

**IMPLEMENTASI MODEL *HYBRID VECTOR AUTOREGRESSIVE  
INTEGRATED MOVING AVERAGE EXOGENOUS (VARIMAX)-GATED  
RECURRENT UNIT (GRU)* DALAM PERAMALAN HARGA PENUTUPAN  
SAHAM PT ICBP TBK DAN PT INDF TBK DENGAN NILAI TUKAR  
RUPIAH SEBAGAI VARIABEL EKSOGEN**

**Skripsi**

**Oleh**

**ANGGY WAHYUNI  
NPM. 2117031024**



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

**2025**

## ABSTRACT

### **IMPLEMENTATION OF THE HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE EXOGENOUS (VARIMAX)–GATED RECURRENT UNIT (GRU) MODEL IN FORECASTING THE CLOSING STOCK PRICES OF PT ICBP TBK AND PT INDF TBK WITH THE RUPIAH EXCHANGE RATE AS AN EXOGENOUS VARIABLE**

By

**Anggy Wahyuni**

The fluctuation of the rupiah exchange rate is one of the external factors that influence the stock movements of companies such as PT Indofood Consumer Brand Product Sukses Makmur Tbk (ICBP) and PT Indofood Sukses Makmur Tbk (INDF), amid the significant growth of Indonesia's capital market. This condition underscores the need for a forecasting model capable of generating accurate predictions of future values. This study develops a hybrid model by combining the Vector Autoregressive Integrated Moving Average Exogenous (VARIMAX) and the Gated Recurrent Unit (GRU) to improve forecasting accuracy. The hybrid model is designed to address the limitations of VARIMAX in capturing nonlinear patterns and the limitations of GRU in effectively modeling linear structures. Two hybrid modeling approaches are proposed. The first approach, the hybrid VARIMAX-E\_GRU model, combines the VARIMAX prediction results with the VARIMAX residuals which are further processed using the GRU model. The second approach, the hybrid VARIMAX-EP\_GRU model, integrates both the predictions and residuals of the VARIMAX model, with both components further processed by the GRU model. This study uses historical closing price data of PT ICBP Tbk and PT INDF Tbk as endogenous variables, and the rupiah exchange rate against the US dollar as an exogenous variable, from January 2021 to February 2025. The results show that the hybrid VARIMAX-EP\_GRU provides the best forecasting performance compared to both the standalone VARIMAX model and the hybrid VARIMAX-E\_GRU model, as indicated by the smallest Kolmogorov–Smirnov statistic value and the ability to follow recent data patterns.

**Keywords:** Hybrid VARIMAX–GRU, VARIMAX, GRU, Stock closing prices, Forecasting.

## ABSTRAK

### **IMPLEMENTASI MODEL *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE EXOGENOUS (VARIMAX)-GATED RECURRENT UNIT (GRU)* DALAM PERAMALAN HARGA PENUTUPAN SAHAM PT ICBP TBK DAN PT INDF TBK DENGAN NILAI TUKAR RUPIAH SEBAGAI VARIABEL EKSOGEN**

Oleh

**Anggy Wahyuni**

Fluktuasi nilai tukar rupiah merupakan salah satu faktor eksternal yang memengaruhi pergerakan saham seperti PT Indofood *Consumer Brand Product* Sukses Makmur Tbk (ICBP) dan PT Indofood Sukses Makmur Tbk (INDF), di tengah pertumbuhan pasar modal Indonesia yang signifikan. Kondisi tersebut mendorong perlunya model yang mampu menghasilkan peramalan nilai secara akurat di masa mendatang. Penelitian ini mengembangkan model *hybrid* dengan menggabungkan *Vector Autoregressive Integrated Moving Average Exogenous (VARIMAX)* dan *Gated Recurrent Unit (GRU)* untuk meningkatkan akurasi peramalan. Model ini dirancang untuk mengatasi keterbatasan VARIMAX dalam mengenali pola nonlinear serta keterbatasan GRU dalam menangkap pola linier secara menyeluruh. Model *hybrid* dalam penelitian ini dikembangkan melalui dua pendekatan. Pendekatan pertama yaitu model *hybrid VARIMAX-E-GRU*, yang menggabungkan hasil prediksi model VARIMAX dan nilai residual model VARIMAX yang diproses lebih lanjut menggunakan model GRU. Sedangkan pendekatan kedua yaitu model *hybrid VARIMAX-EP-GRU*, yang menggabungkan hasil prediksi dan residual model VARIMAX, yang keduanya diproses lebih lanjut menggunakan model GRU. Data yang digunakan pada penelitian ini berupa data historis harga penutupan saham PT ICBP Tbk dan PT INDF Tbk sebagai variabel endogen serta nilai tukar rupiah terhadap dolar Amerika Serikat sebagai variabel eksogen, periode Januari 2021 hingga Februari 2025. Hasil penelitian menunjukkan bahwa model *hybrid VARIMAX-EP-GRU* memberikan kinerja terbaik dalam melakukan peramalan dibandingkan model VARIMAX maupun model *hybrid VARIMAX-E-GRU* berdasarkan nilai statistik Kolmogorov-Smirnov terkecil.

**Kata kunci:** *Hybrid VARIMAX-GRU*, VARIMAX, GRU, Harga penutupan saham, Peramalan.

**IMPLEMENTASI MODEL *HYBRID VECTOR AUTOREGRESSIVE  
INTEGRATED MOVING AVERAGE EXOGENOUS (VARIMAX)-GATED  
RECURRENT UNIT (GRU)* DALAM PERAMALAN HARGA PENUTUPAN  
SAHAM PT ICBP TBK DAN PT INDF TBK DENGAN NILAI TUKAR  
RUPIAH SEBAGAI VARIABEL EKSOGEN**

**ANGGY WAHYUNI**

**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 EXOGENOUS (VARIMAX)-GATED RECURRENT UNIT (GRU)* DALAM PERAMALAN HARGA PENUTUPAN SAHAM PT ICBP TBK DAN PT INDF TBK DENGAN NILAI TUKAR RUPIAH SEBAGAI VARIABEL EKSOGEN**

Nama Mahasiswa : **Anggy Wahyuni**  
Nomor Pokok Mahasiswa : **2117031024**  
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 : **Dr. Aang Nuryaman, 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: **11 Juni 2025**

## PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : **Anggy Wahyuni**  
Nomor Pokok Mahasiswa : **2117031024**  
Jurusan : **Matematika**  
Judul Skripsi : **IMPLEMENTASI MODEL *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE EXOGENOUS (VARIMAX)-GATED RECURRENT UNIT (GRU)* DALAM PERAMALAN HARGA PENUTUPAN SAHAM PT ICBP TBK DAN PT INDF TBK DENGAN NILAI TUKAR RUPIAH SEBAGAI VARIABEL EKSOGEN**

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, 11 Juni 2025

Penulis,



**Anggy Wahyuni**

NPM. 2117031024

## **RIWAYAT HIDUP**

Penulis bernama lengkap Anggy Wahyuni, lahir pada hari Kamis, 21 Agustus 2003 di Bandar Lampung. Penulis merupakan anak kedua dari dua bersaudara dari pasangan Bapak Suminarno (alm) dan Ibu Sriami.

Penulis pertama kali menempuh pendidikan di Taman Kanak-Kanak (TK) Beringin Raya pada tahun 2008-2009. Kemudian menempuh pendidikan Sekolah Dasar (SD) di SD Negeri 3 Sumberejo pada tahun 2009-2015. Lalu penulis melanjutkan jenjang pendidikan ke Sekolah Menengah Pertama (SMP) di SMP Negeri 26 Bandar Lampung pada tahun 2015-2018. Selanjutnya penulis belajar pada jenjang yang lebih tinggi yaitu Sekolah Menengah Atas (SMA) di SMA Negeri 7 Bandar Lampung pada tahun 2018-2021.

Pada tahun 2021 penulis terdaftar sebagai mahasiswa di Program Studi S1 Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung, melalui jalur SNMPTN. Selama menjadi mahasiswa, penulis pernah menjadi anggota dari Himpunan Mahasiswa Matematika (HIMATIKA) dan Badan Eksekutif Mahasiswa Tingkat Fakultas (BEMF) pada tahun 2022.

Sebagai bentuk pengaplikasian ilmu yang didapat, pada bulan Desember 2023 hingga Februari 2024, penulis melaksanakan Kerja Praktik (KP) di Dinas Bina Marga dan Bina Konstruksi (BMBK) Provinsi Lampung. Kemudian, pada bulan Juni hingga Agustus 2024, penulis melaksanakan Kuliah Kerja Nyata (KKN) di Desa Waringin Jaya, Kecamatan Bandar Sribhawono, Kabupaten Lampung Timur, Provinsi Lampung.

## KATA INSPIRASI

”Jangan engkau bersedih, sesungguhnya Allah bersama kita.”

**(Q.S. At-Taubah: 40)**

”Barang siapa bertakwa kepada Allah maka Dia akan menjadikan jalan keluar baginya, dan memberinya rezeki dari jalan yang tidak ia sangka, dan barang siapa yang bertawakal kepada Allah maka cukuplah Allah baginya. Sesungguhnya Allah melaksanakan kehendak-Nya, Dia telah menjadikan untuk setiap sesuatu kadarnya.”

**(Q.S. Ath-Thalaq: 2-3)**

”Barang siapa menempuh jalan untuk mencari ilmu, Allah akan memudahkan baginya jalan menuju surga.”

**(HR. Muslim)**

*”When life gives you lemons, make orange juice and leave the world wondering how you did it.”*

**(Grace Helbig)**

## **PERSEMBAHAN**

*Alhamdulillahirobbil'alamin,*

Puji dan syukur kehadirat Allah Subhanahu Wata'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 Wassalam. Dengan penuh syukur, penulis persembahkan karya ini 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

Alhamdulillahirabbil'alamin, puji syukur kehadiran Allah SWT. atas limpahan rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul "Implementasi Model *Hybrid Vector Autoregressive Integrated Moving Average Exogenous (VARIMAX)-Gated Recurrent Unit (GRU)* dalam Peramalan Harga Penutupan Saham PT ICBP Tbk dan PT INDF Tbk dengan Nilai Tukar Rupiah sebagai Variabel Eksogen".

Terselesaikannya skripsi ini, tidak lepas dari bimbingan, arahan, motivasi, serta doa dari berbagai pihak. Oleh karena itu, penulis mengucapkan terimakasih 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. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Pembahas yang telah meluangkan waktu untuk memberikan kritik, saran, serta masukan yang membangun demi perbaikan skripsi ini.
4. Ibu Prof. Dra. Wamiliana, M.A., Ph.D. 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. Ibu Prof. Dr. Ir. Lusmeilia Afriani, D.E.A., I.P.M. selaku Rektor Universitas Lampung.

8. 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.
9. Almamater tercinta, Universitas Lampung.
10. Teristimewa untuk kedua orang tua, Bapak Suminarno (alm) dan Ibu Sriami, serta kakak tercinta, Aditia Fransiska, yang selalu memberikan doa, dukungan moral, serta materiil yang tidak ternilai harganya, sehingga penulis dapat menyelesaikan skripsi ini.
11. Risa Dita Adifitri, terima kasih karena sudah kebersamai sejak bangku SMA dan selalu memberikan doa, motivasi, dan dukungan terbaik untuk penulis sehingga bisa menyelesaikan skripsi tepat pada waktunya.
12. Rekan-rekan terbaik penulis selama menjalani perkuliahan, Mey Ari Wardhani, Amanda Az Zahra, dan Nindi Ovilia yang banyak membantu penulis selama perkuliahan dan memberi dukungan dalam proses penyelesaian skripsi ini.
13. Teman-teman seperbimbingan, Andi, Mey, Maya, Nabila, Dita, Ariz, Sherina, Rhea, Erwin, Yulina, Dina, Adinda, Lusi, Anastasia, dan Fathan yang telah kebersamai dan banyak membantu penulis selama proses penyelesaian skripsi.
14. Teman-teman Jurusan Matematika angkatan 2021 serta Abang dan Yunda yang telah membantu selama proses perkuliahan.
15. 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, 11 Juni 2025  
Penulis,

**Anggy Wahyuni**  
NPM. 2117031024

## DAFTAR ISI

<b>DAFTAR ISI</b> . . . . .	<b>xiii</b>
<b>DAFTAR TABEL</b> . . . . .	<b>xiv</b>
<b>DAFTAR GAMBAR</b> . . . . .	<b>xv</b>
<b>I PENDAHULUAN</b> . . . . .	<b>1</b>
1.1 Latar Belakang Masalah . . . . .	1
1.2 Rumusan Masalah . . . . .	6
1.3 Tujuan Penelitian . . . . .	7
1.4 Manfaat Penelitian . . . . .	7
<b>II TINJAUAN PUSTAKA</b> . . . . .	<b>8</b>
2.1 Penelitian Terkait Analisis Deret Waktu . . . . .	8
2.2 Deret Waktu . . . . .	11
2.2.1 Analisis Deret Waktu . . . . .	11
2.2.2 Model Deret Waktu Multivariat . . . . .	13
2.2.2.1 Model <i>Vector Autoregressive</i> (VAR) . . . . .	13
2.2.2.2 Model <i>Vector Moving Average</i> (VMA) . . . . .	14
2.2.2.3 Model <i>Vector Autoregressive Moving Average</i> (VARMA) . . . . .	14
2.2.2.4 Model <i>Vector Autoregressive Integrated Moving</i> <i>Average</i> (VARIMA) . . . . .	15
2.2.2.5 Model <i>Vector Autoregressive Integrated Moving</i> <i>Average Exogenous</i> (VARIMAX) . . . . .	15
2.2.3 Asumsi Model Deret Waktu . . . . .	16
2.2.3.1 Stasioneritas Data . . . . .	16
2.2.3.2 Residual <i>White Noise</i> . . . . .	18
2.2.4 Kausalitas Granger . . . . .	19
2.2.5 Peramalan . . . . .	20
2.3 <i>Machine Learning</i> . . . . .	21
2.3.1 <i>Feature Scaling</i> . . . . .	22
2.3.1.1 Normalisasi Data . . . . .	22
2.3.1.2 Denormalisasi Data . . . . .	23

2.3.2	<i>Deep Learning</i>	23
2.3.2.1	<i>Recurrent Neural Network (RNN)</i>	23
2.3.2.2	<i>Gated Recurrent Unit (GRU)</i>	25
2.3.2.3	Fungsi Aktivasi	27
2.3.2.4	<i>Hyperparameter</i>	29
2.4	<i>Hybrid VARIMAX-GRU</i>	31
2.5	Evaluasi Model	33
2.5.1	<i>Mean Absolute Percentage Error (MAPE)</i>	33
2.5.2	<i>Root Mean Square Error (RMSE)</i>	34
2.6	<i>Goodness of Fit</i>	34
<b>III</b>	<b>METODE PENELITIAN</b>	<b>36</b>
3.1	Waktu dan Tempat Penelitian	36
3.2	Alat Penelitian	36
3.3	Data Penelitian	37
3.4	Metode Penelitian	38
<b>IV</b>	<b>HASIL DAN PEMBAHASAN</b>	<b>43</b>
4.1	<i>Input Data</i>	43
4.2	Visualisasi Data	44
4.3	Prediksi dan Peramalan Model VARIMAX	46
4.3.1	<i>Splitting Data</i>	46
4.3.2	<i>Preprocessing Data</i>	46
4.3.3	Uji Stasioneritas Data	47
4.3.4	Identifikasi Model	50
4.3.5	Uji Kausalitas Granger	51
4.3.6	Estimasi Parameter	52
4.3.7	Prediksi Model VARIMAX	52
4.3.8	Menghitung Residual	55
4.3.9	Uji Asumsi Residual <i>White Noise</i>	56
4.3.10	Peramalan Model VARIMAX	56
4.4	Prediksi dan Peramalan Model <i>Hybrid VARIMAX-E_GRU</i>	58
4.4.1	<i>Scaling Data Residual Model VARIMAX</i>	58
4.4.2	Membangun Model E_GRU	59
4.4.3	<i>Hyperparameter Tuning Model E_GRU</i>	60
4.4.4	Prediksi Model E_GRU	61
4.4.5	Prediksi Model <i>Hybrid VARIMAX-E_GRU</i>	63

4.4.6	Peramalan Model E_GRU . . . . .	65
4.4.7	Peramalan Model <i>Hybrid</i> VARIMAX-E_GRU . . . . .	66
4.5	Prediksi dan Peramalan Model <i>Hybrid</i> VARIMAX-EP_GRU . . . . .	68
4.5.1	<i>Scaling</i> Data Hasil Prediksi Model VARIMAX . . . . .	69
4.5.2	Membangun Model P_GRU . . . . .	69
4.5.3	<i>Hyperparameter Tuning</i> Model P_GRU . . . . .	70
4.5.4	Prediksi Model P_GRU . . . . .	71
4.5.5	Prediksi Model <i>Hybrid</i> VARIMAX-EP_GRU . . . . .	73
4.5.6	Peramalan Model P_GRU . . . . .	75
4.5.7	Peramalan Model <i>Hybrid</i> VARIMAX-EP_GRU . . . . .	76
4.6	<i>Goodness of Fit</i> . . . . .	78
<b>V</b>	<b>KESIMPULAN DAN SARAN . . . . .</b>	<b>80</b>
5.1	Kesimpulan . . . . .	80
	<b>DAFTAR PUSTAKA . . . . .</b>	<b>82</b>

## DAFTAR TABEL

1.	Penelitian Terkait . . . . .	9
2.	Kriteria Nilai MAPE . . . . .	34
3.	Data Penelitian . . . . .	38
4.	<i>Input</i> Data . . . . .	43
5.	Statistik Deskriptif . . . . .	44
6.	<i>Splitting</i> Data . . . . .	46
7.	<i>Preprocessing</i> Data . . . . .	47
8.	Nilai Korelasi antar Variabel . . . . .	47
9.	Hasil Uji Stasioneritas Data . . . . .	48
10.	Hasil <i>Differencing</i> Pertama . . . . .	48
11.	Hasil Uji Stasioneritas Data Setelah <i>Differencing</i> . . . . .	49
12.	Hasil Uji Kausalitas Granger . . . . .	51
13.	Pemilihan Model VARIMAX Terbaik . . . . .	52
14.	Hasil Prediksi Model VARIMAX . . . . .	53
15.	Hasil Data Prediksi Model VARIMAX setelah <i>Undifferencing</i> . . . . .	53
16.	Evaluasi Model VARIMAX(1,1,1) . . . . .	54
17.	Nilai Residual Model VARIMAX . . . . .	55
18.	Uji Ljung-Box . . . . .	56
19.	Data Hasil Peramalan Model VARIMAX . . . . .	57
20.	Inisialisasi parameter Model E_GRU . . . . .	59
21.	Model E_GRU Terbaik . . . . .	60
22.	Data Hasil Prediksi Model E_GRU . . . . .	61
23.	Data Residual Hasil Prediksi Model VARIMAX dan Data Residual Hasil Prediksi Model E_GRU . . . . .	61
24.	Evaluasi Model E_GRU . . . . .	62
25.	Data Hasil Prediksi Model <i>Hybrid</i> VARIMAX-E_GRU . . . . .	63
26.	Evaluasi Model <i>Hybrid</i> VARIMAX-E_GRU . . . . .	64
27.	Hasil Peramalan Model E_GRU . . . . .	65
28.	Data Hasil Peramalan Model <i>Hybrid</i> VARIMAX-E_GRU . . . . .	67

29.	Inisialisasi parameter Model P_GRU . . . . .	69
30.	Model P_GRU Terbaik . . . . .	71
31.	Data Hasil Prediksi Model P_GRU . . . . .	71
32.	Data Hasil Prediksi Model VARIMAX dan Data Hasil Prediksi Model P_GRU . . . . .	72
33.	Evaluasi Model P_GRU . . . . .	73
34.	Data Hasil Prediksi Model <i>Hybrid</i> VARIMAX-EP_GRU . . . . .	73
35.	Evaluasi Model <i>Hybrid</i> VARIMAX-EP_GRU . . . . .	74
36.	Data Hasil Peramalan Model P_GRU . . . . .	75
37.	Data Hasil Peramalan Model <i>Hybrid</i> VARIMAX-EP_GRU . . . . .	77
38.	<i>Goodness of Fit</i> ICBP.JK . . . . .	78
39.	<i>Goodness of Fit</i> INDF.JK . . . . .	79

## DAFTAR GAMBAR

1.	Pola Data Deret Waktu (Montgomery dkk., 2015) . . . . .	12
2.	Arsitektur <i>Recurrent Neural Network</i> (Wijanarko dkk., 2024) . . . . .	25
3.	Arsitektur <i>Gated Recurrent Unit</i> (Saputra dkk., 2023) . . . . .	26
4.	Fungsi Aktivasi Sigmoid . . . . .	28
5.	Fungsi Aktivasi Tan Hiperbolik . . . . .	29
6.	<i>Flowchart</i> Model <i>Hybrid VARIMAX-E_GRU</i> . . . . .	41
7.	<i>Flowchart</i> Model <i>Hybrid VARIMAX-EP_GRU</i> . . . . .	42
8.	Plot Data Historis ICBP.JK . . . . .	45
9.	Plot Data Historis INDF.JK . . . . .	45
10.	Plot Data <i>Differencing</i> Pertama . . . . .	49
11.	Plot ACF dan PACF ICBP.JK . . . . .	50
12.	Plot ACF dan PACF INDF.JK . . . . .	51
13.	Plot Hasil Prediksi Model VARIMAX . . . . .	54
14.	Plot Data Residual Hasil Prediksi Model VARIMAX . . . . .	55
15.	Plot Hasil Peramalan Model VARIMAX . . . . .	57
16.	Plot Data Hasil Prediksi Model E_GRU . . . . .	62
17.	Plot Data Hasil Prediksi Model <i>Hybrid VARIMAX-E_GRU</i> . . . . .	64
18.	Plot Data Hasil Peramalan Model E_GRU . . . . .	66
19.	Plot Data Hasil Peramalan Model <i>Hybrid VARIMAX-E_GRU</i> . . . . .	67
20.	Plot Data Hasil Prediksi Model P_GRU . . . . .	72
21.	Plot Data Hasil Prediksi Model <i>Hybrid VARIMAX-EP_GRU</i> . . . . .	74
22.	Plot Data Hasil Peramalan Model P_GRU . . . . .	76
23.	Plot Data Hasil Peramalan Model <i>Hybrid VARIMAX-EP_GRU</i> . . . . .	77

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang Masalah

Perkembangan pasar modal di Indonesia menunjukkan pertumbuhan yang sangat signifikan. Berdasarkan data statistik dari Kustodian Sentral Efek Indonesia (KSEI) per Desember 2024, jumlah investor pasar modal Indonesia mencapai 14,58 juta *Single Investor Identification* (SID), mengalami peningkatan sebesar 22,59% *year to date* (ytd) dibandingkan dengan 12,13 juta SID per Desember 2023. Pasar modal berfungsi sebagai sarana pembentukan modal dan akumulasi dana jangka panjang, yang mendukung pembiayaan pembangunan nasional. Namun, fluktuasi harga saham yang dipengaruhi oleh berbagai faktor, termasuk nilai tukar mata uang rupiah terhadap mata uang asing, menimbulkan tantangan bagi investor dalam mengambil keputusan investasi. Perubahan nilai tukar dapat memengaruhi kinerja perusahaan, terutama yang bergantung pada impor bahan baku, sehingga berdampak pada harga saham (Nurfitriani dan Dewi, 2024). Peramalan menjadi alat penting dalam analisis keuangan untuk menghadapi ketidakpastian pasar tersebut. Peramalan (*forecasting*) merupakan teknik untuk memperkirakan suatu nilai di masa depan yang sebagian besar masalahnya melibatkan penggunaan data deret waktu. Deret waktu (*time series*) adalah urutan pengamatan yang berorientasi pada waktu terhadap suatu variabel yang menjadi fokus analisis (Montgomery dkk., 2015). Pendekatan ini memungkinkan identifikasi pola, tren, dan hubungan antar variabel ekonomi sehingga investor dan pengambil kebijakan dapat memperoleh wawasan yang lebih akurat untuk mendukung strategi investasi dan mitigasi risiko di pasar keuangan.

Metode peramalan data deret waktu atau *time series* berfokus pada analisis pola data historis untuk memprediksi kejadian di masa depan. Model deret waktu dapat diklasifikasikan berdasarkan jumlah variabel yang dianalisis, yaitu menjadi model univariat dan multivariat. Deret waktu univariat hanya melibatkan

satu variabel, sedangkan deret waktu multivariat melibatkan dua variabel atau lebih (Wei, 2006). Suatu variabel dalam deret waktu seringkali tidak bersifat independen, melainkan dipengaruhi oleh variabel-variabel lain yang saling berinteraksi sehingga pendekatan multivariat dianggap lebih efektif karena mampu menangkap pola data sekaligus hubungan antar variabel yang relevan dalam proses prediksi dan peramalan.

Model yang terdapat dalam analisis deret waktu multivariat mencakup berbagai model, seperti *Vector Autoregressive* (VAR), *Vector Moving Average* (VMA), *Vector Autoregressive Moving Average* (VARMA), *Vector Autoregressive Integrated Moving Average* (VARIMA), dan *Vector Autoregressive Integrated Moving Average Exogenous* (VARIMAX). Model VAR merupakan salah satu model dasar dalam peramalan data deret waktu multivariat yang dikembangkan dari model univariat *Autoregressive* (AR) yang menganalisis hubungan antara beberapa deret waktu secara simultan. Model VAR digunakan untuk menjelaskan hubungan timbal balik antar variabel-variabel yang berhubungan tanpa mempertimbangkan pengaruh residual atau kesalahan prediksi dari periode sebelumnya terhadap variabel saat ini. Model VMA dikembangkan dari model univariat *Moving Average* (MA) dimana estimasi pada suatu periode tertentu bergantung pada residual variabel tersebut serta residual variabel lain yang terlibat dalam model pada periode sebelumnya. Namun, karena model ini hanya mengandalkan komponen residual, penggunaannya menjadi terbatas pada kasus tertentu yang lebih menekankan pada efek residual dibandingkan keterkaitan langsung antar variabel dalam jangka panjang (Pratama dan Saputro, 2018). Model VARMA merupakan gabungan dari model VAR dan model VMA dengan mengombinasikan keunggulan keduanya dimana estimasi pada suatu periode tertentu bergantung pada hubungan antar variabel dan residualnya, baik pada variabel itu sendiri maupun variabel lain yang terlibat dalam model pada periode sebelumnya. Ketiga model deret waktu multivariat tersebut tidak cocok digunakan untuk data deret waktu yang tidak stasioner, sesuai dengan syarat modelnya yang mengharuskan data bersifat stasioner (Pratiwi, 2023).

Model deret waktu multivariat yang dapat digunakan untuk menganalisis data yang tidak stasioner adalah model VARIMA yang merupakan pengembangan dari model VARMA dengan menambahkan komponen integrasi (I) pada model. Integrasi ini digunakan untuk mengatasi data yang tidak stasioner dengan cara melakukan *differencing* (Pratiwi, 2023). Model VARIMAX merupakan pengembangan dari model VARIMA dengan menambahkan variabel eksogen ke dalam proses analisis.

Menurut Suttichaimethee (2017), model VARIMAX merupakan salah satu metode deret waktu yang dirancang untuk menganalisis dan memodelkan lebih dari satu variabel endogen secara simultan, dengan mempertimbangkan adanya variabel eksogen yang turut memengaruhi variabel-variabel endogen tersebut. Sebagaimana dalam penelitiannya yang melakukan peramalan terhadap emisi karbon dioksida, populasi, dan produk domestik bruto dengan konsumsi energi di berbagai sektor sebagai variabel eksogen dan menghasilkan MAPE sebesar 1,16%. Namun, kelemahan utama dari model ini adalah model menganggap hubungan antar data deret waktu hanya bersifat linier. Artinya, model hanya dapat mengenali pola yang lurus atau teratur, sehingga pola nonlinier tidak dapat ditangkap oleh model (Zhang, 2003). Salah satu metode yang dapat digunakan adalah dengan menggunakan pendekatan *machine learning* yang memiliki kemampuan dalam menangani data dengan pola nonlinier secara lebih efektif (Rowan dkk., 2022).

Pendekatan berbasis *machine learning* banyak dimanfaatkan untuk meningkatkan akurasi dalam memodelkan data deret waktu yang bersifat nonlinier. *Machine learning* sendiri merupakan metode komputasi yang mampu belajar dari data atau pengalaman guna meningkatkan kinerja dalam suatu tugas dan menghasilkan prediksi yang lebih tepat (Alpaydin, 2004). Meskipun demikian, pendekatan ini memiliki kelemahan dalam menangani data yang berurutan (*sequential*), karena tidak dirancang khusus untuk memahami hubungan antar data dalam waktu pada deret waktu. *Deep learning* dikembangkan untuk mengatasi masalah yang ada pada *machine learning* sehingga lebih andal dalam mengenali pola keterkaitan jangka panjang dalam data deret waktu (Rowan dkk., 2022).

*Deep learning* berbasis jaringan saraf tiruan dengan minimal 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 dari *deep learning* adalah *Recurrent Neural Network* (RNN) yang merupakan model untuk mengolah data berurutan (*sequential*) dengan menangani hubungan antar data dalam waktu (Tarkus dkk., 2020). Model ini memanfaatkan struktur lapisan yang lebih kompleks untuk mencapai tingkat akurasi dan efisiensi yang tinggi, serta mampu menangani pola data baik yang bersifat linier maupun nonlinier. Hal ini menjadikan model RNN unggul dibandingkan dengan metode peramalan tradisional. Meskipun demikian, model RNN memiliki keterbatasan ketika digunakan untuk peramalan jangka panjang, khususnya saat memproses data dalam skala besar. Salah satu

kelemahannya adalah ketidakmampuan untuk menyimpan informasi jangka panjang secara efektif, sehingga informasi penting yang diperoleh di awal urutan data dapat terlupakan atau hilang (Tian dkk., 2018).

Berdasarkan pada kelemahan metode RNN, dikembangkanlah arsitektur khusus dari RNN, yaitu *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) yang memperkenalkan *gating mechanism*. 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. Model GRU dikembangkan dengan struktur yang lebih sederhana dengan hanya menggunakan dua gerbang utama, yaitu *reset gate* dan *update gate*. Arsitektur model GRU dan proses komputasinya yang lebih sederhana daripada model LSTM, model GRU masih tepat dan efektif dalam menangani masalah yang ada pada model RNN (Atharsyah dan Romli, 2024). Sebagaimana penelitian multivariat yang dilakukan oleh Ananda (2023) untuk meramalkan harga beras di Jakarta berdasarkan kualitasnya dengan mempertimbangkan faktor seperti cuaca, inflasi, harga bahan bakar, nilai tukar rupiah, dan jumlah kasus positif COVID-19 yang menghasilkan nilai MAPE sebesar 2,628%. Metode *deep learning* seperti model GRU ini memiliki keterbatasan karena hanya berfokus pada hubungan nonlinier dalam data dimana data deret waktu yang digunakan jarang menunjukkan karakteristik linier atau nonlinier saja, melainkan kombinasi antar keduanya. Oleh karena itu, pendekatan *hybrid* digunakan untuk mengatasi keterbatasan dalam menangani pola linier dan nonlinier secara bersamaan dalam model individu.

Zhang (2003) menyatakan bahwa tidak ada satu pun metode peramalan yang mampu memberikan hasil terbaik di semua situasi. Hal ini dikarenakan pola data di dunia nyata sangat kompleks dan tidak selalu bisa ditangani secara optimal dengan satu pendekatan model saja. Berdasarkan hal tersebut, dikembangkan sebuah model gabungan yang mengombinasikan kelebihan masing-masing metode sekaligus mengurangi kelemahannya. Model *hybrid* merupakan pendekatan yang mengintegrasikan dua atau lebih model ke dalam satu sistem guna meningkatkan kinerja peramalan. Salah satu pengaplikasiannya adalah dengan menggabungkan model VARIMAX dan model GRU. Model VARIMAX digunakan untuk menganalisis hubungan antar variabel dan menghasilkan prediksi terhadap nilai yang akan datang. Kemudian, hasil prediksi dan residual yang dihasilkan oleh model VARIMAX dijadikan sebagai *input* bagi model GRU, yang bertugas

menangani pola kompleks dan nonlinier dalam data. Model GRU selanjutnya melakukan prediksi ulang berdasarkan informasi yang diberikan sehingga mampu menyempurnakan hasil prediksi yang sebelumnya dibuat oleh model VARIMAX. Kedua model ini dapat bekerja secara komplementer, dimana kelemahan satu model dapat diatasi oleh keunggulan model lainnya. Pendekatan ini diharapkan mampu menghasilkan prediksi yang lebih akurat dibandingkan dengan penggunaan salah satu model secara terpisah. Salah satu penelitian terdahulu telah menunjukkan efektivitas pendekatan *hybrid*, yaitu Aji dan Surjandari (2020) yang melakukan penelitian dengan model *hybrid* VAR-LSTM dan VAR-GRU dalam meramalkan harga transaksi bahan bakar jet di bandara internasional Soekarno-Hatta (CGK), Tangerang. Tidak hanya membandingkan hasil peramalan model *hybrid* saja, pada penelitian ini juga membandingkan hasil peramalan yang diperoleh model *hybrid* dengan model individu VAR, LSTM, dan GRU. Hasil penelitian menunjukkan bahwa model *hybrid* VAR-GRU memiliki hasil yang paling baik untuk kriteria RMSE dan MAPE dibandingkan keempat model lainnya, yaitu sebesar 63,25 dan 0,0060%.

Model *hybrid* dapat diterapkan di berbagai sektor, termasuk dalam analisis pasar saham sebagai bagian dari strategi investasi modern. Salah satu penerapannya adalah untuk menganalisis dan meramalkan pergerakan harga saham emiten besar sektor *consumer goods* seperti PT Indofood Consumer Brand Product Sukses Makmur Tbk (ICBP.JK) dan PT Indofood Sukses Makmur Tbk (INDF.JK) yang memiliki kapitalisasi pasar signifikan serta tergabung dalam indeks LQ45. Indeks LQ45 merupakan indeks yang berisi 45 saham dari perusahaan-perusahaan dengan kapitalisasi pasar besar dan tingkat likuiditas tinggi di Bursa Efek Indonesia (BEI). Saham-saham dalam indeks ini dipilih berdasarkan kriteria seperti frekuensi dan nilai transaksi yang tinggi, kinerja keuangan yang sehat, serta prospek pertumbuhan yang menjanjikan. Komposisi indeks LQ45 dievaluasi setiap enam bulan untuk memastikan hanya saham-saham unggulan yang masuk. Saham yang termasuk dalam indeks LQ45, seperti INDF.JK dan ICBP.JK, umumnya dianggap sebagai saham *blue chip* yang menarik bagi investor karena kestabilan dan reputasinya di pasar modal. Pergerakan saham INDF.JK dan ICBP.JK sebagai perusahaan produsen kebutuhan pokok sebagai perusahaan produsen kebutuhan pokok cenderung bersifat defensif, namun tetap dipengaruhi oleh faktor eksternal seperti harga bahan baku dan nilai tukar rupiah. Nilai tukar memiliki dampak langsung terhadap biaya operasional karena ketergantungan perusahaan pada bahan impor seperti gandum dan minyak sawit, sehingga fluktuasinya dapat

memengaruhi profitabilitas dan sentimen pasar terhadap saham kedua emiten ini.

Penelitian terkait penggunaan model *hybrid* VARIMAX–GRU masih terbatas, terutama dalam konteks peramalan harga penutupan saham PT Indofood *Consumer Brand Product* Sukses Makmur Tbk (ICBP.JK) dan PT Indofood Sukses Makmur Tbk (INDF.JK). Oleh karena itu, penelitian ini bertujuan untuk meramalkan pergerakan harga penutupan saham ICBP.JK dan INDF.JK dengan menerapkan pendekatan model *hybrid* VARIMAX–GRU, yang memadukan keunggulan analisis hubungan linier dan nonlinier dalam data. Hasil dari penelitian ini diharapkan dapat memberikan wawasan yang lebih akurat dan aplikatif bagi investor dalam mengambil keputusan strategis, mengelola risiko, serta mengoptimalkan peluang keuntungan di pasar modal.

## 1.2 Rumusan Masalah

Berdasarkan uraian latar belakang masalah, disusun rumusan masalah sebagai berikut:

1. Pembentukan model VARIMAX, model *hybrid* VARIMAX–E\_GRU, serta model *hybrid* VARIMAX–EP\_GRU untuk meramalkan harga penutupan saham PT ICBP Tbk dan PT INDF Tbk dengan nilai tukar rupiah sebagai variabel eksogen.
2. Hasil peramalan harga penutupan saham PT ICBP Tbk dan PT INDF Tbk dengan nilai tukar rupiah sebagai variabel eksogen yang dihasilkan oleh model VARIMAX, model *hybrid* VARIMAX–E\_GRU, serta model *hybrid* VARIMAX–EP\_GRU.
3. Perbandingan kinerja model VARIMAX, model *hybrid* VARIMAX–E\_GRU, serta model *hybrid* VARIMAX–EP\_GRU dalam melakukan peramalan harga penutupan saham PT ICBP Tbk dan PT INDF Tbk dengan nilai tukar rupiah sebagai variabel eksogen.

### 1.3 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah sebagai berikut:

1. Membangun model VARIMAX, model *hybrid* VARIMAX-E\_GRU, serta model *hybrid* VARIMAX-EP\_GRU untuk meramalkan harga penutupan saham PT ICBP Tbk dan PT INDF Tbk dengan nilai tukar rupiah sebagai variabel eksogen.
2. Mengetahui hasil peramalan harga penutupan saham PT ICBP Tbk dan PT INDF Tbk dengan nilai tukar rupiah sebagai variabel eksogen yang dihasilkan oleh model VARIMAX, model *hybrid* VARIMAX-E\_GRU, serta model *hybrid* VARIMAX-EP\_GRU.
3. Membandingkan kinerja model VARIMAX, model *hybrid* VARIMAX-E\_GRU, serta model *hybrid* VARIMAX-EP\_GRU dalam melakukan peramalan harga penutupan saham PT ICBP Tbk dan PT INDF Tbk dengan nilai tukar rupiah sebagai variabel eksogen.

### 1.4 Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah sebagai berikut:

1. Menambah wawasan bagi pembaca terhadap model *hybrid* VARIMAX-GRU serta pengaplikasiannya.
2. Dapat dijadikan sebagai referensi bagi peneliti selanjutnya dalam melakukan peramalan menggunakan model *hybrid* VARIMAX-GRU dengan jenis data yang berbeda.

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1 Penelitian Terkait Analisis Deret Waktu**

Tahap awal dalam penelitian adalah dengan terlebih dahulu meninjau berbagai penelitian terdahulu yang memiliki keterkaitan dengan topik yang diangkat. Kajian terhadap penelitian sebelumnya tidak hanya memberikan landasan teoritis yang kuat, tetapi juga menjadi dasar empiris yang membantu peneliti memahami bagaimana topik serupa telah dikaji oleh peneliti lain. Penelitian yang relevan memberikan pengetahuan tentang pendekatan metodologis yang telah digunakan, jenis data yang dianalisis, serta hasil atau temuan yang diperoleh. Hal ini memungkinkan peneliti untuk merancang penelitian dengan lebih terarah, menghindari pengulangan yang tidak perlu, dan memilih strategi penelitian yang sesuai dengan tujuan yang ingin dicapai.

Selain itu, kajian terhadap penelitian terdahulu juga membantu peneliti dalam mengidentifikasi kekurangan, keterbatasan, maupun celah yang belum banyak dieksplorasi oleh penelitian sebelumnya sehingga penelitian yang dilakukan dapat menawarkan kontribusi baru dan memiliki nilai kebaruan. Beberapa studi dipilih secara selektif karena memiliki keterkaitan langsung dengan topik yang dibahas, baik dari segi pendekatan, metode analisis, maupun jenis data yang digunakan. Studi-studi tersebut menjadi rujukan dalam menyusun kerangka berpikir serta dalam memilih metode analisis yang tepat. Ringkasan dari penelitian-penelitian terdahulu tersebut disajikan dalam Tabel 1 yang mencakup informasi mengenai judul penelitian, jenis data, metode yang digunakan, serta hasil yang diperoleh.

Tabel 1. Penelitian Terkait

No.	Penelitian	Data	Metode	Hasil	
				RMSE	MAPE
1.	<i>VARIMAX Model to Forecast the Emission of Carbon Dioxide from Energy Consumption in Rubber and Petroleum Industries Sectors in Thailand</i> (Suttichaimethee, 2017)	Data historis harian dari emisi karbon dioksida, populasi, dan PDB serta konsumsi energi pada berbagai sektor di Thailand (2000-2015).	VARIMAX	-	1,01% dan 1,16%
2.	<i>Model Analysis of Gated Recurrent Unit for Multivariate Rice Price Forecasting</i> (Ananda, 2023)	Data historis harian harga beras di Jakarta dengan berbagai kualitas dan faktor cuaca, ekonomi, serta kesehatan (2017-2023).	GRU	-	2,628%
3.	<i>Hybrid Vector Autoregression Recurrent Neural Networks to Forecast Multivariate Time Series Jet Fuel Transaction Price</i> (Aji dan Surjandari, 2020)	Data historis harian harga transaksi bahan bakar jet di Bandara Soekarno-Hatta (CGK), Tangerang, dengan faktor ekonomi (2017-2020).	VAR LSTM GRU VAR-LSTM VAR-GRU	VAR: 62,53 LSTM: 989,95 GRU: 794,27 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%

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

- a. *VARIMAX Model to Forecast the Emission of Carbon Dioxide from Energy Consumption in Rubber and Petroleum Industries Sectors in Thailand* (Suttichaimethee, 2017).

Penelitian ini dilakukan dengan model VARIMAX untuk memprediksi emisi gas karbon dioksida, populasi, dan PDB dengan mempertimbangkan besarnya konsumsi energi di tiga sektor industri di Thailand, yaitu industri karet, kimia dan minyak bumi. Tahapan yang dilakukan dalam penelitian ini adalah pengumpulan data dari tahun 2000 hingga 2015, uji stasioneritas data, uji kointegrasi, menentukan *lag optimum* dengan AIC, membangun model VARIMAX, dan evaluasi model dengan MAPE. Penelitian ini melakukan prediksi untuk meramalkan emisi gas karbon dioksida selama sepuluh tahun kedepan dengan model VARIMAX terbaik yang diperoleh adalah VARIMAX(2,1,2) dengan MAPE sebesar 1,01% dan tiga puluh tahun kedepan dengan model VARIMAX terbaik yang diperoleh adalah VARIMAX(2,1,3) dengan MAPE sebesar 1,16%. Hasil prediksi ini menunjukkan bahwa pada tahun 2025, emisi karbon dioksida di Thailand diperkirakan meningkat sebesar 17,65%, sedangkan pada tahun 2045, diprediksi meningkat hingga 39,68%.

- b. *Model Analysis of Gated Recurrent Unit for Multivariate Rice Price Forecasting* (Ananda, 2023)

Penelitian ini dilakukan dengan model GRU untuk meramalkan harga beras di Jakarta dari kategori *Low-Quality Rice 1* hingga *Super-Quality Rice 2* dengan melibatkan variabel independen. Variabel independen yang digunakan diantaranya adalah faktor cuaca seperti suhu rata-rata, kelembaban rata-rata, curah hujan, durasi sinar matahari, dan kecepatan angin rata-rata, faktor ekonomi seperti tingkat inflasi, harga BBM kategori RON 90 dan RON 92, dan nilai tukar Rupiah terhadap USD, serta faktor kesehatan seperti kasus aktif COVID-19 dan kasus positif harian. Data berasal dari hasil pencatatan harian dari 1 Januari 2017 hingga 28 Februari 2023 oleh Pusat Informasi Harga Pangan Strategis Nasional (PIHPSN) di Pasar Induk Jatinegara, Kramat Jati, dan Pasar Minggu, Stasiun Meteorologi Halim Perdana Kusuma, Bank Indonesia, serta Pertamina. Tahapan yang dilakukan dalam penelitian ini adalah pengumpulan data, *preprocessing* data, *splitting* data, inialisasi parameter model GRU, perancangan model GRU, serta evaluasi model. Evaluasi model dilakukan menggunakan nilai MAPE pada kategori harga beras berbeda. Pada harga beras kategori *Low-Quality Rice 2*, MAPE peramalan adalah sebesar 0.047%.

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

Penelitian ini mengadopsi pendekatan *hybrid* dengan menggabungkan model VAR–LSTM dan VAR–GRU untuk meramalkan harga transaksi bahan bakar jet di Bandara Soekarno-Hatta (CGK), Tangerang, Indonesia. Data yang digunakan mencakup data harian dari harga minyak mentah global, harga dasar bahan bakar jet, harga bahan bakar lokal, nilai tukar mata uang, serta tingkat inflasi di Indonesia dalam rentang waktu Januari 2017 hingga April 2020. Tahapan yang dilakukan dalam penelitian ini adalah pengumpulan data dari berbagai sumber, integrasi dan pembersihan data, normalisasi skala data, pembangunan model VAR, pelatihan model LSTM dan GRU, serta evaluasi kinerja model menggunakan MAD, RMSE, MAPE, dan tingkat akurasi. Hasil analisis menunjukkan bahwa model *hybrid* VAR–GRU memiliki akurasi tertinggi, yakni 99,40%, disusul 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.

## 2.2 Deret Waktu

Deret waktu atau *time series* merupakan rangkaian data observasi yang dicatat secara berurutan berdasarkan interval waktu tertentu, seperti harian, bulanan, atau tahunan (Wei, 2006). Setiap observasi dalam deret waktu tidak berdiri sendiri, melainkan memiliki keterkaitan dengan observasi sebelumnya. Data ini umumnya digunakan untuk merepresentasikan informasi historis yang dapat dianalisis lebih lanjut guna memahami suatu fenomena dari waktu ke waktu.

### 2.2.1 Analisis Deret Waktu

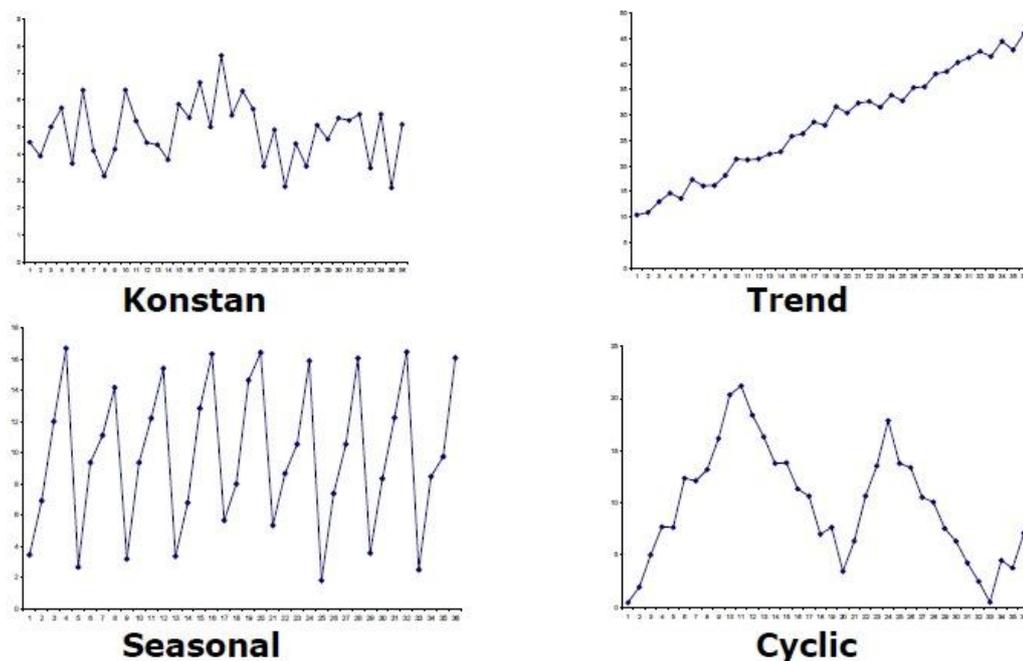
Analisis deret waktu adalah metode statistik yang digunakan untuk menganalisis serangkaian data yang dikumpulkan secara teratur dari waktu ke waktu secara berurutan dalam interval waktu yang konsisten, seperti dalam hari, minggu, bulan, kuartal, dan tahun (Wei, 2006). Tujuan utama dari analisis deret waktu adalah menemukan model yang tepat untuk merepresentasikan hubungan antar periode dalam data, serta mengidentifikasi pola, tren, dan fluktuasi yang terdapat dalam

data historis.

Menurut Hanke dan Wichern (2009), data dapat dikelompokkan ke dalam empat pola utama sebagai berikut:

1. Pola Konstan muncul ketika data deret waktu bergerak naik-turun di sekitar nilai rata-rata yang relatif konstan. Data dengan karakteristik ini dikenal sebagai data deret waktu stasioner.
2. Pola Tren menunjukkan pergerakan data deret waktu dalam jangka panjang untuk suatu periode tertentu, baik berupa peningkatan maupun penurunan.
3. Pola Seasonal atau Musiman terlihat dari fluktuasi data deret waktu yang terjadi secara teratur dalam periode tertentu yang kurang dari satu tahun, seperti setiap triwulan, kuartal, bulan, minggu, atau bahkan hari.
4. Pola Siklik ditandai dengan pergerakan data deret waktu yang naik atau turun tanpa adanya periode waktu yang tetap.

Visualisasi pola data deret waktu diilustrasikan pada Gambar 1 sebagai berikut:



Gambar 1. Pola Data Deret Waktu (Montgomery dkk., 2015)

## 2.2.2 Model Deret Waktu Multivariat

Model deret waktu multivariat digunakan ketika analisis deret waktu melibatkan lebih dari satu variabel yang diamati secara simultan (Wei, 2006). Pendekatan ini memanfaatkan keterkaitan antar variabel untuk menghasilkan prediksi yang lebih akurat dibandingkan jika variabel dianalisis secara terpisah. Beberapa model yang umum digunakan dalam analisis deret waktu multivariat antara lain *Vector Autoregressive* (VAR), *Vector Moving Average* (VMA), *Vector Autoregressive Moving Average* (VARMA), *Vector Autoregressive Integrated Moving Average* (VARIMA), dan *Vector Autoregressive Integrated Moving Average Exogenous* (VARIMAX).

### 2.2.2.1 Model *Vector Autoregressive* (VAR)

Model VAR merupakan pengembangan dari model *autoregressive* (AR) yang mencakup lebih dari satu variabel amatan yang dimodelkan secara simultan. Model ini pertama kali diperkenalkan sebagai penyempurnaan dari gagasan Granger. Granger (1969) menjelaskan bahwa jika terdapat hubungan kausal antara dua variabel, misalnya  $x$  dan  $y$ , dimana  $x$  memengaruhi  $y$ , maka informasi historis  $x$  dapat digunakan untuk memprediksi  $y$ . Model VAR adalah sistem persamaan dinamis dimana pendugaan suatu variabel pada periode tertentu bergantung pada nilai variabel tersebut dan variabel lain yang terkait pada periode-periode sebelumnya (Pratama dan Saputro, 2018). Menurut Gujarati (2012), salah satu keunggulan utama model VAR adalah tidak memerlukan penentuan variabel endogen dan eksogen secara eksplisit, karena semua variabel dalam model ini diperlakukan sebagai variabel endogen. Persamaan umum dari model VAR( $p$ ) menurut Wei (2019) dituliskan dalam persamaan (2.1) sebagai berikut:

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

dengan:

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

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

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

### 2.2.2.2 Model Vector Moving Average (VMA)

Model VMA adalah pengembangan dari model *moving average* (MA) yang mencakup lebih dari satu variabel amatan yang dimodelkan secara simultan. Model VMA adalah sebuah sistem persamaan dinamis dimana estimasi pada suatu periode waktu tertentu dipengaruhi oleh pola pergerakan variabel dan pengaruh dari variabel lain yang terkait pada periode sebelumnya (Pratama dan Saputro, 2018). Model VMA tidak memerlukan penentuan variabel endogen dan eksogen secara eksplisit, karena semua variabel dalam model ini diperlakukan sebagai variabel endogen. Persamaan umum dari model VMA( $q$ ) menurut Wei (2019) dituliskan dalam persamaan (2.2) sebagai berikut:

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

dengan:

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

$$\Theta_1, \dots, \Theta_q = \text{matriks parameter } \textit{moving average} \text{ berukuran } N \times N$$

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

### 2.2.2.3 Model Vector Autoregressive Moving Average (VARMA)

Model VARMA adalah pengembangan dari *Autoregressive Moving Average* (ARMA) yang dirancang untuk menganalisis hubungan antara beberapa deret waktu secara simultan. Model VARMA merupakan gabungan antara model VAR( $p$ ) dan model VMA( $q$ ) sehingga modelnya berbentuk VARMA( $p, q$ ). Model VARMA tidak memerlukan penentuan variabel endogen dan eksogen secara eksplisit, karena semua variabel dalam model ini diperlakukan sebagai variabel endogen. Namun, model VARMA ini mempunyai syarat bahwa data harus stasioner (Pratiwi, 2023). Persamaan umum dari model VARMA( $p, q$ ) menurut Wei (2019) dituliskan dalam persamaan (2.3) sebagai berikut:

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

dengan:

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

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

$$\Theta_1, \dots, \Theta_q = \text{matriks parameter } \textit{moving average} \text{ berukuran } N \times N$$

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

#### 2.2.2.4 Model Vector Autoregressive Integrated Moving Average (VARIMA)

Model VARIMA adalah pengembangan dari model VARMA dengan memasukkan orde integrasi atau *differencing* pada model. Orde integrasi pada model VARIMA dilambangkan dengan  $d$  sehingga modelnya berbentuk VARIMA( $p, d, q$ ). Integrasi ini digunakan untuk mengatasi data yang tidak stasioner dengan cara melakukan *differencing*. Singkatnya, model VARMA cocok digunakan untuk data yang sudah stasioner, sedangkan model VARIMA dirancang untuk data yang tidak stasioner karena memungkinkan transformasi data menjadi stasioner melalui tahap *differencing* sebelum analisis dilakukan (Pratiwi, 2023). Persamaan umum dari model VARIMA( $p, d, q$ ) menurut Harvey (2006) dituliskan dalam persamaan (2.4) sebagai berikut:

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

dengan:

$$\begin{aligned} \mathbf{Z}_t &= [Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^T \text{ vektor deret waktu stasioner} \\ &\quad \text{ukuran } N \times 1 \\ \Delta^d &= \text{operator } \textit{differencing} \\ \Phi_1, \dots, \Phi_p &= \text{matriks parameter } \textit{autoregressive} \text{ ukuran } N \times N \\ &\quad \text{dengan } \Phi_p(B) = \Phi_0 + \Phi_1 B + \Phi_2 B^2 + \dots + \Phi_p B^p \\ \Theta_1, \dots, \Theta_q &= \text{matriks parameter } \textit{moving average} \text{ ukuran } N \times N \\ &\quad \text{dengan } \Theta_q(B) = \Theta_0 - \Theta_1 B - \Theta_2 B^2 - \dots - \Theta_q B^q \\ \mathbf{a}_t &= [a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T \text{ vektor } \textit{error} \text{ ukuran } N \times 1 \end{aligned}$$

#### 2.2.2.5 Model Vector Autoregressive Integrated Moving Average Exogenous (VARIMAX)

Model VARIMAX adalah pengembangan dari model VARIMA yang mencakup variabel eksogen dalam analisisnya. Variabel eksogen dalam model VARIMAX ditentukan di luar sistem model dan berfungsi sebagai faktor yang memengaruhi variabel endogen. Sementara itu, variabel endogen ditentukan di dalam model dan dapat dipengaruhi oleh variabel eksogen maupun oleh variabel endogen lainnya. Model VARIMAX dapat menganalisis dan menjelaskan hubungan dinamis antara variabel endogen dan variabel eksogen, sehingga cocok digunakan dalam situasi dimana pengaruh faktor luar perlu diperhitungkan dalam model (Nurfadilah dan Kasse, 2018). Persamaan umum dari model VARIMAX( $p, d, q$ ) menurut Harvey

(2006) dituliskan dalam persamaan (2.5) sebagai berikut:

$$\Delta^d \mathbf{Z}_t = \Phi_1 \Delta^d \mathbf{Z}_{t-1} + \dots + \Phi_p \Delta^d \mathbf{Z}_{t-p} + \mathbf{a}_t - \Theta_1 \mathbf{a}_{t-1} - \dots - \Theta_q \mathbf{a}_{t-q} + \delta_r \mathbf{x}_t \quad (2.5)$$

dengan:

$$\begin{aligned} \mathbf{Z}_t &= [Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^T \text{ vektor deret waktu stasioner} \\ &\quad \text{ukuran } N \times 1 \\ \Delta^d &= \text{operator } \textit{differencing} \\ \Phi_1, \dots, \Phi_p &= \text{matriks parameter } \textit{autoregressive} \text{ ukuran } N \times N \\ &\quad \text{dengan } \Phi_p(B) = \Phi_0 + \Phi_1 B + \Phi_2 B^2 + \dots + \Phi_p B^p \\ \Theta_1, \dots, \Theta_q &= \text{matriks parameter } \textit{moving average} \text{ ukuran } N \times N \\ &\quad \text{dengan } \Theta_q(B) = \Theta_0 - \Theta_1 B - \Theta_2 B^2 - \dots - \Theta_q B^q \\ \mathbf{a}_t &= [a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T \text{ vektor } \textit{error} \text{ ukuran } N \times 1 \\ \delta_r &= \text{matriks parameter peubah eksogen ukuran } N \times S \\ \mathbf{x}_t &= \text{vektor peubah eksogen ukuran } N \times 1 \end{aligned}$$

### 2.2.3 Asumsi Model Deret Waktu

Asumsi dasar yang harus dipenuhi agar model yang dibangun dapat menghasilkan estimasi dan peramalan yang andal adalah stasioneritas data dan residual yang bersifat *white noise* (Wei, 2006). Stasioneritas mengacu pada kondisi dimana pola data tidak mengalami pergeseran seiring waktu, sehingga memungkinkan model untuk menangkap struktur data secara konsisten. Selain itu, asumsi lainnya adalah bahwa residual dari model harus bersifat acak dan tidak memiliki pola tertentu.

#### 2.2.3.1 Stasioneritas Data

Stasioneritas suatu data deret waktu dapat mempunyai pengaruh yang signifikan terhadap suatu peramalan. Data deret waktu dianggap stasioner jika rata-rata dan variansi untuk setiap *lag* tetap konsisten sepanjang waktu, tanpa bergantung pada periode tertentu. Sebaliknya, ketidakstasioneran terjadi ketika rata-rata dan variansi data berfluktuasi atau berubah-ubah sepanjang waktu (*time-varying mean and variance*) (Makridakis dkk., 1999). Stasioneritas data dapat dianalisis secara visual dengan memanfaatkan plot data. Selain itu juga dapat melalui pengujian khusus untuk mengukur tingkat kestabilan data. Saat ini, salah satu metode yang paling umum digunakan untuk menguji stasioneritas data adalah uji akar unit (*unit root test*), khususnya melalui pengujian *Augmented Dickey-Fuller* (ADF). Menurut Wei

(2006), persamaan uji ADF dituliskan dalam persamaan (2.6) sebagai berikut:

$$Y_t = \rho Y_{t-1} + \varepsilon_t \quad (2.6)$$

dimana  $\rho$  adalah koefisien *autoregressive* dan  $\varepsilon_t$  adalah *error term* yang mempunyai rata-rata = 0 dan varians konstan serta tidak mengandung autokorelasi. Jika  $\rho = 1$ , maka dapat dinyatakan bahwa variabel mempunyai akar unit. Prosedur pengujian akar unit dengan uji ADF sebagai berikut (Dickey dan Fuller, 1979):

1. Hipotesis

- $H_0: \rho \geq 1$ , terdapat akar unit (data tidak stasioner)
- $H_1: \rho < 1$ , tidak terdapat akar unit (data stasioner)

2. Taraf signifikansi

$$\alpha = 5\% = 0,05$$

3. Statistik Uji

Uji akar unit ADF menggunakan statistik uji  $t$  yang ditulis dalam persamaan (2.7) sebagai berikut:

$$t = \frac{\hat{\delta}}{Se(\hat{\delta})} \quad (2.7)$$

dengan:

$$\begin{aligned} (\hat{\delta}) &= \text{nilai duga parameter } \textit{autoregressive} \\ Se(\hat{\delta}) &= \text{standar } \textit{error} \text{ dari } \hat{\delta} \end{aligned}$$

4. Kriteria Uji

- Tolak  $H_0$  jika statistik uji  $t > t_{n-1, \alpha}$  atau  $p\text{-value} < \alpha$
- Tidak tolak  $H_0$  jika statistik uji  $t < t_{n-1, \alpha}$  atau  $p\text{-value} > \alpha$

5. Keputusan

6. Kesimpulan

Jika ditemukan bahwa data tidak stasioner dalam rata-rata, maka data ditransformasi melalui *differencing* (Box dkk., 2015). *Differencing* adalah proses menghitung selisih antara nilai observasi melalui perubahannya. Rumusnya dituliskan dalam persamaan (2.8) sebagai berikut:

$$\Delta^d Y_t = Y_t - Y_{t-d} \quad (2.8)$$

dengan:

$$\begin{aligned} Y_t &= \text{pengamatan pada waktu ke-}t \\ Y_{t-d} &= \text{pengamatan pada waktu ke-}(t-d) \\ d &= \text{orde } \textit{differencing} \end{aligned}$$

Jika data asli sudah stasioner, maka data tersebut disebut berintegrasi pada orde 0, yang dilambangkan dengan  $d = 0$ . Jika setelah *differencing* pertama data menjadi stasioner, maka data tersebut berintegrasi pada orde 1, yang dilambangkan dengan  $d = 1$ . Proses ini terus dilakukan hingga data menjadi stasioner pada orde tertentu, yaitu  $d = n$ , dengan  $n$  menunjukkan jumlah *differencing* yang diperlukan. *Differencing* pertama menggambarkan pengaruh tren terhadap perubahan rata-rata pada data deret waktu, sedangkan *differencing* kedua menjelaskan perubahan kemiringan pada data deret waktu dan seterusnya (Montgomery dkk., 2015). Pengaplikasian *differencing* pada praktiknya, biasanya satu atau dua kali *differencing* sudah cukup untuk menghilangkan tren yang ada dalam data.

### 2.2.3.2 Residual White Noise

Uji asumsi residual digunakan untuk memastikan bahwa model analisis yang dibuat bekerja dengan baik dan memberikan hasil yang dapat dipercaya. Asumsi dasar bahwa residual bersifat *white noise* adalah tidak terdapat korelasi antar residual dengan mean sama dengan nol dan varians konstan. Uji *white noise* dapat dilakukan dengan menggunakan statistik uji *Ljung-Box*. Prosedur pengujian dengan metode *Ljung-Box* sebagai berikut (Ljung dan Box, 1978):

#### 1. Hipotesis

- $H_0$ :  $\rho_1 = \rho_2 = \dots = \rho_k = 0$ , residual bersifat *white noise*
- $H_1$ : Minimal ada satu  $\rho_k \neq 0$ ;  $k = 1, 2, \dots, k$  residual tidak bersifat *white noise*

#### 2. Taraf signifikansi

$$\alpha = 5\% = 0,05$$

#### 3. Statistik Uji

Uji asumsi residual *white noise* menggunakan statistik uji *Ljung-Box* yang dituliskan dalam persamaan (2.9) sebagai berikut:

$$Q = n(n+2) \sum_{i=1}^k \frac{\rho_k^2}{(n-k)} \quad (2.9)$$

dengan:

- $n$  = banyaknya data pengamatan
- $\rho_k$  = autokorelasi *lag* ke- $k$
- $k$  = jumlah *lag*

4. Kriteria Uji
  - Tolak  $H_0$  jika statistik uji  $Q > \chi^2_{1-\alpha, k}$  atau  $p\text{-value} < \alpha$
  - Tidak tolak  $H_0$  jika statistik uji  $Q < \chi^2_{1-\alpha, k}$  atau  $p\text{-value} > \alpha$
5. Keputusan
6. Kesimpulan

#### 2.2.4 Kausalitas Granger

Kausalitas Granger merupakan suatu pendekatan statistik yang digunakan untuk menguji apakah suatu variabel runtun waktu memiliki pengaruh kausal terhadap variabel lain dalam konteks prediktabilitas. Konsep ini pertama kali diperkenalkan oleh Granger (1969) dan menjadi tonggak penting dalam pengembangan analisis data deret waktu. Kausalitas dalam kerangka Granger tidak dimaknai secara filosofis sebagai hubungan sebab-akibat dalam pengertian mutlak, melainkan sebagai hubungan prediktif yang apabila nilai masa lalu dari suatu variabel secara signifikan membantu meningkatkan kemampuan prediksi terhadap variabel lain, maka dapat dikatakan bahwa variabel tersebut “menyebabkan” variabel lainnya dalam arti Granger.

Metode ini didasarkan pada prinsip bahwa suatu variabel dapat dikatakan sebagai penyebab Granger dari variabel lain jika informasi historis yang dimilikinya mampu menjelaskan pergerakan variabel target secara lebih baik daripada jika hanya menggunakan informasi masa lalu dari variabel target itu sendiri. Dengan kata lain, kausalitas Granger menilai apakah terdapat kontribusi informasi tambahan yang bersifat signifikan dari satu variabel terhadap variabel lainnya.

Pengujian kausalitas Granger memerlukan data deret waktu yang bersifat stasioner. Oleh karena itu, sebelum melakukan pengujian, umumnya dilakukan pengujian stasioneritas seperti uji *Augmented Dickey-Fuller* (ADF). Jika data tidak stasioner, maka transformasi seperti diferensiasi perlu dilakukan terlebih dahulu untuk memenuhi asumsi dasar tersebut.

Uji kausalitas Granger biasanya diterapkan dalam kerangka model VAR untuk sistem dengan variabel endogen, atau model VARMAX apabila terdapat variabel eksogen. Jumlah lag optimal yang digunakan dalam model penting untuk ditentukan karena pemilihan lag yang tidak tepat dapat menghasilkan kesimpulan

kausalitas yang kurang baik. Pemilihan lag optimal biasanya dilakukan dengan menggunakan kriteria informasi seperti *Bayesian Information Criterion* (BIC).

Hasil uji kausalitas Granger ditafsirkan melalui signifikansi statistik dari parameter lag variabel yang diuji. Apabila parameter tersebut signifikan pada tingkat kepercayaan tertentu (misalnya 5%), maka terdapat bukti bahwa variabel independen secara Granger menyebabkan variabel dependen. Namun demikian, penting untuk dicatat bahwa kausalitas Granger tidak membuktikan hubungan kausal dalam arti struktural atau teoritis, melainkan hanya menunjukkan keterkaitan prediktif berdasarkan informasi historis dalam data yang diamati. Kausalitas Granger banyak digunakan dalam berbagai bidang seperti ekonomi dan keuangan untuk mengevaluasi interaksi antar variabel makroekonomi, hubungan pasar keuangan, serta pengaruh faktor eksternal terhadap variabel utama dalam model yang dianalisis.

### **2.2.5 Peramalan**

Peramalan adalah upaya untuk memprediksi peristiwa yang akan terjadi di masa depan. Peramalan memiliki peran penting di berbagai bidang, seperti bisnis, industri, ekonomi, ilmu lingkungan, kedokteran, politik, dan keuangan. Berdasarkan rentang waktunya, peramalan dapat dikelompokkan menjadi jangka pendek, jangka menengah, dan jangka panjang (Montgomery dkk., 2015). Hasil peramalan yang akurat dan bermanfaat dalam pengambilan sebuah keputusan, memiliki dua hal pokok yang perlu diperhatikan, yaitu pengumpulan data yang relevan dengan tujuan peramalan dan pemilihan metode peramalan yang sesuai untuk memaksimalkan pemanfaatan informasi yang diperoleh dari data tersebut sehingga hasil peramalan akan optimal (Nurfadilah dan Kasse, 2018).

Menurut Montgomery dkk. (2015), metode peramalan secara garis besar dibagi menjadi dua kelompok, yaitu:

1. Metode peramalan kualitatif adalah metode yang bersifat subjektif karena melibatkan penilaian dan keputusan para ahli dalam prosesnya. Metode ini sering digunakan dalam situasi dimana data historis yang dapat dijadikan dasar untuk peramalan sangat terbatas atau bahkan tidak ada.
2. Metode peramalan kuantitatif adalah metode yang menggunakan data historis dan model matematis untuk melakukan prediksi. Model ini membantu

mengenali pola dalam data dan menunjukkan hubungan statistik antara nilai di masa lalu dengan nilai saat ini. Setelah pola tersebut dirangkum, model ini digunakan untuk memproyeksikan tren atau pola serupa ke masa depan. Dengan kata lain, metode ini memanfaatkan perilaku masa lalu dan saat ini untuk memperkirakan apa yang akan terjadi di masa depan.

### 2.3 *Machine Learning*

*Machine learning* atau pembelajaran mesin merupakan cabang dari kecerdasan buatan yang bertujuan untuk membuat komputer mampu belajar dan bertindak layaknya manusia. Komputer dibekali dengan data dan informasi sebagai bentuk pengalaman agar dapat mengenali pola yang kompleks serta membuat keputusan cerdas secara mandiri. Menurut Rowan dkk. (2022), *machine learning* diterapkan dalam berbagai disiplin ilmu seperti matematika, statistika, dan data mining, dengan pendekatan yang memungkinkan mesin belajar dari data tanpa memerlukan instruksi atau pemrograman tambahan. Proses ini mencakup dua tahapan utama, yaitu *training* yang berfungsi untuk membangun model pembelajaran, serta *testing* yang digunakan untuk mengukur kinerja model yang telah dikembangkan. Pendekatan utama yang digunakan untuk mengembangkan model yang dapat belajar dari data adalah sebagai berikut (Alpaydin, 2004):

1. Pembelajaran *supervised* (terawasi)

Pembelajaran terawasi adalah model belajar dari pasangan data yang berisi *input* dan *output* yang sesuai, dimana model dilatih menggunakan dataset berlabel. Artinya, setiap data masukan (*input*) memiliki pasangan dengan label atau hasil yang diinginkan (*output*). Model menggunakan data untuk mempelajari hubungan antara *input* dan *output*, sehingga dapat membuat prediksi (*regression*) atau mengklasifikasikan data baru (*classification*).

2. Pembelajaran *unsupervised* (tidak terawasi)

Pembelajaran tidak terawasi adalah model belajar yang tidak memiliki informasi target yang tepat dalam data, dimana model dilatih menggunakan *dataset* yang tidak memiliki label. Tujuan utama adalah menemukan struktur atau pola yang tersembunyi dalam data. Model ini bertujuan untuk menemukan struktur tersembunyi, pola, atau hubungan dalam data tanpa adanya informasi eksplisit tentang *output* yang diinginkan, sehingga biasanya digunakan untuk *clustering*.

3. Pembelajaran *semi-supervised* dan *reinforcement*

Pembelajaran *semi-supervised* adalah model belajar yang cocok digunakan

untuk sejumlah data berukuran besar yang dibagi menjadi dua bagian, yaitu data yang berlabel dan tidak berlabel. Pembelajaran *reinforcement* bertujuan untuk memaksimalkan *output* dan meminimalkan risiko melalui interaksi agen dengan lingkungannya. Agen mengamati data, mengambil tindakan, dan menerima "reward" sebagai umpan balik. Proses ini berulang, dengan agen terus menyesuaikan keputusan berdasarkan pengalaman untuk meningkatkan akurasi hasil.

### 2.3.1 Feature Scaling

*Feature scaling* merupakan salah satu teknik *preprocessing* data yang digunakan untuk mengubah nilai-nilai numerik yang memiliki rentang berbeda menjadi skala yang seragam. Proses ini sangat penting dalam *machine learning* karena membantu meningkatkan kestabilan data serta mencegah gangguan yang mungkin terjadi selama proses pelatihan model. Selain itu, *feature scaling* juga dapat mempercepat waktu pelatihan dan meningkatkan efektivitas serta akurasi model dalam melakukan peramalan. *Feature scaling* dapat berupa standarisasi data atau normalisasi data. Normalisasi bertujuan untuk mengubah nilai data ke dalam suatu rentang tertentu, sehingga setiap fitur berada dalam skala yang sama dan lebih mudah diproses oleh algoritma pembelajaran (Singh dan Singh, 2020).

#### 2.3.1.1 Normalisasi Data

Metode *scaling* yang umum digunakan adalah *MinMaxScaler* dimana metode ini mengubah proporsi data dari rentang aslinya sehingga semua nilai dalam *dataset* berada dalam kisaran antara 0 dan 1 (Ambarwari dkk., 2020). Persamaan dari pendekatan *MinMaxScaler* dalam *dataset* dituliskan dalam persamaan (2.10) sebagai berikut:

$$X_{norm} = \frac{(x_i - x_{min})}{(x_{max} - x_{min})} \quad (2.10)$$

dengan:

- $X_{norm}$  = nilai hasil normalisasi
- $x$  = nilai data aktual ke- $i$
- $x_{min}$  = nilai minimum data aktual
- $x_{max}$  = nilai maksimum data aktual

### 2.3.1.2 Denormalisasi Data

Proses denormalisasi data digunakan untuk dapat mengembalikan *output* dari jaringan saraf agar *output* dapat kembali berada pada *range* sebelumnya seperti pada data aktual (Tasyurek, 2022). Rumus denormalisasi data yang digunakan berasal dari skalasi apa yang dipakai sebelumnya. Persamaan denormalisasi data untuk *MinMaxScaler* dituliskan dalam persamaan (2.11) sebagai berikut:

$$X_d = x_p(x_{max} - x_{min}) + x_{min} \quad (2.11)$$

dengan:

$X_d$	= nilai data normal
$x_p$	= nilai hasil <i>output</i>
$x_{min}$	= data dengan nilai minimum
$x_{max}$	= data dengan nilai maksimum

### 2.3.2 Deep Learning

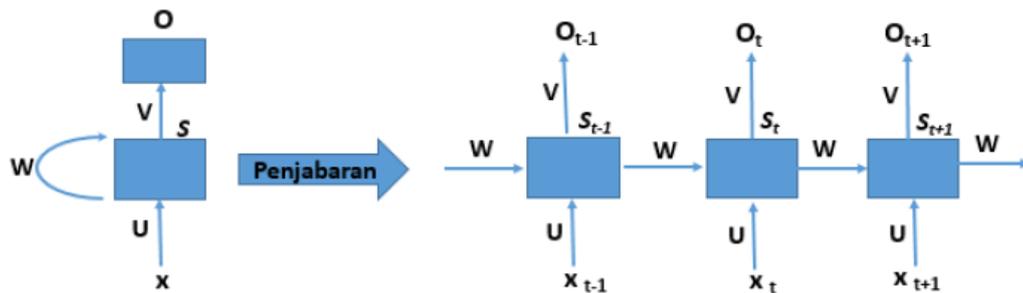
Pembelajaran mendalam, juga dikenal sebagai *deep learning* merupakan pengembangan dari *machine learning* yang memanfaatkan struktur jaringan saraf tiruan dengan minimal tiga lapisan untuk mengekstraksi fitur-fitur yang lebih kompleks dari data sehingga memungkinkan model untuk belajar dan mengolah data dalam jumlah besar dan beragam, serta dapat menyelesaikan permasalahan yang sering kali sulit ditangani oleh metode *machine learning* (Rowan dkk., 2022). *Deep learning* terdiri atas beberapa lapisan utama, yaitu lapisan *input*, lapisan tersembunyi, dan lapisan *output*. Salah satu keunggulan *deep learning* adalah kemampuannya untuk mengubah data yang bersifat nonlinear menjadi bentuk linear secara bertahap melalui proses transformasi di lapisan tersembunyi. Keunggulan tersebut menjadikan algoritma *deep learning* banyak digunakan dalam berbagai aplikasi, terutama dalam pengenalan pola (*pattern analysis*) dan klasifikasi, yang meliputi data gambar, suara, teks, serta deret waktu.

#### 2.3.2.1 Recurrent Neural Network (RNN)

*Recurrent Neural Network* merupakan jenis jaringan saraf tiruan yang dirancang secara khusus untuk menangani data yang bersifat sekuensial, seperti pada analisis

deret waktu. Salah satu karakteristik utama dari model RNN adalah adanya koneksi berulang yang memungkinkan jaringan ini menyimpan dan memperbarui lapisan tersembunyi dengan mempertimbangkan *input* saat ini serta informasi dari waktu sebelumnya (Yu dkk., 2019). Struktur dasar model RNN terdiri atas sel berulang, termasuk fungsi aktivasi seperti *tanh*, yang menjalankan proses yang sama pada setiap elemen dalam suatu urutan. Keunggulan utama arsitektur ini terletak pada kemampuannya memanfaatkan informasi historis untuk menghasilkan prediksi terhadap data sekuensial yang belum diketahui di masa depan.

Model RNN memiliki struktur utama yang terdiri dari tiga lapisan, yaitu lapisan *input*, lapisan tersembunyi, dan lapisan *output*. Informasi yang diterima dari *input* diteruskan ke lapisan tersembunyi, dimana jaringan juga menggabungkan informasi historis dari waktu sebelumnya (Yin dkk., 2017). Meskipun model RNN menunjukkan kinerja yang baik dalam berbagai aplikasi, jaringan ini seringkali menghadapi tantangan teknis seperti *vanishing gradient* dan *exploding gradient*, yang membatasi kemampuannya dalam mempertahankan informasi jangka panjang (Tian dkk., 2018). Masalah *vanishing gradient* terjadi ketika jaringan memiliki banyak lapisan dan urutan *input* yang panjang, menyebabkan bobot yang dihitung selama proses *backpropagation* menjadi sangat kecil hingga mendekati nol. Hal ini membuat sinyal gradien melemah atau bahkan hilang, sehingga pembelajaran menjadi tidak efektif. Sebaliknya, jika bobot yang dihitung terlalu besar, gradien dapat membesar secara berlebihan dan menimbulkan *exploding gradient*, yang menyebabkan ketidakstabilan dalam pelatihan model (Salehinejad dkk., 2018). Masalah ini diatasi dengan dikembangkannya varian dari model RNN seperti LSTM dan GRU. Kedua model ini dirancang untuk meningkatkan efisiensi serta kemampuan jaringan dalam memproses data sekuensial secara lebih efektif. Model LSTM memperkenalkan tiga jenis gerbang utama, yaitu *forget gate*, *input gate*, dan *output gate*, yang berfungsi untuk mengatur informasi mana yang perlu dipertahankan atau diabaikan. Meskipun efektif, struktur model LSTM cenderung lebih kompleks dan membutuhkan sumber daya komputasi yang lebih besar. Model GRU yang diperkenalkan oleh Cho dkk. (2014) menjadi alternatif karena menawarkan arsitektur yang lebih sederhana dengan hanya dua gerbang, yaitu *reset gate* dan *update gate*. Model GRU tetap mampu mempertahankan kinerja yang baik dalam mengatasi masalah pemrosesan data sekuensial yang dihadapi oleh model RNN dengan desain yang lebih ringan daripada model LSTM. Arsitektur model RNN diilustrasikan pada Gambar 2 sebagai berikut:



Gambar 2. Arsitektur *Recurrent Neural Network* (Wijanarko dkk., 2024)

Berdasarkan Gambar 2,  $s_t$  dan  $o_t$  dapat direpresentasikan dalam persamaan (2.12) dan (2.13) sebagai berikut (Wijanarko dkk., 2024):

$$s_t = f(U \cdot X_t + W \cdot s_{t-1}) \quad (2.12)$$

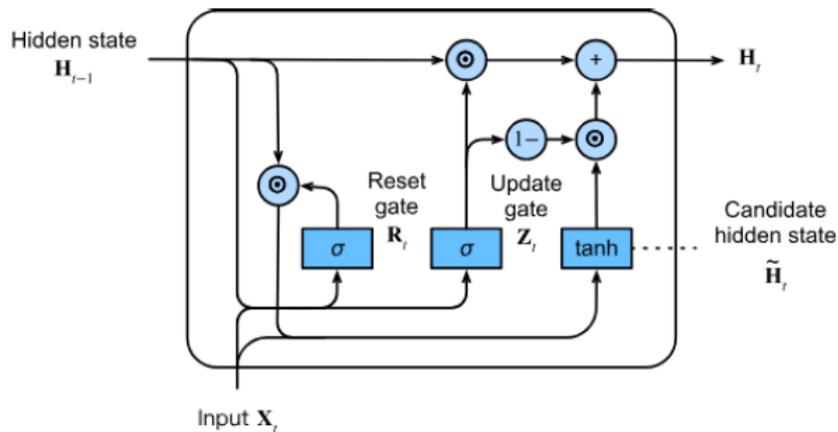
$$o_t = g(V \cdot s_t) \quad (2.13)$$

dengan:

$s_t$	= <i>hidden state</i> untuk tiap-tiap <i>time step</i> $t$
$U, V, W$	= bobot pada setiap <i>layer</i>
$x_t$	= <i>input</i> pada waktu ke- $t$
$o_t$	= <i>output</i> pada waktu ke- $t$
$f(\dots)$ dan $g(\dots)$	= fungsi nonlinier

### 2.3.2.2 *Gated Recurrent Unit (GRU)*

*Gated Recurrent Unit* diperkenalkan pertama kali oleh Cho dkk. (2014) sebagai salah satu varian dari arsitektur model RNN. Model GRU dirancang agar setiap unit di dalam jaringan mampu secara adaptif melakukan *reset* atau pembaruan terhadap informasi yang tersimpan dalam *memory cell*. Model GRU merupakan versi yang lebih sederhana dari LSTM karena tidak menggunakan *cell state* secara eksplisit. Sebaliknya, pembaruan parameter dilakukan langsung melalui *hidden state*. Model GRU juga menggunakan lebih sedikit gerbang (*gate*) dalam proses pembaruan tersebut. Salah satunya adalah *reset gate*, yang menentukan seberapa banyak informasi dari *hidden state* sebelumnya yang akan digunakan kembali. Sementara itu, *update gate* bertugas untuk mengontrol bagian mana dari informasi terdahulu yang akan dipertahankan dan dibawa ke langkah waktu berikutnya (Aggarwal, 2018). Skema cell dari arsitektur GRU ditampilkan pada Gambar 3 sebagai berikut:



Gambar 3. Arsitektur *Gated Recurrent Unit* (Saputra dkk., 2023)

Tahapan yang dilakukan dalam penggunaan model GRU adalah sebagai berikut (Chung dkk., 2014):

1. *Reset gate* menerima *input* saat ini dan *hidden state timestep* sebelumnya. *Reset gate* akan memilih dan menentukan banyak informasi yang akan disimpan dari *hidden state* sebelumnya, dengan fungsi aktivasi sigmoid. Persamaan untuk menghitung *reset gate* dituliskan dalam persamaan (2.14) sebagai berikut:

$$r_t = \sigma(W_r \cdot X_t + U_r \cdot h_{t-1} + b_r) \quad (2.14)$$

dengan:

- $r_t$  = nilai *reset gate* pada *timestep t*
- $\sigma$  = fungsi aktivasi sigmoid
- $W_r, U_r$  = nilai parameter *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. Menentukan seberapa banyak informasi dari *time step* terdahulu yang dapat disimpan untuk perhitungan *hidden state* yang digunakan sebagai *input* di *time step* berikutnya dan menentukan pengaruh informasi dari *time step* terdahulu pada *output* di *time step* saat ini. Proses ini berlangsung di *update gate* menggunakan fungsi aktivasi sigmoid. Persamaan untuk menghitung *update gate* dituliskan dalam persamaan (2.15) sebagai berikut:

$$z_t = \sigma(W_z \cdot X_t + U_z \cdot h_{t-1} + b_z) \quad (2.15)$$

dengan:

$$\begin{aligned}
 Z_t &= \text{nilai } \textit{update gate} \text{ pada } \textit{timestep } t \\
 \sigma &= \text{fungsi aktivasi sigmoid} \\
 W_z, U_z &= \text{nilai parameter } \textit{weight} \text{ untuk } \textit{update gate} \\
 h_{t-1} &= \text{nilai } \textit{output} \text{ pada } \textit{timestep } t - 1 \\
 x_t &= \text{nilai } \textit{input} \text{ pada } \textit{timestep } t \\
 b_z &= \text{nilai bias pada } \textit{update gate}
 \end{aligned}$$

3. Menentukan kandidat *hidden state* pada *time step* saat ini ( $t$ ) dari informasi yang relevan pada *time step* masa lalu ( $t - 1$ ) dengan menggunakan fungsi aktivasi tanh. Persamaan untuk menghitung kandidat *hidden state* dituliskan dalam persamaan (2.16) sebagai berikut:

$$\tilde{h}_t = \tanh(W_h \cdot X_t + r_t \cdot U_h \cdot h_{t-1} + b_h) \quad (2.16)$$

dengan:

$$\begin{aligned}
 \tilde{h}_t &= \text{kandidat } \textit{hidden state} \\
 \tanh &= \text{fungsi aktivasi tanh} \\
 W_h, U_h &= \text{nilai parameter } \textit{weight} \\
 r_t &= \text{nilai } \textit{reset gate} \\
 h_{t-1} &= \text{nilai } \textit{output} \text{ pada } \textit{timestep } t - 1 \\
 x_t &= \text{nilai } \textit{input} \text{ pada } \textit{timestep } t \\
 b_h &= \text{nilai bias pada } \textit{hidden gate}
 \end{aligned}$$

4. *Output* hasil akhir atau informasi final dari unit saat ini dan meneruskannya ke *time step* berikutnya sebagai *hidden state*. Persamaan untuk menghitung *final output* dituliskan dalam persamaan (2.17) sebagai berikut:

$$h_t = (1 - z) \cdot h_{t-1} + z \cdot \tilde{h}_t \quad (2.17)$$

dengan:

$$\begin{aligned}
 h_t &= \textit{output} \\
 z_t &= \textit{output} \text{ pada } \textit{update gate} \\
 h_{t-1} &= \text{nilai } \textit{output} \text{ pada } \textit{timestep } t - 1 \\
 \tilde{h}_t &= \text{kandidat } \textit{hidden state}
 \end{aligned}$$

### 2.3.2.3 Fungsi Aktivasi

Fungsi aktivasi dalam jaringan saraf tiruan berperan penting dalam memungkinkan proses pembelajaran dan membantu model menyelesaikan tugas-tugas yang kompleks. Tanpa fungsi aktivasi, jaringan masih bisa bekerja secara linier, namun kinerjanya menjadi kurang efisien dan akurasinya menurun. Fungsi aktivasi

nonlinier sangat diperlukan untuk memperkenalkan elemen nonlinier ke dalam jaringan, sehingga model mampu menangani variasi data yang lebih rumit. Kehadiran fungsi ini menjadi salah satu kunci utama dalam meningkatkan kemampuan sistem dalam melakukan pengenalan pola. Fungsi aktivasi nonlinier yang digunakan pada model GRU, seperti sigmoid dan tanh, untuk memproses dan menyaring informasi yang masuk maupun keluar dari unit memori (Goodfellow dkk., 2016). Fungsi aktivasi yang digunakan pada model GRU sebagai berikut:

#### 1. Fungsi Sigmoid

Fungsi aktivasi sigmoid memiliki karakteristik kurva berbentuk huruf "S" dan merupakan salah satu fungsi yang umum digunakan dalam jaringan saraf tiruan (JST) (Haykin, 2009). Fungsi ini menghasilkan *output* dalam rentang antara 0 hingga 1, sehingga setiap nilai *output*-nya selalu positif dan berada di dalam kisaran tersebut. Rentang nilai ini sangat berguna dalam tugas klasifikasi biner, karena memungkinkan model untuk secara efektif mengatur informasi mana yang perlu dipertahankan dan mana yang harus diabaikan (Aggarwal, 2018). Bentuk umum fungsi sigmoid dituliskan dalam persamaan (2.18) sebagai berikut:

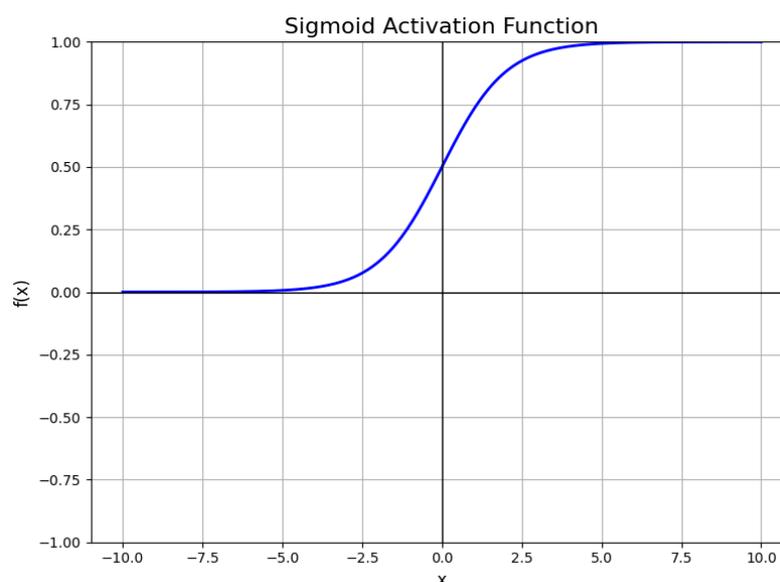
$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.18)$$

dengan:

$e$  = konstanta *euler* (sekitar 2.71828)

$x$  = data

Grafik fungsi aktivasi sigmoid ditampilkan pada Gambar 4 sebagai berikut:



Gambar 4. Fungsi Aktivasi Sigmoid

## 2. Fungsi Tan Hiperbolik

Fungsi aktivasi tanh, atau *hyperbolic tangent*, adalah jenis fungsi aktivasi yang menghasilkan *output* dalam kisaran -1 hingga 1. Artinya, nilai *output*-nya berada di antara nilai negatif dan positif. Cakupan nilai fungsi tanh yang lebih luas dibandingkan fungsi sigmoid berimplikasi memiliki kemampuan yang lebih baik dalam merepresentasikan serta memproses informasi yang mengandung unsur positif maupun negatif secara seimbang (Goodfellow dkk., 2016). Bentuk umum fungsi tanh dituliskan dalam persamaan (2.19) sebagai berikut:

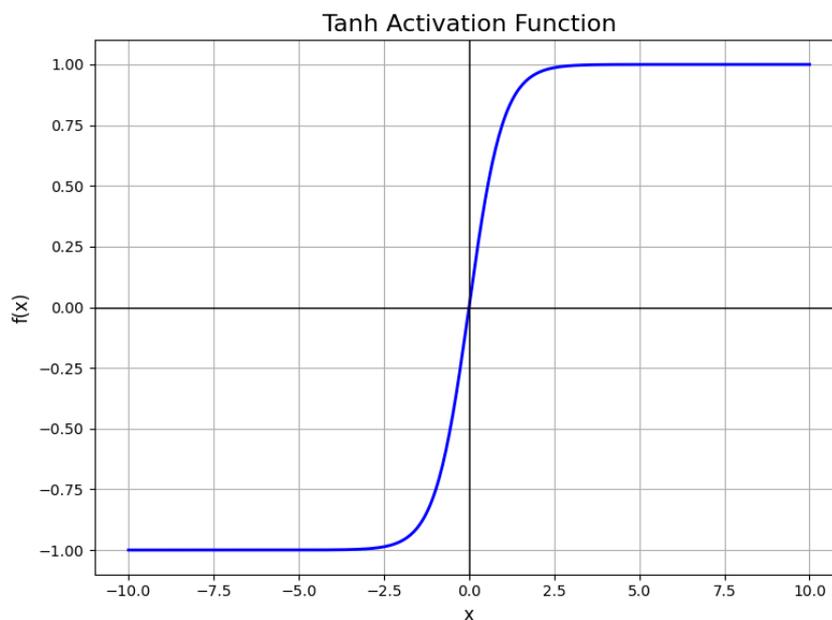
$$\tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (2.19)$$

dengan:

$e$  = konstanta *euler* (sekitar 2.71828)

$x$  = data

Grafik fungsi aktivasi tanh ditampilkan pada Gambar 5 sebagai berikut:



Gambar 5. Fungsi Aktivasi Tan Hiperbolik

### 2.3.2.4 Hyperparameter

*Hyperparameter* merupakan parameter dari algoritma pembelajaran untuk mengontrol perilaku algoritma pembelajaran. Oleh karena itu, *hyperparameter* tidak terpengaruh oleh algoritma pembelajaran serta harus ditentukan sebelum pelatihan. Penggunaan *hyperparameter* yang tepat merupakan hal penting dalam

membangun model yang baik. Penjelasan setiap *hyperparameter* yang digunakan dalam model GRU adalah sebagai berikut (Goodfellow dkk., 2016):

1. *Feature* mengacu pada variabel yang digunakan oleh algoritma. Kinerja model dipengaruhi oleh kualitas dan jumlah *feature* yang digunakan. Penggunaan *feature* dengan kualitas yang buruk akan mengakibatkan model kesulitan untuk mempelajari pola-pola pada data serta akan menghasilkan model yang memiliki akurasi rendah.
2. Unit atau *neuron* merupakan unit dasar pada jaringan saraf tiruan. Banyak unit dapat mempengaruhi kinerja dan akurasi model, karena unit berfungsi untuk menerima dan memproses *input* untuk menghasilkan *output*.
3. *Batch size* adalah jumlah sampel data yang digunakan dalam setiap *epoch* selama proses pelatihan. *Batch size* dapat mempengaruhi kecepatan proses pelatihan, konvergensi, dan keakuratan model. *Batch size* yang terlalu kecil dapat memperlambat proses pelatihan dan menghasilkan bobot yang tidak stabil. Sedangkan *batch size* yang terlalu besar akan mengakibatkan model mengalami *overfitting* serta kebutuhan memori yang besar untuk menyimpan aktivasi dan gradien model. *Overfitting* terjadi karena model menjadi terlalu fokus pada data pelatihan, sehingga data baru yang belum pernah dilihat sebelumnya tidak dapat digeneralisasi dengan baik.
4. *Timestep* merupakan jumlah langkah waktu yang diperlukan untuk merepresentasikan data berurutan. Semakin besar nilai *timestep*, maka semakin banyak pula informasi masa lalu yang dapat digunakan model untuk memprediksi nilai selanjutnya. Akan tetapi, nilai *timestep* yang terlalu besar dapat memperlambat proses pembelajaran.
5. *Learning rate* menentukan besar perubahan bobot model pada setiap iterasi selama proses pelatihan dan dapat mempengaruhi konvergensi model, waktu yang dibutuhkan pada proses pelatihan, serta keakuratan prediksi. Nilai *learning rate* yang terlalu kecil akan memperpanjang waktu model dalam mencapai konvergensi, akibat nilai bobot yang menjadi sangat kecil. Sebaliknya, nilai *learning rate* yang terlalu besar dapat mempersulit model mencapai konvergensi, akibat nilai bobot yang menjadi sangat besar.
6. *Epoch* merupakan satu kali proses *training* pada seluruh data *training*. Setiap *epoch* pada model akan memperbarui bobot berdasarkan gradien dari kesalahan data *training*. *Epoch* yang terlalu kecil dapat mengakibatkan pelatihan model menjadi kurang baik.
7. *Optimizer* merupakan metode optimasi berbasis gradien stokastik untuk memaksimalkan atau meminimalkan bobot berdasarkan data *training*. Penelitian

ini menggunakan *optimizer* Adam (*Adaptive Moment Estimation*) yang menggunakan *adaptive learning rate* dan momentum untuk mempercepat proses pelatihan. Adam dirancang untuk memperoleh keuntungan dari dua *optimizer*, yaitu AdaGrad (dapat bekerja dengan baik pada gradien yang jarang dengan menyesuaikan laju pembelajaran) dan RMSProp (dapat bekerja dengan baik pada pengaturan online dan non-stasioner) (Kingma dan Ba, 2014).

8. *Loss function* merupakan fungsi yang digunakan untuk mengukur kehilangan atau kesalahan model dalam melakukan prediksi selama proses pelatihan. *Loss function* digunakan sebagai tanda untuk memperbaiki model dengan meminimalkan kesalahan dan memaksimalkan akurasi saat proses pembelajaran. *Loss function* yang digunakan dalam penelitian ini adalah MSE.

#### 2.4 Hybrid VARIMAX-GRU

Model *hybrid* adalah teknik analisis data dengan menggabungkan dua atau lebih metode peramalan yang berbeda. Tujuan utama dari model *hybrid* ini adalah untuk memanfaatkan keunggulan kemampuan dari tiap metode sehingga meningkatkan akurasi prediksi dalam aplikasinya di dunia nyata. Menurut Zhang (2003), pengembangan model *hybrid* didasarkan pada beberapa alasan utama sebagai berikut:

1. Sulit untuk memastikan apakah data deret waktu mengikuti pola linear atau nonlinear dalam praktik peramalan. Ketidakpastian ini mendorong peneliti untuk menerapkan lebih dari satu pendekatan pemodelan, lalu membandingkan hasilnya guna memperoleh model dengan tingkat akurasi terbaik. Pendekatan ini membantu meminimalkan risiko kesalahan dalam pemilihan model.
2. Kenyataannya, sebagian besar data deret waktu tidak sepenuhnya bersifat linear maupun sepenuhnya nonlinear, melainkan merupakan gabungan dari keduanya. Oleh karena itu, penerapan satu metode saja dianggap tidak mampu menangkap dinamika kompleks yang terkandung dalam data, sehingga pendekatan tunggal menjadi kurang optimal.
3. Tidak ada satu metode peramalan pun yang secara universal dapat diterapkan untuk semua jenis data atau situasi. Kompleksitas data pada permasalahan dunia nyata seringkali menuntut pendekatan yang lebih fleksibel, sehingga penggunaan kombinasi beberapa metode menjadi strategi yang lebih efektif dan adaptif dalam menghasilkan peramalan yang akurat.

Studi empiris telah membuktikan bahwa model *hybrid* dapat memberikan hasil yang lebih unggul dibandingkan model individu. Secara umum, pendekatan *hybrid* dalam analisis deret waktu terdiri dari dua komponen utama, yaitu komponen linier dan nonlinier, sebagaimana dalam persamaan (2.20) yang dikemukakan oleh Zhang (2003) sebagai berikut:

$$Y_t = L_t + N_t \quad (2.20)$$

dengan:

- $Y_t$  = data aktual pada periode  $t$
- $L_t$  = komponen linear pada periode  $t$
- $N_t$  = komponen nonlinear pada periode  $t$
- $t$  = indeks waktu

Menurut persamaan (2.20), kedua komponen tersebut harus diestimasi dari data untuk mendapatkan hasil peramalan. Tahapan pertama, model VARIMAX digunakan untuk mengekstraksi komponen linier deret waktu. Selanjutnya, residual dari model VARIMAX digunakan sebagai komponen nonlinier atau *input* dari model GRU. Perbandingan nilai aktual  $Y_t$  dari deret waktu dan nilai prediksi komponen linier  $L'_t$  memperoleh serangkaian residu, yang didefinisikan dalam persamaan (2.21) sebagai berikut:

$$E_t = Y_t - L'_t \quad (2.21)$$

dengan:

- $E_t$  = nilai residual dari model VARIMAX pada periode  $t$
- $Y'_t$  = data aktual pada periode  $t$
- $L'_t$  = nilai peramalan dari model VARIMAX pada periode  $t$
- $t$  = indeks waktu

Selanjutnya, setelah data residual dari model VARIMAX digunakan sebagai *input* ke model GRU untuk memodelkan komponen nonlinier, diperlukan integrasi dari komponen linier dan nonlinier deret waktu untuk menghasilkan peramalan model *hybrid*. Persamaan *hybrid* VARIMAX–GRU dapat dituliskan dalam persamaan (2.22) sebagai berikut (Zhang, 2003):

$$Y'_t = L'_t + N'_t \quad (2.22)$$

dengan:

- $Y_t$  = nilai peramalan dari model *hybrid* pada periode  $t$
- $L'_t$  = nilai peramalan dari komponen linear pada periode  $t$
- $N'_t$  = nilai peramalan dari komponen nonlinear pada periode  $t$
- $t$  = indeks waktu

## 2.5 Evaluasi Model

Evaluasi model adalah proses untuk mengukur seberapa baik kinerja model setelah dilatih dengan data. Proses ini dilakukan dengan menguji model menggunakan data testing yang belum pernah dilihat sebelumnya, untuk memastikan bahwa model dapat memprediksi dengan akurat. Evaluasi model ini dapat mengetahui seberapa baik model bekerja dan apakah perlu dilakukan perbaikan atau penyesuaian parameter agar kinerjanya lebih optimal. Menurut Azhari dan Haryanto (2024), untuk mengevaluasi kinerja model dilakukan dengan menggunakan metode *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE). Kedua metrik ini sangat berguna dalam konteks model prediksi karena mereka memberikan informasi tentang kualitas dan keandalan prediksi yang dibuat oleh model.

### 2.5.1 Mean Absolute Percentage Error (MAPE)

Nilai MAPE mengukur kesalahan rata-rata dalam persentase, yang memungkinkan kita untuk memahami kesalahan relatif terhadap skala nilai yang sebenarnya. Nilai MAPE yang lebih rendah menunjukkan prediksi yang lebih akurat dalam hal persentase (Azhari dan Haryanto, 2024). Persamaan umum yang digunakan untuk menghitung MAPE dituliskan dalam persamaan (2.23) sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{\hat{Y}_t - Y_t}{Y_t} \right| \times 100\% \quad (2.23)$$

dengan:

$n$  = jumlah periode yang diprediksi

$t$  = indeks waktu

$Y_t$  = nilai aktual pada periode  $t$

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

Berdasarkan nilai MAPE yang diperoleh, semakin kecil nilai MAPE menunjukkan semakin akurat hasil peramalan. Kriteria nilai MAPE disajikan pada Tabel 2 sebagai berikut (Chang dkk., 2007):

Tabel 2. Kriteria Nilai MAPE

Nilai MAPE	Keterangan Akurasi Peramalan
$MAPE \leq 10\%$	Sangat Baik
$10\% < MAPE \leq 20\%$	Baik
$20\% < MAPE \leq 50\%$	Cukup
$MAPE > 50\%$	Buruk

Tabel 2 menunjukkan kriteria penilaian terhadap tingkat akurasi hasil peramalan berdasarkan nilai MAPE. Jika nilai MAPE berada pada kisaran  $\leq 10\%$ , maka peramalan dikategorikan sangat baik. Sedangkan, nilai MAPE antara 10% hingga 20% dianggap baik. Sementara itu, nilai MAPE antara 20% hingga 50% menunjukkan akurasi peramalan yang cukup. Jika nilai MAPE melebihi 50%, maka hasil peramalan tergolong buruk. Dengan demikian, tabel ini berfungsi sebagai acuan untuk mengevaluasi seberapa baik model prediktif merepresentasikan data aktual berdasarkan tingkat kesalahan persentasenya.

### 2.5.2 Root Mean Square Error (RMSE)

Nilai RMSE memberikan ukuran seberapa dekat prediksi yang dibuat oleh model terhadap nilai-nilai yang sebenarnya. Nilai RMSE yang lebih rendah menunjukkan kesalahan prediksi yang lebih kecil dan oleh karena itu model yang lebih akurat (Azhari dan Haryanto, 2024). Persamaan umum yang digunakan untuk menghitung RMSE dituliskan dalam persamaan (2.24) sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t - Y_t)^2} \quad (2.24)$$

dengan:

$n$  = jumlah periode yang diprediksi

$t$  = indeks waktu

$Y_t$  = nilai aktual pada periode  $t$

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

### 2.6 Goodness of Fit

*Goodness of fit* mengukur sejauh mana model sesuai dengan data. Uji Kolmogorov-Smirnov (KS) digunakan untuk membandingkan perbedaan antara

data yang diamati dan distribusi yang diharapkan dengan menunjukkan jarak maksimum antara dua distribusi, yaitu data peramalan dan data aktual ter-*update*. Semakin kecil jarak tersebut, semakin baik model menangkap pola data. Statistik uji KS menunjukkan tingkat kesesuaian model dengan data dengan persamaan sebagai berikut (Kolmogorov, 1933):

$$KS = \max |F_n(x) - F(x)| \quad (2.25)$$

dengan:

$KS$  = statistik uji Kolmogorov-Smirnov

$F_n(x)$  = fungsi distribusi kumulatif empiris

$F(x)$  = fungsi distribusi kumulatif teoritis

$\max$  = nilai maksimum dari perbedaan antara distribusi

## **BAB III**

### **METODE PENELITIAN**

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

Penelitian ini dilaksanakan pada semester ganjil tahun akademik 2024/2025 bertempat di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung. Penelitian meliputi tiga tahapan dengan periode waktu di setiap tahapannya sebagai berikut:

1. Tahap pertama meliputi studi literatur dan penentuan tema penelitian, pengumpulan data, penyusunan bab 1-3, dan seminar proposal dengan periode waktu mulai dari Agustus 2024 sampai dengan Februari 2025.
2. Tahap kedua meliputi melakukan pengolahan data untuk mendapatkan hasil dari model *hybrid* VARIMAX-GRU dengan periode waktu mulai dari November 2024 sampai dengan April 2025.
3. Tahap ketiga meliputi penyusunan bab 4-5, seminar hasil penelitian, dan sidang komprehensif dengan periode waktu mulai dari Februari 2025 sampai dengan Juni 2025.

#### **3.2 Alat Penelitian**

Perangkat yang digunakan dalam penelitian ini adalah sebagai berikut:

1. Perangkat keras (*hardware*) meliputi laptop dengan merk ASUS dengan tipe 64-bit *operating system*, dan x64-based *processor*. Spesifikasi *hardware* adalah sebagai berikut:
  - a. *Processor* AMD A4-9125 RADEON R3, 4 COMPUTE CORES 2C+2G 2.30 GHz
  - b. *Installed* RAM 8,00 GB
2. Perangkat lunak (*software*) meliputi *open source* dengan bahasa pemrograman *Python* (3.11.11) dengan menggunakan *library* sebagai berikut:

- a. *pandas* (2.2.2) digunakan untuk membaca dataset dan mengonversi data ke format *datetime* untuk analisis deret waktu
- b. *numpy* (1.26.4) digunakan untuk operasi matematis pada model VARIMAX dan transformasi data sebelum masuk ke model GRU
- c. *matplotlib* (3.10.0) dan *seaborn* (0.13.2) untuk visualisasi data guna memahami pola dan karakteristik *dataset*
- d. *scikit-learn* (1.2.2) digunakan untuk *scaling* data, *splitting* data, dan evaluasi pada model yang telah dibuat dengan RMSE dan MAPE
- e. *statsmodels* (0.14.4) digunakan untuk uji stasioneritas data dan estimasi parameter model VARIMAX, *library* ini menyediakan fungsi yang dapat menangkap hubungan linier yang ada pada data
- f. *tensorflow* (2.18.0) digunakan untuk membangun model GRU yang bertanggung jawab menangkap pola nonlinier data

### 3.3 Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh secara *online* melalui *website* <https://finance.yahoo.com/quote/INDF.JK/history/> untuk data historis harian harga penutupan saham PT Indofood Sukses Makmur Tbk (INDF.JK), <https://finance.yahoo.com/quote/ICBP.JK/history/> untuk data historis harian harga penutupan saham PT Indofood Consumer Brand Product Sukses Makmur Tbk (ICBP.JK), dan <https://www.bi.go.id/id/statistik/informasi-kurs/jisdor/Default.aspx> untuk data historis harian nilai tukar rupiah terhadap dolar Amerika Serikat. Rentang periode data yang digunakan adalah 04 Januari 2021 sampai dengan 13 Februari 2025 dengan masing-masing jumlah data sebanyak 997 data.

$Y_1$  = data historis harga penutupan saham PT ICBP Tbk (ICBP.JK)

$Y_2$  = data historis harga penutupan saham PT INDF Tbk (INDF.JK)

$X$  = data historis nilai tukar rupiah terhadap dolar Amerika Serikat (KURS)

Data yang digunakan dalam penelitian ini disajikan pada Tabel 3 sebagai berikut:

Tabel 3. Data Penelitian

Periode	ICBP,JK (Rp/Lembar)	INDF,JK (Rp/Lembar)	KURS (\$/Rp)
2021-01-04	8785,577148	5791,897461	13903,00
2021-01-05	8670,828812	5813,113281	13945,00
2021-01-06	8647,944336	5728,250488	13926,00
2021-01-07	8716,761719	5749,466309	13938,00
2021-01-08	8739,700195	5770,682129	14058,00
⋮	⋮	⋮	⋮
2025-02-13	11225,000000	7800,000000	16350,00

Tabel 3 merepresentasikan data penelitian yang mencakup dua variabel endogen dan satu variabel eksogen. Variabel endogen meliputi harga penutupan saham ICBP,JK dan INDF,JK, sedangkan variabel eksogen meliputi kurs rupiah terhadap dolar Amerika Serikat.

### 3.4 Metode Penelitian

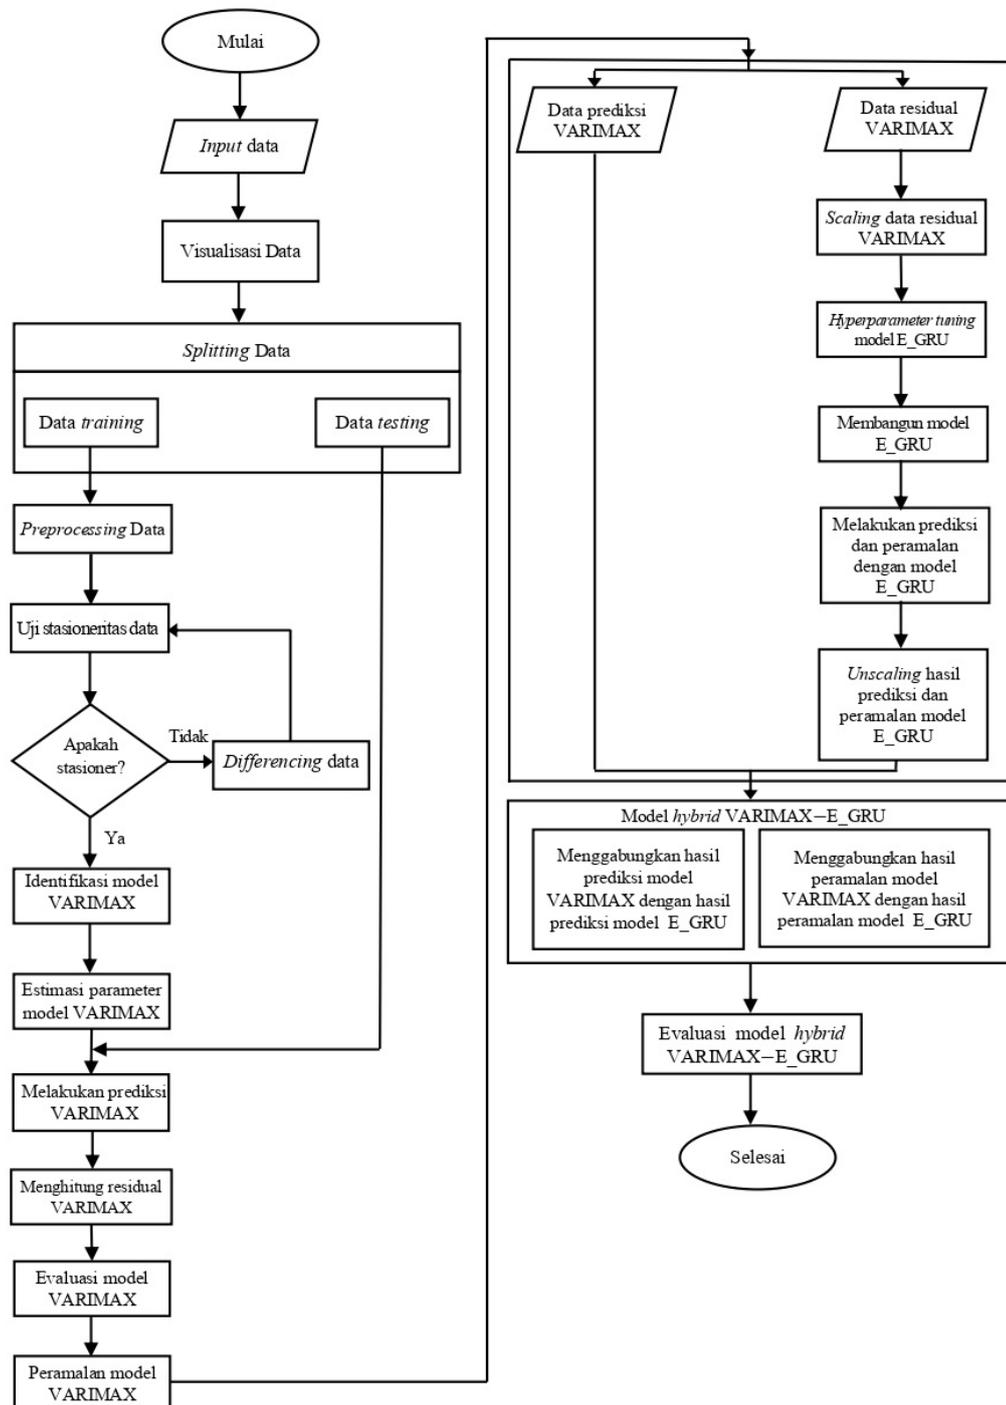
Langkah-langkah dalam melakukan peramalan dengan menggunakan metode *hybrid VARIMAX-GRU* adalah sebagai berikut:

1. Melakukan studi literatur yang mencakup model *hybrid VARIMAX-GRU* yang bersumber dari artikel, jurnal, buku, dan dibantu oleh narasumber yang memahami tentang model *hybrid VARIMAX-GRU*.
2. Melakukan pengumpulan data historis untuk proses peramalan dengan model *hybrid VARIMAX-GRU* yang terdiri dari harga penutupan saham ICBP,JK dan INDF,JK sebagai variabel endogen dan kurs rupiah terhadap dolar Amerika Serikat sebagai variabel eksogen.
3. Melakukan *input* data penelitian ke bahasa pemrograman *Python* dengan menggunakan aplikasi *Google Colaboratory*.
4. Melakukan visualisasi data penelitian yang bertujuan untuk mengidentifikasi variabel dan melihat pola data yang digunakan.
5. Melakukan *splitting* data penelitian menjadi data *training* dan data *testing* dengan persentase 80% untuk data *training* dan 20% untuk data *testing*.
6. Melakukan *preprocessing* data untuk memastikan data *training* siap digunakan dalam model, misalnya menangani data yang hilang dan melihat korelasi antar variabel.

7. Melakukan uji stasioneritas dengan menggunakan uji akar unit, yaitu *Augmented Dickey-Fuller* (ADF). Jika data *training* tidak stasioner, maka perlu dilakukan proses *differencing*.
8. Setelah data stasioner, langkah selanjutnya adalah menentukan nilai orde  $p$ ,  $d$ ,  $q$  untuk model VARIMAX. Penentuan ini dilakukan berdasarkan analisis plot ACF, PACF, dan jumlah *differencing* yang diterapkan hingga data mencapai stasioneritas.
9. Mengestimasi parameter model VARIMAX dengan menganalisis plot ACF dan PACF, tujuannya adalah untuk menentukan model terbaik yang akan digunakan untuk prediksi dan peramalan. Model terbaik akan dipilih berdasarkan nilai *Bayesian Information Criterion* (BIC) yang terkecil, karena BIC memberikan penalti lebih besar untuk model yang lebih rumit dibandingkan kriteria lain seperti *Akaike Information Criterion* (AIC), sehingga mendorong agar model tetap sederhana dan mengurangi risiko *overfitting*. AIC lebih memperhatikan seberapa baik model cocok dengan data, tanpa memikirkan seberapa rumit model tersebut yang mengakibatkan model terlalu mengikuti data *training*, yang disebut *overfitting*.
10. Melakukan prediksi model VARIMAX dengan menggunakan data *training* dan model VARIMAX terbaik yang telah dipilih pada tahap sebelumnya.
11. Menghitung nilai residual model VARIMAX dengan terlebih dahulu meng-*undifferencing* data hasil prediksi model VARIMAX karena nilai residual diperoleh dengan cara mengurangi data aktual dari data PT ICBP Tbk dan PT INDF Tbk dengan data hasil prediksi model VARIMAX yang telah di-*undifferencing*.
12. Mengevaluasi model VARIMAX menggunakan data *testing* dengan melihat nilai RMSE dan MAPE.
13. Melakukan peramalan dengan model VARIMAX selama 30 periode ke depan.
14. Melakukan *input* data hasil prediksi dan residual dari model VARIMAX sebagai langkah awal untuk model *hybrid*.
15. Melakukan *scaling* terhadap data hasil prediksi dan residual dari model VARIMAX dengan menggunakan *MinMaxScaler*.
16. Membangun dua model utama GRU untuk melakukan proses *hybrid* dimana model P\_GRU dibangun dengan *input* data hasil prediksi model VARIMAX dan model E\_GRU dibangun dengan *input* data residual model VARIMAX.
17. *Hyperparameter tuning* untuk penentuan parameter terbaik kedua model GRU dilakukan dengan menggunakan *GridSearch*.

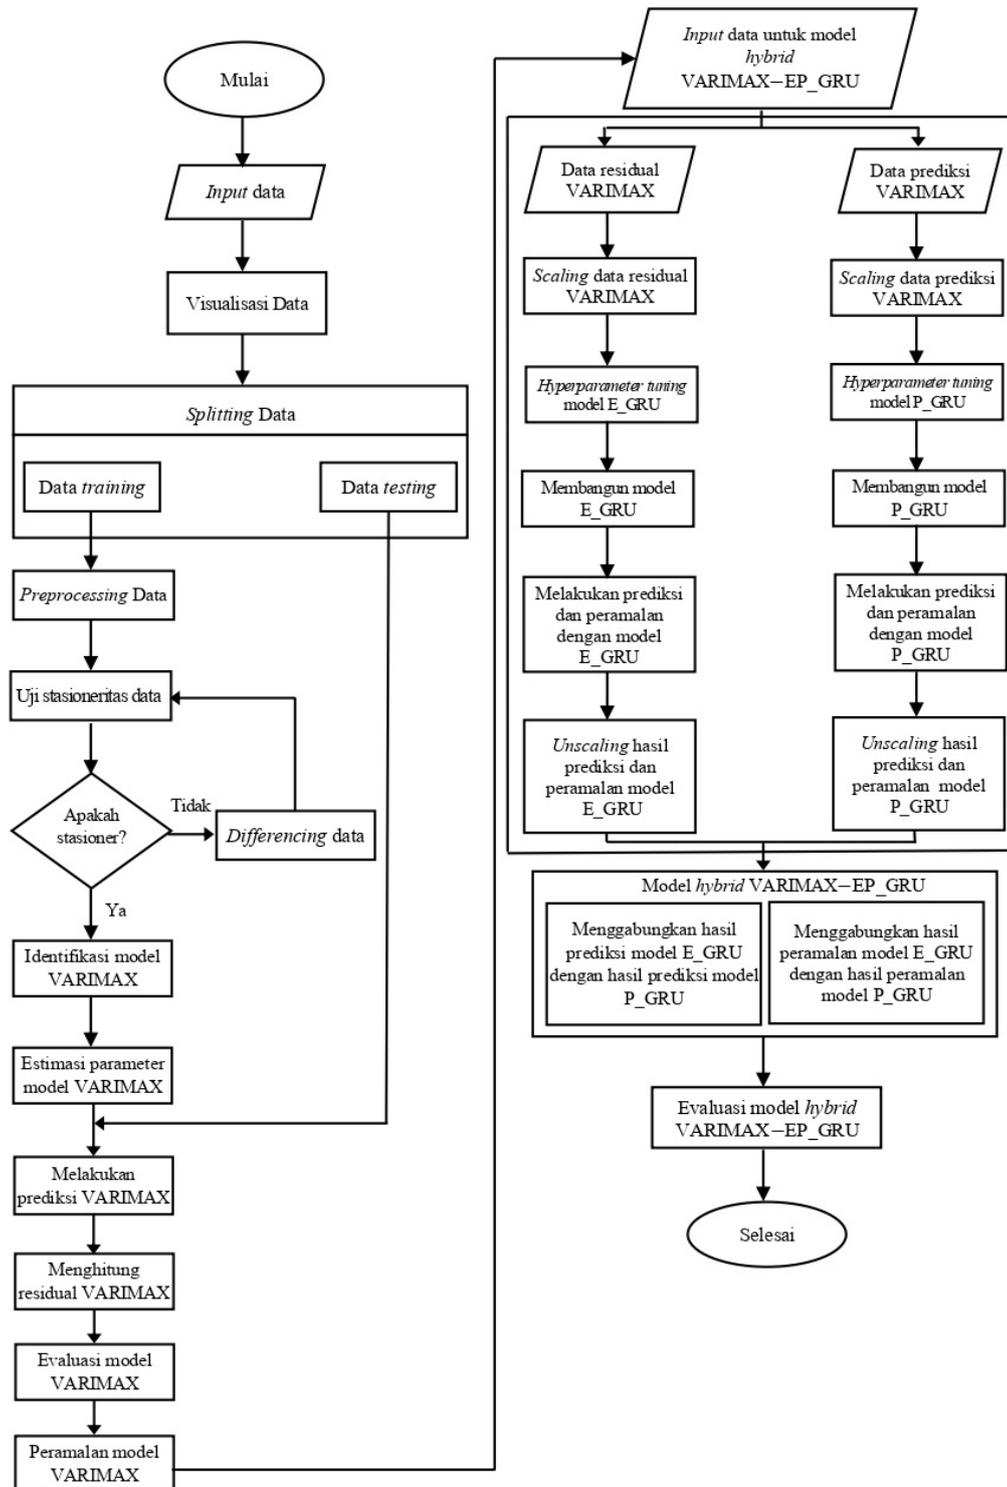
18. Melakukan prediksi dan peramalan model GRU dimana prediksi dan peramalan model P\_GRU menggunakan hasil prediksi model VARIMAX sebagai data *input*, serta prediksi dan peramalan model E\_GRU menggunakan residual model VARIMAX sebagai data *input*.
19. Melakukan denormalisasi data pada hasil prediksi dan peramalan dari model P\_GRU dan model E\_GRU agar kembali pada *range* sebenarnya seperti pada data aktual.
20. Model *hybrid* VARIMAX-GRU  
Model *hybrid* VARIMAX-GRU yang dibangun meliputi dua model sebagai berikut:
  - a. Model *hybrid* VARIMAX-E\_GRU adalah penggabungan hasil prediksi dan peramalan model VARIMAX dan model E\_GRU dengan operasi penjumlahan.
  - b. Model *hybrid* VARIMAX-EP\_GRU adalah penggabungan hasil prediksi dan peramalan model P\_GRU dan model E\_GRU dengan operasi penjumlahan.
21. Melakukan evaluasi model dengan melihat nilai RMSE dan MAPE pada kedua model *hybrid*.

Flowchart peramalan dengan model *hybrid* VARIMAX-E\_GRU sebagai berikut:



Gambar 6. Flowchart Model Hybrid VARIMAX-E\_GRU

Flowchart peramalan dengan model *hybrid* VARIMAX-EP\_GRU sebagai berikut:



Gambar 7. Flowchart Model Hybrid VARIMAX-EP\_GRU

## BAB V

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

Berdasarkan hasil dan pembahasan mengenai peramalan harga penutupan saham PT ICBP Tbk dan PT INDF Tbk dengan menggunakan model *hybrid* VARIMAX-GRU dapat diperoleh kesimpulan sebagai berikut:

1. Model *hybrid* VARIMAX-GRU dibangun dengan dua pendekatan. Model *hybrid* VARIMAX-E-GRU dibangun dengan menjumlahkan hasil prediksi model VARIMAX dan model E-GRU (nilai residual model VARIMAX sebagai data *input*). Model *hybrid* VARIMAX-EP-GRU dibangun dengan menjumlahkan model E-GRU (nilai residual model VARIMAX sebagai data *input*) dan model P-GRU (hasil prediksi model VARIMAX sebagai data *input*). Model GRU dalam dua pendekatan ini dibangun menggunakan kombinasi parameter terbaik yang diperoleh melalui proses *hyperparameter tuning* dengan rincian sebagai berikut:
  - a. Model P-GRU dengan data *input* hasil prediksi model VARIMAX, kombinasi parameter terbaik yang diperoleh dari jumlah *GRU Unit*, *Dense Unit*, dan *Batch Size* menggunakan model dengan pembagian 80% data *training* dan 20% data *testing*, yaitu 128 *GRU Unit*, 128 *Dense Unit*, dan 8 *Batch Size*.
  - b. Model E-GRU dengan data *input* residual hasil prediksi model VARIMAX, kombinasi parameter terbaik yang diperoleh dari jumlah *GRU Unit*, *Dense Unit*, *Batch Size*, dan *Dropout* menggunakan model dengan pembagian 80% data *training* dan 20% data *testing*, yaitu 64 *GRU Unit*, 64 *Dense Unit*, 16 *Batch Size*, dan 0,2 *Dropout*.
2. Peramalan harga penutupan saham PT ICBP Tbk dan PT INDF Tbk dengan mempertimbangkan nilai tukar rupiah terhadap dolar Amerika Serikat untuk

30 periode ke depan (14 Februari 2025-27 Maret 2025) telah dilakukan menggunakan model VARIMAX, model *hybrid* VARIMAX-E\_GRU, dan model *hybrid* VARIMAX-EP\_GRU. Hasil peramalan dari model *hybrid* VARIMAX-EP\_GRU menunjukkan perbedaan yang signifikan dibandingkan dengan model VARIMAX dan model *hybrid* VARIMAX-E\_GRU. Meskipun model VARIMAX merupakan model terbaik dalam melakukan prediksi, namun peramalannya cenderung kurang responsif dengan hanya menunjukkan pola linier tanpa adanya fluktuasi. Demikian pula dengan hasil peramalan model *hybrid* VARIMAX-E\_GRU yang mirip dengan hasil peramalan model VARIMAX individu. Sebaliknya, model *hybrid* VARIMAX-EP\_GRU mampu mengikuti pola dan tren pergerakan kedua harga saham dengan tetap mempertahankan hasil evaluasi yang optimal.

3. Kinerja model VARIMAX, model *hybrid* VARIMAX-E\_GRU, dan model *hybrid* VARIMAX-EP\_GRU dalam meramalkan harga penutupan saham PT ICBP Tbk dan PT INDF Tbk dengan mempertimbangkan nilai tukar rupiah terhadap dolar Amerika Serikat untuk 30 periode ke depan (14 Februari 2025-27 Maret 2025) diuji dengan uji Kolmogorov-Smirnov. Model *hybrid* VARIMAX-EP\_GRU menghasilkan nilai statistik terkecil dibandingkan dengan kedua model lainnya yang berimplikasi bahwa kinerja model *hybrid* VARIMAX-EP\_GRU dapat dikatakan paling baik dalam melakukan peramalan.

## DAFTAR PUSTAKA

- Aggarwal, C. C. 2018. *Neural Networks and Deep Learning: A Textbook*. New York: Springer.
- Aji, A. B., dan 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).
- Alpaydin, E. 2004. *Introduction to Machine Learning*. MIT press.
- Ambarwari, A., Adrian, Q.J., & Herdiyeni, Y. 2020. Analysis of the Effect of Data Scaling on the Performance of the Machine Learning Algorithm for Plant Identification. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*. **4**(1): 117–122.
- Ananda, M. I. 2023. Model Analysis of Gated Recurrent Unit for Multivariate Rice Price Forecasting. *Jurnal ELTIKOM: Jurnal Teknik Elektro, Teknologi Informasi dan Komputer*. **7**(2): 125-132.
- Atharsyah, M., dan Romli, M. A. 2024. Implementasi Model LSTM, GRU, BILSTM, dan BiGRU dalam Prediksi Harga Nikel. *Jurnal Informatika dan Rekayasa Elektronik*. **7**(2): 413-420.
- Azhari, I. C., dan Haryanto, T. 2024. Modeling of Hyperparameter Tuned RNN-LSTM and Deep Learning for Garlic Price Forecasting in Indonesia. *Journal of Informatics and Telecommunication Engineering*. **7**(2): 502-513.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., dan Ljung, G. M. 2015. *Time Series Analysis Forecasting and Control*. Fifth Edition. John Wiley & Sons, New Jersey.
- Chang, P. C., Wang, Y. W., dan Liu, C. H. 2007. The Development of a Weighted Evolving Fuzzy Neural Network for PCB Sales Forecasting. *Expert Systems with Applications*. **32**(1): 86-96.
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., dan Bengio, Y. 2014. Learning Phrase Representations using RNN encoder-decoder for Statistical Machine Translation. *arXiv preprint arXiv:1406.1078*.
- Choudhury, N. A., dan Soni, B. 2023. An Adaptive Batch Size based-CNN-LSTM Framework for Human Activity Recognition in Uncontrolled Environment. *IEEE Transactions on Industrial Informatics*. **42**(13): 197.

- Chung, J., Gulcehre, C., Cho, K., dan Bengio, Y. 2014. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *arXiv preprint arXiv:1412.3555*.
- Dickey, D. A., dan 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.
- Goodfellow, I., Bengio, Y., dan Courville, A. 2016. *Deep learning*. Cambridge(Massachusetts): MIT press.
- Granger, C. W. 1969. Investigating Causal Relations by Econometric Models and Cross-spectral Methods. *Econometrica: Journal of the Econometric Society*. 424-438.
- Gujarati, N. D. 2012. *Dasar-Dasar Ekonometrika*. Jakarta: Salemba.
- Hanke, J. E. dan Wichern, D. W. 2009. *Business Forecasting*. Ninth Edition. Pearson Prentice Hall, New Jersey.
- Harvey, A. 2006. Forecasting with Unobserved Components Time Series Models. *Handbook of Economic Forecasting*. **1**: 327-412
- Haykin, S. 2009. *Neural Networks and Learning Machines*. Third Edition. Pearson Prentice Hall, New Jersey.
- Kingma, D. P., dan Ba, J. 2014. Adam: A Method for Stochastic Optimization. *arXiv preprint arXiv:1412.6980*.
- Kolmogorov, A. 1933. Sulla Determinazione Empirica di Una Legge di Distribuzione. *Giorn Dell'inst Ital Degli Att*. **4**: 89-91.
- Ljung, G. M., dan Box, G. E. 1978. On a Measure of Lack of Fit in Time Series Models. *Biometrika*. **65**(2): 297-303.
- Makridakis, S., Wheelwright, S. C., dan McGee, V. E. 1999. *Metode dan Aplikasi Peramalan*. Edisi ke-2. Jakarta: Binarupa Aksara.
- Montgomery, D. C., Jennings, C. L., dan Kulahci, M. 2015. *Introduction to Time Series Analysis and Forecasting*. Second Edition. John Wiley & Sons.
- Nurfadilah, K., dan Kasse, I. 2018. Peramalan Tingkat Suku Bunga Pasar Uang Antar Bank (PUAB) dengan Vector Autoregressive Exogenous (VARX). *Jurnal MSA (Matematika dan Statistika serta Aplikasinya)*. **6**(1): 51-60.
- Nurfitriani dan Dewi, C. K. 2024. Analisis Pengaruh Faktor Makroekonomi terhadap Harga Saham di Bursa Efek Indonesia. *Prosiding FRIMA (Festival Riset Ilmiah Manajemen dan Akuntansi)*. **1**(7): 1550-1558.

- Pratama, R. I. H., dan Saputro, D. R. S. 2018. Model Runtun Waktu Vector Autoregressive Moving Average With Exogenous Variable (VARMAX). *Prosiding Konferensi Nasional Penelitian Matematika dan Pembelajarannya*. 490-497.
- Pratiwi, S. 2023. Pengaruh Harga Pangan terhadap Inflasi dengan Metode Vector Autoregressive Integrated Moving Average. *Jurnal Riset Statistika*. **3**(2): 87-96.
- Rowan, R., Muflikhah, L., dan 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.
- Salehinejad, H., Sankar, S., Barfett, J., Colak, E., dan Valaee, S. 2018. *Recent Advance in Recurrent Neural Network*. *Computer Research Repository*. 1-21.
- Saputra, N. W., Insani, F., Agustian, S., dan Sanjaya, S. 2023. Penerapan Deep Learning Menggunakan Gated Recurrent Unit Untuk Memprediksi Harga Minyak Mentah Dunia. *Building of Informatics, Technology and Science (BITS)*. **5**(1): 86-94.
- Singh, D., dan Singh, B. 2020. Investigating the Impact of Data Normalization on Classification Performance. *Applied Soft Computing*. **97**: 105524
- Sutthichaimethee, P. 2017. VARIMAX Model to Forecast the Emission of Carbon Dioxide from Energy Consumption in Rubber and Petroleum Industries Sectors in Thailand. *Journal of Ecological Engineering*. **18**(3): 112-117.
- Tarkus, E. D., Sompie, S. R., dan Jacobus, A. 2020. Implementasi Metode Recurrent Neural Network pada Pengklasifikasian Kualitas Telur Puyuh. *Jurnal Teknik Informatika*. **15**(2): 137-144.
- Tasyurek, M. 2022. A Novel Approach to Improve the Performance of the Database Storing Big Data with Time Information. *Balkan Journal of Electrical and Computer Engineering*. **10**(4): 388–396.
- 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): 3493-3500.
- Wei, W. W. S. 2006. *Time Series Analysis: Univariate and Multivariate Methods*. Second Edition. Pearson Education, Inc. Boston.
- Wei, W.W.S. 2019. *Multivariate Time Series Analysis and Applications*. Hoboken, New Jersey: John Wiley and Sons, Inc.
- Wijanarko, A., Al Haura, A. N., Puspitaningrum, I., dan Saputra, D. I. S. 2024. Model Recurrent Neural Network-Gated Recurrent Unit untuk Membangun Mesin Penerjemah Bahasa Indonesia-Banyumasan. *Jurnal Eksplora Informatika*. **13**(2): 218-226.

- Yin, C., Zhu, Y., Fei, J., dan He, X. 2017. A Deep Learning Approach for Intrusion Detection using Recurrent Neural Networks. *IEEE Access*. **5**(29): 54-61.
- Yu, Y., Si, X., Hu, C., dan Zhang, J. 2019. A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. *Neural Computation*. **31**(7): 1235-70.
- Zhang, G. P. 2003. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*. **50**: 159-75.