

IMPLEMENTASI MODEL *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (VARIMA)-BIDIRECTIONAL LONG SHORT-TERM MEMORY (BILSTM)* PADA PERAMALAN HARGA SAHAM PT. BANK NEGARA INDONESIA, TBK DAN PT. BANK RAKYAT INDONESIA, TBK

Skripsi

Oleh

**MEY ARI WARDHANI
NPM. 2117031032**



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

2025

ABSTRACT

IMPLEMENTATION OF THE *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (VARIMA)-BIDIRECTIONAL LONG SHORT-TERM MEMORY (BiLSTM)* MODEL FOR FORECASTING THE STOCK PRICES OF PT BANK NEGARA INDONESIA, TBK AND PT BANK RAKYAT INDONESIA, TBK

By

Mey Ari Wardhani

Stock price forecasting plays an important role in supporting investment decisions in the capital market, especially in large bank stocks such as PT. Bank Negara Indonesia and PT. Bank Rakyat Indonesia which often experience fluctuations. Therefore, a precise analysis is needed using the *hybrid Vector Autoregressive Integrated Moving Average (VARIMA)–Bidirectional Long Short-Term Memory (BiLSTM)* model to forecast the stock prices of the two banks. The combination of the two produces a *hybrid* model that is able to capture linear and *non*-linear patterns simultaneously. There are three approaches used, namely VARIMA, *hybrid* VARIMA–E_BiLSTM, and *hybrid* VARIMA–EP_BiLSTM. The analysis in this study uses daily stock price data from January 2017 to November 2024 as many as 1962 data with a scheme division of 80% for training and 20% for testing. The results of the analysis show that the *hybrid* VARIMA–EP_BiLSTM model is better able to follow the actual data pattern than other models. Based on the Kolmogorov–Smirnov (KS) test, this model shows a good agreement between the forecasting results and the actual data. Thus, the *hybrid* VARIMA–EP_BiLSTM model has the most optimal performance in forecasting the stock prices of PT. Bank Negara Indonesia Tbk and PT. Bank Rakyat Indonesia Tbk.

Keywords: Fluctuation, Prediction, Forecasting, VARIMA, BiLSTM, *Hybrid* Model, Stock Price.

ABSTRAK

IMPLEMENTASI MODEL *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (VARIMA)-BIDIRECTIONAL LONG SHORT-TERM MEMORY (BiLSTM)* PADA PERAMALAN HARGA SAHAM PT. BANK NEGARA INDONESIA, TBK DAN PT. BANK RAKYAT INDONESIA, TBK

Oleh

Mey Ari Wardhani

Peramalan harga saham berperan penting dalam mendukung keputusan investasi di pasar modal terutama pada saham bank besar seperti PT. Bank Negara Indonesia dan PT. Bank Rakyat Indonesia yang sering mengalami fluktuasi. Oleh karena itu, dibutuhkan analisis yang tepat dengan menggunakan model *hybrid Vector Autoregressive Integrated Moving Average (VARIMA)-Bidirectional Long Short-Term Memory (BiLSTM)* untuk meramalkan harga saham kedua bank tersebut. Kombinasi keduanya menghasilkan model *hybrid* yang mampu menangkap pola linier dan *non*-linier secara bersamaan. Terdapat tiga pendekatan yang digunakan yaitu VARIMA, *hybrid* VARIMA-E_BiLSTM, dan *hybrid* VARIMA-EP_BiLSTM. Analisis pada penelitian ini menggunakan data harga saham harian dari Januari 2017 hingga November 2024 sebanyak 1962 data dengan pembagian skema sebesar 80% untuk pelatihan dan 20% untuk pengujian. Hasil analisis menunjukkan bahwa model *hybrid* VARIMA-EP_BiLSTM lebih mampu mengikuti pola data aktual dibandingkan model lainnya. Berdasarkan uji *Kolmogorov-Smirnov* (KS), model ini menunjukkan kesesuaian antara hasil peramalan dan data aktual. Dengan demikian, model *hybrid* VARIMA-EP_BiLSTM memiliki kinerja paling optimal dalam meramalkan harga saham PT. Bank Negara Indonesia Tbk dan PT. Bank Rakyat Indonesia Tbk.

Kata-kata kunci: Fluktuasi, Prediksi, Peramalan, VARIMA, BiLSTM, *Hybrid* model, harga saham.

IMPLEMENTASI MODEL *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (VARIMA)-BIDIRECTIONAL LONG SHORT-TERM MEMORY (BILSTM)* PADA PERAMALAN HARGA SAHAM PT. BANK NEGARA INDONESIA, TBK DAN PT. BANK RAKYAT INDONESIA, TBK

MEY ARI WARDHANI

Skripsi

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

Pada

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



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

2025

Judul Skripsi : **IMPLEMENTASI MODEL *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (VARIMA)-BIDIRECTIONAL LONG SHORT-TERM MEMORY (BILSTM)* PADA PERAMALAN HARGA SAHAM PT. BANK NEGARA INDONESIA, TBK DAN PT. BANK RAKYAT INDONESIA, TBK.**

Nama Mahasiswa : **Mey Ari Wardhani**

Nomor Pokok Mahasiswa : **2117031032**

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: 03 Juni 2025

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : **Mey Ari Wardhani**
Nomor Pokok Mahasiswa : **2117031032**
Jurusan : **Matematika**
Judul Skripsi : **IMPLEMENTASI MODEL *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (VARIMA)*-*BIDIRECTIONAL LONG SHORT-TERM MEMORY (BILSTM)* PADA PERAMALAN HARGA SAHAM PT. BANK NEGARA INDONESIA, TBK DAN PT. BANK RAKYAT INDONESIA, TBK.**

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, 03 Juni 2025

Penulis,



Mey Ari Wardhani
NPM. 2117031032

RIWAYAT HIDUP

Penulis bernama lengkap Mey Ari Wardhani, lahir di Tulang Bawang pada tanggal 4 Mei 2003. Penulis merupakan anak pertama dari dua bersaudara, putri dari pasangan Bapak Fitri Aryanto dan Ibu Karyati, dengan satu orang adik bernama Kirani Dwi Cahyani.

Pendidikan penulis dimulai dari Taman Kanak-Kanak Aisyiyah Bustanul Athfal II pada tahun 2008 sampai 2009, dilanjutkan ke jenjang Sekolah Dasar di SD Negeri 01 Daya Asri dari tahun 2009 sampai 2015. Kemudian melanjutkan pendidikan di SMP Negeri 01 Tumijajar dari tahun 2015 sampai 2018, dan SMA Negeri 01 Tumijajar dari tahun 2018 sampai 2021.

Pada tahun 2021, penulis diterima sebagai mahasiswi Program Studi S1 Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung melalui jalur Seleksi Nasional Masuk Perguruan Tinggi Negeri (SNMPTN). Selama masa perkuliahan, penulis aktif dalam berbagai organisasi dan kegiatan kemahasiswaan, di antaranya sebagai Anggota Bidang Keilmuan HIMATIKA FMIPA pada tahun 2022 sampai 2023, Staf Ahli Advokasi dan Kesejahteraan Mahasiswa BEM FMIPA pada tahun 2023 sampai 2024, dan Internal Staff Pengembangan Sumber Daya Manusia Senyum Anak Nusantara (SAN) *Chapter* Provinsi Lampung pada tahun 2023 sampai 2024.

Penulis juga terlibat dalam sejumlah kepanitiaan, antara lain sebagai Subkoordinator Kompetisi Matematika pada kegiatan Dies Natalis Jurusan Matematika (DINAMIKA) dan Sekretaris Divisi Acara pada Talkshow Beasiswa. Penulis pernah dipercaya sebagai mentor fotografi dalam kegiatan pengembangan minat mahasiswa serta menjadi mentor akademik di Jurusan Matematika. Pada bidang prestasi, penulis meraih Juara 2 Lomba Fotografi Tingkat Fakultas, mewakili Jurusan Matematika dalam kompetisi tersebut.

Pada awal tahun 2024, penulis melaksanakan Kerja Praktik (KP) di Dinas Bina Marga dan Bina Konstruksi Provinsi Lampung. Selain itu, penulis mengikuti Kuliah Kerja Nyata (KKN) sebagai bentuk pengabdian kepada masyarakat di Desa Sidodadi, Kecamatan Arma Jaya, Kabupaten Bengkulu Utara, Provinsi Bengkulu selama lebih dari satu bulan sebagai salah satu delegasi Universitas Lampung dalam program KKN Kolaborasi dengan Universitas Bengkulu.

KATA INSPIRASI

”Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya.”

(QS. Al-Baqarah: 286)

”Dan janganlah kamu merasa lemah, dan jangan pula bersedih hati, sebab kamu paling tinggi derajatnya, jika kamu orang beriman.”

(QS. Ali Imran: 139)

”Barangsiapa yang mengerjakan kebaikan sekecil apapun, niscaya dia akan melihat balasannya.”

(QS. Al-Zalzalah: 7)

”Dan bersabarlah kamu, sesungguhnya janji Allah adalah benar.”

(QS. Ar-Rum: 60)

”Setiap lelah yang orang tuaku sembunyikan, menjelma kekuatan yang mendorongku untuk terus melangkah.”

(Mey Ari Wardhani)

PERSEMBAHAN

Alhamdulillah rabbil 'alamin, rasa syukur kepada Allah SWT atas rahmat dan hidayah-Nya hingga skripsi ini dapat terselesaikan dengan baik. Sebagai ungkapan syukur, kupersembahkan karya kecil dan sederhana ini kepada:

Bapak dan Mamakku Tercinta

Terima kasih yang tak terhingga kepada kedua orang tua yang sangat dicintai oleh penulis, yang telah bekerja tanpa kenal lelah, mengorbankan waktu, tenaga, dan segalanya demi masa depan penulis. Doa-doa yang tak pernah putus, cinta yang begitu tulus, serta motivasi yang selalu menguatkan di setiap langkah, menjadi cahaya dalam setiap perjalanan hidup penulis. Rasa terima kasih ini tak akan pernah sebanding dengan segala kasih sayang dan pengorbanan yang telah diberikan. Gelar ini adalah milik kita bersama.

Dosen Pembimbing dan Penguji

Terimakasih kepada dosen pembimbing dan penguji yang sudah sangat membantu dalam memberikan arahan, motivasi, serta ilmu yang berharga sehingga penulis dapat menyelesaikan skripsi ini.

Sahabat-Sahabatku

Terima kasih kepada semua orang-orang baik yang hadir memberi bantuan dan semangat, dalam setiap langkah dan situasi selama perjalanan ini.

Almamater Tercinta, Universitas Lampung

SANWACANA

Alhamdulillah rabbil 'alamin, puji dan syukur penulis panjatkan kepada Allah SWT atas limpahan rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul "Implementasi Model *Hybrid Vector Autoregressive Integrated Moving Average (VARIMA) - Bidirectional Long Short-Term Memory (BiLSTM)* pada Peramalan Harga Saham PT. Bank Negara Indonesia, Tbk dan PT. Bank Rakyat Indonesia, Tbk".

Skripsi ini dibuat sebagai salah satu syarat memperoleh gelar Sarjana Matematika di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung. Proses penyusunan skripsi ini dibimbing, didukung, dan dibantu oleh banyak pihak yang memberikan bimbingan, dukungan, arahan, motivasi serta saran sehingga skripsi ini dapat terselesaikan. Oleh karena itu, dalam kesempatan ini penulis mengucapkan terimakasih kepada:

1. Bapak Ir. Warsono, M.S., Ph.D., selaku Pembimbing I yang banyak meluangkan waktunya untuk memberikan arahan, bimbingan, motivasi, saran serta dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
2. Ibu Dr. Dian Kurniasari, S.Si., M.Sc., selaku Pembimbing II yang memberikan waktu, arahan, bimbingan, saran dan dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
3. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Penguji yang bersedia memberikan kritik dan saran serta evaluasi kepada penulis.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku dosen pembimbing akademik yang selalu bersedia membimbing, mendukung, serta memberikan saran kepada penulis tentang semua hal yang berkaitan dengan akademik.
5. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

7. Seluruh dosen, staff dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
8. Bapak, Mamak, Adek, dan seluruh keluarga tercinta. Terima kasih atas kasih sayang yang tak pernah putus, doa-doa yang diam-diam menguatkan, serta dukungan yang setia mengiringi setiap langkah penulis. Tanpa kehadiran dan pengorbanan kalian, perjalanan ini tak mungkin sampai sejauh ini. Setiap pencapaian yang penulis raih adalah buah dari cinta, kesabaran, dan ketulusan kalian yang sering tak terlihat, namun selalu terasa dalam hati penulis. Semoga kebahagiaan ini menjadi milik kita bersama.
9. Teman seperbimbingan, PT. Cinta Sejati, dan PDD KKN 80, atas kebersamaan yang tulus, semangat yang saling menular, dan tawa yang sering kali menjadi penawar di tengah tekanan penyusunan skripsi.
10. Semua pihak yang membantu penulis dalam menyelesaikan skripsi.

Penulis menyadari bahwa skripsi ini masih jauh dari sempurna, sehingga penulis mengharapkan kritik dan saran yang membangun untuk menjadikan skripsi ini lebih baik lagi. Semoga skripsi ini dapat bermanfaat bagi pembaca.

Bandar Lampung, 03 Juni 2025
Penulis,

Mey Ari Wardhani

DAFTAR ISI

| | |
|---|---------------|
| DAFTAR ISI | xiv |
| DAFTAR TABEL | xvi |
| DAFTAR GAMBAR | .xviii |
| I PENDAHULUAN | 1 |
| 1.1 Latar Belakang Masalah | 1 |
| 1.2 Rumusan Masalah | 7 |
| 1.3 Tujuan Penelitian | 7 |
| 1.4 Manfaat Penelitian | 7 |
| II TINJAUAN PUSTAKA | 9 |
| 2.1 Penelitian Terkait | 9 |
| 2.2 Deret Waktu | 12 |
| 2.2.1 Analisis Deret Waktu | 12 |
| 2.2.2 Peramalan | 13 |
| 2.3 Stasioneritas Data | 13 |
| 2.4 Model Deret Waktu | 15 |
| 2.4.1 Model Deret Waktu Univariat | 15 |
| 2.4.1.1 <i>Autoregressive (AR)</i> | 15 |
| 2.4.1.2 <i>Moving Average (MA)</i> | 16 |
| 2.4.1.3 <i>Autoregressive Moving Average (ARMA)</i> | 16 |
| 2.4.1.4 <i>Autoregressive Integrated Moving Average (ARIMA)</i> | 16 |
| 2.4.2 Model Deret Waktu Multivariat | 17 |
| 2.4.2.1 <i>Vector Autoregressive (VAR)</i> | 17 |
| 2.4.2.2 <i>Vector Moving Average (VMA)</i> | 18 |
| 2.4.2.3 <i>Vector Autoregressive Moving Average (VARMA)</i> | 18 |
| 2.4.2.4 <i>Vector Autoregressive Intagreted Moving Average (VARIMA)</i> | 19 |
| 2.5 Uji Asumsi Residual <i>White Noise</i> | 19 |
| 2.6 <i>Machine Learning</i> | 20 |
| 2.7 <i>Deep Learning</i> | 21 |

| | | |
|------------|--|-----------|
| 2.8 | <i>Recurrent Neural Network (RNN)</i> | 21 |
| 2.9 | <i>Long Short-Term Memory (LSTM)</i> | 22 |
| 2.10 | <i>Bidirectional Long Short-Term Memory (BiLSTM)</i> | 25 |
| 2.11 | Fungsi Aktivasi | 26 |
| 2.12 | <i>Scaling Data</i> | 27 |
| 2.13 | <i>Unscaling Data</i> | 28 |
| 2.14 | <i>Hyperparameter</i> | 28 |
| 2.15 | <i>Hybrid VARIMA-BiLSTM</i> | 29 |
| 2.16 | Evaluasi Model | 30 |
| 2.16.1 | <i>Root Mean Square Error (RMSE)</i> | 31 |
| 2.16.2 | <i>Mean Absolute Percentage Error (MAPE)</i> | 31 |
| 2.17 | <i>Goodness of Fit</i> | 32 |
| III | METODE PENELITIAN | 33 |
| 3.1 | Waktu dan Tempat Penelitian | 33 |
| 3.2 | Data Penelitian | 33 |
| 3.3 | Alat Penelitian | 34 |
| 3.4 | Metode Penelitian | 35 |
| IV | HASIL DAN PEMBAHASAN | 39 |
| 4.1 | Proses <i>Input Data</i> | 39 |
| 4.2 | Visualisasi Data | 40 |
| 4.3 | <i>Splitting Data</i> | 41 |
| 4.4 | <i>Preprocessing Data</i> | 41 |
| 4.5 | Prediksi dan Peramalan Model VARIMA | 42 |
| 4.5.1 | Stasioneritas Data | 42 |
| 4.5.2 | Identifikasi Model VARIMA | 44 |
| 4.5.3 | Estimasi Parameter Model VARIMA | 45 |
| 4.5.4 | Prediksi Model VARIMA | 45 |
| 4.5.5 | Residual Model VARIMA | 48 |
| 4.5.6 | Uji Asumsi Residual <i>White Noise</i> | 49 |
| 4.5.7 | Peramalan Model VARIMA | 50 |
| 4.6 | Prediksi dan Peramalan Model <i>Hybrid VARIMA-E_BiLSTM</i> | 51 |
| 4.6.1 | <i>Scaling data</i> | 52 |
| 4.6.2 | <i>Hyperparameter Tuning Model E_BiLSTM</i> | 52 |
| 4.6.3 | Membangun Model <i>E_BiLSTM</i> | 53 |
| 4.6.4 | Prediksi Model <i>E_BiLSTM</i> | 53 |

| | | |
|----------|---|-----------|
| 4.6.5 | Prediksi Model <i>Hybrid</i> VARIMA–E_BiLSTM | 55 |
| 4.6.6 | Peramalan Model E_BiLSTM | 57 |
| 4.6.7 | Peramalan Model <i>Hybrid</i> VARIMA–E_BiLSTM | 58 |
| 4.7 | Prediksi dan Peramalan Model <i>Hybrid</i> VARIMA–EP_BiLSTM | 60 |
| 4.7.1 | <i>Scaling</i> data | 60 |
| 4.7.2 | <i>Hyperparameter Tuning</i> Model P_BiLSTM | 60 |
| 4.7.3 | Membangun Model P_BiLSTM | 61 |
| 4.7.4 | Prediksi Model P_BiLSTM | 62 |
| 4.7.5 | Prediksi Model <i>Hybrid</i> VARIMA–EP_BiLSTM | 63 |
| 4.7.6 | Peramalan Model P_BiLSTM | 65 |
| 4.7.7 | Peramalan Model <i>Hybrid</i> VARIMA–EP_BiLSTM | 66 |
| 4.8 | <i>Goodness of Fit</i> (Uji Kesesuaian Model) | 68 |
| V | KESIMPULAN | 70 |
| 5.1 | Kesimpulan | 70 |
| | DAFTAR PUSTAKA | 72 |

DAFTAR TABEL

| | | |
|-----|---|----|
| 1. | Penelitian Terkait | 10 |
| 2. | Data Penelitian | 34 |
| 3. | <i>Input Data</i> | 39 |
| 4. | <i>Missing Value</i> | 41 |
| 5. | Nilai Koefisien Korelasi | 41 |
| 6. | Nilai Uji Stasioner Awal | 42 |
| 7. | Nilai Uji Stasioner <i>Differencing</i> Pertama | 43 |
| 8. | Nilai BIC pada Model-Model VARIMA | 45 |
| 9. | Hasil Prediksi Model VARIMA (1,1,1) | 46 |
| 10. | Hasil Prediksi Model VARIMA (1,1,1) (<i>Undifferencing</i>) | 46 |
| 11. | Nilai Evaluasi Model VARIMA | 47 |
| 12. | Hasil Residual Model VARIMA (1,1,1) | 48 |
| 13. | Nilai Uji Ljung-Box | 50 |
| 14. | Peramalan Model VARIMA (1,1,1) | 50 |
| 15. | <i>Hyperparameter Tuning</i> Model E_BiLSTM | 52 |
| 16. | Hasil <i>Hyperparameter Tuning</i> Model E_BiLSTM | 53 |
| 17. | Hasil Prediksi Model E_BiLSTM | 54 |
| 18. | Nilai Evaluasi Prediksi Model E_BiLSTM | 55 |
| 19. | Hasil Prediksi Model <i>Hybrid</i> VARIMA–E_BiLSTM | 55 |
| 20. | Nilai Evaluasi Prediksi Model <i>Hybrid</i> VARIMA–E_BiLSTM | 56 |
| 21. | Peramalan Model E_BiLSTM | 57 |
| 22. | Peramalan Model <i>Hybrid</i> VARIMA–E_BiLSTM | 58 |
| 23. | <i>Hyperparameter Tuning</i> Model P_BiLSTM | 61 |
| 24. | Hasil <i>Hyperparameter Tuning</i> Model P_BiLSTM | 61 |
| 25. | Hasil Prediksi Model P_BiLSTM | 62 |
| 26. | Nilai Evaluasi Prediksi Model P_BiLSTM | 63 |
| 27. | Hasil Prediksi Model <i>Hybrid</i> VARIMA–EP_BiLSTM | 64 |
| 28. | Nilai Evaluasi Prediksi Model <i>Hybrid</i> VARIMA–EP_BiLSTM | 65 |
| 29. | Peramalan Model P_BiLSTM | 65 |

| | | |
|-----|--|----|
| 30. | Peramalan Model <i>Hybrid</i> VARIMA–EP_BiLSTM | 67 |
| 31. | <i>Goodness of Fit</i> BBRI.JK | 68 |
| 32. | <i>Goodness of Fit</i> BBNI.JK | 69 |

DAFTAR GAMBAR

| | | |
|-----|--|----|
| 1. | Arsitektur LSTM (Wang et al., 2024). | 22 |
| 2. | Arsitektur BiLSTM (Cui et al., 2020). | 25 |
| 3. | <i>Flowchart</i> Model <i>Hybrid</i> VARIMA–E_BiLSTM | 37 |
| 4. | <i>Flowchart</i> Model <i>Hybrid</i> VARIMA–EP_BiLSTM | 38 |
| 5. | Plot Data Harga Saham <i>Adj Close</i> BBRI.JK dan BBNI.JK | 40 |
| 6. | Plot Data Stasioner Setelah <i>Differencing</i> Pertama. | 43 |
| 7. | Plot ACF dan PACF Variabel BBRI.JK. | 44 |
| 8. | Plot ACF dan PACF Variabel BBNI.JK. | 44 |
| 9. | Plot Hasil Prediksi Model VARIMA (1,1,1) | 47 |
| 10. | Plot Hasil Residual Model VARIMA (1,1,1) | 49 |
| 11. | Plot Peramalan Model VARIMA (1,1,1) | 51 |
| 12. | Plot Hasil Prediksi Model E_BiLSTM | 54 |
| 13. | Plot Hasil Prediksi Model <i>Hybrid</i> VARIMA–E_BiLSTM | 56 |
| 14. | Plot Peramalan Model E_BiLSTM | 58 |
| 15. | Plot Peramalan Model <i>Hybrid</i> VARIMA–E_BiLSTM | 59 |
| 16. | Plot Hasil Prediksi Model P_BiLSTM | 63 |
| 17. | Plot Hasil Prediksi Model <i>Hybrid</i> VARIMA–EP_BiLSTM | 64 |
| 18. | Plot Peramalan Model P_BiLSTM | 66 |
| 19. | Plot Peramalan Model <i>Hybrid</i> VARIMA–EP_BiLSTM | 67 |

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Pada era perubahan yang bergerak sangat cepat, kemampuan dalam menganalisis urutan kejadian dan pergerakan data melalui analisis deret waktu telah menjadi aspek krusial dalam mendukung pengambilan keputusan yang tepat. Analisis deret waktu merupakan analisis statistika yang digunakan untuk mengolah data observasi atau data amatan yang berbentuk urutan waktu (Hyndman & Athanasopoulos, 2018). Pendekatan ini sering disebut sebagai analisis deret waktu dan umumnya diterapkan untuk meramalkan nilai pada periode berikutnya. Peramalan dalam analisis deret waktu ini dapat digunakan untuk memperoleh informasi yang akurat dalam memperkirakan tren masa depan dengan melihat data dari masa lalu.

Metode peramalan dalam konteks analisis deret waktu dapat didefinisikan berdasarkan jumlah variabel yang diamati, yaitu univariat dan multivariat (Al Haromainy *et al.*, 2021). Model peramalan data deret waktu univariat merupakan Model yang melibatkan satu variabel yang diamati, sedangkan model multivariat merupakan model yang melibatkan dua atau lebih variabel diamati. Pendekatan univariat berguna dalam menganalisis pergerakan dari satu variabel tunggal tanpa mempertimbangkan variabel lain, sedangkan pendekatan multivariat ini berguna untuk menganalisis interaksi antar variabel yang mempengaruhi suatu fenomena secara bersamaan.

Pendekatan univariat memiliki beberapa model yang dapat digunakan, seperti *Autoregressive* (AR), *Moving Average* (MA), *Autoregressive Moving Average* (ARMA), dan *Autoregressive Integrated Moving Average* (ARIMA). Model AR menjelaskan pergerakan suatu variabel yang dipengaruhi oleh nilai variabel itu sendiri pada waktu sebelumnya, model MA mempertimbangkan pergerakan variabel berdasarkan residual (kesalahan) di masa lalu, ARMA menggabungkan

dari model AR dan MA untuk memprediksi berdasarkan data masa lalu, sedangkan model ARIMA bentuk pengembangan dari model ARMA dengan data tidak stasioner yang dilakukan *differencing* agar datanya stasioner (Rezaldi & Sugiman, 2021).

Sementara itu, model yang terdapat dalam analisis deret waktu multivariat mencakup berbagai model, seperti *Vector Autoregressive* (VAR), *Vector Moving Average* (VMA), *Vector Autoregressive Moving Average* (VARMA), dan *Vector Autoregressive Integrated Moving Average* (VARIMA). Model VAR merupakan pengembangan dari model AR yang melibatkan lebih dari satu variabel. Model ini digunakan untuk menjelaskan hubungan timbal balik antar variabel-variabel yang berhubungan (Mirtawati & Saputra, 2023). Model VMA yang dikembangkan dari model MA dengan data lebih dari satu variabel dan digunakan untuk meramalkan beberapa variabel berdasarkan pergerakan residual masa lalu. Model VARMA merupakan pengembangan dari model ARMA dalam analisis deret waktu multivariat (Caliwag & Lim, 2019). Model ini juga menggabungkan antara Model VAR dan model VMA. Model VAR, VMA, dan VARMA merupakan model yang menggunakan data lebih dari satu variabel dengan syarat bahwa data harus stasioner. Ketiga model tersebut tidak cocok digunakan untuk data deret waktu yang tidak stasioner, sesuai dengan syarat model yang mengharuskan data bersifat stasioner (Enders, 2014).

Model yang memiliki kecocokan dalam mengatasi data tidak stasioner adalah model VARIMA, model tersebut merupakan pengembangan dari model ARIMA dengan data lebih dari satu variabel yang membentuk vektor dimana antar variabel saling berhubungan satu sama lain (Wei, 2006). Model VARIMA digunakan untuk menganalisis hubungan dinamis antar beberapa variabel yang saling bergantung dalam deret waktu, model ini menggunakan data tidak stasioner sehingga data dilakukan *differencing* untuk mendapatkan data yang stasioner. Beberapa penelitian yang menggunakan model VARIMA yaitu penelitian yang dilakukan oleh Pertiwi *et al.* (2021) dalam memperkirakan Indeks Harga Saham Gabungan (IHSG) dan kurs rupiah terhadap *United States Dollar* (USD) dengan data harian dari periode 01 Januari 2020 sampai 31 Maret 2021 menggunakan model VARIMA, dan hasil penelitian menunjukkan bahwa peramalan yang diperoleh memiliki nilai akurasi yang cukup baik. Nilai *Mean Absolute Percentage Error* (MAPE) untuk variabel Indeks Harga Saham Gabungan (IHSG) sebesar 1,21% dan variabel kurs rupiah sebesar 1,07%. Selain itu, penelitian lainnya dilakukan oleh Nugroho &

Suwanda (2022) dalam pemodelan VARIMA pada nilai impor dan ekspor *non* migas di Jawa Barat dengan data bulanan dari Januari 2013 sampai April 2022 dengan hasil penelitian menunjukkan akurasi yang cukup baik. Nilai MAPE untuk variabel impor sebesar 9,38%, dan variabel ekspor sebesar 8,16%. Meskipun model multivariat menunjukkan akurasi yang tinggi, penting untuk diketahui bahwa model VARIMA hanya mampu menangkap pola linier pada data deret waktu dan memiliki keterbatasan dalam memproses data deret waktu yang bersifat *non*-linier, untuk mengatasi keterbatasan ini diperlukan pendekatan yang lebih baru dalam kemampuannya menangkap data yang bersifat *non*-linier. Menurut Rowan *et al.* (2022) salah satu model yang dapat digunakan adalah dengan menggunakan pendekatan *machine learning* yang memiliki kemampuan dalam menangani data dengan pola *non*-linier secara lebih efektif.

Machine learning merupakan metode yang dapat digunakan untuk melakukan peramalan data deret waktu, termasuk data deret waktu yang bersifat *non*-linier. Salah satu pendekatan *machine learning* adalah *deep learning*. *Deep learning* adalah sebuah teknik berbasis jaringan saraf tiruan yang terdiri dari beberapa lapisan yang memungkinkan mesin untuk mempelajari pola dan fitur kompleks dari data dalam jumlah yang besar (Goodfellow *et al.*, 2018). Penggunaan model *deep learning* mampu menghasilkan akurasi yang baik, seperti penelitian yang dilakukan oleh Putri (2023) dalam memprediksi harga saham syariah menggunakan model *Long Short-Term Memory* (LSTM) dan *Bidirectional Long Short-Term Memory* (BiLSTM) dengan data harian dari periode 01 Januari 2018 sampai 01 Januari 2023. Penelitian tersebut menghasilkan nilai akurasi yang cukup baik. Nilai *Mean Absolute Percentage Error* (MAPE) pada variabel PT. Aneka Tambang, Tbk (ANTM.JK), PT. Unilever, Tbk (UNVR.JK), dan PT. Indofood, Tbk (INDF.JK) untuk model LSTM berturut-turut adalah 2,66%, 2,11%, dan 1,08%. Pada model BiLSTM berturut-turut adalah 2,59%, 1,77%, dan 1,05%. Penelitian ini membuktikan bahwa model *deep learning* terutama model LSTM dan model BiLSTM mampu mengatasi tantangan dalam data deret waktu dengan tingkat akurasi yang tinggi.

Pencapaian tingkat akurasi yang tinggi didapatkan dari hasil pengembangan model *deep learning* pada analisis data deret waktu yang melalui beberapa tahap. Model pertama yaitu *Recurrent Neural Network* (RNN) yang dirancang untuk mengolah informasi berdasarkan urutan waktu atau susunan kata dalam kata (Pramunendar *et al.*, 2022). Namun, model RNN memiliki kesulitan dalam

menyimpan informasi dalam jangka panjang akibat masalah *vanishing gradient*. Hochreiter & Schmidhuber (1997) mengembangkan model LSTM sebagai solusi untuk meningkatkan kinerja model RNN dan mengatasi masalah *vanishing gradient* yang ada pada model RNN. Model LSTM merupakan model yang menyertakan *memory cell* agar dapat menyimpan informasi dalam waktu yang lama dan dapat mengatasi terjadinya *vanishing gradient* pada model RNN saat melakukan proses data sekuensial yang panjang (Pontoh *et al.*, 2022). Meskipun model LSTM lebih baik dari model RNN, model ini masih memiliki kekurangan karena hanya memproses data secara satu arah (maju) sehingga kurang mampu memahami konteks dua arah yang seringkali penting dalam analisis data deret waktu.

Graves & Schmidhuber pada tahun 2005 melakukan pengembangan lebih lanjut dari model LSTM yaitu *Bidirectional Long Short Term-Memory* (BiLSTM). Model BiLSTM mampu memproses data dari dua arah, yaitu informasi sebelumnya dan informasi dari data berikutnya dengan memproses data dari dua arah yang berlawanan (Nilasari *et al.*, 2023). Jaringan model LSTM pertama berfungsi untuk memproses urutan data ke arah depan (*forward*) dan jaringan model LSTM kedua berfungsi untuk memproses urutan data ke arah belakang (*backward*). Kelebihan ini menjadikan model BiLSTM sebagai pilihan utama untuk memprediksi data deret waktu karena kemampuannya dalam memahami konteks secara lebih menyeluruh. Selain itu, model BiLSTM juga lebih efektif dalam menangkap hubungan jangka panjang dan kemampuan dalam meningkatkan akurasi prediksi. Hal ini terlihat jelas dalam penelitian Putri (2023), yang menunjukkan variabel ANTM.JK, UNVR.JK, dan INDF.JK pada model BiLSTM memiliki nilai MAPE lebih rendah dibandingkan nilai MAPE model LSTM. Berdasarkan keunggulan-keunggulan tersebut, model BiLSTM menjadi pilihan utama untuk memodelkan data deret waktu yang kompleks. Namun, model *deep learning* cenderung hanya membangun hubungan *non-linier* dengan waktu pelatihan yang cukup lama serta jumlah parameter yang besar dalam mencapai performa terbaik (Rowan *et al.*, 2022).

Model *deep learning* memiliki keterbatasan karena hanya berfokus pada hubungan *non-linier* dalam data. Sementara itu, data deret waktu yang digunakan pada model statistika klasik dan model *deep learning* jarang menunjukkan karakteristik linier atau *non-linier* saja, melainkan seringkali terjadi kombinasi antar keduanya. Oleh karena itu, kombinasi antara model linier dan model *non-linier* dapat digunakan untuk menangani kasus deret waktu yang melibatkan elemen linier

maupun *non*-linier. Maka diperlukan pendekatan yang mampu menangkap kedua karakteristik tersebut secara efektif guna meningkatkan akurasi dan ketepatan dalam analisis data deret waktu. Model VARIMA sebagai model klasik memiliki keunggulan dalam mengidentifikasi pola linier dan hubungan langsung antara variabel dalam data deret waktu. Sementara itu, model BiLSTM yang merupakan bagian dari model *deep learning* unggul dalam menangani pola *non*-linier serta memahami dinamika data dari dua arah. Kombinasi kedua model dalam pendekatan *hybrid* menjadi solusi optimal, dimana model VARIMA bertanggung jawab dalam menangkap pola linier, sedangkan model BiLSTM melengkapinya dengan kemampuan dalam mengidentifikasi pola *non*-linier dan kompleksitas jangka panjang. Integrasi dari kedua model ini akan menghasilkan model yang mampu menangkap pola yang lebih beragam serta meningkatkan kualitas prediksi secara keseluruhan.

Menurut Zhang (2003), salah satu pilihan dalam metode statistik untuk peramalan adalah dengan mengkombinasikan model linier dan model *non*-linier atau biasa disebut dengan model *hybrid*. Pendekatan ini lebih efektif karena memanfaatkan kelebihan masing-masing model. Model linier mampu menangkap pola tren dan musiman, sementara model *non*-linier dapat mengatasi fluktuasi dalam data. Penerapan model *hybrid* tidak hanya meningkatkan keakuratan prediksi tetapi juga fleksibel dalam menghadapi berbagai jenis data deret waktu. Penelitian terdahulu sering melakukan prediksi menggunakan model *hybrid* dengan mengkombinasikan antara model statistika klasik dengan model *deep learning*. Salah satu penerapan model *hybrid* dilakukan oleh Caliwag & Lim (2019), yang membahas tentang peramalan status pengisian dan tegangan keluaran baterai lithium-ion dalam aplikasi sepeda motor menggunakan model *hybrid* VARMA-LSTM. Penelitian tersebut menghasilkan akurasi yang cukup baik, yakni memperoleh nilai *Root Mean Square Error* (RMSE) untuk model VARMA sebesar 3,836, model LSTM sebesar 0,4032, dan model *hybrid* VARMA-LSTM sebesar 0,161. Berdasarkan hasil akurasi tersebut, dapat dikatakan bahwa melakukan kombinasi model linier dan *non*-linier mampu meningkatkan keakuratan prediksi karena pada penelitian model *hybrid* tersebut akurasi yang dihasilkan sangat baik. Berdasarkan pemaparan tersebut, dirancang suatu kombinasi model yang memanfaatkan kelebihan masing-masing model. Salah satu pendekatan yang mengkombinasikan model tersebut adalah model *hybrid* VARIMA-BiLSTM.

Bentuk implementasi dari model *hybrid* VARIMA-BiLSTM yaitu untuk meramalkan harga saham. Harga saham adalah nilai yang ditetapkan untuk transaksi jual beli saham di pasar modal. Pasar modal merupakan mekanisme berbagai instrumen keuangan, seperti saham yang diperdagangkan. Harga saham umumnya bersifat tidak stabil dan sering mengalami fluktuasi yang signifikan (Nilsen, 2022). Fluktuasi tersebut terjadi karena beberapa faktor, seperti dampak ekonomi negara, dinamika pasar, dan kinerja perusahaan. Hal ini sering terjadi pada bank-bank besar yang memiliki peran strategis dalam sistem keuangan nasional karena bank besar di Indonesia seperti PT. Bank Negara Indonesia, Tbk dan PT. Bank Rakyat Indonesia, Tbk merupakan suatu lembaga keuangan di bidang ekonomi dan perbankan yang pergerakannya dipengaruhi oleh faktor-faktor pemicu terjadinya fluktuasi. Pernyataan tersebut juga didasarkan pada Laporan Profil Industri Perbankan pada triwulan III tahun 2024 yang diakses dari situs Otoritas Jasa Keuangan, menyatakan bahwa kinerja pertumbuhan ekonomi di bank umum Indonesia sama seperti triwulan III tahun 2023, dimana menunjukkan perlambatan ekonomi yang terjadi di bank umum Indonesia tetapi triwulan III tahun 2024 sudah mengalami perlambatan sejak awal tahun. Adanya fluktuasi yang terjadi secara terus-menerus menjadi alasan utama calon investor untuk melakukan analisis menyeluruh sebelum melakukan investasi saham. Analisis ini membantu calon investor dalam memahami pergerakan harga saham perusahaan di masa depan. Oleh karena itu, melakukan prediksi pergerakan harga saham dalam beberapa periode ke depan menjadi aspek penting dalam pengambilan keputusan investasi di pasar saham.

Berdasarkan uraian di atas, dilakukan peramalan pada harga saham dari data historis PT. Bank Negara Indonesia, Tbk dan PT. Bank Rakyat Indonesia, Tbk untuk membantu calon investor dalam mengambil keputusan sebelum melakukan investasi saham dengan penelitian yang berjudul “Implementasi Model *Hybrid Vector Autoregressive Integrated Moving Average (VARIMA) – Bidirectional Long Short Term-Memory (BiLSTM)* pada Peramalan Harga Saham PT. Bank Negara Indonesia, Tbk dan PT. Bank Rakyat Indonesia, Tbk”.

1.2 Rumusan Masalah

Rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Pembangunan model VARIMA, model *Hybrid* VARIMA–E_BiLSTM, dan model *Hybrid* VARIMA–EP_BiLSTM dalam meramalkan harga saham PT. Bank Negara Indonesia, Tbk dan PT. Bank Rakyat Indonesia, Tbk.
2. Menghasilkan peramalan harga saham PT. Bank Negara Indonesia, Tbk dan PT. Bank Rakyat Indonesia, Tbk dengan menggunakan model VARIMA, model *Hybrid* VARIMA–E_BiLSTM dan model *Hybrid* VARIMA–EP_BiLSTM.
3. Perbandingan kinerja model VARIMA, model *Hybrid* VARIMA–E_BiLSTM, dan model *Hybrid* VARIMA–EP_BiLSTM dalam meramalkan harga saham PT. Bank Negara Indonesia, Tbk dan PT. Bank Rakyat Indonesia, Tbk.

1.3 Tujuan Penelitian

Tujuan dalam penelitian ini adalah sebagai berikut:

1. Membangun model VARIMA, model *Hybrid* VARIMA–E_BiLSTM, dan model *Hybrid* VARIMA–EP_BiLSTM dalam meramalkan harga saham PT. Bank Negara Indonesia, Tbk dan PT. Bank Rakyat Indonesia, Tbk.
2. Mengetahui hasil peramalan harga saham PT. Bank Negara Indonesia, Tbk dan PT. Bank Rakyat Indonesia, Tbk dengan menggunakan model VARIMA, model *Hybrid* VARIMA–E_BiLSTM dan model *Hybrid* VARIMA–EP_BiLSTM.
3. Membandingkan kinerja model antara model VARIMA, model *Hybrid* VARIMA–E_BiLSTM, dan model *Hybrid* VARIMA–EP_BiLSTM dalam meramalkan harga saham PT. Bank Negara Indonesia, Tbk dan PT. Bank Rakyat Indonesia, Tbk.

1.4 Manfaat Penelitian

Manfaat dalam penelitian ini adalah sebagai berikut:

1. Memberikan pemahaman tentang proses pembangunan model menggunakan model *hybrid*.

2. Meningkatkan pemahaman hasil peramalan dengan menggunakan model *hybrid* dalam memberikan evaluasi untuk harga saham, dan memberi pemahaman tentang perbandingan kinerja model *hybrid*.
3. Memberikan kontribusi sebagai sumber dan referensi bagi peneliti selanjutnya dengan menggunakan model *hybrid* VARIMA–E_BiLSTM dan model *hybrid* VARIMA–EP_BiLSTM.

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Penyusunan suatu penelitian perlu didasarkan pada pemahaman terhadap penelitian-penelitian sebelumnya yang berkaitan dengan topik yang dibahas. Tujuannya adalah agar penelitian yang dilakukan memiliki dasar yang kuat, tidak hanya berdasarkan teori saja, tetapi juga memperhatikan hasil dari penelitian yang sudah ada. Berdasarkan penelitian terdahulu, dapat diketahui model apa saja yang pernah digunakan, jenis data yang dianalisis, serta bagaimana hasil dari penelitian tersebut.

Pada penelitian ini, beberapa penelitian sebelumnya dipelajari secara teliti dan digunakan sebagai referensi dalam menyusun kerangka berpikir dan memilih model yang tepat. Penelitian-penelitian tersebut dipilih karena memiliki hubungan dengan topik, menggunakan model yang mirip, serta memakai jenis data yang sejalan. Berdasarkan pemahaman terhadap penelitian-penelitian yang dilakukan sebelumnya, peneliti dapat melaksanakan penelitian ini dengan lebih terarah dan dapat memperoleh hasil yang bermanfaat serta dapat dipertanggung jawabkan.

Selain itu, kajian ini memungkinkan peneliti dapat melihat apa yang belum dibahas oleh penelitian sebelumnya. Hal ini membantu dalam menciptakan penelitian yang baru dan berbeda. Tabel berikut ini menyajikan ringkasan dari beberapa penelitian terdahulu yang relevan, meliputi judul penelitian, jenis data, model yang digunakan, dan hasil yang diperoleh. Ringkasan tersebut dapat disajikan pada Tabel 1 di bawah ini.

Tabel 1. Penelitian Terkait

| No. | Penelitian | Data | Metode | Hasil | |
|-----|---|---|-------------------------------------|---|--|
| | | | | RMSE | MAPE |
| 1. | Penerapan Model <i>Vector Autoregressive Integrated Moving Average</i> untuk Prakiraan Indeks Harga Saham Gabungan dan Kurs Rupiah terhadap USD (Pertiwi <i>et al.</i> , 2021) | Data harian dari periode 01 Januari 2020-31 Maret 2021 | VARIMA | - | IHSG: 1,21% Kurs: 1,07% Gabungan: 1,14% |
| 2. | Pemodelan <i>Multivariate Time Series</i> dengan <i>Vector Autoregressive Integrated Moving Average</i> pada Nilai Impor dan Ekspor Non Migas di Jawa Barat (Nugroho & Suwanda, 2022) | Data bulanan dari Januari 2013-April 2022 | VARIMA | - | Impor: 9,38% Ekspor: 8,16% |
| 3. | Implementasi <i>Long Short-Term Memory</i> dan <i>Bidirectional Long Short-Term Memory</i> dalam Prediksi Harga Saham Syariah (Putri, 2023) | Data harian dari periode 01 Januari 2018-01 Januari 2023 | LSTM & BiLSTM | - | LSTM ANTM.JK: 2,66% UNVR.JK: 2,11% INDE.JK: 1,08% BiLSTM ANTM.JK: 2,59% UNVR.JK: 1,77% INDE.JK: 1,05% |
| 4. | <i>Hybrid VARMA and LSTM Method for lithium-ion battery state-of-charge and output voltage forecasting in electric motorcycle applications</i> (Caliwag & Lim, 2019) | Data performa baterai, seperti : status pengisian dan tegangan keluaran baterai lithium-ion dalam aplikasi sepeda motor listrik | VARMA LSTM VARMA-LSTM | VARMA: 3,836 LSTM: 0,4032 VARMA-LSTM: 0,161 | - |

Berdasarkan ringkasan dalam Tabel 1, penelitian terkait memberikan informasi mengenai pendekatan, model, dan hasil studi sebelumnya. Penjelasan lebih lanjut akan disampaikan sebagai berikut:

1. Penelitian Pertama (Pertiwi dkk., 2021)

Penelitian yang dilakukan oleh Pertiwi *et al.* (2021), membahas tentang hasil prakiraan Indeks Harga Saham Gabungan (IHSG) dan kurs rupiah terhadap *United States Dollar* (USD) dengan model VARIMA. Pada penelitian ini, menggunakan data harian dari periode 01 Januari 2020 hingga 31 Maret 2021. Kemudian, nilai MAPE IHSG diperoleh sebesar 1,21%, MAPE Kurs diperoleh sebesar 1,07%, dan MAPE gabungan diperoleh sebesar 1,14%. Model VARIMA mempunyai tingkat akurasi yang sangat baik karena nilai MAPE yang diperoleh dari setiap variabel berada di bawah 10%.

2. Penelitian Kedua (Nugroho & Suwanda, 2022)

Penelitian yang dilakukan oleh Nugroho & Suwanda (2022), membahas tentang peramalan nilai impor dan ekspor *non* migas di Jawa Barat menggunakan model VARIMA. Pada penelitian ini, menggunakan data bulanan dari Januari 2013 hingga April 2022. Nilai MAPE impor *non* migas diperoleh sebesar 9,38%, dan ekspor *non* migas diperoleh sebesar 8,16%. Nilai MAPE yang dihasilkan berada di bawah 10% sehingga memiliki tingkat akurasi yang sangat baik.

3. Penelitian Ketiga (Putri, 2023)

Penelitian yang dilakukan oleh Putri (2023), membahas tentang perbandingan LSTM dan BiLSTM pada peramalan harga saham syariah dari data PT. Aneka Tambang, Tbk (ANTM.JK), PT. Unilever, Tbk (UNVR.JK), dan PT. Indofood, Tbk (INDF.JK). Pada penelitian ini, menggunakan data harian dari periode 01 Januari 2018 hingga 01 Januari 2023, nilai MAPE LSTM yang diperoleh untuk variabel ANTM.JK, UNVR.JK, dan INDF.JK berturut-turut sebesar 2,66%, 2,11%, dan 1,08%, serta nilai MAPE BiLSTM diperoleh berturut-turut sebesar 2,59%, 1,77%, dan 1,05%. Berdasarkan nilai MAPE, dapat disimpulkan bahwa akurasi yang dimiliki sangat baik karena nilai MAPE berada di bawah 10%.

4. Penelitian Keempat (Caliwag & Lim, 2019)

Penelitian berikutnya dilakukan oleh Caliwag & Lim (2019), membahas tentang peramalan status pengisian dan tegangan keluaran baterai lithium-ion dalam aplikasi sepeda motor menggunakan model *hybrid* VARMA-LSTM. Kumpulan data yang digunakan adalah data performa baterai, seperti status pengisian dan tegangan keluaran baterai lithium-ion dalam aplikasi sepeda motor listrik dan diperoleh nilai RMSE untuk VARMA sebesar 3,836, LSTM sebesar 0,4032, dan *hybrid* VARMA-LSTM sebesar 0,161. Berdasarkan nilai RMSE dapat

disimpulkan bahwa nilai RMSE tersebut adalah nilai yang terkecil sehingga semakin kecil nilai RMSE, semakin baik kinerja model dalam memprediksi secara akurat.

2.2 Deret Waktu

Menurut Granger & Newbold (1986), deret waktu atau biasa disebut dengan *time series* dideskripsikan sebagai suatu rangkaian data observasi yang dicatat secara berurutan berdasarkan suatu interval waktu tertentu, seperti harian, bulanan, atau tahunan. Tujuannya digunakan untuk menyajikan data historis yang dapat digunakan dalam analisis lebih lanjut.

2.2.1 Analisis Deret Waktu

Analisis deret waktu adalah metode statistik yang digunakan untuk menganalisis data yang tersusun secara berurutan berdasarkan waktu. Tujuan utama dari analisis ini adalah untuk mengidentifikasi pola, tren, serta fluktuasi dalam data historis, dan menemukan model yang tepat untuk merepresentasikan hubungan antar periode dalam data (Montgomery *et al.*, 2015).

Menurut Makridakis *et al.* (1983) ada beberapa pola utama dalam analisis deret waktu, yaitu :

1. Pola data horizontal adalah pola yang sering disebut sebagai data stasioner karena nilai-nilai dalam data cenderung mengalami fluktuasi di sekitar rata-rata yang relatif stabil.
2. Pola data musiman adalah pola yang terjadi ketika data dipengaruhi oleh faktor musiman, seperti harian, mingguan, dan bulanan.
3. Pola data siklis adalah pola yang menunjukkan fluktuasi berupa peningkatan dan penurunan nilai data yang tidak terjadi dalam interval waktu tertentu.
4. Pola data tren adalah pola yang terjadi jika ada perubahan yang konsisten dalam peningkatan maupun penurunan jangka panjang.

2.2.2 Peramalan

Peramalan adalah proses yang digunakan untuk memperkirakan kondisi di masa depan berdasarkan data historis. Menurut Montgomery *et al.* (2015), peramalan memainkan peran penting dalam manajemen, membantu organisasi dalam perencanaan dan pengambilan keputusan yang lebih baik. Proses ini tidak hanya melibatkan estimasi angka, tetapi juga analisis terhadap tren dan pola yang ada dalam data, yang dapat memberikan wawasan berharga mengenai faktor-faktor yang mempengaruhi hasil di masa depan.

Peramalan dalam konteks bisnis sangat penting untuk merencanakan kebutuhan sumber daya dan strategi pemasaran. Hal ini dapat dikatakan bahwa peramalan berperan dalam membantu organisasi mengelola ketidakpastian dan meminimalkan risiko dalam proses pengambilan keputusan. Selain itu, pemahaman yang mendalam mengenai peramalan dianggap penting bagi pengambil keputusan agar organisasi dapat menyesuaikan diri dan tetap bertahan di tengah dinamika perubahan lingkungan.

2.3 Stasioneritas Data

Proses dalam analisis deret waktu dapat dikatakan stasioner jika mengalami proses yang mengacu pada perubahan baik dalam rata-rata maupun dalam variansi. Stasioneritas dalam rata-rata mengacu pada kondisi dimana data menunjukkan pola kenaikan atau penurunan pada data yang terjadi di sekitar rata-rata yang tetap dan tidak terpengaruh oleh perubahan waktu. Sedangkan stasioner dalam variansi mengacu pada kondisi dimana struktur data dari waktu ke waktu menunjukkan pola kenaikan atau penurunan yang konsisten dan tidak berubah-ubah (Makridakis *et al.*, 1983). Stasioneritas data dapat diuji menggunakan uji *unit root* (akar unit) salah satunya menggunakan *Augmented Dickey-Fuller* (ADF), dimana data dikatakan stasioner jika nilai statistik $ADF_{hitung} > ADF_{tabel}$. Proses pengujian ini melibatkan langkah-langkah sebagai berikut (Wei, 2006) :

1. Hipotesis

- $H_0: \gamma = 0$ (deret waktu tidak stasioner)
- $H_1: \gamma < 0$ (deret waktu stasioner)

2. Taraf Signifikansi

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

3. Kriteria Uji

- Jika $ADF_{hitung} > ADF_{tabel}$ atau $p\text{-value} < \alpha$, maka H_0 ditolak.
- Jika $ADF_{hitung} < ADF_{tabel}$ atau $p\text{-value} > \alpha$, maka H_0 tidak ditolak.

4. Statistik Uji

Statistik uji menggunakan ADF dijabarkan dengan Persamaan (2.1) sebagai berikut:

$$ADF_{hitung} = \frac{\gamma - 1}{SE(\gamma)} \quad (2.1)$$

Keterangan:

- γ : nilai dugaan parameter *autoregressive* (AR) dengan orde p
- SE : *standard error*

5. Keputusan

Nilai $p\text{-value} > \alpha$, maka H_0 tidak ditolak atau nilai $p\text{-value} < \alpha$, maka H_0 ditolak.

6. Kesimpulan

Berdasarkan keputusan, dapat diketahui bahwa jika nilai $p\text{-value} > \alpha$, maka H_0 tidak ditolak yang mengartikan bahwa data tidak stasioner sehingga perlu dilakukan *differencing* agar datanya stasioner. Jika $p\text{-value} < \alpha$, maka H_0 ditolak yang mengartikan bahwa data stasioner.

Jika hasil pengujian menunjukkan deret waktu tidak stasioner, diferensiasi dapat dilakukan untuk melakukan transformasi pada data sehingga menghasilkan deret waktu yang stasioner untuk analisis lebih lanjut. Diferensiasi biasanya dilakukan secara bertahap, seperti *differencing* orde pertama, kedua, atau lebih, dengan rumus matematis yang dinyatakan dalam Persamaan (2.2) sebagai berikut:

$$\Delta Y_t = Y_t - Y_{t-1} \quad (2.2)$$

Keterangan:

- ΔY_t : data hasil diferensiasi
- Y_t : data periode saat ini
- Y_{t-1} : data periode sebelumnya

Setelah data berhasil distasionerkan, analisis lanjutan dapat dilakukan dengan membuat plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) untuk menentukan orde model yang sesuai (Wei, 2006).

2.4 Model Deret Waktu

Model deret waktu digunakan untuk proses peramalan deret waktu yang melibatkan data historis. Data historis dicatat berdasarkan urutan dalam waktu, penggunaannya digunakan untuk memprediksi nilai-nilai di masa depan. Tujuan utama dari peramalan ini adalah untuk mengidentifikasi pola, tren, dan hubungan dalam data sehingga dapat membuat prediksi yang tepat mengenai peristiwa yang terjadi. Analisis deret waktu yang digunakan dalam peramalan terbagi menjadi dua, yaitu model deret waktu univariat dan model deret waktu multivariat.

2.4.1 Model Deret Waktu Univariat

Pada model deret waktu univariat, analisis hanya melibatkan satu variabel atau satu rangkaian data. Model ini berasumsi bahwa pola masa depan dapat diidentifikasi secara efektif dari data historis satu variabel tanpa perlu mempertimbangkan variabel lainnya atau faktor eksternal. Beberapa model dalam peramalan analisis deret waktu univariat adalah *Autoregressive (AR)*, *Moving Average (MA)*, *Autoregressive Moving Average (ARMA)*, *Autoregressive Integrated Moving Average (ARIMA)*.

2.4.1.1 *Autoregressive (AR)*

Autoregressive yaitu model regresi yang menjelaskan pergerakan suatu variabel yang dipengaruhi oleh nilai variabel itu sendiri pada periode sebelumnya. Model AR dinotasikan dengan (p) dan model AR bekerja pada data yang stasioner. Secara umum model AR dinyatakan pada Persamaan (2.3) sebagai berikut (Wei, 2006):

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_P Z_{t-P} + a_t \quad (2.3)$$

Keterangan:

- Z_t : Deret waktu stasioner
- Z_{t-p} : Nilai masa lalu yang berhubungan
- ϕ_P : Parameter *autoregressive*
- a_t : Residual pada waktu t

2.4.1.2 *Moving Average (MA)*

Moving Average yaitu suatu model yang melihat pergerakan variabel dari residual di masa lalu. Model MA dinotasikan dengan (q) dan model MA bekerja pada data yang bersifat stasioner. Secara umum model MA dapat dinyatakan pada Persamaan(2.4) sebagai berikut (Wei, 2006):

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.4)$$

Keterangan:

- Z_t : Deret waktu stasioner
- a_{t-q} : Nilai residual pada masa lalu
- θ_q : Parameter *moving average*
- a_t : Residual pada waktu t

2.4.1.3 *Autoregressive Moving Average (ARMA)*

Autoregressive Moving Average (ARMA) yaitu penggabungan dari model AR dan MA untuk memprediksi berdasarkan data masa lalu. Model ARMA dinotasikan dengan (p, q) dan model ARMA bekerja pada data yang stasioner. Secara umum model ARMA dinyatakan pada Persamaan (2.5) sebagai berikut (Wei, 2006) :

$$Z_t = (\phi_1 Z_{t-1} + \dots + \phi_P Z_{t-P} + a_t) - (\theta_1 a_{t-1} + \dots + \theta_q a_{t-q}) \quad (2.5)$$

Keterangan:

- Z_t : Deret waktu stasioner
- Z_{t-p} : Nilai masa lalu yang berhubungan
- ϕ_P : Parameter *autoregressive*
- a_{t-q} : Nilai residual pada masa lalu
- θ_q : Parameter *moving average*
- a_t : Residual pada waktu t

2.4.1.4 *Autoregressive Integrated Moving Average (ARIMA)*

Autoregressive Integrated Moving Average (ARIMA) yaitu model yang serupa dengan model ARMA, namun mengalami proses *differencing*. Model ARIMA

memiliki 3 notasi karena terdapat 3 parameter dalam model yaitu AR, I, dan MA, sehingga dinotasikan dengan (p, d, q). Model ARIMA bekerja pada data yang stasioner. Secara umum model ARIMA dinyatakan pada Persamaan (2.6) sebagai berikut (Harvey, 2006):

$$\Delta^d Z_t = \phi_1 \Delta^d Z_{t-1} + \dots + \phi_p \Delta^d Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.6)$$

Keterangan:

| | | |
|------------|---|----------------------------------|
| Z_t | : | Deret waktu stasioner |
| Δ^d | : | Operator <i>differencing</i> |
| Z_{t-p} | : | Nilai masa lalu yang berhubungan |
| ϕ_p | : | Parameter <i>autoregressive</i> |
| a_{t-q} | : | Nilai residual pada masa lalu |
| θ_q | : | Parameter <i>moving average</i> |
| a_t | : | Residual pada waktu t |

2.4.2 Model Deret Waktu Multivariat

Model deret waktu multivariat digunakan pada proses peramalan deret waktu yang melibatkan lebih dari satu variabel diamati. Model deret waktu multivariat digunakan untuk menganalisis dan memahami hubungan dinamis antar beberapa variabel yang saling memengaruhi seiring waktu. Terdapat beberapa model dalam deret waktu multivariat, yaitu *Vector Autoregressive* (VAR), *Vector Moving Average* (VMA), *Vector Autoregressive Moving Average* (VARMA), *Vector Autoregressive Integrated Moving Average* (VARIMA).

2.4.2.1 *Vector Autoregressive* (VAR)

Vector Autoregressive yaitu model yang berasal dari pengembangan model AR dengan melibatkan lebih dari satu variabel. Model ini merupakan sebuah sistem persamaan dinamis yang melakukan estimasi pada periode waktu tertentu dengan bergantung pada pergerakan variabel dan variabel lain yang terlibat dalam model pada periode sebelumnya (Rusyana *et al.*, 2020). Model VAR digunakan untuk data stasioner yang dinyatakan pada Persamaan (2.7) sebagai berikut (Wei, 2006):

$$Z_t = \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + a_t \quad (2.7)$$

Keterangan:

$$\begin{aligned} \mathbf{Z}_t & : [\mathbf{Z}_{1,t}, \mathbf{Z}_{2,t}, \dots, \mathbf{Z}_{N,t}]^T \text{ vektor deret waktu stasioner ukuran } \mathbf{N} \times \mathbf{1} \\ \Phi_1, \dots, \Phi_p & : \text{ matriks parameter } \textit{autoregressive} \text{ berukuran } \mathbf{N} \times \mathbf{N} \\ \mathbf{a}_t & : [\mathbf{a}_{1,t}, \mathbf{a}_{2,t}, \dots, \mathbf{a}_{N,t}]^T \text{ vektor residual ukuran } \mathbf{N} \times \mathbf{1} \end{aligned}$$

2.4.2.2 Vector Moving Average (VMA)

Vector Moving Average yaitu model yang dikembangkan dari model MA dengan melibatkan lebih dari satu variabel. Model ini merupakan sebuah sistem persamaan dinamis yang melakukan estimasi pada periode waktu tertentu dengan bergantung pada kesalahan (residual) variabel dan kesalahan (residual) variabel lainnya yang terlibat dalam model pada periode sebelumnya (Rusyana *et al.*, 2020). Model VMA bekerja pada data yang bersifat stasioner. Secara umum model VMA dinyatakan pada Persamaan (2.8) sebagai berikut (Wei, 2006):

$$\mathbf{Z}_t = \mathbf{a}_t - \Theta_1 \mathbf{a}_{t-1} - \Theta_2 \mathbf{a}_{t-2} - \dots - \Theta_q \mathbf{a}_{t-q} \quad (2.8)$$

Keterangan:

$$\begin{aligned} \mathbf{Z}_t & : [\mathbf{Z}_{1,t}, \mathbf{Z}_{2,t}, \dots, \mathbf{Z}_{N,t}]^T \text{ vektor deret waktu stasioner ukuran } \mathbf{N} \times \mathbf{1} \\ \Theta_1, \dots, \Theta_p & : \text{ matriks parameter } \textit{moving average} \text{ berukuran } \mathbf{N} \times \mathbf{N} \\ \mathbf{a}_t & : [\mathbf{a}_{1,t}, \mathbf{a}_{2,t}, \dots, \mathbf{a}_{N,t}]^T \text{ vektor residual ukuran } \mathbf{N} \times \mathbf{1} \end{aligned}$$

2.4.2.3 Vector Autoregressive Moving Average (VARMA)

Vector Autoregressive Moving Average yaitu model yang dikembangkan dari model ARMA dengan melibatkan lebih dari satu variabel. Model ini merupakan sebuah sistem persamaan dinamis yang melakukan estimasi pada periode waktu tertentu dengan bergantung pada pergerakan variabel, kesalahan (residual) variabel, pergerakan variabel lain dan kesalahan dari variabel lain yang terlibat dalam model pada periode sebelumnya (Rusyana *et al.*, 2020). Model VARMA bekerja pada data yang bersifat stasioner. Secara umum model VARMA dinyatakan pada Persamaan (2.9) sebagai berikut (Wei, 2006):

$$\mathbf{Z}_t = \Phi_1 \mathbf{Z}_{t-1} + \dots + \Phi_p \mathbf{Z}_{t-p} + \mathbf{a}_t - \Theta_1 \mathbf{a}_{t-1} - \dots - \Theta_q \mathbf{a}_{t-q} \quad (2.9)$$

Keterangan:

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

$$\begin{aligned}
\Phi_1, \dots, \Phi_p & : \text{ matriks parameter } \textit{autoregressive} \text{ berukuran } \mathbf{N} \times \mathbf{N} \\
\Theta_1, \dots, \Theta_q & : \text{ matriks parameter } \textit{moving average} \text{ berukuran } \mathbf{N} \times \mathbf{N} \\
\mathbf{a}_t & : [\mathbf{a}_{1,t}, \mathbf{a}_{2,t}, \dots, \mathbf{a}_{N,t}]^T \text{ vektor residual ukuran } \mathbf{N} \times \mathbf{1}
\end{aligned}$$

2.4.2.4 Vector Autoregressive Integrated Moving Average (VARIMA)

Vector Autoregressive Integrated Moving Average adalah model yang memiliki kesamaan dengan model VARMA, namun VARIMA mengalami proses *differencing*. Model VARIMA bekerja pada data yang bersifat tidak stasioner, sehingga dilakukan *differencing* agar data stasioner. Secara umum model VARIMA dinyatakan pada Persamaan (2.10) sebagai berikut (Harvey, 2006):

$$\Delta^d \mathbf{Z}_t = \Phi_1 \Delta^d \mathbf{Z}_{t-1} + \dots + \Phi_p \Delta^d \mathbf{Z}_{t-p} + \mathbf{a}_t - \Theta_1 \mathbf{a}_{t-1} - \dots - \Theta_q \mathbf{a}_{t-q} \quad (2.10)$$

Keterangan:

$$\begin{aligned}
\mathbf{Z}_t & : [\mathbf{Z}_{1,t}, \mathbf{Z}_{2,t}, \dots, \mathbf{Z}_{N,t}]^T \text{ vektor deret waktu stasioner ukuran } \mathbf{N} \times \mathbf{1} \\
\Delta^d & : \text{ operator } \textit{differencing} \\
\Phi_1, \dots, \Phi_p & : \text{ matriks parameter } \textit{autoregressive} \text{ berukuran } \mathbf{N} \times \mathbf{N} \\
\Theta_1, \dots, \Theta_q & : \text{ matriks parameter } \textit{moving average} \text{ berukuran } \mathbf{N} \times \mathbf{N} \\
\mathbf{a}_t & : [\mathbf{a}_{1,t}, \mathbf{a}_{2,t}, \dots, \mathbf{a}_{N,t}]^T \text{ vektor residual ukuran } \mathbf{N} \times \mathbf{1}
\end{aligned}$$

2.5 Uji Asumsi Residual *White Noise*

Asumsi dasar bahwa residual bersifat *white noise* artinya proses deret waktu yang memiliki residual independen dan identik ketika rata-rata sama dengan nol dan varians konstan. Uji *white noise* dilakukan dengan menggunakan statistik uji Ljung-Box yang didefinisikan sebagai berikut (Wei, 2006) :

1. Hipotesis

- $H_0 = 0$ (memenuhi asumsi *white noise*)
- $H_1 \neq 0$ (tidak memenuhi asumsi *white noise*)

2. Taraf Signifikansi

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

3. Kriteria Uji

- Jika $p\text{-value} < \alpha$, maka H_0 ditolak
- Jika $p\text{-value} > \alpha$, maka H_0 tidak ditolak

4. Statistik Uji

Statistik uji menggunakan uji Ljung-Box dijabarkan pada Persamaan (2.11) sebagai berikut:

$$Q = n(n + 2) \sum_{k=1}^m \frac{\hat{\rho}_k^2}{n - k} \quad (2.11)$$

Keterangan:

- Q : Uji *white noise*
- n : Banyak data
- m : Nilai pada lag
- k : Nilai maksimum
- ρ_k : Nilai perkiraan autokorelasi residual lag- k

5. Keputusan

Nilai $p\text{-value} > \alpha$, maka H_0 tidak ditolak atau nilai $p\text{-value} < \alpha$, maka H_0 ditolak.

6. Kesimpulan

Berdasarkan keputusan, dapat diketahui bahwa jika nilai $p\text{-value} > \alpha$, maka H_0 tidak ditolak yang mengartikan bahwa data memenuhi asumsi *white noise*. Jika $p\text{-value} < \alpha$, maka H_0 ditolak yang mengartikan bahwa data tidak memenuhi asumsi *white noise*.

2.6 Machine Learning

Machine Learning merupakan cabang yang sangat penting dalam kecerdasan buatan (AI), berfokus pada pengembangan algoritma dan model komputer untuk memungkinkan sistem belajar dari data. Prinsip dasar *machine learning* adalah memberikan kemampuan kepada komputer untuk memahami pola dan tren data, serta menggunakan pemahaman tersebut untuk membuat prediksi atau keputusan. Keunikan *machine learning* terletak pada kemampuannya untuk belajar secara mandiri dari data yang diberikan, tanpa memerlukan pemrograman eksplisit. Hal ini memungkinkan aplikasi *machine learning* untuk beradaptasi dengan perubahan data atau lingkungan. *Machine learning* memiliki berbagai jenis algoritma yang digunakan untuk beragam tugas, sehingga teknologi ini memiliki banyak aplikasi di berbagai bidang seperti pemrosesan bahasa alami dan visi komputer, serta

berperan penting dalam pemecahan masalah modern. Pembelajaran *machine learning* dikelompokkan menjadi beberapa kategori, yaitu:

1. *Supervised Learning*

Supervised learning adalah metode yang memanfaatkan data yang dilabeli sebelumnya. Contoh yang populer dalam kategori ini adalah *Deep Neural Networks* (DNN), *Convolutional Neural Networks* (CNN), *Long Short Term-Memory* (LSTM), dan *Gated Recurrent Unit* (GRU) (Alom *et al.*, 2019).

2. *Unsupervised Learning*

Unsupervised learning adalah proses pembelajaran yang beroperasi dengan memanfaatkan data yang sepenuhnya tidak diberi label sebelumnya. Tujuan utamanya adalah mengelompokkan data dengan karakteristik serupa ke dalam kategori tertentu, tanpa memerlukan target *output* (Alom *et al.*, 2019).

3. *Reinforcement Learning*

Reinforcement learning adalah metode yang tidak memanfaatkan data yang dilabeli. Metode ini digunakan pada interaksi lingkungan yang tidak diketahui (*unknown environments*) (Mnih *et al.*, 2015).

2.7 Deep Learning

Deep learning adalah cabang dari *machine learning* yang dirancang untuk berbagai aplikasi, seperti mendeteksi objek dalam video, mengidentifikasi objek dalam gambar, serta mendeteksi dan mengklasifikasikan suara. Teknologi ini efektif dalam mengelola data dalam jumlah besar, menggunakan algoritma *backpropagation* untuk menginformasikan mesin dalam mengubah parameter internal yang berfungsi sebagai representasi di setiap lapisan yang berasal dari lapisan sebelumnya. Pada arsitektur *deep learning*, data dengan volume besar dan kompleksitas tinggi dapat dikelola dengan sangat efisien. Salah satu algoritma dalam kategori *deep learning* adalah *Recurrent Neural Network* (RNN).

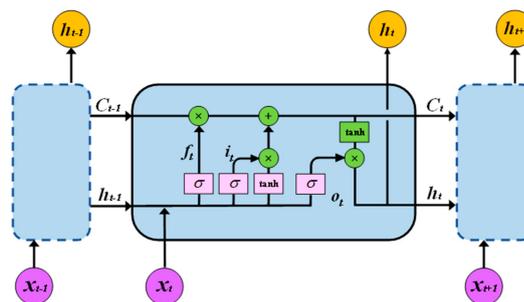
2.8 Recurrent Neural Network (RNN)

Recurrent Neural Network adalah jenis *Artificial Neural Network* (ANN) yang memproses data sekuensial dengan koneksi siklik yang memungkinkan pembaruan

keadaan berdasarkan status masa lalu dan *input* saat ini (Yin *et al.*, 2017). Model RNN terdiri dari sel berulang, termasuk sel sigma dan *tanh*, yang memanfaatkan informasi sebelumnya untuk memprediksi data berurutan yang belum terlihat. Struktur model RNN mencakup *input layer*, *hidden layer*, dan *output layer*, dengan aliran informasi dari unit *input* ke unit tersembunyi (Yin *et al.*, 2017). Meskipun model RNN efektif untuk *supervised classification learning*, ia kesulitan menyimpan informasi jangka panjang karena masalah *vanishing gradient* (Tian *et al.*, 2018).

2.9 Long Short-Term Memory (LSTM)

Long Short-Term Memory adalah arsitektur model RNN yang dirancang untuk mengatasi masalah *vanishing gradient* pada data dengan ketergantungan jangka panjang. Menurut Hochreiter & Schmidhuber (1997), model LSTM memiliki unit penyimpanan yang mengandalkan tiga gerbang. Gerbang ini mengatur aliran informasi, sehingga model LSTM mampu menyimpan informasi relevan dalam jangka waktu lama, sehingga efektif untuk aplikasi seperti pemrosesan bahasa alami dan analisis deret waktu. Model LSTM unggul dalam menangkap ketergantungan jangka panjang dalam data sekuensial, membuatnya lebih handal dibandingkan model RNN tradisional. Model LSTM terdapat 3 jenis *gate* yang diilustrasikan sebagai berikut:



Gambar 1. Arsitektur LSTM (Wang *et al.*, 2024).

1. Forget Gate

Forget gate (f_t) merupakan gerbang pertama yang menentukan informasi mana yang perlu dilupakan dari *cell state*. Nilai *forget gate* pada model LSTM menggunakan fungsi aktivasi sigmoid untuk memproses *input* dan *hidden state*

sebelumnya, memungkinkan penghapusan informasi yang tidak relevan untuk prediksi masa depan. Rumusnya ditunjukkan pada Persamaan (2.12) sebagai berikut (Rowan *et al.*, 2022):

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.12)$$

Keterangan:

| | | |
|-----------|---|---|
| f_t | : | <i>forget gate</i> dalam <i>timestep</i> t |
| σ | : | fungsi sigmoid |
| W_f | : | nilai bobot untuk <i>forget gate</i> |
| h_{t-1} | : | nilai <i>output</i> dalam <i>timestep</i> $t - 1$ |
| x_t | : | nilai <i>input</i> dalam <i>timestep</i> t |
| b_f | : | nilai bias <i>forget gate</i> |

2. *Input Gate*

Input gate (i_t) adalah gerbang yang mengontrol informasi baru yang ditambahkan ke dalam *cell state*. Proses ini melibatkan fungsi aktivasi sigmoid untuk menentukan informasi yang diperbarui, serta fungsi aktivasi *tanh* yang menghasilkan nilai kandidat baru yang dikombinasikan dengan *cell state*. Rumus *input gate* dinyatakan pada Persamaan (2.13) sebagai berikut (Rowan *et al.*, 2022):

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.13)$$

Keterangan:

| | | |
|-----------|---|---|
| i_t | : | <i>input gate</i> dalam <i>timestep</i> t |
| σ | : | fungsi sigmoid |
| W_i | : | nilai bobot untuk <i>input gate</i> |
| h_{t-1} | : | nilai <i>output</i> dalam <i>timestep</i> $t - 1$ |
| x_t | : | nilai <i>input</i> dalam <i>timestep</i> t |
| b_i | : | nilai bias <i>input gate</i> |

Pada *input gate* dilakukan perhitungan nilai kandidat *cell state* baru (\hat{c}_t) yang melibatkan penggunaan fungsi aktivasi *tanh*. Fungsi *tanh* ini memastikan bahwa nilai kandidat berada dalam rentang -1 hingga 1 , yang memungkinkan model untuk lebih efektif dalam menangani informasi yang diperbarui. Rumusnya dapat diuraikan pada Persamaan (2.14) sebagai berikut (Rowan *et al.*, 2022):

$$\hat{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (2.14)$$

Keterangan:

| | | |
|-------------|---|--|
| \hat{c}_t | : | nilai baru yang ditambahkan pada <i>cell state</i> |
| \tanh | : | fungsi <i>tanh</i> |

| | | |
|-----------|---|---|
| W_c | : | nilai bobot untuk <i>cell state</i> |
| h_{t-1} | : | nilai <i>output</i> dalam <i>timestep</i> $t - 1$ |
| x_t | : | nilai <i>input</i> dalam <i>timestep</i> t |
| b_c | : | nilai bias <i>cell state</i> |

Selanjutnya, mencari nilai *cell state* baru (c_t) dengan memperbarui nilai *cell state* lama (c_{t-1}) menggunakan Persamaan (2.15) sebagai berikut (Rowan *et al.*, 2022):

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \hat{c}_t \quad (2.15)$$

Keterangan:

| | | |
|-------------|---|---|
| c_t | : | nilai <i>cell state</i> baru |
| f_t | : | <i>forget gate</i> dalam <i>timestep</i> t |
| c_{t-1} | : | nilai <i>cell state</i> dalam <i>timestep</i> $t - 1$ |
| i_t | : | nilai <i>input gate</i> dalam <i>timestep</i> t |
| \hat{c}_t | : | nilai baru yang ditambahkan pada <i>cell state</i> |

3. Output Gate

Output gate mengatur informasi mana yang digunakan sebagai *output* pada *hidden state* selanjutnya. *Output gate* juga menggunakan fungsi aktivasi sigmoid yang mengolah *input* dan *hidden state* sebelumnya, kemudian menghasilkan *hidden state* baru yang digunakan untuk prediksi. Rumusnya dapat dinyatakan pada Persamaan (2.16) sebagai berikut (Rowan *et al.*, 2022):

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.16)$$

Keterangan:

| | | |
|-----------|---|---|
| o_t | : | <i>output gate</i> dalam <i>timestep</i> t |
| σ | : | fungsi sigmoid |
| W_o | : | nilai bobot untuk <i>output gate</i> |
| h_{t-1} | : | nilai <i>output</i> dalam <i>timestep</i> $t - 1$ |
| x_t | : | nilai <i>input</i> dalam <i>timestep</i> t |
| b_o | : | nilai bias <i>output gate</i> |

Nilai *hidden state* (h_t) diperoleh dengan mengalikan *output* dari sigmoid dan *tanh* menggunakan fungsi *tanh*, seperti pada Persamaan (2.17) berikut ini:

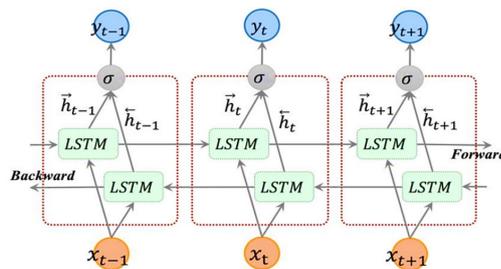
$$h_t = o_t \cdot \tanh(c_t) \quad (2.17)$$

Keterangan:

- h_t : nilai *output* dalam *timestep* t
- o_t : nilai *output gate*
- \tanh : fungsi *tanh*
- c_t : nilai *cell state*

2.10 Bidirectional Long Short-Term Memory (BiLSTM)

Bidirectional Long Short-Term Memory adalah pengembangan dari model LSTM yang mampu memproses data urutan dalam dua arah, yaitu maju (*forward*) dan mundur (*backward*). Pada model BiLSTM, dua jaringan LSTM bekerja secara paralel, salah satu jaringan memproses data dari awal hingga akhir (*forward*), sedangkan jaringan lain memproses data dari akhir ke awal (*backward*). *Output* dari kedua jaringan tersebut digabungkan untuk memberikan informasi yang lebih kaya, memungkinkan model untuk memahami konteks dari kedua arah (Chen *et al.*, 2024). Hal ini memungkinkan model BiLSTM untuk menangkap informasi yang relevan baik dari masa lalu maupun masa depan, sehingga meningkatkan akurasi prediksi pada tugas yang melibatkan data sekuensial. Arsitektur model BiLSTM dapat ditunjukkan pada gambar berikut ini:



Gambar 2. Arsitektur BiLSTM (Cui *et al.*, 2020).

Gambar 2, menunjukkan bahwa *output* dihasilkan dengan menggabungkan lapisan tersembunyi dari kedua arah, yaitu *forward* dan *backward* sesuai dengan perhitungan yang dijelaskan dalam Persamaan (2.18), (2.19) dan (2.20) berikut ini (Roy & Cheung, 2018):

$$\vec{h}_t = H(W_{x\vec{h}} \vec{x}_t + W_{\vec{h}\overleftarrow{h}} \overleftarrow{h}_{t+1} + b_{\vec{h}}) \quad (2.18)$$

$$\overleftarrow{h}_t = H \left(W_{x\overleftarrow{h}} X_t + W_{\overleftarrow{h}\overleftarrow{h}} \overleftarrow{h}_{t+1} + b_{\overleftarrow{h}} \right) \quad (2.19)$$

$$y_t = W_{\overrightarrow{h}y} \overrightarrow{h}_t + W_{\overleftarrow{h}y} \overleftarrow{h}_t + b_y \quad (2.20)$$

Keterangan:

| | | |
|---------------------------|---|--|
| y_t | : | <i>Output gate</i> BiLSTM |
| $W_{\overrightarrow{h}y}$ | : | Nilai bobot untuk <i>output gate</i> pada LSTM <i>forward</i> |
| \overrightarrow{h}_t | : | Nilai <i>output</i> pada LSTM <i>forward</i> |
| $W_{\overleftarrow{h}y}$ | : | Nilai bobot untuk <i>output gate</i> pada LSTM <i>backward</i> |
| \overleftarrow{h}_t | : | Nilai <i>output</i> pada LSTM <i>backward</i> |

2.11 Fungsi Aktivasi

Fungsi aktivasi adalah elemen penting dalam jaringan saraf yang digunakan untuk memodelkan hubungan *non-linear* antara masukan dan keluaran. Fungsi ini menentukan bagaimana neuron merespon *input* yang diterimanya dan juga berperan dalam mentransmisikan sinyal ke neuron lain dalam jaringan. Fungsi aktivasi diterapkan pada *output* setiap neuron di lapisan tertentu dan bertindak sebagai reseptor, menunggu stimulasi dan memberikan respon yang sesuai, sehingga mengubah nilai *input* menjadi *output* dalam rentang tertentu (Pasaribu *et al.*, 2020). Beberapa jenis fungsi aktivasi yang umum digunakan meliputi:

1. Fungsi Aktivasi Sigmoid

Menurut Pasaribu *et al.* (2020), sigmoid merupakan salah satu fungsi aktivasi yang umum diterapkan dalam jaringan saraf tiruan dan model statistik. Pada fungsi sigmoid, *output* mendekati 0 ketika *input* mengecil, dan mendekati 1 saat *input* membesar. Rumus untuk fungsi sigmoid dapat dituliskan pada Persamaan (2.21) sebagai berikut:

$$f(z) = \frac{1}{1 + e^{-z}} \quad (2.21)$$

Keterangan:

| | | |
|-----|---|----------------|
| z | : | data |
| e | : | bilangan Euler |

2. Fungsi Aktivasi *tanh*

Menurut Pasaribu *et al.* (2020), Fungsi aktivasi *tanh* adalah salah satu fungsi yang juga digunakan dalam jaringan saraf tiruan dan model statistik. Fungsi *tanh* mirip dengan sigmoid, tetapi perbedaannya adalah bahwa nilai *input* dan *output*

berada dalam rentang -1 hingga 1. Semakin besar nilai *input*, semakin dekat *output* menjadi 1, sementara semakin kecil *input*, *output* mendekati -1. Rumus untuk fungsi *tanh* dapat dituliskan pada Persamaan (2.22) sebagai berikut:

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (2.22)$$

Keterangan:

z : data
 e : bilangan Euler

2.12 *Scaling Data*

Scaling data (Normalisasi data) adalah teknik untuk mengubah nilai numerik dalam data menjadi skala seragam, memudahkan analisis dan pengolahan. Proses ini mengurangi kesalahan dan memastikan semua fitur berkontribusi secara adil dalam model, serta mencegah penyimpangan dan ketidakonsistenan, terutama dengan variabel berskala berbeda (Han *et al.*, 2012). Teknik yang umum digunakan dalam normalisasi data (Han *et al.*, 2012):

1. *MinMaxScaler* adalah teknik normalisasi yang mengubah nilai dalam data ke rentang tertentu, biasanya antara 0 dan 1. Teknik ini penting dalam *preprocessing* data, terutama ketika model yang digunakan sensitif terhadap skala fitur (Han *et al.*, 2012). Secara umum teknik normalisasi data menggunakan Persamaan (2.23) sebagai berikut:

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (2.23)$$

Keterangan:

X' : data hasil yang dinormalisasikan
 X : data yang dinormalisasikan
 X_{\min} : nilai minimum dari seluruh data X
 X_{\max} : nilai maksimum dari seluruh data X

2.13 *Unscaling Data*

Unscaling adalah proses yang bertujuan untuk mengembalikan hasil *output* dari proses prediksi yang sebelumnya telah dinormalisasi ke dalam bentuk aslinya agar mendapatkan nilai yang diharapkan serta mengevaluasi dari model hasil evaluasi (Tasyurek, 2022). Rumusnya dapat dinyatakan pada Persamaan (2.24) sebagai berikut:

$$x_i = x' \cdot (x_{\max} - x_{\min}) + x_{\min} \quad (2.24)$$

Keterangan:

| | | |
|------------|---|-------------------------------|
| x_i | : | hasil denormalisasi |
| x' | : | data yang dinormalisasi |
| x_{\max} | : | nilai maksimum dari data asli |
| x_{\min} | : | nilai minimum dari data asli |

2.14 *Hyperparameter*

Hyperparameter adalah variabel konfigurasi di luar model dan memiliki nilai yang ditentukan sebelum proses pelatihan model dimulai. Berbeda dengan parameter model yang dipelajari selama pelatihan, *hyperparameter* tidak dioptimalkan secara otomatis oleh algoritma sehingga nilainya sulit diperkirakan dari kumpulan data (Bergstra & Bengio, 2012). Pemilihan *hyperparameter* dalam konteks peramalan menjadi sangat penting karena dapat mempengaruhi akurasi dan efektivitas model dalam memprediksi nilai di masa depan. Apabila pemilihan *hyperparameter* yang buruk, maka menghasilkan model yang kurang efektif. Menurut Bergstra & Bengio (2012), alasan menerapkan *hyperparameter* dalam *deep learning* mencakup beberapa poin penting:

1. Dampak signifikan pada kinerja model, karena *hyperparameter* dapat mempengaruhi kinerja model. Pemilihan yang tepat dapat meningkatkan akurasi dan kemampuan generalisasi model terhadap data yang tidak terlihat.
2. Pencarian ruang konfigurasi yang efisien, metode seperti *grid search* memungkinkan eksplorasi ruang *hyperparameter* yang lebih luas. Sehingga mampu menemukan kombinasi *hyperparameter* yang lebih baik dalam waktu yang lebih singkat.
3. Adaptasi terhadap data berbeda, *hyperparameter* memungkinkan penyesuaian model yang lebih baik terhadap karakteristik data yang berbeda. Hal ini dapat

meningkatkan fleksibilitas model dan kemampuannya untuk beradaptasi dengan berbagai jenis data.

Ketiga poin tersebut menunjukkan bahwa *hyperparameter* tidak hanya berfungsi sebagai parameter teknis dalam model, tetapi juga sebagai faktor kunci yang dapat mempengaruhi kinerja model *deep learning*.

2.15 Hybrid VARIMA-BiLSTM

Model *hybrid* adalah pendekatan yang menggabungkan dua atau lebih teknik untuk meningkatkan akurasi dan efisiensi dalam analisis data. Pendekatan ini sering kali memadukan metode statistik klasik dengan *machine learning*, memungkinkan pemodelan yang lebih baik terhadap pola data. *Hybrid VARIMA-BiLSTM* mengintegrasikan model VARIMA, yang efektif untuk menangkap pola linier, dengan BiLSTM, yang mampu menangani pola temporal kompleks dan *non*-linier. Model VARIMA menganalisis komponen linier dari data, sedangkan model BiLSTM mengeksplorasi hubungan jangka panjang dalam data. Penggunaan kombinasi ini mampu memberikan prediksi yang lebih akurat dibandingkan penggunaan metode tunggal.

Penerapan model *hybrid* bertujuan untuk meningkatkan efisiensi dalam analisis peramalan deret waktu (Zhang, 2003). Pada analisis deret waktu, seringkali sulit untuk menentukan apakah data mengikuti pola linier atau tidak linier. Oleh karena itu, banyak penelitian menggunakan lebih dari satu model analisis untuk perbandingan. Secara umum, kombinasi dari model deret waktu yang mencakup struktur autokorelasi linier dan tidak linier dapat dinyatakan dalam Persamaan (2.25) berikut:

$$y_t = L_t + N_t + a_t \quad (2.25)$$

Keterangan:

- y_t : data pengamatan deret waktu ke- t
- L_t : komposisi linear ke- t
- N_t : komponen tidak linear ke- t
- a_t : error

Pada penerapan model *hybrid* VARIMA-BiLSTM untuk peramalan, terdapat dua komponen utama dalam persamaan sebelumnya. Pertama, komponen linier melalui penggunaan model VARIMA untuk meramalkan data. Kedua, pola tidak linier dalam data diidentifikasi dengan membangun model BiLSTM. Proses pengembangan model ini terdiri dari beberapa langkah:

1. Langkah pertama adalah membangun model VARIMA menggunakan data aktual untuk memperkirakan elemen linier.
2. Kemudian, model BiLSTM dikembangkan untuk menghasilkan prediksi serta residual dari model VARIMA, digunakan untuk memperkirakan elemen tidak linier.
3. Terakhir, kedua model ini digabungkan untuk melakukan prediksi dan analisis lebih lanjut.

Sehingga, persamaan peramalan *hybrid* VARIMA-BiLSTM dapat dinyatakan pada Persamaan (2.26) sebagai berikut:

$$Y'_t = L'_t + N'_t \quad (2.26)$$

Keterangan:

- Y'_t : prediksi dari model *hybrid* ke- t
 L'_t : prediksi komponen linear dari model VARIMA ke- t
 N'_t : prediksi komponen residual dari model BiLSTM ke- t
 t : indeks waktu

2.16 Evaluasi Model

Evaluasi model bertujuan untuk menilai apakah model yang diterapkan efektif dalam mengolah data. Proses evaluasi ini untuk mengukur akurasi model dalam memprediksi data yang diketahui. Penentuan tingkat ketepatan model dapat dilakukan melalui beberapa metode evaluasi, antara lain RMSE, MAPE. Metode-metode ini membantu dalam memahami kinerja model dan memperbaiki strategi pemodelan yang digunakan.

2.16.1 Root Mean Square Error (RMSE)

Root mean square error adalah ukuran untuk menilai seberapa baik model prediktif dapat memperkirakan nilai aktual. Menurut Hafezi *et al.* (2018), RMSE adalah salah satu ukuran evaluasi yang umum digunakan dalam peramalan dan pemodelan. Nilai RMSE yang lebih kecil menunjukkan model yang lebih baik. RMSE dihitung menggunakan rumus yang dapat dinyatakan pada Persamaan (2.27) sebagai berikut:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (2.27)$$

Keterangan:

- y_t : nilai aktual
- \hat{y}_t : nilai yang diprediksi
- n : jumlah total pengamatan

2.16.2 Mean Absolute Percentage Error (MAPE)

Mean absolute percentage error adalah metode evaluasi yang mengukur ketepatan prediksi dalam bentuk persentase. Menurut Tiwari *et al.* (2021), MAPE sangat berguna dalam analisis peramalan, terutama ketika membandingkan model dengan data yang berbeda. Jika MAPE berada di bawah 10% dikatakan sangat baik, jika berada pada rentan 10% hingga 20% dikatakan baik, dan jika berada di atas 20% dikatakan kurang baik. Rumusnya dapat dinyatakan pada Persamaan (2.28) sebagai berikut:

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100 \quad (2.28)$$

Keterangan:

- y_t : nilai aktual
- \hat{y}_t : nilai yang diprediksi
- n : jumlah total pengamatan

2.17 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 nilai *Kolmogorov-Smirnov* yang menunjukkan jarak maksimum antara dua distribusi, yaitu data peramalan dan data *update* (Kolmogorov, 1933). Semakin kecil jarak tersebut, semakin baik model menangkap pola data. Nilai *Kolmogorov-Smirnov* dapat dinyatakan dalam Persamaan (2.29) sebagai berikut:

$$KS = \max_x |F_n(x) - F(x)| \quad (2.29)$$

Keterangan:

- KS : statistik uji *Kolmogorov-Smirnov*
- $F_n(x)$: fungsi distribusi kumulatif empiris
- $F(x)$: fungsi distribusi kumulatif teoritis
- \max_x : maksimum dari perbedaan antara distribusi

BAB III

METODE PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilaksanakan dengan pendekatan studi pustaka pada semester ganjil tahun ajaran 2024/2025, terdiri dari tiga tahapan dengan jadwal yang sudah ditetapkan untuk setiap tahap. Tahap pertama, melakukan studi literatur, pemilihan topik penelitian, pengumpulan data, penyusunan Bab 1-3, serta seminar proposal (Agustus 2024 hingga Februari 2025). Tahap kedua, melakukan analisis data, pengolahan awal data (*preprocessing*), pemodelan VARIMA, penyesuaian *hyperparameter* pada model BiLSTM, serta integrasi model *hybrid* VARIMA-BiLSTM (Agustus 2024 hingga Maret 2025). Tahap ketiga, melakukan penyusunan Bab 4-5, seminar hasil penelitian, dan sidang komprehensif (Januari hingga Juni 2025).

Penelitian ini dilakukan di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung, Jalan Prof. Dr. Soemantri Brojonegoro No. 1, Gedong Meneng, Bandar Lampung.

3.2 Data Penelitian

Data penelitian menggunakan data harian harga saham PT. Bank Rakyat Indonesia, Tbk (BBRI.JK) dan PT. Bank Negara Indonesia, Tbk (BBNI.JK) yang berasal dari situs <https://finance.yahoo.com/quote/BBRI.JK/history/> dan <https://finance.yahoo.com/quote/BBNI.JK/history/>. Data harga saham *adj close* yang digunakan mencakup periode Januari 2017 hingga November 2024 dengan masing-masing berjumlah 1962 data.

Tabel 2. Data Penelitian

| Date | BBRI.JK | BBNI.JK |
|------------|-----------|-----------|
| 03/01/2017 | 1448.6853 | 2000.5782 |
| 04/01/2017 | 1485.2067 | 2046.2536 |
| 05/01/2017 | 1473.0328 | 2055.3884 |
| 06/01/2017 | 1473.0328 | 2046.2536 |
| 09/01/2017 | 1430.4246 | 2027.9835 |
| ⋮ | ⋮ | ⋮ |
| 26/11/2024 | 4025.0222 | 4543.0585 |

Tabel 2. menunjukkan data historis harga saham menggunakan *adj close* untuk saham BBRI.JK dan BBNI.JK pada periode 3 Januari 2017 hingga 26 November 2024. Data ini digunakan sebagai analisis dasar dalam melakukan peramalan harga saham pada penelitian yang dilakukan.

3.3 Alat Penelitian

Penelitian ini dilaksanakan dengan berbagai alat penunjang yang mendukung penelitian secara efektif dan efisien. Alat yang digunakan meliputi:

1. Perangkat Keras (*Hardware*)

(a) Laptop Asus

- *Processor: Intel(R) Core(TM) i3-1005g1 CPU @ 1.20GHz (4 CPUs), 1.2GHz.*
- *RAM: 8.00 GB.*

2. Perangkat Lunak (*Software*)

(a) *Google Colaboratory.*

(b) *Sistem Operasi : Windows 11 Home Single Language 64-bit.*

(c) *Library yang digunakan:*

- *Scikit-Learn (1.3.0) : Membagi data dan evaluasi model.*
- *Pandas (2.2.2) : Memahami struktur dan isi data.*
- *NumPy (1.26.4) : Melakukan operasi numerik.*
- *TensorFlow (2.12.0) : Membangun model BiLSTM.*
- *Matplotlib (3.7.1) : Melakukan visualisasi hasil.*

- *Seaborn* (0.13.2) : Visualisasi data.
- *Statsmodels* (0.14.4) : Evaluasi model VARIMA.
- *Pmdarima* (2.0.4) : Melakukan optimasi model VARIMA.

3.4 Metode Penelitian

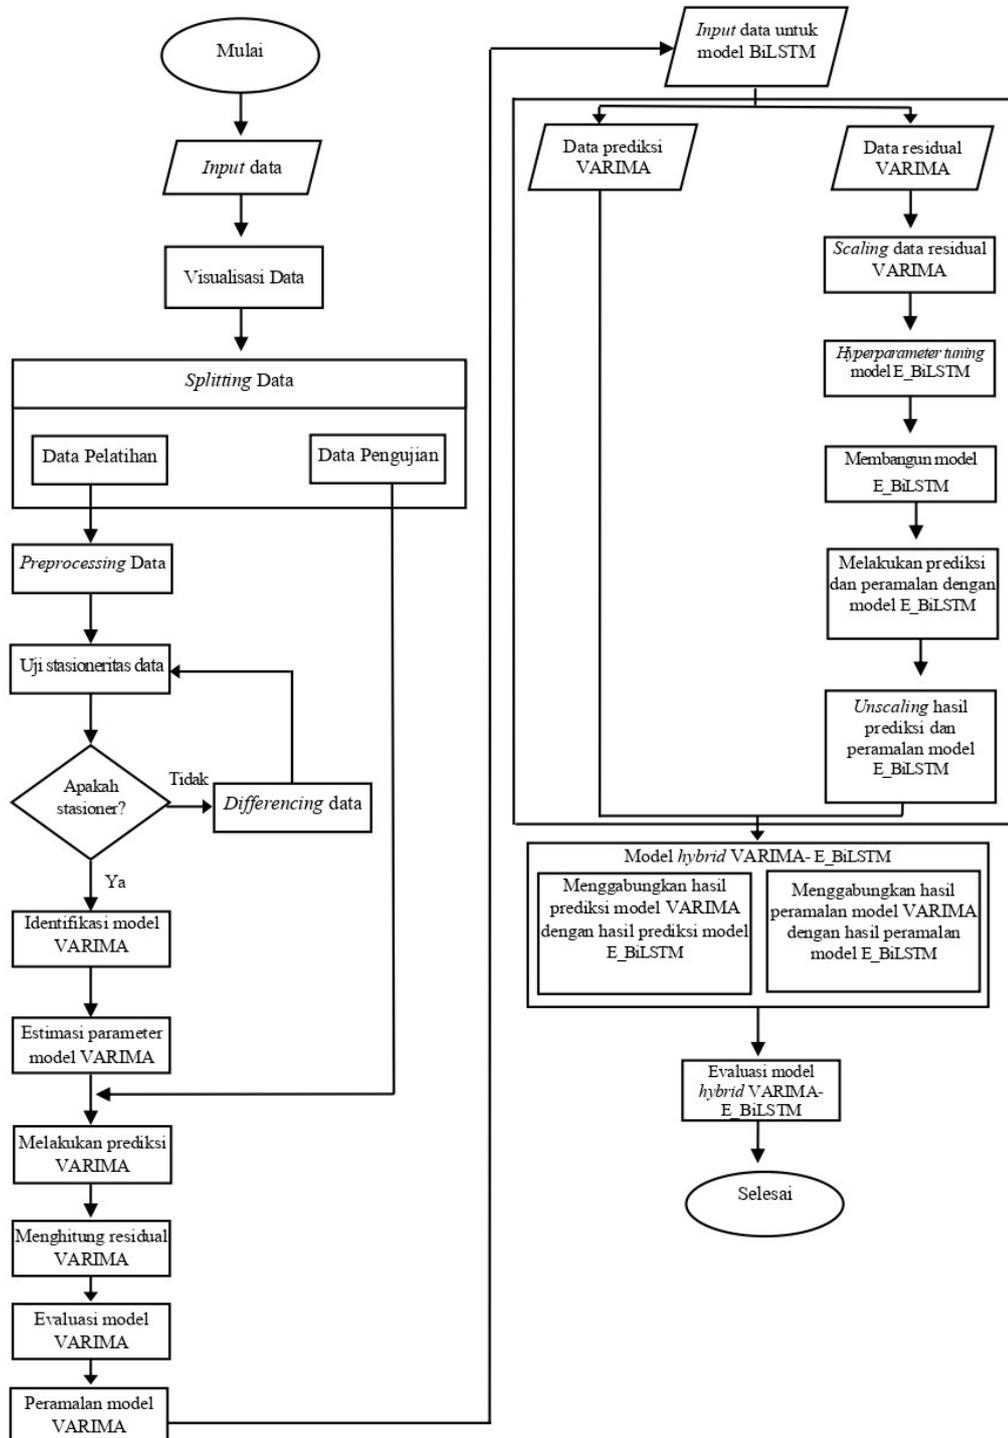
Penelitian ini mengandalkan studi literatur yang dikumpulkan secara sistematis dari berbagai sumber seperti buku, artikel jurnal, dan internet untuk mendapatkan informasi yang luas. Proses penelitian untuk melakukan peramalan menggunakan model *hybrid* VARIMA–E_BiLSTM dan model *hybrid* VARIMA–EP_BiLSTM dapat dijelaskan sebagai berikut:

1. Melakukan studi literatur terkait model *hybrid* melalui artikel, jurnal, dan buku yang digunakan sebagai sumber referensi.
2. Mencari data historis harga saham PT. Bank Negara Indonesia dan PT. Bank Rakyat Indonesia, kemudian mengumpulkan kedua data tersebut.
3. Memasukkan (*input*) data historis harga saham PT. Bank Negara Indonesia dan PT. Bank Rakyat Indonesia ke dalam *google colab*.
4. Melakukan visualisasi pada data asli untuk mengetahui tren dan pola pada data.
5. Membagi (*splitting*) data terhadap data historis harga saham yang dikumpulkan menjadi 80% data *training* dan 20% data *testing*. Pembagian data tersebut dipilih agar model dapat belajar optimal dari data *training* dengan jumlah informasi yang cukup, sementara data *testing* digunakan untuk mengevaluasi kinerja model.
6. Melaksanakan *preprocessing* data dengan melakukan pengecekan terhadap *missing value* untuk mengidentifikasi data yang hilang, serta menganalisis korelasi untuk memahami hubungan antar variabel.
7. Menguji stasioneritas pada data pelatihan menggunakan uji *Dickey-Fuller test*. Jika data tidak stasioner, maka dilakukan *differencing* pada data.
8. Setelah dilakukan *differencing* dan didapatkan hasil bahwa data stasioner, maka proses selanjutnya dilakukan pengidentifikasian model VARIMA menggunakan plot ACF dan PACF.
9. Mengestimasi parameter model VARIMA yang terbentuk dari identifikasi model dengan menganalisis plot ACF dan PACF, tujuannya adalah untuk menentukan model terbaik yang digunakan untuk prediksi dan peramalan. Model terbaik

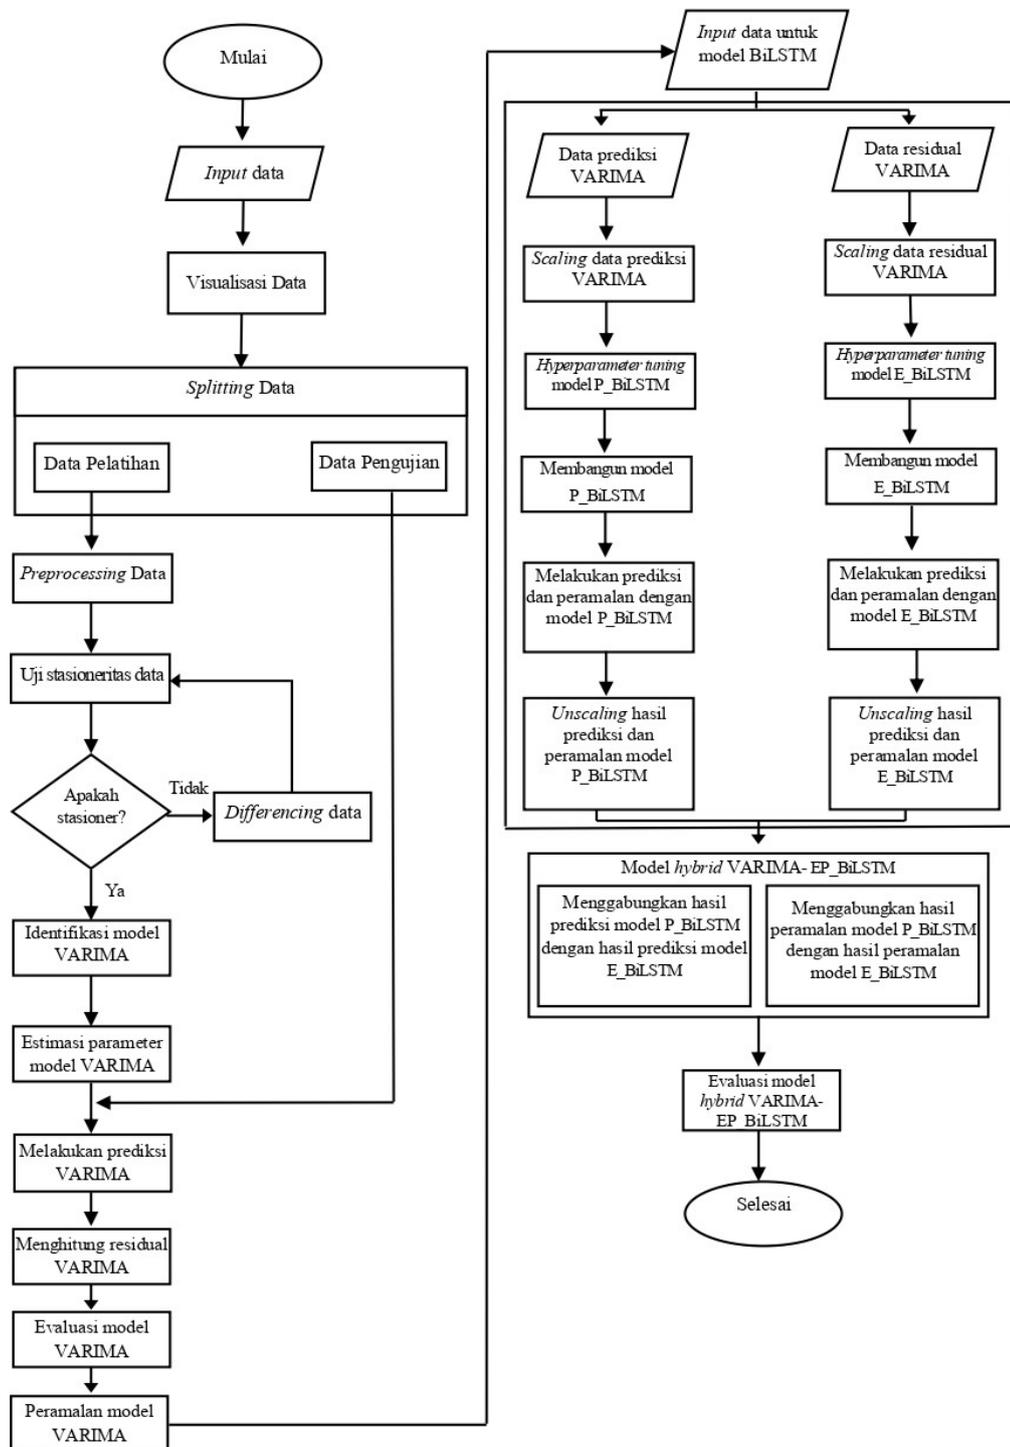
dipilih berdasarkan BIC, karena BIC memberikan pinalti lebih besar untuk model yang lebih rumit, mendorong agar model tetap sederhana dan mengurangi risiko *overfitting*. Sedangkan AIC lebih memperhatikan seberapa baik model cocok dengan data, tanpa memikirkan seberapa rumit model tersebut. Hal ini bisa membuat model terlalu mengikuti data pelatihan, yang disebut *overfitting*.

10. Melakukan prediksi data *testing* menggunakan model VARIMA terbaik yang ditentukan pada proses estimasi parameter.
11. Menghitung nilai residual dari model VARIMA terbaik.
12. Mengevaluasi model VARIMA menggunakan RMSE, MAPE, dan akurasi.
13. Meramalkan data *testing* menggunakan model VARIMA terbaik.
14. Melakukan *input* data prediksi dan residual yang diperoleh sebelumnya untuk diolah menggunakan BiLSTM. Model E_BiLSTM menggunakan data residual model VARIMA sebagai *input*, sedangkan P_BiLSTM menggunakan data prediksi model VARIMA sebagai *input*.
15. Melakukan *scaling* data prediksi dan residual VARIMA dengan menggunakan *MinMaxScaler*.
16. *Hyperparameter tuning* dilakukan menggunakan metode *grid search* untuk menentukan parameter terbaik yang digunakan dalam model E_BiLSTM dan model P_BiLSTM.
17. Membangun model E_BiLSTM dan model P_BiLSTM dengan menggunakan parameter terbaik dari *hyperparameter tuning*.
18. Melakukan prediksi dan peramalan pada model E_BiLSTM dan model P_BiLSTM.
19. Melakukan *unscaling* data, dimana dilakukan pengembalian data prediksi dan peramalan ke bentuk semula. Tujuannya adalah untuk membandingkan data asli dengan data hasil prediksi dan peramalan pada model E_BiLSTM dan model P_BiLSTM.
20. Menggabungkan hasil prediksi dan peramalan untuk model *hybrid* pada data prediksi model VARIMA dan model E_BiLSTM melalui proses penjumlahan yang disebut dengan model *hybrid* VARIMA–E_BiLSTM.
21. Menggabungkan hasil prediksi dan peramalan untuk model *hybrid* pada model E_BiLSTM dan model P_BiLSTM melalui proses penjumlahan yang disebut dengan model *hybrid* VARIMA–EP_BiLSTM.
22. Mengevaluasi model *hybrid* VARIMA–E_BiLSTM dan model *hybrid* VARIMA–EP_BiLSTM yang dievaluasi menggunakan akurasi, MAPE dan RMSE.

Berikut ini merupakan diagram alir peramalan menggunakan model *hybrid*:



Gambar 3. Flowchart Model Hybrid VARIMA–E_BiLSTM



Gambar 4. Flowchart Model Hybrid VARIMA–EP_BiLSTM

BAB V

KESIMPULAN

5.1 Kesimpulan

Berdasarkan hasil yang diperoleh dari analisis yang dilakukan mengenai penelitian harga saham *adj close* PT. Bank Negara Indonesia, Tbk dan PT. Bank Rakyat Indonesia, Tbk. menggunakan model *hybrid* VARIMA-BiLSTM, telah diperoleh beberapa kesimpulan sebagai berikut:

1. Model VARIMA, model *hybrid* VARIMA–E_BiLSTM dan model *hybrid* VARIMA–EP_BiLSTM memiliki pengembangan model masing-masing, seperti model VARIMA yang dikembangkan menggunakan estimasi parameter terbaik dengan melihat plot ACF dan PACF sedangkan model *hybrid* dikembangkan dengan mengintegrasikan dua model. Model VARIMA–E_BiLSTM dikembangkan dengan data *input* prediksi model VARIMA (1,1,1) dan model E_BiLSTM yang memanfaatkan data *input* residual model VARIMA (1,1,1). Sedangkan Model VARIMA–EP_BiLSTM dikembangkan dengan model E_BiLSTM yang memanfaatkan data *input* residual model VARIMA (1,1,1) dan model P_BiLSTM yang memanfaatkan data *input* prediksi model VARIMA (1,1,1). Model ini dibangun dengan menerapkan kombinasi parameter optimal, meliputi jumlah BiLSTM *unit*, *dense unit*, *batch size* yang diperoleh melalui proses *hyperparameter tuning*. Rincian konfigurasi terbaik yang digunakan dalam membangun model adalah sebagai berikut :
 - a. Pemodelan VARIMA menggunakan estimasi parameter terbaik dengan melihat plot ACF dan PACF, sehingga mendapatkan estimasi parameter terbaik berdasarkan nilai BIC adalah model VARIMA (1,1,1).
 - b. Pemodelan *hybrid* VARIMA–E_BiLSTM yang memanfaatkan data *input* residual model VARIMA (1,1,1) dengan rincian parameter terbaik yang diperoleh adalah 64 BiLSTM *unit*, 64 *dense unit* dan 32 *batch size*, serta 0.2 *dropout*.

- c. Pemodelan *hybrid* VARIMA–EP_BiLSTM yang memanfaatkan data *input* prediksi model VARIMA (1,1,1) dengan rincian parameter terbaik yang diperoleh adalah 64 BiLSTM *unit*, 128 *dense unit* dan 8 *batch size*.
2. Peramalan harga saham *adj close* PT. Bank Rakyat Indonesia dan PT. Bank Negara Indonesia untuk 1 bulan ke depan telah dilakukan menggunakan model VARIMA, model *hybrid* VARIMA–E_BiLSTM dan model *hybrid* VARIMA–EP_BiLSTM. Jika diketahui berdasarkan visualisasi hasil peramalan dari ketiga model, yaitu visualisasi peramalan model VARIMA, model *hybrid* VARIMA–E_BiLSTM dan model *hybrid* VARIMA–EP_BiLSTM yang memiliki perbedaan visualisasi antar model. Model VARIMA menghasilkan evaluasi yang sangat baik tetapi memiliki visualisasi peramalan yang cenderung kurang responsif terhadap fluktuasi pola data *update*, sehingga pola yang dihasilkan cenderung konstan. Kemudian, visualisasi peramalan model *hybrid* VARIMA–E_BiLSTM tidak mampu mengikuti pola data *update* dan tren pergerakan harga saham karena pola yang dihasilkan cenderung stabil atau konstan, namun tetap mempertahankan hasil evaluasi yang cukup baik. Selanjutnya, visualisasi peramalan model *hybrid* VARIMA–EP_BiLSTM memiliki pola yang mengikuti pola data *update* dan tren pergerakan harga saham, serta tetap mempertahankan hasil evaluasi yang optimal. Oleh karena itu, dapat dikatakan bahwa model terbaik berdasarkan visualisasi peramalan adalah model *hybrid* VARIMA–EP_BiLSTM karena mampu menangkap fluktuasi dan tren yang sesuai dengan data *update*.
3. Perbandingan kinerja model VARIMA, model *hybrid* VARIMA–E_BiLSTM, dan model *hybrid* VARIMA–EP_BiLSTM dapat dilihat berdasarkan peramalan masing-masing model ketika dilakukan uji kesesuaian model (*goodness of fit*) terhadap data *update* saham BBRI.JK dan BBNI.JK. Hasil pengujian tersebut menunjukkan bahwa model *hybrid* VARIMA–EP_BiLSTM merupakan model terbaik dibandingkan dengan model-model lainnya. Hal ini ditunjukkan oleh nilai uji *Kolmogorov-Smirnov* (KS) terkecil, yaitu sebesar 0.5000 untuk saham BBRI.JK dan 0.4000 untuk saham BBNI.JK. Nilai KS yang rendah ini menunjukkan bahwa hasil peramalan *hybrid* VARIMA–EP_BiLSTM paling mendekati data *update*, serta terdapat kesesuaian yang signifikan antara hasil peramalan model *hybrid* VARIMA–EP_BiLSTM dengan data *update*.

DAFTAR PUSTAKA

- Al Haromainy, M. M., Fatchah, C., & Saikhu, A. (2021). Prediksi Data Deret Waktu Multivariat Menggunakan *Echo State Network* dan *Harmony Search*. *Jurnal Ilmiah Teknologi Informasi*. **19**(2): 111–119.
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Hasan, M., Van Essen, B. C., Awwal, A. A. S., & Asari, V. K. (2019). A State-of-the-Art Survey on Deep Learning Theory and Architectures. *Journal of Electronics*. **8**(3): 1–3.
- Bergstra, J., & Bengio, Y. (2012). Random Search for Hyper-Parameter Optimization. *Journal of Machine Learning Research*. **13**: 281–305.
- Caliwag, A. C., & Lim, W. (2019). Hybrid VARIMA and LSTM Method for Lithium-Ion Battery State-of-Charge and Output Voltage Forecasting in Electric Motorcycle Applications. *IEEE Access*. **7**: 59680–59689.
- Chen, M., Qiu, F., Xiong, X., Chang, Z., & Wei, Y. (2024). BILSTM-SimAM: An Improved Algorithm for Short-Term Electric Load Forecasting Based on Multi-Feature. *Energy Reports*. **7**(10): 4059–4072.
- Cui, Z., Ke, R., Pu, Z., & Wang, Y. (2020). Stacked Bidirectional and Unidirectional LSTM Recurrent Neural Network for Forecasting Network-Wide Traffic State with Missing Values. *Transportation Research Part C: Emerging Technologies*. **118**: 1–14.
- Enders, W. (2014). *Applied Econometric Time Series* (4th ed.). New Jersey: Wiley.
- Goodfellow, I., Bengio, Y., & Courville, A. (2018). *Deep Learning*. Cambridge, MA: MIT Press.
- Granger, C. W. J., & Newbold, P. (1986). *Forecasting Economic Time Series* (2nd ed.). New York: Academic Press.

- Graves, A., & Schmidhuber, J. (2005). Framewise Phoneme Classification with Bidirectional Long Short-Term Memory and Other Neural Network Architectures. *Neural Networks*. **18**(5–6): 602–610.
- Hafezi, R., Akhavan, A. N., & Akhavan, R. (2018). Forecasting Gold Price Changes: Application of an Equipped Artificial Neural Network. *Autonomous Journal of Modern Simulation Engineering*. **50**(1): 71–82.
- Han, J. W., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques* (3rd ed.). Waltham: Morgan Kaufmann Publishers.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*. **9**(8): 1735–1780.
- Harvey, A. 2006. Forecasting with Unobserved Components Time Series Models. *Handbook of Economic Forecasting*. **1**(7): 327-412.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2nd ed.). ISBN: 978-0994625920.
- Kolmogorov, A. (1933). Sulla Determinazione Empirica di Una Legge di Distribuzione. *Giornale dell'Istituto Italiano degli Attuari*. **4**: 89–91.
- Makridakis, S., Wheelright, S. C., & Hyndman, R. J. 1983. *Forecasting: Methods and Applications* (2nd ed.). John Wiley & Sons, New York.
- Mirtawati, M., & Saputra, A. (2023). Model Vektor Autoregresi untuk Prakiraan Curah Hujan di Jakarta Timur dan Jakarta Selatan. *Jurnal Matematika Sains*. **1**(1): 19–26.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., Ostrovski, G., Petersen, S., Beattie, C., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., & Hassabis, D. (2015). Human-Level Control Through Deep Reinforcement Learning. *Nature*. **518**: 529–533.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. 2015. *Introduction to Time Series Analysis and Forecasting*. John Wiley & Sons.
- Nilasari, N. K. N., Sudarman, M., & Gunantara, N. (2023). Prediksi Nilai Cryptocurrency dengan Metode BiLSTM dan LSTM. *Jurnal Ilmiah Teknologi Elektro*. **22**(2): 221.

- Nilsen, J. (2022). Understanding Stock Market Volatility: Causes and Implications. *Journal of Financial Markets*. **25**(3): 215–230.
- Nugroho, A. A., & Suwanda. (2022). Pemodelan Multivariate Time Series dengan Vector Autoregressive Integrated Moving Average (VARIMA). *Jurnal Riset Statistika*. **2**(2): 93–102.
- Pasaribu, D. J. M., Kusriani, K., & Sudarmawan, S. 2020. Peningkatan Akurasi Klasifikasi Sentimen Ulasan Makanan Amazon dengan Bidirectional LSTM dan BERT Embedding. *Inspiration: Jurnal Teknologi Informasi dan Komunikasi*. **10**(1): 9–20.
- Pertiwi, A., Dewi, L. F., Toharudin, T., & Ruchjana, B. N. 2021. Penerapan Model Vector Autoregressive Integrated Moving Average (VARIMA) untuk Prakiraan Indeks Harga Saham Gabungan dan Kurs Rupiah terhadap USD. *Pattimura Proceeding: Conference of Science and Technology*. 431–442.
- Pontoh, R. S., Toharudin, T., Ruchjana, B. N., Gumelar, F., Putri, F. A., Agisya, M. N., & Caraka, R. E. 2022. Jakarta Pandemic to Endemic Transition: Forecasting COVID-19 menggunakan NNAR dan LSTM. *Applied Sciences*. **12**: 5771.
- Pramunendar, R. A., Prabowo, D. P., & Megantara, R. A. 2022. Metode Recurrent Neural Network (RNN) dengan Arsitektur LSTM untuk Analisis Sentimen Opini Publik terkait Vaksin COVID-19. *Jurnal Informatika UPGRIS*. **8**(1): 2460–4801/2447–6645.
- Putri, D. I. 2023. Implementasi Long Short Term Memory dan Bidirectional Long Short Term Memory dalam Prediksi Harga Saham Syariah. *Jurnal Ilmiah Matematika, Sains dan Teknologi*. **11**(1): 35–43.
- Rezaldi, D. A., & Sugiman. 2021. Peramalan Metode ARIMA Data Saham PT. Telekomunikasi Indonesia. *PRISMA, Prosiding Seminar Nasional Matematika 4*. 611–620.
- Rowan, M., Muflikhah, L., & Cholissodin, I. 2022. Peramalan Kasus Positif COVID-19 di Jawa Timur menggunakan Metode Hybrid ARIMA–LSTM. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*. **6**(9): 4146–4153.
- Roy, B., & Cheung, H. 2018. A Deep Learning Approach for Intrusion Detection in Internet of Things menggunakan Bi-Directional Long

Short-Term Memory Recurrent Neural Network. *28th International Telecommunication Networks and Applications Conference*, Australia.

Rusyana, A., Tatsara, N., Balqis, R., & Rahmi, S. 2020. Application of Clustering dan VARIMA untuk Rainfall Prediction. *IOP Conference Series: Materials Science and Engineering*. **796**(1).

Tasyurek, M. 2022. A Novel Approach to Improve the Performance of the Database Storing Big Data dengan 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 untuk Short-Term Load Forecast berdasarkan Long Short-Term Memory Network dan Convolutional Neural Network. *Energies*. **11**(12).

Tiwari, D. K., Singh, K. R., & Kumar, V. 2021. MAPE sebagai Alat untuk Perbandingan Model dalam Analisis Peramalan. *Journal of Water and Climate Change*. **15**(3): 1172–1183.

Wang, B., Tan, Z., Sheng, W., Liu, Z., Wu, X., Ma, L., & Li, Z. 2024. Identification of Groundwater Contamination Sources berdasarkan Deep Belief Neural Network. *Water*. **16**(17): 2449.

Wei, W. W. S. 2006. *Time Series Analysis: Univariate and Multivariate Methods (2nd ed.)*. Temple University, New York.

Yin, C., Zhu, Y., Fei, J., & He, X. 2017. A Deep Learning Approach untuk Intrusion Detection menggunakan Recurrent Neural Networks. *IEEE Access*. **5**: 21954–21961.

Zhang, G. P. 2003. Time Series Forecasting menggunakan Hybrid ARIMA dan Neural Network Model. *Neurocomputing*. **50**: 159–175.