

**ANALISIS PERBANDINGAN METODE *LSTM* DAN *BILSTM*
UNTUK PREDIKSI HARGA SAHAM MENGGUNAKAN
*ALPHA VANTAGE API***

SKRIPSI

DISUSUN OLEH

RIFQI YAFIK

NPM. 2109020044



**PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
MEDAN
2025**

**ANALISIS PERBANDINGAN METODE *LSTM* DAN *BILSTM*
UNTUK PREDIKSI HARGA SAHAM MENGGUNAKAN
*ALPHA VANTAGE API***

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer
(S.Kom) dalam Program Studi Teknologi Informasi pada Fakultas Ilmu
Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara**

**RIFQI YAFIK
NPM. 2109020044**

**PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
MEDAN
2025**

LEMBAR PENGESAHAN

LEMBAR PENGESAHAN

Judul Skripsi : Analisis Perbandingan Metode *Lstm* Dan *Bilstm* Untuk
Prediksi Harga Saham Menggunakan *Alpha Vantage Api*
Nama Mahasiswa : Rifqi Yafik
NPM : 2109020044
Program Studi : Teknologi Informasi

Menyetujui
Komisi Pembimbing



Mulkan Azhari S.Kom., M.Kom.
NIDN. 0108129402

Ketua Program Studi
Teknologi Informasi



Fatma Sari Hutagalung S.Kom., M.Kom.
NIDN. 0117019301

Dekan



Dr. Al-Khwarizmi, S.Kom., M.Kom.
NIDN. 0127099201

PERNYATAAN ORISINALITAS

PERNYATAAN ORISINALITAS

ANALISIS PERBANDINGAN METODE LSTM DAN BILSTM UNTUK PREDIKSI HARGA SAHAM MENGGUNAKAN ALPHA VANTAGE API

SKRIPSI

Saya menyatakan bahwa karya tulis ini adalah hasil karya sendiri, kecuali beberapa kutipan dan ringkasan yang masing-masing disebutkan sumbernya.

Medan, 16 Juli 2025

Yang membuat pernyataan



Rifqi Yafik

NPM. 2109020044

**PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN
AKADEMIS**

Sebagai sivitas akademika Universitas Muhammadiyah Sumatera Utara, saya bertanda tangan dibawah ini:

Nama	: Rifqi Yafik
NPM	: 2109020044
Program Studi	: Teknologi Informasi
Karya Ilmiah	: Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bedas Royalti Non-Eksekutif (*Non-Exclusive Royalty free Right*) atas penelitian skripsi saya yang berjudul:

**ANALISIS PERBANDINGAN METODE *LSTM* DAN *BILSTM*
UNTUK PREDIKSI HARGA SAHAM MENGGUNAKAN
*ALPHA VANTAGE API***

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non-Eksekutif ini, Universitas Muhammadiyah Sumatera Utara berhak menyimpan, mengalih media, memformat, mengelola dalam bentuk database, merawat dan mempublikasikan Skripsi saya ini tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis dan sebagai pemegang dan atau sebagai pemilik hak cipta.

Demikian pernyataan ini dibuat dengan sebenarnya.

Medan, 16 Juli 2025

Yang membuat pernyataan



Rifqi Yafik

NPM. 2109020044

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap	: Rifqi Yafik
Tempat dan Tanggal Lahir	: Medan, 06 Desember 2003
Alamat Rumah	: Jalan M. Basir Linkungan 30 No. 10
Telepon/Faks/HP	: 082160478546
E-mail	: rifqiyafika50@gmail.com
Instansi Tempat Kerja	: -
Alamat Kantor	: -

DATA PENDIDIKAN

SD	: SD Negeri 067260	TAMAT: 2015
SMP	: SMP Negeri 39 Medan	TAMAT: 2018
SMA	: SMA Negeri 19 Medan	TAMAT: 2021

KATA PENGANTAR



Assalamualaikum Warahmatullahi Wabarakatuh

Alhamdulillah, puji syukur penulis panjatkan ke hadirat Allah SWT atas segala rahmat, karunia, serta nikmat kesehatan dan kesempatan yang telah diberikan, sehingga penulis dapat menyelesaikan penyusunan skripsi ini yang berjudul “Analisis Perbandingan Metode *LSTM* dan *BiLSTM* untuk Prediksi Harga Saham menggunakan *Alpha Vantage API*” sebagai salah satu syarat untuk memperoleh gelar Sarjana pada Program Studi Teknologi Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara.

Penulis menyadari bahwa keberhasilan dalam penyusunan skripsi ini tidak terlepas dari dukungan dan bantuan berbagai pihak. Oleh karena itu, dengan segala kerendahan hati, penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Bapak Prof. Dr. Agussani, M.AP., Rektor Universitas Muhammadiyah Sumatera Utara (UMSU)
2. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom. Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
3. Ibu Fatma Sari Hutagaulung, S.Kom., M.Kom., selaku Ketua Program Studi Teknologi Informasi.
4. Bapak Muhammad Basri, S.Kom., M.Kom., selaku Sekretaris Program Studi Teknologi Informasi.
5. Bapak Mulkan Azhari, S.Kom., M.Kom., selaku dosen pembimbing yang telah dengan penuh kesabaran membimbing, memberikan masukan, arahan, dan motivasi selama proses penyusunan skripsi ini.
6. Seluruh dosen dan staf akademik di lingkungan Fakultas Ilmu Komputer dan Teknologi Informasi, khususnya Program Studi Teknologi Informasi, yang telah memberikan ilmu dan pengalaman berharga selama masa studi.

7. Kedua orang tua tercinta, Bapak Rahmat Sayhputra dan Ibu Ratna Sari Dewi, yang selalu memberikan doa, semangat, cinta, serta dukungan moral dan material tanpa henti.
8. Keluarga Besar Almarhum Basri yang selalu memberikan doa, nasihat, serta dukungan kepada penulis selama proses pendidikan hingga penyusunan skripsi ini.
9. Rekan-rekan seperjuangan di grup “Punyaku-punyaku Grup” yaitu Yoga, Qodri, Anggi, Gatot, Farhan, Ikhsan, dan Mubarton, yang telah menjadi teman diskusi sekaligus motivasi selama menempuh studi di UMSU.
10. Semua pihak yang tidak dapat disebutkan satu per satu yang telah membantu dan memberikan dukungan secara langsung maupun tidak langsung dalam penyelesaian skripsi ini.

Penulis menyadari bahwa skripsi ini masih jauh dari kata sempurna. Oleh karena itu, penulis sangat mengharapkan kritik dan saran yang membangun untuk perbaikan di masa mendatang. Semoga skripsi ini dapat memberikan manfaat bagi pembaca serta menjadi referensi yang berguna, khususnya dalam pengembangan sistem prediksi harga saham berbasis deep learning.

Medan, 16 Juli 2025

Penulis



Rifqi Yafik

ANALISIS PERBANDINGAN METODE *LSTM* DAN *BiLSTM*
UNTUK PREDIKSI HARGA SAHAM MENGGUNAKAN
ALPHA VANTAGE API

ABSTRAK

Pasar saham Indonesia menunjukkan pertumbuhan signifikan dengan meningkatnya jumlah investor, namun fluktuasi harga saham yang tinggi masih menjadi tantangan besar dalam pengambilan keputusan investasi. Prediksi harga saham menjadi upaya penting untuk meminimalkan risiko dan meningkatkan akurasi strategi investasi. Penelitian ini bertujuan untuk membandingkan performa dua metode deep learning, yaitu Long Short-Term Memory (LSTM) dan Bidirectional LSTM (BiLSTM), dalam memprediksi harga saham harian dua emiten blue chip Indonesia, yaitu PT Bank Central Asia Tbk (BBCA) dan PT Telkom Indonesia Tbk (TLKM), dengan menggunakan data historis dari Alpha Vantage API periode 2019–2023. Proses preprocessing dilakukan melalui ekstraksi harga penutupan (Close), normalisasi dengan MinMaxScaler, serta pembentukan sliding window untuk data time series. Model LSTM dan BiLSTM kemudian dilatih dan diuji menggunakan framework TensorFlow-Keras, dengan tuning hyperparameter melalui pendekatan Grid Search terhadap kombinasi jumlah neuron, batch size, epoch, dan dropout rate. Evaluasi dilakukan menggunakan tiga metrik utama, yaitu Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Hasil menunjukkan bahwa BiLSTM memberikan akurasi prediksi yang lebih tinggi dibandingkan LSTM pada kedua saham yang diuji, terutama karena kemampuannya membaca urutan data dua arah. Penelitian ini memberikan kontribusi terhadap pengembangan model prediksi saham berbasis deep learning yang lebih akurat dan sistematis, serta dapat direplikasi oleh peneliti maupun praktisi pasar modal lainnya.

Kata Kunci: Prediksi Harga Saham, LSTM, BiLSTM, Alpha Vantage API, Grid Search.

COMPARATIVE ANALYSIS OF LSTM AND BiLSTM METHODS FOR STOCK PRICE PREDICTION USING ALPHA VANTAGE API

ABSTRACT

The Indonesian stock market has shown significant growth in recent years, marked by a rising number of investors. However, the high volatility of stock prices remains a major challenge in investment decision-making. Stock price prediction is therefore crucial to minimize risks and improve the accuracy of investment strategies. This study aims to compare the performance of two deep learning methods, namely Long Short-Term Memory (LSTM) and Bidirectional LSTM (BiLSTM), in predicting the daily stock prices of two Indonesian blue chip stocks: PT Bank Central Asia Tbk (BBCA) and PT Telkom Indonesia Tbk (TLKM), using historical data obtained from the Alpha Vantage API from 2019 to 2023.

The preprocessing stage involved extracting closing price data, applying MinMaxScaler normalization, and creating sliding windows for time series modeling. Both LSTM and BiLSTM models were trained and tested using TensorFlow-Keras, with hyperparameter tuning conducted via Grid Search, focusing on combinations of neurons, batch size, epochs, and dropout rate.

The models were evaluated using three key metrics: Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and Mean Absolute Percentage Error (MAPE). The results indicate that the BiLSTM model outperformed LSTM in prediction accuracy, particularly due to its ability to learn bidirectional dependencies in time series data. This study contributes to the development of more accurate and systematic stock price prediction models using deep learning, which can be replicated by researchers and financial practitioners.

Keywords: Stock Price Prediction; LSTM; BiLSTM; Alpha Vantage API; Grid Search.

DAFTAR ISI

LEMBAR PENGESAHAN	i
PERNYATAAN ORISINALITAS	Error! Bookmark not defined.
PERNYATAAN PERSETUJUAN PUBLIKASI	iii
RIWAYAT HIDUP	iv
KATA PENGANTAR	v
ABSTRAK	vii
ABSTRACT	viii
DAFTAR ISI	ix
DAFTAR TABEL	xii
DAFTAR GAMBAR	xiii
BAB I PENDAHULUAN	1
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	3
1.3. Batasan Masalah	3
1.4. Tujuan Penelitian	4
1.5. Manfaat Penelitian	5
BAB II LANDASAN TEORI	6
2.1. Saham	6
2.1.1. Jenis Jenis Saham	7
2.1.2. Harga Saham	9
2.2. Prediksi Saham	10
2.2.1. Konsep Prediksi Harga Saham	10
2.2.2. Faktor-Faktor yang Mempengaruhi Harga Saham	11
2.2.3. Pendekatan Prediksi Harga Saham	12
2.3. <i>Machine Learning</i>	14
2.3.1. Konsep <i>Machine Learning</i>	14
2.3.2. Penerapan <i>Machine Learning</i> dalam Prediksi Saham	15
2.4. <i>Deep Learning</i>	16
2.4.1. <i>Artificial Neural Network (ANN)</i>	18
2.4.2. <i>Recurrent Neural Network (RNN)</i>	19
2.4.3. <i>Long Short-Term Memory (LSTM)</i>	20
2.4.4. <i>Bidirectional Long Short-Term Memory (BiLSTM)</i>	23
2.5. <i>Alpha Vantage</i>	24

2.6.	<i>Grid Search</i>	26
2.6.1.	Konsep dan Penerapan <i>Grid Search</i> dalam <i>Deep Learning</i>	26
2.6.2.	Evaluasi, Perbandingan, dan Contoh Implementasi	27
2.7.	Metrik Evaluasi Model	29
2.7.1.	<i>Mean Squared Error (MSE)</i>	29
2.7.2.	<i>Root Mean Squared Error (RMSE)</i>	30
2.7.3.	<i>Mean Absolute Percentage Error (MAPE)</i>	31
2.8.	Studi Literatur	31
BAB III METODOLOGI PENELITIAN		36
3.1.	Jenis Penelitian	36
3.2.	Sumber dan Teknik Pengumpulan Data	37
3.2.1.	Sumber Data	37
3.2.2.	Teknik Pengumpulan Data	38
3.3.	Teknik Analisis Data.....	38
3.3.1	<i>Preprocessing</i> Data	38
3.3.2	Pelatihan Model LSTM dan BiLSTM	39
3.3.3	Optimasi <i>Hyperparameter</i> Menggunakan <i>Grid Search</i>	40
3.3.4	Evaluasi Kinerja Model	41
3.3.5	Perbandingan Hasil dan Visualisasi.....	41
3.4.	Alat dan Perangkat Penelitian	43
3.5.	Diagram Alur Penelitian	45
3.6.	Kerangka Waktu Penelitian	48
BAB IV HASIL DAN PEMBAHASAN		49
4.1.	Deskripsi Data	49
4.2.	Hasil <i>Preprocessing</i> Data	50
4.3.	Implementasi Model LSTM dan BiLSTM	56
4.3.1.	Arsitektur Model	56
4.3.2.	Hasil Konfigurasi Awal Model	58
4.4.	Hasil Optimasi <i>Hyperparameter (Grid Search)</i>	62
4.4.1.	Proses <i>Grid Search</i>	62
4.4.2.	Hasil Optimasi untuk Model LSTM	65
4.4.3.	Hasil Optimasi untuk Model BiLSTM	66
4.5.	Evaluasi Kinerja Model	67
4.5.1.	Hasil Evaluasi Model.....	67
4.5.2.	Visualisasi Hasil Prediksi	68
4.6.	Perbandingan Kinerja Model LSTM dan BiLSTM	70
4.6.1.	Perbandingan Metrik Evaluasi	70
4.6.2.	Perbandingan Efisiensi Komputasi	71

4.6.1. Analisis Kelebihan dan Kekurangan	72
4.7. Pembahasan Hasil Penelitian	73
4.7.1. Interpretasi Hasil Prediksi.....	73
4.7.2. Validasi Hasil dengan Teori	74
BAB V PENUTUP	77
5.1 Kesimpulan	77
5.2 Saran	78
DAFTAR PUSTAKA	80

DAFTAR TABEL

Tabel 2.1 Perbandingan Grid Search dan Random Search	28
Tabel 2.2 Kriteria Nilai MAPE	31
Tabel 2.3 Studi Literatur	31
Tabel 3.1 Variabel Harga Saham	37
Tabel 3.2 Proses Pengumpulan Data Saham	38
Tabel 3.3 Parameter Arsitektur Model	39
Tabel 3.4 Parameter Grid Search	40
Tabel 3.5 Alat dan Perangkat Penelitian	43
Tabel 3.6 Waktu Penelitian	48
Tabel 4.1 Hasil Evaluasi Model pada Data Uji	60
Tabel 4.2 Optimasi Terbaik Model LSTM saham BBCA	66
Tabel 4.3 Optimasi Terbaik Model LSTM saham TLKM	66
Tabel 4.4 Optimasi Terbaik Model BiLSTM saham BBCA	66
Tabel 4.5 Optimasi Terbaik Model BiLSTM saham TLKM	66
Tabel 4.6 Kombinasi terbaik yang digunakan sebagai model final	67
Tabel 4.7 Hasil Evaluasi Model Terhadap Data Uji	67
Tabel 4.8 Perbandingan Kelebihan dan Kekurangan Model LSTM dan BiLSTM	72

DAFTAR GAMBAR

Gambar 2.1 Klasifikasi Machine Learning.....	15
Gambar 2.2 Perbedaan Arsitektur Neural Network dan Arsitektur Deep Learning	17
Gambar 2.3 Arsitektur ANN	19
Gambar 2.4 Arsitektur RNN	20
Gambar 2.5 Arsitektur LSTM	21
Gambar 2.6 Arsitektur BiLSTM	23
Gambar 3.1 Diagram Fishbone	42
Gambar 3.2 Flowchart Penelitian	46
Gambar 4.1 Pengambilan Data Harga Saham	50
Gambar 4.2 Tampilan data awal BBKA	50
Gambar 4.3 Tampilan data awal TLKM	51
Gambar 4.4 Fungsi untuk pembersihan data	51
Gambar 4.5 Tampilan setelah pembersihan data	53
Gambar 4.6 Fungsi untuk membuat dataset	54
Gambar 4.7 Perbandingan data BBKA sebelum dan sesudah normalisasi	56
Gambar 4.8 Arsitektur model LSTM	56
Gambar 4.9 Arsitektur model BiLSTM	57
Gambar 4.10 Grafik Loss Training dan Validasi Saham BBKA	59
Gambar 4.11 Grafik Loss Training dan Validasi Saham TLKM	59
Gambar 4.12 Grafik Training Data saham BBKA menggunakan LSTM	61
Gambar 4.13 Grafik Training Data saham BBKA menggunakan BiLSTM	61
Gambar 4.14 Grafik Training Data saham TLKM menggunakan LSTM	62
Gambar 4.15 Grafik Training Data saham TLKM menggunakan BiLSTM	62
Gambar 4.16 Implementasi Grid Search untuk Optimasi Hyperparameter	63
Gambar 4.17 Contoh Output Pelatihan dari Grid Search.....	65
Gambar 4.18 Prediksi vs Aktual BBKA (LSTM).....	68
Gambar 4.19 Prediksi vs Aktual TLKM (LSTM)	69
Gambar 4.20 Prediksi vs Aktual BBKA (BiLSTM)	69
Gambar 4.21 Prediksi vs Aktual TLKM (BiLSTM).....	70

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Pasar saham merupakan salah satu instrumen investasi yang sangat populer di dunia. Di Indonesia, pasar modal berkembang pesat dengan semakin banyaknya investor yang tertarik untuk berpartisipasi. Menurut data dari Kustodian Sentral Efek Indonesia (KSEI), jumlah investor saham di Indonesia terus meningkat, menunjukkan minat masyarakat terhadap pasar saham sebagai alternatif investasi yang menjanjikan keuntungan finansial yang besar (KSEI, 2022). Namun, di balik potensi keuntungan yang tinggi, investasi saham juga memiliki risiko yang signifikan. Fluktuasi harga saham yang tajam dan tidak terduga merupakan tantangan besar yang dihadapi oleh para investor (Hanafiah, Agusta, & Puteri, 2023).

Harga saham dipengaruhi oleh berbagai faktor yang sangat dinamis, baik yang bersifat internal perusahaan maupun eksternal seperti kondisi ekonomi global, kebijakan pemerintah, serta peristiwa sosial dan politik (Mushliha, 2024). Oleh karena itu, untuk memperoleh keuntungan dari investasi saham, investor perlu melakukan analisis yang cermat terhadap pergerakan harga saham. Prediksi harga saham yang akurat dapat membantu investor dalam pengambilan keputusan yang tepat, mengurangi risiko, dan meningkatkan peluang keuntungan. Hal ini menjadikan prediksi harga saham sebagai salah satu topik yang banyak diteliti dalam bidang keuangan (Puteri, Darmawan, & Ruchjana, 2024).

Namun, prediksi harga saham bukanlah hal yang mudah dilakukan. Sebagian besar metode tradisional yang digunakan dalam analisis saham, seperti analisis teknikal dan fundamental, sering kali tidak cukup memadai dalam menangani kompleksitas dan fluktuasi harga saham yang bersifat dinamis dan non-linear. Salah satu pendekatan yang

lebih modern dan efektif untuk memprediksi harga saham adalah dengan menggunakan teknik *machine learning*, khususnya *deep learning*, yang memiliki kemampuan untuk menganalisis data besar dan kompleks secara efisien (Luthfiansyah & Wasito, 2023).

Long Short-Term Memory (LSTM) adalah salah satu metode *deep learning* yang sering digunakan untuk memprediksi data deret waktu, seperti harga saham. LSTM merupakan pengembangan dari *Recurrent Neural Network (RNN)* yang dirancang untuk mengatasi masalah *vanishing gradient*, yaitu masalah yang terjadi pada RNN ketika harus memproses data yang memiliki ketergantungan jangka panjang. LSTM memiliki struktur yang memungkinkan model untuk menyimpan informasi dalam waktu yang lama, sehingga dapat menangani data deret waktu yang kompleks dan bersifat dinamis. Beberapa penelitian menunjukkan bahwa LSTM efektif dalam memprediksi harga saham, terutama dengan mengoptimalkan *hyperparameter* model untuk meningkatkan akurasi prediksi (Hanafiah, Agusta, & Puteri, 2023; Agusta & Hanafiah, 2021).

Meskipun LSTM telah terbukti efektif, model ini memiliki keterbatasan karena hanya memproses data dalam satu arah, yaitu dari masa lalu ke masa depan. Untuk mengatasi hal ini, model *Bidirectional Long Short-Term Memory (BiLSTM)* diperkenalkan. BiLSTM merupakan pengembangan dari LSTM yang memproses data dalam dua arah, yaitu maju (dari masa lalu ke masa depan) dan mundur (dari masa depan ke masa lalu). Dengan pemrosesan informasi dari kedua arah, BiLSTM dapat mempelajari pola data secara lebih komprehensif dan efektif. Penelitian oleh Puteri, Darmawan, dan Ruchjana (2024) serta Mushliha (2024) menunjukkan bahwa BiLSTM lebih unggul dalam memprediksi harga saham dibandingkan dengan LSTM, terutama dalam menangkap ketergantungan jangka panjang dan informasi yang berhubungan dengan kedua arah waktu.

Berdasarkan penelitian-penelitian sebelumnya, metode LSTM dan BiLSTM terbukti efektif dalam prediksi harga saham. Namun, terdapat beberapa celah (*research gap*) yang belum banyak dikaji secara eksplisit. Pertama, sebagian besar penelitian hanya

menggunakan salah satu model, tanpa melakukan perbandingan langsung antara LSTM dan BiLSTM dalam satu eksperimen yang setara. Kedua, optimasi *hyperparameter* pada studi sebelumnya umumnya dilakukan secara manual atau menggunakan nilai default, sehingga belum menunjukkan pendekatan eksploratif yang sistematis. Dalam penelitian ini digunakan pendekatan *Grid Search* sebagai strategi untuk mengevaluasi berbagai kombinasi parameter seperti jumlah neuron, *batch size*, *epoch*, dan *dropout rate*, guna meningkatkan akurasi model secara objektif dan dapat diulang kembali dengan hasil yang konsisten.

Dengan demikian, penelitian ini bertujuan untuk mengisi celah tersebut melalui perbandingan model LSTM dan BiLSTM dalam memprediksi harga saham BBKA dan TLKM, dengan data historis dari Alpha Vantage API dan penerapan Grid Search sebagai strategi untuk mengoptimalkan parameter model. Harapannya, penelitian ini dapat memberikan kontribusi nyata dalam pengembangan metode prediksi harga saham berbasis *deep learning* yang lebih akurat, terukur, dan dapat diterapkan kembali pada studi serupa di masa depan.

1.2. Rumusan Masalah

Permasalahan utama dalam penelitian ini adalah bagaimana membandingkan kinerja model *Long Short-Term Memory* (LSTM) dan *Bidirectional LSTM* (BiLSTM) dalam memprediksi harga saham harian menggunakan data dari *Alpha Vantage API*. Fokus penelitian ini mencakup analisis perbandingan akurasi kedua model, serta pengaruh kombinasi *hyperparameter* seperti jumlah neuron, *batch size*, *epoch*, dan *dropout rate*, dengan penerapan *Grid Search Optimization* sebagai metode bantu untuk mengoptimalkan parameter model.

1.3. Batasan Masalah

Adapun batasan-batasan yang diberlakukan dalam penelitian ini agar terfokus dan menghasilkan analisis yang jelas. Batasan tersebut adalah sebagai berikut:

1. Penelitian ini hanya menggunakan data harga saham harian dari dua saham *Blue Chip* Indonesia, yaitu Bank Central Asia (BBCA) dan Telkom Indonesia (TLKM), yang diperoleh melalui *Alpha Vantage API*. Analisis difokuskan secara eksklusif pada fitur harga penutupan (*Close*) sebagai representasi pergerakan harga saham. Fitur lain seperti harga pembukaan (*Open*), tertinggi (*High*), terendah (*Low*), volume, maupun indikator teknikal tidak disertakan dalam penelitian ini.
2. Penelitian ini hanya membandingkan akurasi prediksi antara model LSTM dan BiLSTM, tanpa melibatkan metode lain. Evaluasi dilakukan dengan tiga metrik regresi utama yaitu MSE (Mean Squared Error), RMSE (Root Mean Squared Error) dan MAPE (Mean Absolute Percentage Error).
3. Analisis dibatasi pada prediksi harga saham harian (*next-day forecasting*) berdasarkan data historis 5 tahun terakhir (Januari 2019 hingga Desember 2023). Penelitian tidak mencakup prediksi jangka menengah atau panjang.
4. Cakupan penelitian hanya terbatas pada pasar saham Indonesia, tanpa membandingkan dengan pasar *global*. Objek penelitian difokuskan pada saham BBCA dan TLKM sebagai representasi saham unggulan dengan volatilitas tinggi.
5. Optimasi *hyperparameter* dilakukan menggunakan Grid Search sebagai metode bantu, dengan ruang pencarian terbatas pada jumlah *neuron*, *batch size*, *epoch*, dan *dropout rate*. Parameter lain seperti *learning rate* dan *activation function* tidak disertakan dalam ruang lingkup optimasi.

1.4. Tujuan Penelitian

1. Membandingkan akurasi prediksi antara model LSTM dan BiLSTM dalam memproyeksikan harga saham BBCA dan TLKM berdasarkan data historis dari *Alpha Vantage API*, menggunakan metrik evaluasi *MSE*, *RMSE* dan *MAPE*.
2. Menganalisis pengaruh kombinasi *hyperparameter* seperti jumlah neuron, *batch size*, *epoch*, dan *dropout rate* terhadap performa masing-masing model.

3. Menggunakan *Grid Search Optimazition* sebagai metode bantu untuk mengoptimalkan konfigurasi *hyperparameter* selama proses pelatihan model.
4. Memberikan rekomendasi arsitektur model yang paling akurat dan efisien untuk prediksi harga saham harian berbasis *deep learning*.

1.5. Manfaat Penelitian

1. Bagi Peneliti

Penelitian ini memberikan pengalaman langsung dalam penerapan metode *deep learning* (LSTM dan BiLSTM) untuk prediksi data deret waktu, sekaligus memperluas pemahaman teknis terhadap implementasi praktis menggunakan *Python*, *TensorFlow*, dan teknik optimasi *hyperparameter* seperti *Grid Search*. Selain itu, peneliti memperoleh wawasan tentang proses pengolahan data saham historis dan penggunaan *API* modern seperti *Alpha Vantage* secara efektif.

2. Bagi Investor

Hasil penelitian ini dapat menjadi referensi dalam memilih metode prediksi harga saham yang lebih akurat dan berbasis data, khususnya dalam menghadapi fluktuasi jangka pendek di pasar saham Indonesia. Dengan membandingkan akurasi model prediksi, investor dapat mempertimbangkan penggunaan pendekatan teknologi dalam pengambilan keputusan investasi.

3. Bagi Universitas

Penelitian ini memberikan kontribusi dalam pengembangan keilmuan di bidang teknologi informasi, khususnya pada penerapan *deep learning* untuk analisis deret waktu. Hasil penelitian dapat digunakan sebagai bahan ajar, referensi penelitian lanjutan, serta penguatan materi praktikum pada mata kuliah yang berkaitan dengan *data science*, *machine learning* dan *artificial intelligence*.

BAB II

LANDASAN TEORI

2.1. Saham

Saham merupakan surat berharga yang menjadi tanda kepemilikan seseorang atau badan terhadap suatu perusahaan, memberikan hak kepada pemegangnya atas sebagian aset dan laba perusahaan. Saham menjadi instrumen penting dalam pasar modal karena menyediakan mekanisme bagi perusahaan untuk mendapatkan pembiayaan eksternal dan bagi investor untuk mendapatkan potensi imbal hasil berupa *dividen* dan *capital gain* (Ardini, 2020).

Selain sebagai instrumen investasi, saham juga memainkan peran vital dalam penggerak perekonomian nasional. Dengan adanya transaksi saham, dana masyarakat dapat dihimpun untuk digunakan dalam berbagai kegiatan produktif, mendorong pertumbuhan ekonomi (Ardini, 2020). Oleh karena itu, fluktuasi saham tidak hanya berdampak pada investor individu, tetapi juga pada stabilitas ekonomi makro.

Menurut Indarningsih (2022), saham berfungsi sebagai salah satu media utama dalam menyalurkan investasi dan mengefisienkan alokasi sumber daya keuangan di pasar modal. Harga saham yang naik dapat menjadi sinyal positif terhadap kinerja suatu perusahaan, sedangkan harga yang menurun bisa mencerminkan memburuknya ekspektasi pasar.

Dari sudut pandang Samudra dan Ardini (2020) menjelaskan bahwa saham tidak hanya dilihat dari sisi keuntungan, tetapi juga sebagai alat komunikasi informasi ke pasar. Misalnya, pengumuman laba atau pembagian dividen akan menjadi sinyal kepada investor tentang prospek perusahaan di masa depan.

Teori Signaling (Samudra & Ardini, 2020) memberikan dasar teoretis yang kuat bahwa tindakan perusahaan, seperti pembagian dividen atau penerbitan saham baru,

membawa informasi penting bagi investor, yang kemudian tercermin dalam perubahan harga saham. Hubungan ini mendukung pemahaman bagaimana pasar merespons informasi dan mengubah ekspektasi terhadap nilai saham.

2.1.1. Jenis Jenis Saham

Saham dapat diklasifikasikan dalam berbagai kategori berdasarkan kriteria tertentu, seperti hak yang diberikan kepada pemegangnya, karakteristik peralihan kepemilikan, hingga kinerja perdagangan saham di pasar modal. Pemahaman terhadap klasifikasi ini penting karena masing-masing jenis saham memiliki implikasi risiko dan imbal hasil yang berbeda (Soebiantoro, 2022).

1. Dilihat berdasarkan hak tagih atau klaim terhadap laba dan aset perusahaan dibedakan menjadi:
 - a. Saham Biasa (Common Stock) adalah saham yang memberikan hak kepada pemegangnya untuk mengklaim laba perusahaan melalui dividen dan bagian dari aset perusahaan saat likuidasi, tetapi setelah seluruh kewajiban kepada kreditur dan pemegang saham preferen diselesaikan. Pemegang saham biasa juga memiliki hak suara dalam rapat umum pemegang saham (RUPS) Soebiantoro (2022) dan Indarningsih (2022).
 - b. Saham Preferen (Preferred Stock) adalah saham yang memberikan hak istimewa berupa prioritas atas pembayaran dividen dan hak klaim atas aset perusahaan saat terjadi likuidasi. Dividen saham preferen biasanya tetap dan tidak bergantung pada laba perusahaan dalam periode tertentu (Soebiantoro, 2022).
2. Dilihat dari kemudahan dalam peralihannya, saham dibedakan menjadi:
 - a. Saham Atas Unjuk (Bearer Stocks) adalah saham yang tidak mencantumkan nama pemilik dalam sertifikat saham. Pemindahan hak atas saham ini cukup dengan menyerahkan fisik saham tersebut, sehingga memudahkan dalam jual-beli dan transfer kepemilikan (Indarningsih, 2022).

- b. Saham Atas Nama (Registered Stocks) merupakan saham yang mencantumkan nama pemilik dalam sertifikat saham dan dalam daftar perusahaan. Peralihan saham ini harus melalui prosedur administrasi tertentu, seperti perubahan pencatatan nama di daftar pemegang saham (Indarningsih, 2022).
3. Dilihat dari kinerja perdagangan, saham dapat dikategorikan sebagai berikut:
 - a. Saham *Blue Chip* merupakan saham perusahaan besar yang memiliki reputasi tinggi, kinerja keuangan yang stabil, dan likuiditas tinggi di pasar. Saham *blue chip* umumnya menjadi pilihan utama bagi investor konservatif karena tingkat risikonya relatif rendah dan memberikan dividen yang konsisten (Nafiah, 2019). Namun, studi oleh Agustina et al. (2025) menunjukkan bahwa volume perdagangan dapat mempengaruhi volatilitas harga saham *Blue Chip* tertentu, seperti ADRO dan ANTM, meskipun IHSG dan transaksi asing tidak berpengaruh signifikan. Hal ini mengindikasikan bahwa faktor-faktor tertentu dapat mempengaruhi volatilitas saham *Blue Chip*.
 - b. Saham Second Liner adalah saham dari perusahaan yang berkapitalisasi menengah. Walaupun tidak sebesar *blue chip*, saham second liner sering kali menawarkan potensi pertumbuhan yang lebih tinggi, namun dengan volatilitas yang lebih besar (Nafiah, 2019). Studi oleh Dewi et al. (2023) menunjukkan bahwa selama pandemi COVID-19, pasar saham Indonesia mengalami peningkatan volatilitas yang signifikan, yang dapat mempengaruhi saham-saham dengan kapitalisasi menengah seperti Second Liner.
 - c. Saham Third Liner adalah saham dari perusahaan kecil yang kapitalisasinya rendah. Jenis saham ini memiliki tingkat risiko yang tinggi, tetapi juga potensi imbal hasil yang besar bagi investor yang bersedia mengambil risiko tinggi (Nafiah, 2019). Menurut Dewi et al. (2023), selama periode ketidakpastian ekonomi seperti pandemi COVID-19, saham dengan kapitalisasi kecil cenderung mengalami volatilitas yang lebih tinggi, menjadikannya kurang ideal untuk

penelitian prediksi harga jangka menengah hingga panjang menggunakan model berbasis *machine learning*.

2.1.2. Harga Saham

Harga saham merupakan harga pasar dari suatu saham yang terbentuk melalui mekanisme permintaan dan penawaran di bursa saham. Harga ini mencerminkan nilai perusahaan yang dipercaya oleh investor berdasarkan berbagai faktor seperti kinerja keuangan, prospek pertumbuhan, kondisi ekonomi makro, dan sentimen pasar. Menurut Hutami (2022), perubahan harga saham mencerminkan respons pasar terhadap dinamika internal perusahaan maupun faktor eksternal, termasuk gejolak ekonomi global dan kebijakan pemerintah.

Harga saham memiliki karakteristik fluktuatif dan dinamis, yang berarti bahwa perubahan harga dapat terjadi dalam waktu singkat. Fluktuasi harga saham menjadi cerminan dari bagaimana pasar menginterpretasikan informasi baru serta ekspektasi masa depan terhadap kinerja suatu perusahaan. Berikut ini teori terkait harga saham:

1. Teori Sinyal (Signaling Theory)

Teori ini menyatakan bahwa perusahaan dapat mengirimkan sinyal ke pasar melalui berbagai tindakan korporasi, seperti pembagian dividen, penerbitan saham baru, atau pengumuman laba. Tindakan ini dipandang oleh investor sebagai indikator kinerja dan prospek perusahaan di masa depan. Menurut Ainun (2019), sinyal positif dari perusahaan dapat meningkatkan minat beli investor, yang akhirnya mendorong kenaikan harga saham, sementara sinyal negatif dapat menurunkan harga saham.

2. Teori Efisiensi Pasar (Efficient Market Hypothesis - EMH)

EMH menyatakan bahwa semua informasi yang tersedia telah tercermin dalam harga saham saat ini. Oleh karena itu, tidak ada investor yang secara konsisten dapat

memperoleh keuntungan abnormal dari perdagangan saham berbasis informasi publik. Hutami (2022) menegaskan bahwa dalam pasar yang efisien, reaksi harga terhadap informasi baru terjadi dengan cepat dan akurat.

Menurut Prestiwi, Kencana, dan Fadly (2022), walaupun teori pasar efisien menggambarkan pasar sebagai responsif terhadap informasi, dalam praktiknya sering terjadi deviasi akibat faktor psikologis investor. Misalnya, investor dapat bereaksi berlebihan (overreaction) terhadap berita positif atau negatif, yang menyebabkan harga saham melonjak atau jatuh di luar proporsi rasional. Faktor-faktor behavioral ini menjadi salah satu alasan mengapa harga saham sering menunjukkan volatilitas tinggi yang sulit diprediksi hanya dengan pendekatan fundamental.

2.2. Prediksi Saham

2.2.1. Konsep Prediksi Harga Saham

Prediksi dalam konteks pasar modal mengacu pada upaya memperkirakan pergerakan harga saham di masa depan dengan menganalisis data historis serta mempertimbangkan berbagai faktor yang mempengaruhi pasar. Prediksi ini menjadi metode bantu strategis bagi investor dalam membuat keputusan investasi yang lebih akurat, mengurangi risiko kerugian, serta memaksimalkan potensi keuntungan (Djamal, 2019).

Prediksi harga saham tidak hanya penting untuk kebutuhan trading jangka pendek, melainkan juga untuk manajemen portofolio jangka panjang. Dengan memahami arah pergerakan harga saham, investor dapat menyesuaikan strategi investasinya sesuai dengan profil risiko yang dimiliki.

Menurut Pipin, Purba, dan Kurniawan (2023), akurasi prediksi harga saham menjadi faktor penentu dalam kesuksesan strategi investasi, baik dalam trading harian (day trading) maupun dalam investasi berbasis nilai jangka panjang. Mereka menekankan

bahwa prediksi bukan hanya tentang memperkirakan angka harga, tetapi juga memahami ekspektasi pasar dan perilaku kolektif investor.

Seiring perkembangan teknologi, prediksi harga saham juga telah bertransformasi dari metode tradisional ke penggunaan algoritma prediktif canggih, seperti *Recurrent Neural Network (RNN)* dan *Long Short-Term Memory (LSTM)*, yang mampu menangani karakteristik data *time series* yang kompleks.

Dalam teori pasar keuangan klasik, prediksi sering kali dibatasi oleh asumsi bahwa pasar adalah efisien dan semua informasi sudah tercermin dalam harga (teori pasar efisien). Namun, dengan kemajuan dalam teknologi komputasi dan pengembangan algoritma *machine learning*, pendekatan prediksi modern kini mampu mengungkap pola-pola non-linear yang tidak terdeteksi oleh metode tradisional. Dengan demikian, terjadi sinergi antara teori keuangan klasik dan pendekatan teknologi modern dalam meningkatkan ketepatan prediksi harga saham.

2.2.2. Faktor-Faktor yang Mempengaruhi Harga Saham

Harga saham dipengaruhi oleh kombinasi faktor fundamental, makroekonomi, sentimen pasar, dan perilaku psikologis investor. Pemahaman mendalam terhadap faktor-faktor ini menjadi prasyarat dalam membangun model prediksi harga saham yang efektif. Berikut ini faktor-faktor utama yang mempengaruhi harga saham:

1. Fundamental Perusahaan

Kinerja internal perusahaan, seperti laba bersih, pertumbuhan pendapatan, rasio keuangan (seperti ROE, DER), dan arus kas menjadi indikator utama yang mempengaruhi harga saham (Lutfi, 2019). Semakin baik kinerja keuangan perusahaan, semakin besar kecenderungan harga saham untuk meningkat.

2. Ekonomi Makro

Variabel makroekonomi seperti tingkat suku bunga, inflasi, nilai tukar, dan pertumbuhan Produk Domestik Bruto (PDB) memiliki pengaruh signifikan terhadap

harga saham (Tobing & Situmeang, 2025). Misalnya, kenaikan suku bunga cenderung menekan harga saham karena biaya pinjaman yang lebih tinggi mengurangi profitabilitas perusahaan.

3. Sentimen Pasar

Selain faktor fundamental dan makro, sentimen kolektif investor berdasarkan berita, rumor, dan peristiwa ekonomi-politik juga berdampak pada harga saham (Arif & Widodo, 2025). Sentimen pasar sering kali memicu volatilitas jangka pendek yang tidak selalu sejalan dengan kondisi fundamental.

4. Faktor Perilaku

Faktor psikologis seperti herd behavior, overconfidence, dan bias kognitif dapat menyebabkan pergerakan harga saham yang tidak rasional (Widiputra, Mailangkay, & Gautama, 2021). Misalnya, dalam situasi panic selling, investor cenderung mengikuti tindakan mayoritas tanpa analisis mendalam, menyebabkan harga saham jatuh drastis.

Setyawan (2023) mengemukakan bahwa dalam era informasi cepat seperti sekarang, faktor perilaku menjadi semakin dominan dalam menentukan pergerakan harga saham. Akses cepat terhadap informasi melalui media sosial dan portal berita mempercepat pembentukan sentimen pasar, yang dapat memicu pergerakan harga secara instan tanpa didukung data fundamental. Faktor-faktor ini, baik yang berbasis fundamental maupun perilaku, menciptakan tantangan dalam membangun model prediksi harga saham. Oleh sebab itu, model prediksi modern tidak hanya memasukkan variabel finansial kuantitatif, tetapi juga mempertimbangkan data alternatif (seperti analisis sentimen dari media sosial) untuk meningkatkan akurasi prediksi.

2.2.3. Pendekatan Prediksi Harga Saham

Secara umum, terdapat tiga pendekatan utama dalam prediksi harga saham yang berkembang dalam praktik keuangan dan penelitian:

1. Analisis Teknikal

Mengandalkan pola historis grafik harga dan volume perdagangan, serta penggunaan indikator teknikal seperti moving average, RSI (Relative Strength Index), dan MACD (Moving Average Convergence Divergence) untuk memprediksi arah harga saham di masa depan (Amalia, Christyn, & Banjarnahor, 2025). Pendekatan ini didasarkan pada asumsi bahwa pola pergerakan harga akan berulang.

2. Analisis Fundamental

Menurut Saepudin (2025) analisis fundamental berfokus pada penilaian nilai intrinsik saham melalui evaluasi kinerja keuangan perusahaan dan faktor makroekonomi. Pendekatan ini bertujuan untuk menentukan apakah suatu saham dinilai terlalu tinggi atau terlalu rendah oleh pasar.

3. Machine Learning

Menggunakan algoritma seperti *Recurrent Neural Network (RNN)*, *Long Short-Term Memory (LSTM)*, dan *Bidirectional LSTM (BiLSTM)* untuk mempelajari pola kompleks dalam data historis harga saham (Tauran, 2021). Algoritma ini mampu menangani dependensi jangka panjang dalam data deret waktu, yang sulit dianalisis menggunakan metode statistik tradisional.

Fitri dan Riana (2022) menekankan bahwa *machine learning* memiliki keunggulan dalam menangkap hubungan non-linear dan kompleks antar variabel yang tidak dapat dideteksi oleh analisis fundamental maupun teknikal tradisional. Dengan demikian, integrasi *machine learning* dalam prediksi harga saham menjadi solusi untuk meningkatkan akurasi prediksi. Setiap pendekatan prediksi menangkap dimensi yang berbeda dari dinamika pasar saham. Analisis fundamental memberikan gambaran jangka panjang berdasarkan nilai ekonomi, analisis teknikal mengidentifikasi momentum jangka pendek, sedangkan *machine learning* mengintegrasikan kompleksitas pola historis dan perilaku pasar. Kombinasi ketiga pendekatan ini menciptakan prediksi yang lebih komprehensif dan adaptif terhadap perubahan pasar yang cepat.

2.3. *Machine Learning*

2.3.1. Konsep *Machine Learning*

Machine Learning (ML) adalah cabang dari kecerdasan buatan (Artificial Intelligence/AI) yang memungkinkan komputer untuk melakukan pembelajaran secara otomatis melalui data, tanpa perlu diprogram secara eksplisit untuk setiap tugas (Muzakir & Kom, 2024). *Machine Learning* bekerja berdasarkan prinsip bahwa sistem dapat belajar dari data, mengidentifikasi pola, dan membuat keputusan dengan intervensi manusia yang minimal. *Machine learning* secara umum diklasifikasikan menjadi tiga pendekatan utama:

1. *Supervised Learning*

Pendekatan ini menggunakan dataset berlabel, yaitu data dengan *input* dan *output* yang diketahui. Algoritma dilatih untuk mempelajari hubungan antara *input* dan *output*, kemudian digunakan untuk memprediksi hasil pada data baru. Contoh algoritma dalam kategori ini meliputi regresi linier, *decision tree*, dan LSTM. *Supervised learning* sangat cocok untuk prediksi harga saham karena tersedia data historis yang terstruktur.


2. *Unsupervised Learning*

Dalam pendekatan ini, data yang digunakan tidak memiliki label. Tujuannya adalah untuk menemukan pola tersembunyi atau pengelompokan alami dalam data, seperti pada metode *clustering* (K-Means, DBSCAN). Meskipun tidak umum digunakan untuk prediksi harga saham secara langsung, pendekatan ini bermanfaat dalam analisis sentimen atau segmentasi pasar.

3. *Reinforcement Learning*

Pendekatan ini menggunakan sistem berbasis reward, di mana model belajar dari interaksi dengan lingkungan dan memperbaiki aksinya berdasarkan umpan balik. Meskipun jarang digunakan dalam penelitian akademik prediksi harga saham di

Indonesia, beberapa penelitian luar negeri mulai menerapkannya untuk strategi trading adaptif.



Gambar 2.1 Klasifikasi *Machine Learning*

Josaphat (2025) menegaskan bahwa metode *machine learning* modern seperti *Long Short-Term Memory (LSTM)* memiliki keunggulan signifikan dalam pengolahan data runtun waktu (*time series*). Hal ini disebabkan oleh kemampuan LSTM dalam mengatasi keterbatasan *Recurrent Neural Network (RNN)* tradisional, khususnya pada masalah *vanishing gradient*. Dalam prediksi harga saham, kemampuan untuk mengingat hubungan jangka panjang dalam data historis sangat penting karena harga saham dipengaruhi oleh tren yang sering kali tidak bersifat linear.

Dalam pengembangan sistem prediktif berbasis ML, pemrosesan data menjadi komponen utama. Ini mencakup proses *cleaning*, normalisasi, dan transformasi data historis saham seperti harga pembukaan, penutupan, volume transaksi, hingga indikator teknikal. Keberhasilan model *machine learning* sangat ditentukan oleh kualitas dan relevansi data pelatihan yang digunakan. Oleh karena itu, ML tidak hanya soal algoritma, tetapi juga bagaimana mempersiapkan dan memahami data secara menyeluruh.

2.3.2. Penerapan *Machine Learning* dalam Prediksi Saham

Penerapan *machine learning* dalam prediksi saham bertujuan untuk mengatasi kompleksitas pasar modal yang ditandai dengan non-linearitas, volatilitas tinggi, dan data

berukuran besar. Model-model *deep learning* seperti LSTM dan BiLSTM dirancang secara khusus untuk menangani data runtun waktu (*time-series*), di mana urutan dan keterkaitan antar data menjadi sangat penting.

LSTM dirancang untuk mempertahankan informasi dari waktu ke waktu, sehingga dapat mengenali pola historis jangka panjang yang memengaruhi harga saham saat ini. Sedangkan BiLSTM (*Bidirectional LSTM*) meningkatkan kinerja dengan memproses informasi dalam dua arah, dari masa lalu ke masa depan dan sebaliknya sehingga mampu menangkap konteks yang lebih luas dan menyeluruh dalam data deret waktu.

Afrinato (2022) dalam penelitiannya menunjukkan bahwa penerapan BiLSTM dalam prediksi harga saham perusahaan-perusahaan di Indonesia memberikan hasil prediksi yang lebih akurat dibandingkan metode statistik tradisional. BiLSTM tidak hanya mempertimbangkan data historis secara linier, tetapi juga memanfaatkan dependensi dua arah yang sering kali diabaikan dalam model lain.

Dalam praktiknya, penerapan LSTM dan BiLSTM memerlukan pengolahan data yang komprehensif, termasuk normalisasi, pembentukan *sliding window*, serta pembagian data pelatihan dan pengujian. Selain itu, pemilihan parameter seperti jumlah *neuron*, ukuran batch, dan *learning rate* sangat mempengaruhi performa model. Oleh karena itu, proses *training* dan *tuning* model menjadi aspek penting dalam eksperimen prediksi harga saham menggunakan pendekatan *machine learning*.


Pemanfaatan API seperti *Alpha Vantage API* sangat mempermudah akses terhadap data saham historis secara real-time dan terstruktur, yang dapat langsung digunakan dalam proses pelatihan model. Hal ini menjadi solusi efisien bagi peneliti dan praktisi yang ingin membangun sistem prediksi harga saham berbasis data aktual.

2.4. Deep Learning

Deep Learning merupakan cabang dari *Machine Learning* yang meniru cara kerja otak manusia melalui struktur jaringan saraf tiruan yang mendalam (*deep neural networks*). Menurut Muzakir, Komari, dan Ilham (2024), *deep learning* memanfaatkan

arsitektur jaringan multilayer untuk mengenali pola-pola kompleks dari data secara otomatis tanpa perlu desain fitur manual. Model *deep learning* menggunakan banyak lapisan (layers) untuk mengekstraksi fitur dan representasi data secara bertingkat. Hal ini menjadikan *deep learning* sangat efektif dalam mengenali pola-pola kompleks dan non-linear, yang sering ditemukan dalam data finansial seperti harga saham (Saputri & Majid, 2024).

Teknologi *deep learning* telah diadopsi secara luas dalam berbagai sektor industri. Di bidang teknologi, Google menerapkan *deep learning* untuk layanan Google Translate dan Google Assistant. Meta menggunakan *deep learning* untuk fitur pengenalan wajah dan deteksi objek otomatis. Dalam sektor keuangan, perusahaan seperti JPMorgan Chase dan Bloomberg memanfaatkan *deep learning* untuk mendeteksi pola pasar, memprediksi pergerakan saham, dan mengembangkan sistem trading otomatis (Josaphat & Pangestika, 2025).



Gambar 2.2 Perbedaan Arsitektur Neural Network dan Arsitektur *Deep Learning*

Sumber: <https://medium.com/@hannnfh/deep-learning-3840922fc77b>

Meskipun *deep learning* menawarkan akurasi tinggi dan kemampuan generalisasi yang kuat, implementasinya tidak lepas dari tantangan. Model *deep learning* memerlukan sumber daya komputasi besar (seperti GPU), data dalam jumlah besar untuk pelatihan, serta keahlian dalam pemodelan dan *tuning hyperparameter* (Switrayana, Hammad, & Irfan, 2025). Selain itu, model ini rawan terhadap *overfitting*, yaitu kondisi ketika model


terlalu menyesuaikan diri terhadap data pelatihan sehingga kurang baik dalam menghadapi data baru.

2.4.1. *Artificial Neural Network (ANN)*

Artificial Neural Network (ANN) merupakan model komputasi yang meniru cara kerja jaringan saraf biologis manusia. *ANN* terdiri dari sejumlah *neuron* buatan yang terhubung satu sama lain dan tersusun dalam lapisan-lapisan (*layers*). Menurut Muzakir et al. (2024), *ANN* merupakan fondasi utama dari *deep learning* dan digunakan secara luas dalam berbagai bidang seperti pengenalan pola, klasifikasi citra, dan prediksi berbasis data.

Jaringan ini dirancang untuk mempelajari hubungan fungsional antara *input* dan output, baik secara linier maupun non-linear (Barua, Kumar, & Roy, 2024). Arsitektur *ANN* umumnya terdiri dari tiga jenis lapisan:

1. *Input Layer* merupakan Lapisan yang menerima data awal yang akan diproses oleh sistem.
2. *Hidden Layer* adalah lapisan tersembunyi yang berada diantara *input* dan output yang melakukan proses perhitungan kompleks. Setiap *neuron* pada *hidden layer* menerima *input*, menerapkan bobot (*weight*), dan memprosesnya menggunakan fungsi aktivasi (*activation function*) seperti ReLU, sigmoid, atau tanh.
3. *Output Layer* merupakan lapisan yang menghasilkan output akhir dari jaringan yang telah di proses didalam layer-layer sebelumnya, seperti nilai prediksi harga saham. Bentuk output bisa satu nilai numerik (regresi) atau klasifikasi (naik/turun).




Gambar 2.3 Arsitektur ANN

Sumber: https://cs231n.stanford.edu/slides/2017/cs231n_2017_lecture4.pdf

Kelebihan ANN terletak pada fleksibilitasnya dalam memproses berbagai jenis data dan kemampuannya dalam mempelajari representasi kompleks. Namun, ANN konvensional kurang efektif dalam menangani data sekuensial atau *time series* karena tidak memiliki mekanisme untuk menyimpan informasi jangka panjang. Hal ini menyebabkan ANN tidak dapat mempertahankan konteks historis dari data yang sangat penting dalam prediksi harga saham (Barua et al., 2024).

2.4.2. Recurrent Neural Network (RNN)

Recurrent Neural Network (RNN) dirancang untuk mengatasi keterbatasan ANN dalam mengolah data sekuensial. RNN memiliki struktur loop dalam arsitekturnya yang memungkinkan informasi dari langkah sebelumnya untuk mempengaruhi output saat ini. Menurut Muzakir et al. (2024), RNN memberikan pendekatan adaptif terhadap data yang memiliki ketergantungan waktu seperti teks dan data keuangan. Hal ini menjadikannya sangat cocok untuk data yang memiliki urutan waktu, seperti sinyal suara, teks, atau harga saham harian (Alkahfi, Kurnia, & Saefuddin, 2024).



Gambar 2.4 Arsitektur RNN

Sumber: <https://www.analyticsvidhya.com/blog/2022/03/a-brief-overview-of-recurrent-neural-networks-rnn/>

Berbeda dengan ANN yang memperlakukan setiap *input* secara independen, RNN mempertahankan state internal (hidden state) yang dapat “mengingat” informasi dari *input* sebelumnya. Mekanisme ini memungkinkan RNN memodelkan dependensi temporal, menjadikannya cocok untuk prediksi berbasis *time series*.


Kelebihan utama RNN adalah kemampuannya untuk menangani dependensi jangka pendek dalam data sekuensial. Namun, RNN konvensional memiliki kelemahan besar, yaitu *vanishing gradient problem*, yang terjadi saat pelatihan pada urutan panjang. *Gradient* yang sangat kecil menyebabkan pembaruan bobot menjadi tidak signifikan, sehingga model gagal mempelajari dependensi jangka panjang yang penting dalam data finansial (Alkahfi et al., 2024).

2.4.3. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah bentuk pengembangan dari *Recurrent Neural Network* (RNN) yang dirancang secara khusus untuk mengatasi permasalahan *vanishing gradient* yang sering terjadi ketika jaringan dilatih menggunakan urutan data panjang. LSTM memiliki arsitektur yang lebih kompleks dibandingkan RNN biasa, dengan menambahkan tiga jenis gate utama: *input gate*, *forget gate*, dan *output gate*. Ketiga komponen ini bertugas untuk mengatur aliran informasi yang masuk ke dalam sel

memori, disimpan dalam jangka panjang, atau dikeluarkan sebagai output (Simamora, Purba, & Pasha, 2025).

LSTM memungkinkan model untuk mengingat informasi jangka panjang sekaligus menyaring informasi yang tidak relevan. Dalam konteks prediksi harga saham, kemampuan ini sangat penting karena pergerakan harga tidak hanya dipengaruhi oleh kondisi saat ini, tetapi juga oleh tren dan pola yang terbentuk di masa lalu.



Gambar 2.5 Arsitektur LSTM

Sumber: <https://medium.com/bina-nusantara-it-division/lstm-long-short-term-memory-d29779e2ebf8>

Secara matematis, LSTM bekerja melalui persamaan-persamaan berikut, yang dibagi ke dalam tiga jenis *gate* utama:

1. *Forget Gate* berfungsi untuk menentukan informasi dari cell state sebelumnya yang perlu dibuang atau dilupakan.

$$f_t = \sigma(W_f \cdot x_t + U_f \cdot h_{t-1} + b_f) \quad (2.1)$$

Dimana:

f_t = nilai aktivasi *forget gate* pada waktu ke- t

σ = fungsi aktivasi sigmoid

W_f, U_f = matriks bobot dan *hidden state*

x_t = *input* saat ini

h_{t-1} = *hidden state* dari waktu sebelumnya

b_f = bias

2. *Input Gate* berfungsi untuk menentukan informasi baru yang akan ditambahkan ke memori jangka panjang (*cell state*).

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (2.2)$$

$$\widetilde{C}_t = \tanh(W_c \cdot x_t + U_c \cdot h_{t-1} + b_c) \quad (2.3)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \widetilde{C}_t \quad (2.4)$$

Dimana:

i_t = nilai aktivasi *input gate*

$\widetilde{C}_t$ = kandidat nilai baru untuk *cell state*

C_t = nilai *cell state* saat ini

$\odot$ = operasi perkalian elemen (*element-wise multiplication*)

C_{t-1} = *cell state* dari waktu sebelumnya

$\tanh$ = fungsi aktivasi tanh

W_i, U_i, b_i = parameter bobot dan bias *output gate*

W_c, U_c, b_c = parameter bobot dan bias *output gate*

3. *Output Gate* berfungsi untuk mengatur bagian dari *cell state* yang akan digunakan untuk menghasilkan output (*hidden state*).

$$o_t = \sigma(W_o \cdot x_t + U_o \cdot h_{t-1} + b_o) \quad (2.5)$$

$$h_t = o_t \odot \tanh(C_t) \quad (2.6)$$

Dimana:

o_t = nilai aktivasi *output gate*


h_t = *hidden state output* saat ini

W_o, U_o, b_o = parameter bobot dan bias *output gate*

Dengan struktur tersebut, *LSTM* mampu mempertahankan informasi penting dari masa lalu untuk jangka panjang sambil membuang informasi yang tidak relevan, menjadikannya sangat efektif dalam memodelkan data *time series* seperti harga saham (Simamora et al., 2025; Muzakir et al, 2024).

2.4.4. Bidirectional Long Short-Term Memory (BiLSTM)

Bidirectional LSTM (BiLSTM) adalah pengembangan lebih lanjut dari arsitektur *LSTM*. Berbeda dengan *LSTM* biasa yang hanya memproses data dari masa lalu ke masa depan, *BiLSTM* memproses data dalam dua arah, satu memproses data dari arah depan (*forward*) dan satu lagi dari arah belakang (*backward*). Tujuannya adalah untuk menggunakan konteks sebelum dan sesudah suatu titik waktu dalam proses prediksi (Puteri et al., 2024; Muzakir et al, 2024).



Gambar 2.6 Arsitektur BiLSTM

Sumber: https://www.researchgate.net/figure/Bidirectional-LSTM-architecture_fig6_365344152

BiLSTM terdiri dari dua lapisan *LSTM* parallel seperti yang terlihat pada Gambar 2.5. Satu membaca urutan *input* dari awal ke akhir, dan satu lagi dari akhir ke awal. Output dari kedua lapisan ini kemudian digabung untuk membentuk representasi yang lebih lengkap dari data.

Persamaan gabungan *hidden state*:

$$\mathbf{h}_t = [\vec{h}_t; \overleftarrow{h}_t] \quad (2.7)$$

Dimana:

$\vec{h}_t$ = *hidden state forward LSTM*

$\overleftarrow{h}_t$ = *hidden state backward LSTM*

h_t = hasil gabungan yang digunakan sebagai output BiLSTM

Dengan pendekatan dua arah ini, BiLSTM lebih mampu menangkap pola kontekstual dan menghasilkan prediksi yang lebih akurat dibandingkan LSTM standar. Namun, karena kompleksitas arsitekturnya, BiLSTM membutuhkan sumber daya komputasi yang lebih tinggi dan waktu pelatihan yang lebih lama (Simamora et al., 2025; Muzakir et al, 2024).

2.5. *Alpha Vantage*

Alpha Vantage merupakan salah satu penyedia layanan data pasar keuangan berbasis cloud yang mulai dikenal luas sejak peluncurannya pada tahun 2017. Platform ini menyediakan akses data keuangan secara gratis melalui RESTful API dan dirancang untuk dapat digunakan oleh berbagai kalangan, mulai dari akademisi, peneliti, pengembang sistem, hingga pelaku pasar. Salah satu daya tarik utama dari *Alpha Vantage* adalah kemudahannya dalam menyediakan data historis dan real-time untuk berbagai instrumen keuangan, termasuk saham, mata uang, indeks, dan kripto. Popularitasnya di kalangan peneliti *machine learning* dan pelaku pasar berbasis data tumbuh seiring dengan dokumentasinya yang terbuka serta dukungan antarmuka pemrograman yang mudah diintegrasikan ke berbagai bahasa seperti *Python*, *R*, dan *JavaScript* (*Alpha Vantage*, 2024).

Secara fungsional, *Alpha Vantage* menawarkan beragam fitur yang sangat mendukung penelitian berbasis prediksi saham, khususnya dengan metode *deep learning*. Platform ini menyediakan data *time series* untuk berbagai resolusi waktu, mulai dari intraday (menit), daily (harian), weekly (mingguan), hingga monthly (bulanan). Hal ini memungkinkan peneliti untuk menyesuaikan tingkat granularitas data sesuai kebutuhan

model. Selain data harga saham, *Alpha Vantage* juga menyajikan data fundamental perusahaan seperti income statement, balance sheet, dan rasio keuangan. Komponen ini penting bagi analisis kuantitatif atau kombinasi antara pendekatan teknikal dan fundamental. Tidak hanya itu, tersedia pula ratusan indikator teknikal seperti SMA (Simple Moving Average), EMA, RSI (Relative Strength Index), MACD, Bollinger Bands, dan lainnya, yang semuanya dapat diakses secara langsung melalui endpoint yang telah ditentukan. *Alpha Vantage* bahkan menyediakan data performa sektor (sector performance) yang membandingkan kinerja harga berdasarkan sektor industri dalam pasar modal.

Penggunaan *Alpha Vantage* dalam penelitian memerlukan *API key* yang dapat diperoleh secara gratis setelah registrasi. *API key* ini menjadi bagian penting dalam setiap request untuk mengakses data. Pengguna cukup menyusun parameter request seperti *function*, *symbol*, *interval*, dan *apikey* ke dalam URL endpoint yang sesuai. Sebagai contoh, untuk mengambil data harian saham BCA (kode saham BBKA), endpoint yang digunakan adalah `TIME_SERIES_DAILY` dengan simbol BBKA.JK, format default `JSON`, dan dilengkapi *API key*. Fleksibilitas parameter dan endpoint inilah yang membuat *Alpha Vantage* ideal untuk proses otomatisasi pengumpulan data menggunakan skrip *Python* atau *notebook Jupyter*, terutama dalam studi prediksi harga saham berbasis LSTM dan BiLSTM.

Format data yang disediakan oleh *Alpha Vantage* sangat ramah pengguna. Secara default, data diberikan dalam bentuk `JSON`, namun pengguna juga dapat memilih format `CSV` untuk keperluan analisis statistik lanjutan. Setiap endpoint memiliki struktur penamaan yang konsisten, sehingga memudahkan dalam proses parsing data ke dalam `DataFrame` atau database. Endpoint yang tersedia antara lain `TIME_SERIES_DAILY`, `SMA`, `INCOME_STATEMENT`, dan `SECTOR`. Dukungan ini menjadikan *Alpha Vantage* sangat cocok untuk studi akademik seperti penelitian ini, karena menghemat

waktu pengumpulan data dan memungkinkan peneliti untuk fokus pada eksperimen model prediktif.

Dalam konteks penelitian ini, *Alpha Vantage* digunakan sebagai sumber utama pengambilan data harga saham harian dari dua saham unggulan yaitu Bank Central Asia (BBCA) dan Telkom Indonesia (TLKM). Data yang diambil mencakup harga penutupan harian (closing price), volume transaksi, dan indikator teknikal pendukung yang digunakan sebagai fitur dalam pelatihan model *deep learning*. Integrasi *Alpha Vantage* dengan pipeline *preprocessing* data, normalisasi, dan pelatihan model LSTM/BiLSTM sangat efisien, sekaligus mendukung prinsip replikasi penelitian karena datanya mudah diakses oleh peneliti lain (*Alpha Vantage*, 2024).

2.6. *Grid Search*

2.6.1. Konsep dan Penerapan *Grid Search* dalam *Deep Learning*

Grid Search merupakan metode eksplorasi sistematis yang digunakan untuk menemukan kombinasi *hyperparameter* terbaik dalam pelatihan model *machine learning* maupun *deep learning*. Teknik ini melakukan pencarian menyeluruh dengan menguji semua kemungkinan kombinasi dari nilai-nilai parameter yang telah ditentukan sebelumnya. Dalam model prediktif berbasis data deret waktu seperti LSTM (*Long Short-Term Memory*) dan BiLSTM (*Bidirectional LSTM*), pemilihan parameter seperti jumlah *neuron*, *learning rate*, *batch size*, *epoch*, dan *dropout rate* sangat memengaruhi kualitas hasil prediksi. Kombinasi *hyperparameter* yang tidak optimal dapat menyebabkan *underfitting* atau *overfitting*, yaitu kondisi ketika model terlalu sederhana atau terlalu kompleks dalam menyesuaikan data pelatihan (Muzakir et al., 2024).

Sebagai contoh, dalam studi yang dilakukan oleh Puteri et al., (2024), *Grid Search* digunakan untuk mengatur *hyperparameter* pada model BiLSTM dalam prediksi harga

saham syariah Indonesia. Penelitian ini membuktikan bahwa konfigurasi tertentu dari *dropout*, *learning rate*, dan *epoch* secara signifikan meningkatkan akurasi prediksi dibandingkan pengaturan default. Hasil serupa juga ditemukan oleh Simamora et al., (2025), yang menunjukkan peningkatan performa model BiLSTM setelah *tuning* parameter menggunakan *Grid Search*. Jumlah *neuron* yang terlalu sedikit menghambat kemampuan model dalam mengenali pola kompleks, sedangkan jumlah yang terlalu besar meningkatkan risiko *overfitting*. *Learning rate* yang terlalu tinggi menyebabkan ketidakstabilan pelatihan, sementara yang terlalu rendah memperlambat proses konvergensi. *Dropout* digunakan untuk meningkatkan generalisasi model dengan mematikan sebagian *neuron* secara acak saat pelatihan.

Dalam implementasinya, *Grid Search* biasanya diterapkan menggunakan pustaka seperti *GridSearchCV* pada *scikit-learn* atau skrip iteratif khusus pada framework *deep learning* seperti *Keras* dan *TensorFlow*. Ruang pencarian (parameter space) ditentukan berdasarkan literatur terdahulu, hasil eksperimen awal, dan parameter default yang umum digunakan. Misalnya, *learning rate* sering kali diuji dalam kisaran 0.001 hingga 0.01, *dropout rate* antara 0.2 hingga 0.5, dan jumlah *neuron* antara 50 hingga 200 (Muzakir et al., 2024). *Grid Search* memberikan landasan eksperimen yang kuat dalam proses *tuning* karena menyajikan proses eksplorasi yang sistematis dan menyeluruh terhadap semua kemungkinan konfigurasi

2.6.2. Evaluasi, Perbandingan, dan Contoh Implementasi

Kelebihan utama *Grid Search* adalah kemampuannya dalam mengevaluasi seluruh kombinasi parameter secara menyeluruh, sehingga memungkinkan identifikasi konfigurasi optimal dari ruang pencarian yang telah ditentukan. Namun, teknik ini juga memiliki kekurangan, terutama dalam hal konsumsi waktu dan sumber daya komputasi. Ketika jumlah parameter dan variasi nilai meningkat, jumlah kombinasi yang harus diuji juga meningkat secara eksponensial. Sebagai pembanding, metode *Random Search* hanya mencoba beberapa kombinasi acak dari ruang parameter, sehingga lebih efisien dalam

waktu tetapi tidak menjamin pencapaian hasil optimal (Simamora et al., 2025; Muzakir et al., 2024)

Perbandingan *Grid Search* dan *Random Search* dapat disajikan kedalam tabel sebagai berikut:

Tabel 2.1 Perbandingan *Grid Search* dan *Random Search*

No.	Aspek	<i>Grid Search</i>	<i>Random Search</i>
1	Strategi	Mencoba semua kombinasi parameter	Mengambil kombinasi secara acak
2	Eksplorasi	Menyeluruh	Terbatas pada kombinasi acak
3	Efisiensi waktu	Rendah pada ruang parameter besar	Tinggi pada ruang parameter besar
4	Jaminan hasil optimal	Ya (dalam ruang yang ditentukan)	Tidak selalu optimal
5	Cocok untuk	Model kecil–menengah	Model besar dan ruang parameter luas

Meskipun *Grid Search* cenderung memakan lebih banyak waktu, penelitian seperti yang dilakukan oleh Puteri et al. (2024) menunjukkan bahwa metode ini tetap relevan dan efektif, khususnya dalam konteks akademik dan eksplorasi ilmiah. Mereka menggunakan *Grid Search* untuk mengevaluasi model BiLSTM dalam memprediksi harga saham syariah dengan variasi konfigurasi, seperti *batch size*, jumlah *epoch*, dan *dropout rate*, yang masing-masing diuji dengan kombinasi yang sistematis. Proses ini menghasilkan konfigurasi terbaik berdasarkan nilai *Mean Squared Error (MSE)* dan *Mean Absolute Percentage Error (MAPE)*

Dalam penelitian ini, *Grid Search* diterapkan untuk mengevaluasi performa model LSTM dan BiLSTM pada data harga saham BBKA dan TLKM. Eksperimen dilakukan dengan menguji berbagai kombinasi parameter: jumlah *neuron* (50, 100, 150), *batch size* (16, 32), *learning rate* (0.001, 0.005), *epoch* (50, 100), dan *dropout rate* (0.2, 0.3, 0.5). Evaluasi performa dilakukan menggunakan metrik regresi seperti MSE, RMSE, dan MAPE. *Cross-validation* digunakan untuk memastikan bahwa hasil tidak bias terhadap

subset data tertentu, dan konfigurasi dengan performa terbaik dari seluruh metrik dipilih sebagai konfigurasi akhir untuk pelatihan model.

Dengan metode ini, *Grid Search* tidak hanya menjadi alat *tuning data*, tetapi juga menjadi pendekatan eksperimental yang mendalam dalam pencarian performa model terbaik. Ini sangat penting dalam konteks prediksi harga saham yang bersifat non-linear dan fluktuatif, di mana pendekatan tradisional sering gagal menangkap dinamika pasar secara akurat.

2.7. Metrik Evaluasi Model

Evaluasi model merupakan proses penting dalam pembelajaran mesin (*machine learning*) dan pembelajaran mendalam (*deep learning*) untuk mengukur sejauh mana model mampu menghasilkan prediksi yang akurat terhadap data yang tidak pernah dilihat sebelumnya, yaitu data uji. Tujuan utama dari evaluasi ini adalah untuk menilai kemampuan generalisasi model, mengidentifikasi kemungkinan *overfitting* atau *underfitting*, serta membandingkan performa dari beberapa model atau konfigurasi berbeda (Simamora et al., 2025).

Dalam konteks prediksi harga saham, proses evaluasi menjadi sangat krusial karena harga saham bersifat fluktuatif dan mengandung pola non-linear yang kompleks. Tanpa evaluasi yang tepat, model bisa memberikan hasil yang tampak akurat di data pelatihan tetapi gagal dalam mengantisipasi pergerakan harga aktual. Hal ini berpotensi menyebabkan kesalahan analisis dalam pengambilan keputusan investasi (Setyawan, 2023). Oleh karena itu, diperlukan metrik evaluasi yang mampu menggambarkan tingkat kesalahan model secara kuantitatif maupun kualitatif.

2.7.1. Mean Squared Error (MSE)

Mean Squared Error (MSE) adalah metrik regresi paling umum yang digunakan untuk menghitung rata-rata dari kuadrat selisih antara nilai aktual dan nilai hasil prediksi. Rumus MSE secara matematis ditulis sebagai berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.8)$$

Dimana:

n = jumlah total data (observasi),

y_i = nilai aktual pada data ke- i ,

$\hat{y}_i$ = nilai prediksi oleh model pada data ke- i .

Semakin kecil nilai MSE, maka semakin baik model dalam memprediksi nilai yang mendekati kenyataan. Namun, karena menghitung kuadrat dari error, MSE sangat sensitif terhadap outlier atau error yang besar. Pipin, Purba, dan Kurniawan (2023) mencatat bahwa penggunaan *tuning* parameter secara tepat pada model RNN-LSTM dapat menurunkan MSE secara signifikan dalam konteks prediksi saham.

2.7.2. Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) adalah akar kuadrat dari MSE. Metrik ini berguna karena nilai akhirnya memiliki satuan yang sama dengan nilai target, misalnya dalam konteks harga saham, sehingga lebih mudah untuk diinterpretasikan secara praktis. Rumus RMSE ditulis sebagai:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.9)$$

Dengan menggunakan metrik ini, investor atau peneliti dapat memahami secara langsung sejauh mana prediksi model berbeda dari nilai aktual dalam satuan yang relevan. Dalam studi oleh Setyawan (2023), RMSE dijadikan sebagai metrik utama karena mampu menyampaikan deviasi prediktif secara realistis dalam konteks pasar saham harian.

2.7.3. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan salah satu metrik evaluasi yang digunakan untuk mengukur tingkat kesalahan prediksi model regresi dalam bentuk persentase. MAPE menghitung rata-rata dari nilai absolut selisih antara nilai aktual dan prediksi, kemudian membaginya dengan nilai aktual dan mengalikannya dengan 100. Rumus umum MAPE dituliskan sebagai berikut

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (2.10)$$

Dimana:

y_i = nilai aktual pada data ke- i

$\hat{y}_i$ = nilai prediksi oleh model pada data ke- i .

n = jumlah data

Tabel 2.2 Kriteria Nilai MAPE

MAPE (%)	Interpretasi
< 10%	Akurasi sangat tinggi
10% – 20%	Akurasi baik
20% – 50%	Akurasi sedang
> 50%	Akurasi rendah / buruk

MAPE sangat populer digunakan karena menghasilkan skor yang mudah diinterpretasikan oleh pengguna non-teknis, yaitu dalam bentuk persentase rata-rata kesalahan prediksi. Semakin kecil nilai MAPE, semakin baik performa model. Nilai MAPE sebesar 5% mengindikasikan bahwa prediksi model, secara rata-rata, meleset sebesar 5% dari nilai sebenarnya.

2.8. Studi Literatur

Tabel 2.3 Studi Literatur

No.	Penulis	Judul Penelitian	Hasil Penelitian
-----	---------	------------------	------------------

	(Tahun)		
1	Puteri, D. I., Darmawan, G., & Ruchjana, B. N. (2024)	<i>Prediksi Harga Saham Syariah Menggunakan BiLSTM dan Algoritma Grid Search</i>	Penelitian ini menunjukkan bahwa <i>Grid Search</i> secara signifikan meningkatkan performa BiLSTM. Proses <i>tuning hyperparameter</i> seperti <i>epoch</i> , <i>batch size</i> , dan <i>dropout</i> menghasilkan model prediktif yang lebih akurat.
2	Simamora, F. P., Purba, R., & Pasha, M. F. (2025)	<i>Optimisasi Hyperparameter BiLSTM Menggunakan Bayesian Optimization untuk Prediksi Harga Saham</i>	Hasil studi menunjukkan bahwa <i>tuning parameter</i> BiLSTM sangat krusial terhadap akurasi prediksi. Meski menggunakan <i>Bayesian Optimization</i> , prinsipnya memperkuat pentingnya eksplorasi parameter seperti pada <i>Grid Search</i> dalam meningkatkan performa model <i>deep learning</i> .
3	Puteri, D. I. (2023)	<i>Implementasi LSTM dan BiLSTM dalam Prediksi Harga Saham Syariah</i>	Penelitian ini menunjukkan bahwa BiLSTM memiliki performa lebih baik dibanding LSTM dalam memprediksi harga saham syariah, karena mampu memproses data secara dua arah dan menangkap pola kompleks <i>time series</i> lebih efektif.
4	Muzakir, A., Komari, A., &	<i>Penerapan Konsep Machine Learning & Deep Learning</i>	Buku ini memberikan landasan teoretis mengenai arsitektur LSTM dan BiLSTM, serta pentingnya optimasi

	Ilham, M. (2024)		<i>hyperparameter</i> menggunakan <i>Grid Search</i> . Pemahaman ini menjadi fondasi penting dalam membangun model prediksi harga saham berbasis <i>time series</i> .
5	Hanafiah, M., Agusta, S., & Puteri, D. I. (2023)	<i>Penerapan Metode RNN dengan Pendekatan LSTM untuk Prediksi Harga Saham</i>	Studi ini fokus pada penerapan LSTM sebagai model berbasis RNN dalam prediksi harga saham. Hasilnya menunjukkan bahwa LSTM unggul dalam menangani data berurutan dengan ketergantungan temporal, meskipun belum dibandingkan langsung dengan BiLSTM.

Kajian penelitian sebelumnya menunjukkan bahwa penggunaan model *deep learning*, terutama LSTM dan BiLSTM, menjadi pendekatan populer dalam prediksi harga saham. Penelitian oleh Puteri, Darmawan, dan Ruchjana (2024) menjadi acuan utama karena mengkaji langsung penggunaan BiLSTM dalam prediksi harga saham syariah dengan mengintegrasikan algoritma *Grid Search* untuk optimasi *hyperparameter*. Penelitian ini menunjukkan bahwa kombinasi BiLSTM dan *Grid Search* mampu menurunkan nilai MAPE secara signifikan melalui *tuning* parameter seperti *epoch*, *dropout*, dan *batch size*. Studi ini secara eksplisit menegaskan bahwa pemilihan konfigurasi parameter yang tepat sangat menentukan performa model. Hasil ini memperkuat pentingnya optimasi terstruktur, menjadikan *Grid Search* tidak hanya sebagai alat pendukung teknis, tetapi sebagai bagian integral dalam proses pengembangan model prediktif yang presisi.

Simamora, Purba, dan Pasha (2025) juga mengangkat isu yang serupa dengan fokus pada optimisasi *hyperparameter* BiLSTM menggunakan pendekatan *Bayesian Optimization*. Meskipun metode optimasinya berbeda, penelitian ini menyoroti aspek yang sama: *tuning* parameter merupakan kunci utama untuk meningkatkan kinerja model prediksi saham. Penelitian ini menunjukkan peningkatan signifikan dalam akurasi setelah dilakukan penyesuaian parameter seperti jumlah *neuron* dan *learning rate*. Temuan ini menunjukkan bahwa tanpa proses *tuning*, performa BiLSTM tidak akan mencapai potensi optimalnya. Oleh karena itu, pendekatan eksperimen terhadap *hyperparameter* juga menjadi kontribusi utama dalam penelitian Anda.

Selanjutnya, Puteri (2023) melakukan komparasi antara model LSTM dan BiLSTM dalam konteks prediksi saham syariah. Hasil penelitian tersebut menunjukkan bahwa BiLSTM memberikan hasil prediksi yang lebih akurat dibandingkan LSTM, karena kemampuannya membaca urutan data dari dua arah. Arsitektur BiLSTM yang menangkap konteks masa lalu dan masa depan secara bersamaan terbukti lebih efektif dalam memahami pola-pola harga saham yang bersifat kompleks dan fluktuatif. Penelitian ini memperkuat dasar pemilihan BiLSTM dalam penelitian Anda, sekaligus memberikan justifikasi kuat untuk melakukan perbandingan eksplisit antara LSTM dan BiLSTM pada data pasar saham Indonesia.

Sebagai pelengkap landasan konseptual, Muzakir, Komari, dan Ilham (2024) dalam bukunya menjelaskan secara rinci teori mengenai *machine learning* dan *deep learning*, termasuk arsitektur LSTM, BiLSTM, serta berbagai teknik optimasi *hyperparameter* seperti *Grid Search*. Buku ini menjadi sumber yang penting dalam membangun kerangka teoretis, karena tidak hanya menjelaskan bagaimana model bekerja secara struktural, tetapi juga menyampaikan pentingnya eksplorasi kombinasi parameter untuk meningkatkan generalisasi model terhadap data baru. Kehadiran buku ini memperkuat aspek teoritik dalam penelitian Anda dan menjembatani antara konsep dan implementasi.

Penelitian oleh Hanafiah, Agusta, dan Puteri (2023) memperkenalkan penerapan LSTM dalam memprediksi harga saham dengan pendekatan *Recurrent Neural Network* (RNN). Studi ini memberikan bukti bahwa LSTM mampu menangani data deret waktu dengan baik, mengingat struktur memorinya yang adaptif terhadap ketergantungan jangka panjang. Meskipun belum membandingkan dengan BiLSTM, hasil penelitian ini tetap relevan sebagai dasar awal penggunaan LSTM sebagai *baseline* model dalam penelitian Anda, yang kemudian akan dibandingkan secara kuantitatif dengan performa BiLSTM.

Berdasarkan kajian terhadap kelima penelitian tersebut, dapat disimpulkan bahwa penggunaan model *deep learning* seperti LSTM dan BiLSTM telah terbukti efektif dalam menangani prediksi harga saham yang bersifat non-linear dan kompleks. Namun, sebagian besar studi masih terbatas pada penerapan tunggal atau belum melakukan perbandingan performa secara mendalam dengan pendekatan optimasi sistematis. Oleh karena itu, penelitian ini hadir untuk mengisi celah tersebut dengan cara membandingkan kinerja LSTM dan BiLSTM secara empiris dalam konteks pasar saham Indonesia, serta mengintegrasikan *Grid Search* sebagai strategi optimasi untuk memperoleh konfigurasi parameter terbaik. Dengan demikian, penelitian ini tidak hanya memperkuat temuan-temuan sebelumnya, tetapi juga memberikan kontribusi baru dalam hal pendekatan eksperimental dan praktik prediksi harga saham yang lebih akurat dan dapat direplikasi oleh peneliti atau praktisi lainnya.

BAB III

METODOLOGI PENELITIAN

3.1. Jenis Penelitian

Penelitian ini merupakan penelitian kuantitatif komparatif dengan pendekatan eksperimen komputasional. Metode kuantitatif digunakan karena penelitian ini bertujuan untuk mengukur dan membandingkan performa dua model *deep learning*, yaitu *Long Short-Term Memory (LSTM)* dan *Bidirectional Long Short-Term Memory (BiLSTM)*, dalam memprediksi harga saham berdasarkan data historis secara numerik dan objektif.

Pendekatan komparatif dipilih karena fokus utama penelitian adalah membandingkan akurasi dan efisiensi dari dua model yang berbeda. Melalui pendekatan ini, peneliti dapat melakukan evaluasi kinerja kedua model berdasarkan metrik yang sama, seperti *Mean Squared Error (MSE)*, *Root Mean Squared Error (RMSE)*, dan *Mean Absolute Percentage Error (MAPE)*. Dengan demikian, penelitian ini dapat mengidentifikasi model mana yang lebih unggul dalam menangani kompleksitas dan fluktuasi harga saham.

Sementara itu, pendekatan eksperimen komputasional digunakan karena seluruh proses pelatihan, validasi, dan pengujian model dilakukan menggunakan perangkat lunak berbasis Python, dengan pustaka TensorFlow dan Keras. Penelitian ini juga menerapkan teknik *Grid Search* sebagai metode bantu untuk mengoptimalkan kombinasi *hyperparameter*, seperti jumlah neuron, *batch size*, *epoch*, dan *dropout rate*, agar diperoleh konfigurasi terbaik yang meningkatkan akurasi model.

Pendekatan ini relevan karena data yang digunakan adalah data deret waktu harga saham yang bersifat sekuensial. Oleh karena itu, model prediksi memerlukan metode khusus seperti LSTM dan BiLSTM yang mampu menangani ketergantungan temporal. Dengan lingkungan eksperimen yang terstruktur dan sistematis, hasil penelitian ini

diharapkan dapat diukur secara objektif, direplikasi, dan memberikan kontribusi dalam pengembangan sistem prediksi harga saham yang lebih adaptif dan akurat.

3.2. Sumber dan Teknik Pengumpulan Data

3.2.1. Sumber Data

Penelitian ini menggunakan data sekunder yang bersifat kuantitatif historis dan diperoleh dari layanan *Alpha Vantage API*, yakni penyedia data keuangan berbasis cloud yang menyediakan akses gratis dan berstandar industri terhadap data pasar modal global. *Alpha Vantage* dipilih sebagai sumber data utama karena memiliki dokumentasi lengkap, mendukung format data terbuka (*JSON* dan *CSV*), serta menyediakan endpoint yang kompatibel dengan kebutuhan prediksi harga saham berbasis *deep learning*.

Data yang diunduh mencakup lima fitur utama, yaitu harga pembukaan (*Open*), tertinggi (*High*), terendah (*Low*), penutupan (*Close*), dan volume perdagangan (*Volume*) dari dua perusahaan *blue chip* yang terdaftar di Bursa Efek Indonesia:

1. PT Bank Central Asia Tbk (BBCA)
2. PT Telkom Indonesia Tbk (TLKM)

Rentang data yang digunakan adalah Januari 2019 hingga Desember 2023. Saham BBCA dan TLKM dipilih karena mewakili saham *blue chip* dengan likuiditas tinggi dan fundamental yang kuat di pasar modal Indonesia. Dari lima fitur OHLCV yang tersedia, hanya harga penutupan (*Close*) yang digunakan dalam pemodelan karena paling umum mewakili nilai akhir suatu sesi perdagangan dan relevan untuk analisis deret waktu. Berikut ini adalah daftar variabel awal dalam dataset:

Tabel 3.1 Variabel Harga Saham

No.	Variabel	Keterangan
1	Open Price	Harga pembukaan setiap hari perdagangan
2	High Price	Harga tertinggi dalam satu hari perdagangan
3	Low Price	Harga terendah dalam satu hari perdagangan
4	Close Price	Harga penutupan pada akhir hari perdagangan
5	Volume	Jumlah total saham yang diperdagangkan per hari

3.2.2. Teknik Pengumpulan Data

Penelitian ini menggunakan data harga saham harian yang diperoleh secara otomatis melalui Alpha Vantage API. Proses pengambilan data dilakukan menggunakan bahasa pemrograman Python dengan pendekatan programatik, mulai dari pendaftaran API hingga penyimpanan data dalam format CSV. Tahapan lengkap dijelaskan dalam Tabel 3.2 berikut:

Tabel 3.2 Proses Pengumpulan Data Saham

No.	Langkah	Deskripsi
1	Mendaftar dan mendapatkan API Key	Mengakses situs <i>Alpha Vantage</i> dan registrasi untuk memperoleh API Key.
2	Menentukan simbol saham	Menggunakan <i>BBCA.JK</i> dan <i>TLKM.JK</i> sebagai kode saham di Bursa Efek Indonesia.
3	Memilih endpoint API	Menggunakan <i>TIME_SERIES_DAILY_ADJUSTED</i> untuk mendapatkan data harian historis.
4	Memanggil API dengan <i>Python</i>	Menggunakan library <i>requests</i> untuk mengakses URL API secara programatik.
5	Menentukan rentang waktu	Menyaring data dari 1 Januari 2019 sampai 31 Desember 2023.
6	Menyimpan hasil sebagai file <i>CSV</i>	Data yang diperoleh disimpan dalam format <i>.csv</i> untuk keperluan analisis lanjutan.

3.3. Teknik Analisis Data

Analisis data dalam penelitian ini dilakukan dengan pendekatan eksperimen komputasional berbasis *Python*, yang mencakup tahapan *preprocessing*, pelatihan model, optimasi *hyperparameter* evaluasi performa, dan perbandingan hasil antar model.

3.3.1 *Preprocessing* Data

Sebelum dilakukan pelatihan model, data harga saham yang diperoleh dari Alpha Vantage perlu melalui tahap *preprocessing* untuk memastikan struktur data sesuai dengan kebutuhan model deep learning. Proses ini bertujuan untuk meningkatkan akurasi prediksi, menghindari noise, dan mengatasi perbedaan skala data yang dapat

memengaruhi hasil pembelajaran. Adapun tahapan preprocessing yang dilakukan dalam penelitian ini meliputi:

1. Ekstraksi kolom harga penutupan (*close*) dari dataset.
2. Penerapan *sliding window*, yaitu membentuk *input* dan target (*label*) untuk memodelkan pola berurutan pada data deret waktu.
3. Normalisasi data menggunakan metode *Min-Max Scaler* untuk menjaga skala nilai tetap seragam antara 0 dan 1.
4. Pembagian dataset menjadi data latih dan data uji dengan rasio 80:20 untuk menghindari *overfitting* dan memastikan evaluasi obyektif.

3.3.2 Pelatihan Model LSTM dan BiLSTM

Model LSTM dan BiLSTM dibangun menggunakan pustaka *Tensorflow* dan *Keras*. Masing-masing model dilatih pada data latih dengan konfigurasi awal (*baseline*) untuk memperoleh gambaran awal performa sebelum dilakukan proses optimasi. Arsitektur model terdiri dari satu atau dua lapisan LSTM/BiLSTM, yang dilengkapi dengan dropout layer untuk mengurangi risiko overfitting, dan dense layer sebagai output regresi.

Tabel 3.3 Parameter Arsitektur Model

No.	Parameter	Nilai	Keterangan
1	Input shape	(60, 1)	Urutan 60 hari harga penutupan
2	Units (neuron)	64	Jumlah neuron di lapisan utama
3	Dropout	0.2	Untuk mencegah overfitting
4	Return sequences	False	Hanya digunakan 1 lapisan utama
5	Output layer	Dense (1 unit)	Regresi nilai harga penutupan
6	Loss function	Mean Squared Error	Untuk mengukur selisih prediksi
7	Optimizer	Adam	Digunakan karena stabil dan adaptif
8	Metrics	Mean Absolute Error	Untuk monitoring selama training

Setelah pelatihan awal dilakukan, tahap selanjutnya adalah optimasi *hyperparameter* menggunakan Grid Search, sebagaimana dijelaskan pada subbab 3.3.3.

3.3.3 Optimasi *Hyperparameter* Menggunakan *Grid Search*

Setelah pelatihan awal dilakukan, tahap selanjutnya adalah mengoptimalkan performa model dengan menentukan kombinasi *hyperparameter* terbaik. Optimasi dilakukan menggunakan metode *Grid Search*, yaitu pendekatan eksploratif sistematis yang menguji semua kemungkinan kombinasi dari sejumlah nilai parameter yang telah ditentukan sebelumnya.

Seluruh kombinasi tersebut diujicobakan pada data latih dan divalidasi terhadap data uji menggunakan metrik evaluasi seperti Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan *Mean Absolute Percentage Error (MAPE)*. Konfigurasi terbaik ditentukan berdasarkan hasil evaluasi dengan MSE, RMSE dan MAPE paling rendah. Berikut adalah parameter yang diuji dalam *Grid Search*:

Tabel 3.4 Parameter *Grid Search*

No.	Hyperparameter	Nilai yang Diuji	Fungsi dalam Model
1	Units (neuron)	5, 10, 15, 20, 25	Menentukan kapasitas memorisasi model dalam <i>hidden layer</i>
2	Batch size	4, 16, 32, 64, 128	Ukuran subset data untuk update bobot setiap iterasi
3	Epochs	50, 100, 150, 200, 250	Jumlah siklus pelatihan model terhadap keseluruhan data
4	Dropout	0,1; 0,2; 0,3	Mengurangi <i>overfitting</i> dengan menonaktifkan sebagian <i>neuron</i>

Dengan pendekatan ini, *Grid Search* tidak hanya digunakan sebagai metode bantu teknis, tetapi juga menjadi komponen penting dalam proses eksperimen untuk menemukan konfigurasi model terbaik. Evaluasi terhadap ratusan kombinasi parameter dilakukan secara sistematis guna meningkatkan akurasi, stabilitas, dan keandalan model dalam melakukan prediksi harga saham berbasis *deep learning*.

3.3.4 Evaluasi Kinerja Model

Setelah model dilatih dan dioptimalkan menggunakan *Grid Search*, langkah selanjutnya adalah melakukan evaluasi kinerja untuk menilai efektivitas model dalam melakukan prediksi. Evaluasi dilakukan menggunakan tiga metrik regresi utama, yaitu:

1. *Mean Squared Error (MSE)* untuk mengukur rata-rata kuadrat kesalahan prediksi.
2. *Root Mean Squared Error (RMSE)* merupakan Akar dari MSE, memberikan gambaran kesalahan dalam satuan aslinya.
3. *Mean Absolute Percentage Error (MAPE)* untuk mengukur rata-rata persentase kesalahan terhadap nilai aktual.


Ketiga metrik ini digunakan secara bersamaan, baik dalam proses validasi *Grid Search* maupun evaluasi akhir, untuk memberikan gambaran menyeluruh terhadap akurasi dan generalisasi model.

3.3.5 Perbandingan Hasil dan Visualisasi

Tahap akhir dalam analisis data adalah membandingkan performa model LSTM dan BiLSTM berdasarkan hasil evaluasi menggunakan metrik MSE, RMSE, dan MAPE. Model terbaik ditentukan dari kombinasi nilai MSE, RMSE dan MAPE terendah, yang mencerminkan tingkat akurasi dan kemampuan generalisasi yang optimal.

Selain evaluasi numerik, dilakukan pula visualisasi grafik perbandingan antara nilai aktual dan hasil prediksi pada data uji. Grafik ini disajikan untuk masing-masing model (LSTM dan BiLSTM) pada kedua saham (BBCA dan TLKM), guna mengamati sejauh mana model mampu mengikuti tren harga saham. Visualisasi ini juga digunakan untuk mengidentifikasi indikasi *overfitting* atau *underfitting* serta mengevaluasi sensitivitas model terhadap fluktuasi pasar.

Untuk mengidentifikasi potensi penyebab ketidakoptimalan akurasi dalam proses prediksi harga saham menggunakan model LSTM dan BiLSTM, peneliti menyusun diagram *fishbone* sebagai berikut:



Gambar 3.1 Diagram *Fishbone*

Berdasarkan gambar 3.1 di atas digunakan untuk mengidentifikasi faktor-faktor yang dapat menyebabkan akurasi prediksi harga saham menggunakan model LSTM dan BiLSTM tidak optimal. Diagram ini disusun dengan pendekatan $5M + 1E$, yang meliputi aspek *Man*, *Machine*, *Method*, *Material*, *Measurement*, dan *Environment*.

1. *Man* (Manusia)

Faktor manusia berfokus pada keterlibatan peneliti. Eksplorasi terhadap pengaruh hyperparameter masih terbatas, dan belum tersedia sistem evaluasi otomatis antar model. Keterbatasan ini dapat berdampak pada pengambilan keputusan yang kurang optimal dalam pemilihan konfigurasi model.

2. *Machine* (Perangkat/Sistem)

Platform eksperimen menggunakan Google Colab memiliki keterbatasan dalam hal RAM dan waktu eksekusi. Selain itu, proses pelatihan dan evaluasi model sangat bergantung pada koneksi internet dan runtime cloud, yang bisa mempengaruhi stabilitas eksperimen.

3. *Method* (Metode)

Pendekatan metode masih memiliki ruang perbaikan. Model belum diuji menggunakan teknik validasi silang seperti *TimeSeriesSplit*, dan belum dibandingkan

dengan pendekatan lain seperti GRU yang bisa menjadi alternatif dari LSTM dan BiLSTM.

4. *Material* (Data)

Kualitas data yang digunakan juga menjadi salah satu penyebab utama. Dataset berasal dari Alpha Vantage yang memiliki keterbatasan struktur dan hanya menggunakan harga penutupan (*closing price*) tanpa melibatkan fitur tambahan seperti indikator teknikal atau volume.

5. *Measurement* (Pengukuran)

Evaluasi model terbatas pada dua metrik utama, yaitu MSE dan RMSE. Tidak ada analisis lebih lanjut terhadap performa model dalam kondisi pasar yang ekstrem atau tidak stabil, sehingga hasil evaluasi belum mencerminkan robustnes secara menyeluruh.

6. *Environment* (Lingkungan)

Faktor eksternal juga memengaruhi eksperimen. *API Alpha Vantage* memiliki batasan penggunaan (*rate limit*), dan seluruh proses eksperimen dilakukan dalam rentang waktu yang sempit mengikuti jadwal akademik. Kondisi ini membatasi fleksibilitas dalam replikasi dan eksplorasi lanjutan.

3.4. Alat dan Perangkat Penelitian

Penelitian ini menggunakan berbagai alat dan perangkat, baik perangkat keras (*hardware*) maupun perangkat lunak (*software*), yang mendukung proses tahapan eksperimen secara komputasional. Rincian alat dan perangkat yang digunakan disajikan pada Tabel 3.5 berikut:

Tabel 3.5 Alat dan Perangkat Penelitian

No.	Nama	Jenis	Spesifikasi / Keterangan
1	Asus TUF Dash F15	Perangkat	RAM 16 GB, SSD 512 GB, GPU NVIDIA RTX 3060, OS Windows 11
2	<i>Visual Studio Code</i>	Alat	Editor kode yang digunakan untuk menulis dan menjalankan program secara lokal

3	<i>Google Colab</i>	Alat	<i>Platform</i> komputasi awan berbasis <i>Python</i> , mendukung GPU/TPU
4	<i>Python</i>	Alat	Versi 3.10.6
5	<i>TensorFlow & Keras</i>	Alat	<i>Library deep learning</i> (<i>TensorFlow 2.x</i> , <i>Keras</i> sebagai API-nya)
6	<i>Alpha Vantage API</i>	Alat	<i>Endpoint: TIME_SERIES_DAILY</i> , Output: <i>JSON/CSV</i>
7	<i>Scikit-learn</i>	Alat	<i>Library machine learning</i> (versi 1.x)
8	<i>Matplotlib & Seaborn</i>	Alat	<i>Library</i> visualisasi data
9	<i>NumPy & Joblib</i>	Alat	Untuk penyusunan dataset time series dan penyimpanan scaler

Penelitian ini didukung oleh seperangkat alat dan tools berbasis komputasi yang digunakan untuk menunjang proses pelatihan dan evaluasi model *deep learning*. Berdasarkan Tabel 3.1, laptop yang peneliti gunakan adalah Asus TUF Dash F15 dengan spesifikasi RAM 16 GB, SSD 512 GB, dan GPU NVIDIA RTX 3060, yang berjalan pada sistem operasi Windows 11. Spesifikasi ini cukup untuk mendukung proses eksperimen lokal maupun koneksi ke platform komputasi awan.

Untuk proses pengembangan dan pengujian kode program secara lokal, peneliti menggunakan Visual Studio Code (VS Code) sebagai editor utama. VS Code dipilih karena mendukung integrasi pustaka *Python*, terminal, visualisasi direktori proyek, dan pengelolaan *virtual environment* secara fleksibel.

Sebagian besar proses pelatihan dan eksplorasi model dilakukan secara daring melalui Google Colab, yaitu *platform* komputasi awan berbasis *Python* yang menyediakan akses GPU/TPU secara gratis. Google Colab dipilih karena efisien, mudah digunakan, serta terintegrasi langsung dengan pustaka *deep learning* populer seperti TensorFlow dan Keras.

Bahasa pemrograman yang digunakan dalam penelitian ini adalah Python versi 3.10 atau lebih baru, dengan pustaka utama TensorFlow dan Keras sebagai framework


untuk membangun dan melatih arsitektur model LSTM dan BiLSTM. Optimasi parameter dilakukan menggunakan pendekatan eksploratif dengan struktur looping manual di Python, bukan GridSearchCV, karena Grid Search dilakukan terhadap ratusan kombinasi secara eksplisit. Untuk evaluasi dan preprocessing digunakan pustaka Scikit-learn, sedangkan NumPy dan Joblib digunakan untuk menyusun dataset dalam format time series serta menyimpan scaler hasil normalisasi.

Data historis harga saham BBKA dan TLKM diperoleh dari Alpha Vantage API, khususnya menggunakan endpoint `TIME_SERIES_DAILY`, yang menyediakan data harga saham dalam format JSON dan CSV. Pengambilan data dilakukan secara otomatis melalui permintaan HTTP menggunakan pustaka requests, yang kemudian diproses dan disimpan untuk analisis lanjutan.

Untuk kebutuhan visualisasi hasil prediksi, digunakan pustaka Matplotlib dan Seaborn, yang membantu menampilkan grafik perbandingan antara nilai aktual dan hasil prediksi dalam bentuk yang informatif dan mudah diinterpretasikan. Visualisasi ini juga digunakan untuk mendeteksi indikasi overfitting, underfitting, serta respons model terhadap tren pasar. Dengan dukungan perangkat keras dan perangkat lunak tersebut, penelitian ini dapat dilaksanakan secara sistematis dan efisien, serta memungkinkan replikasi eksperimen oleh peneliti lain di masa mendatang.

3.5. Diagram Alur Penelitian

Diagram alur dalam bentuk *Flowchart* berikut digunakan untuk menggambarkan tahapan-tahapan utama dalam penelitian ini secara sistematis. Visualisasi ini mempermudah pemahaman terhadap proses penelitian, mulai dari pengumpulan data hingga evaluasi dan perbandingan model.



Gambar 3.2 Flowchart Penelitian

Untuk memperjelas alur pada Gambar 3.2, berikut ini adalah uraian setiap tahapan berdasarkan urutan pada diagram:

1. Mulai (*Start*)

Penelitian dimulai dengan merumuskan tujuan dan ruang lingkup, serta menetapkan dua model utama yang akan dibandingkan, yaitu LSTM dan BiLSTM.

2. Pengumpulan Data Saham (*Alpha Vantage API*)

Data historis harga saham BBKA dan TLKM diambil melalui Alpha Vantage API menggunakan endpoint `TIME_SERIES_DAILY`, mencakup periode Januari 2019 hingga Desember 2023.

3. *Preprocessing Data*

Meliputi ekstraksi kolom Close, normalisasi data dengan Min-Max Scaler, pembentukan dataset time series dengan metode sliding window, dan pembagian data menjadi 80% data latih dan 20% data uji

4. Pembangunan Model LSTM dan BiLSTM

Masing-masing model dibangun menggunakan TensorFlow dan Keras, dengan konfigurasi awal (*baseline*) yang akan dievaluasi lebih lanjut.

5. Optimasi *Hyperparameter* (*Grid Search*)

Dilakukan eksplorasi terhadap ratusan kombinasi parameter seperti jumlah neuron, batch size, epoch, dan dropout rate, guna menemukan konfigurasi terbaik untuk masing-masing model.

6. Pelatihan Model

Model dilatih menggunakan data latih dan konfigurasi hyperparameter terbaik yang diperoleh dari proses Grid Search.

7. Evaluasi Model

Performa masing-masing model diuji pada data uji menggunakan tiga metrik utama: MSE, RMSE, dan MAPE.

8. Perbandingan Hasil dan Visualisasi

Hasil evaluasi dibandingkan secara numerik dan divisualisasikan untuk mengamati sejauh mana model mampu mengikuti tren harga saham. Visualisasi dilakukan terhadap data BBKA dan TLKM untuk masing-masing model.

9. Selesai (End)

Penelitian ditutup dengan penarikan kesimpulan dan dokumentasi hasil, termasuk pemilihan model terbaik berdasarkan performa keseluruhan.

BAB IV

HASIL DAN PEMBAHASAN

4.1. Deskripsi Data

Penelitian ini menggunakan data sekunder berupa data harga saham harian yang diperoleh dari sumber terbuka melalui layanan *Application Programming Interface (API)* milik *Alpha Vantage*. Data diambil dalam bentuk deret waktu harian yang mencakup lima komponen utama, yaitu harga pembukaan (*open*), harga tertinggi (*high*), harga terendah (*low*), harga penutupan (*close*), dan *volume* perdagangan. Informasi ini menjadi representasi standar dari aktivitas pasar saham dalam periode waktu tertentu dan digunakan sebagai basis untuk membangun model prediksi harga saham.

Proses pengambilan data dilakukan secara otomatis menggunakan bahasa pemrograman *Python* yang mengirim permintaan (*request*) ke *endpoint API Alpha Vantage*. Permintaan ini disusun dengan menyertakan parameter yang sesuai, seperti simbol saham yang ingin diteliti dan jenis data harian yang dibutuhkan. Sistem API kemudian memberikan respons berupa data historis dalam format JSON yang dapat diproses dan dikonversi ke dalam format tabular untuk kepentingan penelitian.

Periode data yang digunakan dalam penelitian ini adalah dari tanggal 1 Januari 2019 hingga 31 Desember 2023. Rentang waktu ini dipilih untuk memastikan ketersediaan data historis yang cukup panjang serta konsisten dalam mencerminkan kondisi pasar dalam jangka menengah. Dengan periode tersebut, model prediksi dapat dibangun dan diuji pada data yang memiliki kontinuitas serta keragaman pergerakan harga yang memadai. Oleh karena itu, hanya data yang berada dalam cakupan waktu tersebut yang disaring dan digunakan dalam proses selanjutnya.

Gambar 4.1 menampilkan kode program yang digunakan untuk mengakses API, mengunduh data harga saham sesuai simbol yang ditentukan, serta melakukan penyaringan berdasarkan tanggal agar sesuai dengan periode yang telah ditetapkan.


```

def get_daily_stock(symbol, start_date, end_date, output_size=1000):
    print(f'Mengambil data saham {symbol}...')

    url = f'https://www.alphavantage.com/query'
    params = {
        'function': 'TIME_SERIES_DAILY',
        'symbol': symbol,
        'apikey': 'demo',
        'datatype': 'json',
        'outputsize': 'full'
    }

    response = requests.get(url, params=params)
    data = response.json()

    if 'Time Series [Daily]' not in data:
        raise Exception(f'Gagal mengambil data saham {symbol}, pesan: {data}')

    df = pd.DataFrame.from_dict(data['Time Series [Daily]'], orient='index')
    df = df.reset_index()
    df.columns = ['date', 'open', 'high', 'low', 'close', 'volume']
    df = df[['open', 'high', 'low', 'close', 'volume']]
    df = df.reset_index()
    df.index = pd.to_datetime(df.date)
    df = df.sort_index()

    # Filter data yang sesuai dengan rentang waktu
    df = df.loc[start_date:end_date]

    return df

```

Gambar 4.1 Pengambilan Data Harga Saham

4.2. Hasil Preprocessing Data

Tahapan preprocessing merupakan langkah awal yang penting dalam penelitian ini. ujuannya adalah untuk menyiapkan data historis harga saham agar dapat diproses secara optimal oleh model deep learning berbasis time series. Data mentah diperoleh melalui *Alpha Vantage API*, yang menyediakan informasi harga saham harian dalam format OHLCV (*Open, High, Low, Close, Volume*). Data ini bersifat time series dan mencerminkan dinamika pasar secara kronologis. Berikut Gambar 4.1 dan Gambar 4.2 yang menampilkan struktur awal data saham BBKA dan TLKM yang masih mengandung beberapa baris metadata serta kolom-kolom selain Close yang tidak dibutuhkan dalam penelitian ini.

	Price	Close	High	Low	Open	Volume
0	Ticker	BBKA.JK	BBKA.JK	BBKA.JK	BBKA.JK	BBKA.JK
1	Date	NaN	NaN	NaN	NaN	NaN
2	2019-01-01	4469.35791015625	4469.35791015625	4469.35791015625	4469.35791015625	0
3	2019-01-02	4503.7392578125	4508.036718938367	4469.35868821565	4469.359588821565	35856000
4	2019-01-03	4482.16796875	4486.547644184363	4396.3009961881805	4469.357906467181	72358000
...	...	...	...	...	...	...
1229	2023-12-21	8798.982421875	8798.982421875	8728.213126256702	8775.3926566689	88116700
1230	2023-12-22	8798.982421875	8822.5721870811	8751.802891462801	8751.802891462801	64449600
1231	2023-12-27	8846.162109375	8898.751875	8798.982578125	8846.162109375	64464700
1232	2023-12-28	8869.751953125	8893.34171895778	8798.982655626682	8798.982655626682	70184600
1233	2023-12-29	8869.751953125	8916.931484790559	8822.572421459441	8893.34171895778	79903400

1234 rows x 6 columns

Gambar 4.2 Tampilan data awal BBKA

Gambar 4.3 menunjukkan fungsi `clean_and_save_csv()` yang digunakan untuk membersihkan data mentah hasil unduhan dari Alpha Vantage. Fungsi ini merupakan langkah pertama dalam proses preprocessing dan bertanggung jawab dalam mengubah data mentah menjadi data bersih yang hanya terdiri atas tanggal (Date) dan harga penutupan (Close), siap untuk dianalisis lebih lanjut.

Langkah pertama yang dilakukan fungsi ini adalah membaca file CSV menggunakan `pandas`, sambil melewati tiga baris pertama yang tidak mengandung data numerik. Hal ini disebabkan oleh adanya informasi metadata dari file Alpha Vantage yang harus diabaikan agar pembacaan data tidak error. Selanjutnya, hanya kolom indeks ke-0 dan ke-1 yang dipilih, yang masing-masing berisi tanggal dan harga penutupan. Kedua kolom ini kemudian dinamai ulang menjadi `Date` dan `Close` untuk menyederhanakan proses transformasi selanjutnya.

Setelah kolom-kolom dipilih, proses dilanjutkan dengan konversi nilai tanggal dari format teks menjadi tipe data `datetime` standar menggunakan fungsi `pd.to_datetime()`. Ini memastikan bahwa tanggal dapat digunakan sebagai indeks deret waktu pada tahap berikutnya. Konversi ini juga menangani kemungkinan kesalahan format dengan menandai nilai tak valid sebagai `NaT` (Not a Time).

Langkah berikutnya adalah penghapusan nilai-nilai yang tidak valid atau kosong (`null`). Dalam fungsi ini, digunakan metode `dropna()` dengan parameter `subset = ['Date', 'Close']`, yang berarti hanya baris-baris yang memiliki nilai lengkap di kedua kolom tersebut yang dipertahankan. Dengan kata lain, baris yang tidak memiliki tanggal valid atau harga penutupan akan dihapus dari dataset. Ini adalah tindakan preventif untuk mencegah error saat proses training, serta untuk memastikan integritas model prediksi.

Setelah nilai-nilai kosong dihapus, kolom `Close` yang sebelumnya masih berupa string dikonversi menjadi tipe numerik float untuk memudahkan proses normalisasi. Terakhir, kolom `Date` dijadikan indeks utama (`index`) dari `DataFrame`, yang merupakan format ideal untuk analisis time series. Setelah semua proses selesai, data yang telah

dibersihkan disimpan kembali ke dalam file CSV dengan nama baru yang mencerminkan bahwa file tersebut sudah melalui proses pembersihan awal.



	Date	Close
0	2019-01-01	4408.357810
1	2019-01-02	4503.738258
2	2019-01-03	4452.167869
3	2019-01-04	4473.655762
4	2019-01-07	4508.035156
...		
1227	2023-12-21	8798.962422
1228	2023-12-22	8798.962422
1229	2023-12-27	8846.162109
1230	2023-12-28	8869.751953
1231	2023-12-29	8869.751953

1232 rows x 2 columns

Gambar 4.5 Tampilan setelah pembersihan data

Gambar 4.4 menunjukkan hasil dari proses pembersihan, di mana hanya dua kolom (*Date* dan *Close*) yang dipertahankan, dan seluruh nilai yang kosong atau tidak valid telah dihapus. Data juga telah disusun ulang dengan *Date* sebagai indeks, menjadikannya format ideal untuk *time series modeling*.

Secara keseluruhan, fungsi ini memastikan bahwa hanya data valid, relevan, dan siap olah yang masuk ke tahap pemrosesan selanjutnya. Langkah-langkah ini bersifat deterministik dan mendukung replikasi, artinya dapat digunakan kembali dengan struktur data serupa dari saham lain tanpa harus melakukan penyesuaian tambahan secara manual.

Setelah data dibersihkan, tahap berikutnya adalah normalisasi harga penutupan ke dalam skala $[0, 1]$. Proses ini dilakukan menggunakan metode *MinMaxScaler* agar nilai-nilai yang besar tidak mendominasi proses pembelajaran model. Selain itu, normalisasi juga mempercepat proses konvergensi saat pelatihan dan mencegah masalah numerik seperti gradien eksplosif.

```
def create_dataset(df, prefix, output_dir="preprocessed", window_size=60, split_ratio=0.8):
    # 1. Scaling
    scaler = MinMaxScaler()
    scaled = scaler.fit_transform(df[['Close']])

    # 2. Sliding window
    X, y = [], []
    for i in range(window_size, len(scaled)):
        X.append(scaled[i - window_size:i])
        y.append(scaled[i])
    X, y = np.array(X), np.array(y)

    # 3. Split
    split_index = int(len(X) * split_ratio)
    X_train, y_train = X[:split_index], y[:split_index]
    X_test, y_test = X[split_index:], y[split_index:]

    # 4. Save data to npy
    os.makedirs(output_dir, exist_ok=True)
    np.save(os.path.join(output_dir, f"{prefix}_X_train.npy"), X_train)
    np.save(os.path.join(output_dir, f"{prefix}_y_train.npy"), y_train)
    np.save(os.path.join(output_dir, f"{prefix}_X_test.npy"), X_test)
    np.save(os.path.join(output_dir, f"{prefix}_y_test.npy"), y_test)

    # 5. Save scaler
    joblib.dump(scaler, os.path.join(output_dir, f"{prefix}_scaler.save"))

    print(f"Dataset dan scaler untuk {prefix.upper()} disimpan di folder: {output_dir}")

if __name__ == "__main__":
    datasets = {
```

Gambar 4.6 Fungsi untuk membuat dataset

Gambar 4.5 menampilkan fungsi yang digunakan dalam penelitian ini untuk membentuk dataset time series yang sesuai dengan kebutuhan model *Long Short-Term Memory (LSTM)* dan *Bidirectional LSTM (BiLSTM)*. Fungsi ini merupakan tahapan lanjutan dari *preprocessing* yang sebelumnya telah menghasilkan data harga penutupan (*Close*) yang bersih dan siap untuk ditransformasikan.

Pertama dalam fungsi ini adalah melakukan normalisasi data harga penutupan menggunakan metode Min-Max Scaling. Normalisasi ini mengubah rentang nilai harga saham menjadi antara 0 dan 1. Tujuannya adalah untuk menyamakan skala nilai agar proses pelatihan model tidak bias terhadap harga yang besar, serta mempercepat proses konvergensi model selama proses training. Tanpa normalisasi, perbedaan skala antar saham atau antara hari-hari dalam data dapat menyebabkan model kesulitan dalam mengenali pola yang konsisten.

Setelah proses normalisasi, data kemudian disusun ulang ke dalam format *supervised learning time series* menggunakan teknik *sliding window*. *Sliding window* adalah pendekatan di mana sejumlah hari sebelumnya digunakan sebagai *input* (fitur), dan hari berikutnya digunakan sebagai target (*label*). Dalam penelitian ini, digunakan jendela waktu (*window*) sepanjang 60 hari, yang berarti setiap 60 harga penutupan

terakhir digunakan untuk memprediksi harga penutupan hari ke-61. Proses ini dilakukan secara berurutan sepanjang data historis, membentuk pasangan data input dan target yang mencerminkan urutan kronologis alami dari pasar saham.

Langkah berikutnya dalam fungsi tersebut adalah pembagian dataset ke dalam dua bagian yaitu data pelatihan (*training set*) dan data pengujian (*testing set*). Pembagian dilakukan dengan proporsi 80% untuk pelatihan dan 20% untuk pengujian. Yang penting dalam proses ini adalah bahwa pembagian dilakukan secara berurutan berdasarkan waktu, tanpa pengacakan. Ini sangat penting dalam konteks data time series, karena menjaga kesinambungan temporal merupakan hal mendasar untuk mencegah kebocoran data dan memastikan evaluasi model dilakukan pada data yang benar-benar tidak terlihat sebelumnya.

Seluruh hasil dari pembentukan dataset ini kemudian disimpan dalam format *array biner* (.npy), yang merupakan format efisien dan cepat untuk dibaca oleh *Python* selama pelatihan model. Dataset yang disimpan meliputi empat komponen utama: input dan target untuk pelatihan, serta input dan target untuk pengujian. Di samping itu, fungsi ini juga menyimpan model normalisasi (*scaler*) ke dalam berkas tersendiri. Penyimpanan ini sangat penting karena model normalisasi yang sama harus digunakan kembali saat melakukan transformasi balik (*inverse transform*) terhadap hasil prediksi agar dapat dikembalikan ke nilai harga sebenarnya.

Dengan fungsi ini, seluruh proses pembentukan dataset dilakukan secara otomatis, sistematis, dan replikasi. Hal ini memungkinkan proses yang sama dijalankan untuk berbagai saham dengan hanya mengganti parameter nama saham, tanpa perlu melakukan modifikasi manual terhadap isi fungsi.

	Data Aktual	Data Normalisasi
0	4469.357910	0.122595
1	4503.739258	0.129450
2	4452.167969	0.119167
3	4473.655762	0.123452
4	4508.035156	0.130307
5	4503.739258	0.129450
6	4516.830371	0.132021
7	4516.830371	0.132021
8	4512.333884	0.131164
9	4469.357910	0.122595

Gambar 4.7 Perbandingan data BBKA sebelum dan sesudah normalisasi

4.3. Implementasi Model LSTM dan BiLSTM

4.3.1. Arsitektur Model

Model LSTM dan BiLSTM dibangun menggunakan pustaka TensorFlow dan Keras dengan arsitektur awal yang sederhana sebagai *baseline* sebelum dilakukan proses optimasi. Masing-masing model terdiri dari satu lapisan utama (LSTM atau BiLSTM), diikuti oleh satu lapisan *dropout* untuk mencegah *overfitting*, serta satu lapisan *dense* sebagai *output* untuk regresi nilai harga penutupan.

```

model_lstm.py
def build_lstm_model(input_shape, units=64, dropout_rate=0.2):
    model = Sequential()
    model.add(LSTM(units=units, return_sequences=False, input_shape=input_shape))
    model.add(Dropout(dropout_rate))
    model.add(Dense(1))

    model.compile(optimizer='adam', loss='mean_squared_error', metrics=['mae'])
    return model

```

Gambar 4.8 Arsitektur model LSTM

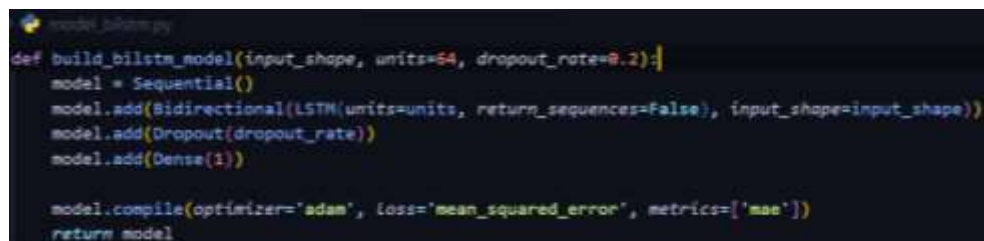
Arsitektur model LSTM dalam Gambar 4.7 dibangun secara bertingkat menggunakan pendekatan sekuensial, di mana setiap lapisan ditambahkan satu per satu ke dalam model. Lapisan pertama adalah lapisan LSTM itu sendiri, yang menerima parameter *units*, yaitu jumlah unit memori sel yang akan digunakan. Jumlah ini menentukan kapasitas model dalam menyimpan dan memproses informasi jangka panjang dari data time series.

Input *shape* yang diberikan ke model adalah (60, 1), yang merepresentasikan bahwa setiap input terdiri atas 60 nilai harga penutupan berturut-turut. Dengan `return_sequences=False`, model hanya mengembalikan output pada waktu terakhir, karena hanya diperlukan satu prediksi untuk hari ke-61.

Setelah lapisan LSTM, terdapat lapisan *Dropout* yang digunakan sebagai bentuk regularisasi. *Dropout* berfungsi untuk mencegah model mengalami *overfitting* dengan cara mengabaikan sejumlah *neuron* secara acak selama proses pelatihan. Nilai *dropout_rate* diatur pada 0.2, yang berarti 20% neuron akan dinonaktifkan secara acak selama satu iterasi *training*.

Lapisan terakhir adalah lapisan *Dense*, yang terdiri dari satu unit dengan aktivasi linear. Tujuannya adalah untuk menghasilkan satu nilai kontinu sebagai output prediksi, yaitu harga penutupan saham pada hari berikutnya.

Model kemudian dikompilasi menggunakan *optimizer* Adam, sebuah algoritma optimasi adaptif yang umum digunakan karena konvergensinya yang cepat dan stabil. Fungsi *loss* yang digunakan adalah *Mean Squared Error (MSE)*, yang sangat sesuai untuk masalah regresi. Selain itu, model juga dikonfigurasi untuk melacak metrik *Mean Absolute Error (MAE)* sebagai indikator performa tambahan.



```

model_bilstm.py
def build_bilstm_model(input_shape, units=64, dropout_rate=0.2):
    model = Sequential()
    model.add(Bidirectional(LSTM(units=units, return_sequences=False), input_shape=input_shape))
    model.add(Dropout(dropout_rate))
    model.add(Dense(1))

    model.compile(optimizer='adam', loss='mean_squared_error', metrics=['mae'])
    return model
  
```

Gambar 4.9 Arsitektur model BILSTM

Gambar 4.8 menampilkan fungsi `build_bilstm_model()` yang digunakan untuk membangun model Bidirectional Long Short-Term Memory (BiLSTM). Model ini merupakan pengembangan dari arsitektur LSTM standar dengan kemampuan tambahan untuk mempelajari urutan data dari dua arah waktu sekaligus yaitu maju (*forward*) dan

mundur (*backward*). Pendekatan ini bermanfaat dalam menangkap pola yang mungkin tidak sepenuhnya dapat dikenali jika hanya dilihat dari satu arah.

Struktur model BiLSTM dalam gambar juga dibangun secara sekuensial. Lapisan pertamanya adalah lapisan *Bidirectional*, yang membungkus lapisan *LSTM*. Dalam konteks ini, setiap *input sequence* akan diproses dua kali, sekali dari urutan waktu awal ke akhir, dan sekali lagi dari akhir ke awal. Kedua hasil ini kemudian digabungkan (*concatenated*) dan diteruskan ke lapisan berikutnya.

Seperti pada model LSTM, arsitektur ini juga menyertakan *Dropout Layer* sebagai langkah regularisasi untuk mencegah *overfitting*. Dengan tingkat *dropout* yang sama (20%), model dijaga agar tidak terlalu menghafal data pelatihan.


Lapisan terakhir dari model ini adalah *Dense Layer* dengan satu unit *output*. Fungsi utama lapisan ini adalah memberikan hasil akhir berupa prediksi nilai harga penutupan untuk satu langkah ke depan.

Model BiLSTM ini juga menggunakan Adam sebagai *optimizer* dan *Mean Squared Error* sebagai fungsi *loss* utama, dengan metrik evaluasi berupa *Mean Absolute Error*. Pemilihan parameter ini dilakukan secara konsisten agar perbandingan performa antara LSTM dan BiLSTM tetap adil dan terkontrol.

4.3.2. Hasil Konfigurasi Awal Model

Setelah arsitektur model LSTM dan BiLSTM dibangun dan dikompilasi menggunakan konfigurasi awal (*baseline*), masing-masing model kemudian dilatih menggunakan dataset saham BBKA dan TLKM. Tujuan dari pelatihan awal ini adalah untuk mengevaluasi kemampuan dasar model dalam mempelajari pola historis harga saham sebelum dilakukan optimasi *hyperparameter* lebih lanjut.


Selama pelatihan berlangsung, model mencatat nilai *loss* (*Mean Squared Error*) pada data pelatihan dan validasi di setiap *epoch*. Grafik *loss* ini memberikan gambaran visual tentang bagaimana model belajar dari waktu ke waktu dan menjadi indikator penting untuk mendeteksi fenomena *underfitting*, *overfitting*, atau konvergensi stabil.



Gambar 4.10 Grafik Loss Training dan Validasi Saham BBKA

Pada Gambar 4.9 memperlihatkan grafik hasil pelatihan model LSTM yang digunakan untuk memprediksi harga saham BBKA. Pada grafik tersebut, terlihat bahwa nilai *training loss* secara umum mengalami penurunan bertahap, yang mengindikasikan bahwa model berhasil mempelajari pola historis dari data latih.

Namun demikian, nilai *validation loss* menunjukkan fluktuasi yang cukup tinggi, terutama pada epoch ke-33 dan beberapa titik setelahnya. Lonjakan-lonjakan tajam ini menunjukkan adanya ketidakstabilan model saat diuji pada data yang tidak dilihat sebelumnya, yang bisa disebabkan oleh ketidaksesuaian parameter, kapasitas model yang berlebih, atau kebutuhan regularisasi yang lebih baik.



Gambar 4.11 Grafik Loss Training dan Validasi Saham TLKM

Selanjutnya pada Gambar 4.10 menunjukkan grafik *loss* dari model BiLSTM untuk prediksi harga saham TLKM. Secara umum, nilai *loss* pada data training dan validasi berada dalam rentang yang cukup dekat, menunjukkan kemampuan generalisasi model

yang baik. Akan tetapi, terdapat satu lonjakan besar pada nilai *loss* validasi sekitar *epoch* ke-16 yang kemudian kembali stabil. Setelah titik tersebut, *loss* validasi bahkan cenderung lebih rendah daripada *loss* training pada sebagian besar *epoch* berikutnya. Hal ini menunjukkan bahwa meskipun model BiLSTM dapat belajar dengan baik, masih terdapat peluang peningkatan performa melalui *tuning* konfigurasi.

Selanjutnya dilakukan evaluasi performa model dengan menggunakan tiga metrik utama, yaitu *Mean Squared Error (MSE)*, *Root Mean Squared Error (RMSE)*, dan *Mean Absolute Percentage Error (MAPE)*. Ketiga metrik ini digunakan untuk mengukur seberapa besar kesalahan prediksi model terhadap data aktual dari sudut pandang kuadrat selisih, akar kuadrat selisih, dan kesalahan persentase *absolut*.

Evaluasi dilakukan terhadap hasil prediksi pada data uji (*test set*) untuk masing-masing model dan saham, yaitu LSTM dan BiLSTM terhadap saham BBKA dan TLKM. Nilai-nilai dari ketiga metrik tersebut dirangkum dalam Tabel 4.1 berikut:

Tabel 4.1 Hasil Evaluasi Model pada Data Uji

No.	Model	Saham	MSE	RMSE
1	LSTM	BBKA	0.0012	0.0343
2	BiLSTM	BBKA	0.0010	0.0313
3	LSTM	TLKM	0.0006	0.0235
4	BiLSTM	TLKM	0.0005	0.0233

Dari hasil evaluasi di atas, terlihat bahwa BiLSTM memberikan hasil prediksi yang lebih baik dibandingkan *LSTM* untuk saham BBKA, baik dari segi MSE, RMSE, maupun MAPE. Hal ini menunjukkan bahwa arsitektur *bidirectional* mampu menangkap pola harga saham BBKA dengan lebih baik. Namun, pada saham TLKM, performa kedua model relatif seimbang, di mana BiLSTM memiliki MSE dan RMSE yang sedikit lebih kecil, sementara LSTM memiliki MAPE yang sedikit lebih rendah.

Gambar 4.11 dan Gambar 4.12 menampilkan hasil prediksi model LSTM dan BiLSTM terhadap saham BBKA. Secara umum, kedua model berhasil mengikuti pola tren harga aktual dengan baik pada data training. Model BiLSTM tampak menghasilkan

prediksi yang lebih halus dan mendekati harga aktual, khususnya saat terjadi fluktuasi besar pada akhir tahun.



Gambar 4.12 Grafik Training Data saham BBCA menggunakan LSTM



Gambar 4.13 Grafik *Training* Data saham BBCA menggunakan BiLSTM

Sementara itu, Gambar 4.13 dan Gambar 4.14 menampilkan grafik hasil prediksi untuk saham TLKM. Kedua model menunjukkan kemampuan yang sangat baik dalam menangkap pola tren utama. LSTM dan BiLSTM sama-sama mampu mengikuti arah harga secara detail, termasuk saat terjadi penurunan tajam pada Oktober November 2023. Namun, BiLSTM sedikit lebih halus dalam transisi antara tren naik dan turun.



Gambar 4.14 Grafik *Training* Data saham TLKM menggunakan LSTM



Gambar 4.15 Grafik *Training* Data saham TLKM menggunakan BiLSTM

Secara keseluruhan, hasil evaluasi numerik dan visual menunjukkan bahwa kedua model memiliki performa yang layak untuk digunakan dalam prediksi harga saham, dengan BiLSTM sedikit lebih unggul dalam menangkap dinamika harga terutama pada saham BBCA. Temuan ini menjadi dasar untuk melanjutkan ke tahap *optimasi hyperparameter* yang bertujuan untuk meningkatkan akurasi model lebih lanjut

4.4. Hasil Optimasi *Hyperparameter* (*Grid Search*)

4.4.1. Proses *Grid Search*

Setelah memperoleh hasil pelatihan awal menggunakan konfigurasi baseline, tahap selanjutnya dalam penelitian ini adalah melakukan optimasi *hyperparameter* untuk meningkatkan performa model. Optimasi dilakukan menggunakan pendekatan *Grid Search*, yaitu metode pencarian sistematis untuk menemukan kombinasi parameter

terbaik dengan melakukan evaluasi pada setiap kemungkinan kombinasi dalam ruang parameter yang telah ditentukan.

```
# Gridsearch parameter grid
param_grid = {
    'units': [5, 10, 15, 20, 25],
    'batch_size': [4, 16, 32, 64, 128],
    'epochs': [50, 100, 150, 200, 250],
    'dropout': [0.1, 0.2, 0.3]
}

# Output:
ticker = 'time'
data_dir = 'preprocessed'
results_dir = f'results/gridsearch_lstm_{ticker}'
os.makedirs(results_dir, exist_ok=True)

# Load data dan scaler
X_train = np.load(f'{data_dir}/{ticker}_X_train.npy')
y_train = np.load(f'{data_dir}/{ticker}_y_train.npy')
X_test = np.load(f'{data_dir}/{ticker}_X_test.npy')
y_test = np.load(f'{data_dir}/{ticker}_y_test.npy')
scaler = joblib.load(f'{data_dir}/{ticker}_scaler.save')

# Load tanggal
data = pd.read_csv(f'data/{ticker}_k_clean.csv', parse_dates=True, index_col=0).index[-len(y_test):]

# Logging hasil
log_file = os.path.join(results_dir, f'gridsearch_log_lstm_{ticker}.csv')
with open(log_file, 'w') as f:
    f.write("units,batch_size,epochs,dropout,mse,rmse,mape\n")

best_rmse = float('inf')
best_config = None
```

Gambar 4.16 Implementasi Grid Search untuk Optimasi Hyperparameter

Ruang pencarian yang digunakan telah dijelaskan pada Subbab 3.3.3, meliputi kombinasi dari jumlah unit *neuron* (*units*), *batch size*, *epoch*, dan *dropout*. Setiap parameter didefinisikan dalam bentuk list nilai yang akan diuji seperti pada Gambar 4.15, yang jika dikombinasikan secara menyeluruh akan menghasilkan total jumlah kombinasi yang ekstensif. Dalam penelitian ini terdapat total $5 \times 5 \times 5 \times 3 = 375$ kombinasi yang diuji.

Setelah ruang pencarian ditentukan, program mengatur direktori hasil dan memuat kembali data pelatihan serta pengujian dalam format *.npy* untuk efisiensi proses. Di samping itu, scaler hasil normalisasi yang digunakan pada tahap preprocessing juga dimuat kembali untuk melakukan transformasi balik (*inverse transform*) terhadap hasil prediksi model.

Fungsi ini juga memuat data tanggal yang disesuaikan dengan panjang data pengujian. Hal ini penting agar setiap hasil prediksi dapat ditautkan secara akurat ke tanggal aslinya, baik untuk keperluan *plotting* maupun evaluasi performa.

Langkah terakhir adalah menyiapkan file log, yaitu file .csv tempat seluruh hasil eksperimen disimpan. File *log* ini akan mencatat semua kombinasi *hyperparameter* yang diuji bersama dengan metrik evaluasinya: *MSE*, *RMSE*, dan *MAPE*. Dengan adanya pencatatan ini, proses seleksi terhadap kombinasi terbaik dapat dilakukan secara sistematis dan terdokumentasi.

Model dengan nilai *RMSE* terkecil dianggap sebagai model terbaik untuk kombinasi saham dan arsitektur tertentu. Selain itu, digunakan juga *Early Stopping* dengan *patience*=10 untuk menghentikan pelatihan lebih awal jika tidak terjadi peningkatan performa pada data validasi, guna menghemat waktu komputasi.

Proses *Grid Search* yang digunakan dalam penelitian ini memerlukan waktu komputasi yang cukup signifikan, mengingat banyaknya kombinasi parameter yang harus diuji secara menyeluruh. Dengan total sebanyak 375 kombinasi *hyperparameter* untuk setiap model dan setiap saham, eksperimen menjadi sangat intensif secara waktu dan sumber daya. Masing-masing kombinasi mewakili konfigurasi unik dari jumlah *unit*, *batch size*, *epoch*, dan tingkat *dropout* yang harus dilatih secara penuh untuk mengevaluasi performanya terhadap data uji.

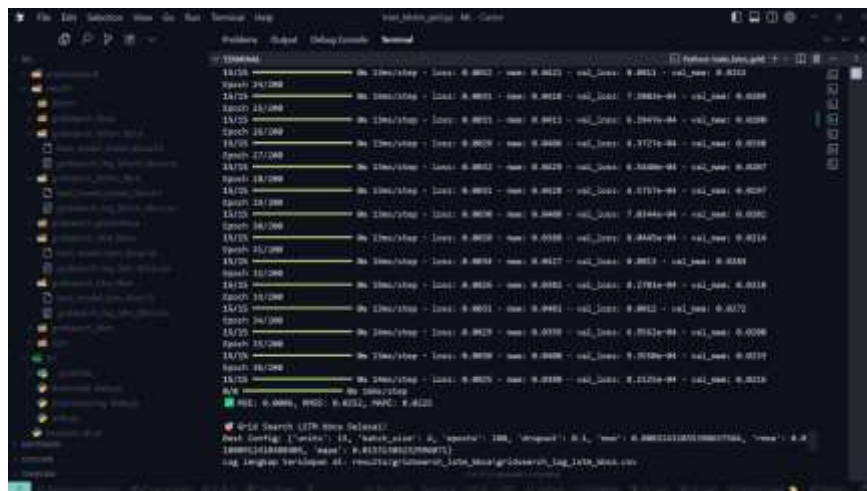
Rata-rata waktu yang dibutuhkan untuk melatih satu model dengan konfigurasi tertentu berkisar antara 1 hingga 2 menit, tergantung pada jumlah epoch yang digunakan dan ukuran data. Meskipun waktu pelatihan per model relatif singkat, akumulasi dari ratusan kombinasi yang diuji menyebabkan total durasi proses *Grid Search* menjadi panjang.

Secara keseluruhan, waktu komputasi untuk menyelesaikan seluruh *Grid Search* pada empat eksperimen utama dalam penelitian ini yaitu LSTM untuk BBKA, LSTM untuk TLKM, BiLSTM untuk BBKA, dan BiLSTM untuk TLKM yang diperkirakan mencapai 15 hingga 18 jam. Estimasi ini mencakup seluruh proses dari pelatihan awal, validasi model, pencatatan hasil evaluasi, hingga penyimpanan model terbaik.

Seluruh eksperimen dilakukan secara lokal menggunakan komputer pribadi peneliti dengan prosesor Intel Core i7 dan RAM sebesar 16 GB serta GPU RTX 3060, yang menjalankan lingkungan pengembangan berbasis Python dan *framework deep learning TensorFlow*. Meskipun tidak menggunakan GPU eksternal, sistem ini mampu menyelesaikan seluruh proses dengan efisien berkat optimasi kode yang modular, penggunaan format array .npy, dan mekanisme *Early Stopping* untuk menghentikan pelatihan lebih awal apabila model tidak menunjukkan peningkatan performa yang berarti.

4.4.2. Hasil Optimasi untuk Model LSTM

Setelah seluruh proses *Grid Search* selesai dijalankan untuk model LSTM, diperoleh kombinasi *hyperparameter* terbaik untuk masing-masing saham berdasarkan nilai *Root Mean Squared Error (RMSE)* terendah pada data uji. Evaluasi dilakukan terhadap seluruh *log* hasil percobaan yang telah disimpan secara sistematis dalam file .csv, sehingga pemilihan kombinasi terbaik dapat dilakukan dengan objektif dan terverifikasi.



Gambar 4.17 Contoh *Output* Pelatihan dari *Grid Search*

Hasil optimasi menunjukkan bahwa kombinasi terbaik untuk model LSTM dalam memprediksi harga saham BBKA adalah sebagai berikut:

Tabel 4.2 Optimasi Terbaik Model LSTM saham BBKA

Parameter	Nilai Terbaik
<i>Units</i>	15
<i>Batch Size</i>	4
<i>Epochs</i>	100
<i>Dropout</i>	0.1
<i>RMSE</i>	0.0180

Performa ini mengalami peningkatan dari *baseline* RMSE sebelumnya (0.0343), menandakan bahwa tuning terhadap kapasitas dan regularisasi model memberikan dampak positif terhadap akurasi prediksi.

Tabel 4.3 Optimasi Terbaik Model LSTM saham TLKM

Parameter	Nilai Terbaik
<i>Units</i>	15
<i>Batch Size</i>	4
<i>Epochs</i>	200
<i>Dropout</i>	0.1
<i>RMSE</i>	0.0199

Performa ini juga mengalami peningkatan dibanding *baseline* RMSE (0.0235), meskipun margin peningkatannya tidak terlalu besar, mengindikasikan bahwa model *baseline* LSTM pada TLKM sudah cukup optimal sejak awal.

4.4.3. Hasil Optimasi untuk Model BiLSTM

Model BiLSTM menunjukkan hasil yang lebih unggul dibanding LSTM dalam eksperimen ini. Kombinasi hyperparameter terbaik untuk saham BBKA adalah:

Tabel 4.4 Optimasi Terbaik Model BiLSTM saham BBKA

Parameter	Nilai Terbaik
<i>Units</i>	20
<i>Batch Size</i>	4
<i>Epochs</i>	100
<i>Dropout</i>	0.1
<i>RMSE</i>	0.0178

Penurunan RMSE dari *baseline* (0.0313) ke hasil optimasi ini cukup signifikan, menunjukkan efektivitas penggunaan arsitektur bidirectional dan tuning parameter secara bersamaan.

Tabel 4.5 Optimasi Terbaik Model BiLSTM saham TLKM

Parameter	Nilai Terbaik
<i>Units</i>	50
<i>Batch Size</i>	4

<i>Epochs</i>	200
<i>Dropout</i>	0.1
<i>RMSE</i>	0.0172

Performa ini memperbaiki hasil *baseline* BiLSTM sebelumnya (0.0233) dengan penurunan RMSE yang stabil dan konsisten.

Tabel 4.6 Kombinasi terbaik yang digunakan sebagai model final

Model	Saham	Units	Batch Size	Epochs	Dropout
LSTM	BBCA	15	4	100	0.1
BiLSTM	BBCA	20	4	100	0.1
LSTM	TLKM	15	4	200	0.1
BiLSTM	TLKM	50	4	200	0.1

Dari analisis ini dapat disimpulkan bahwa arsitektur *BiLSTM* lebih andal untuk data *time series* yang bersifat volatil dan siklikal, karena kemampuannya dalam memproses informasi dua arah yaitu *forward* dan *backward*, yang secara teoritis mendukung ketepatan dalam memetakan perubahan arah harga.

4.5. Evaluasi Kinerja Model

4.5.1. Hasil Evaluasi Model

Setelah model dilatih menggunakan konfigurasi terbaik dari hasil *Grid Search*, tahap selanjutnya adalah melakukan evaluasi akhir terhadap performa prediksi pada data uji (*test set*). Tahapan ini bertujuan untuk mengukur kemampuan generalisasi model terhadap data baru yang tidak pernah dilihat selama pelatihan. Evaluasi dilakukan menggunakan tiga metrik utama yaitu *Mean Squared Error (MSE)*, *Root Mean Squared Error (RMSE)*, dan *Mean Absolute Percentage Error (MAPE)*. Nilai-nilai ini dihitung terhadap data uji dari masing-masing model, seperti ditampilkan dalam tabel berikut:

Tabel 4.7 Hasil Evaluasi Model Terhadap Data Uji

Model	Saham	MSE	RMSE	MAPE (%)
LSTM	BBCA	0.0012	0.0180	1.53
BiLSTM	BBCA	0.0010	0.0178	1.45
LSTM	TLKM	0.0016	0.0199	2.24
BiLSTM	TLKM	0.0005	0.0172	1.94

Dari hasil evaluasi di atas, terlihat bahwa model *BiLSTM* memiliki nilai error yang sedikit lebih rendah dibandingkan *LSTM* pada kedua jenis saham. Meskipun selisihnya tidak terlalu besar, hal ini tetap menunjukkan konsistensi arsitektur *BiLSTM* dalam mengurangi galat prediksi, khususnya *RMSE*.

4.5.2. Visualisasi Hasil Prediksi

Untuk melihat kemampuan model dalam mengikuti pola pergerakan harga, grafik perbandingan antara harga prediksi dan harga aktual disajikan. Gambar 4.18 hingga 4.21 menyajikan grafik perbandingan antara harga saham aktual dan hasil prediksi dari model *LSTM* dan *BiLSTM* pada dua emiten, yaitu *BBCA* dan *TLKM*. Garis biru mewakili harga penutupan aktual, sementara garis oranye menunjukkan hasil prediksi model.



Gambar 4.18 Prediksi vs Aktual BBKA (LSTM)

Secara umum, model *LSTM* mampu mengikuti tren utama dari harga saham *BBKA* dengan cukup baik. Pola naik dan turun dapat direplikasi oleh model, meskipun pada beberapa titik terjadi deviasi antara prediksi dan harga aktual, terutama saat terjadi lonjakan harga mendadak. Hal ini menunjukkan bahwa *LSTM* memiliki kecenderungan untuk sedikit tertinggal dalam menangkap momentum harga pada perubahan tren yang tajam.



Gambar 4.19 Prediksi vs Aktual TLKM (LSTM)

Visualisasi untuk saham TLKM juga menunjukkan performa yang cukup baik. Model LSTM berhasil merekonstruksi pola musiman dan fluktuasi mingguan dengan akurat, terutama pada fase penurunan tajam sekitar November 2023. Namun, serupa dengan BBKA, model ini sesekali menghasilkan prediksi yang sedikit lebih lambat dalam menangkap titik pembalikan tren.



Gambar 4.20 Prediksi vs Aktual BBKA (BiLSTM)

Model BiLSTM menunjukkan performa visual yang lebih halus dan mendekati garis aktual, terutama saat terjadi perubahan tren yang signifikan. Karakteristik bidirectional memungkinkan model ini memproses informasi dari dua arah waktu, sehingga menghasilkan prediksi yang lebih seimbang antara *respons* terhadap data historis dan antisipasi terhadap pola yang akan datang. Hal ini terlihat jelas dalam fase

fluktuasi antara Juni hingga November 2023, di mana garis prediksi BiLSTM tetap sejajar dengan tren aktual secara konsisten.



Gambar 4.21 Prediksi vs Aktual TLKM (BiLSTM)

Grafik prediksi saham TLKM oleh BiLSTM menunjukkan akurasi visual yang tinggi dan kestabilan dalam mengikuti harga aktual. Model ini mampu mereplikasi pergerakan harga secara detail, terutama saat terjadi konsolidasi pasar atau *sideways* trend. Dibandingkan LSTM, hasil prediksi BiLSTM terlihat lebih halus, tidak terlalu fluktuatif, dan tetap berada dekat dengan garis aktual bahkan pada periode volatilitas tinggi.

Secara keseluruhan, visualisasi menunjukkan bahwa model BiLSTM cenderung memberikan prediksi yang lebih mendekati harga aktual dan lebih halus dalam pola pergerakannya. Hal ini secara visual mengonfirmasi keunggulan arsitektur bidirectional dalam menangkap pola time series yang kompleks, terutama saat terjadi pembalikan tren dan fluktuasi jangka pendek. Meski LSTM sudah cukup baik dalam mengikuti arah tren, BiLSTM menawarkan stabilitas dan ketepatan bentuk yang lebih baik, menjadikannya pilihan yang lebih unggul dalam hal interpretasi visual terhadap pola harga saham.

4.6. Perbandingan Kinerja Model LSTM dan BiLSTM

4.6.1. Perbandingan Metrik Evaluasi

Evaluasi kuantitatif dilakukan terhadap performa model LSTM dan BiLSTM dalam memprediksi harga saham BBKA dan TLKM pada data uji. Tabel 4.7 merangkum hasil evaluasi berdasarkan tiga metrik utama, yaitu *Mean Squared Error (MSE)*, *Root Mean Squared Error (RMSE)*, dan *Mean Absolute Percentage Error (MAPE)*.

Dari hasil evaluasi di atas, terlihat bahwa model BiLSTM memiliki nilai error yang sedikit lebih rendah dibandingkan LSTM pada kedua jenis saham. Selisih nilai MSE dan RMSE antara kedua model memang tidak terlalu besar, tetapi menunjukkan bahwa arsitektur BiLSTM memiliki keunggulan dalam menangkap pola dinamis dari data harga saham.

Secara khusus, pada saham BBKA, BiLSTM mencatat RMSE sebesar 0.0178 dan MAPE sebesar 1.45%, sedikit lebih baik dibanding LSTM dengan RMSE 0.0180 dan MAPE 1.53%. Sementara pada saham TLKM, BiLSTM menunjukkan keunggulan yang lebih signifikan dengan MSE sebesar 0.0005 dan RMSE 0.0172, dibandingkan LSTM yang mencatat MSE 0.0016 dan RMSE 0.0199.

Secara keseluruhan, model BiLSTM dapat diidentifikasi sebagai model dengan performa terbaik berdasarkan ketiga metrik evaluasi, baik dalam hal akurasi prediksi *absolut* maupun akurasi relatif terhadap harga aktual.

4.6.2. Perbandingan Efisiensi Komputasi

Selain akurasi prediksi, efisiensi komputasi merupakan aspek penting yang perlu dipertimbangkan dalam pemilihan model deep learning, terutama dalam konteks implementasi nyata yang memiliki batasan waktu proses atau sumber daya perangkat keras. Dalam penelitian ini, efisiensi komputasi model LSTM dan BiLSTM dibandingkan berdasarkan pengalaman pelatihan yang dijalankan dalam lingkungan eksperimen yang sama, yaitu perangkat lokal dengan prosesor Intel Core i7, RAM 16 GB, dan GPU NVIDIA RTX 3060.

Secara umum, model LSTM memiliki keunggulan dalam hal efisiensi waktu pelatihan dan penggunaan memori. Hal ini disebabkan oleh arsitekturnya yang lebih

sederhana, di mana data hanya diproses dalam satu arah waktu (*forward*). Proses pelatihan model LSTM berlangsung relatif lebih cepat untuk setiap kombinasi parameter dalam *Grid Search*, dan beban memori GPU juga lebih rendah, sehingga memungkinkan eksperimen dilakukan lebih cepat secara keseluruhan.

Sebaliknya, model BiLSTM memiliki kompleksitas komputasi yang lebih tinggi. Dengan dua arah propagasi (*forward* dan *backward*), model ini membutuhkan lebih banyak operasi komputasi dan alokasi memori. Hal ini menyebabkan waktu pelatihan menjadi lebih lama, terutama pada kombinasi *hyperparameter* dengan jumlah *unit* dan *epoch* yang besar. Meskipun demikian, kompleksitas ini dapat dibenarkan oleh akurasi prediksi yang lebih baik pada sebagian besar kasus, sebagaimana ditunjukkan dalam hasil evaluasi sebelumnya.

4.6.1. Analisis Kelebihan dan Kekurangan

Untuk memberikan pemahaman yang lebih terstruktur mengenai keunggulan dan keterbatasan masing-masing model, dilakukan analisis komparatif terhadap arsitektur LSTM dan BiLSTM berdasarkan hasil eksperimen yang telah dilaksanakan. Sebagai penelitian kuantitatif komparatif dengan pendekatan eksperimen komputasional, penilaian dilakukan tidak hanya dari segi akurasi prediksi numerik, tetapi juga mempertimbangkan efisiensi pelatihan, kestabilan model terhadap *noise*, serta kecocokan model terhadap karakteristik data *time series* harga saham.

Analisis ini dirancang untuk menjawab pertanyaan mendasar seperti “model mana yang lebih optimal dalam konteks prediksi harga saham berdasarkan data historis harian?” Dengan menyusun perbandingan dalam format tabel, evaluasi dapat dilakukan secara objektif terhadap kinerja, efisiensi, dan ketepatan prediksi masing-masing model dalam skenario yang serupa.

Tabel 4.8 Perbandingan Kelebihan dan Kekurangan Model LSTM dan BiLSTM

Aspek Evaluasi	LSTM	BiLSTM
----------------	------	--------

Arsitektur & Arah Input	Satu arah (<i>forward-only</i>)	Dua arah (<i>bidirectional</i>)
Waktu Pelatihan	Lebih cepat dan efisien	Lebih lambat karena kompleksitas dua arah
Kebutuhan Komputasi	Lebih rendah (ringan untuk eksperimen skala besar)	Lebih tinggi (membutuhkan GPU/komputasi paralel)
Kemampuan Menangkap Tren	Baik untuk tren jangka menengah dan stabil	Unggul dalam mengenali pola kompleks dan pembalikan tren
Kinerja pada Data Stabil	Lebih konsisten, tidak mudah overfit	Kadang overfit jika data tidak terlalu fluktuatif
Respons Terhadap Noise	Lebih stabil dan konservatif terhadap fluktuasi	Lebih sensitif, bisa mendeteksi fluktuasi kecil
Hasil Visualisasi Prediksi	Garis prediksi cenderung mengikuti tren umum	Garis prediksi lebih halus dan lebih dekat dengan data aktual
MAPE Saham TLKM	2.24% (<i>lebih baik</i>)	1.94% (<i>lebih tinggi</i>)
RMSE Saham BBKA	0.0180	0.0178 (<i>lebih baik</i>)
Kondisi Optimal Penggunaan	Sistem terbatas, aplikasi real-time, atau analisis cepat	Prediksi kompleks, data volatil, atau analisis jangka pendek

4.7. Pembahasan Hasil Penelitian

4.7.1. Interpretasi Hasil Prediksi

Berdasarkan visualisasi dan evaluasi performa yang telah dilakukan, baik model LSTM maupun BiLSTM menunjukkan kemampuan yang baik dalam menangkap pola temporal dari data harga saham harian. Model LSTM mampu mengikuti arah tren jangka menengah dengan stabil, namun memiliki keterbatasan dalam merespons perubahan tren yang tiba-tiba, seperti lonjakan atau penurunan tajam harga. Hal ini tercermin dari beberapa deviasi antara garis prediksi dan aktual pada fase pembalikan tren.

Sebaliknya, model BiLSTM menunjukkan performa yang lebih responsif terhadap volatilitas pasar, terutama dalam menangkap titik-titik balik harga secara lebih presisi.

Karakteristik arsitektur dua arah pada BiLSTM memungkinkan model untuk memperoleh konteks dari masa lalu dan masa depan dalam satu jendela input, sehingga prediksi yang dihasilkan lebih halus dan dekat dengan data aktual, bahkan dalam kondisi pasar yang fluktuatif.

Faktor-faktor yang memengaruhi akurasi prediksi antara lain:

1. Ukuran *window time series* (60 hari), yang cukup untuk menangkap siklus harga mingguan hingga bulanan.
2. Kombinasi *hyperparameter* seperti jumlah *neuron*, *epoch*, dan *dropout*, yang berhasil dioptimasi melalui *Grid Search*.
3. Stabilitas data saham, di mana saham BBKA cenderung memberikan hasil lebih baik karena pola historis yang lebih konsisten dibandingkan TLKM.

Dengan demikian, model BiLSTM lebih unggul dalam menangkap dinamika jangka pendek dan pola kompleks, sedangkan model LSTM memberikan hasil yang stabil dan lebih efisien pada data yang relatif lebih tenang.

4.7.2. Validasi Hasil dengan Teori

Hasil penelitian ini secara umum sejalan dengan teori dan karakteristik arsitektur LSTM dan BiLSTM yang banyak dibahas dalam literatur. Model LSTM dikenal efisien dalam memproses data berurutan satu arah dan cukup akurat dalam mengenali pola jangka menengah yang stabil. Hal ini sesuai dengan hasil penelitian oleh Hanafiah et al. (2023), yang menemukan bahwa LSTM mampu menangani dependensi temporal dalam prediksi harga saham, meskipun tanpa perbandingan langsung dengan BiLSTM .

Di sisi lain, hasil penelitian ini memperkuat temuan dari Puteri (2023), yang menunjukkan bahwa BiLSTM secara konsisten mengungguli LSTM dalam memprediksi harga saham syariah karena kemampuannya memproses data secara dua arah dan mengenali pola kompleks time series dengan lebih efektif . Dalam konteks penelitian ini, BiLSTM menunjukkan akurasi prediksi yang lebih baik khususnya pada saham BBKA

yang memiliki pola harga lebih dinamis, mendukung keunggulan teoritis arsitektur tersebut.

Selain itu, penelitian oleh Puteri et al. (2024) juga menegaskan bahwa penerapan Grid Search secara signifikan meningkatkan akurasi model BiLSTM melalui tuning hyperparameter seperti epoch, batch size, dan dropout . Meskipun penelitian tersebut menggunakan saham syariah sebagai objek, prinsip optimasi hyperparameter yang diterapkan tetap relevan dan sejalan dengan pendekatan yang digunakan dalam penelitian ini.

Simamora et al. (2025) juga menekankan pentingnya eksplorasi hyperparameter terhadap performa BiLSTM, meskipun menggunakan metode Bayesian Optimization. Ini semakin menguatkan bahwa proses tuning parameter, baik dengan Grid Search maupun pendekatan lainnya, merupakan kunci dalam mengoptimalkan performa model deep learning untuk prediksi harga saham .

Dengan demikian, temuan dalam penelitian ini tidak hanya sesuai dengan teori dasar dan arsitektur LSTM maupun BiLSTM, tetapi juga mengonfirmasi hasil-hasil penelitian sebelumnya. Selain itu, penelitian ini turut memberikan kontribusi baru dengan menguji dan membandingkan kedua model pada saham BBCA dan TLKM menggunakan data dari Alpha Vantage, serta menunjukkan bahwa kombinasi Grid Search dan arsitektur BiLSTM memberikan hasil prediksi yang lebih akurat pada kondisi pasar yang fluktuatif.

penelitian ini menunjukkan bahwa penerapan model *BiLSTM* yang dioptimasi dengan *Grid Search* menghasilkan performa prediksi yang lebih baik dibandingkan model *LSTM* standar. Temuan ini tidak muncul secara terpisah, melainkan selaras dengan sejumlah penelitian terdahulu yang juga mengevaluasi efektivitas model *BiLSTM* serta pentingnya proses tuning hyperparameter dalam prediksi data deret waktu, khususnya pada konteks harga saham. Untuk memperkuat validitas hasil penelitian ini, dilakukan penelusuran terhadap beberapa literatur akademik yang telah dibahas pada 2.8 Studi

literatur. Tabel berikut merangkum lima studi literatur utama yang dijadikan rujukan dan membandingkan keterkaitannya dengan temuan penelitian ini

BAB V

PENUTUP

5.1 Kesimpulan

Penelitian ini bertujuan untuk membandingkan tingkat akurasi model Long Short-Term Memory (LSTM) dan Bidirectional LSTM (BiLSTM) dalam memprediksi harga saham harian BBKA dan TLKM. Berdasarkan hasil eksperimen, evaluasi metrik (MSE, RMSE, dan MAPE), serta analisis visualisasi hasil prediksi, diperoleh beberapa temuan utama sebagai berikut:

1. Model BiLSTM menunjukkan tingkat akurasi yang lebih tinggi dibandingkan LSTM dalam memprediksi harga saham harian. Untuk saham BBKA, BiLSTM mencatat nilai RMSE sebesar 0.0178 dan MAPE 1.45%, sedangkan LSTM mencatat RMSE sebesar 0.0180 dan MAPE 1.53%. Pada saham TLKM, BiLSTM mencatat nilai RMSE sebesar 0.0172 dan MAPE 1.94%, lebih baik dibandingkan LSTM yang memperoleh RMSE sebesar 0.0199 dan MAPE 2.24%. Selisih nilai kesalahan ini menunjukkan bahwa BiLSTM lebih mampu menangkap pola harga historis secara akurat dan memberikan prediksi harga saham yang lebih presisi.
2. Proses optimasi *hyperparameter* menggunakan Grid Search memberikan dampak signifikan terhadap peningkatan performa model dibandingkan dengan konfigurasi awal. Penentuan jumlah *neuron*, jumlah *epoch*, ukuran *batch*, dan *dropout rate* terbukti berdampak langsung terhadap penurunan nilai RMSE dan MAPE pada kedua model, sehingga memberikan hasil prediksi yang lebih optimal.
3. Keunggulan arsitektur BiLSTM yang mampu membaca data dalam dua arah (*forward* dan *backward*) membuatnya lebih efektif dalam mengenali pola tren jangka pendek maupun musiman dalam pergerakan harga saham. Hal ini secara langsung berkontribusi terhadap peningkatan akurasi prediksi, terutama pada saham dengan volatilitas tinggi seperti BBKA.

4. Visualisasi hasil prediksi menunjukkan bahwa kurva prediksi yang dihasilkan oleh BiLSTM mendekati harga aktual, khususnya saat terjadi perubahan tren yang tajam. Sebaliknya, model LSTM cenderung menunjukkan deviasi prediksi yang lebih besar, terutama pada kondisi pasar yang tidak stabil, yang mengindikasikan kemampuan adaptasi yang lebih rendah terhadap dinamika harga saham.
5. Secara keseluruhan, penelitian ini membuktikan bahwa arsitektur BiLSTM lebih mampu menangkap pola-pola kompleks dalam data time series harga saham, terutama ketika diterapkan pada data dengan volatilitas tinggi seperti saham BBCA. Dan penelitian ini juga menunjukkan efektivitas penerapan Grid Search dalam meningkatkan performa model deep learning.

5.2 Saran

Adapun saran yang kiranya dapat dilakukan pada penelitian selanjutnya adalah sebagai berikut:

1. Menggunakan lebih banyak data historis dengan cakupan multivariat, seperti indikator teknikal (MACD, RSI) atau sentimen berita pasar untuk meningkatkan konteks input model.
2. Model yang dikembangkan dalam penelitian ini dapat dijadikan acuan awal oleh investor individu maupun institusi dalam melakukan analisis prediktif terhadap harga saham. Implementasi model dalam sistem trading decision support dapat menjadi kontribusi praktis dari penelitian ini.
3. Penelitian ini juga dapat dikembangkan lebih lanjut untuk membandingkan strategi optimasi ini dengan metode optimasi lainnya untuk efisiensi dan efektivitas *tuning hyperparameter*.

4. Diharapkan penelitian ini dapat menjadi dasar pengembangan sistem prediksi saham yang lebih akurat dan aplikatif, serta mendorong integrasi model deep learning dalam layanan keuangan berbasis data publik.

DAFTAR PUSTAKA

- Agusta, A., Ernawati, I., & Muliawati, A. (2021). Prediksi pergerakan harga saham pada sektor farmasi menggunakan algoritma *Long Short-Term Memory*. *Jurnal Informatik*, 17(2), 55–65. <https://ejournal.upnvj.ac.id/informatik/article/view/3651/1410>
- Afrinato, N. (2022). *Prediksi harga saham menggunakan BiLSTM dengan faktor fundamental perusahaan Indonesia*. Universitas Islam Indonesia. <https://dspace.uui.ac.id/handle/123456789/39884>
- Ainun, M. B. (2019). Efek moderasi kebijakan hutang pada pengaruh kebijakan dividen terhadap harga saham. *EKUITAS (Jurnal Ekonomi dan Keuangan)*, 3(4), 501–512. <https://ejournal.stiesia.ac.id/ekuitas/article/view/4192>
- Alpha Vantage. (2024). *Alpha Vantage API Documentation*. Diakses 30 April 2025, dari <https://www.alphavantage.co/documentation/>
- Amalia, S., Christyn, M., & Banjarnahor, R. M. (2025). Prediksi harga saham dan estimasi risiko BBKA menggunakan model Geometric Brownian Motion (GBM). *Innovative: Journal Of Research*, 6(1), 45–60. <https://j-innovative.org/index.php/Innovative/article/view/18756>
- Ardini, L., & Samudra, B. (2020). Pengaruh struktur modal, kinerja keuangan, dan ukuran perusahaan terhadap harga saham. *Jurnal Ilmu dan Riset Akuntansi*, 9(6), 1–20. <https://jurnalmahasiswa.stiesia.ac.id/index.php/jira/article/view/2876>
- Arif, M., & Widodo, B. (2025). Sentimen pasar saham Indonesia di era digital. *Jurnal Pasar Modal dan Investasi*, 4(1), 88–103. <https://books.google.com/books?id=Y7BYEQAAQBAJ>
- Athoillah, M. (2023). Perkembangan pasar saham syariah di Indonesia: Kategori saham, indeks saham, dan standarisasi. *Al-Bay': Journal of Islamic Finance and Banking*, 5(1), 90–102. <http://jurnal.uinsyahada.ac.id/index.php/albay/article/view/9688>

- Dewi, R. M., Anggraeni, L., & Irawan, T. (2023). Indonesian stock market return volatility and foreign portfolio capital: Evidence before and during COVID-19 pandemic. *Jurnal Aplikasi Bisnis dan Manajemen*, 9(1), 152–157. <https://doi.org/10.17358/jabm.9.1.152>
- Djamel, E. C. (2019). Prediksi harga saham menggunakan metode Recurrent Neural Network. *Seminar Nasional Aplikasi Teknologi Informasi (SNATI)*. <https://journal.uui.ac.id/Snati/article/view/13398>
- Fitri, E., & Riana, D. (2022). Analisa perbandingan model prediction dalam prediksi harga saham menggunakan metode Linear Regression, Random Forest Regression, dan Multilayer Perceptron. *METHOMIKA: Jurnal Manajemen Informatika*, 6(2), 55–67. <https://ejurnal.methodist.ac.id/index.php/methomika/article/view/926>
- Hanafiah, M., Agusta, S., & Puteri, D. I. (2023). Penerapan metode *Recurrent Neural Network* dengan pendekatan *Long Short-Term Memory* (LSTM) untuk prediksi harga saham. *Jurnal Teknologi dan Sistem Informasi*. <https://hostjournals.com/bulletincsr/article/view/321/199>
- Hutami, P. (2022). Dampak integrasi harga saham pasar modal syariah di Indonesia terhadap return saham pada peristiwa perang dagang Amerika. *Repository Raden Intan Lampung*. <https://repository.radenintan.ac.id/19283/>
- Indarningsih, N. A. (2022). Analisis perbandingan risiko volatilitas indeks harga saham syariah dan konvensional (Jakarta Islamic Index dan Indeks LQ45). *Jurnal Ekonomi Syariah Teori dan Terapan*, 9(1), 1–10. <https://ejournal.unair.ac.id/JESTT/article/view/37504>
- Josaphat, B. P., & Pangestika, Z. (2025). Predicting stock price using convolutional neural network and *long short-term memory* (case study: Stock of BBKA). *Journal of the Indonesian Mathematical Society*. <http://jimsa.org/index.php/jimsa/article/view/1512>
- Kustodian Sentral Efek Indonesia (KSEI). (2022). Statistik jumlah investor saham di

- Indonesia. Diakses dari https://www.ksei.co.id/publications/Data_Statistik_KSEI
- Luthfiansyah, R., & Wasito, B. (2023). Penerapan teknik *deep learning* (Long Short Term Memory) dan pendekatan klasik (Regresi Linier) dalam prediksi pergerakan saham BRI. *Jurnal Informatika dan Bisnis*, 12(2), 42–50. <https://jurnal.kwikkiangie.ac.id/index.php/JIB/article/view/1059/744>
- Lutfi, M. (2019). Prediksi harga terendah dan harga tertinggi dengan menggunakan metode ANFIS untuk analisa teknikal pada forex market. *Jurnal Teknologi Informasi dan Multimedia*, 1(1), 1–10. <http://journal.sekawan-org.id/index.php/jtim/article/view/40>
- Mushliha, M. (2024). Implementasi CNN-BiLSTM untuk prediksi harga saham Bank Syariah di Indonesia. *Jambura Journal of Mathematics*, 6(2), 195–203. <https://doi.org/10.37905/jjom.v6i2.26509>
- Muzakir, A., Komari, A., & Ilham, M. (2024). Penerapan konsep *machine learning* & *deep learning*. Asosiasi Dosen Sistem Informasi Indonesia. <https://adsii.or.id/wp-content/uploads/2024/10/Penerapan-Konsep-Machine-Learning-Deep-Learning-Ari-Muzakir-et-al.pdf>
- Nafiah, R. (2019). Analisis pengaruh rasio keuangan dan variabel makro ekonomi terhadap harga saham. *Jurnal Masharif al-Syariah*, 4(1), 45–58. <https://journal.um-surabaya.ac.id/index.php/Mas/article/view/3082/>
- Pipin, S. J., Purba, R., & Kurniawan, H. (2023). Prediksi saham menggunakan *Recurrent Neural Network* (RNN-LSTM) dengan optimasi Adaptive Moment Estimation. *Journal of Computer Systems and Informatics*, 2(1), 22–34. https://www.academia.edu/110859743/Prediksi_Saham_Menggunakan_RNN_LST_M_dengan_Optimasi_Adam
- Pratama, N. I. (2023). Prediksi harga saham pada indeks KOMPAS100 menggunakan bidirectional long short-term memory dengan faktor foreign flow. *Universitas Kristen Duta Wacana*. <https://katalog.ukdw.ac.id/8055/>

- Prestiwi, P. D. C., Kencana, D. T., & Fadly, M. (2022). Pengaruh profitabilitas, likuiditas dan aktivitas terhadap harga saham perusahaan sub sektor ritel yang terdaftar di Bursa Efek Indonesia tahun 2016–2020. *Jurnal Cakrawala Ilmiah*, 6(2), 180–191. <https://bajangjournal.com/index.php/JCI/article/view/2563>
- 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. <https://doi.org/10.34312/euler.v11i1.19791>
- Puteri, D. I., Darmawan, G., & Ruchjana, B. N. (2024). Prediksi harga saham syariah menggunakan Bidirectional Long Short Term Memory (BiLSTM) dan algoritma Grid Search. *Jambura Journal of Mathematics*, 6(1), 39–45. <https://doi.org/10.37905/jjom.v6i1.23297>
- Saepudin, D., & Lesmana, R. (2025). Sistem pendukung keputusan pemilihan saham untuk portofolio dengan menggunakan metode Support Vector Regression (SVR) dan analisis fundamental. *eProceedings of Engineering Telkom University*. <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/25748>
- Setyawan, R. (2023). Prediksi harga saham berbasis web menggunakan metode LSTM dan GRU. *Repository UIN Jakarta*. <https://repository.uinjkt.ac.id/dspace/handle/123456789/83911>
- Simamora, F. P., Purba, R., & Pasha, M. F. (2025). Optimisasi hyperparameter BiLSTM menggunakan Bayesian Optimization untuk prediksi harga saham. *Jambura Journal of Machine Learning*, 7(1), 73–84. <https://ejurnal.ung.ac.id/index.php/jjom/article/view/27166>
- Soebiantoro, U. (2022). Respon cepat pasar modal (LQ45) terhadap pandemi COVID-19. *Repository UPN Veteran Jawa Timur*. <https://repository.upnjatim.ac.id/4975/>
- Tauran, E. R. (2021). Prediksi harga saham PT Bank Central Asia Tbk berdasarkan data

dari Bursa Efek Indonesia menggunakan metode K-Nearest Neighbors (KNN).
TeIKa: Jurnal Teknologi Informasi dan Komunikasi, 10(1), 25–35.
<https://jurnal.unai.edu/index.php/teika/article/view/2609>

Tobing, A., & Situmeang, S. (2025). Prediksi Harga Saham PT Bukit Asam Tbk Menggunakan Metode Moving Average. *Jurnal Ilmiah Pendidikan Matematika (MATHUNESA)*, 13(1), 87–95.
<https://ejournal.unesa.ac.id/index.php/mathunesa/article/view/64644>

Widiputra, H., Mailangkay, A., & Gautama, E. (2021). Prediksi indeks BEI dengan Ensemble Convolutional Neural Network dan Long Short-Term Memory. *Jurnal RESTI*, 5(2), 321–330.
<http://www.jurnal.iaii.or.id/index.php/RESTI/article/view/3111>

LAMPIRAN

Lampiran 1 SK-2 Penetapan Dosen Pembimbing



UMSU
Universitas Muhammadiyah Sumatera Utara

MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PUSAT MUHAMMADIYAH

UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 88/SK/BAN-PT/Akred/PT/03/2018
 Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003
idm.umsu.ac.id info@umsu.ac.id umsu.ac.id [umsu.id](https://www.facebook.com/umsu.id) [umsu.id](https://www.instagram.com/umsu.id) [umsu.id](https://www.youtube.com/umsu.id) [umsu.id](https://www.tiktok.com/umsu.id)

**PENETAPAN DOSEN PEMBIMBING
PROPOSAL/SKRIPSI MAHASISWA**
NOMOR : 482/ILJ-AU/UMSU-09/F/2025

Assalamu'alaikum Warahmatullahi Wabarakatuh

Dekan Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara, berdasarkan Persetujuan permohonan judul penelitian Proposal / Skripsi dari Ketua / Sekretaris,

Program Studi : Teknologi Informasi
Pada tanggal : 12 Maret 2025

Dengan ini menetapkan Dosen Pembimbing Proposal / Skripsi Mahasiswa.

Nama : Rifqi Yafik
NPM : 2109020044
Semester : VIII (Delapan)
Program studi : Teknologi Informasi
Judul Proposal / Skripsi : Analisis Perbandingan Metode LSTM dan BiLSTM untuk Prediksi Harga Saham Menggunakan Alpha Vantage API

Dosen Pembimbing : Mulkan Azhari, S.Kom., M.Kom.

Dengan demikian di izinkan menulis Proposal / Skripsi dengan ketentuan

1. Penulisan berpedoman pada buku panduan penulisan Proposal / Skripsi Fakultas Ilmu Komputer dan Teknologi Informasi UMSU
2. Pelaksanaan Sidang Skripsi harus berjarak 3 bulan setelah dikeluarkannya Surat Penetapan Dosen Pembimbing Skripsi.
3. **Proyek Proposal / Skripsi dinyatakan " BATAL " bila tidak selesai sebelum Masa Kadaluarsa tanggal : 12 Maret 2026**
4. Revisi judul.....

Wassalamu'alaikum Warahmatullahi Wabarakatuh.

Ditetapkan di : Medan
 Pada Tanggal : 12 Ramadhan 1446 H
 12 Maret 2025M

Dekan



Dr. Al-Khwarizmi, M.Kom.
 NPM 27099201





Cc. File





Lampiran 2 Turnitin

ANALISIS PERBANDINGAN METODE LSTM DAN BILSTM UNTUK PREDIKSI HARGA SAHAM MENGGUNAKAN ALPHA VANTAGE API

ORIGINALITY REPORT

23%	20%	14%	12%
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS

PRIMARY SOURCES

1	Submitted to Universitas Muhammadiyah Sumatera Utara Student Paper	1%
2	repository.umsu.ac.id Internet Source	1%
3	journal.eng.unila.ac.id Internet Source	1%
4	etheses.uin-malang.ac.id Internet Source	<1%
5	newinera.com Internet Source	<1%
6	repository.its.ac.id Internet Source	<1%
7	penerbitgoodwood.com Internet Source	<1%
8	text-id.123dok.com Internet Source	<1%
9	Submitted to Fakultas Ekonomi Universitas Indonesia Student Paper	<1%
10	etd.umy.ac.id Internet Source	<1%

docplayer.info

11	Internet Source	<1 %
12	ejournal.undip.ac.id Internet Source	<1 %
13	Submitted to Universitas Pamulang Student Paper	<1 %
14	Submitted to UM Surabaya Student Paper	<1 %
15	Muhamad Rizki, Aditya Eka Danneswara, Yesa Dwi Aprilia, Muhammad Fatir Rizky Al Fajri, Yayan Hendrian, Shynde Limar Kinanti. "Prediksi Harga Saham Bank BRI dan Bank BCA dengan Menggunakan Model LSTM", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1 %
16	Muhammad Miftakhudin, Aang Alim Murtopo, Zaenul Arif. "Integrasi Artificial Neural Network dan Algoritma Genetika untuk Prediksi Bencana Banjir Pesisir Kota Tegal", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1 %
17	ejurnal.ung.ac.id Internet Source	<1 %
18	repository.upi.edu Internet Source	<1 %
19	Dimas Thaqif Attaulah, Dewi Soyusiawaty. "Analisis Sentimen Program Makan Siang Gratis di Twitter/X menggunakan Metode BI-LSTM", Edumatic: Jurnal Pendidikan Informatika, 2025 Publication	<1 %

20	www.journal.stiemb.ac.id Internet Source	<1 %
21	Submitted to Sriwijaya University Student Paper	<1 %
22	Vivin Mahat Putri, M Syafrizal Zain, Satria Agus Darma. "Prediksi Harga Saham Malindo Feedmill Tbk. (MAIN) Menggunakan Jaringan Saraf Tiruan Long Short-Term Memory (LSTM)", Jurnal Pengembangan Sistem Informasi dan Informatika, 2025 Publication	<1 %
23	ojs.jurnalmahasiswa.com Internet Source	<1 %
24	repository.univ-tridianti.ac.id Internet Source	<1 %
25	Submitted to Telkom University Student Paper	<1 %
26	Submitted to Universitas Maritim Raja Ali Haji Student Paper	<1 %
27	doaj.org Internet Source	<1 %
28	dspace.uui.ac.id Internet Source	<1 %
29	adoc.pub Internet Source	<1 %
30	jims-a.org Internet Source	<1 %
31	Submitted to Institut Bisnis dan Teknologi Indonesia (INSTIKI) Student Paper	<1 %

32	ejournal.nusamandiri.ac.id Internet Source	<1 %
33	eprints.amikompurwokerto.ac.id Internet Source	<1 %
34	eprints.utem.edu.my Internet Source	<1 %
35	eprints.walisongo.ac.id Internet Source	<1 %
36	jurnal.kwikkiangie.ac.id Internet Source	<1 %
37	sistemasi.ftik.unisi.ac.id Internet Source	<1 %
38	123dok.com Internet Source	<1 %
39	Andre Wiejaya, Indah Fenriana. "Prediksi Harga Saham Top 10 NASDAQ dengan Time Series Prophet", bit-Tech, 2024 Publication	<1 %
40	danielstephanus.wordpress.com Internet Source	<1 %
41	ejournal.catursakti.ac.id Internet Source	<1 %
42	kc.umh.ac.id Internet Source	<1 %
43	stmik-budidarma.ac.id Internet Source	<1 %
44	journal.ppmi.web.id Internet Source	<1 %
45	jurnal.ranahresearch.com Internet Source	<1 %

46	digilib.unila.ac.id Internet Source	<1 %
47	Rizal Muslim Sinaga, Muhammad Rosyid Fauzan, Ega Pratama, Muhammad Rizki Alfahri, Kana Saputra. "Pemanfaatan Teknik Machine Learning dalam Memprediksi Kepadatan Lalu Lintas Guna Efisiensi Transportasi", PROSISKO: Jurnal Pengembangan Riset dan Observasi Sistem Komputer, 2025 Publication	<1 %
48	export.arxiv.org Internet Source	<1 %
49	journal.student.uny.ac.id Internet Source	<1 %
50	mail.jurnal.kampuswiduri.ac.id Internet Source	<1 %
51	Submitted to Fakultas Teknik Student Paper	<1 %
52	Submitted to Universitas Muslim Indonesia Student Paper	<1 %
53	Submitted to LPPM Student Paper	<1 %
54	Mitra Unik, M. Eddo Aldo Fahrurrozi, Harmaini Harmaini, Chandra Kusuma. "Implementation of Ensemble Learning Algorithm - Stacking Regressor on PM2.5 Prediction Model", Jurnal CoSciTech (Computer Science and Information Technology), 2024 Publication	<1 %
55	Submitted to Universitas Sumatera Utara Student Paper	<1 %

56	eprints.perbanas.ac.id Internet Source	<1 %
57	Meta Nursita. "PENGARUH LABA AKUNTANSI, ARUS KAS OPERASI, ARUS KAS INVESTASI, ARUS KAS PENDANAAN, DAN UKURAN PERUSAHAAN TERHADAP RETURN SAHAM", GOING CONCERN : JURNAL RISET AKUNTANSI, 2021 Publication	<1 %
58	lib.unnes.ac.id Internet Source	<1 %
59	www.307bwassoc.org Internet Source	<1 %
60	Submitted to Forum Perpustakaan Perguruan Tinggi Indonesia Jawa Timur Student Paper	<1 %
61	Harditya Prayoga, De Rosal Ignatus Moses Setiadi, Hendy Kurniawan. "Application of Machine Learning and Deep Learning to Predict Financial Product Subscriptions Based on Customer Features", INOVTEK Polbeng - Seri Informatika, 2025 Publication	<1 %
62	Submitted to Universitas Pendidikan Ganesha Student Paper	<1 %
63	ejurnal.seminar-id.com Internet Source	<1 %
64	eprints.umsb.ac.id Internet Source	<1 %
65	journal.stiestekom.ac.id Internet Source	<1 %

66	jurnal.fe.unram.ac.id Internet Source	<1 %
67	repository.unika.ac.id Internet Source	<1 %
68	starbanjar.com Internet Source	<1 %
69	digilibadmin.unismuh.ac.id Internet Source	<1 %
70	eprints.upj.ac.id Internet Source	<1 %
71	Submitted to Universitas Negeri Jakarta Student Paper	<1 %
72	Yogi Astriana, Daniel Nuralamsyah, Angga Putra Al-Farrezs, Khairul Akmal, Mely Gusti Mawarni, Zurnan Alfian. "Titik Balik Partisipasi Kerja Lansia: Studi Regresi Data AS 1880–2024", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1 %
73	e-jurnal.lppmunsera.org Internet Source	<1 %
74	repository.unifa.ac.id Internet Source	<1 %
75	www.researchsquare.com Internet Source	<1 %
76	www.scribd.com Internet Source	<1 %
77	Fatkurokhman Fauzi, Syifa Aulia, Ahmad Reyhan Syaifullah, Tiani Wahyu Utami. "Peramalan Harga Emas Menggunakan Pendekatan Long-Short Term Memory	<1 %

(LSTM)", Jurnal Edukasi dan Penelitian
Informatika (JEPIN), 2024

Publication

78	dqlab.id Internet Source	<1 %
79	j-innovative.org Internet Source	<1 %
80	journal.umkendari.ac.id Internet Source	<1 %
81	mail.strategi.it.maranatha.edu Internet Source	<1 %
82	repository.radenintan.ac.id Internet Source	<1 %
83	Submitted to Indian Institute of Technology Student Paper	<1 %
84	Neternomia Maria Ausiladora Da Costa, Anief Fauzan Rozi. "Analisis efisiensi tidur berdasarkan faktor demografi dan kebiasaan harian dengan metode random forest regression", Jurnal Pendidikan Informatika dan Sains, 2025 Publication	<1 %
85	eprints.utdi.ac.id Internet Source	<1 %
86	jurnal.iain-padangsidempuan.ac.id Internet Source	<1 %
87	repository.dinamika.ac.id Internet Source	<1 %
88	repository.telkomuniversity.ac.id Internet Source	<1 %
	repository.ukdw.ac.id	

89	Internet Source	<1 %
90	www.hostjournals.com Internet Source	<1 %
91	www.sciencegate.app Internet Source	<1 %
92	Jilang Ramadhani, Lusiana Efrizoni, Helda Yenni, Fransiskus Zoromi. "Analisis Performa Penjualan dan Prediksi Omzet dengan Pendekatan Market Basket Analysis Berbasis Data Analytics", The Indonesian Journal of Computer Science, 2025 Publication	<1 %
93	Submitted to Konsorsium Perguruan Tinggi Swasta Indonesia II Student Paper	<1 %
94	polinema.gitbook.io Internet Source	<1 %
95	repository.stiewidyagamalumajang.ac.id Internet Source	<1 %
96	Submitted to stie-pembangunan Student Paper	<1 %
97	Submitted to Brush High School Student Paper	<1 %
98	D. Diffran Nur Cahyo, Andi Sunyoto. "Analisis Perbandingan Klasifikasi dalam Data Mining pada Prediksi Hujan dengan menggunakan Algoritma LSTM dan GRU", Jurnal Sains dan Informatika, 2025 Publication	<1 %
99	Submitted to University of Bristol Student Paper	<1 %

100	repo.uinsatu.ac.id Internet Source	<1 %
101	Ananda Rizki Dani, Irma Handayani. "Classification of Yogyakarta Batik Motifs Using GLCM and CNN Methods", Jurnal Teknologi Terpadu, 2024 Publication	<1 %
102	Anggi Putri Meriani, Alam Rahmatulloh. "PERBANDINGAN GATED RECURRENT UNIT (GRU) DAN ALGORITMA LONG SHORT TERM MEMORY (LSTM) LINEAR REFRESSION DALAM PREDIKSI HARGA EMAS MENGGUNAKAN MODEL TIME SERIES", Jurnal Informatika dan Teknik Elektro Terapan, 2024 Publication	<1 %
103	Submitted to Universitas Jember Student Paper	<1 %
104	blog.hsb.co.id Internet Source	<1 %
105	Alrafiful Rahman, Lucia Sri Istiyowati, Valentinus Valentinus, Ivan Ivan, Zainal Azis. "IMPLEMENTASI DATA MINING DALAM PREDIKSI HARGA SAHAM BBNI DENGAN PEMODELAN MATEMATIKA MENGGUNAKAN METODE LSTM DENGAN OPTIMASI ADAM", JUTECH : Journal Education and Technology, 2024 Publication	<1 %
106	Submitted to Loughborough University Student Paper	<1 %
107	Submitted to Surabaya University Student Paper	<1 %

108	Submitted to Tarumanagara University Student Paper	<1 %
109	Submitted to Universitas Bengkulu Student Paper	<1 %
110	Submitted to Universitas Riau Student Paper	<1 %
111	ejurnal.itenas.ac.id Internet Source	<1 %
112	ekonomimanajemen.com Internet Source	<1 %
113	www.kirkshelmerdine.com Internet Source	<1 %
114	Muhammad Atharsyah, Moh. Ali Romli. "IMPLEMENTASI MODEL LSTM, GRU, BILSTM, DAN BIGRU DALAM PREDIKSI HARGA NIKEL", Jurnal Informatika dan Rekayasa Elektronik, 2024 Publication	<1 %
115	Submitted to Sekolah Teknik Elektro & Informatika Student Paper	<1 %
116	Submitted to Udayana University Student Paper	<1 %
117	Submitted to Universitas Budi Luhur Student Paper	<1 %
118	Submitted to Universitas Islam Indonesia Student Paper	<1 %
119	academia.kaust.edu.sa Internet Source	<1 %
120	bloggermalastukangcopypaste.blogmoncrot.com Internet Source	<1 %

121	dspace.nm-aist.ac.tz Internet Source	<1 %
122	journal.das-institute.com Internet Source	<1 %
123	jurnal.uimedan.ac.id Internet Source	<1 %
124	mohromlie.blogspot.com Internet Source	<1 %
125	moneyduck.com Internet Source	<1 %
126	ojs.unikom.ac.id Internet Source	<1 %
127	Submitted to Treamis International School Student Paper	<1 %
128	eprints.upnjatim.ac.id Internet Source	<1 %
129	journal.apthi.or.id Internet Source	<1 %
130	jurnal.sainsglobal.com Internet Source	<1 %
131	newcomerscuerna.org Internet Source	<1 %
132	repositorio.ucsp.edu.pe Internet Source	<1 %
133	repository.lainpalopo.ac.id Internet Source	<1 %
134	repository.uph.edu Internet Source	<1 %
135	revistas.unae.edu.ec Internet Source	<1 %

		<1 %
136	scholar.ui.ac.id Internet Source	<1 %
137	spada.uns.ac.id Internet Source	<1 %
138	Fandi Presly Simamora, Ronsen Purba, Muhammad Fermi Pasha. "Optimisasi Hyperparameter BiLSTM Menggunakan Bayesian Optimization untuk Prediksi Harga Saham", Jambura Journal of Mathematics, 2025 Publication	<1 %
139	ejournal.widyakarya.ac.id Internet Source	<1 %
140	elibrary.stipram.ac.id Internet Source	<1 %
141	etd.repository.ugm.ac.id Internet Source	<1 %
142	jurnal.unai.edu Internet Source	<1 %
143	Novandra Hanifah Najlawarni, Tukino Paryono, Fitria Nurapriani, Baenil Huda. "Klasifikasi Dan Prediksi Pada Data Ulasan Traveloka Menggunakan Algoritma LSTM", INTECOMS: Journal of Information Technology and Computer Science, 2025 Publication	<1 %
144	Putra, Reno Ferizqo Andika. "Analisis Pemilihan Alternatif Penanganan Kerusakan Jalan (Studi Kasus di Ruas Jalan Weleri-Patean,	<1 %

Kabupaten Kendal)", Universitas Islam Sultan
Agung (Indonesia), 2023

Publication

145	Submitted to Universitas Pancasila Student Paper	<1 %
146	adoc.tips Internet Source	<1 %
147	anzdoc.com Internet Source	<1 %
148	bajangjournal.com Internet Source	<1 %
149	e-journal.hamzanwadi.ac.id Internet Source	<1 %
150	economy.okezone.com Internet Source	<1 %
151	ejournal.indo-intellectual.id Internet Source	<1 %
152	ejournal.stiesia.ac.id Internet Source	<1 %
153	ejournal.widyamataram.ac.id Internet Source	<1 %
154	eprints.umg.ac.id Internet Source	<1 %
155	journal.fourzero.id Internet Source	<1 %
156	journal.unhas.ac.id Internet Source	<1 %
157	jtsiskom.undip.ac.id Internet Source	<1 %
	jurnal.icjambi.id	

158	Internet Source	<1 %
159	jurnal.stkipppersada.ac.id Internet Source	<1 %
160	kliknklikdotcom.blogspot.com Internet Source	<1 %
161	ml.scribd.com Internet Source	<1 %
162	na-st01.ext.exlibrisgroup.com Internet Source	<1 %
163	opac.wsb.torun.pl Internet Source	<1 %
164	puncakpilihanbinerpadang.blogspot.com Internet Source	<1 %
165	repositori.utu.ac.id Internet Source	<1 %
166	repository.unpas.ac.id Internet Source	<1 %
167	repository.unsri.ac.id Internet Source	<1 %
168	studylib.net Internet Source	<1 %
169	www.mdpi.com Internet Source	<1 %
170	Ahmad Yunizar, Tedy Rismawan, Dwi Marisa Midyanti. "PENERAPAN METODE RECURRENT NEURAL NETWORK MODEL GATED RECURRENT UNIT UNTUK PREDIKSI HARGA CRYPTOCURRENCY", Coding Jurnal Komputer dan Aplikasi, 2023 Publication	<1 %

- | | | |
|-------|--|------|
| 171 | <p>Ambar Ramadhani Putri, Nugroho Adhi Santoso, Bayu Aji Santoso. "Implementasi Algoritma Regresi Linier dan ARIMA untuk Prediksi Harga Emas", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025</p> <p><small>Publication</small></p> | <1 % |
| <hr/> | | |
| 172 | <p>Angellika Kristy Menteng, Anief Fauzan Rozi. "Prediksi hasil panen padi berdasarkan data curah hujan, suhu, dan kelembapan dengan metode ARIMA", Jurnal Pendidikan Informatika dan Sains, 2025</p> <p><small>Publication</small></p> | <1 % |
| <hr/> | | |
| 173 | <p>Anting B.N Sinurat, Wildan Aprizal Arifin, Wenny Ananda Larasati. "Sea Level Prediction Using Gated Recurrent Unit and Bidirectional Long Short-Term Memory Methods", INOVTEK Polbeng - Seri Informatika, 2024</p> <p><small>Publication</small></p> | <1 % |
| <hr/> | | |
| 174 | <p>Muchamad Aries Firmansyah, Aang Alim Murtopo, Nurul Fadilah. "Penerapan Metode Fuzzy Tsukamoto untuk Prediksi Jumlah Produksi PT Wings Padaharja", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025</p> <p><small>Publication</small></p> | <1 % |
| <hr/> | | |
| 175 | <p>Rizki Fegiyanto, Arief Hermawan, Farida Ardiani. "Prediksi Harga Crypto dengan Algoritma Jaringan Saraf Tiruan", Jurnal Indonesia : Manajemen Informatika dan Komunikasi, 2024</p> <p><small>Publication</small></p> | <1 % |
| <hr/> | | |
| 176 | <p>Salsabila Rabbani, Agustin, Susandri, Rahmiati, M. Khairul Anam. "OPTIMALISASI</p> | <1 % |

KINERJA KLASIFIKASI TEKS BERDASARKAN
ANALISIS BERBASIS ASPEK DAN MODEL
HYBRID DEEP LEARNING", Indonesian Journal of
Computer Science, 2024

Publication

177	Submitted to Universitas Muhammadiyah Buton Student Paper	<1 %
178	Submitted to Universitas Pendidikan Indonesia Student Paper	<1 %
179	arbaswedan.id Internet Source	<1 %
180	cits5501.github.io Internet Source	<1 %
181	ejournal.bsi.ac.id Internet Source	<1 %
182	ejournal.itn.ac.id Internet Source	<1 %
183	ekohariadicom.wordpress.com Internet Source	<1 %
184	elibrary.undipa.ac.id Internet Source	<1 %
185	fkip.univetbantara.ac.id Internet Source	<1 %
186	id.123dok.com Internet Source	<1 %
187	journal.stmik-bandung.ac.id Internet Source	<1 %
188	jurnal.uisu.ac.id Internet Source	<1 %

189	ojs.pseb.or.id Internet Source	<1 %
190	repo.undiksha.ac.id Internet Source	<1 %
191	repository.uin-suska.ac.id Internet Source	<1 %
192	www.jprjournal.com Internet Source	<1 %
193	www.pantaipandawa.id Internet Source	<1 %
194	www.polgan.ac.id Internet Source	<1 %
195	www.ufjf.br Internet Source	<1 %
196	Akhmad Faeda Insani, Ahmad Mushawir, Zainuddin, Aditya Adiaksa, Sparisoma Viridi. "Optimization of Variable Combinations for Household Electricity Consumption Prediction Using a Multivariate Time Series Machine Learning Approach", INOVTEK Polbeng - Seri Informatika, 2024 Publication	<1 %
197	Anggie Yolanda. "Prediksi Pergerakan Harga Saham Menggunakan Support Vector Machines Di Indonesia", BUDGETING : Journal of Business, Management and Accounting, 2024 Publication	<1 %
198	Azwar Azwar, Abur Hamdi Usman. "Artificial intelligence in public finance: A bibliometric exploration", Jurnal Tata Kelola dan Akuntabilitas Keuangan Negara, 2025	<1 %

199	Dian Islamiaty Puteri, Gungum Darmawan, Budi Nurani Ruchjana. "Prediksi Harga Saham Syariah menggunakan Bidirectional Long Short Term Memory (BiLSTM) dan Algoritma Grid Search", Jambura Journal of Mathematics, 2024	<1%
200	H L Gururaj, Francesco Flammini, V Ravi Kumar, N S Prema. "Recent Trends in Healthcare Innovation", CRC Press, 2025	<1%
201	Khumukcham Robindro Singh, Nazrul Hoque, Arnab Kumar Maji, Sabyasachi Mondal et al. "Emerging Trends and Future Directions in Artificial Intelligence, Machine Learning, and Internet of Things Innovations - A proceeding of NEIAIS — 2025", CRC Press, 2025	<1%
202	Dwi Ismiyana Putri, Mardi Yudhi Putra. "KOMPARASI ALGORITMA DALAM MEMPREDIKSI PERUBAHAN HARGA SAHAM GOTO MENGGUNAKAN RAPIDMINER", Jurnal Khatulistiwa Informatika, 2023	<1%
203	Fahira Fahira, Cahyo Prianto. "Prediksi Pola Kedatangan Turis Mancanegara dan Menganalisis Ulasan Tripadvisor dengan LSTM dan LDA", Jurnal Tekno Insentif, 2023	<1%
204	Irwan Trinugroho, Evan Lau. "Business Innovation and Development in Emerging Economies", CRC Press, 2019	<1%

- | | | |
|-------|---|------|
| 205 | M. Amin, Deuis Astrida, Eling Sekar. "Analisis Prediktif Terhadap Kinerja Siswa dalam Ujian Menggunakan Algoritma Random Forest dan K-Nearest Neighbors", Jurnal Teknologi Pendidikan, 2025 | <1 % |
| <hr/> | | |
| 206 | Maila D.H. Rahiem. "Towards Resilient Societies: The Synergy of Religion, Education, Health, Science, and Technology", CRC Press, 2025 | <1 % |
| <hr/> | | |
| 207 | Moumita Barua, Teerath Kumar, Kislay Raj, Arunabha M. Roy. "Comparative Analysis of Deep Learning Models for Stock Price Prediction in the Indian Market", FinTech, 2024 | <1 % |
| <hr/> | | |
| 208 | Oetami, Elok Retno. "Model Peningkatan Perilaku Inovatif Berbasis Akuisisi Pengetahuan dan Berbagi Pengetahuan Proyek Perubahan Dengan Penggunaan Teknologi dan Informasi Pada Pemerintah Kabupaten Kotawaringin Barat", Universitas Islam Sultan Agung (Indonesia), 2024 | <1 % |
| <hr/> | | |
| 209 | Septian Dwi Cahyo, Aang Alim Murtopo, Bayu Aji Santoso. "Penerapan Metode Regresi Linier untuk Prediksi Jumlah Penumpang Kereta Api", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 | <1 % |
| <hr/> | | |
| 210 | Taufik Hidayat, Irwan Sembiring, Hindriyanto Dwi Purnomo, Ade Iriani. "Prediction of Stunting Prevalence in Toddlers Using | <1 % |

Support Vector Machine Algorithm and
Synthetic Minority Oversampling Technique
(SMOTE)", Jurnal Pekommas, 2025

Publication

211

Veri Arinal, Melli Puspita. "Peningkatan
Akurasi Nilai Harga Saham Menggunakan
Metode Long Short-Term Memory (LSTM)
pada PT Unilever Tbk", Jurnal Indonesia :
Manajemen Informatika dan Komunikasi,
2025

Publication

<1%

Exclude quotes Off

Exclude bibliography Off

Exclude matches Off