

**IMPLEMENTASI MODEL *HYBRID VECTOR AUTOREGRESSIVE
INTEGRATED MOVING AVERAGE (VARIMA)-BIDIRECTIONAL GATED
RECURRENT UNIT (BIGRU)* PADA PERAMALAN HARGA *EXCHANGE-
TRADED FUND (ETF) SPDR GOLD SHARES (GLD) DAN
VANECK GOLD MINERS (GDX)***

Skripsi

Oleh

**ANDI WAHYUDIANSYAH
NPM. 2117031044**



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

ABSTRACT

IMPLEMENTATION OF HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (VARIMA)-BIDIRECTIONAL GATED RECURRENT UNIT (BiGRU) MODEL FOR FORECASTING THE PRICES OF EXCHANGE-TRADED FUND (ETF) SPDR GOLD SHARES (GLD) AND VANECK GOLD MINERS (GDX)

By

Andi Wahyudiansyah

The fluctuation of investment values such as the Exchange-Traded Fund (ETF) SPDR Gold Shares (GLD) and VanEck Gold Miners (GDX) is influenced by various complex economic factors, requiring a model capable of accurately forecasting future values. This study develops a hybrid model based on the Vector Autoregressive Integrated Moving Average (VARIMA) and the Bidirectional Gated Recurrent Unit (BiGRU) to improve the accuracy of ETF price forecasting. The model is designed to address the limitations of VARIMA in capturing nonlinear patterns, as well as the shortcomings of BiGRU in fully understanding the linear structure of the data. The hybrid model in this study is constructed using two approaches. The first approach, the VARIMA-E_BiGRU hybrid model, combines the VARIMA prediction results with the VARIMA residuals which are processed using the BiGRU model. The second approach, the VARIMA-EP_BiGRU hybrid model, integrates both the predictions and residuals of the VARIMA model, with both components further processed by the BiGRU model. The data used in this study consist of historical closing prices of the GLD and GDX ETFs from January 2017 to November 2024. The results show that the VARIMA-EP_BiGRU hybrid model delivers the best forecasting performance compared to both the standalone VARIMA model and the VARIMA-E_BiGRU hybrid model, indicated by the smallest Kolmogorov-Smirnov (KS) statistic and a superior ability to follow the pattern of the updated data. Therefore, the VARIMA-EP_BiGRU hybrid model is the most effective forecasting model compared to both the VARIMA model and the VARIMA-E_BiGRU hybrid model.

Keywords: Hybrid VARIMA-BiGRU, VARIMA, BiGRU, Exchange-Traded Fund, forecasting.

ABSTRAK

IMPLEMENTASI MODEL *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (VARIMA)-BIDIRECTIONAL GATED RECURRENT UNIT (BiGRU)* PADA PERAMALAN HARGA *EXCHANGE-TRADED FUND (ETF) SPDR GOLD SHARES (GLD)* DAN *VANECK GOLD MINERS (GDX)*

Oleh

Andi Wahyudiansyah

Fluktuasi nilai investasi seperti *Exchange-Traded Fund (ETF) SPDR Gold Shares (GLD)* dan *Vaneck Gold Miners (GDX)* dipengaruhi oleh berbagai faktor ekonomi yang kompleks, sehingga dibutuhkan model yang mampu meramalkan nilai di masa mendatang secara akurat. Penelitian ini mengembangkan model *hybrid* berbasis *Vector Autoregressive Integrated Moving Average (VARIMA)* dan *Bidirectional Gated Recurrent Unit (BiGRU)* untuk meningkatkan akurasi peramalan harga ETF. Model ini dirancang untuk mengatasi keterbatasan VARIMA dalam menangkap pola nonlinear, serta kekurangan BiGRU dalam memahami struktur linier data secara utuh. Model *hybrid* dalam penelitian ini dibangun melalui dua pendekatan. Pendekatan pertama yaitu model *hybrid VARIMA-E_BiGRU*, yang menggabungkan hasil prediksi VARIMA dengan residual model VARIMA yang diproses lebih lanjut pada model BiGRU. Sementara pendekatan kedua yaitu model *hybrid VARIMA-EP_BiGRU*, yang menggabungkan antara prediksi dan residual VARIMA yang keduanya diproses lebih lanjut pada model BiGRU. Data yang digunakan pada penelitian ini berupa data historis harga penutupan ETF GLD dan GDX periode Januari 2017 hingga November 2024. Hasil penelitian menunjukkan bahwa model *hybrid VARIMA-EP_BiGRU* memberikan kinerja peramalan terbaik dibandingkan model VARIMA maupun model *hybrid VARIMA-E_BiGRU*, dengan nilai statistik Kolmogorov-Smirnov (KS) terkecil dan kemampuan yang lebih baik dalam mengikuti pola data *update*. Sehingga, model *hybrid VARIMA-EP_BiGRU* merupakan model yang paling efektif dalam melakukan peramalan dibandingkan model VARIMA maupun model *hybrid VARIMA-E_BiGRU*.

Kata kunci: *Hybrid VARIMA-BiGRU, VARIMA, BiGRU, Exchange-Traded Fund, peramalan.*

**IMPLEMENTASI MODEL *HYBRID VECTOR AUTOREGRESSIVE
INTEGRATED MOVING AVERAGE (VARIMA)-BIDIRECTIONAL GATED
RECURRENT UNIT (BIGRU)* PADA PERAMALAN HARGA *EXCHANGE-
TRADED FUND (ETF) SPDR GOLD SHARES (GLD)* DAN
*VANECK GOLD MINERS (GDX)***

ANDI WAHYUDIANSYAH

Skripsi

Sebagai Salah Satu Syarat untuk Memperoleh Gelar
SARJANA MATEMATIKA

Pada

Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam



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

2025

Judul Skripsi : **IMPLEMENTASI MODEL *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (VARIMA) BIDIRECTIONAL GATED RECURRENT UNIT (BIGRU)* PADA PERAMALAN HARGA *EXCHANGE TRADED FUND (ETF) SPDR GOLD - SHARES (GLD)* DAN *VANECK GOLD MINERS (GDX)***

Nama Mahasiswa : **Andi Wahyudiansyah**

Nomor Pokok Mahasiswa : **2117031044**

Program Studi : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**

MENYETUJUI

1. Komisi Pembimbing



Ir. Warsono, M.S., Ph.D.
NIP. 196302161987031003



Dr. Dian Kurniasari, S.Si., M.Sc.
NIP. 196903051996032001

2. Ketua Jurusan Matematika



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

MENGESAHKAN

1. Tim penguji

Ketua : **Ir. Warsono, M.S., Ph.D.**



Sekretaris : **Dr. Dian Kurniasari, S.Si., M.Sc.**



Penguji
Bukan Pembimbing : **Widiarti, S.Si., M.Si.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si.

NIP. 197110012005011002

Tanggal Lulus Ujian Skripsi: **04 Juni 2025**

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : **Andi Wahyudiansyah**
Nomor Pokok Mahasiswa : **2117031044**
Jurusan : **Matematika**
Judul Skripsi : **Implementasi Model *Hybrid Vector Autoregressive Integrated Moving Average (VARIMA)*-*Bidirectional Gated Recurrent Unit (BIGRU)* pada Peramalan Harga *Exchange-Traded Fund (ETF) SPDR Gold Shares (GLD)* dan *VanEck Gold Miners (GDX)***

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

Bandar Lampung, 04 Juni 2025

Penulis,



Andi Wahyudiansyah

RIWAYAT HIDUP

Penulis bernama lengkap Andi Wahyudiansyah, lahir di Tanggamus pada 24 Juni 2003. Penulis merupakan anak kedua dari dua bersaudara dari pasangan Bapak Katmin (alm) dan Ibu Warni.

Penulis menempuh pendidikan Sekolah Dasar (SD) di SD Negeri 3 Dadapan pada tahun 2009-2015, kemudian melanjutkan pendidikan ke Sekolah Menengah Pertama (SMP) di SMP Negeri 1 Sumberejo pada tahun 2015-2018, dan Sekolah Menengah Atas (SMA) di SMA Negeri 1 Sumberejo pada tahun 2018-2021.

Pada tahun 2021 penulis melanjutkan pendidikan di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung, melalui jalur SBMPTN. Selama menjadi mahasiswa, penulis pernah menjadi bagian dari Humas Universitas Lampung sebagai Ilustrator periode November 2023 hingga November 2024.

Sebagai bentuk pengaplikasian ilmu yang didapat, pada bulan Desember 2023 hingga Februari 2024, penulis melaksanakan Kerja Praktik (KP) di Badan Pusat Statistik (BPS) Kabupaten Tanggamus, Provinsi Lampung. Kemudian, pada bulan Juni hingga Agustus 2024, penulis melaksanakan Kuliah Kerja Nyata (KKN) di Desa Srimenanti, Kecamatan Bandar Sribhawono, Kabupaten Lampung Timur, Provinsi Lampung.

KATA INSPIRASI

”Sesungguhnya bersama kesulitan ada kemudahan. Maka apabila engkau telah selesai (dari suatu urusan), tetaplah bekerja keras (untuk urusan yang lain). Dan hanya kepada Tuhanmulah engkau berharap”

(Q.S. Al-Insyirah: 6-8)

”Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya”

(Q.S. Al-Baqarah: 286)

”Tugas kita bukanlah untuk berhasil, tugas kita adalah untuk mencoba, karena di dalam mencoba itulah kita menemukan kesempatan untuk berhasil”

(Buya Hamka)

”Letaknya takdir adalah di batas maksimalnya usaha dan doa”

PERSEMBAHAN

Alhamdulillahirobbil'alamin, puji dan syukur ke hadirat Allah Subhanahu Wa Ta'ala, atas limpahan nikmat serta hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi ini. Shalawat serta salam senantiasa tercurahkan kepada junjungan kita Nabi Muhammad Shallallahu 'Alaihi Wasallam. Penulis mempersembahkan karya ini sebagai bentuk penghargaan dan rasa terima kasih kepada:

Ayah, Ibu, dan Kakak

Terima kasih atas segala pengorbanan, doa, serta dukungannya selama ini. Terima kasih telah menjadi sumber semangat, mengupayakan yang terbaik, dan selalu menguatkan penulis dalam kondisi apapun. Tanpa kasih sayang, keteguhan, dan doa tulus kalian, perjalanan ini tidak akan sampai sejauh ini.

Dosen Pembimbing dan Pembahas

Terima kasih kepada dosen pembimbing dan pembahas yang sudah sangat berjasa membantu, memberikan motivasi, memberikan arahan, serta ilmu yang berharga untuk penulis.

Sahabat-sahabatku

Terima kasih kepada semua orang-orang baik yang telah memberikan pengalaman, semangat, motivasi, serta doa dan dukungan dalam hal apapun.

Almamater Tercinta

Universitas Lampung

SANWACANA

Alhamdulillahilabbil'alamin, puji syukur ke hadirat Allah Subhanahu Wa Ta'ala, atas limpahan rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul "Implementasi Model *Hybrid Vector Autoregressive Integrated Moving Average* (VARIMA)-*Bidirectional Gated Recurrent Unit* (BIGRU) pada Peramalan Harga *Exchange-Traded Fund* (ETF) SPDR Gold Shares (GLD) dan VanEck Gold Miners (GDX)".

Terselesaikannya skripsi ini, tidak lepas dari bimbingan, arahan, motivasi, serta doa dari berbagai pihak. Oleh karena itu, penulis mengucapkan terima kasih kepada:

1. Bapak Ir. Warsono, M.S., Ph.D. selaku Pembimbing I yang dengan penuh dedikasi membimbing penulis melalui setiap tahap penulisan skripsi ini. Bimbingan, motivasi, serta ilmu dan wawasan yang diberikan sangat membantu penulis dalam menyelesaikan skripsi ini.
2. Ibu Dr. Dian Kurniasari, S.Si., M.Sc. selaku Pembimbing II yang telah memberikan ilmu, wawasan, motivasi, serta masukan yang membangun kepada penulis. Dukungan dan arahan yang diberikan sangat membantu penulis dalam menghadapi berbagai tantangan selama proses penulisan skripsi ini.
3. Ibu Widiarti, S.Si., M.Si. selaku Pembahas yang telah meluangkan waktu untuk memberikan kritik, saran, serta masukan yang membangun demi perbaikan skripsi ini.
4. Ibu Dra. Dorrah Azis, M.Si. selaku Pembimbing Akademik atas bimbingan dan arahnya selama penulis menjalani proses 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 Universitas Lampung.
7. Seluruh dosen dan staf Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung, yang telah memberikan wawasan, ilmu, dan pengetahuan yang sangat berharga bagi penulis selama menjalani proses perkuliahan.

8. Ayah, Ibu, Kakak, dan keluarga yang selalu memberikan doa, dukungan moral, serta materiel yang tidak ternilai harganya, sehingga penulis dapat menyelesaikan skripsi ini.
9. Rekan-rekan terbaik penulis selama menjalani perkuliahan, Windi Lestari dan Syarli Dita Anjani yang banyak membantu penulis selama perkuliahan maupun penyelesaian skripsi ini.
10. Teman-teman seperbimbingan, Anggy, Ariz, Dita, Maya, Mey, Nabila, Sherina, Adinda, Anastasia, Dina, Erwin, Fathan, Lusi, Rhea, dan Yulina, yang telah kebersamai dan banyak membantu penulis selama proses penyelesaian skripsi.
11. Teman-teman Jurusan Matematika angkatan 2021 serta Abang dan Yunda yang telah membantu selama proses perkuliahan.
12. Seluruh pihak terkait yang telah membantu menyelesaikan skripsi ini yang tidak dapat penulis sebutkan satu per satu.

Penulis menyadari bahwa masih terdapat banyak kekurangan dalam penulisan skripsi ini. Oleh karena itu, penulis mengharapkan kritik dan saran yang membangun dari semua pihak.

Bandar Lampung, 04 Juni 2025

Andi Wahyudiansyah

DAFTAR ISI

Halaman

DAFTAR ISI	xiii
DAFTAR TABEL	xiv
DAFTAR GAMBAR	xv
I PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	6
1.3 Tujuan Penelitian	7
1.4 Manfaat Penelitian	7
II TINJAUAN PUSTAKA	8
2.1 Penelitian Terkait	8
2.2 Deret Waktu	11
2.2.1 Analisis Deret Waktu	11
2.2.2 Peramalan Deret Waktu	11
2.3 Model Deret Waktu Multivariat	12
2.3.1 Model <i>Vector Autoregressive</i> (VAR)	12
2.3.2 Model <i>Vector Moving Average</i> (VMA)	13
2.3.3 Model <i>Vector Autoregressive Moving Average</i> (VARMA)	13
2.3.4 Model <i>Vector Autoregressive Integrated Moving Average</i> (VARIMA)	14
2.4 Uji Asumsi	14
2.4.1 Stasioneritas Data	14
2.4.2 Residual <i>White Noise</i>	15
2.5 <i>Machine Learning</i>	16
2.5.1 <i>Scaling</i> Data	17
2.5.2 <i>Unscaling</i> Data	17
2.5.3 Fungsi Aktivasi	18
2.6 <i>Deep Learning</i>	19

2.6.1	<i>Recurrent Neural Network (RNN)</i>	19
2.6.2	<i>Gated Recurrent Unit (GRU)</i>	20
2.6.3	<i>Bidirectional Gated Recurrent Unit (BiGRU)</i>	22
2.6.4	<i>Hyperparameter</i>	23
2.7	<i>Hybrid VARIMA-BiGRU</i>	24
2.8	Evaluasi Model	25
2.9	<i>Goodness of Fit</i>	26
III METODE PENELITIAN		27
3.1	Waktu dan Tempat Penelitian	27
3.2	Data dan Alat Penelitian	27
3.3	Metode Penelitian	28
IV HASIL DAN PEMBAHASAN		33
4.1	<i>Input Data</i>	33
4.2	Visualisasi Data	33
4.3	<i>Splitting data</i>	35
4.4	Prediksi dan Peramalan dengan Model VARIMA	35
4.4.1	<i>Preprocessing Data</i>	35
4.4.2	Uji Stasioneritas	36
4.4.3	Identifikasi Model	38
4.4.4	Estimasi Parameter Model	39
4.4.5	Prediksi Model VARIMA	40
4.4.6	Residual Model VARIMA	42
4.4.7	Peramalan Model VARIMA	43
4.5	Prediksi dan Peramalan Model <i>Hybrid VARIMA-E_BiGRU</i>	45
4.5.1	<i>Scaling Data Residual Model VARIMA</i>	45
4.5.2	<i>Hyperparameter Tuning Model E_BiGRU</i>	46
4.5.3	Membangun Model E_BiGRU	47
4.5.4	Prediksi Model E_BiGRU	47
4.5.5	Prediksi Model <i>Hybrid VARIMA-E_BiGRU</i>	49
4.5.6	Peramalan Model E_BiGRU	51
4.5.7	Peramalan Model <i>Hybrid VARIMA-E_BiGRU</i>	52
4.6	Prediksi dan Peramalan Model <i>Hybrid VARIMA-EP_BiGRU</i>	53
4.6.1	<i>Scaling Data Prediksi Model VARIMA</i>	54
4.6.2	<i>Hyperparameter Tuning Model P_BiGRU</i>	54
4.6.3	Membangun Model P_BiGRU	55

4.6.4	Prediksi Model P_BiGRU	56
4.6.5	Prediksi Model <i>Hybrid</i> VARIMA–EP_BiGRU	58
4.6.6	Peramalan Model P_BiGRU	59
4.6.7	Peramalan Model <i>Hybrid</i> VARIMA–EP_BiGRU	60
4.7	<i>Goodness of Fit</i>	62
V	KESIMPULAN	64
5.1	Kesimpulan	64
	DAFTAR PUSTAKA	66

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu	8
2. Data Harga Penutupan ETF GLD dan GDX	28
3. <i>Input</i> Data	33
4. Hasil Pengecekan <i>Missing Value</i>	35
5. Nilai Korelasi antara GLD dan GDX	36
6. Uji Stasioneritas	36
7. Uji Stasioneritas Setelah <i>Differencing</i>	37
8. Pemilihan Model VARIMA Terbaik	39
9. Hasil Prediksi Model VARIMA	40
10. Hasil Prediksi Model VARIMA Setelah <i>Undifferencing</i>	40
11. Evaluasi Model VARIMA	41
12. Residual Model VARIMA	42
13. Hasil Uji <i>Ljung-Box</i>	43
14. Hasil Peramalan Model VARIMA	44
15. <i>Hyperparameter Tuning</i> Model E_BiGRU	46
16. Hasil <i>Hyperparameter Tuning</i> Model E_BiGRU	47
17. Prediksi Model E_BiGRU	47
18. Hasil Prediksi Model E_BiGRU	48
19. Evaluasi Model E_BiGRU	49
20. Hasil Prediksi Model <i>Hybrid</i> VARIMA-E_BiGRU	49
21. Evaluasi Model <i>Hybrid</i> VARIMA-E_BiGRU	50
22. Hasil Peramalan Residual Model E_BiGRU	51
23. Hasil Peramalan Model <i>Hybrid</i> VARIMA-E_BiGRU	52
24. <i>Hyperparameter Tuning</i> Model P_BiGRU	55
25. Hasil <i>Hyperparameter Tuning</i> Model P_BiGRU	55
26. Prediksi Model P_BiGRU	56
27. Hasil Prediksi Model P_BiGRU	56

28. Evaluasi Model P_BiGRU	57
29. Hasil Prediksi Model <i>Hybrid</i> VARIMA-EP_BiGRU	58
30. Evaluasi Model <i>Hybrid</i> VARIMA-EP_BiGRU	59
31. Hasil Peramalan Model P_BiGRU	59
32. Hasil Peramalan Model <i>Hybrid</i> VARIMA-EP_BiGRU	61
33. <i>Goodness of fit</i> GLD	62
34. <i>Goodness of fit</i> GDX	63

DAFTAR GAMBAR

Gambar	Halaman
1. Arsitektur <i>Gated Recurrent Unit</i> (Zhang dkk., 2021)	20
2. Arsitektur <i>Bidirectional Gated Recurrent Unit</i> (Zhang dkk., 2021)	23
3. <i>Flowchart</i> Model <i>Hybrid VARIMA-E_BiGRU</i>	31
4. <i>Flowchart</i> Model <i>Hybrid VARIMA-EP_BiGRU</i>	32
5. Plot Data Historis ETF GLD.	34
6. Plot Data Historis ETF GDX.	34
7. Plot Data Historis ETF GLD dan ETF GDX Setelah <i>Differencing</i>	37
8. Plot ACF dan PACF ETF GLD	38
9. Plot ACF dan PACF ETF GDX	39
10. Plot Hasil Prediksi Model VARIMA	41
11. Plot Residual Model VARIMA	42
12. Plot Hasil Peramalan Model VARIMA	44
13. Plot Residual Prediksi E_BiGRU	48
14. Plot Hasil Prediksi Model <i>Hybrid VARIMA-E_BiGRU</i>	50
15. Plot Hasil Peramalan Residual Model E_BiGRU	51
16. Plot Hasil Peramalan Model <i>Hybrid VARIMA-E_BiGRU</i>	53
17. Plot Hasil Prediksi Model P_BiGRU	57
18. Plot Hasil Prediksi Model <i>Hybrid VARIMA-EP_BiGRU</i>	58
19. Plot Hasil Peramalan Model P_BiGRU	60
20. Plot Hasil Peramalan Model <i>Hybrid VARIMA-EP_BiGRU</i>	61

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Salah satu faktor utama dalam pertumbuhan ekonomi suatu negara adalah investasi. Pergerakan nilai investasi menjadi salah satu aspek krusial yang dipantau oleh para investor, ekonom, maupun pemerintah dalam merumuskan strategi keuangan yang tepat. Fluktuasi nilai investasi dapat dipengaruhi oleh berbagai faktor ekonomi, sehingga dibutuhkan model yang mampu menganalisis data historis dan menghasilkan prediksi maupun peramalan yang akurat. Salah satu pendekatan yang banyak digunakan untuk memahami pola perubahan nilai investasi adalah peramalan deret waktu. Peramalan merupakan proses memperkirakan nilai suatu variabel berdasarkan data historis yang tersedia dari variabel itu sendiri atau variabel lain yang berkaitan (Makridakis dkk., 1983). Adapun deret waktu merupakan urutan pengamatan yang teratur secara waktu atau kronologis pada suatu variabel yang ingin dianalisis (Montgomery dkk., 2015). Sehingga, peramalan deret waktu berfokus pada pemodelan hubungan dalam data historis untuk menghasilkan prediksi nilai di masa mendatang (Zhang, 2003).

Model deret waktu berdasarkan jumlah variabel yang diamati dibagi menjadi dua, yaitu model deret waktu univariat dan multivariat. Deret waktu yang hanya menggunakan satu variabel disebut dengan deret waktu univariat, sedangkan deret waktu yang melibatkan lebih dari satu variabel disebut dengan deret waktu multivariat (Wei, 2006). Suatu variabel dalam analisis deret waktu tidak selalu hanya berdiri sendiri, melainkan dipengaruhi oleh variabel lain yang saling berinteraksi. Oleh karena itu, pendekatan multivariat lebih sesuai untuk menangkap pola deret waktu, sekaligus keterkaitan antar variabel dalam menghasilkan prediksi dan peramalan.

Model *Vector Autoregressive* (VAR) merupakan salah satu model dasar dalam peramalan data deret waktu multivariat. Model VAR adalah pengembangan dari model *Autoregressive* (AR) yang dirancang untuk menganalisis hubungan antara beberapa deret waktu secara simultan. Model VAR merupakan sistem persamaan dinamis, yang mengestimasi nilai pada suatu periode tertentu berdasarkan perubahan variabel tersebut serta variabel lain yang terlibat dalam model pada periode sebelumnya (Rusyana dkk., 2020). Namun, model ini hanya melihat hubungan antar variabel berdasarkan nilai-nilai sebelumnya, tanpa mempertimbangkan pengaruh residual atau kesalahan prediksi dari periode sebelumnya terhadap variabel saat ini.

Model *Vector Moving Average* (VMA) dikembangkan sebagai alternatif dari keterbatasan model VAR yang hanya melihat hubungan antar variabel berdasarkan nilai-nilai sebelumnya. Model VMA merupakan pengembangan dari model *Moving Average* (MA) yang dirancang untuk menganalisis hubungan antara beberapa deret waktu secara simultan. Model VMA merupakan sistem persamaan dinamis, yang mengestimasi nilai pada suatu periode tertentu berdasarkan residual variabel tersebut serta residual variabel lain yang terlibat dalam model pada periode sebelumnya (Rusyana dkk., 2020). Namun, model ini hanya mengandalkan komponen residual, sehingga penggunaannya menjadi terbatas pada kasus tertentu yang lebih menekankan pada efek residual dibandingkan keterkaitan langsung antar variabel dalam jangka panjang.

Model *Vector Autoregressive Moving Average* (VARMA) dikembangkan sebagai pendekatan yang lebih fleksibel dibandingkan model VAR maupun model VMA, dengan mengombinasikan keunggulan keduanya. Model VARMA merupakan pengembangan dari model *Autoregressive Moving Average* (ARMA) yang dirancang untuk menganalisis hubungan antara beberapa deret waktu secara simultan. Model VARMA merupakan sistem persamaan dinamis, yang mengestimasi nilai pada suatu periode tertentu berdasarkan perubahan variabel dan residual dari variabel, baik variabel itu sendiri maupun variabel lain yang terlibat dalam model pada periode sebelumnya (Rusyana dkk., 2020). Namun, penggunaan model ini terbatas pada data yang sudah stasioner.

Data dalam kasus nyata, seringkali bersifat tidak stasioner sehingga memerlukan proses *differencing* untuk menghilangkan tren. Oleh karena itu, dikembangkan model *Vector Autoregressive Integrated Moving Average* (VARIMA), yang

merupakan pengembangan model VARMA dengan menambahkan komponen integrasi (*I*) untuk menangani data tidak stasioner (Rusyana dkk., 2020). Model VARIMA merupakan pengembangan dari model *Autoregressive Integrated Moving Average* (ARIMA) yang dirancang untuk menganalisis hubungan antara beberapa deret waktu secara simultan. Penelitian menggunakan model VARIMA pernah dilakukan oleh Nugroho & Suwanda (2022), untuk meramalkan nilai impor dan ekspor nonmigas di Jawa Barat. Dari penelitian ini diperoleh nilai MAPE sebesar 1,66% untuk impor dan 8,16% untuk ekspor, yang menunjukkan bahwa model VARIMA cukup akurat dalam menangkap pola hubungan antar variabel ekonomi. Namun, sebagai metode statistika klasik pengembangan dari model ARIMA, model VARIMA juga memiliki keterbatasan yang hampir sama dengan model ARIMA. Menurut Zhang (2003), model ini memiliki keterbatasan utama dalam bentuk model yang diasumsikan bersifat linier. Struktur korelasi linier diasumsikan di antara nilai-nilai deret waktu, sehingga pola nonlinier tidak dapat ditangkap oleh model.

Pendekatan berbasis *machine learning* mulai banyak digunakan untuk meningkatkan akurasi dalam memodelkan data yang bersifat nonlinear dalam analisis deret waktu. *Machine learning* merupakan pendekatan komputasi yang belajar dari data atau pengalaman untuk meningkatkan kinerja dalam suatu tugas dan membuat prediksi yang lebih akurat (Alpaydin, 2004). Namun, pendekatan *machine learning* memiliki keterbatasan dalam menangani pola data berurutan, karena tidak dirancang secara khusus untuk memproses keterkaitan antar waktu dalam data deret waktu. Sebagai solusi atas permasalahan ini, dikembangkanlah model *deep learning* yang memiliki kemampuan lebih baik dalam mengenali pola hubungan jangka panjang pada data deret waktu (Fikriaziz dkk., 2024).

Deep learning merupakan pengembangan dari *machine learning* yang berbasis jaringan saraf tiruan dengan setidaknya tiga lapisan, yang memungkinkan model untuk belajar dan beradaptasi dengan data besar serta menyelesaikan berbagai masalah kompleks yang sulit dipecahkan oleh algoritma *machine learning* (Rowan dkk., 2022). Salah satu algoritma *deep learning* yaitu model *Recurrent Neural Network* (RNN), yang mampu mengidentifikasi korelasi tersembunyi dalam data, terutama dalam aplikasi seperti pengenalan suara, pemrosesan bahasa alami, dan peramalan deret waktu. Model RNN unggul dalam menangani masalah yang melibatkan pemodelan urutan karena mampu memproses sejumlah informasi sebagai *input* sekaligus mempertahankan informasi dari langkah sebelumnya,

berkat koneksi berulang yang dimilikinya. Namun, model RNN memiliki keterbatasan dalam menyimpan informasi jangka panjang akibat masalah gradien menghilang (Tian dkk., 2018).

Keterbatasan dalam menyimpan informasi jangka panjang pada model RNN, dapat ditangani dengan arsitektur khusus dari model RNN, yaitu model *Long Short-Term Memory* (LSTM) dan model *Gated Recurrent Unit* (GRU). Model LSTM memiliki tiga gerbang utama yaitu *input gate*, *forget gate*, dan *output gate*, yang memungkinkan model menyaring informasi secara lebih selektif, tetapi memiliki kompleksitas komputasi yang tinggi. Sebagai alternatif, model GRU diperkenalkan dengan struktur yang lebih sederhana, hanya menggunakan dua gerbang utama yaitu *reset gate* dan *update gate*. Meskipun model GRU memiliki arsitektur yang lebih ringan, model ini tetap mampu mengatasi masalah gradien yang menghilang dan sering kali menunjukkan performa yang setara atau lebih baik dibandingkan model LSTM (Zhang dkk., 2021). Meskipun model GRU lebih efisien dibandingkan model LSTM, model ini masih memiliki keterbatasan dalam menangkap konteks informasi dari seluruh urutan data, terutama pada data dengan dependensi kompleks yang bersifat dua arah. Model GRU hanya memproses informasi dalam satu arah (maju), sehingga informasi dari masa depan dalam suatu urutan tidak dapat digunakan untuk meningkatkan akurasi prediksi. Hal ini dapat menjadi kendala pada data deret waktu yang memiliki hubungan dinamis antarperiode, karena pola yang terjadi di masa depan juga dapat memberikan kontribusi penting dalam memahami pola sebelumnya.

Pengembangan arsitektur model GRU yaitu model *Bidirectional Gated Recurrent Unit* (BiGRU), dapat menangani keterbatasan model GRU dalam menangkap informasi dari seluruh urutan data. Model BiGRU memproses informasi dalam dua arah, yaitu *forward* dan *backward*. Struktur *bidirectional* ini terdiri dari dua lapisan tersembunyi yang bergerak berlawanan arah, masing-masing menggunakan unit model GRU. Saat menerima *input*, informasi disalurkan secara bersamaan ke kedua lapisan tersebut, sehingga hasil akhirnya diperoleh dari kombinasi keduanya. Lapisan *forward* GRU memproses informasi dari masa lalu hingga saat ini, sementara *backward* GRU memanfaatkan informasi dari masa depan ke masa sekarang (Zhang dkk., 2021). Pendekatan ini memungkinkan model BiGRU untuk menangkap informasi secara lebih lengkap, sehingga dapat meningkatkan akurasi model dalam memahami pola nonlinear yang lebih kompleks. Penelitian menggunakan model BiGRU pernah dilakukan oleh Tanjung dkk. (2024), untuk

meramalkan data Indeks Harga Konsumen (IHK) Indonesia. Dari penelitian ini diperoleh nilai MAPE 0,24%, yang menunjukkan bahwa model BiGRU memiliki performa yang sangat baik dalam menangkap pola kompleks pada data ekonomi. Menurut Rowan dkk., (2022) model BiGRU mampu menangani data nonlinear secara optimal, namun memerlukan waktu pelatihan cukup lama serta jumlah parameter yang besar untuk mencapai performa terbaik.

Meskipun model BiGRU memiliki keunggulan dalam menangani pola nonlinear, tetapi model ini tetap memiliki keterbatasan ketika digunakan secara mandiri. Menurut Zhang (2003), tidak ada satu model peramalan yang paling efektif dalam setiap situasi. Hal ini disebabkan oleh kompleksitas pola data dalam kasus nyata yang tidak dapat ditangani secara optimal dengan hanya menggunakan satu model. Oleh karena itu, penggabungan berbagai model dapat meningkatkan peluang untuk mengidentifikasi pola yang berbeda dalam data, serta meningkatkan hasil peramalan. Berdasarkan pertimbangan tersebut, akan dirancang sebuah model gabungan yang memanfaatkan kelebihan kedua model dan mengurangi atau mengatasi kekurangan masing-masing. Model *hybrid* adalah model yang mengintegrasikan dua atau lebih model dalam satu sistem untuk meningkatkan akurasi peramalan. Salah satu bentuk penerapannya yaitu penggabungan model VARIMA dan BiGRU.

Beberapa penelitian telah menunjukkan efektivitas pendekatan model *hybrid* dalam berbagai bidang. Aji & Surjandari (2020), melakukan penelitian dengan model *hybrid* VAR-LSTM dan VAR-GRU dalam meramalkan harga transaksi bahan bakar jet di bandara CGK, Tangerang. Dari penelitian ini diperoleh nilai RMSE untuk model VAR: 62,53, LSTM: 989,95, GRU: 794,27, VAR-LSTM: 81,52, dan VAR-GRU: 62,53, serta nilai MAPE untuk model VAR: 2,52%, LSTM: 13,07%, GRU: 10,97%, VAR-LSTM: 1,02%, dan VAR-GRU: 0,60%. Hasil ini menunjukkan bahwa model *hybrid* memiliki performa yang lebih baik dibandingkan model tunggal dalam menangkap pola data yang kompleks. Selain itu, Caliwag & Lim (2019), juga melakukan penelitian dengan model *hybrid* VARMA dan LSTM untuk meramalkan status pengisian dan tegangan keluaran baterai *lithium-ion* dalam aplikasi sepeda motor listrik. Hasil penelitian ini menunjukkan bahwa model *hybrid* VARMA-LSTM memiliki performa terbaik dengan nilai RMSE sebesar 0,161 dibandingkan dengan model VARMA (3,836) dan model LSTM (0,4032).

Model *hybrid* dapat diterapkan dalam berbagai bidang, salah satunya di bidang investasi modern untuk menganalisis dan meramalkan pergerakan harga berbagai instrumen investasi, termasuk *Exchange-Traded Fund* (ETF) yang semakin populer di kalangan investor. Menurut Bursa Efek Indonesia (2024), ETF adalah jenis reksa dana dalam bentuk kontrak investasi kolektif yang unit penyertaannya dapat diperjualbelikan di bursa efek. Instrumen ini menggabungkan prinsip reksa dana dalam pengelolaan dana dan mekanisme saham untuk proses transaksi jual beli. Sehingga ETF memiliki keunggulan diversifikasi secara otomatis atas beberapa saham unggulan dalam satu transaksi, sekaligus fleksibilitas tinggi karena dapat diperjualbelikan selama jam bursa layaknya saham. Instrumen ini dirancang untuk melacak kinerja aset dasar (*underlying asset*) tertentu, seperti indeks saham, komoditas, obligasi, atau sektor industri tertentu. Aset investasi yang berbasis komoditas emas dapat ditemukan dalam ETF seperti *Standard & Poor's Depositary Receipts* (SPDR) *Gold Shares* (GLD) dan *VanEck Gold Miners* (GDX). Keduanya memiliki keterkaitan langsung dengan emas, yang sering dianggap sebagai aset yang aman (*safe haven*) di tengah ketidakstabilan ekonomi. Aset GLD dirancang untuk mencerminkan harga emas fisik, sementara aset GDX dirancang untuk mengikuti kinerja perusahaan-perusahaan tambang emas. Keduanya menawarkan perlindungan nilai terhadap inflasi dan ketidakstabilan ekonomi, tetapi pergerakan harga ETF tersebut seringkali dipengaruhi oleh berbagai faktor makroekonomi yang kompleks, sehingga peramalan harga ETF GLD dan GDX penting bagi investor untuk membuat keputusan investasi yang tepat.

Penelitian menggunakan model *hybrid* VARIMA–BiGRU masih minim dilakukan, khususnya terkait peramalan harga ETF GLD dan GDX. Oleh karena itu, peneliti tertarik untuk melakukan peramalan harga ETF GLD dan GDX dengan menggunakan model *hybrid* VARIMA–BiGRU. Hasil dari penelitian ini dapat memberikan wawasan yang diperlukan para investor untuk memaksimalkan potensi keuntungan sekaligus memitigasi risiko yang ada terkait investasi terutama investasi pada ETF GLD dan GDX.

1.2 Rumusan Masalah

Adapun rumusan masalah dari penelitian ini adalah sebagai berikut:

1. Pembentukan model VARIMA, model *hybrid* VARIMA–E_BiGRU, dan model *hybrid* VARIMA–EP_BiGRU untuk meramalkan harga ETF GLD dan GDX.

2. Hasil peramalan harga ETF GLD dan GDX menggunakan model VARIMA, model *hybrid* VARIMA-E_BiGRU, serta model *hybrid* VARIMA-EP_BiGRU.
3. Perbandingan kinerja model VARIMA, model *hybrid* VARIMA-E_BiGRU, serta model *hybrid* VARIMA-EP_BiGRU dalam melakukan peramalan harga ETF GLD dan GDX.

1.3 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah sebagai berikut:

1. Membangun model VARIMA, model *hybrid* VARIMA-E_BiGRU, serta model *hybrid* VARIMA-EP_BiGRU untuk meramalkan harga ETF GLD dan GDX.
2. Mengetahui hasil peramalan harga ETF GLD dan GDX yang dihasilkan oleh model VARIMA, model *hybrid* VARIMA-E_BiGRU, serta model *hybrid* VARIMA-EP_BiGRU.
3. Membandingkan kinerja model VARIMA, model *hybrid* VARIMA-E_BiGRU, serta model *hybrid* VARIMA-EP_BiGRU dalam melakukan peramalan harga ETF GLD dan GDX.

1.4 Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah sebagai berikut:

1. Memberikan pengetahuan dan wawasan mengenai penggunaan model *hybrid* VARIMA-BiGRU dalam peramalan.
2. Membantu para investor dalam menyusun strategi investasi yang lebih baik terkait investasi pada ETF GLD dan GDX.
3. Sebagai sumber referensi dan literatur tentang peramalan dengan model *hybrid* VARIMA-BiGRU bagi penelitian selanjutnya.

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Penelitian ini mengacu pada berbagai studi terdahulu sebagai landasan dalam menganalisis hasil yang diperoleh. Topik penelitian yang menjadi referensi meliputi model VARIMA, BiGRU, VAR-GRU, VAR-LSTM, dan VARMA-LSTM. Evaluasi performa model dilakukan dengan menggunakan *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Ringkasan dan hasil dari penelitian terdahulu yang dijadikan acuan disajikan pada Tabel 1 berikut:

Tabel 1. Penelitian Terdahulu

No.	Penelitian	Data	Metode	RMSE	MAPE
1.	Pemodelan <i>Multivariate Time Series</i> dengan <i>Vector Autoregressive Integrated Moving Average</i> (Nugroho & Suwanda, 2022)	Data nilai impor dan ekspor nonmigas di Jawa Barat pada Januari 2013-April 2022	VARIMA	–	Impor: 1,66% Ekspor: 8,16%
2.	<i>Implementation of the Bidirectional Gated Recurrent Unit Algorithm on Consumer Price Index Data in Indonesia</i> (Tanjung dkk., 2024)	Data Indeks Harga Konsumen Indonesia dari Januari 2006-Desember 2022	BiGRU	–	0,24%

No.	Penelitian	Data	Metode	RMSE	MAPE
3.	<i>Hybrid Vector Autoregression Recurrent Neural Networks to Forecast Multivariate Time Series Jet Fuel Transaction Price</i> (Aji & Surjandari, 2020).	Data harga transaksi bahan bakar jet di Bandara CGK, Tangerang, Indonesia, Januari 2017-April 2020.	VAR LSTM GRU VAR-LSTM VAR-GRU	VAR: 62,53 LSTM: 989,95 GRU: 794,270 VAR-LSTM: 81,52 VAR-GRU: 62,53	VAR: 2,52% LSTM: 13,07% GRU: 10,97% VAR-LSTM: 1,02% VAR-GRU: 0,60%
4.	<i>Hybrid VARMA and LSTM Method for Lithium-ion Battery State-of-Charge and Output Voltage Forecasting in Electric Motorcycle Applications</i> (Caliwag & Lim, 2019).	Data indikator keamanan baterai pada kendaraan berbasis listrik.	VARMA LSTM VARMA-LSTM	VARMA: 3,836 LSTM: 0,4032 VARMA-LSTM: 0,161	—

Ringkasan dari penelitian-penelitian terkait pada Tabel 1 yaitu sebagai berikut:

- Pemodelan *Multivariate Time Series* dengan *Vector Autoregressive Integrated Moving Average* (Nugroho & Suwanda, 2022).

Penelitian ini menggunakan model VARIMA untuk meramalkan nilai impor dan ekspor nonmigas di Jawa Barat. Data yang digunakan dalam penelitian ini mencakup nilai impor dan ekspor nonmigas di Jawa Barat dari Januari 2013 hingga April 2022.

Tahapan dalam penelitian ini berupa melihat deskripsi statistik setiap variabel, uji stasioneritas data, identifikasi model dengan MACF/MPACF dan AIC, estimasi parameter signifikan, uji asumsi residual, evaluasi akurasi model dengan MAPE, serta peramalan impor-ekspor nonmigas Jawa Barat ke depan. Peramalan dilakukan delapan bulan ke depan dengan hasil MAPE pada model VARIMA (2,1,1) untuk impor sebesar 1,66% dan untuk ekspor sebesar 8,16%.

- b. *Implementation of the Bidirectional Gated Recurrent Unit Algorithm on Consumer Price Index Data in Indonesia* (Tanjung dkk., 2024).

Penelitian ini menggunakan model BiGRU untuk meramalkan nilai Indeks Harga Konsumen Indonesia. Penelitian ini menggunakan data Indeks Harga Konsumen Indonesia dari Januari 2006-Desember 2022.

Tahapan dalam penelitian ini meliputi *preprocessing* data, *splitting* data, membuat model dan evaluasi model dengan menggunakan nilai MAPE. Pada penelitian ini dilakukan peramalan untuk dua belas bulan ke depan dengan nilai MAPE sebesar 0,24%.

- c. *Hybrid Vector Autoregression–Recurrent Neural Networks to Forecast Multivariate Time Series Jet Fuel Transaction Price* (Aji & Surjandari, 2020).

Penelitian ini menggunakan model *hybrid* VAR-LSTM dan VAR-GRU untuk meramalkan harga transaksi bahan bakar jet di bandara CGK, Tangerang, Indonesia. Data yang digunakan mencakup harga minyak mentah global, harga dasar bahan bakar jet, harga bahan bakar lokal, nilai tukar mata uang, dan tingkat inflasi Indonesia dari Januari 2017 hingga April 2020.

Tahapan dalam penelitian ini meliputi pengumpulan data dari berbagai sumber, integrasi dan pembersihan data, transformasi skala data, pembangunan model VAR, pelatihan model LSTM dan GRU, serta evaluasi akurasi dengan MAD, RMSE, MAPE dan akurasi. Model *hybrid* VAR-GRU menghasilkan akurasi tertinggi sebesar 99,40%, diikuti oleh VAR-LSTM dengan akurasi 98,98%. Peramalan dilakukan untuk mengatasi fluktuasi harga akibat pandemi COVID-19 dan hasil penelitian menunjukkan model *hybrid* dapat meminimalkan bias dan menghasilkan peramalan yang lebih akurat dibandingkan model individual.

- d. *Hybrid VARMA and LSTM Method for Lithium-ion Battery State-of-Charge and Output Voltage Forecasting in Electric Motorcycle Applications* (Caliwag & Lim, 2019).

Penelitian ini menggunakan model *hybrid* VARMA-LSTM untuk meramalkan status pengisian dan tegangan keluaran baterai *lithium-ion* dalam aplikasi sepeda motor listrik. Data yang digunakan berasal dari pengukuran aktual sepeda motor listrik yang dikendarai di bawah siklus penggerak CVS-40 dengan suhu operasi 0 °C dan 25 °C.

Tahapan penelitian dimulai dengan pemilihan variabel penjelas melalui analisis korelasi pearson, diikuti oleh dekomposisi komponen linier dan nonlinier data

historis baterai. Model VARIMA digunakan untuk menangkap pola linear, sedangkan LSTM digunakan untuk pola nonlinear. Evaluasi model dilakukan menggunakan nilai RMSE pada data suhu yang berbeda. Hasil penelitian menunjukkan bahwa metode *hybrid* VARIMA-LSTM mampu mencapai tingkat kesalahan RMSE yang lebih rendah dibandingkan penggunaan model individu. Pada suhu 25 °C, RMSE peramalan untuk tegangan keluaran adalah 0,161.

2.2 Deret Waktu

2.2.1 Analisis Deret Waktu

Analisis deret waktu berkaitan dengan teknik untuk menganalisis ketergantungan pada data deret waktu. Adapun deret waktu merupakan serangkaian pengamatan yang dilakukan secara berurutan dalam waktu (Box dkk., 2015). Makridakis dkk. (1983), mengatakan bahwa pada umumnya, suatu data deret waktu terdiri atas satu atau beberapa jenis pola data sebagai berikut:

1. Pola data horizontal
Pola ini terjadi ketika nilai data berfluktuasi di sekitar rata-rata yang konstan. Pola ini sering dikenal sebagai data stasioner.
2. Pola data musiman
Pola ini terjadi apabila serangkaian data dipengaruhi oleh faktor musiman, seperti triwulanan, bulanan, mingguan, atau harian.
3. Pola data siklis
Pola ini ditandai dengan kenaikan dan penurunan data yang tidak terjadi dalam interval waktu yang tetap. Dalam konteks ekonomi, pola ini biasanya disebabkan oleh fluktuasi yang berkaitan dengan siklus bisnis.
4. Pola data tren
Pola ini terjadi saat data menunjukkan peningkatan atau penurunan jangka panjang.

2.2.2 Peramalan Deret Waktu

Peramalan deret waktu merupakan proses yang menggunakan pengamatan masa lalu dari variabel yang sama dikumpulkan dan dianalisis untuk mengembangkan

model yang menjelaskan hubungan yang mendasarinya. Model ini kemudian digunakan untuk memperkirakan nilai deret waktu di masa mendatang (Zhang, 2003). Menurut Montgomery dkk. (2015), terdapat dua metode peramalan, yaitu:

1. Metode peramalan kualitatif

Metode ini bersifat subjektif dan bergantung pada penilaian dari para ahli. Peramalan kualitatif sering digunakan ketika data historis yang tersedia terbatas atau bahkan tidak ada. Meskipun analisis data dapat dilakukan, dasar peramalan dalam metode ini adalah penilaian yang bersifat subjektif.

2. Metode peramalan kuantitatif

Metode ini menggunakan data historis dan model peramalan untuk mengidentifikasi pola dalam data serta menggambarkan hubungan statistik antara nilai sebelumnya dan nilai saat ini dari variabel yang diamati. Model ini kemudian digunakan untuk memproyeksikan pola-pola tersebut ke masa depan, atau dengan kata lain, model ini digunakan untuk memperpanjang pola perilaku masa lalu dan saat ini ke depan.

2.3 Model Deret Waktu Multivariat

2.3.1 Model *Vector Autoregressive* (VAR)

Model VAR adalah pengembangan dari model *Autoregressive* (AR) yang dirancang untuk menganalisis hubungan antara beberapa deret waktu secara simultan. Model VAR merupakan sistem persamaan dinamis, yang mengestimasi nilai pada suatu periode tertentu berdasarkan perubahan variabel tersebut serta variabel lain yang terlibat dalam model pada periode sebelumnya (Rusyana dkk., 2020). Bentuk umum dari model VAR ditulis pada Persamaan (2.1) sebagai berikut (Wei, 2006):

$$\mathbf{Z}_t = \Phi_1 \mathbf{Z}_{t-1} + \Phi_2 \mathbf{Z}_{t-2} + \cdots + \Phi_p \mathbf{Z}_{t-p} + \mathbf{a}_t \quad (2.1)$$

dengan:

$$\mathbf{Z}_t = [Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^T \text{ vektor deret waktu stasioner}$$

ukuran $N \times 1$

$$\Phi_1, \dots, \Phi_p = \text{matriks parameter } \textit{Autoregresif} \text{ berukuran } N \times N$$

$$\mathbf{a}_t = [a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T \text{ vektor residual ukuran } N \times 1$$

2.3.2 Model Vector Moving Average (VMA)

Model VMA adalah pengembangan dari model *Moving Average* (MA) yang dirancang untuk menganalisis hubungan antara beberapa deret waktu secara simultan. Model VMA merupakan sistem persamaan dinamis, yang mengestimasi nilai pada suatu periode tertentu berdasarkan residual variabel tersebut serta residual variabel lain yang terlibat dalam model pada periode sebelumnya (Rusyana dkk., 2020). Bentuk umum dari model VMA ditulis pada Persamaan (2.2) sebagai berikut (Wei, 2006):

$$\mathbf{Z}_t = \mathbf{a}_t - \Theta_1 \mathbf{a}_{t-1} - \Theta_2 \mathbf{a}_{t-2} - \cdots - \Theta_q \mathbf{a}_{t-q} \quad (2.2)$$

dengan:

$$\begin{aligned} \mathbf{Z}_t &= [Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^T \text{ vektor deret waktu stasioner} \\ &\quad \text{ukuran } N \times 1 \\ \Theta_1, \dots, \Theta_q &= \text{matriks parameter } \textit{Moving Average} \text{ berukuran } N \times N \\ \mathbf{a}_t &= [a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T \text{ vektor residual ukuran } N \times 1 \end{aligned}$$

2.3.3 Model Vector Autoregressive Moving Average (VARMA)

Model VARMA adalah pengembangan dari model *Autoregressive Moving Average* (ARMA) yang dirancang untuk menganalisis hubungan antara beberapa deret waktu secara simultan. Model VARMA merupakan sistem persamaan dinamis, yang mengestimasi nilai pada suatu periode tertentu berdasarkan perubahan variabel dan residual variabel itu sendiri, maupun perubahan variabel lain dan residual dari variabel lain yang terlibat dalam model pada periode sebelumnya (Rusyana dkk., 2020). Bentuk umum dari model VARMA ditulis pada Persamaan (2.3) sebagai berikut (Wei, 2006):

$$\mathbf{Z}_t = \Phi_1 \mathbf{Z}_{t-1} + \cdots + \Phi_p \mathbf{Z}_{t-p} + \mathbf{a}_t - \Theta_1 \mathbf{a}_{t-1} - \cdots - \Theta_q \mathbf{a}_{t-q} \quad (2.3)$$

dengan:

$$\begin{aligned} \mathbf{Z}_t &= [Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^T \text{ vektor deret waktu stasioner} \\ &\quad \text{ukuran } N \times 1 \\ \Phi_1, \dots, \Phi_p &= \text{matriks parameter } \textit{Autoregresif} \text{ berukuran } N \times N \\ \Theta_1, \dots, \Theta_q &= \text{matriks parameter } \textit{Moving Average} \text{ berukuran } N \times N \\ \mathbf{a}_t &= [a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T \text{ vektor residual ukuran } N \times 1 \end{aligned}$$

2.3.4 Model Vector Autoregressive Integrated Moving Average (VARIMA)

Model VARIMA adalah pengembangan dari model VARMA yang melalui proses *differencing* untuk menstasionerkan data (Rusyana dkk., 2020). Bentuk umum dari model VARIMA ditulis pada Persamaan (2.4) sebagai berikut (Harvey, 2006):

$$\Delta^d \mathbf{Z}_t = \Phi_1 \Delta^d \mathbf{Z}_{t-1} + \cdots + \Phi_p \Delta^d \mathbf{Z}_{t-p} + \mathbf{a}_t - \Theta_1 \mathbf{a}_{t-1} - \cdots - \Theta_q \mathbf{a}_{t-q} \quad (2.4)$$

dengan:

$$\begin{aligned} \mathbf{Z}_t &= [Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^T \text{ vektor deret waktu stasioner} \\ &\quad \text{ukuran } N \times 1 \\ \Delta^d &= \text{operator differencing} \\ \Phi_1, \dots, \Phi_p &= \text{matriks parameter Autoregresif berukuran } N \times N \\ \Theta_1, \dots, \Theta_q &= \text{matriks parameter Moving Average berukuran } N \times N \\ \mathbf{a}_t &= [a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T \text{ vektor residual ukuran } N \times 1 \end{aligned}$$

2.4 Uji Asumsi

2.4.1 Stasioneritas Data

Stasioneritas adalah kondisi ketika data deret waktu tidak menunjukkan tren kenaikan atau penurunan. Data tersebut berfluktuasi di sekitar nilai rata-rata dan variansi yang konstan, tanpa dipengaruhi oleh interval waktu tertentu (Makridakis dkk., 1983). Uji stasioneritas data dapat dilakukan dengan pengujian akar unit, salah satunya dengan metode *Augmented Dickey-Fuller* (ADF). Uji ADF bertujuan untuk mendeteksi keberadaan akar unit. Data yang stasioner tidak memiliki akar unit, sedangkan data yang tidak stasioner sebaliknya. Tahapan dalam uji ADF adalah sebagai berikut (Dickey & Fuller, 1979):

1. Hipotesis

- H_0 : terdapat akar unit (data tidak stasioner)
- H_1 : tidak terdapat akar unit (data stasioner)

2. Taraf signifikansi

$$\alpha = 5\%$$

3. Statistik Uji

Uji ADF menggunakan statistik uji yang ditulis pada Persamaan (2.5) sebagai

berikut:

$$ADF_{hitung} = \frac{\hat{\gamma}}{Se(\hat{\gamma})} \quad (2.5)$$

dengan:

$(\hat{\gamma})$ = nilai duga parameter *Autoregressive*
 $Se(\hat{\gamma})$ = standar *error* dari $\hat{\gamma}$

4. Kriteria Uji

- Tolak H_0 jika statistik uji $ADF_{hitung} < ADF_{tabel}$ atau $p\text{-value} < \alpha$
- Tidak tolak H_0 jika statistik uji $ADF_{hitung} > ADF_{tabel}$ atau $p\text{-value} > \alpha$

5. Keputusan

6. Kesimpulan

Menurut Makridakis dkk. (1983), jika hasil uji ADF menunjukkan bahwa data tidak stasioner, maka data tersebut perlu ditransformasikan menjadi stasioner dengan melakukan *differencing*. Bentuk umum *differencing* ditulis pada Persamaan (2.6) sebagai berikut:

$$\Delta^d Y_t = Y_t - Y_{t-d} \quad (2.6)$$

dengan:

Y_t = pengamatan pada waktu ke- t
 Y_{t-d} = pengamatan pada waktu ke- $(t-d)$
 d = orde *differencing*

2.4.2 Residual White Noise

Uji asumsi residual dilakukan untuk memastikan bahwa model yang diperoleh layak digunakan. Uji residual *white noise* bertujuan untuk mengetahui apakah residual yang dihasilkan bersifat independen dan memiliki karakteristik yang identik. Uji asumsi residual *white noise*, dapat dilakukan dengan metode *Ljung-Box*. Pengujian yang dilakukan sebagai berikut (Ljung & Box, 1978):

1. Hipotesis

- H_0 : residual memenuhi asumsi *white noise*
- H_1 : residual tidak memenuhi asumsi *white noise*

2. Taraf signifikansi

$$\alpha = 5\%$$

3. Statistik Uji

Uji asumsi residual *white noise* menggunakan statistik uji *Ljung-Box* yang ditulis pada Persamaan (2.7) sebagai berikut:

$$Q = n(n+2) \sum_{i=1}^m \frac{\rho_i^2}{(n-i)} \quad (2.7)$$

dengan:

n = banyaknya data pengamatan

ρ_i = autokorelasi *lag* ke i

m = jumlah *lag*

4. Kriteria Uji

- Tolak H_0 jika statistik uji $Q > \chi_{1-\alpha, m}^2$ atau $p\text{-value} < \alpha$
- Tidak tolak H_0 jika statistik uji $Q < \chi_{1-\alpha, m}^2$ atau $p\text{-value} > \alpha$

5. Keputusan

6. Kesimpulan

2.5 Machine Learning

Machine learning dapat didefinisikan sebagai pendekatan komputasi yang belajar dari data atau pengalaman untuk meningkatkan kinerja dalam suatu tugas dan membuat prediksi yang lebih akurat. Algoritma *machine learning* dapat dibedakan berdasarkan jenis pengalaman yang dimanfaatkan selama proses pembelajaran, yaitu (Alpaydin, 2004):

1. Supervised Learning

Supervised learning adalah metode pembelajaran yang menggunakan data berlabel, setiap *input* memiliki target atau kelas yang telah ditentukan. Model dilatih dengan data ini agar dapat mengenali pola dan membuat prediksi yang akurat untuk data baru yang belum pernah dilihat sebelumnya. Data yang digunakan diharapkan dapat melatih algoritma selama proses pembelajaran untuk menghasilkan model klasifikasi atau prediksi yang optimal (Alpaydin, 2004).

2. Unsupervised Learning

Unsupervised learning adalah metode pembelajaran yang menggunakan data tanpa label, kelas, atau target yang telah ditentukan. Karena tidak memiliki data latih, algoritma harus secara mandiri menemukan pola atau struktur tersembunyi dalam data untuk mengelompokkan data ke dalam beberapa kategori. Pendekatan ini bertujuan untuk menemukan pola atau hubungan tersembunyi dalam data yang belum berlabel (Alpaydin, 2004).

3. Reinforcement Learning

Reinforcement Learning adalah metode pembelajaran yang memungkinkan suatu agen belajar dengan cara mencoba berbagai tindakan dalam sebuah lingkungan dan mendapatkan umpan balik berupa *reward* (hadiah) atau *punishment* (hukuman). Agen akan terus menyesuaikan tindakannya berdasarkan umpan balik yang diterima agar dapat memilih strategi terbaik untuk mencapai tujuan. Pendekatan ini banyak digunakan dalam sistem pengambilan keputusan otomatis, seperti robotika, game, dan optimasi proses (Alpaydin, 2004).

2.5.1 Scaling Data

Scaling data adalah metode untuk mengubah nilai numerik dalam *dataset* ke skala yang lebih umum. Teknik ini bertujuan untuk meminimalkan kesalahan atau ketidaksesuaian data serta mengurangi ukuran *dataset* tanpa memengaruhi nilai aslinya. *Scaling* data dilakukan untuk membantu mempercepat proses pembelajaran dalam *machine learning*. Salah satu metode *scaling* data yang dapat digunakan adalah *min-max scaler*. Metode ini digunakan ketika data aktual memiliki rentang nilai masih cukup besar. *Min-max scaler* mengubah nilai data dari rentang aslinya ke dalam interval $[0, 1]$. Transformasi ini memastikan setiap fitur memiliki kontribusi yang seimbang dalam proses pelatihan (Zhang dkk., 2021). Persamaan untuk *min-max scaler* ditulis pada Persamaan (2.8) sebagai berikut:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.8)$$

dengan:

- x' = nilai hasil *scaling*
- x = nilai data aktual
- x_{min} = nilai minimum data aktual
- x_{max} = nilai maksimum data aktual

2.5.2 Unscaling Data

Unscaling data adalah tahapan yang mengubah nilai hasil prediksi kembali ke dalam skala aslinya untuk mendapatkan nilai yang diharapkan (Lattifia dkk, 2022). *Unscaling* data perlu dilakukan karena pada tahap *preprocessing* sebelumnya, data

telah di-*scaling* untuk meningkatkan kinerja model. Sehingga, nilai prediksi yang dihasilkan masih dalam skala yang telah diubah, maka perlu dikembalikan ke skala aslinya agar dapat dibandingkan dengan data aktual dan dievaluasi dengan baik. Persamaan *unscaling* data untuk *min-max scaler* ditulis pada Persamaan (2.9) sebagai berikut:

$$x_i = y_i(\max(x) - \min(x)) + \min(x) \quad (2.9)$$

dengan:

- x_i = nilai data aktual
- y_i = nilai hasil *output*
- $\min(x)$ = data dengan nilai minimum
- $\max(x)$ = data dengan nilai maksimum

2.5.3 Fungsi Aktivasi

Fungsi aktivasi merupakan komponen penting dalam jaringan saraf tiruan yang berperan dalam mengubah sembarang *input* menjadi *output* tertentu. Informasi dalam jaringan saraf tiruan diterima melalui lapisan *input*, kemudian fungsi aktivasi bertugas untuk menentukan apakah suatu neuron akan diaktifkan atau tidak. Sehingga, kinerja jaringan saraf tiruan sangat bergantung pada bobot serta hubungan antara *input* dan *output* dari fungsi aktivasi (Pratiwi dkk., 2020). Proses ini memungkinkan data yang awalnya bersifat nonlinear diubah menjadi lebih linear, sehingga mempermudah pemrosesan pada lapisan jaringan berikutnya. Beberapa fungsi aktivasi yang dapat digunakan adalah sebagai berikut:

1. Fungsi sigmoid (fungsi logistik)

Fungsi sigmoid adalah fungsi yang berperan dalam memperbarui informasi (Ivan & Purnomo, 2022). Fungsi ini menerima sembarang nilai real sebagai *input* dan menghasilkan *output* dalam rentang 0 hingga 1. Persamaan untuk fungsi sigmoid ditulis pada Persamaan (2.10) sebagai berikut:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.10)$$

dengan:

- e = bilangan *euler*
- x = data

2. Fungsi tangen hiperbolik (fungsi tanh)

Fungsi tanh adalah fungsi yang digunakan untuk menghasilkan vektor nilai baru (Ivan & Purnomo, 2022). Fungsi ini menerima sembarang nilai real

sebagai *input* dan menghasilkan *output* dalam rentang nilai antara -1 hingga 1. Persamaan untuk fungsi tanh ditulis pada Persamaan (2.11) sebagai berikut:

$$\tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (2.11)$$

dengan:

e = bilangan *euler*

x = data

2.6 Deep Learning

Deep learning merupakan pengembangan dari *machine learning* yang berbasis jaringan saraf tiruan dengan setidaknya tiga lapisan, memungkinkan model untuk belajar dan beradaptasi dengan data besar serta menyelesaikan berbagai masalah kompleks yang sulit dipecahkan oleh algoritma *machine learning* (Rowan dkk., 2022). Model ini terdiri dari lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan keluaran (*output layer*). Salah satu keunggulan utama *deep learning* adalah kemampuannya mengubah data nonlinear menjadi linear melalui transformasi bertahap pada lapisan tersembunyi (*hidden layer*) (Putra dkk., 2022). Algoritma *deep learning* banyak diterapkan dalam pengenalan pola (*pattern analysis*) dan klasifikasi, khususnya seperti pada data gambar, suara, teks, maupun deret waktu.


2.6.1 Recurrent Neural Network (RNN)

Model RNN adalah jenis jaringan saraf tiruan yang mampu mengidentifikasi korelasi tersembunyi dalam data, terutama dalam aplikasi seperti pengenalan suara, pemrosesan bahasa alami, dan peramalan deret waktu. Model RNN unggul dalam menangani masalah yang melibatkan pemodelan urutan karena mampu memproses sejumlah informasi sebagai *input* sekaligus mempertahankan jejak informasi dari langkah-langkah sebelumnya, berkat koneksi berulang yang dimilikinya (Tian dkk., 2018). Sehingga, model RNN mampu memprediksi data tidak hanya berdasarkan *input* pada satu waktu tertentu, tetapi juga dengan mempertimbangkan *input* dari waktu sebelumnya.

Model RNN terdiri dari tiga komponen utama, yaitu *input layer*, *hidden layer*, dan *output layer*. Model RNN dirancang untuk mengalirkan informasi secara satu arah, dimulai dari *input layer* ke *hidden layer* sebelumnya, lalu dilanjutkan ke *hidden layer* saat ini. Namun, model RNN memiliki keterbatasan dalam menyimpan informasi jangka panjang akibat masalah gradien yang menghilang (Tian dkk., 2018). Keterbatasan ini dapat diatasi dengan tipe khusus model RNN, yaitu model *Long Short Term Memory* (LSTM) dan model *Gated Recurrent Unit* (GRU), yang dirancang untuk meningkatkan kinerja dan kemampuan model RNN dalam memproses data berurutan. Model LSTM memiliki tiga gerbang utama (*forget gate*, *input gate*, dan *output gate*) yang memungkinkan model menyaring informasi secara lebih selektif, tetapi memiliki kompleksitas komputasi yang tinggi. Sebagai alternatif, GRU diperkenalkan dengan struktur yang lebih sederhana, hanya menggunakan dua gerbang utama (*reset gate* dan *update gate*). Meskipun memiliki arsitektur yang lebih ringan, GRU tetap mampu mengatasi masalah gradien yang menghilang dan sering kali menunjukkan performa yang setara atau lebih baik dibandingkan model LSTM (Zhang dkk., 2021).

2.6.2 Gated Recurrent Unit (GRU)

Gated Recurrent Unit merupakan salah satu varian dari RNN yang dirancang untuk mengatasi kendala dalam menangani ketergantungan jangka panjang dan gradien menghilang pada RNN (Zhang dkk., 2021). Arsitektur model GRU ditampilkan pada Gambar 1 sebagai berikut:



Gambar 1. Arsitektur *Gated Recurrent Unit* (Zhang dkk., 2021)

Menurut Zhang dkk. (2021), GRU memiliki dua jenis gerbang, yaitu *reset gate* dan *update gate*.

1. *Reset Gate* (r_t)

Reset gate bertugas memutuskan seberapa banyak informasi dari masa lalu (*timestep* $t - 1$) yang perlu diabaikan dalam *hidden state*. Artinya, gerbang ini menentukan informasi apa yang harus dilupakan dan disimpan dari data *input* sebelumnya. Semakin kecil nilai *reset gate*, semakin sedikit informasi dari keadaan sebelumnya yang dipertahankan. Persamaan untuk *reset gate* ditulis pada Persamaan (2.12) sebagai berikut (Zhang dkk., 2021):

$$r_t = \sigma (W_r \cdot [h_{t-1}, x_t] + b_r) \quad (2.12)$$

dengan:

- r_t = nilai *reset gate* pada *timestep* t
- σ = fungsi aktivasi sigmoid
- W_r = nilai *weight* untuk *reset gate*
- h_{t-1} = nilai *output* pada *timestep* $t - 1$
- x_t = nilai *input* pada *timestep* t
- b_r = nilai bias pada *reset gate*

2. *Update Gate* (z_t)

Update gate bertugas menentukan seberapa banyak informasi dari momen sebelumnya yang perlu dibawa ke dalam momen saat ini. Semakin besar nilai *update gate*, semakin banyak informasi dari momen sebelumnya yang dimasukkan. Persamaan untuk *update gate* ditulis pada Persamaan (2.13) sebagai berikut (Zhang dkk., 2021):

$$z_t = \sigma (W_z \cdot [h_{t-1}, x_t] + b_z) \quad (2.13)$$

dengan:

- z_t = nilai *update gate* pada *timestep* t
- σ = fungsi aktivasi sigmoid
- W_z = nilai *weight* untuk *update gate*
- h_{t-1} = nilai *output* pada *timestep* $t - 1$
- x_t = nilai *input* pada *timestep* t
- b_z = nilai bias pada *update gate*

Selanjutnya, GRU menghitung kandidat *hidden state* pada *timestep* t berdasarkan informasi relevan dari *timestep* sebelumnya ($t - 1$) menggunakan fungsi aktivasi tanh. Fungsi tanh digunakan untuk mengaktifkan data dan menskalakannya ke rentang -1 hingga 1 . Persamaan untuk kandidat *hidden state* ditulis pada Persamaan (2.14) sebagai berikut (Zhang dkk., 2021):

$$\hat{h}_t = \tanh(W \cdot [r_t \cdot h_{t-1}, x_t] + b_h) \quad (2.14)$$

dengan:

- $\hat{h}_t$ = kandidat *hidden state*
- $\tanh$ = fungsi aktivasi tanh
- W = nilai *weight*
- r_t = nilai *reset gate*
- h_{t-1} = nilai *output* pada *timestep* $t - 1$
- x_t = nilai *input* pada *timestep* t
- b_h = nilai bias pada *hidden state*

Output terakhir dari GRU adalah keadaan *hidden state* baru h_t yang dihitung menggunakan Persamaan (2.15) berikut (Zhang dkk., 2021):


$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \hat{h}_t \quad (2.15)$$

dengan:

- h_t = nilai *output* pada *timestep* t
- z_t = nilai *output* pada *update gate*
- h_{t-1} = nilai *output* pada *timestep* $t - 1$
- $\hat{h}_t$ = kandidat *hidden state*

2.6.3 Bidirectional Gated Recurrent Unit (BiGRU)

BiGRU merupakan pengembangan arsitektur GRU yang menggabungkan informasi dari urutan *input* dalam dua arah, yaitu maju (*forward*) dan mundur (*backward*). Struktur *bidirectional* ini dapat dianggap sebagai dua lapisan tersembunyi dengan arah transfer informasi yang berlawanan, masing-masing menggunakan unit GRU. Pada momen t , *input* x_t memberikan informasi ke lapisan tersembunyi dalam dua arah yang berlawanan secara simultan. *Output* y_t pada momen t ditentukan secara bersama oleh dua lapisan tersembunyi satu arah tersebut. Lapisan *forward* GRU ($\vec{h}_t$) memiliki informasi dari momen t dan momen sebelumnya dalam urutan *input*, sementara lapisan *backward* GRU ($\overleftarrow{h}_t$) memiliki informasi dari momen t dan momen berikutnya dalam urutan *input* (Zhang dkk., 2021). Arsitektur model BiGRU ditampilkan pada Gambar 2 sebagai berikut:



Gambar 2. Arsitektur *Bidirectional Gated Recurrent Unit* (Zhang dkk., 2021)

Proses lapisan tersembunyi pada model BiGRU dapat didefinisikan pada Persamaan (2.16) dan (2.17) sebagai berikut (Zhang dkk., 2021):

$$\vec{h}_t = f(\vec{W}x_t + \vec{V}\vec{h}_{t-1} + \vec{b}) \quad (2.16)$$

$$\overleftarrow{h}_t = f(\overleftarrow{W}x_t + \overleftarrow{V}\overleftarrow{h}_{t+1} + \overleftarrow{b}) \quad (2.17)$$

dengan:

- $\vec{h}_t, \overleftarrow{h}_t$ = nilai *output forward* dan *backward* GRU pada *timestep t*
- f = fungsi aktivasi
- $\vec{W}, \overleftarrow{W}$ = nilai *weight input* untuk *forward* dan *backward* GRU
- x_t = nilai *input* pada *timestep t*
- $\vec{V}, \overleftarrow{V}$ = nilai *weight hidden state* untuk *forward* dan *backward* GRU
- $\vec{b}, \overleftarrow{b}$ = nilai *bias* untuk *forward* dan *backward* GRU

Dari Persamaan (2.16) dan (2.17), terbentuk model BiGRU pada Persamaan (2.18) berikut (Zhang dkk., 2021):

$$y_t = \sigma(\vec{h}_t + \overleftarrow{h}_t) \quad (2.18)$$

dengan:

- y_t = nilai *output* BiGRU pada *timestep t*
- σ = fungsi aktivasi sigmoid
- $\vec{h}_t, \overleftarrow{h}_t$ = nilai *output forward* dan *backward* GRU pada *timestep t*

2.6.4 Hyperparameter

Algoritma *machine learning* maupun *deep learning* memiliki sejumlah pengaturan khusus yang dapat digunakan untuk mengontrol proses pembelajaran,

yang disebut *hyperparameter*. *Hyperparameter* merupakan parameter yang tidak dipelajari secara otomatis melalui algoritma pembelajaran itu sendiri, melainkan harus ditetapkan sebelum proses pelatihan dimulai. Penentuan nilai *hyperparameter* dapat dilakukan menggunakan metode pembelajaran bertingkat yang memungkinkan satu algoritma digunakan untuk mengoptimalkan pemilihan *hyperparameter* bagi algoritma lainnya (Goodfellow dkk., 2016). *Hyperparameter tuning* berperan penting dalam proses *machine learning* dan *deep learning*, karena parameter ini secara langsung memengaruhi kinerja model, sehingga menghasilkan performa yang maksimal (Putra dkk., 2022). Beberapa *hyperparameter* dalam *deep learning* di antaranya jumlah *hidden layer*, jumlah *hidden neuron per-layer*, *batch size*, *epoch*, *dropout*, *optimizer*, dan *learning rate*.

2.7 Hybrid VARIMA-BiGRU

Model *hybrid* adalah pendekatan yang menggabungkan dua atau lebih model ke dalam satu sistem untuk meningkatkan kinerja peramalan. Salah satu contohnya adalah kombinasi model VARIMA dan BiGRU. Menurut Zhang (2003), pengembangan model *hybrid* didasarkan pada beberapa alasan berikut:

1. Beberapa kasus peramalan, sulit menentukan apakah data deret waktu memiliki pola linear atau nonlinear. Hal ini mendorong peneliti untuk menggunakan lebih dari satu model, kemudian membandingkannya guna memperoleh hasil yang paling akurat. Sehingga dengan menggabungkan model yang berbeda, masalah seleksi model dapat diminimalkan.
2. Data deret waktu yang sepenuhnya linear atau nonlinear sangat jarang ditemukan. Sebagian besar data mengandung kombinasi keduanya. Penggunaan model tunggal kurang efektif karena tidak mampu menangkap pola campuran tersebut.
3. Tidak ada model peramalan tunggal yang cocok untuk semua situasi. Data kompleks dalam kasus nyata seringkali tidak dapat ditangani dengan baik oleh model tunggal, sehingga kombinasi model menjadi solusi yang lebih efektif.

Menggabungkan model yang berbeda memungkinkan pola data yang beragam dapat ditangkap dengan lebih baik, sehingga meningkatkan akurasi peramalan. Studi empiris menunjukkan bahwa kombinasi model seringkali lebih akurat dibandingkan model individu. Secara umum, kombinasi model deret waktu terdiri dari dua komponen utama, yaitu komponen linear dan nonlinear, seperti disajikan dalam Persamaan (2.19) berikut (Zhang, 2003):

$$Y_t = L_t + NL_t + a_t \quad (2.19)$$

dengan:

$$\begin{aligned} Y_t &= \text{data aktual pada periode } t \\ L_t &= \text{komponen linear pada periode } t \\ NL_t &= \text{komponen nonlinear pada periode } t \\ a_t &= \text{error} \end{aligned}$$

Model *hybrid* VARIMA-BiGRU dilakukan dalam dua tahap. Tahap pertama menggunakan model VARIMA untuk menangkap pola linear, sedangkan tahap kedua menggunakan model BiGRU untuk menangkap pola nonlinear. Sehingga persamaan model *hybrid* VARIMA-BiGRU dapat ditulis dalam Persamaan (2.20) sebagai berikut (Zhang, 2003):

$$Y'_t = L'_t + NL'_t \quad (2.20)$$

dengan:

$$\begin{aligned} Y'_t &= \text{nilai peramalan dari model } \textit{hybrid} \text{ pada periode } t \\ L'_t &= \text{nilai peramalan dari komponen linear pada periode } t \\ NL'_t &= \text{nilai peramalan dari komponen nonlinear pada periode } t \end{aligned}$$

2.8 Evaluasi Model

Evaluasi model bertujuan untuk menilai tingkat akurasi prediksi dengan membandingkan hasil prediksi dengan nilai observasi atau nilai sebenarnya. Evaluasi suatu model dapat dilakukan dengan menggunakan *Mean Absolute Percentage Error* dan *Root Mean Square Error* (Lattifia dkk, 2022).

1. *Mean Absolute Percentage Error* (MAPE)

Nilai MAPE digunakan untuk mengukur tingkat akurasi suatu prediksi dengan menentukan persentase penyimpangan dari nilai aktual. Nilai MAPE dihitung sebagai rata-rata kesalahan absolut dalam suatu periode tertentu, kemudian dikalikan 100% untuk mendapatkan hasil dalam bentuk persentase (Lattifia dkk, 2022). Persamaan umum yang digunakan untuk menghitung MAPE ditulis pada Persamaan (2.21) sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{\hat{Y}_t - Y_t}{Y_t} \right| \times 100\% \quad (2.21)$$

dengan:

n = jumlah periode yang diprediksi

Y_t = nilai aktual pada periode t

$\hat{Y}_t$ = nilai prediksi pada periode t

2. Root Mean Square Error (RMSE)

Nilai RMSE digunakan untuk mengukur tingkat kesalahan dalam suatu prediksi data. Nilai RMSE menentukan selisih antara nilai aktual dan nilai prediksi, kemudian menghitung rata-rata kuadrat dari selisih tersebut, yang akhirnya diakarkan (Lattifia dkk, 2022). Persamaan umum untuk menghitung RMSE ditulis pada Persamaan (2.22) sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t - Y_t)^2} \quad (2.22)$$

dengan:

n = jumlah periode yang diprediksi

Y_t = nilai aktual pada periode t

$\hat{Y}_t$ = nilai prediksi pada periode t

2.9 Goodness of Fit

Goodness of fit merupakan metode statistik yang digunakan untuk mengevaluasi seberapa baik suatu distribusi dapat merepresentasikan data yang diamati. Salah satu metode *goodness of fit* yang umum digunakan adalah uji Kolmogorov–Smirnov (KS). Uji KS mengukur selisih maksimum antara fungsi distribusi kumulatif dari data yang diamati dengan fungsi distribusi kumulatif dari distribusi teoretis yang diharapkan. Statistik uji KS ditulis pada Persamaan (2.23) sebagai berikut (Kolmogorov, 1933):

$$KS = \sup_x |F_n(x) - F(x)| \quad (2.23)$$

dengan:

KS = statistik uji Kolmogorov-Smirnov

$F_n(x)$ = fungsi distribusi kumulatif dari data empiris

$F(x)$ = fungsi distribusi kumulatif dari distribusi teoretis

$\sup$ = nilai maksimum dari selisih absolut antara kedua fungsi

Semakin kecil nilai statistik KS yang diperoleh, maka semakin kecil pula perbedaan antara distribusi dari data yang diamati dengan distribusi teoretis yang diharapkan.

BAB III

METODE PENELITIAN

3.1 Waktu dan Tempat Penelitian

a. Tempat Penelitian

Penelitian ini dilakukan dengan menggunakan studi pustaka di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung, yang berlokasi di Jl. Prof. Dr. Sumantri Brojonegoro, No. 1, Gedong Meneng, Bandar Lampung.

b. Waktu Penelitian

Penelitian ini dilakukan pada bulan Agustus 2024, pada semester ganjil tahun akademik 2024/2025. Penelitian ini terdiri dari tiga tahap, tahap pertama meliputi studi literatur untuk mengumpulkan jurnal atau buku yang relevan dengan topik penelitian sebagai referensi dalam penyusunan proposal hingga selesai. Kemudian dilanjutkan dengan pengumpulan data yang digunakan dalam penelitian dan penyusunan draf proposal. Tahap kedua mencakup pengerjaan program yang meliputi *splitting* data, *preprocessing* data, pembangunan model VARIMA, pembangunan model *hybrid* VARIMA–BiGRU, serta evaluasi kinerja model. Tahap terakhir adalah penyusunan hasil pengujian dan analisis dalam bentuk draf laporan yang disampaikan pada seminar hasil dan sidang komprehensif.

3.2 Data dan Alat Penelitian

a. Data Penelitian

Data yang digunakan pada penelitian ini adalah data sekunder yang terdiri dari dua variabel, berupa data harian harga penutupan ETF GLD dan ETF GDX periode Januari 2017 sampai November 2024 yang diperoleh dari laman Yahoo *Finance* (<https://finance.yahoo.com/>). Data yang digunakan berjumlah 1991, yang disajikan

pada Tabel 2 berikut:

Tabel 2. Data Harga Penutupan ETF GLD dan GDX

Tanggal	GLD	GDX
2017/01/03	110.470001	19.933672
2017/01/04	110.860001	20.080244
2017/01/05	112.580002	21.252813
2017/01/06	111.750000	20.510798
2017/01/09	112.669998	20.574921
...	...	...
2024/11/29	245.589996	37.223003

b. Alat Penelitian

1. Perangkat keras (*Hardware*)

Perangkat keras yang digunakan pada penelitian ini yaitu:

- *Processor* Intel (R) Celeron N3350 CPU @ 1.10GHz 2.40 GHz
- *Installed* RAM 2,00 GB

2. Perangkat lunak (*Software*)

- Sistem Operasi Windows 11 Pro 64-bit
- *Google Colaboratory* (Python 3.10.12)

Package yang digunakan:

- *NumPy* 1.26.4
- *Pandas* 2.2.2
- *Matplotlib* 3.8.0
- *Sklearn* 1.5.2
- *Statsmodels* 0.14.4
- *Tensorflow* 2.12.0

3.3 Metode Penelitian

Adapun langkah-langkah yang dilakukan untuk peramalan dengan model *hybrid* VARIMA-BiGRU pada penelitian ini adalah sebagai berikut:


1. Melakukan *input* data ke dalam bahasa pemrograman *Python* melalui *Google Colaboratory*.
2. Melakukan visualisasi data untuk melihat tren dan fluktuasi data.
3. Melakukan *splitting* data menjadi data pelatihan dan data pengujian dengan skema 80% data latih dan 20% data uji. Skema ini dipilih karena 80%

data cukup untuk menangkap pola dan kompleksitas data, sementara 20% sisanya cukup mewakili data baru untuk menguji performa model. Skema ini juga membantu menjaga keseimbangan agar model tidak *overfitting* maupun *underfitting*, sehingga mampu bekerja dengan baik pada data yang belum pernah dilihat.


4. Melakukan *preprocessing* data pada data pelatihan berupa pengecekan terhadap *missing value*, serta melihat nilai korelasi antara variabel GLD dan GDX.
5. Melakukan uji stasioneritas pada data pelatihan dengan uji *Augmented Dickey Fuller* (ADF). Jika data tidak stasioner maka perlu dilakukan *differencing* data hingga data menjadi stasioner.
6. Mengidentifikasi model VARIMA dengan menganalisis *lag* yang melewati batas signifikan pada plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF), serta orde *differencing* untuk menstasionerkan data.
7. Mengestimasi parameter model VARIMA dengan *Maximum Likelihood Estimation* (MLE), kemudian menentukan model terbaik dengan melihat model yang memiliki nilai *Bayesian Information Criterion* (BIC) terkecil untuk digunakan dalam prediksi maupun peramalan. BIC dipilih karena kriteria ini memberikan penalti yang lebih besar terhadap kompleksitas model dibandingkan kriteria lain seperti AIC, sehingga meminimalisir terjadinya *overfitting* dan mendorong pemilihan model yang lebih sederhana namun tetap memiliki performa yang optimal.
8. Melakukan prediksi untuk data latih dan data uji dengan menggunakan model VARIMA terbaik yang telah diperoleh.
9. Menghitung nilai residual yang dihasilkan dari model VARIMA, kemudian dilanjutkan dengan menguji asumsi residual *white noise* dengan uji *Ljung-Box*.
10. Mengevaluasi model VARIMA dengan menghitung nilai RMSE, MAPE, dan akurasi.
11. Melakukan peramalan dengan model VARIMA.
12. Menyiapkan data residual VARIMA untuk digunakan sebagai data *input* model E_BiGRU dan data prediksi VARIMA sebagai data *input* model P_BiGRU.
13. Melakukan *scaling* data pada data residual maupun prediksi VARIMA dengan *min-max scaler*.
14. Melakukan *hyperparameter tuning* pada model E_BiGRU dan model P_BiGRU.
15. Membangun model E_BiGRU dan model P_BiGRU dengan menggunakan parameter terbaik yang telah diperoleh.

16. Melakukan prediksi dan peramalan dengan menggunakan model E_BiGRU dan model P_BiGRU.
17. Melakukan *unscaling* pada data hasil prediksi dan peramalan model E_BiGRU dan model P_BiGRU.
18. Menggabungkan data hasil prediksi dan peramalan dari model VARIMA dan E_BiGRU melalui proses penjumlahan sebagai model *hybrid* VARIMA–E_BiGRU, serta menggabungkan data hasil prediksi dan peramalan dari model E_BiGRU dan P_BiGRU melalui proses penjumlahan sebagai model *hybrid* VARIMA–EP_BiGRU.
19. Mengevaluasi model *hybrid* VARIMA–E_BiGRU dan model *hybrid* VARIMA–EP_BiGRU dengan menghitung nilai RMSE, MAPE, dan akurasi.

Flowchart peramalan dengan model *hybrid* VARIMA–BiGRU sebagai berikut:



Gambar 3. Flowchart Model Hybrid VARIMA–E_BiGRU



Gambar 4. Flowchart Model Hybrid VARIMA-EP_BiGRU

BAB V

KESIMPULAN

5.1 Kesimpulan

Berdasarkan hasil dan pembahasan yang telah didapatkan pada penerapan model *hybrid* VARIMA–BiGRU untuk peramalan harga ETF GLD dan GDX, diperoleh kesimpulan sebagai berikut:

1. Model *hybrid* VARIMA–BiGRU yang digunakan untuk melakukan peramalan dibangun dengan dua pendekatan, yaitu model *hybrid* VARIMA–E_BiGRU dan model *hybrid* VARIMA–EP_BiGRU. Model *hybrid* VARIMA–E_BiGRU dibangun dari penjumlahan model VARIMA dan model E_BiGRU, sedangkan model *hybrid* VARIMA–EP_BiGRU dibangun dari penjumlahan model E_BiGRU dan P_BiGRU. Model E_BiGRU merupakan model BiGRU yang dibangun dari residual model VARIMA, sedangkan model P_BiGRU dibangun dari hasil prediksi model VARIMA. Model BiGRU dalam dua pendekatan ini dibangun menggunakan kombinasi parameter terbaik yang diperoleh melalui proses *hyperparameter tuning* dengan rincian sebagai berikut:
 - a. Model E_BiGRU, dibangun dengan kombinasi parameter terbaik yang diperoleh yaitu 32 BiGRU *unit*, 64 *dense unit*, 64 *batch size*, dan 0,2 *dropout*.
 - b. Model P_BiGRU, dibangun dengan kombinasi parameter terbaik yang diperoleh yaitu 64 BiGRU *unit*, 32 *dense unit*, dan 32 *batch size*.
2. Hasil peramalan yang diperoleh selama periode 30 hari ke depan, dari 1 Desember 2024 hingga 15 Januari 2025 menggunakan model *hybrid* VARIMA–EP_BiGRU, menunjukkan perbedaan yang signifikan dibandingkan model VARIMA maupun model *hybrid* VARIMA–E_BiGRU. Peramalan model VARIMA hanya menunjukkan pola linear sepanjang periode peramalan, sehingga belum mampu mengikuti fluktuasi data *update*. Sementara itu, peramalan model *hybrid* VARIMA–E_BiGRU mulai menunjukkan adanya sedikit fluktuasi, namun masih belum mampu mengikuti fluktuasi data *update* dengan baik. Sebaliknya, peramalan model *hybrid* VARIMA–EP_

BiGRU sudah mampu mengikuti pola fluktuasi data *update* dengan baik. Sehingga, model *hybrid* VARIMA–EP_BiGRU merupakan model terbaik dalam melakukan peramalan dibandingkan model VARIMA maupun model *hybrid* VARIMA–E_BiGRU.

3. Berdasarkan Uji *Goodness of fit* menggunakan uji Kolmogorov-Smirnov, model *hybrid* VARIMA–EP_BiGRU menunjukkan nilai statistik uji KS yang paling kecil dibandingkan model VARIMA maupun model *hybrid* VARIMA–E_BiGRU, baik pada variabel GLD maupun GDX. Hasil ini menunjukkan bahwa model *hybrid* VARIMA–EP_BiGRU memiliki kemampuan terbaik dalam menyesuaikan distribusi hasil peramalan terhadap distribusi data *update*. Oleh karena itu, dapat disimpulkan bahwa model *hybrid* VARIMA–EP_BiGRU memiliki kinerja yang paling baik dalam melakukan peramalan dibandingkan model VARIMA maupun model *hybrid* VARIMA–E_BiGRU.

DAFTAR PUSTAKA

- Aji, A. B. & Surjandari, I. 2020. Hybrid Vector Autoregression–Recurrent Neural Networks to Forecast Multivariate Time Series Jet Fuel Transaction Price. *IOP Conference Series: Materials Science and Engineering*. **909**(1): 1-10.
- Alpaydin, E. 2004. *Introduction to Machine Learning*. MIT Press.
- Bursa Efek Indonesia. 2024. Exchange-Traded Fund (ETF). <https://www.idx.co.id/id/produk/exchange-traded-fund-etf>. Diakses pada 30 November 2024.
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. 2015. *Time Series Analysis: Forecasting and Control*. John Wiley & Sons.
- Caliwag, A.C., & Lim, W. 2019. Hybrid VARMA and LSTM Method for Lithium-ion Battery State-of-Charge and Output Voltage Forecasting in Electric Motorcycle Applications. *IEEE Access*. **7**(10): 59680–59689.
- 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**(366): 427-431.
- Fikriaziz, J., Estri, M. N., Maryani, S., & Sihwaningrum, I. 2024. Metode Long Short-Term Memory untuk Memprediksi Konsumsi Energi Listrik di Kabupaten Kebumen Tahun 2023. *Prosiding Seminar Nasional Sains Data*. **4**(1): 823-831.
- Goodfellow, I., Bengio, Y. & Courville, A. 2016. *Deep Learning: Machine Learning Book*. The MIT Press, London.
- Harvey, A. 2006. Forecasting with Unobserved Components Time Series Models. *Handbook of Economic Forecasting*. **1**(7): 327–412.
- Ivan, E. & Purnomo, H. D. 2022. Forecasting Prices of Fertilizer Raw Materials Using Long Short Term Memory. *Jurnal Teknik Informatika (Jutif)*. **3**(6): 1663–1673.
- Kolmogorov, A. 1933. Sulla Determinazione Empirica di Una Legge di Distribuzione. *Giorn Dell'inst Ital Degli Att*. **4**: 89-91.
- Lattifa, T., Buana, P. W., & Rusjyanthi, N. K. D. 2022. Model Prediksi Cuaca Menggunakan Metode LSTM. *Jurnal Ilmu Teknologi dan Komputer (JITTER)*. **3**(1): 994-1000.

- Ljung, G. M. & Box, G. E. P. 1978. On a Measure of Lack of Fit in Time Series Models. *Biometrika*. **65**(2): 297-303.
- Makridakis, S., Wheelright, S.C., & Hyndman, R.J. 1983. *Forecasting: Methods and Applications*. Second Edition. John Wiley & Sons, New York.
- Montgomery, D.C., Jennings, C.L., & Kulahci, M. 2015. *Introduction to Time Series Analysis and Forecasting*. Second Edition. John Wiley & Sons, Inc., Hoboken, New Jersey.
- Nugroho, A. A. Z. & Suwanda. 2022. Pemodelan Multivariate Time Series dengan Vector Autoregressive Integrated Moving Average (VARIMA). *Jurnal Riset Statistika*. **2**(2): 93-102.
- Pratiwi, H., Windarto, A. P., Susliansyah, S., Aria, R. R., Susilowati, S., Rahayu, L. K., & Rahadjeng, I. R. 2020. Sigmoid Activation Function in Selecting the Best Model of Artificial Neural Networks. *Journal of Physics: Conference Series*. **1471**(1): 1-7.
- Putra, T. I. Z. M., Suprpto, & Bukhori, A. F. 2022. Model Klasifikasi Berbasis Multiclass Classification dengan Kombinasi Indobert Embedding dan Long Short-Term Memory untuk Tweet Berbahasa Indonesia. *Jurnal Ilmu Siber dan Teknologi Digital (JISTED)*. **1**(1): 1–28.
- Rowan, Muflikhah, L. & Cholissodin, I. 2022. Peramalan Kasus Positif COVID-19 di Jawa Timur Menggunakan Metode Hybrid ARIMA-LSTM. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*. **6**(9): 4146–4153.
- Rusyana, A., Tatsara, N., Balqis, R., & Rahmi, S. 2020. Application of Clustering and VARIMA for Rainfall Prediction. *IOP Conference Series: Materials Science and Engineering*. **796**(1): 1-9.
- Tanjung, A. A. C., Saputro, D. R. S., & Kurdhi, N. A. 2024. Implementation of the Bidirectional Gated Recurrent Unit Algorithm on Consumer Price Index Data in Indonesia. *Barekeng: Jurnal Ilmu Matematika dan Terapan*. **18**(1): 95-104.
- Tian, C., Ma, J., Zhang, C., & Zhan, P. 2018. A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network. *Energies*. **11**(12): 1-13.
- Wei, W. W. S. 2006. *Time Series Analysis: Univariate and Multivariate Methods*. Second Edition. Temple University, New York.
- Zhang, G.P. 2003. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*. **50**: 159–175.
- Zhang, Z., Dong, Z., Lin, H., He, Z., Wang, M., He, Y., & Gao, M. 2021. An Improved Bidirectional Gated Recurrent Unit Method for Accurate State-of-Charge Estimation. *IEEE Access*. **9**: 11252-11263.