

**IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE
INTEGRATED MOVING AVERAGE EXOGENOUS – BIDIRECTIONAL
LONG SHORT-TERM MEMORY (VARIMAX – Bi-LSTM)* DALAM
PERAMALAN HARGA EMAS DAN PERAK**

(Skripsi)

Oleh

MUHAMMAD WAIS ALQORNI



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

ABSTRACT

IMPLEMENTATION OF THE HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE EXOGENOUS – BIDIRECTIONAL LONG SHORT-TERM MEMORY (VARIMAX – Bi-LSTM) METHOD FOR FORECASTING GOLD AND SILVER PRICES

By

MUHAMMAD WAIS ALQORNI

Gold and silver are among the metals that are currently favored as investment options. The prices of gold and silver fluctuate significantly, making the forecasting of future gold and silver prices crucial for assessing their viability as profitable investments. One method that can be used to forecast the prices of gold and silver is the Vector Autoregressive Integrated Moving Average Exogenous (VARIMAX) method. However, VARIMAX still has a weakness due to the assumption of linearity. In reality, the residuals produced have nonlinear components. On the other hand, there is the Bidirectional Long Short-Term Memory (Bi-LSTM) method. The Bi-LSTM method has an advantage over the VARIMAX method, as it can handle nonlinear data. Therefore, this study applies a hybrid VARIMAX – Bi-LSTM method based on the advantages of each method to handle both linear and nonlinear problems. The hybrid VARIMAX – Bi-LSTM method has two main models: the first Bi-LSTM model for predicting and forecasting the VARIMAX prediction data, and the second Bi-LSTM model for predicting and forecasting the VARIMAX residual data. The hybrid model VARIMAX – Bi-LSTM with a splitting dataset into 90% training data and 10% testing data in this study achieved the highest accuracy and resulted in smaller RMSE and MAPE values compared to other splitting dataset schemes.

Keywords: Forecasting, Gold and silver prices, Hybrid VARIMAX – Bi-LSTM

ABSTRAK

IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE EXOGENOUS – BIDIRECTIONAL LONG SHORT-TERM MEMORY* (VARIMAX – Bi-LSTM) DALAM PERAMALAN HARGA EMAS DAN PERAK

Oleh

MUHAMMAD WAIS ALQORNI

Emas dan perak merupakan salah satu logam yang saat ini sedang diminati sebagai opsi investasi. Harga emas dan perak berfluktuasi signifikan, sehingga peramalan harga emas dan perak berjangka sangat penting untuk menilai kelayakannya sebagai investasi yang menguntungkan. Salah satu metode yang dapat digunakan untuk melakukan peramalan terhadap harga emas dan perak yaitu dengan menggunakan metode *Vector Autoregressive Integrated Moving Average Exogenous* (VARIMAX). Namun, VARIMAX masih mempunyai kelemahan, karena asumsi yang disyaratkan linieritas. Padahal, residual yang dihasilkan mempunyai komponen tidak linier. Disisi lain terdapat metode *Bidirectional Long Short-Term Memory* (Bi-LSTM). Metode Bi-LSTM memiliki keunggulan dibandingkan metode VARIMAX, yaitu dapat menangani data tidak linier. Oleh karena itu, penelitian ini menerapkan metode *hybrid VARIMAX – Bi-LSTM* berdasarkan keunggulan masing-masing metode untuk menangani masalah linier dan tidak linier. Metode *hybrid VARIMAX – Bi-LSTM* memiliki 2 model utama yaitu model Bi-LSTM pertama untuk prediksi dan peramalan data prediksi VARIMAX dan model Bi-LSTM kedua untuk melakukan prediksi dan peramalan data residual VARIMAX. Model *hybrid VARIMAX – Bi-LSTM* dengan skema pembagian 90% data pelatihan 10% data pengujian pada penelitian ini menghasilkan tingkat akurasi paling tinggi dan menghasilkan nilai RMSE dan MAPE lebih kecil dibandingkan skema pembagian data lainnya.

Kata kunci: Peramalan, Harga emas dan perak, *Hybrid VARIMAX – Bi-LSTM*

**IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE
INTEGRATED MOVING AVERAGE EXOGENOUS – BIDIRECTIONAL
LONG SHORT-TERM MEMORY (VARIMAX – Bi-LSTM)* DALAM
PERAMALAN HARGA EMAS DAN PERAK**

Oleh
MUHAMMAD WAIS ALQORNI
2017031075

Skripsi

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

Pada

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



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

Judul Skripsi

: **IMPLEMENTASI METODE *HYBRID*
*VECTOR AUTOREGRESSIVE INTEGRATED
MOVING AVERAGE EXOGENOUS
BIDIRECTIONAL LONG SHORT TERM
MEMORY (VARIMAX – Bi-LSTM) DALAM
PERAMALAN HARGA EMAS DAN PERAK***

Nama Mahasiswa

: **Muhammad Wais Alqorni**

Nomor Pokok Mahasiswa

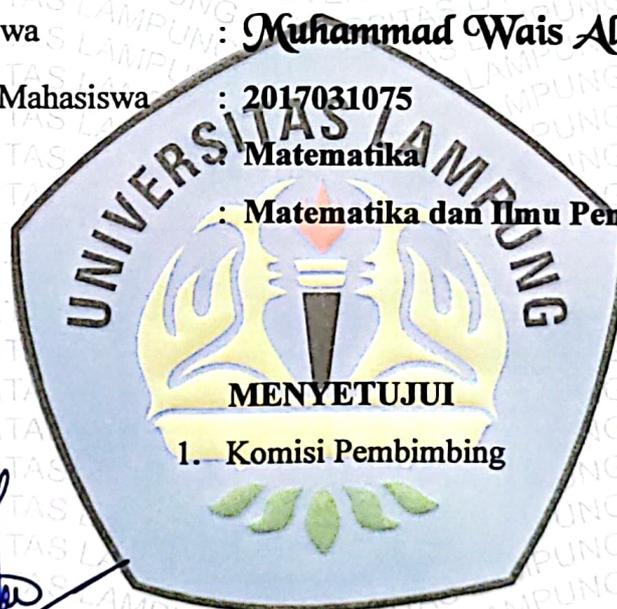
: **2017031075**

Jurusan

: **Matematika**

Fakultas

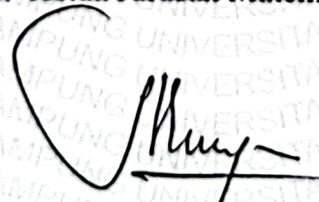
: **Matematika dan Ilmu Pengetahuan Alam**




Dr. Dian Kurniasari, S.Si., M.Sc.
NIP. 19690305 199603 2 001


Ir. Warsono, M.S., Ph.D.
NIP. 19630216 198703 1 003

2. Ketua Jurusan Matematika FMIPA



Dr. Aang Nuryaman, S.Si., M.Si.
NIP. 19740316 200501 100 1

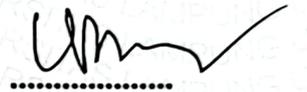
MENGESAHKAN

1. Tim Penguji

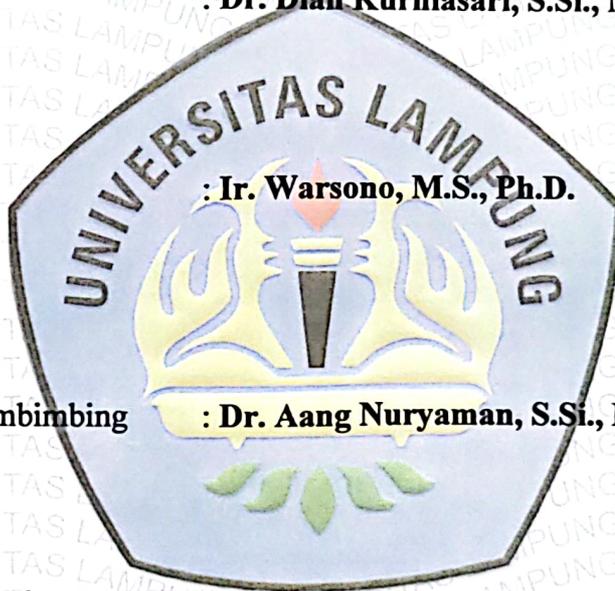
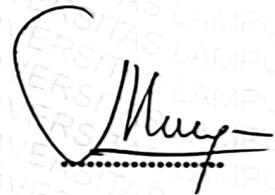
Ketua : Dr. Dian Kurniasari, S.Si., M.Sc.



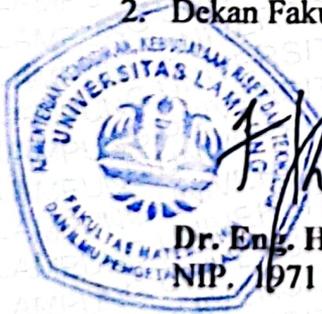
Sekretaris : Ir. Warsono, M.S., Ph.D.



**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. 19711001 200501 1 002**



Tanggal Lulus Ujian Skripsi: 10 Juni 2024

PERNYATAAN SKRIPSI MAHASISWA

Saya yang bertanda tangan di bawah ini:

Nama : **Muhammad Wais Alqorni**
Nomor Pokok Mahasiswa : **2017031075**
Jurusan : **Matematika**
Judul Skripsi : **Implementasi Metode *Hybrid*
Vector Autoregressive Integrated Moving
Average Exogenous – Bidirectional Long Short
Term Memory (VARIMAX – Bi-LSTM) Dalam
Peramalan Harga Emas dan Perak**

Dengan ini menyatakan bahwa apa yang tertulis dalam skripsi ini adalah hasil pekerjaan saya sendiri berdasarkan pengetahuan dan informasi yang saya dapatkan. Skripsi ini tidak berisi materi yang telah dipublikasikan sebelumnya atau dengan kata lain hasil plagiat orang lain.

Demikian pernyataan ini saya buat dan dapat dipertanggungjawabkan. Apabila di kemudian hari terdapat kecurangan dalam karya ilmiah ini, maka saya siap mempertanggungjawabkannya.

Bandar Lampung, 12 Juni 2023

Penulis



Muhammad Wais Alqorni
NPM. 2017031075

RIWAYAT HIDUP

Penulis bernama Muhammad Wais Alqorni, lahir pada hari Senin, 16 September 2002 di Bandar Lampung. Penulis merupakan putra bungsu 3 bersaudara dari Bapak Ir. H. Muhtar Hasan, MM dan Ibu Ir. Hi. Ariana Widyawati, MM.

Penulis pertama kali menempuh pendidikan di Taman Kanak-Kanak Aisyah 1 Labuhan Ratu pada tahun 2006-2008. Kemudian menempuh pendidikan sekolah dasar di SD Muhammadiyah 1 Bandar Lampung pada tahun 2008-2014. Lalu penulis melanjutkan jenjang pendidikannya di SMP Negeri 2 Bandar Lampung pada tahun 2014-2017. Selanjutnya penulis belajar pada jenjang selanjutnya di SMA Negeri 9 Bandar Lampung pada tahun 2017-2020. Pada tahun 2020 penulis terdaftar sebagai mahasiswa Program Studi S1 Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur Seleksi Nasional Berbasis Tes (SNBT).

Selama menjadi mahasiswa, penulis aktif di beberapa kegiatan di antaranya:

1. Pada tahun 2021, penulis menjadi anggota bidang Kaderisasi dan Kepemimpinan di Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) FMIPA Unila.
2. Pada tahun 2022, penulis menjadi Wakil Ketua Umum di Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) FMIPA Unila.
3. Pada bulan Januari – Februari 2023, penulis melaksanakan Praktik Kerja Lapangan di Badan Pengelola Pajak dan Retribusi Daerah (BPPRD) Kota Bandar Lampung dan ditempatkan pada Sub Bagian Umum dan Kepegawaian.

4. Pada bulan Juli 2023, penulis terpilih sebagai salah satu perwakilan mahasiswa dalam proses akreditasi program studi internasional oleh ASIIN.
5. Pada bulan Juli – Agustus 2023, penulis melaksanakan Kuliah Kerja Nyata di Desa Sidoluhur, Kecamatan Bangun Rejo, Kabupaten Lampung Tengah, Provinsi Lampung.
6. Pada bulan Agustus – Desember 2023, penulis melaksanakan kegiatan Magang dan Studi Independen Bersertifikat (MSIB) Angkatan 5 dan diterima pada program Kampus Merdeka Bank Indonesia (KMBI) Angkatan 7. Penulis ditempatkan di Kantor Perwakilan Bank Indonesia Provinsi Lampung dan ditugaskan dalam Tim Fungsi Perumusan Kekda Provinsi (FPKP).

PERSEMBAHAN

Dengan mengucapkan rasa syukur kehadirat Allah SWT yang Maha Kuasa, saya persembahkan karya tulis ini dengan penuh ketulusan dan keikhlasan hati sebagai tanda cinta, sayang dan bakti kepada:

Kedua Orang tuaku, dua orang yang paling berharga bagi hidup saya, Bapak Ir. Hi. Muhtar Hasan, MM dan Ibu Ir. H. Ariana Widyawati, MM. yang telah memberikan kasih sayang, dukungan, motivasi, serta melindungi saya dengan do'a yang selalu dipanjatkan setiap saat hingga langkah saya selalu diringankan dan dimudahkan hingga sataa ini.

Kedua kakakku tercinta yang saya sayangi, Muhammad Azwar Prayogo, S.Tr.Ak. dan Muhammad Dzaky Prasetyo, SH yang senantiasa memanjatkan do'a dan memberikan motivasi serta dukungan hingga sampai di tahap ini.

Keluarga besar Jurusan Matematika FMIPA Unila yang telah menjadi orang tua kedua di kampus yang tidak pernah lelah memberikan ilmu serta bimbingan dengan tulus, ikhlas, dan penuh kasih hingga saya berhasil mencapai gelar sarjana.

Teman-teman yang telah berjuang bersama dari awal sampai akhir dan seterusnya, serta selalu mendukung saya dalam setiap perjalanan hidup.

Almamater tercinta, Universitas Lampung, tempatku memperoleh ilmu dan merancang masa depan untuk mendapatkan kebaikan di dunia dan akhirat.

KATA INSPIRASI

*“Sesungguhnya sholatku, ibadahku, hidup dan matiku hanya untuk Allah SWT
Tuhan Semesta Alam”*

(Q.S. Al-An'am : 162)

*“Sesungguhnya bersama kesulitan itu ada kemudahan, maka apabila kamu
merasa telah selesai (dari suatu urusan), tetaplah bekerja keras (untuk urusan
yang lain)”*

(Q.S. Al-Insyirah : 6 – 7)

“Janganlah kamu berduka cita, sesungguhnya Allah selalu bersama kita”

(Q.S. At-Taubah : 40)

*“Tidak ada mimpi yang gagal, yang ada hanyalah mimpi yang tertunda. Cuman
sekiranya kalau teman-teman merasa gagal dalam mencapai mimpi, jangan
khawatir, mimpi-mimpi lain bisa diciptakan”*

(Windah Basudara)

SANWACANA

Assalamu'alaikum warahmatullahi wabarakatuh,

Puji syukur saya panjatkan kehadirat Allah SWT, atas segala limpahan nikmat, rahmat, hidayah serta pertolongan-Nya yang tak terhingga sehingga skripsi ini dapat diselesaikan.

Skripsi yang berjudul ***“Implementasi Metode Hybrid Vector Autoregressive Integrated Moving Average Exogenous – Bidirectional Long Short Term Memory (VARIMAX – Bi-LSTM) pada Peramalan Harga Emas dan Perak”*** dibuat sebagai bentuk pertanggungjawaban penulis selama menempuh studi S1 dan merupakan salah satu syarat untuk mendapatkan gelar sarjana Matematika (S.Mat) di Universitas Lampung.

Penulis menyadari bahwa selama proses penyusunan skripsi ini tidak luput dari banyak pihak yang telah membantu memberikan bimbingan, dukungan, motivasi, kritik serta saran sehingga skripsi ini dapat terselesaikan. Pada kesempatan ini, penulis ingin mengucapkan rasa hormat dan ucapan terima kasih kepada:

1. Teristimewa untuk kedua orang tua, Bapak Ir. Hi. Muhtar Hasan, MM dan Ibu Ir. H. Ariana Widyawati, MM, kedua kakak tercinta yang senantiasa memberikan dukungan, semangat, motivasi serta do'a yang tulus dan ikhlas sehingga menemani perjalanan hidup penulis hingga saat ini;
2. Ibu Dr. Dian Kurniasari, S.Si., M.Sc., selaku Pembimbing I dan Pembimbing Akademik yang telah ikhlas memberikan waktu dan tenaganya untuk membimbing dan mengarahkan penulis selama proses akademik dan penyusunan skripsi;

3. Bapak Ir Warsono, M.S., Ph.D., selaku Pembimbing II yang telah bersedia memberikan waktu, arahan, bimbingan, saran serta dukungan kepada penulis selama melaksanakan penelitian dan penyusunan skripsi;
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Pembahas yang telah memberikan masukan, kritik, dan saran kepada penulis demi kesempurnaan dalam penelitian maupun penyusunan skripsi;
5. Seluruh Dosen Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung yang telah memberikan ilmu yang bermanfaat selama di bangku perkuliahan dan mengantarkan penulis mencapai gelar sarjana;
6. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung;
7. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung;
8. Ibu Prof. Dr. Ir. Lusmeilia Afriani, D.E.A., I.P.M., selaku Rektor Universitas Lampung;
9. Almamater tercinta, Universitas Lampung;
10. Claudya Annisa Rahmawati Susanto, terimakasih karena sudah memberikan semangat dan motivasi untuk penulis sehingga bisa menyelesaikan skripsi tepat pada waktunya;
11. Sahabat seperjuangan yang telah menemani penulis sejak bangku SMA (Ali, Muklis, Nopri, Dahlan, dan Wawan) yang selalu menemani dan memberikan dukungan kepada penulis;
12. Teman-teman seperjuangan skripsi (Muhtarom, Arif, Yazid, Tama, Ziyad, Harum dan Nanda) yang selalu memberikan dukungan kepada penulis;
13. Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) FMIPA Unila yang telah menjadi tempat untuk berkembang di bidang non akademik bagi penulis;
14. Teman-teman seperjuangan Matematika Angkatan 2020 yang namanya tidak bisa disebutkan satu per satu, terimakasih telah menjadi rekan seperjuangan selama perkuliahan.

Penulis menyadari skripsi ini masih jauh dari kata sempurna dan masih terdapat banyak kekurangan baik dalam penyajian maupun teknik penulisan. Oleh sebab itu, kritik dan saran yang membangun diharapkan dapat menjadi bahan perbaikan bagi penulis. Semoga skripsi ini dapat bermanfaat bagi seluruh pihak tak terkecuali penulis.

Bandar Lampung, 13 Juni 2024

Penulis

Muhammad Wais Alqorni

NPM. 2017031075

DAFTAR ISI

	Halaman
DAFTAR TABEL	xviii
DAFTAR GAMBAR	xxi
I. PENDAHULUAN	1
1.1 Latar Belakang dan Masalah	1
1.2 Rumusan Masalah.....	4
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	5
II. TINJAUAN PUSTAKA	6
2.1 Penelitian Terkait Analisis Deret Waktu	6
2.2 Peramalan	8
2.3 Analisis Deret Waktu.....	9
2.4 Stasioneritas.....	10
2.5 <i>Scaling</i> Data.....	11
2.6 Model <i>Vector Autoregressive</i> (VAR).....	12
2.7 Model <i>Vector Moving Average</i> (VMA).....	13
2.8 Model <i>Vector Autoregressive Moving Average</i> (VARMA).....	14
2.9 Model <i>Vector Autoregressive Integrated Moving Average</i> (VARIMA).....	14
2.10 Model <i>Vector Autoregressive Integrated Moving Average Exogenous</i> (VARIMAX)	15
2.11 Estimasi Parameter Menggunakan Metode <i>Maximum Likelihood</i>	15
2.12 <i>Machine Learning</i>	18
2.13 Fungsi Aktivasi.....	19
2.14 <i>Hyperparameter</i> dan Parameter <i>Training</i>	21
2.15 <i>Deep Learning</i>	22
2.15.1 <i>Recurrent Neural Network</i> (RNN).....	23
2.15.2 <i>Long Short-Term Memory</i> (LSTM)	25
2.15.3 <i>Bidirectional Long Short-Term Memory</i> (Bi-LSTM).....	29

2.16	<i>Hybrid</i> VARIMAX-Bi-LSTM.....	31
2.17	Evaluasi Model	32
2.17.1	Mean Absolute Percentage Error (MAPE)	33
2.17.2	Root Mean Square Error (RMSE)	33
2.18	Uji T ² Hotelling.....	34
III.	METODOLOGI PENELITIAN.....	36
3.1	Waktu dan Tempat Penelitian.....	36
3.2	Spesifikasi Perangkat.....	36
3.3	Data Penelitian.....	37
3.4	Metode Penelitian	38
IV.	HASIL DAN PEMBAHASAN.....	41
4.1	<i>Input</i> Data	41
4.2	Visualisasi Data	42
4.3	Proses Prediksi Data dengan VARIMAX	44
4.3.1	<i>Preprocessing</i> Data.....	44
4.3.2	Uji Stasioner	45
4.3.3	Identifikasi Model.....	48
4.3.4	Estimasi Parameter dan Uji Diagnostik Model.....	49
4.3.5	Prediksi VARIMAX	51
4.3.6	Menghitung Residual	56
4.4	Proses <i>Hybrid</i> VARIMAX – Bi-LSTM.....	59
4.4.1	Membangun Model Bi-LSTM Pertama dan Kedua.....	59
4.4.2	<i>Hyperparameter Tuning</i> Model Bi-LSTM Pertama dan Kedua.....	60
4.4.3	Prediksi Model Bi-LSTM Pertama	63
4.4.4	Prediksi Model Bi-LSTM Kedua.....	67
4.4.5	Prediksi Model <i>Hybrid</i> VARIMAX – Bi-LSTM.....	70
4.5	Membangun Model Bi-LSTM.....	74
4.5.1	<i>Hyperparameter Tuning</i> Model Bi-LSTM.....	75
4.5.2	Prediksi Model Bi-LSTM	76
4.6	Hasil Peramalan	80
4.6.1	Hasil Peramalan VARIMAX	80
4.6.2	Hasil Peramalan Bi-LSTM	85
4.6.3	Hasil Peramalan Model <i>Hybrid</i> VARIMAX – Bi-LSTM	89
4.6.3.1	Hasil Peramalan Model <i>Hybrid</i> Bi-LSTM Pertama	89
4.6.3.2	Hasil Peramalan Model <i>Hybrid</i> Bi-LSTM Kedua	92

4.6.3.3 Hasil Peramalan Model *Hybrid* VARIMAX – Bi-LSTM . 94

V. KESIMPULAN	101
DAFTAR PUSTAKA	103
LAMPIRAN	108
Lampiran 1. Data Penelitian.....	109

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terkait	6
2. Data Penelitian	38
3. <i>Input Data</i>	41
4. Statistik Deskriptif.....	42
5. <i>Preprocessing Data</i>	44
6. Hasil <i>Differencing</i> Pertama	46
7. Pemilihan Model VARIMAX Terbaik	50
8. Hasil Prediksi Model VARIMAX Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	51
9. Hasil Data Prediksi Model VARIMAX Setelah <i>Undifferencing</i> Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	52
10. Hasil Prediksi Model VARIMAX Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	53
11. Hasil Data Prediksi Model VARIMAX Setelah <i>Undifferencing</i> Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	54
12. Evaluasi Model VARIMAX(1, 1, 1)	55
13. Nilai Residual Model VARIMAX Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	56
14. Nilai Residual Model VARIMAX Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	57

15. Model Bi-LSTM Pertama Terbaik Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	61
16. Model Bi-LSTM Pertama Terbaik Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	61
17. Model Bi-LSTM Kedua Terbaik Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	62
18. Model Bi-LSTM Kedua Terbaik Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	63
19. Data Hasil Prediksi Model VARIMAX dengan Data Hasil Prediksi Model Bi-LSTM Pertama Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	64
20. Data Hasil Prediksi Model VARIMAX dengan Data Hasil Prediksi Model Bi-LSTM Pertama Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	65
21. Evaluasi Model Bi-LSTM Pertama	66
22. Data Residual Hasil Prediksi Model VARIMAX dengan Data Residual Hasil Prediksi Model Bi-LSTM Kedua Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	67
23. Data Residual Hasil Prediksi Model VARIMAX dengan Data Residual Hasil Prediksi Model Bi-LSTM Kedua Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	69
24. Evaluasi Model Bi-LSTM Kedua	70
25. Data Hasil Prediksi Model <i>Hybrid</i> VARIMAX – Bi-LSTM Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	71
26. Data Hasil Prediksi Model <i>Hybrid</i> VARIMAX – Bi-LSTM Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	72
27. Evaluasi Model <i>Hybrid</i> VARIMAX – Bi-LSTM	74
28. Model Bi-LSTM Terbaik Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	75
29. Model Bi-LSTM Terbaik Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	76
30. Data Hasil Prediksi Model Bi-LSTM Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	76

31. Data Hasil Prediksi Model Bi-LSTM Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	78
32. Evaluasi Model Bi-LSTM	79
33. Hasil Peramalan Model VARIMAX Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	81
34. Hasil Peramalan Model VARIMAX Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	83
35. Hasil Peramalan Model Bi-LSTM Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	85
36. Hasil Peramalan Model Bi-LSTM Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	87
37. Hasil Peramalan Model <i>Hybrid</i> VARIMAX – Bi-LSTM dengan Data Aktual <i>Ter-update</i> Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian.....	94
38. Hasil Peramalan Model <i>Hybrid</i> VARIMAX – Bi-LSTM dengan Data Aktual <i>Ter-update</i> Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian.....	97

DAFTAR GAMBAR

Gambar	Halaman
1. Fungsi Aktivasi <i>Sigmoid</i>	20
2. Fungsi Aktivasi <i>Tangen Hiperbolik</i>	21
3. Arsitektur RNN	24
4. Arsitektur LSTM	26
5. Arsitektur Bi-LSTM	30
6. <i>Flowchart</i> Peramalan Metode <i>Hybrid VARIMAX – Bi-LSTM</i>	40
7. Plot Data Historis Harga Emas Berjangka	43
8. Plot Data Historis Harga Perak Berjangka	43
9. Hasil Uji Stasioneritas Data	45
10. Plot Data <i>Differencing</i> Pertama	46
11. Hasil Uji Stasioneritas Data Setelah <i>Differencing</i> Pertama	47
12. Plot ACF dan PACF Harga Emas	48
13. Plot ACF dan PACF Harga Perak	49
14. Hasil <i>Summary</i> Model VARIMAX(1, 1, 1)	50
15. Plot Prediksi Model VARIMAX Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	52
16. Plot Prediksi Model VARIMAX Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	54

17. Plot Residual Harga Emas dan Perak Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	56
18. Plot Residual Harga Emas dan Perak Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	58
19. Plot Prediksi Model Bi-LSTM Pertama Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	64
20. Plot Prediksi Model Bi-LSTM Pertama Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	65
21. Plot Prediksi Model Bi-LSTM Kedua Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	68
22. Plot Prediksi Model Bi-LSTM Kedua Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	69
23. Plot Prediksi Model <i>Hybrid</i> VARIMAX – Bi-LSTM Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	72
24. Plot Prediksi Model <i>Hybrid</i> VARIMAX – Bi-LSTM Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	73
25. Plot Prediksi Model Bi-LSTM Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	77
26. Plot Prediksi Model Bi-LSTM Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	78
27. Plot Peramalan Model VARIMAX Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	82
28. Plot Peramalan Model VARIMAX Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	84
29. Plot Peramalan Model Bi-LSTM Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	86
30. Plot Peramalan Model Bi-LSTM Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	88
31. Plot Peramalan Model Bi-LSTM Pertama Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	90
32. Plot Peramalan Model Bi-LSTM Pertama Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	91

33. Plot Peramalan Model Bi-LSTM Kedua Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	92
34. Plot Peramalan Model Bi-LSTM Kedua Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	93
35. Plot Peramalan Model <i>Hybrid</i> VARIMAX – Bi-LSTM Menggunakan Skema 80% Data Pelatihan dan 20% Data Pengujian	95
36. Plot Peramalan Model <i>Hybrid</i> VARIMAX – Bi-LSTM Menggunakan Skema 90% Data Pelatihan dan 10% Data Pengujian	98

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Peramalan deret waktu merupakan pengamatan data masa lalu dari suatu variabel yang kemudian dilakukan analisis sehingga memperoleh sebuah model yang dapat dikembangkan agar mampu menggambarkan hubungan dari variabel yang dianalisis. Model tersebut kemudian digunakan untuk memprediksi nilai suatu data deret waktu di masa depan (Zhang, 2003). Pada analisis data deret waktu, tidak semua model terbaik dapat digunakan untuk semua variabel. Langkah yang perlu dilakukan, yaitu memilih dan mengumpulkan variabel yang tepat, kemudian memilih model terbaik agar mendapatkan hasil akurasi yang tinggi (Zahra dan Lazaar, 2019).

Data deret waktu dapat dianalisis dengan lebih dari satu variabel menggunakan metode deret waktu multivariat. Salah satu metode deret waktu yang dapat digunakan untuk peramalan data multivariat adalah *Vector Autoregressive Integrated Moving Average Exogenous* (VARIMAX). Model VARIMAX adalah model deret waktu multivariat yang dikembangkan dari metode *Vector Autoregressive Integrated Moving Average* (VARIMA) (Pertiwi dkk., 2021). Metode VARIMA mendeskripsikan bahwa semua peubah atau variabel yang digunakan merupakan variabel endogen. Penambahan variabel atau peubah yang digunakan dalam model VARIMAX adalah peubah endogen dan eksogen. Sutthichaimethee (2017) menyatakan bahwa model VARIMAX merupakan model deret waktu yang digunakan untuk memodelkan beberapa variabel endogen dan

terdapat variabel eksogen yang mempengaruhi variabel endogen tersebut. Data harga emas dan perak berjangka merupakan contoh data deret waktu multivariat yang dapat diprediksi menggunakan metode VARIMAX. Namun dalam penggunaannya, metode VARIMAX akan sulit memprediksi karena memiliki kelemahan pada data deret waktu dengan pola *non-linear*.

Peramalan dapat juga dilakukan dengan menggunakan metode *deep learning*. Salah satu jenis dari metode *deep learning* adalah *Recurrent Neural Network* (RNN). Model RNN adalah salah satu arsitektur dalam *deep learning* yang memiliki nilai akurasi cukup baik dalam melakukan prediksi menggunakan data berbentuk deret waktu. Model RNN melakukan pembelajaran dengan lapisan yang lebih kompleks untuk mencapai akurasi dan efisiensi yang cukup baik, serta mampu memodelkan data linear dan *non-linear* dengan mencapai hasil akurasi yang lebih akurat dibanding peramalan tradisional (Arissinta dkk., 2022). Model RNN masih memiliki kelemahan dalam melakukan peramalan jangka panjang dengan menggunakan data dalam jumlah besar karena tidak mampu menampung memori jangka panjang sehingga sulit untuk mengingat informasi sebelumnya dan mengakibatkan informasi penting dari awal akan terhapus (Wiranda dan Sadikin, 2019). Untuk mengatasi masalah tersebut dikembangkan sebuah arsitektur baru yaitu metode *Long Short Term-Memory* (LSTM). Model LSTM merupakan metode dengan arsitektur seperti RNN tetapi memiliki perubahan dengan menambahkan memori sel yang dapat menyimpan informasi dalam jangka panjang. Metode ini merupakan kerangka kerja dengan basis komputasi yang fleksibel serta mampu mempelajari depedensi jangka panjang sehingga cocok apabila digunakan untuk memodelkan masalah *non-linear* dengan jumlah data yang besar (Caliwag dan Lim, 2019).

Arsitektur LSTM dikembangkan kembali menjadi *Bidirectional Long Short-Term Memory* (Bi-LSTM) untuk mengatasi kekurangan LSTM, yaitu hanya dapat memproses data sekuensial dalam satu arah saja. Hal ini dapat menjadi masalah khususnya dalam peramalan data deret waktu, dimana informasi dari masa lalu dan masa depan sama penting untuk menentukan hasil peramalan. Bi-LSTM

mengatasi masalah ini dengan memproses data sekuensial dalam dua arah yaitu maju dan mundur (Rusul dkk., 2021). Hal ini memungkinkan Bi-LSTM untuk menangkap informasi dari seluruh data deret waktu, termasuk informasi dari masa lalu dan masa depan. Serupa dengan LSTM yang hanya memproses urutan *input* hanya dalam satu arah (maju atau mundur), Bi-LSTM memproses urutan di kedua arah secara bersamaan dengan tetap mempertahankan *hidden state* dan *memory cells*. Setelah proses urutan *input* dua arah tersebut selesai, *hidden state* dari kedua lapisan LSTM digabungkan pada setiap langkah waktu (Staudemeyer dan Morris, 2019). Bi-LSTM juga dapat digunakan untuk memodelkan masalah *non-linear* pada model VARIMAX. Namun diperlukan sejumlah kumpulan data dalam jumlah yang besar untuk mempelajari pola *non-linear* tersebut. Dengan demikian, Bi-LSTM secara individual tidak mampu menangani pola linear dan *non-linear* secara bersamaan. Salah satu cara untuk meningkatkan kinerja model dan mengatasi kelemahan masing-masing metode ini adalah dengan menggunakan model *hybrid*.

Pengembangan prediksi model multivariat dengan menggunakan model VARIMAX dan menggunakan model Bi-LSTM adalah metode *hybrid* VARIMAX – Bi-LSTM. Model VARIMAX digunakan untuk menganalisis deret waktu multivariat dan memprediksi nilai di masa depan. Kemudian hasil prediksi dan residual yang didapatkan dari model VARIMAX digunakan sebagai *input* dalam model Bi-LSTM yang selanjutnya akan memprediksi nilai prediksi dimasa depan. Penggabungan antara model VARIMAX dan Bi-LSTM ini bertujuan untuk mengatasi kelemahan pada kedua model secara individual sehingga kombinasi model VARIMAX dan Bi-LSTM diharapkan dapat meningkatkan nilai akurasi yang dihasilkan.

Penelitian Sutthichaimethee (2017) menggunakan VARIMAX untuk memprediksi emisi CO₂, populasi, dan PDB dengan variabel konsumsi energi di berbagai sektor. Prediksi dilakukan tiga puluh tahun kedepan dengan hasil MAPE sebesar 1.16%. Penelitian terdahulu menggunakan metode Bi-LSTM dilakukan oleh Puteri (2023) untuk memprediksi harga saham. Hasil pengujian model

menunjukkan bahwa dari tiga data saham yang digunakan didapatkan pada model Bi-LSTM. Nilai MAPE yang diperoleh untuk setiap data saham secara berurutan yaitu, 2,59%, 1,77%, dan 1,05%.

Salah satu implementasi menggunakan metode *hybrid* pernah dilakukan oleh Caliwag dan Lim (2019). Peramalan ini menggunakan metode *hybrid* VARMA – LSTM serta terbukti menghasilkan kinerja yang lebih baik berdasarkan RMSE yang lebih rendah daripada peramalan yang dilakukan hanya dengan VARMA atau LSTM secara individual. Kemudian penelitian yang dilakukan oleh Tejoyadav dkk. (2022) melakukan peramalan menggunakan metode *hybrid* VAR – LSTM. Hasil dari penelitian ini membuktikan bahwa kinerja *hybrid* model lebih baik berdasarkan MAE dan RMSE yang lebih rendah dibandingkan hanya menggunakan VAR atau LSTM secara individual.

Penelitian menggunakan metode *hybrid* VARIMAX – Bi-LSTM masih sedikit dilakukan khususnya terkait peramalan harga emas dan perak. Emas dan perak merupakan logam mulia bernilai tinggi yang digunakan dalam industri, investasi, dan cadangan likuiditas bank sentral. Pada perkembangan selanjutnya, kedua logam tersebut sangat diminati mengingat logam tersebut dapat dijadikan opsi investasi karena posisi harga yang bersaing cukup kuat dalam komoditas perdagangan dunia (Solikin dan Suseno, 2002). Berdasarkan penjelasan di atas, penelitian ini dilakukan untuk mengetahui keefektifan metode *hybrid* VARIMAX – Bi-LSTM serta melakukan peramalan terhadap harga emas dan perak. Sehingga hasil peramalan dari penelitian ini dapat digunakan sebagai acuan bagi calon investor maupun pemegang kebijakan dalam mengambil keputusan mengenai waktu yang tepat agar bisa melakukan investasi pada emas dan perak.

1.2 Rumusan Masalah

Berdasarkan latar belakang masalah yang telah diuraikan, maka rumusan masalah dapat disusun sebagai berikut:

1. Bagaimana cara membangun model *hybrid* VARIMAX – Bi-LSTM dengan data *input* prediksi VARIMAX dan residual VARIMAX untuk peramalan harga emas dan perak?
2. Bagaimana kinerja model *hybrid* VARIMAX – Bi-LSTM dalam meramalkan harga emas dan perak?
3. Bagaimana hasil peramalan harga emas dan perak selama beberapa periode kedepan dengan menggunakan model *hybrid* VARIMAX – Bi-LSTM?

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah :

1. Membangun model *hybrid* VARIMAX – Bi-LSTM dengan data *input* prediksi VARIMAX dan residual VARIMAX untuk peramalan harga emas dan perak.
2. Melakukan pengembangan dan mengevaluasi kinerja model dari metode *hybrid* VARIMAX – Bi-LSTM terhadap peramalan harga emas dan perak.
3. Mengetahui peramalan harga emas dan perak menggunakan metode *hybrid* VARIMAX – Bi-LSTM.

1.4 Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah :

1. Menambah wawasan pembaca terhadap metode *hybrid* VARIMAX – Bi-LSTM serta pengaplikasiannya.
2. Dapat menjadi referensi bagi peneliti selanjutnya dalam melakukan peramalan menggunakan metode *hybrid* VARIMAX – Bi-LSTM dengan jenis data yang berbeda atau metode yang telah dikembangkan.
3. Dapat menambah khasanah ilmu pengetahuan dan informasi yang berkaitan dengan peramalan harga emas dan perak.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terkait Analisis Deret Waktu

Penelitian ini memerlukan kajian literatur yang relevan untuk meningkatkan pemahaman tentang topik penelitian yang dipakai dalam penelitian ini. Ringkasan dari kajian literatur yang terkait dapat dilihat pada Tabel 1.

Tabel 1. Penelitian Terkait

Penelitian	Data	Metode	Hasil
VARIMAX Model to Forecast the Emmission of Carbon Dioxide from Energy Comsumption in Rubber and Petroleum Industries Sectors in Thailand (Sutthichaimethee, 2017)	Data emisi CO2, populasi, dan PDB sebagai variabel endogen serta konsumsi energi di sektor industri karet, kimia dan perminyakan sebagai variabel eksogen	VARIMAX	MAPE VARIMAX :1,16%
Implementasi Long Short-Term Memory (LSTM) dan Bidirectional Long Short-Term Memory (Bi-LSTM) Dalam Prediksi Harga Saham Syariah (Puteri, 2023).	Harga penutupan dari saham Aneka Tambang Tbk, PT Unilever Indonesia Tbk, dan PT Indofood Sukses Makmur Tbk	LSTM, Bi-LSTM	MAPE LSTM: 1. Antam 2,66% 2. Unilever 2,59% 3. Indofood 2,11% MAPE Bi-LSTM: 1. Antam 1,77% 2. Unilever 1,08% 3. Indofood 1,07%

Tabel 1. (Lanjutan)

Penelitian	Data	Metode	Hasil
Hybrid VARMA and LSTM method for lithium-ion battery state-of-charge and output voltage forecasting in electric motorcycle applications (Caliwag dan Lim, 2019)	Menggunakan data indikator keamanan baterai pada kendaraan berbasis listrik, meliputi status kesehatan baterai, status daya baterai, keamanan baterai, pengisian daya, dan status lamanya hidup baterai	VARMA – LSTM	RMSE VARMA: 3,836 RMSE LSTM: 0,4032 RMSE <i>Hybrid</i> : 0,161
Multivariate Water Quality Forecasting of River Ganga Using VAR-LSTM based Hybrid Model (Tejoyadav dkk., 2022)	Menggunakan data kualitas air sungai Gangga yang mengalir di Uttar Pradesh, India. Meliputi 4 polutan air, yaitu <i>Dissolved Oxygen (DO)</i> , <i>Biological Oxygen (BO)</i> , <i>Total Coliform (TO)</i> , <i>Fecal Coliform (FO)</i> dan <i>Water Quality Indeks (WQI)</i> .	VAR – LSTM	MAE VAR: 4,97 RMSE VAR: 6,95 MAE LSTM: 5,86 RMSE LSTM: 8,36 MAE VAR – LSTM: 4,27 RMSE VAR – LSTM: 6,52

Penelitian pertama menggunakan metode VARIMAX yang dilakukan oleh Sutthichaimethee (2017). Pada penelitian ini bertujuan untuk menganalisis prakiraan emisi CO₂, populasi, dan pertumbuhan ekonomi PDB dengan mempertimbangkan variabel konsumsi energi di berbagai sektor seperti industri karet, kimia dan perminyakan di Thailand. Prediksi dilakukan tiga puluh tahun kedepan dengan hasil MAPE pada model adalah VARIMAX (2,1,3) sebesar 1.16%.

Penelitian selanjutnya dilakukan oleh Puteri (2023) membahas tentang peramalan harga saham dengan menggunakan metode LSTM dan Bi-LSTM lalu dibandingkan satu sama lain. Pada penelitian ini menggunakan beberapa data

penutupan harga saham (harian), yaitu adalah Aneka Tambang Tbk, PT Unilever Indonesia Tbk, dan PT Indofood Sukses Makmur Tbk. Berdasarkan Tabel 1. model Bi-LSTM memperoleh nilai MAPE yang lebih kecil dibandingkan model LSTM.

Selanjutnya penelitian yang dilakukan Caliwag dan Lim (2019), yaitu melakukan peramalan pada keamanan baterai, meliputi pengisian daya, status kesehatan baterai, status daya baterai, dan status lamanya hidup baterai pada sebuah kendaraan berbasis listrik. Peramalan ini menggunakan metode *hybrid* VARMA – LSTM serta terbukti menghasilkan kinerja yang lebih baik berdasarkan RMSE yang lebih rendah daripada peramalan yang dilakukan hanya dengan model VARMA atau model LSTM secara individual.

Kemudian penelitian yang dilakukan oleh Tejoyadav dkk. (2022) menyajikan studi penelitian tentang peramalan kualitas air mengalir sungai Gangga di Uttar Pradesh, India. Menggunakan data harian sebanyak 1827 sampel pada periode Januari 2016 sampai dengan Desember 2020. Penelitian ini difokuskan pada model *hybrid* VAR – LSTM yang merupakan kombinasi model VAR dan model LSTM. Hasil penelitian ini membuktikan bahwa pendekatan *hybrid* memiliki kemampuan yang lebih baik dibandingkan kinerja model VAR atau model LSTM secara individual, yaitu menghasilkan nilai MAE dan RMSE paling kecil, yaitu berturut-turut sebesar 4,27 dan 6,52.

2.2 Peramalan

Peramalan merupakan prediksi nilai suatu variabel berdasarkan nilai masa lalu yang diketahui dari variabel tersebut atau variabel terkait lainnya. Peramalan juga dapat didasarkan pada penilaian ahli, menggunakan data-data historis dari suatu variabel yang nantinya akan digunakan dalam pengambilan keputusan (Makridakis dkk., 1999). Untuk mendapatkan hasil peramalan yang akurat maka dibutuhkan perhitungan yang tepat. Menurut Nurfadilah dan Kasse (2018),

terdapat dua hal yang perlu diperhatikan agar menghasilkan peramalan yang akurat sehingga hasil peramalan dapat digunakan dalam pengambilan keputusan. Pertama adalah mengumpulkan data yang relevan dengan tujuan peramalan yang ingin dicapai, dan kedua adalah memilih metode peramalan yang sesuai dengan data yang telah dikumpulkan agar hasil peramalan memiliki nilai akurasi yang tinggi. Montgomery dkk. (2015) mengatakan bahwa metode peramalan dibedakan menjadi dua kategori, yaitu:

1. Peramalan Kualitatif adalah teknik peramalan yang bersifat subjektif dan membutuhkan penilaian dari para ahli. Peramalan kualitatif sering digunakan dalam situasi dimana hanya ada sedikit atau tidak ada data historis yang dapat digunakan sebagai dasar prediksi.
2. Peramalan Kuantitatif adalah teknik peramalan yang menggunakan data historis dan model peramalan secara formal. Model ini dapat menangkap pola dalam data sehingga dapat melihat hubungan statistik antara nilai variabel sebelumnya. Kemudian model tersebut digunakan untuk memproyeksikan pola-pola dalam data ke waktu yang akan datang.

2.3 Analisis Deret Waktu

Analisis deret waktu adalah analisis yang mempertimbangkan pengaruh waktu secara berurutan. Deret waktu adalah sekumpulan data sebuah objek yang diambil secara berurutan dalam interval waktu yang tetap. Sedangkan data deret waktu adalah data yang dikumpulkan berdasarkan urutan dan interval dalam satu waktu tertentu, seperti dalam hari, minggu, bulan, kuartal, dan tahun (Wei, 2006). Makridakis dkk. (1999) mengatakan bahwa terdapat langkah penting dalam memilih metode peramalan yang tepat dengan mempertimbangkan jenis pola data sehingga metode yang paling sesuai dengan pola-pola tersebut dapat digunakan. Pada umumnya, suatu data deret waktu terdiri atas satu atau beberapa jenis pola data sebagai berikut:

1. Pola Horizontal merupakan sebuah kondisi dimana nilai data berfluktuasi secara horizontal disekitar rata-rata yang konstan atau bisa disebut dalam keadaan deret waktu yang stasioner.
2. Pola Musiman merupakan keadaan yang muncul ketika sebuah deret waktu dipengaruhi oleh faktor musiman seperti, hari, minggu, bulan, tahun dan kuartal. Meskipun deret waktu musiman biasanya juga disebut periodik karena berulang-ulang, tetapi tidak benar-benar berulang setiap periode.
3. Pola Siklis merupakan sebuah kondisi ketika data menunjukkan peningkatan dan penurunan yang tidak memiliki periode waktu yang tetap. Perbedaan utama antara pola musiman dan pola siklus adalah pola musiman memiliki panjang deret waktu yang konstan dan berulang secara berkala, sedangkan pola siklus memiliki panjang deret waktu yang bervariasi dan tidak selalu berulang.
4. Pola Tren merupakan suatu keadaan ketika ada peningkatan atau penurunan jangka panjang dalam data deret waktu untuk suatu periode tertentu.

2.4 Stasioneritas

Stasioner merupakan suatu proses dengan tidak terdapat perubahan kenaikan atau penurunan dalam data deret waktu. Fluktuasi data tersebut berada disekitar nilai rata-rata maupun ragam secara konstan dan tidak tergantung pada interval waktu (Makridakis dkk., 1999). Suatu deret waktu yang stasioner dapat dilihat melalui grafik, jika rata-rata dan ragam konstan, tidak ada unsur tren dalam data, serta tidak ada unsur musiman maka deret waktu tersebut dapat dikatakan stasioner. Metode yang digunakan untuk menguji kestasioneran data dapat dilakukan dengan menggunakan uji akar unit. Salah satu metode uji akar unit yang dapat digunakan adalah *Augmented Dickey-Fuller (ADF)*.

Menurut Box dkk. (2015), perilaku non-stasioner dalam rata-rata dapat ditransformasi dengan melakukan *differencing*. *Differencing* merupakan sebuah proses mencari selisih antara data satu periode dengan periode sebelumnya

dengan menggunakan autoregresif umum dengan operator φ . Kunci dari model ini adalah keberadaan akar unit dalam polinomial φ . Akar unit adalah selisih nilai pada B yang membuat φ sama dengan nol. Jika polinomial memiliki akar unit, berarti polinomial tersebut memiliki faktor $(1 - B)$.

Keberadaan nilai faktor ini menunjukkan bahwa perubahan sebelumnya dalam deret waktu secara langsung memengaruhi nilai-nilai berikutnya. Operator $\varphi(B)$ dapat ditulis pada persamaan (2.1) sebagai berikut:

$$\begin{aligned}\varphi Y_t &= Y_t - Y_{t-1} \\ \varphi Y_t &= Y_t - B Y_t \\ \varphi Y_t &= (1 - B) Y_t\end{aligned}\tag{2.1}$$

dengan:

Y_t : data pengamatan deret waktu ke- t
 B : operator *backshift*

2.5 *Scaling Data*

Scaling data adalah metode yang digunakan untuk mengkonversi nilai numerik dalam *dataset* ke skala yang lebih umum. Tujuan utama dari teknik ini adalah untuk mengurangi kesalahan atau ketidakcocokan data. *Scaling* data juga bermanfaat dalam mengurangi proporsi ukuran *dataset* tanpa mempengaruhi nilai aktualnya. Selain itu, *scaling* data digunakan untuk mengatasi potensi penyimpangan dan inkonsistensi dalam data (Aldi dkk., 2018). Proses skalasi data ini terintegrasi dalam tahap *preprocessing* dan dapat memanfaatkan berbagai teknik yang ada.

1. *Min-max scaler*

Min-max scaler adalah metode yang diterapkan pada *dataset* dengan mengubah nilai-nilai aslinya menjadi rentang dalam interval $[0, 1]$. Pendekatan ini relevan saat standar deviasinya rendah dan tidak mengikuti distribusi normal. Skema *scaling* data dalam *min-max scaler* diimplementasikan dengan persamaan sebagai berikut (Aldi dkk., 2018):

$$X' = \frac{(x - \min_x)}{(\max_x - \min_x)} \quad (2.2)$$

dengan:

- X' : data hasil normalisasi
- x : data asli
- \min_x : nilai minimum dari data x
- \max_x : nilai maximum dari data x

2. *StandardScaler*

Teknik *standardScaler* didasarkan pada nilai *mean* dan standar deviasi. Penerapan *standardScaler* pada *dataset* adalah cara mengubah skala distribusi nilai sehingga rata-rata bernilai 0 dan standar deviasinya adalah 1. Pendekatan ini ideal digunakan saat ada asumsi bahwa data mengikuti distribusi normal. Pada *standardScaler*, proses *scaling* data dilakukan menggunakan pada persamaan (2.3) sebagai berikut (Ambarwari dkk., 2020):

$$X' = \frac{(x - \text{mean}_x)}{(\text{std}_x)} \quad (2.3)$$

dengan :

- X' : data hasil normalisasi
- x : data asli
- mean_x : nilai rata-rata dari data x
- std_x : nilai standar deviasi dari data x

2.6 Model *Vector Autoregressive* (VAR)

Model VAR merupakan sebuah kombinasi dari beberapa model *autoregressive* (AR) yang awalnya berfokus untuk menganalisis pada deret waktu univariat, menjadi sebuah model deret waktu multivariat yang memperhitungkan lebih dari satu variabel endogen. Model VAR merupakan sistem persamaan dinamis dengan interval waktu estimasi yang disesuaikan berdasarkan perubahan variabel dan variabel lain yang terlibat pada periode sebelumnya (Rusyana dkk., 2020). Model

VAR digunakan untuk memodelkan serangkaian variabel endogen secara simultan. Setiap variabel endogen dalam model ini dijelaskan oleh nilai-nilai masa lalu (*lagged*) serta nilai-nilai *lagged* dari semua variabel endogen lain dalam model tersebut. Secara umum, model VAR(p) dapat ditulis pada persamaan (2.4) berikut (Wei, 2006):

$$\mathbf{Z}_t = \phi_1 \mathbf{Z}_{t-1} + \phi_2 \mathbf{Z}_{t-2} + \dots + \phi_p \mathbf{Z}_{t-p} + \mathbf{a}_t \quad (2.4)$$

dengan :

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

ϕ_1, \dots, ϕ_t : matriks parameter AR berukuran $N \times N$

\mathbf{a}_t : nilai residual pada waktu ke- t $[a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T$ vektor error ukuran $N \times 1$

2.7 Model Vector Moving Average (VMA)

Model VMA merupakan sebuah kombinasi dari beberapa model *Moving Average* (MA) yang awalnya berfokus untuk menganalisis pada deret waktu univariat, menjadi sebuah model deret waktu multivariat yang memperhitungkan lebih dari satu variabel endogen. Model VMA merupakan sistem persamaan dinamis dengan interval waktu estimasi yang disesuaikan berdasarkan perubahan variabel dan variabel lain yang terlibat pada periode sebelumnya (Rusyana dkk., 2020). Model VMA digunakan untuk memodelkan serangkaian variabel endogen secara simultan. Setiap variabel endogen dalam model ini dijelaskan oleh nilai-nilai masa lalu (*lagged*) serta nilai-nilai *lagged* dari semua variabel endogen lain dalam model tersebut. Secara umum, model VMA(q) dapat ditulis pada persamaan (2.5) sebagai berikut (Wei, 2006):

$$\mathbf{Z}_t = \mathbf{a}_t - \theta_1 \mathbf{a}_{t-1} - \theta_2 \mathbf{a}_{t-2} - \dots - \theta_t \mathbf{a}_{t-q} \quad (2.5)$$

dengan:

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

$\theta_1, \dots, \theta_t$: matriks parameter MA berukuran $N \times N$

a_t : nilai residual pada waktu ke- t $[a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T$ vektor error ukuran $N \times 1$

2.8 Model Vector Autoregressive Moving Average (VARMA)

Model VARMA merupakan sebuah model deret waktu yang dapat digunakan untuk menganalisis lebih dari satu variabel endogen. Model VARMA adalah kombinasi dari orde p pada model VAR dan orde q pada model VMA sehingga menjadi sebuah model VARMA (p, q) (Auliasari dkk., 2019). Secara umum model VARMA mempunyai bentuk persamaan (2.6) sebagai berikut (Wei, 2006):

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

dengan:

Z_t : vektor pengamatan dengan $Z_t = [Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^T$ vektor deret waktu stasioner ukuran $N \times 1$

ϕ_1, \dots, ϕ_t : matriks parameter AR berukuran $N \times N$

$\theta_1, \dots, \theta_t$: matriks parameter MA berukuran $N \times N$

a_t : nilai residual pada waktu ke- t $[a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T$ vektor error ukuran $N \times 1$

2.9 Model Vector Autoregressive Integrated Moving Average (VARIMA)

Model VARIMA merupakan model VARMA yang mengalami proses *differencing* (Rusyana dkk., 2020). Model VARIMA terjadi ketika data yang diperoleh tidak stasioner sehingga diperlukan proses *differencing* agar data yang digunakan menjadi stasioner. Sebagai contoh, dalam deret waktu univariat suatu data tidak stasioner Z_t direduksi menjadi serangkaian stasioner *series* $(1 - B)^d Z_t$ untuk $d > 0$, dapat ditulis pada persamaan (2.7) sebagai berikut (Wei, 2006):

$$\Phi_p(\mathbf{B})(1 - \mathbf{B})^d \mathbf{Z}_t = \Theta_q(\mathbf{B}) \mathbf{a}_t \quad (2.7)$$

dengan Φ_p adalah operator stasioner untuk AR dan Θ_q adalah operator stasioner untuk MA. Bentuk umum ini menunjukkan bahwa semua komponen adalah *difference* dari beberapa waktu. Agar lebih sederhana, dapat diasumsikan bahwa Z_t yang tidak stasioner, dapat direduksi dengan serangkaian vektor *series* yang merupakan operator *difference* $D(\mathbf{B})$ (Pertiwi dkk., 2021). Sehingga, model VARMA yang tidak stasioner untuk Z_t ditulis dalam persamaan (2.8) sebagai berikut (Wei, 2006):

$$\Phi_p(\mathbf{B})D(\mathbf{B})\mathbf{Z}_t = \Theta_q(\mathbf{B})\mathbf{a}_t \quad (2.8)$$

dengan:

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

$D(\mathbf{B})$: operator *differencing*

Φ_p, \dots, Φ_t : matriks parameter AR berukuran $N \times N$

$\Theta_q, \dots, \Theta_t$: matriks parameter MA berukuran $N \times N$

\mathbf{a}_t : nilai residual pada waktu ke- t $[a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T$ vektor error ukuran $N \times 1$

2.10 Model *Vector Autoregressive Integrated Moving Average Exogenous* (VARIMAX)

Model VARIMAX merupakan kasus khusus dari model VARIMA dengan penambahan variabel eksogen ke dalam model. Variabel eksogen dalam model VARIMAX ditentukan di luar model dan sifatnya mempengaruhi variabel endogen dalam suatu model. Model VARIMAX juga dapat digunakan untuk menjelaskan hubungan antara variabel endogen dengan variabel eksogen (Nurfadilah dan Kasse, 2018). Menurut Wei (2006) bentuk umum model VARIMAX (p, d, q) ditulis pada persamaan (2.9) sebagai berikut:

$$\Phi_p(\mathbf{B})D(\mathbf{B})\mathbf{Z}_t = \Theta_q(\mathbf{B})\mathbf{a}_t + \delta_r(\boldsymbol{\gamma})\mathbf{x}_t \quad (2.9)$$

dengan:

- \mathbf{Z}_t : vektor pengamatan dengan $Z_t = [Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^T$ vektor deret waktu stasioner ukuran $N \times 1$
- $D(\mathbf{B})$: operator *differencing*
- Φ_p, \dots, Φ_t : matriks parameter AR berukuran $N \times N$
- $\Theta_q, \dots, \Theta_t$: matriks parameter MA berukuran $N \times N$
- $\delta_r(\boldsymbol{\gamma})$: matriks parameter variabel eksogen berukuran $N \times S$
- \mathbf{x}_t : vektor variabel eksogen
- \mathbf{a}_t : nilai residual pada waktu ke- t $[a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T$ vektor error ukuran $N \times 1$

2.11 Estimasi Parameter Menggunakan Metode *Maximum Likelihood*

Estimasi parameter model VARIMAX dilakukan menggunakan metode *Maximum Likelihood Estimation* (MLE) yang bertujuan untuk memaksimalkan fungsi *likelihood*, lebih spesifiknya, MLE bertujuan untuk menemukan nilai-nilai parameter yang membuat data yang diamati paling mungkin terjadi di bawah model probabilistik yang telah ditentukan (Hamilton, 1994). Untuk melakukan estimasi parameter model VARIMAX menggunakan metode MLE, dilakukan tahapan-tahapan sebagai berikut:

Persamaan (2.9) dapat ditulis menjadi persamaan (2.10) sebagai berikut:

$$\mathbf{Z}_t = \Phi_p(\mathbf{B})^{-1}\Theta_q(\mathbf{B})\mathbf{a}_t + \Phi_p(\mathbf{B})^{-1}\delta_r(\boldsymbol{\gamma})\mathbf{x}_t \quad (2.10)$$

diasumsikan bahwa vektor nilai residual pada waktu ke- t mengikuti distribusi normal multivariat $\mathbf{a}_t \sim N(0, \Sigma)$ kemudian didefinisikan fungsi peluang bersama dari variabel *random error* adalah sebagai berikut:

$$l(\boldsymbol{\beta}, \Sigma | \mathbf{Z}_t) = \prod_{t=1}^M f(\boldsymbol{\beta}, \Sigma | \mathbf{Z}_t) \quad (2.11)$$

berdasarkan persamaan (2.11) diperoleh fungsi *likelihood*-nya adalah sebagai berikut:

$$\begin{aligned} l(\boldsymbol{\beta}, \Sigma | \mathbf{Z}_t) &= \prod_{t=1}^M (2\pi)^{-\frac{N}{2}} |\Sigma|^{-\frac{1}{2}} \exp\left(-\frac{1}{2} \boldsymbol{\alpha}_t^T \Sigma^{-1} \boldsymbol{\alpha}_t\right) \\ &= (2\pi)^{-\frac{MN}{2}} |\Sigma|^{-\frac{M}{2}} \exp\left(-\frac{1}{2} \boldsymbol{\alpha}_t^T \Sigma^{-1} \boldsymbol{\alpha}_t\right) \end{aligned}$$

Selanjutnya fungsi log *likelihood*-nya adalah sebagai berikut:

$$\begin{aligned} L &= \ln l \\ &= \ln \left[(2\pi)^{-\frac{MN}{2}} |\Sigma|^{-\frac{M}{2}} \exp\left(-\frac{1}{2} \boldsymbol{\alpha}_t^T \Sigma^{-1} \boldsymbol{\alpha}_t\right) \right] \\ &= -\frac{MN}{2} \ln(2\pi) - \frac{M}{2} \ln(|\Sigma|) - \frac{1}{2} (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})^T \Sigma^{-1} (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}) \\ &= -\frac{MN}{2} \ln(2\pi) - \frac{M}{2} \ln(|\Sigma|) - \frac{1}{2} (\mathbf{Y}^T \Sigma^{-1} \mathbf{Y} - \boldsymbol{\beta}^T \mathbf{X}^T \Sigma^{-1} \mathbf{Y} - \boldsymbol{\beta}^T \mathbf{X}^T \Sigma^{-1} \mathbf{Y} + \\ &\quad \boldsymbol{\beta}^T \mathbf{X}^T \Sigma^{-1} \mathbf{X}\boldsymbol{\beta}) \\ &= -\frac{MN}{2} \ln(2\pi) - \frac{M}{2} \ln(|\Sigma|) - \frac{1}{2} (\mathbf{Y}^T \Sigma^{-1} \mathbf{Y} - 2\boldsymbol{\beta}^T \mathbf{X}^T \Sigma^{-1} \mathbf{Y} + \boldsymbol{\beta}^T \mathbf{X}^T \Sigma^{-1} \mathbf{X}\boldsymbol{\beta}) \end{aligned}$$

Untuk mendapatkan penduga parameter *Maximum Likelihood* akan dicari turunan pertama untuk masing-masing parameter, kemudian menyamakan hasilnya dengan nol dan diperoleh sebagai berikut:

$$\begin{aligned} \frac{\partial L}{\partial \boldsymbol{\beta}} &= \frac{\partial}{\partial \boldsymbol{\beta}} \left(-\frac{MN}{2} \ln(2\pi) - \frac{M}{2} \ln(|\Sigma|) - \frac{1}{2} (\mathbf{Y}^T \Sigma^{-1} \mathbf{Y} - 2\boldsymbol{\beta}^T \mathbf{X}^T \Sigma^{-1} \mathbf{Y} + \boldsymbol{\beta}^T \mathbf{X}^T \Sigma^{-1} \mathbf{X}\boldsymbol{\beta}) \right) \\ 0 &= -\frac{1}{2} (-2\mathbf{X}^T \Sigma^{-1} \mathbf{Y} + \mathbf{X}^T \Sigma^{-1} \mathbf{X}\boldsymbol{\beta} + (\boldsymbol{\beta}^T \mathbf{X}^T \Sigma^{-1} \mathbf{X})^T) \\ &= -\frac{1}{2} (-2\mathbf{X}^T \Sigma^{-1} \mathbf{Y} + \mathbf{X}^T \Sigma^{-1} \mathbf{X}\boldsymbol{\beta} + \mathbf{X}^T (\Sigma^{-1})^T \mathbf{X}\boldsymbol{\beta}) \\ &= -\frac{1}{2} (-2\mathbf{X}^T \Sigma^{-1} \mathbf{Y} + \mathbf{X}^T \Sigma^{-1} \mathbf{X}\boldsymbol{\beta} + \mathbf{X}^T \Sigma^{-1} \mathbf{X}\boldsymbol{\beta}) \\ &= -\frac{1}{2} (-2\mathbf{X}^T \Sigma^{-1} \mathbf{Y} + 2\mathbf{X}^T \Sigma^{-1} \mathbf{X}\boldsymbol{\beta}) \\ &= \mathbf{X}^T \Sigma^{-1} \mathbf{Y} - \mathbf{X}^T \Sigma^{-1} \mathbf{X}\boldsymbol{\beta} \end{aligned}$$

sehingga didapatkan persamaannya sebagai berikut:

$$\begin{aligned} X^T \Sigma^{-1} X \beta &= X^T \Sigma^{-1} Y \\ \beta &= (X^T \Sigma^{-1} X)^{-1} X^T \Sigma^{-1} Y \end{aligned}$$

Dengan demikian, estimasi parameter dari β adalah:

$$\beta = (X^T \Sigma^{-1} X)^{-1} X^T \Sigma^{-1} Y \quad (2.12)$$

2.12 Machine Learning

Machine learning atau pembelajaran mesin adalah bidang ilmu kecerdasan buatan yang mengajarkan komputer untuk belajar dan berperilaku seperti manusia, serta meningkatkan kemampuan belajarnya secara bertahap dengan memberikan data dan informasi sebagai bentuk pengalaman sehingga komputer dapat belajar sendiri mendeteksi pola yang rumit dan mengambil keputusan pintar berdasarkan data yang disediakan. Rowan dkk. (2022) menyatakan bahwa pembelajaran mesin diterapkan pada berbagai bidang seperti matematika, statistika, dan *data mining* agar mesin dapat belajar dengan cara mengolah data tanpa membutuhkan instruksi atau pemrograman baru. *Machine learning* ditandai dengan adanya *training* dan *testing*, yaitu *training* adalah proses pembuatan model sedangkan *testing* adalah proses yang digunakan untuk mengevaluasi kinerja model pembelajaran yang telah dibuat. *Machine learning* memiliki dua teknik pembelajaran, yaitu:

1. *Supervised learning* (pembelajaran terarah) adalah algoritma *machine learning* yang mendapatkan informasi dari data-data yang sudah memiliki label. *Output* pada pembelajaran terarah sudah ditetapkan sebelumnya dan proses pembelajaran akan berakhir ketika algoritma telah mencapai hasil yang diharapkan. *Supervised learning* biasanya digunakan untuk membuat prediksi dan klasifikasi.

2. *Unsupervised learning* (pembelajaran tidak terarah) adalah proses pembelajaran yang mendapatkan informasi dari data yang tidak memiliki label. Tujuan dari teknik pembelajaran tidak terarah ini adalah menggolongkan data yang memiliki kesamaan karakteristik dalam suatu area tertentu dan tidak membutuhkan target *output*. Teknik pembelajaran tidak terarah biasanya digunakan untuk *clustering*.

2.13 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi yang umum digunakan pada jaringan saraf tiruan untuk mengaktifkan atau menonaktifkan *neuron*. Fungsi ini berperan agar jaringan saraf tiruan mengenali data yang bersifat *non-linear* karena *output* yang dihasilkan dari jaringan saraf tiruan jarang bersifat *linear* sehingga cara kerja fungsi tersebut adalah mengubah data yang bersifat *non-linear* menjadi *linear* dalam rentang tertentu. Karakteristik jaringan saraf tiruan ditentukan oleh bobot dan *input-output* fungsi aktivasi yang diterapkan. Fungsi aktivasi yang sering digunakan sebagai berikut (Pasaribu dkk., 2020):

1. Fungsi *Sigmoid*

Fungsi aktivasi *sigmoid* memiliki *input* berupa bilangan real dan *output* fungsi ini memiliki jarak antara 0 sampai 1. Persamaan dari fungsi *sigmoid* adalah persamaan (2.13) sebagai berikut:

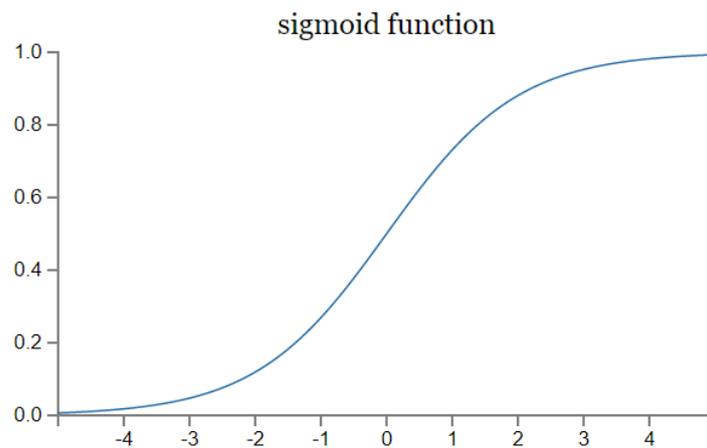
$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.13)$$

dengan:

x : data *input*

e : bilangan *euler*

Output yang dihasilkan oleh fungsi *sigmoid* akan membentuk grafik yang ditunjukkan oleh Gambar 1 di bawah ini:



Gambar 1. Fungsi Aktivasi Sigmoid

Pada fungsi *sigmoid* apabila semakin kecil *input* yang diberikan maka *output* yang dihasilkan akan mendekati nol dan jika semakin besar *input* yang diberikan maka *output* yang dihasilkan akan mendekati satu. *Sigmoid* memiliki rentang, $0 < \sigma \leq 0,5$ artinya bernilai nol dan $0,5 < \sigma \leq 1$ artinya bernilai satu (Siegel, 2016).

2. Fungsi Tanh

Fungsi aktivasi *tanh* merupakan fungsi *non-linear* yang memiliki rentang nilai lebih luas dari fungsi *sigmoid* sehingga lebih efektif digunakan untuk pemodelan *non-linear* kompleks. Fungsi *tanh* memiliki *input* berupa bilangan *real* dan *output* dari fungsi tersebut memiliki jarak antara -1 sampai 1. Fungsi ini juga memiliki derivatif yang lebih konsisten dibandingkan fungsi aktivasi lain, yang berarti tidak ada perubahan yang cukup signifikan saat *input*-nya berubah sehingga menghasilkan perubahan yang lebih halus pada *output* model (Nwankpa dkk., 2018). Persamaan fungsi *tanh* dituliskan pada persamaan (2.14) dan (2.15) sebagai berikut:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.14)$$

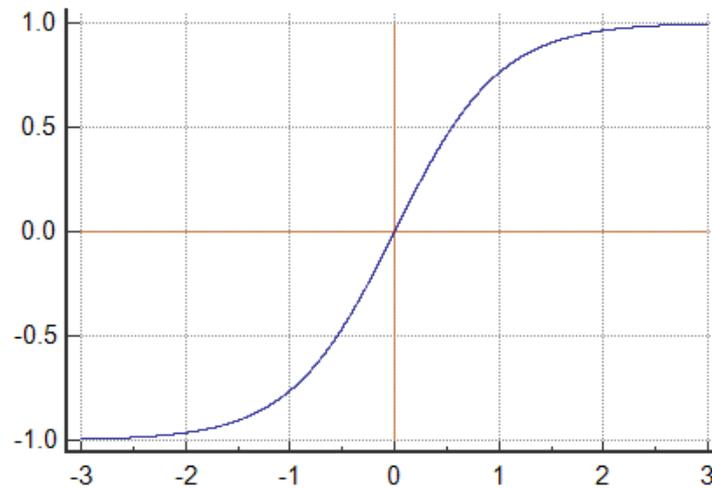
$$\tanh(x) = \frac{\sinh(x)}{\cosh(x)} \quad (2.15)$$

dengan:

x : data *input*

e : bilangan *euler*

Output yang dihasilkan oleh fungsi *tanh* akan membentuk grafik yang ditunjukkan oleh Gambar 2 di bawah ini:



Gambar 2. Fungsi Aktivasi *Tangen Hiperbolik*

2.14 *Hyperparameter* dan *Parameter Training*

Hyperparameter merupakan variabel konfigurasi diluar model dan nilainya sulit diperkirakan dari kumpulan data, yang artinya *hyperparameter* perlu ditetapkan terlebih dahulu sebelum melakukan pelatihan model sehingga nilai prediksi yang diperoleh adalah nilai yang terbaik (Hikmaturokhman dkk., 2022). Sebelum melatih data pelatihan untuk membuat model, tahap selanjutnya adalah menentukan parameter model pelatihan. Berikut ini adalah beberapa komponen penting yang perlu diperhatikan ketika membuat konfigurasi model pelatihan.

1. Fungsi aktivasi digunakan dalam jaringan syaraf tiruan untuk mengaktifkan atau menonaktifkan *neuron*.
2. Fungsi *loss* digunakan dalam jaringan syaraf tiruan untuk menghitung kesalahan model selama proses optimasi.
3. *Optimizers* digunakan dalam optimasi model dengan memperbarui bobot jaringan berdasarkan data pelatihan.

Hyperparameter harus dipertimbangkan ketika membangun sebuah model karena dapat mempengaruhi kinerja model dan meningkatkan akurasi. Berikut adalah beberapa *hyperparameter* dalam *deep learning* (Hikmaturokhman dkk., 2022):

1. Jumlah lapisan tersembunyi.
2. Jumlah *neuron* tersembunyi pada setiap lapisan tersembunyi.
3. Ukuran *batch* (merepresentasikan jumlah data *training* yang dilatih pada setiap *epoch*). Pada proses iterasi, misalnya jumlah data adalah 10.000 dan *batch size* adalah 200, maka satu *epoch* terdiri dari 50 iterasi (10.000 dibagi 200).
4. *Epoch* (merepresentasikan satu set iterasi).
5. Tingkat pembelajaran.
6. Parameter regulasi (keteraturan parameter).

Peran masing-masing parameter dalam model pelatihan sangat penting untuk dipertimbangkan. Misalnya, bagaimana memilih fungsi aktivasi, *loss*, dan pengoptimalisasi yang tepat untuk mendapatkan hasil model pelatihan dengan evaluasi *error* yang paling kecil dan nilai *output* mendekati target yang diinginkan (Hikmaturokhman dkk., 2022).

2.15 Deep Learning

Deep learning merupakan bagian dari *machine learning* yang pada intinya merupakan jaringan saraf dengan minimal tiga lapisan jaringan saraf buatan yang memungkinkannya untuk belajar dan beradaptasi dengan data yang banyak serta dapat menyelesaikan berbagai masalah yang sulit diselesaikan oleh algoritma pembelajaran mesin lainnya (Rowan dkk., 2022). Salah satu algoritma *deep learning* adalah *Recurrent Neural Network* (RNN).

Jaringan saraf tiruan sederhana adalah bagian dari kecerdasan buatan yang dibuat menyerupai cara kerja otak manusia. Model ini memiliki tiga lapisan, yaitu lapisan *input*, lapisan tersembunyi, dan lapisan *output*. Model ini juga memiliki prosesor yang sangat sederhana dan terhubung satu sama lain yang disebut *neuron*

(Kurniawan, 2018). Model ini memiliki kekurangan yaitu tidak dapat menghubungkan atau menyimpan informasi baru dengan informasi sebelumnya. Karena kekurangan tersebut, model ini tidak bisa digunakan untuk memproses data deret waktu yang memiliki keterkaitan dengan data periode sebelumnya. Untuk membuat model ini bisa digunakan untuk mengolah data deret waktu, maka *output* dari proses sebelumnya digunakan untuk memperbarui bobot yang baru. Bobot baru ini digunakan sebagai bobot untuk perhitungan data terbaru dan seterusnya sehingga ada keterkaitan antara data periode sekarang dengan data periode sebelumnya.

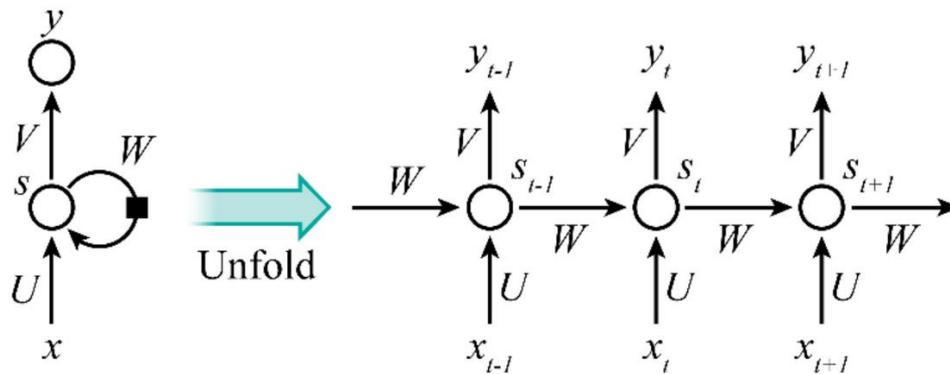
2.15.1 Recurrent Neural Network (RNN)

Recurrent Neural Network merupakan jenis jaringan saraf tiruan yang telah didesain khusus untuk memproses data sekuensial, seperti dalam analisis data deret waktu. Salah satu fitur utama RNN adalah adanya koneksi siklik yang memungkinkannya mempertahankan dan memperbarui informasi saat ini dengan mempertimbangkan informasi dari masa lalu dan data *input* saat ini (Yu dkk., 2019). Arsitektur RNN terdiri dari sel berulang, termasuk sel *tanh*, yang digunakan untuk menjalankan tugas yang serupa untuk setiap elemen dalam urutan data, dengan keunggulan menggunakan informasi yang telah disimpan sebelumnya untuk memprediksi data berurutan yang belum terlihat di masa depan (Namini dkk., 2018).

Struktur dasar RNN terdiri dari lapisan *input*, lapisan tersembunyi, dan lapisan *output*. Pada arus informasinya, data *input* diteruskan dari lapisan *input* ke lapisan tersembunyi, dan prosesnya mencakup integrasi informasi dari masa lalu (Yin dkk., 2017). Walaupun RNN memiliki kinerja yang baik dalam banyak kasus, dalam praktiknya, masalah *vanishing gradient* dan *exploding gradient* dapat menghambat kemampuannya untuk menyimpan informasi sebelumnya dalam jangka waktu yang lama (Tian dkk., 2018). Fenomena *vanishing gradient* muncul saat jaringan saraf tiruan memiliki lapisan yang banyak dengan *input* yang

panjang sehingga bobot saat proses *backpropagation* menjadi sangat kecil atau hampir hilang sehingga gradien menjadi kecil atau bahkan tidak berfungsi dan terjadilah proses *vanishing gradient*. Sebaliknya, saat bobot pada proses *backpropagation* besar dapat menyebabkan gradien akan sangat besar dan menimbulkan masalah *exploding gradient* (Salehinejad dkk., 2018).

Untuk mengatasi masalah ini, Hochreiter dan Schmidhuber (1997) mengusulkan pengembangan khusus yang dikenal sebagai LSTM, yang dirancang untuk efektif menyimpan informasi sebelumnya dan meningkatkan kinerja RNN secara signifikan. Adapun arsitektur dari RNN diilustrasikan pada Gambar 3 sebagai berikut:



Gambar 3. Arsitektur RNN (Sumber: Zhu dkk., 2019)

Berdasarkan Gambar 1, S_t dan O_t dapat direpresentasikan pada persamaan (2.16) dan (2.17) sebagai berikut (Zhu dkk., 2019):

$$S_t = f((U * X_t) + (W * s_{t-1})) \quad (2.16)$$

$$O_t = g(v * S_t) \quad (2.17)$$

dengan:

S_t : memori jaringan pada waktu ke- t

X_t dan O_t : *input* dan *output* pada waktu ke- t

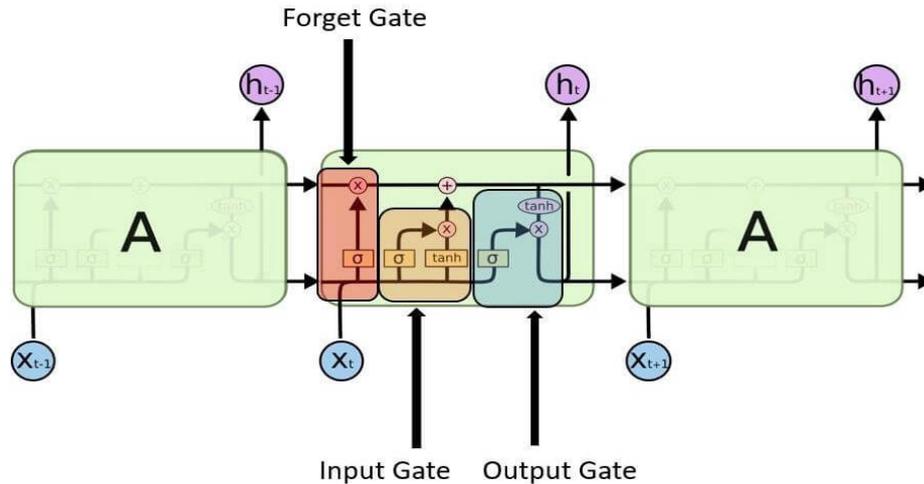
U , V , dan W : bobot disetiap lapisan

$f(\dots)$ dan $g(\dots)$: fungsi *non-linear*

2.15.2 Long Short-Term Memory (LSTM)

Hochreiter dan Schmidhuber mengusulkan LSTM pada tahun 1997 yang merupakan salah satu pengembangan dari RNN. Model LSTM dikembangkan untuk melengkapi kekurangan RNN yang tidak mampu memproses data jangka panjang (Tian dkk., 2018). Model RNN juga memiliki kelemahan pada saat pemrosesan data sekuensial jangka panjang, RNN tidak dapat menghubungkan informasi baru dengan informasi lama karena memori lama yang tersimpan akan semakin tidak berguna dan tertimpa dengan memori yang baru, sedangkan LSTM mampu mengatasi masalah tersebut karena dapat mengatur memori pada setiap *input*-nya dengan menggunakan *cell state* dan *hidden state* (Arfan dan Lusiana, 2019).

Perbedaan struktur LSTM dan RNN terdapat pada lapisan tersembunyi. Pada RNN hanya terdiri dari satu lapisan sederhana dengan fungsi aktivasi *tanh*, sedangkan LSTM terdiri dari dua fungsi aktivasi yakni fungsi aktivasi *tanh* dan fungsi aktivasi *sigmoid* (Felix dkk., 2000). *Long Short-Term Memory* terdapat tiga jenis gerbang yaitu gerbang *forget*, gerbang *input*, dan gerbang *output*. Masing-masing gerbang memiliki peran untuk melindungi dan mengontrol *cell state*. *Cell state* merupakan garis horizontal yang menghubungkan semua lapisan *output* pada LSTM (Tian dkk., 2018). Arsitektur LSTM diilustrasikan pada Gambar 4 sebagai berikut:



Gambar 4. Arsitektur LSTM (Sumber: Usmani dkk., 2021)

Pada Gambar 4 menampilkan ilustrasi dari lapisan tersembunyi LSTM yaitu disebut *memory cell*. *Memory cell* pada LSTM bertugas untuk menyimpan sebuah nilai atau hasil baik dalam periode waktu yang panjang ataupun singkat. Berikut ini merupakan penjelasan untuk setiap gerbang yang ada pada satu *memory cell* LSTM.

1. Gerbang *Forget* (f_t)

Gerbang *Forget* (f_t) merupakan gerbang pertama yang dilalui pada *memory cell* LSTM. Gerbang ini menentukan apakah informasi dari *input* sel x_t dan *output* h_{t-1} layak lewat atau tidak. Lapisan neuron *sigmoid* akan membuat keputusan pada nilai *input* mana yang harus dilewati dan menghasilkan f_t . Pada *output*-nya, mendekati 1 artinya “biarkan lewat” sedangkan 0 artinya “lupakan atau abaikan informasi ini”. Gerbang *Forget* berfungsi untuk merekam seberapa banyak sel C_{t-1} dari waktu sebelumnya dicadangkan ke status sel C_t dari waktu saat ini. Gerbang akan memunculkan nilai antara 0 hingga 1 berdasarkan pada h_{t-1} dan x_t (Nugroho dkk., 2021). Persamaan gerbang *forget* dapat dituliskan pada persamaan (2.18) sebagai berikut:

$$f_t = \sigma(W_f \cdot x_t + W_f \cdot h_{t-1} + b_f) \quad (2.18)$$

dengan:

- f_t : gerbang *forget*
- σ : fungsi *sigmoid*
- W_f : nilai bobot untuk gerbang *forget*

h_{t-1} : nilai *output* sebelum orde ke- t
 x_t : nilai *input* pada order ke- t
 b_f : nilai bias pada gerbang *forget*

2. Gerbang *Input* (i_t)

Gerbang *Input* (i_t) merupakan gerbang yang memiliki *input* dengan fungsi aktivasi (*sigmoid* dan *tanh*) yang akan memilih nilai-nilai *input* yang akan diperbarui. Pertama, lapisan neuron *sigmoid* akan memutuskan nilai *input* mana yang akan diperbarui yang menghasilkan i_t dan fungsi aktivasi *tanh* memberikan bobot pada nilai-nilai yang dilewati. Dengan memberikan bobot pada nilai-nilai *input* yang relevan, gerbang *input* dapat menentukan tingkat kepentingan atau relevansi pada sebuah informasi dalam meng-*update* \hat{C}_t untuk ditambahkan ke *cell state*. Tujuan dari gerbang *input* adalah untuk menentukan seberapa banyak *input* saat ini (x_t) yang dicadangkan ke dalam *cell state* (C_t), sehingga dapat mencegah informasi tidak signifikan memasuki *memory cell*. Gerbang *input* mempunyai dua fungsi, yaitu fungsi untuk menemukan *cell state* yang harus diperbarui dan fungsi untuk meng-*update* *cell state* tersebut. Persamaan gerbang *input* dituliskan dengan persamaan (2.19) sebagai berikut:

$$i_t = \sigma(W_i \cdot x_t + W_i \cdot h_{t-1} + b_i) \quad (2.19)$$

dengan:

i_t : gerbang *input*
 σ : fungsi *sigmoid*
 W_i : nilai bobot untuk gerbang *input*
 h_{t-1} : nilai *output* sebelum orde ke- t
 x_i : nilai *input* pada order ke- t
 b_i : nilai bias pada gerbang *input*

Kemudian, untuk fungsi kedua dari *input gate* ialah untuk memperbarui informasi ke dalam *cell state*. *Cell state* yang telah diperbarui (\hat{C}_t) dibuat dari lapisan *tanh* agar dapat mengontrol seberapa banyak informasi baru yang ditambahkan. Persamaan *cell state* yang telah diperbarui ditulis pada persamaan (2.20) sebagai berikut:

$$\hat{C}_t = \tanh(W_c \cdot x_t + W_c \cdot h_{t-1} + b_c) \quad (2.20)$$

dengan:

- \hat{C}_t : nilai baru yang ditambahkan ke *cell state*
- \tanh : fungsi *tanh*
- W_c : nilai bobot untuk *cell state*
- h_{t-1} : nilai *output* sebelum orde ke- t
- x_c : nilai *input* pada order ke- t
- b_c : nilai bias pada *cell state*

Setelah itu *cell state* yang lama akan diperbarui dengan mengalikan *state* lama dengan *forget gate* (f_t) untuk menghapus informasi yang telah ditentukan pada gerbang lapisan *forget* kemudian ditambahkan dengan ($i_t * \hat{C}_t$) yang merupakan nilai baru untuk memperbarui *cell state*, sehingga menghasilkan persamaan *cell state* yang diuraikan pada persamaan (2.21) sebagai berikut:

$$C_t = f_t * C_{t-1} + i_t * \hat{C}_t \quad (2.21)$$

dengan:

- C_t : *cell state*
- f_t : gerbang *forget*
- C_{t-1} : *cell state* sebelum orde ke- t
- i_t : nilai *output* sebelum orde ke- t
- x_t : gerbang *input*
- b_i : nilai baru yang dapat ditambahkan ke *cell state*

3. Gerbang *Output* (O_t)

Gerbang *Output* (O_t) merupakan gerbang terakhir pada LSTM yang berfungsi untuk memutuskan apa yang akan dihasilkan. Pertama menjalankan lapisan neuron *sigmoid* yang menentukan bagian sel apa yang akan dihasilkan pada O_t . Langkah berikutnya mengalikan dengan *cell state* yang telah melewati lapisan neuron *tanh* dan hasilnya akan menjadi h_t dan meneruskan menuju *cell state*, tetapi gerbang inilah yang membedakan C_t dan h_t yang sebenarnya. Persamaan gerbang *output* diformulasikan pada persamaan (2.22) sebagai berikut:

$$O_t = \sigma(W_o \cdot x_t + W_o \cdot h_{t-1} + b_o) \quad (2.22)$$

dengan:

- O_t : gerbang *output*
- σ : fungsi *sigmoid*
- W_o : nilai bobot untuk gerbang *output*
- h_{t-1} : nilai *output* sebelum orde ke- t
- x_o : nilai *input* pada order ke- t
- b_o : nilai bias pada gerbang *output*

Setelah didapatkannya nilai dari gerbang *output* maka *cell state* akan ditempatkan melalui *tanh*. Kemudian mengalikan gerbang *output* dengan lapisan *sigmoid*. Persamaan nilai *output* orde ke- t pada persamaan (2.23) sebagai berikut:

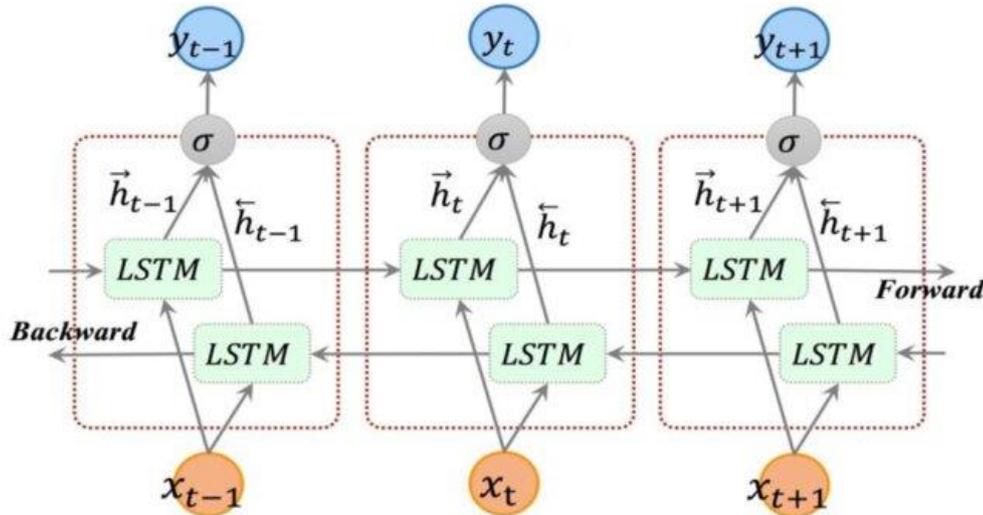
$$h_t = O_t * \tanh(C_t) \quad (2.23)$$

dengan:

- h_t : nilai *output* orde ke- t
- O_t : gerbang *output*
- \tanh : fungsi *tanh*
- C_t : *cell state*

2.15.3 Bidirectional Long Short-Term Memory (Bi-LSTM)

Arsitektur RNN konvensional hanya dapat memanfaatkan konteks sebelumnya dalam satu arah. Pada model RNN dan LSTM, informasi hanya bisa disebarkan ke satu arah, yang berarti bahwa keadaan pada waktu ke- t hanya bergantung pada informasi sebelum waktu ke- t (Yu dkk., 2019). Untuk mengatasi keterbatasan ini, Schuster dan Paliwal (1997) memperkenalkan RNN dua arah (Bi-RNN). Arsitektur ini memungkinkan proses *training* dalam kedua arah waktu secara bersamaan dengan lapisan tersembunyi terpisah untuk lapisan *forward* dan *backward*. Selanjutnya Graves dan Schmidhuber pada tahun 2005, menggabungkan Bi-RNN dengan LSTM dan mengusulkan LSTM dua arah, yaitu Bi-LSTM yang diilustrasikan pada Gambar 5 berikut:



Gambar 5. Arsitektur Bi-LSTM (Sumber: Cui dkk., 2020)

Gambar 5 di atas menggambarkan struktur dari arsitektur Bi-LSTM, yang memiliki lapisan *forward* LSTM dan lapisan *backward* LSTM. Pada *output* lapisan *forward* LSTM (\vec{h}_t), dihitung secara iteratif menggunakan *input* data dalam urutan yang positif, sedangkan *output* lapisan *backward* LSTM (\overleftarrow{h}_t), dihitung secara iteratif dengan menggunakan *input* data dalam urutan yang berkebalikan (Cui, dkk., 2020). *Output* dari lapisan *forward* dan *backward* pada waktu ke- t akan dihubungkan dan selanjutnya informasi akan diproses dengan menggunakan fungsi σ , dimana fungsi tersebut digunakan untuk menggabungkan dua urutan *input* data. Gambar di atas juga menunjukkan bahwa lapisan tersembunyi pada lapisan *forward* dan *backward* akan dihubungkan untuk membentuk nilai *output* dengan perhitungan seperti yang dijelaskan dalam persamaan (2.24) sebagai berikut:

$$y_t = U_y \vec{h}_t + W_y \overleftarrow{h}_t + b_y \quad (2.24)$$

dengan:

y_t : gerbang *output* Bi-LSTM

U_y : nilai bobot untuk gerbang *output* pada \vec{h}_t

\vec{h}_t : nilai *output* pada LSTM *forward*

W_y : nilai bobot untuk gerbang *output* pada \overleftarrow{h}_t

\overleftarrow{h}_t : nilai *output* pada LSTM *backward*

2.16 Hybrid VARIMAX-Bi-LSTM

Metode *hybrid* merupakan strategi penggabungan dua atau lebih metode peramalan yang berbeda untuk menghasilkan prediksi yang lebih akurat dan *robust*. Metode *hybrid* ini memanfaatkan kekuatan dari masing-masing metode secara individual untuk mengatasi keterbatasannya dan meningkatkan kinerja peramalan secara keseluruhan (Dave dkk., 2021). Secara umum, kombinasi model deret waktu yang memiliki struktur autokorelasi *linear* dan *non-linear* dapat dituliskan pada persamaan (2.25) sebagai berikut (Zhang, 2003):

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

dengan:

- y_t : data pengamatan deret waktu ke- t
- L_t : komponen linear ke- t
- N_t : komponen *non-linear* ke- t
- t : indeks waktu

Metode VARIMAX dan Bi-LSTM memiliki kelemahan dan kelebihan masing-masing dalam memproses hasil peramalan. VARIMAX mengalami kesulitan saat menemui deret waktu *non-linear*. Sedangkan Bi-LSTM mampu menangkap pola *non-linear* tersebut dalam kumpulan data (Caliwag dan Lim, 2019). Namun, diperlukan sejumlah data besar untuk mempelajari pola *non-linear* dalam kumpulan data sehingga Bi-LSTM saja tidak mampu menangani pola *linear* dan *non-linear* secara bersamaan sehingga berdasarkan fenomena tersebut maka metode *hybrid* dapat diterapkan.

Kedua komponen yang disebutkan pada persamaan (2.25) digunakan untuk meramalkan data. Pertama, digunakan VARIMAX untuk meramalkan data sebagai komponen *linear*. Kedua, *residual* dari model *linear* digunakan sebagai komponen *non-linear* (Zhang, 2003). Misalkan e_t menunjukkan *residual* pada model *linear* saat waktu ke- t , maka:

$$e_t = y_t - L_t' \quad (2.26)$$

dengan:

y_t : data pengamatan deret waktu ke- t

L'_t : nilai peramalan dari komponen *linear* ke- t

e_t : data *residual* deret waktu ke- t

t : indeks waktu

Persamaan peramalan *hybrid* merupakan kombinasi dari dua komponen yang dapat dituliskan pada persamaan (2.27) sebagai berikut (Zhang, 2003):

$$y'_t = L'_t + N'_t \quad (2.27)$$

dengan:

y'_t : nilai peramalan dari model *hybrid* ke- t

L'_t : nilai peramalan dari komponen *linear* ke- t

N'_t : nilai peramalan dari komponen *non-linear* ke- t

t : indeks waktu

Pemodelan *hybrid* memiliki dua tahapan. Pertama, model VARIMAX digunakan untuk meramalkan komponen *linear*. Kedua, model Bi-LSTM digunakan untuk memodelkan *residual* dari model VARIMAX. Hasil Bi-LSTM dapat digunakan untuk meramalkan *residual* pada model VARIMAX. Selanjutnya dapat menggunakan kedua komponen tersebut untuk melakukan prediksi dan peramalan model *hybrid*.

2.17 Evaluasi Model

Evaluasi model digunakan untuk menentukan apakah model yang digunakan baik atau tidak dalam menangani kumpulan data tersebut. Akurasi merupakan parameter yang dapat digunakan untuk mengukur seberapa baik sebuah model yang telah dibangun. Menurut Temur dkk. (2019), untuk mengevaluasi ketepatan model dapat menggunakan metode, yaitu *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE).

2.17.1 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error digunakan untuk mengetahui persentase hasil pendugaan terhadap hasil aktual. Nilai MAPE merupakan rata-rata kesalahan mutlak selama periode tertentu yang kemudian dikalikan dengan 100% agar mendapatkan hasil persentase (Pertiwi dkk., 2021). Bentuk umum persamaan (2.28) digunakan untuk menghitung (MAPE) sebagai berikut:

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

dengan:

- n : banyaknya data yang diamati
- Y_t : nilai data aktual pada periode ke- t
- \hat{Y}_t : nilai data hasil peramalan pada periode ke- t

2.17.2 Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) merupakan nilai akar kuadrat dari selisih nilai prediksi dengan nilai data aktual (Temur dkk., 2019). Hasil RMSE menunjukkan seberapa jauh nilai akar kuadrat dari nilai asli dan nilai prediksi model. Bentuk umum persamaan (2.29) digunakan untuk menghitung RMSE sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n}} \quad (2.29)$$

dengan:

- n : banyaknya data yang diamati
- Y_t : nilai data aktual pada periode ke- t
- \hat{Y}_t : nilai data hasil peramalan pada periode ke- t

2.18 Uji T^2 Hotelling

Uji T^2 Hotelling adalah salah satu metode statistik yang digunakan untuk membandingkan rata-rata dua populasi dalam analisis multivariat. Uji ini merupakan generalisasi dari uji T Student untuk kasus data multivariat. Uji T^2 Hotelling digunakan untuk menguji hipotesis nol bahwa dua vektor rata-rata populasi multivariat adalah sama (Johnson dan Wichern, 2007). Secara formal uji hipotesis nol tersebut dapat dinyatakan sebagai berikut:

$$H_0 : \mu_1 = \mu_2$$

dengan μ_1 dan μ_2 adalah vektor rata-rata dari dua populasi. Hipotesis alternatifnya adalah bahwa vektor rata-rata tidak sama dan dinyatakan sebagai berikut:

$$H_1 : \mu_1 \neq \mu_2$$

Menurut Johnson dan Wichern (2007), bentuk umum persamaan Uji T^2 Hotelling didasarkan pada statistik T^2 yang didefinisikan pada persamaan (2.30) sebagai berikut:

$$T^2 = \frac{n_1 \cdot n_2}{n_1 + n_2} (\bar{X}_1 - \bar{X}_2)^T S_p^{-1} (\bar{X}_1 - \bar{X}_2) \quad (2.30)$$

dengan :

\bar{X}_1 : vektor rata-rata sampel dari populas pertama

\bar{X}_2 : vektor rata-rata sampel dari populasi kedua

n_1 : ukuran sampel populasi pertama

n_2 : ukuran sampel populasi kedua

S_p : matriks kovarian gabungan

pada persamaan (2.30) bahwa S_p dituliskan pada persamaan (2.31) sebagai berikut:

$$S_p = \frac{(n_1 - 1)S_1 + (n_2 - 1)S_2}{n_1 + n_2 - 2} \quad (2.31)$$

dengan:

n_1 : ukuran sampel populasi pertama

- n_2 : ukuran sampel populasi kedua
- S_1 : matriks kovarian sampel populasi pertama
- S_2 : matriks kovarian sampel populasi kedua

Di bawah hipotesis nol, statistik T^2 Hotelling mengikuti distribusi F dengan derajat kebebasan p dan $n_1 + n_2 - p - 1$, dengan p adalah dimensi dari vektor rata-rata. Distribusi ini digunakan untuk menentukan nilai kritis dan p -value dalam uji hipotesis yang ditunjukkan pada persamaan (2.32) sebagai berikut:

$$F = \frac{(n_1 + n_2 - p - 1)T^2}{p(n_1 + n_2 - 2)} \quad (2.32)$$

dengan:

- n_1 : ukuran sampel populasi pertama
- n_2 : ukuran sampel populasi kedua
- p : dimensi vektor rata-rata
- T^2 : statistik T^2 Hotelling

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini mulai dilaksanakan pada Semester Ganjil tahun akademik 2023/2024, meliputi tiga tahapan penelitian dengan periode waktu di setiap tahapannya. Tahap pertama meliputi studi literatur dan penentuan tema penelitian, pengumpulan data, penyusunan bab 1-3, dan seminar proposal dengan periode waktu mulai dari bulan September tahun 2023 sampai dengan Januari tahun 2024. Tahap kedua meliputi melakukan *explanatory data analysis*, melakukan *preprocessing data*, melakukan pemodelan VARIMAX, melakukan *hyperparameter tuning* model Bi-LSTM dan model *hybrid* VARIMAX – Bi-LSTM dengan periode waktu mulai dari bulan Januari sampai dengan Mei tahun 2024. Tahap ketiga meliputi penyusunan bab 4-5, seminar hasil penelitian dan sidang komprehensif dengan periode waktu mulai dari bulan Januari sampai dengan Juni tahun 2024.

3.2 Spesifikasi Perangkat

1. Perangkat Keras (*Hardware*)

Perangkat yang digunakan dalam melakukan penelitian ini adalah menggunakan laptop dengan merek Lenovo Legion 5 15ITH6 dengan tipe *64-bit operating system, x64-based processor*. Spesifikasi *hardware* perangkat adalah sebagai berikut:

Processor : Intel(R) Core(TM) i7-11800H @ 2.30GHz 2.30 GHz

Memori : SSD 512 GB

RAM : 16 GB

2. Perangkat Lunak (*Software*)

Perangkat lunak yang digunakan adalah bahasa pemrograman dengan basis *open source*, yaitu *python* (3.10.9). Dengan menggunakan *library* sebagai berikut:

- a. *numpy* (1.26.4)
- b. *pandas* (1.5.3)
- c. *scikit-learn* (1.3.0)
- d. *seaborn* (0.12.0)
- e. *statsmodels* (0.14.0)
- f. *tensorflow* (2.12.0)
- g. *torch* (1.12.1)
- h. *scipy* (1.11.4)

3.3 Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder, yaitu data historis harga harian emas dan perak sebagai peubah endogen, dan data historis nilai tukar rupiah terhadap USD, indeks USD dan indeks S&P 500 sebagai peubah eksogen. Rentang periode data yang digunakan adalah 2 Januari 2013 sampai dengan 29 Desember 2023 yang diperoleh dari *website* <https://id.investing.com/> dengan masing-masing jumlah data sebanyak 2771 data.

Y_1 : data historis harga harian emas

Y_2 : data historis harga harian perak

X_1 : data historis indeks USD

X_2 : data historis nilai tukar Rupiah terhadap USD

X_3 : data historis indeks S&P 500

Tabel 2. Data Penelitian

Periode	Harga Emas (\$US/ Troy Ons)	Harga Perak (\$US/ Troy Ons)	Indeks Dolar (Poin)	Nilai Tukar (\$US/ Rp)	S&P 500 (\$US/ Lembar)
02/01/2012	1688,8	31,007	79,948	9650,0	1457,00
03/01/2012	1674,6	30,720	80,515	9655,0	1453,50
04/01/2012	1648,9	29,946	80,610	9660,0	1457,75
⋮	⋮	⋮	⋮	⋮	⋮
27/12/2023	2083,4	24,570	100,654	15425,0	4833,50
28/12/2023	2083,5	24,372	100,913	15415,0	4832,25
29/12/2023	2071,8	24,025	101,029	15395,0	4820,00

Harga emas dan perak digunakan sebagai peubah endogen karena nilai kedua variabel ini secara langsung dipengaruhi oleh peubah eksogen. Nilai tukar rupiah terhadap USD, indeks USD, dan indeks S&P 500 sebagai peubah eksogen karena nilai dari ketiga variabel ini secara tidak langsung mempengaruhi peubah endogen.

3.4 Metode Penelitian

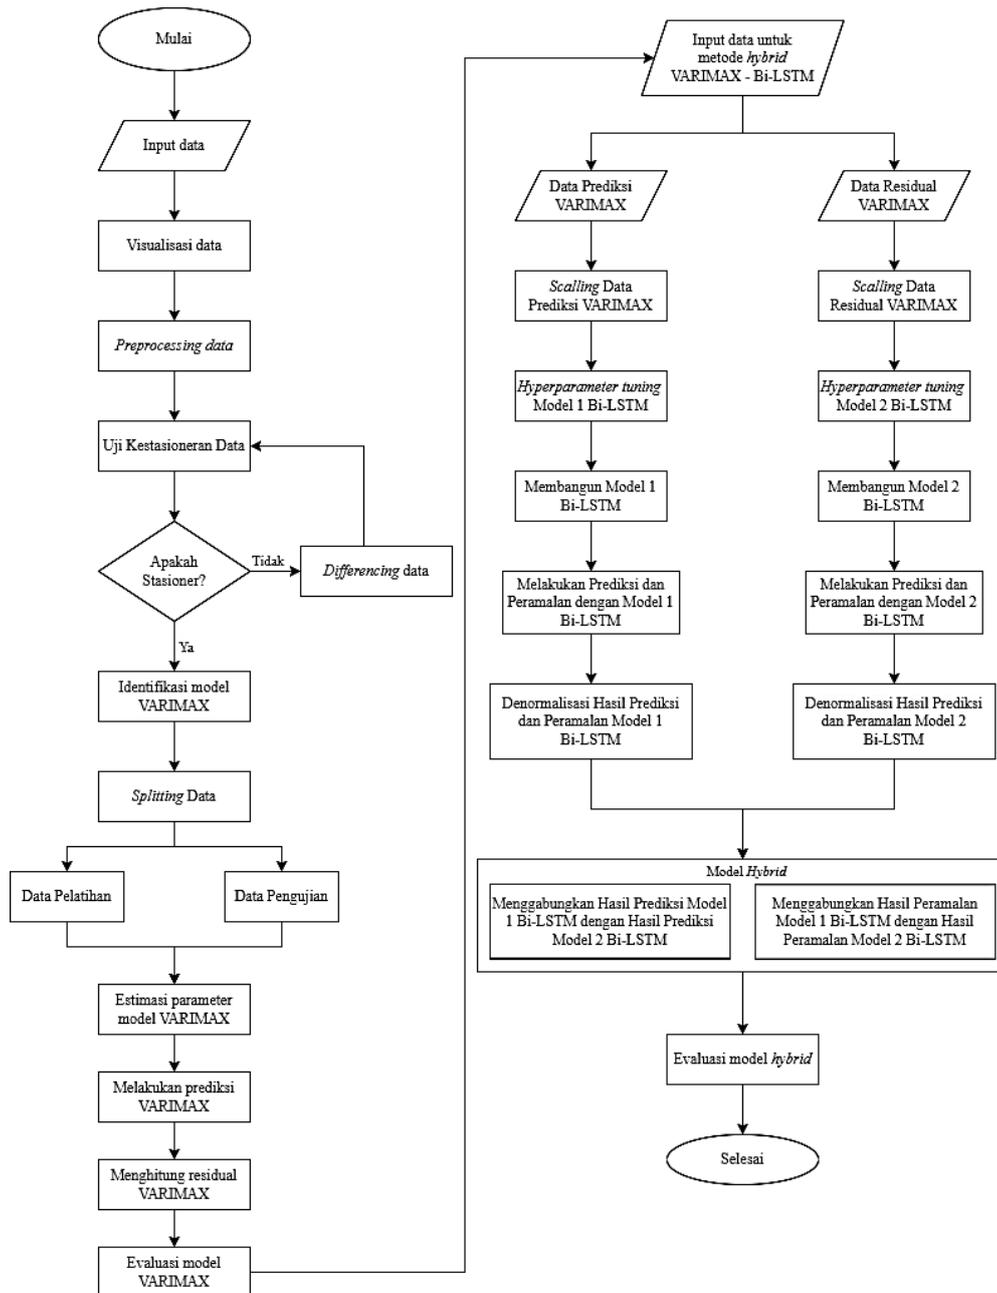
Langkah-langkah yang dilakukan dalam melakukan peramalan menggunakan *hybrid VARIMAX – Bi-LSTM* adalah sebagai berikut:

1. Melakukan studi literatur mengenai metode *hybrid VARIMAX – Bi-LSTM* yang diambil dari artikel, jurnal dan buku tentang metode *hybrid VARIMAX – Bi-LSTM*.
2. Mencari dan mengumpulkan data historis harga harian emas dan perak serta data historis variabel eksogen.
3. Meng-*input* data penelitian ke dalam perangkat lunak Python.
4. Melakukan visualisasi data dengan melihat tren dan pola dalam data.
5. Melakukan *preprocessing data*, yaitu menangani data hilang dan menghilangkan duplikasi dalam kumpulan data.
6. Melakukan uji kestasioneritasan data dengan menggunakan uji *Augmented Dickey-Fuller (ADF)*. Jika data tidak stasioner maka perlu dilakukan proses *differencing*.

7. Setelah data stasioner, kemudian menentukan model VARIMAX yang memiliki orde p , d , q yang dapat dilihat pada plot ACF, PACF, dan proses *differencing* serta memasukkan variabel eksogen kedalam model VARIMAX.
8. Melakukan *splitting* terhadap kumpulan data menjadi data pelatihan dan data pengujian dengan dua skema pembagian, yaitu 90% data pelatihan, 10% data pengujian dan 80% data pelatihan, 10% data pengujian.
9. Melakukan estimasi parameter model VARIMAX untuk mengetahui apakah model sudah cukup baik untuk digunakan dalam prediksi dan peramalan.
10. Menentukan model VARIMAX terbaik berdasarkan nilai BIC terkecil.
11. Berdasarkan model VARIMAX terbaik yang telah dipilih, kemudian dilakukan prediksi menggunakan data pelatihan.
12. Melakukan peramalan pada model VARIMAX menggunakan data pengujian.
13. Menghitung nilai residual dengan cara mengurangi data aktual dari harga historis emas dan perak dengan data hasil prediksi yang diperoleh dari metode VARIMAX yang telah dilakukan *undifferencing*.
14. Menghitung akurasi pada model VARIMAX.
15. Melakukan *input* data prediksi dan residual dari model VARIMAX sebagai data *input* untuk metode Bi-LSTM.
16. Melakukan *scaling* data, yaitu dengan melakukan normalisasi pada data prediksi dan residual VARIMAX dengan menggunakan *minmaxscaler*.
17. Membangun model *hybrid* Bi-LSTM pertama dengan data prediksi model VARIMAX dan model *hybrid* Bi-LSTM kedua dengan data residual model VARIMAX menggunakan parameter terbaik yang telah didapatkan dari proses *hyperparameter tuning*.
18. Melakukan prediksi dan peramalan model Bi-LSTM pertama dengan menggunakan data prediksi model VARIMAX.
19. Melakukan prediksi dan peramalan model Bi-LSTM kedua dengan menggunakan data residual model VARIMAX.
20. Melakukan denormalisasi data pada data prediksi dan peramalan model *hybrid* Bi-LSTM pertama.
21. Melakukan denormalisasi data pada data prediksi dan peramalan model *hybrid* Bi-LSTM kedua.

22. Menggabungkan hasil prediksi dan peramalan kedua model Bi-LSTM dengan proses penjumlahan.
23. Melakukan evaluasi model dengan menghitung akurasi model *hybrid* VARIMAX – Bi-LSTM berdasarkan nilai MAPE dan RMSE.

Berikut merupakan gambar *flowchart* peramalan metode *hybrid* VARIMAX – Bi-LSTM:



Gambar 6. *Flowchart* peramalan metode *hybrid* VARIMAX – Bi-LSTM

V. KESIMPULAN

Berdasarkan hasil dari pembahasan mengenai peramalan harga emas dan perak berjangka dengan menggunakan metode *hybrid* VARIMAX – Bi-LSTM dapat diperoleh kesimpulan sebagai berikut.

1. Model *hybrid* VARIMAX – Bi-LSTM dibangun dengan menggabungkan model Bi-LSTM pertama dengan data prediksi model VARIMAX dan model Bi-LSTM kedua dengan data residual model VARIMAX sebagai data *input*. Model Bi-LSTM pertama dan model Bi-LSTM kedua dibangun dengan menggunakan kombinasi parameter terbaik, yaitu jumlah *Bi-LSTM Unit*, *Dense Unit*, *Batch size*, dan *dropout* yang diperoleh dengan melakukan proses *hyperparameter tuning* dengan rincian sebagai berikut:
 - a. Untuk model Bi-LSTM pertama dengan data input prediksi VARIMAX kombinasi parameter terbaik yang diperoleh dari jumlah *Bi-LSTM Unit*, *Dense Unit*, dan *Batch size* menggunakan model dengan pembagian 80% data pelatihan dan 20% data pengujian, yaitu 64 *Bi-LSTM Unit*, 256 *Dense Unit*, dan 8 *Batch size* serta untuk model dengan pembagian 90% data pelatihan dan 10% data pengujian, yaitu 256 *Bi-LSTM Unit*, 256 *Dense Unit*, dan 8 *Batch size*.
 - b. Untuk model Bi-LSTM kedua dengan data input residual VARIMAX kombinasi parameter terbaik yang diperoleh dari jumlah *Bi-LSTM Unit*, *Dense Unit*, *Batch size*, dan *dropout* menggunakan model dengan pembagian 80% data pelatihan dan 20% data pengujian, yaitu 128 *Bi-LSTM Unit*, 128 *Dense Unit*, 16 *Batch size*, dan 0.1 *dropout* serta untuk model dengan pembagian 90% data pelatihan dan 10% data pengujian, yaitu 128 *Bi-LSTM Unit*, 64 *Dense Unit*, 16 *Batch size*, dan 0.1 *dropout*.

2. Metode *hybrid* VARIMAX – Bi-LSTM merupakan metode yang cukup baik untuk digunakan melakukan prediksi maupun peramalan untuk data harga emas dan perak berjangka karena menghasilkan nilai RMSE, MAPE yang rendah dan tingkat akurasi yang tinggi. Model *hybrid* dengan pembagian 80% data pelatihan dan 20% data pengujian menghasilkan nilai RMSE sebesar 20,2269 dan MAPE sebesar 0,0182. Sedangkan model *hybrid* dengan pembagian 90% data pelatihan dan 10% data pengujian menghasilkan nilai RMSE sebesar 15,6181 dan MAPE sebesar 0,0099. Berdasarkan hal tersebut dapat disimpulkan bahwa model *hybrid* dengan pembagian 90% data pelatihan dan 10% data pengujian memiliki tingkat akurasi lebih tinggi dibandingkan dengan model *hybrid* dengan membagi 80% data pelatihan dan 20% data pengujian.
3. Hasil peramalan yang diperoleh selama 30 periode ke depan (1 Januari sampai dengan 9 Februari 2024) dengan menggunakan metode *hybrid* VARIMAX – Bi-LSTM dengan skema pembagian data 90% data pelatihan 10% data pengujian menghasilkan nilai peramalan paling baik dibandingkan dengan model *hybrid* VARIMAX–Bi-LSTM menggunakan 80% data pelatihan 20% data pengujian maupun dengan menggunakan model VARIMAX serta Bi-LSTM.

DAFTAR PUSTAKA

- Aldi, M.W.P., Jondri, J., dan Aditsania, A. 2018. Analisis dan Implementasi Long Short Term Memory Neural Network untuk Prediksi Harga Bitcoin. *eProceedings of Engineering* **5**(2): 3548–3555.
- Ambarwari, A., Adrian, Q.J., dan Herdiyeni, Y. 2020. Analysis of the effect of data scaling on the performance of the machine learning algorithm for plant identification. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)* **4**(1): 117–22.
- Arfan, A. dan Lusiana, E.T.P 2019. Prediksi harga saham di Indonesia menggunakan algoritma long short-term memory. *Prosiding Seminar Nasional Teknologi Informasi dan Komunikasi* **3**(1): 225–230.
- Arissinta, I.O., Sulistiyawati, I.D., Kurnianto, D. 2022. Pemodelan *Time Series* untuk Peramalan *Web Traffic* Menggunakan Algoritma Arima, LSTM, dan GRU. *Prosiding Seminar Nasional Matematika*. 693–700
- Auliasari, K., Kertaningtyas, M., dan Kriswantono, M. 2019. Penerapan metode peramalan untuk identifikasi potensi permintaan konsumen. *Informatics Journal* **4**(3): 121–129.
- Box, G.E.P., Jenkins, G.M., Reinsel, G.C., dan Ljung, G.M. 2015. *Time Series Analysis Forecasting and Control*. 5th Edition. John Wiley & Sons, New Jersey.
- Caliwag, A.C., dan Lim, W. 2019. Hybrid VARMA and LSTM method for lithium-ion battery state-of-charge and output voltage forecasting in electric motorcycle applications. *IEEE Access* **7**(10): 80–89.
- Cui, Z., Ke, R., Pu, Z., dan Wang, Y. 2020. Stacked Bidirectional and Undirectional LSTM Recurrent Neural Network for Network-wide Traffic State with Missing Values. *Transportation Research Part C: Emerging Technologies* **118**.
- Choudhury, N. A., & Soni, B. 2023. An Adaptive Batch Size based-CNN-LSTM Framework for Human Activity Recognition in Uncontrolled Environment. *IEEE Transactions on Industrial Informatics*. **19**(10): 10379 –10387.

- Dave, E., Leonardo, A., Jeanice, M., dan Hanafiah, N. 2021. Forecasting Indonesia exports using a hybrid model ARIMA-LSTM. *Procedia Computer Science*. **179**: 480–487.
- Felix, A.G., Schmidhuber, J., dan Cummins, F. 2000. Learning to forget: Continual prediction with LSTM. *Neural computation*. **12**(10): 2451–2471.
- Graves, A., dan Schmidhuber, J. 2005. Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural networks*. **18**(5–6): 602–610.
- Hamilton, J.D. 1994. *Time Series Analysis*. Princeton University Press, New Jersey.
- Hikmaturokhman, A., Nafi'ah, H., dan Larasati, S. 2022. Deep Learning Algorithm Models for Spam Identification on Cellular Short Message Service. *Journal of Communications*. **17**(9): 769–776.
- Hochreiter, S., dan Schmidhuber J. 1997. Long short-term memory. *Neural computation*. **9**(8): 1735–1780.
- Johnson, R.A., dan Wichern, D.W. 2007. *Applied Multivariate Statistical Analysis*. 6th Edition. Pearson Prentice Hall.
- Karno, A.S.B. 2020. Prediksi Data Time Series Saham Bank BRI Dengan Mesin Belajar LSTM (Long ShortTerm Memory). *Journal of Informatic and Information Security*. **1**(1): 1–8.
- Kurniawan, A.S. 2018. Implementasi Metode Artificial Neural Network Dalam Memprediksi Hasil Ujian Kompetensi Kebidanan (Studi Kasus Di Akademi Kebidanan Dehasen Bengkulu). *Jurnal Pseudocode*. **5**(1): 37–44.
- Makridakis, S., Wheelwright, S.C. dan McGee, V.E. 1999. *Metode dan Aplikasi Peramalan*. Edisi Ke-2. Jakarta : Binarupa Aksara.
- Montgomery, D.C., Jennings, C.L, dan Kulahci, M. 2015. *Introduction to time series analysis and forecasting*. 2nd Edition. John Wiley & Sons.
- Namini, S.S., Tavakoli, N., & Namin, A.S. 2018. A Comparison of ARIMA and LSTM in Forecasting Time Series. *IEEE International Conference on Machine Learning and Applications*. 1394-1401.
- Nurfadilah, K., dan Kasse, I. 2018. Peramalan Tingkat Suku Bunga Pasar Uang Antar Bank (PUAB) Dengan Vector Autoregressive Exogenous (VARX). *Jurnal Matematika dan Statistika serta Aplikasinya*. **6**(1): 51 –60.

- Nwankpa, C.E., Ijomah, W., Gachagan, A., dan Marshall, S. 2018. Activation functions: Comparison of trends in practice and research for deep learning. *Open Journal of Statistics*. **1**(1): 1–20
- Pasaribu, D.J.M., Kusriani, K., dan Sudarman, S. 2020. Peningkatan Akurasi Klasifikasi Sentimen Ulasan Makanan Amazon dengan Bidirectional LSTM dan BERT Embedding. *Jurnal Teknologi Informasi dan Komunikasi*. **10**(1): 9-20.
- Pertiwi, A., Dewi, L.F., Toharudin, T. dan 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.
- Puteri, D.I. 2023. Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah. *Euler: Jurnal Ilmiah Matematika, Sains dan Teknologi*. **11**(1): 35–43.
- Robinson, Z. 2023. A macroeconomic viewpoint using a structural VAR analysis of silver price behaviour. *Mineral Economics*. **37**(1): 15–23.
- Rowan, R., Muflikhah, L. dan Cholissodin, M. 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.
- Rusul, A., Hussein, D., dan Tsai, P. 2021. Unidirectional and Bidirectional LSTM Models for Short-Term Traffic Prediction. *Journal of Advanced Transportation* **5**(4): 1–16.
- Rusyana, A., Tatsara, N., Balqis, R., dan Rahmi, S. 2020. Application of Clustering and VARIMA for Rainfall Prediction. *IOP Conference Series: Materials Science and Engineering*. **796**(1).
- Salehinejad, H., Sankar, S., Barfett, J., Colak, E., dan Valaee, S. 2018. Recent Advance in Recurrent Neural Network. *Computer Research Repository*. 1–21.
- Schuster, M., dan Paliwal, K.K.. 1997. Bidirectional Recurrent Neural Networks. *IEEE transactions on Signal Processing* **45**(11): 2673–81.
- Siegel, A.F. 2016. *Practical business statistics*. Academic Press.
- Solikin, dan Suseno. 2002. *Uang : Pengertian, Penciptaan, dan Peranannya Dalam Perekonomian*. Seri Kebanksentralan Ke-1. Jakarta : Bank Indonesia Institute.

- Staudemeyer, R.C., dan Morris, E.R. 2019. Understanding LSTM-a tutorial into long short-term memory recurrent neural networks. *Computer Research Repository*. 1–42.
- Sutthichaimethee, P.. 2017. VARIMAX Model to Forecast the emission of Carbon Dioxide from Energy Consumption in Rubber and Petroleum industries sectors in Thailand. *Journal of Ecological Engineering* **18**(3): 112–17.
- Temur, A.S., Akgun, M., dan Temur, G. 2019. Predicting Housing Sales in Turkey Using ARIMA, LSTM, and Hybrid Models. *Journal of Business Economics and Management*. **20**(5): 920-928.
- Tejoyadav, M., Rashmiranjan, N., dan Pati, U.C. 2022. Multivariate Water Quality Forecasting of River Ganga Using VAR-LSTM based Hybrid Model. In *2022 IEEE 19th India Council Internasional Conference (INDICON)*. 1-6.
- Tian, C., Ma, J., Zhang, C., dan Zhan, P. 2018. A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network. *Energies*. **11**(12): 3493–3500.
- Usmani, R.S.A, Pillai, T.R., Hashem, I.A.T, dan Marjani, M. 2021. Air Polution and Cardiorespiratory Hospitalization, Predictive Modeling, and Analysis Using Artificial Intellingence Techniques. *Enviromental Science and Pollution Research*. **28**(40): 56759–56771.
- Varsha, M., Poornima, B. Mp, P.K. dan Basavarajappa, S. 2022. Novel Hybrid ARIMA-BiLSTM Model for Forecasting of Rice Blast Disease Outbreaks for Sustainable Rice Production. *Iran Journal of Computer Science*. **5**(2): 119–132.
- Wei, W.W.S. 2006. *Time Series Analysis Univariate and Multivariate Methods*. Second Edition. Pearson Education, Inc. Bonston.
- Wiranda, L., dan Sadikin. M. 2019. Penerapan Long Short Term Memory Pada Data Time Series Untuk Memprediksi Penjualan Produk PT. Metiska Farma. *Jurnal Nasional Pendidikan Teknik Informatika*. **8**(3): 184-196.
- Yin, C., Zhu, Y., Fei, J. dan He, X. 2017. A deep learning approach for intrusion detection using recurrent neural networks. *IEEE Access* **5**(29): 54–61.
- Yu, Y., Si, X., Hu, C., dan Zhang, J.. 2019. A review of recurrent neural networks: LSTM cells and network architectures. *Neural computation* **31**(7): 1235–70.
- Zahra, B., dan Lazaar, M. 2019. Integration of Principal Component Analysis and Recurrent Neural Network to Forecast the Stock Price of Casablanca Stock Exchange. *Procedia Computer Science* **148**: 55–61.

- Zhang, G.P. 2003. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing* **50**: 159–75
- Zhu, J., Yang, Z., Guo, Y., Zhang, J., dan Yang, H. 2019. Short-term load forecasting for electric vehicle charging stations based on deep learning approaches. *Applied sciences* **9**(9): 1723.