, sehingga data stasioner dalam rata-rata.

Data deret waktu yang tidak stasioner dalam rata-rata dapat diubah menjadi stasioner dalam rata-rata dengan melakukan *differencing*. *Differencing* adalah menghitung perubahan atau selisih nilai pengamatan (Makridakis, dkk., 2000). Nilai yang diperoleh dari *differencing* tadi dicek kembali ke stasionerannya. Jika belum stasioner dalam rata-rata akan di *differencing* kembali hingga data menjadi stasioner.

2.2.4 Autocorrelation Function (ACF)

Autokorelasi adalah korelasi atau hubungan antar data pengamatan suatu data deret waktu. *Autocorrelation Function* (ACF) merupakan suatu hubungan linier antara pengamatan Z_t dengan pengamatan Z_{t-k} (Machmudin dan Brodjol, 2012). *Lag* pada *Autocorrelation Function* hanya 10% yang termasuk pada *lag* awal karena pada 10% *lag* awal akan menghasilkan model *Moving Average* (MA) yang lebih akurat (Andalita dan Irhamah, 2015). Koefisien autokorelasi adalah angka yang

menunjukkan tingkat keeratan hubungan linear antara nilai-nilai dari peubah yang sama dengan periode waktu yang berbeda. Ketidakstasioneran data juga dapat dilihat dari koefisien autokorelasi dan korelogramnya. Koefisien autokorelasi adalah angka yang menunjukkan tingkat keeratan hubungan linear antara nilai-nilai dari peubah yang sama dengan periode waktu yang berbeda. Menurut Wei (2006), koefisien autokorelasi untuk *lag-k* dari data runtun waktu dinyatakan sebagai berikut:

$$r_k = \text{Corr}(Z_t, Z_{t-k}) = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^{n-k} (Z_t - \bar{Z})^2} \quad (2.7)$$

2.2.5 Partial Autocorrelation Function (PACF)

Partial Autocorrelation Function (PACF) berguna untuk menunjukkan seberapa besar hubungan antar nilai variabel yang sama, dengan menganggap pengaruh dari semua kelambatan waktu yang lain adalah konstan (Machmudin dan Brodjol, 2012). *Lag* pada *Partial Autocorrelation Function* hanya 10% yang termasuk pada *lag* awal karena pada 10% *lag* awal akan menghasilkan model AR yang lebih akurat (Andalita dan Irhamah, 2015).

Berikut notasi yang digunakan untuk *Partial Autocorrelation Function* (PACF):

$$r_{kk} = \text{Corr}(Z_t, Z_{t-k} | Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}) \quad (2.8)$$

2.3 Vector Autoregressive (VAR)

2.3.1 Model Autoregressive (AR)

Model *Autoregressive* merupakan kumpulan linier dari data lampau atau data yang didapatkan dari masa lalu dari proses kejadian tak terduga. Model *Autoregressive*

dapat menyatakan suatu ramalan sebagai fungsi nilai-nilai sebelumnya dari deret waktu tertentu.

Model *Autoregressive* (AR) didefinisikan sebagai model yang menjelaskan pergerakan suatu variabel melalui variabel itu sendiri pada periode waktu sebelumnya. Model *Autoregressive* (AR) memiliki bentuk umum dengan ordo p, AR(p) sebagai berikut :

$$Z_t = \theta_0 + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t \quad (2.9)$$

dimana:

θ_0 : suatu konstanta

ϕ_1, \dots, ϕ_p : parameter *autoregressive*

ε_t : nilai galat pada saat ke-t

2.3.2 Model *Vector Autoregressive* (VAR)

Metode *Vector Autoregressive* (VAR) pertama kali diperkenalkan oleh Christopher Sims pada tahun 1980. VAR merupakan persamaan ke- i , model linear variabel ke- i , dimana masing-masing variabel dapat dipaparkan oleh nilai lag nya, dan nilai saat ini serta nilai masa lalu nya dari variabel $i - 1$ pada modelnya (Stock dan Watson, 2001). VAR adalah metode yang digunakan untuk menganalisis data deret waktu yang melibatkan lebih dari satu variabel (Tsay, 2014). Tujuan dari penggunaan metode VAR adalah untuk menganalisis hubungan dan interaksi dalam beberapa data deret waktu.

Model VAR(p) dapat ditulis dalam persamaan berikut :

$$\mathbf{Z}_t = \boldsymbol{\theta}_0 + \sum_{i=1}^p \boldsymbol{\phi}_i \mathbf{Z}_{t-i} + \boldsymbol{\varepsilon}_t \quad (2.10)$$

dimana:

$\boldsymbol{\theta}_0$: vektor konstanta $n \times 1$

\mathbf{Z}_t : vektor $n \times 1$ pada waktu t

\mathbf{Z}_{t-i} : vektor $n \times 1$ pada waktu $t - i$

$\boldsymbol{\phi}_i$: matriks parameter $n \times n$, untuk $i = 1, 2, \dots, p$. p = panjang lag.

$\boldsymbol{\varepsilon}_t$: vektor *shock* dengan ordo $n \times 1$

2.3.3 Penduga Parameter Model VAR

Menurut Tsay (2014), misalkan \mathbf{Z}_t dari model VAR(p) berdistribusi normal multivariat. Dengan $\mathbf{Z}_{p+1:T}$ adalah suatu pengamatan dari $t = p+1$ ke T . Maka fungsi *likelihood* kondisional dapat ditulis sebagai berikut:

$$\begin{aligned} L((\mathbf{Z}_{p+1:T} | \mathbf{Z}_{1:p}, \boldsymbol{\phi}, \boldsymbol{\Sigma})) &= \prod_{t=p+1}^T p(\mathbf{Z}_{p+1:T} | \mathbf{Z}_{1:p}, \boldsymbol{\phi}, \boldsymbol{\Sigma}) \\ &= \prod_{t=p+1}^T p(\mathbf{Z}_t | \mathbf{Z}_{1:p}, \boldsymbol{\phi}, \boldsymbol{\Sigma}) \\ &= \prod_{t=p+1}^T p(\mathbf{Z}_t | \boldsymbol{\phi}, \boldsymbol{\Sigma}) \\ &= \prod_{t=p+1}^T \frac{1}{(2\pi)^{k/2} |\boldsymbol{\Sigma}|^{1/2}} \exp\left[-\frac{1}{2} \mathbf{Z}_t' \boldsymbol{\Sigma}^{-1} \mathbf{Z}_t\right] \\ &= |\boldsymbol{\Sigma}|^{-(T-p)/2} \exp\left[-\frac{1}{2} \sum_{t=p+1}^T \text{tr}(\mathbf{Z}_t' \boldsymbol{\Sigma}^{-1} \mathbf{Z}_t)\right] \end{aligned}$$

Fungsi *log-likelihood* dapat ditulis sebagai berikut:

$$\begin{aligned} L(\boldsymbol{\phi}, \boldsymbol{\Sigma}) &= c - \frac{T-p}{2} \log(|\boldsymbol{\Sigma}|) - \frac{1}{2} \sum_{t=p+1}^T \text{tr}(\mathbf{Z}_t' \boldsymbol{\Sigma}^{-1} \mathbf{Z}_t) \\ &= c - \frac{T-p}{2} \log(|\boldsymbol{\Sigma}|) - \frac{1}{2} \text{tr}(\boldsymbol{\Sigma}^{-1} \sum_{t=p+1}^T \mathbf{Z}_t' \mathbf{Z}_t) \end{aligned}$$

Dimana c merupakan konstan, dan menggunakan sifat bahwa $tr(\mathbf{CD}) = tr(\mathbf{C})tr(\mathbf{D})$ dan $tr(\mathbf{C} + \mathbf{D}) = tr(\mathbf{C}) + tr(\mathbf{D})$. Dengan mempertimbangkan $\sum_{t=p+1}^T \mathbf{Z}'_t \mathbf{Z}_t = \mathbf{A}'\mathbf{A}$ dimana $\mathbf{A} = \mathbf{Y} - \mathbf{X}_\phi$ merupakan matriks *error*, sehingga fungsi *log-likelihood* VAR(p) dapat ditulis sebagai berikut:

$$L(\boldsymbol{\phi}, \boldsymbol{\Sigma}) = c - \frac{t-p}{2} \log(|\boldsymbol{\Sigma}|) - \frac{1}{2} S(\boldsymbol{\phi}) \quad (2.11)$$

Matriks parameter $\boldsymbol{\phi}$ hanya muncul dibagian akhir $L(\boldsymbol{\phi}, \boldsymbol{\Sigma})$, akibatnya memaksimalkan fungsi *log-likelihood* terhadap $\boldsymbol{\phi}$ sama dengan meminimumkan $S(\boldsymbol{\phi})$. Oleh karena itu, pendugaan dengan metode *maximum likelihood* dari $\boldsymbol{\phi}$ sama dengan pendugaan dengan metode *least square*.

2.3.4 Diagnostik Model VAR

Untuk memastikan bahwa model VAR yang digunakan merupakan model yang baik, perlu dilakukan diagnostik model pada model VAR yang telah dipilih. Kriteria yang harus dipenuhi untuk memastikan bahwa model VAR yang terpilih merupakan model yang baik yaitu *residual* tidak berkorelasi atau tidak terjadi autokorelasi pada nilai *residual*. Uji yang digunakan pada data multivariat yaitu uji Portmanteau Q untuk melihat terdapat korelasi antar *residual*.

1. Uji Portmanteau Q

Uji Portmanteau Q digunakan untuk menentukan apakah terdapat korelasi antar *residual*. Uji Portmanteau Q merupakan generalisasi dari uji *Ljung Box* pada kasus multivariat. Uji Portmanteau Q dapat dituliskan sebagai berikut:

$$Q = n(n+2) \sum_{k=1}^k (n-k)^{-1} \hat{\rho}_{k-p-q}^2 \quad (2.12)$$

dimana:

$\hat{\rho}$: autokorelasi *residual*.

k : banyaknya *lag residual*.

n : banyaknya observasi.

Hipotesis pada uji Portmanteau Q sebagai berikut:

H_0 : tidak ada korelasi antar *residual*

H_1 : ada korelasi antar *residual*

Saat $Q > \chi^2_{k-p-q}$ atau $p\text{-value} < \alpha = 0,05$, maka tolak H_0 yang berarti bahwa ada korelasi antar *residual*.

2.4 Uji Lagrange Multiplier

Umumnya pada suatu data, khususnya data finansial masih terdapat keterkaitan antara nilai fluktuasi pada saat ini dengan fluktuasi pada periode sebelumnya atau dengan kata lain masih terdapat efek ARCH. Efek ARCH menunjukkan bahwa pada nilai *residual* yang dihasilkan pada model awal mengalami fluktuasi yang signifikan di sekitar nilai tengahnya (Chand, 2012). Salah satu uji yang dapat digunakan untuk mengetahui apakah terdapat efek ARCH dalam suatu data atau nilai *residual* yaitu uji *Lagrange Multiplier*. Pada kasus model multivariat deret waktu, uji *Lagrange Multiplier* dilakukan masing-masing pada setiap persamaan yang terbentuk (Catani, 2017).

Adapun hipotesis dalam melakukan uji efek ARCH sebagai berikut:

H_0 : *residual* tidak memiliki efek ARCH

H_1 : *residual* memiliki efek ARCH

Kriteria uji nya yaitu bila nilai $p\text{-value} < 0,05$ maka tolak H_0 , yang berarti bahwa *residual* memiliki efek ARCH.

2.5 Model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH)

Residual yang memiliki efek ARCH maka dapat dilanjutkan analisisnya dengan menerapkan model *Autoregressive Conditional Heteroscedasticity* (ARCH). Dalam penerapannya model ARCH cukup sering digunakan untuk menganalisis data-data finansial. Tetapi, kelemahan pada model ARCH yaitu hanya dapat digunakan untuk data yang memiliki tingkat perubahan atau fluktuasi yang sederhana. Menurut (Tsay, 2006), model ARCH tidak efektif digunakan untuk orde yang lebih tinggi. Oleh karena itu, model GARCH dibentuk untuk mengatasi masalah tersebut. Model GARCH merupakan pengembangan dari model ARCH yang diperkenalkan oleh Bollershev pada tahun 1986. Komponen yang sangat penting dalam GARCH yaitu kondisional varians. Model univariat GARCH dapat ditulis sebagai berikut :

$$\varepsilon_t = \sigma_t \epsilon_t \quad (2.13)$$

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i Z_{t-1}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (2.14)$$

dimana :

ε_t : nilai standar *residual* pada waktu t

ϵ_t : galat

σ_t : kondisional standar deviasi pada waktu t

σ_t^2 : kondisional varians pada waktu t

ω : nilai konstan

Z_{t-1}^2 : nilai kuadrat standar *residual* pada waktu $t - 1$

α dan β : parameter

(Berkes, *et al.*, 2003).

2.6 Model *Multivariate* GARCH (M-GARCH)

Model M-GARCH adalah pengembangan dari model *univariate* GARCH. M-GARCH sering kali digunakan untuk menganalisis tingkat volatilitas dalam aspek-aspek finansial, seperti saham, nilai tukar mata uang, dan mata uang digital (*cryptocurrency*). Model M-GARCH dapat digunakan untuk menganalisis interaksi hasil (*return*) tingkat volatilitas dari beberapa variabel dalam periode waktu yang sama (Toraman, *et al.*, 2011).

Model umum M-GARCH dapat dituliskan sebagai berikut :

$$\boldsymbol{\varepsilon}_t = \boldsymbol{\mu}_t + \boldsymbol{\epsilon}_t \quad (2.15)$$

$$\boldsymbol{\epsilon}_t = \mathbf{H}_t^{1/2} \mathbf{z}_t \quad (2.16)$$

dimana:

$\boldsymbol{\varepsilon}_t$: vektor $n \times 1$ nilai residual pada waktu ke- t

$\boldsymbol{\mu}_t$: vektor $n \times 1$ dari *mean-corrected residual* pada waktu ke- t

$\boldsymbol{\epsilon}_t$: vektor *shock* $n \times 1$ pada waktu ke- t

\mathbf{H}_t : matriks $n \times n$ dari kondisional varians $\boldsymbol{\epsilon}_t$ pada waktu ke- t

\mathbf{z}_t : vektor $n \times 1$ dari $\boldsymbol{\epsilon} \sim iid$ dimana $E(\mathbf{z}_t) = 0$, $E(\mathbf{z}_t \mathbf{z}_t^T) = I$

(Orskaug, 2009).

Model M-GARCH terbagi menjadi empat kategori yaitu :

1. Model dari matriks kondisional kovarian

Pada model ini, \mathbf{H}_t dimodelkan secara langsung. Model MGARCH pada kategori ini yaitu model *Vector Error Correction* (VEC) dan model *Baba-Engle-Kraft-Kroner* (BEKK).

2. Model Faktor

Model faktor merupakan model yang terbentuk dari teori ekonomi. Model ini diasumsikan bahwa obeservasinya dibentuk oleh faktor mendasar yaitu kondisional heteroskedastisitas dan memiliki jenis struktur model GARCH. Proses $\boldsymbol{\epsilon}_t$ diasumsikan sebagai proses yang dibentuk oleh sejumlah kecil faktor heteroskedastisitas yang tak terobservasi, sehingga modelnya disebut dengan

model faktor. Beberapa contoh model faktor M-GARCH yaitu model *Generalized Orthogonal (GO)-GARCH*, *Full Factor (FF)-GARCH*, *Generalized Orthogonal Factor (GOF)-GARCH*.

3. Model dari kondisional varians dan korelasi

Model korelasi adalah model yang terbentuk oleh dekomposisi dari matriks kondisional kovarians menjadi kondisional standar deviasi dan korelasi. Model korelasi multivariat yang sederhana yaitu model *Constant Conditional Correlation (CCC)-GARCH*. Beberapa contoh lainnya dari model pada kategori ini antara lain *Extended CCC (ECCC)-GARCH*, *Varying Correlation (VC)-GARCH*, dan *Dynamic Conditional Correlation (DCC)-GARCH*.

4. Model dari pendekatan nonparametrik dan semiparametrik

Model nonparametrik dan semiparametrik membangun sebuah alternatif untuk estimasi parametrik dari struktur kondisional kovarians. Pendekatan ini memiliki kelebihan yaitu tidak memaksakan sebuah struktur partikular pada data.

2.7 Model *Dynamic Conditional Correlation (DCC)-GARCH*

Engle dan Sheppard pada tahun 2001 memperkenalkan model *Dynamic Conditional Correlation (DCC)-GARCH*. Model DCC-GARCH merupakan pengembangan dari model *Constant Conditional Correlation (CCC)-GARCH*. Model DCC-GARCH merupakan model yang dibentuk dari dekomposisi matriks kovarian (\mathbf{H}_t) menjadi matriks kondisional standar deviasi (\mathbf{D}_t) dan matriks korelasi (\mathbf{R}_t). Pada model DCC-GARCH, \mathbf{D}_t dan \mathbf{R}_t nilainya berubah seiring waktu dan tidak konstan.

Misalkan, ada sebuah data ϵ_t , dari n variabel dengan nilai harapannya 0, dan matriks kovarians \mathbf{H}_t , maka model DCC-GARCH dapat dituliskan sebagai berikut:

$$\boldsymbol{\epsilon}_t = \boldsymbol{\mu}_t + \boldsymbol{\epsilon}_t \quad (2.17)$$

$$\boldsymbol{\epsilon}_t = \mathbf{H}_t^{1/2} \mathbf{z}_t \quad (2.18)$$

$$\mathbf{H}_t = \mathbf{D}_t \mathbf{R}_t \mathbf{D}_t \quad (2.19)$$

dimana:

\mathbf{D}_t : matriks diagonal $n \times n$ dari kondisional standar deviasi pada waktu ke- t

\mathbf{R}_t : matriks $n \times n$ kondisional korelasi pada waktu ke- t

Elemen matriks diagonal \mathbf{D}_t merupakan standar deviasi dari model univariat GARCH.

$$\mathbf{D}_t = \begin{bmatrix} \sqrt{h_{11t}} & 0 & \cdots & 0 \\ 0 & \sqrt{h_{22t}} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \sqrt{h_{nnt}} \end{bmatrix}$$

dimana:

$$h_{iit} = \omega_i + \sum_{i=1}^p \alpha_i \epsilon_{i,t-i}^2 + \sum_{j=1}^q \beta_j h_{i,t-j} \quad (2.20)$$

\mathbf{R}_t merupakan matriks korelasi yang simetris sebagai berikut :

$$\mathbf{R}_t = \begin{bmatrix} 1 & \rho_{12,t} & \rho_{13,t} & \cdots & \rho_{1n,t} \\ \rho_{12,t} & 1 & \rho_{23,t} & \cdots & \rho_{2n,t} \\ \rho_{13,t} & \rho_{23,t} & 1 & \ddots & \vdots \\ \vdots & \vdots & \ddots & \ddots & \rho_{n-1,n,t} \\ \rho_{1n,t} & \rho_{2n,t} & \cdots & \rho_{n-1,n,t} & 1 \end{bmatrix}$$

Elemen $\mathbf{H}_t = \mathbf{D}_t \mathbf{R}_t \mathbf{D}_t$ yaitu:

$$[\mathbf{H}_t]_{ij} = \sqrt{h_{it} h_{jt}} \rho_{ij} \quad (2.21)$$

dimana $\rho_{ii} = 1$.

Dalam melakukan spesifikasi bentuk dari \mathbf{R}_t , ada dua syarat yang harus dipertimbangkan yaitu:

1. \mathbf{H}_t harus bernilai positif, karena merupakan matriks kovarian. Untuk memastikan bahwa \mathbf{H}_t bernilai positif, maka \mathbf{R}_t harus bernilai positif juga.
2. Semua elemen dalam matriks korelasi \mathbf{R}_t harus bernilai 1 atau < 1 .

Untuk memastikan bahwa model DCC-GARCH memenuhi kedua persyaratan tersebut, maka \mathbf{R}_t di dekomposisi sehingga berbentuk sebagai berikut:

$$\mathbf{R}_t = \mathbf{Q}_t^{*-1} \mathbf{Q}_t \mathbf{Q}_t^{*-1} \quad (2.22)$$

$$\mathbf{Q}_t = (1 - \alpha - \beta) \bar{\mathbf{Q}} + \alpha \boldsymbol{\epsilon}_{t-1} \boldsymbol{\epsilon}_{t-1}^T + \beta \mathbf{Q}_{t-1} \quad (2.23)$$

dimana $\bar{\mathbf{Q}} = \text{Cov} [\boldsymbol{\epsilon}_t \boldsymbol{\epsilon}_t^T] = E [\boldsymbol{\epsilon}_t \boldsymbol{\epsilon}_t^T]$ merupakan matriks kovarian tak kondisional dari $\boldsymbol{\epsilon}_t$.

$\bar{\mathbf{Q}}$ dapat diestimasi sebagai berikut:

$$\bar{\mathbf{Q}} = \frac{1}{T} \sum_{t=1}^T \boldsymbol{\epsilon}_t \boldsymbol{\epsilon}_t^T \quad (2.24)$$

Parameter α dan β adalah skalar, dan \mathbf{Q}_t^* adalah sebuah matriks diagonal dengan akar kuadrat dari elemen diagonal dari \mathbf{Q}_t .

$$\mathbf{Q}_t^* = \begin{bmatrix} \sqrt{q_{11t}} & 0 & \dots & 0 \\ 0 & \sqrt{q_{22t}} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \dots & 0 & \sqrt{q_{nnt}} \end{bmatrix}$$

dimana:

$$q_{nn,t} = (1 - \alpha - \beta) \bar{q}_{nn} + \alpha \frac{\epsilon_{n,t-1}^2}{\sqrt{h_{nn,t-1}}} \beta q_{nn,t-1} \quad (2.25)$$

$$q_{1n,t} = (1 - \alpha - \beta) \bar{q}_{1n} + \alpha \frac{\epsilon_{1,t-1}^2}{\sqrt{h_{nn,t-1}}} \frac{\epsilon_{n,t-1}^2}{\sqrt{h_{nn,t-1}}} \beta q_{1n,t-1} \quad (2.26)$$

\mathbf{Q}_t harus definit positif, untuk memastikan bahwa \mathbf{R}_t definit positif juga. Untuk memastikan \mathbf{H}_t definit positif, parameter skalar α dan β harus memenuhi: $\alpha \geq 0$, $\beta \geq 0$, dan $\alpha + \beta < 1$.

Struktur korelasi tersebut dapat diperluas menjadi model umum DCC(M,N)
GARCH:

$$\mathbf{Q}_t = (1 - \sum_{m=1}^M \alpha_m - \sum_{n=1}^N \beta_n) \bar{\mathbf{Q}}_t \boldsymbol{\epsilon}_{t-1} \boldsymbol{\epsilon}_{t-1}^T + \sum_{n=1}^N \beta_n \mathbf{Q}_{t-1} \quad (2.27)$$

2.8 Kriteria Informasi Pemilihan Model Multivariat

Untuk mendapatkan model multivariat terbaik dapat dilakukan pemeriksaan kriteria informasi pada model multivariat. Beberapa kriteria informasi dalam pemilihan model antara lain yaitu, *Akaike Information Criterion (AIC)*, *Schwarz Bayesian Criterion (SBC atau BIC)*, *Hannan-Quinn Criterion (HQC)*, dan *Final Prediction Error Criterion (FPEC)*. Model dengan nilai AIC, HQC, dan SBC, dan FPEC terkecil dipilih sebagai model terbaiknya.

$$\text{AIC} = \log(|\tilde{\Sigma}|) + \frac{2s}{N} \quad (2.28)$$

$$\text{HQC} = \log(|\tilde{\Sigma}|) + \frac{2s \log(\log(N))}{N} \quad (2.29)$$

$$\text{SBC} = \log(|\tilde{\Sigma}|) + \frac{s \log(N)}{N} \quad (2.30)$$

$$\text{FPEC} = \left(\frac{N + \frac{s}{k}}{N - \frac{s}{k}} \right)^k |\tilde{\Sigma}| \quad (2.31)$$

dimana:

s : jumlah estimasi parameter

k : jumlah variabel dependen

N : jumlah observasi

$|\tilde{\Sigma}|$: estimasi *maximum likelihood* dari Σ

2.9 Evaluasi Model

Untuk mengukur tingkat ketepatan atau akurasi dalam melakukan peramalan, maka perlu dilakukannya evaluasi model yang digunakan. Alat ukur (metrik) yang dapat digunakan yaitu nilai *Mean Square Error* (MSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Semakin kecil nilai MSE, MAE, dan MAPE menunjukkan bahwa tingkat akurasi peramalan akan semakin baik.

1. *Mean Square Error* (MSE)

MSE merupakan suatu metode untuk menghitung *error* dari rata-rata *error* pada suatu observasi (Willmott & Matsuura, 2005). MSE digunakan untuk mengevaluasi tingkat akurasi peramalan pada suatu metode peramalan. MSE juga dapat digunakan untuk mengetahui tingkat *error* pada data dari model yang digunakan. MSE dapat dihitung dengan menggunakan rumus sebagai berikut:

$$MSE = \frac{\sum_{i=1}^n (z_i - \hat{z})^2}{n} \quad (2.32)$$

Dimana \hat{z} adalah nilai prediksi dan z_i adalah nilai observasi ke- i , serta n adalah banyaknya data.

2. *Mean Absolute Error* (MAE)

MAE adalah nilai rata-rata absolut dari *error* pada peramalan yang nilainya positif. MAE dapat dihitung dengan menggunakan rumus berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |z_i - \hat{z}| \quad (2.33)$$

Dengan \hat{z} adalah nilai prediksi, z_i adalah nilai observasi ke- i , dan n adalah banyaknya data.

3. *Mean Absolute Percentage Error* (MAPE)

Percentage Error (PE) merupakan persentase *error* dari suatu peramalan, dimana:

$$PE = \left(\frac{z_i - \hat{z}}{z_i} \right) \times 100 \quad (2.34)$$

MAPE merupakan nilai rata-rata *error* persentase *absolute* dari suatu peramalan (Hayuningtyas, 2017). MAPE dapat dihitung dengan rumus sebagai berikut:

$$MAPE = \frac{\sum_{i=1}^n |PE|}{n} \quad (2.35)$$

Semakin kecil nilai MAPE berarti nilai taksiran semakin mendekati nilai sebenarnya, atau metode yang dipilih merupakan metode yang tepat dan baik. Dalam MAPE, terdapat *range* nilai yang dapat dijadikan acuan pengukuran mengenai kemampuan dari suatu model peramalan (Hayuningtyas, 2017).

Tabel 1. *Range* Nilai MAPE

<i>Range</i> MAPE	Performa Model
<10%	Kemampuan model peramalan sangat baik
10-20%	Kemampuan model peramalan baik
20-50%	Kemampuan model peramalan layak (cukup baik)
>50%	Kemampuan model peramalan buruk

2.10 Data Return

Return atau tingkat pengembalian adalah selisih antara jumlah yang diterima dengan jumlah yang diinvestasikan dibagi dengan jumlah yang diinvestasikan (Brigham dan Houston, 2006). *Data return* umumnya lebih dipilih menjadi data yang akan dilakukan analisis dibandingkan harga atau nilai asli suatu data oleh peneliti yang akan melakukan penelitian mengenai aspek finansial. *Data return* merupakan aspek yang krusial dalam hal menilai performa dari suatu investasi, dan membantu dalam pengambilan keputusan finansial yang tepat. Hal tersebut dapat membantu seorang investor untuk memantau performa dari investasi yang dijalaninya dan menganalisis harga jual suatu aset berdasarkan nilai historisnya. Untuk melihat tingkat volatilitas dari suatu aset juga sering dilakukan analisisnya

menggunakan data *return*. Volatilitas sering kali didefinisikan sebagai tingkat fluktuasi yang terjadi pada suatu pengamatan yang diamati dalam periode waktu tertentu (Andersen, *et al.*, 2006). Menurut Olkhov (2020), volatilitas didefinisikan sebagai standar deviasi dari suatu distribusi peluang. Tingkat volatilitas yang tinggi dapat diartikan bahwa tingkat ketidakpastian dari hasil (*return*) juga tinggi.

Rumus untuk menghitung *return* secara umum pada suatu data sebagai berikut:

$$Return = \frac{Harga\ Close - Harga\ Open}{Harga\ Open} \quad (2.36)$$

Sedangkan untuk menghitung nilai *return* pada data deret waktu sebagai berikut:

$$Re = \frac{X_t - X_{t-1}}{X_{t-1}} \quad (2.37)$$

dimana:

X_t : nilai observasi pada periode ke- t

X_{t-1} : nilai observasi pada periode ke- t-1

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester ganjil tahun akademik 2023/2024, bertempat di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

3.2 Data Penelitian

Data yang digunakan adalah data *return* dari data *time series* yang diambil dari website <https://finance.yahoo.com> untuk data harian penutupan nilai mata uang digital (*cryptocurrency*) *bitcoin*, *ethereum*, dan *tether* pada periode 15 Agustus 2022 sampai 20 Oktober 2023. Dimana Z_1 merupakan variabel *return* bitcoin, Z_2 merupakan variabel *return* ethereum, dan Z_3 merupakan variabel *return* tether.

3.3 Metode Penelitian

Penelitian dilakukan dengan menggunakan studi literatur secara sistematis yang diperoleh dari buku-buku teks terkait, jurnal, ataupun media pendukung lainnya untuk mendapatkan informasi sebanyak mungkin dalam mendukung penulisan skripsi ini. Penulis menggunakan bantuan *software* R Studio untuk mempermudah dalam melakukan analisis data.

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

1. Melakukan analisis data secara deskriptif.
2. Menghitung data *return*.
3. Menguji kestasioneran data *return* masing-masing mata uang digital (*cryptocurrency*) dengan uji ADF, apabila data tidak stasioner maka lakukan *differencing* hingga data menjadi stasioner.
4. Melakukan estimasi parameter untuk pemilihan model VAR terbaik.
5. Menentukan model VAR terbaik dengan melihat nilai AIC, SBC, HQC, dan FPE terkecil.
6. Pendugaan parameter dengan metode *Maximum Likelihood Estimation* (MLE) dan melakukan uji signifikansi parameter.
7. Melakukan pemeriksaan diagnostik terhadap model VAR terpilih yaitu uji autokorelasi antar nilai *residual* dengan menggunakan uji Portmanteau Q .
8. Melakukan analisis adanya efek heteroskedastisitas dalam model VAR dengan menggunakan uji ARCH *Lagrange Multiplier*.
9. Apabila terdapat efek heteroskedastisitas maka data dapat dimodelkan dengan model DCC-GARCH(1,1) pada nilai *residual* dari model VAR terpilih.
10. Melakukan pendugaan parameter model DCC-GARCH (1,1).
11. Melakukan analisis volatilitas *return* mata uang digital (*cryptocurrency*)
12. Evaluasi model berdasarkan nilai *Mean Square Error* (MSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE).
13. Melakukan peramalan *return* mata uang digital (*cryptocurrency*).

V. KESIMPULAN

Berdasarkan hasil analisis mengenai penerapan metode *multivariate time series* pada data penutupan harian *return* beberapa mata uang digital (*cryptocurrency*) di dunia yaitu bitcoin, etherum, dan tether pada periode 15 Agustus 2022 hingga 20 Oktober 2023, diperoleh kesimpulan sebagai berikut:

1. Model terbaik yang diterapkan dalam penelitian ini untuk melakukan analisis volatilitas dan peramalan *return* mata uang digital (*cryptocurrency*) di dunia adalah model VAR(3) – DCC GARCH (1,1). Model tersebut merupakan model yang baik untuk melakukan peramalan beberapa periode kedepan karena memiliki nilai MAE, MSE, dan MAPE sangat kecil.
2. Tingkat volatilitas yang tinggi berdasarkan kisaran nilainya berada pada variabel *return* etherum, dan terendah adalah variabel *return* tether. Tingkat volatilitas *return* bitcoin merupakan volatilitas yang memiliki pergerakan nilai sangat bervariasi dan cenderung tidak konstan. Volatilitas *return* etherum pergerakannya juga cukup bervariasi, namun pada periode tertentu pergerakannya cenderung konstan. Variabel *return* tether merupakan variabel yang memiliki tingkat volatilitas yang pergerakannya cenderung konstan dan tidak bervariasi. Hasil peramalan 7 hari kedepan masing-masing variabel terdapat pada Tabel 9, dimana pada variabel *return* bitcoin mengalami kenaikan pada nilai-nilainya secara rata-rata sebesar 0,086%, sedangkan variabel *return* etherum mengalami penurunan nilai secara rata-rata sebesar 0,66%, dan *return* tether nilai-nilainya mengalami penurunan nilai secara rata-rata sebesar 0,0028%.

DAFTAR PUSTAKA

- Andalita, I. & Irhamah. 2015. Peramalan Jumlah Penumpang Kereta Api Kelas Ekonomi Kertajaya Menggunakan ANFIS dan ARIMA. *Jurnal Sains dan Seni*. **4**(2): 311-316.
- Andersen, T.G., Bollerslev, T., Christoffersen, P.F., & Diebold, F.X. 2006. *Volatility and Correlation Forecasting*. Elsevier B.V., Amsterdam.
- Brigham, E.F & Houston. 2006. *Fundamental of Financial Management: Dasar-dasar Manajemen Keuangan*. Salemba Empat, Jakarta.
- Berkes, I., Horvath, L., & Kokoszka, P. 2003. GARCH processes: structure and estimation. *Bernoulli*. **9**(2): 201-227.
- Chand, S., Kamal, S., & Ali, I. 2012. Modeling and Volatility Analysis of Share Prices Using ARCH and GARCH Models. *World Applied Science Journal*. **19**(1): 77-82.
- Chatfield, C. 2013. *The Analysis of Time Series: Theory and Practice*. Springer-Science+Business Media, B.V., New York.
- Chatfield, C. 1984. *The Analysis of Time Series: An Introduction*. Chapman and Hall Ltd., London.
- Franke, J., Hardle, K.W., & Hafner, C.M. 2019. *Statistics of Financial Markets*, 5th ed. Springer Nature Switzerland AG, Switzerland.
- Gujarati, D.N. 2004. *Basic Econometrics*, 4th ed. McGraw-Hill Companies, New York.

- Gujarati, D.N. 2006. *Essentials of Econometrics*, 3rd ed. McGraw-Hill Companies, New York.
- Hayuningtyas, R. Y. 2017. Peramalan Persediaan Barang Menggunakan Metode Weighted Moving Average dan Metode Double Exponential Smoothing. *Jurnal PILAR Nusa Mandiri*. **13**(2): 217-219.
- Joyo, A.S. & Lefen, L. 2019. Stock Market Integration of Pakistan with Its Trading Partners: A Multivariate DCC-GARCH Model Approach. *Journal of Sustainability*. **11**(2): 303.
- Kyriazis, N.A., Daskalou, K., Arampatzis, M., Prassa, P., & Papaioannou, E. 2019. Estimating the volatility of cryptocurrencies during bearish markets by employing GARCH models. *Heliyon*. **5**(8): E02239.
- Machmudin, A. & Brodjol, S.S.U. 2012. Peramalan Temperatur Udara di Kota Surabaya dengan Menggunakan ARIMA dan Artificial Neural Network. *Jurnal Sains dan Seni*. **1**(1): 118-123.
- Makridakis, S., Wheelwright, S. C., & McGee, V. E. 2000. *Metode dan Aplikasi Peramalan Jilid I Edisi Revisi (terj.)*. Binapura Aksara, Jakarta.
- Olkhov, V. 2020. *Price, Volatility and The Second-Order Economic Theory*. TVEL, Russia.
- Orskaug, E. 2009. Multivariate DCC-GARCH Model (Tesis). Norwegian University of Science and Technology, Norwegia.
- Purwanto, A. & Hanief, S. 2017. Teknik Peramalan dengan Double Exponential Smoothing pada Distributor Gula. *Jurnal Teknologi Informasi dan Komputer*. **3**(1): 364-365.
- Stock, J.H. & Watson, M.W. 2001. Vector Autoregression. *Journal of Economic Perspectives*. **15**(4): 101-115.
- Toraman, C., Basarir, C., & Bayramoglu, M.F. 2011. Determination of Factors Affecting the Price of Gold: A Study of MGARCH Model. *International Journal of Economics and Business Research*. **2**(4): 37-50.

- Tsay, R.S. 2005. *Analysis of Financial Time Series*. John Wiley & Sons Inc, New Jersey.
- Tsay, R.S. 2014. *Multivariate Time Series Analysis*. John Wiley & Sons Inc, New York.
- Wei, W.W.S. 2006. *Time Series Analysis: Univariate and Multivariate Methods*, 2nd ed. Pearson Education Hall, New Jersey.
- Wei, W.W.S. 2013. *The Oxford Handbook of Quantitative Methods in Psychology: Vol. 2: Statistical Analysis*. Oxford Handbook Online, Oxford University.
- Wei, W.W.S. 2019. *Multivariate Time Series Analysis and Applications*. John Wiley & Sons Ltd., New Jersey.
- Willmott, C. & Matsuura, K. 2005. Advantage of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*. **30**(1): 79-82.
- Yatie, A. 2022. Failure of Gold, Bitcoin, and Ethereum as safe havens during the Ukraina-Russia war. *Bordeaux Economics Working Papers*. **22**(7): 1-12.