

**IMPLEMENTASI *MACHINE LEARNING* DENGAN MODEL LSTM  
UNTUK FORECASTING HARGA SAHAM MENGGUNAKAN DATA  
YAHOO FINANCE**

**SKRIPSI**

**DISUSUN OLEH**

**PRAYOGA SUNGKOWO**

**NPM.21090200046**



**UMSU**

Unggul | Cerdas | Terpercaya

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

**MEDAN**

**2025**

**IMPLEMENTASI *MACHINE LEARNING* DENGAN MODEL LSTM  
UNTUK FORECASTING HARGA SAHAM MENGGUNAKAN DATA  
YAHOO FINANCE**

**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**

**PRAYOGA SUNGKOWO  
NPM.2109020046**

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

## LEMBAR PENGESAHAN

Judul Skripsi : Implementasi *Machine Learning* Dengan Model LSTM  
Untuk Forecasting Harga Saham Menggunakan Data  
Yahoo Finance  
Nama Mahasiswa : Prayoga Sungkowo  
NPM : 2109020046  
Program Studi : Teknologi Informasi

Menyetujui  
Komisi Pembimbing



(Dr. Al-Khoyarizmi, S.Kom., M.Kom.)  
NIDN. 0127099201

Ketua Program Studi



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

Dekan



(Dr. Al-Khoyarizmi, S.Kom., M.Kom.)  
NIDN. 0127099201

## PERNYATAAN ORISINALITAS

### IMPLEMENTASI *MACHINE LEARNING* DENGAN MODEL LSTM UNTUK FORECASTING HARGA SAHAM MENGGUNAKAN DATA YAHOO FINANCE

#### SKRIPSI

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

Medan, 1 Agustus 2025

Yang membuat pernyataan



Prayoga Sungkowo

NPM. 2109020046

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

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

Nama : Prayoga Sungkowo  
NPM : 2109020046  
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:

**IMPLEMENTASI *MACHINE LEARNING* DENGAN MODEL LSTM  
UNTUK FORECASTING HARGA SAHAM MENGGUNAKAN DATA  
YAHOO FINANCE**

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, 1 Agustus 2025

Yang membuat pernyataan



Prayoga Sungkowo

NPM. 2109020044

## RIWAYAT HIDUP

### DATA PRIBADI

Nama Lengkap : Prayoga Sungkowo  
Tempat dan Tanggal Lahir : Medan, 21 November 2002  
Alamat Rumah : Jl Pendidikan Dusun II Desa Bengkel  
Telepon/Faks/HP : 089525760626  
E-mail : prayogasungkowo12@gmail.com  
Instansi Tempat Kerja : -  
Alamat Kantor : -

### DATA PENDIDIKAN

SD : SD Negeri 101943 Bengkel TAMAT: 2015  
SMP : SMP Negeri 3 Perbaungan TAMAT: 2018  
SMA : SMA Negeri 2 Perbaungan 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 “Implementasi *Machine Learning* Dengan Model LSTM Untuk Forecasting Harga Saham Menggunakan Data” 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, sekaligus Dosen Pembimbing penulis.
3. Ibu Fatma Sari Hutagaulung, S.Kom., M.Kom., selaku Ketua Program Studi Teknologi Informasi sekaligus Dosen Pembimbing Akademik penulis.
4. Bapak Muhammad Basri, S.Kom., M.Kom., selaku Sekretaris Program Studi Teknologi Informasi.
5. 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.
6. Kedua orang tua tercinta, Bapak Aipda. Amin Sungkowo dan Ibu Mudrika Sari, yang selalu memberikan doa, semangat, cinta, serta dukungan moral dan material tanpa henti.

7. Keluarga Besar Almarhum Wagimin dan Almarhum Sudirman yang selalu memberikan doa, nasihat, serta dukungan kepada penulis selama proses pendidikan hingga penyusunan skripsi ini.
8. Rekan-rekan seperjuangan di grup “Punyaku-punyaku Grup” yaitu Rifqi, Qodri, Anggi, Gatot, Farhan, Ikhsan, dan Mutiara Akbar, yang telah menjadi teman diskusi sekaligus motivasi selama menempuh studi di UMSU.
9. Pacar penulis yang sudah menemani sedari sekolah menengah pertama hingga akhir perjalanan kuliah, memberikan semangat dan motivasi agar terus maju. Saudari Della Amelia, semoga setelah ini diberikan rezeki menikah dikemudian hari.
10. Tema-teman kelas TI A1 Stambuk 21 yang sudah menemani penulis sedari awal kegiatan perkuliahan hingga akhir perkuliahan terimakasih sebanyak-banyaknya.
11. 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, 09 Agustus  
2025

Penulis



Prayoga Sungkowo

IMPLEMENTASI *MACHINE LEARNING* DENGAN MODEL LSTM UNTUK  
FORECASTING HARGA SAHAM MENGGUNAKAN DATA YAHOO  
FINANCE

**ABSTRAK**

Fluktuasi harga saham yang tinggi dan kompleks menjadi tantangan utama bagi investor dalam mengambil keputusan. Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi efektivitas model *Machine Learning*, khususnya *Long Short-Term Memory* (LSTM), untuk melakukan *forecasting* (peramalan) harga saham. Data yang digunakan adalah data historis harga penutupan harian (*closing price*) saham Apple Inc. (AAPL) dari 1 Januari 2022 hingga 31 Desember 2024, yang diperoleh melalui Yahoo Finance. Proses penelitian meliputi tahapan *preprocessing* data dengan normalisasi *MinMaxScaler* dan pembentukan *dataset* sekuensial menggunakan metode *sliding window*. Model LSTM dengan arsitektur dua lapis kemudian dibangun dan dilatih menggunakan *framework* TensorFlow dan Keras. Kinerja model dievaluasi menggunakan metrik *Root Mean Squared Error* (RMSE) dan *Mean Absolute Error* (MAE) untuk mengukur tingkat akurasi prediksi. Hasil penelitian menunjukkan bahwa model LSTM yang diimplementasikan berhasil menangkap tren umum pergerakan harga saham dengan baik, dibuktikan dengan perolehan nilai RMSE sebesar 3.31 dan MAE sebesar 2.68. Penelitian ini memberikan kontribusi empiris mengenai penerapan praktis model LSTM dalam domain keuangan dan menunjukkan alur kerja yang sistematis untuk membangun sistem peramalan harga saham yang dapat diandalkan.

Kata Kunci: *Forecasting* Harga Saham, *Machine Learning*, *Long Short-Term Memory*, LSTM, Yahoo Finance.

# IMPLEMENTATION OF A LONG SHORT-TERM MEMORY (LSTM) MODEL FOR STOCK PRICE FORECASTING USING YAHOO FINANCE DATA

## ABSTRACT

The high and complex volatility of stock prices poses a major challenge for investors in decision-making. This study aims to implement and evaluate the effectiveness of a Machine Learning model, specifically Long Short-Term Memory (LSTM), for stock price forecasting. The data used is the historical daily closing price of Apple Inc. (AAPL) stock from January 1, 2022, to December 31, 2024, obtained from Yahoo Finance. The research process includes data preprocessing with MinMaxScaler normalization and the creation of a sequential dataset using a sliding window method. A two-layer LSTM model was then built and trained using the TensorFlow and Keras framework. The model's performance was evaluated using Root Mean Squared Error (RMSE) and Mean Absolute Error (MAE) metrics to measure prediction accuracy. The results indicate that the implemented LSTM model successfully captured the general trend of stock price movements, evidenced by an RMSE value of 3.31 and an MAE value of 2.68. This research provides an empirical contribution regarding the practical application of the LSTM model in the financial domain and demonstrates a systematic workflow for building a reliable stock price forecasting system.

Keywords: Stock Price Forecasting, Machine Learning, Long Short-Term Memory, LSTM, Yahoo Finance.

## DAFTAR ISI

LEMBAR PENGESAHAN .....	ii
PERNYATAAN ORISINALITAS .....	iii
PERNYATAAN PERSETUJUAN PUBLIKASI .....	iv
KATA PENGANTAR .....	vi
ABSTRAK .....	viii
ABSTRACT .....	ix
DAFTAR ISI .....	x
DAFTAR TABEL .....	xiii
DAFTAR GAMBAR .....	xiv
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 .....	4
1.5.1 Manfaat Akademis .....	5
1.5.2 Manfaat Praktis .....	5
1.5.3 Manfaat Teknologis .....	5
BAB II LANDASAN TEORI .....	6
2.1 Saham Dan Harga Saham .....	6
2.2 Forecasting Harga Saham .....	8
2.3 <i>Machine Learning</i> Dalam Forecasting Harga Saham .....	10
2.4 <i>Long Short-Term Memory</i> (LSTM) .....	12
2.4.1 Konsep Dasar LSTM dan Latar Belakang Penggunaannya .....	12
2.4.2 Komponen Utama LSTM: <i>Cell State</i> , <i>Hidden State</i> , dan <i>Gate</i> .....	13
2.4.3 Formulasi Matematis LSTM dan Makna Konseptualnya .....	14
2.4.4 Mekanisme Kerja LSTM dari Waktu ke Waktu .....	16
2.5 Pustaka Python Dan Tools Implementasi .....	17
2.6 Metrik Evaluasi Model .....	20
2.6.1 <i>Root Mean Squared Error</i> (RMSE) .....	21
2.6.2 <i>Mean Absolute Error</i> (MAE) .....	21
2.7 Yahoo Finance Sebagai Sumber Data Saham .....	22
2.8 Penelitian Terdahulu .....	24

BAB III METODOLOGI PENELITIAN.....	27
3.1 Pendekatan Penelitian.....	27
3.2 Jenis dan Sumber Data .....	28
3.2.1 Sumber Data.....	29
3.2.2 Rentang Dan Format Data.....	29
3.2.3 Alat Pengambilan Data .....	30
3.2.4 Karakteristik Data .....	31
3.3 Teknik Pengumpulan Data .....	32
3.3.1 Langkah-langkah Pengumpulan Data .....	32
3.3.2 Alasan Pemilihan Teknik Ini.....	33
3.3.3 Kelebihan Teknik Pengumpulan Data Terprogram .....	34
3.3.4 Justifikasi Pemilihan Yahoo Finance .....	34
3.3.5 Struktur Data yang Dihasilkan .....	34
3.4 Teknik Analisis Data .....	35
3.4.1 <i>Preprocessing</i> Data .....	35
3.4.2 Arsitektur Dan Pembentukan Model LSTM .....	36
3.4.3 Pembangunan Model LSTM dari Awal dan Justifikasi Penggunaan Pustaka Keras.....	38
3.4.4 Evaluasi Model.....	47
3.4.4 Interpretasi Hasil .....	48
3.5 Prosedur Pengujian dan Validasi.....	49
3.5.1 Validasi Selama Pelatihan ( <i>Validation Split</i> ).....	49
3.5.2 Pengujian Menggunakan Data Testing .....	50
3.5.3 Visualisasi Hasil Evaluasi .....	50
3.5.4 Interpretasi Hasil .....	50
3.6 Diagram Alir Penelitian.....	51
3.7 Kerangka Waktu Penelitian .....	52
BAB IV HASIL DAN PEMBAHASAN.....	53
4.1 Deskripsi Data .....	53
4.2 <i>Preprocessing Data</i> .....	54
4.3 Implementasi dan Arsitektur Model LSTM .....	56
4.4 Hasil Evaluasi Kinerja Model .....	58
4.4.1 Hasil Evaluasi Kuantitatif .....	59
4.4.2 Visualisasi Hasil Prediksi.....	59
4.4.3 Prediksi Hari Berikutnya.....	60
4.5 Pembahasan .....	60

4.5.1	Analisis Kinerja Model .....	60
4.5.2	Validasi Hasil dengan Teori dan Penelitian Terdahulu .....	61
4.5.3	Implikasi dan Keterbatasan Penelitian .....	62
4.6	Implementasi Aplikasi Prediksi Harga Saham .....	63
BAB V PENUTUP.....		67
5.1	Kesimpulan.....	67
5.2	Saran.....	68
DAFTAR PUTAKA .....		69

## DAFTAR TABEL

Tabel 2. 1 Penelitian Terdahulu .....	24
Tabel 3. 1 Contoh Tabel dataset.....	30
Tabel 3. 2 Kerangka Waktu Penelitian .....	52
Tabel 4. 1 Perbandingan Data Sebelum Dan Sesudah Normalisasi.....	55
Tabel 4. 2 Arsitektur Final Model LSTM .....	57
Tabel 4. 3 Hasil Evaluasi Kuantitatif Model LSTM .....	59

## DAFTAR GAMBAR

Gambar 2. 1 Contoh Penggunaan yfinance.....	23
Gambar 3. 1 Diagram Blok Alur Pembangunan Model LSTM Dari Awal .....	44
Gambar 3. 2 Kode inisiasi matplotlib .....	48
Gambar 3. 3 Alur Penelitian.....	51
Gambar 4. 1 Contoh Kode Pengambilan Data dengan yfinance.....	53
Gambar 4. 2 Grafik Loss Pelatihan dan Validasi Model LSTM.....	58
Gambar 4. 3 Visualisasi Perbandingan Harga Aktual dan Prediksi LSTM.....	60
Gambar 4. 4 Tampilan Awal Aplikasi .....	64
Gambar 4. 5 Tampilan Aplikasi Melatih Model Lalu Menyajikan Dataset Terbaru .....	65
Gambar 4. 6 Setelah Di Training Aplikasi Menampilkan Grafik Visual Harga Aktual vs Prediksi .....	65
Gambar 4. 7 Aplikasi Menampilkan Harga Prediksi Di Hari Berikutnya .....	66
Gambar 4. 8 Aplikasi Menampilkan Hasil Evaluasi Kinerja Model .....	66

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang Masalah

Pasar saham merupakan salah satu instrumen investasi yang paling diminati oleh masyarakat karena potensi imbal hasil yang tinggi. Namun, karakteristiknya yang fluktuatif, kompleks, dan tidak pasti menjadikannya tantangan tersendiri dalam dunia keuangan (Janiesch et al., 2021). Pergerakan harga saham yang dinamis dapat dipengaruhi oleh berbagai faktor seperti kondisi ekonomi makro, kebijakan pemerintah, performa perusahaan, dan psikologi pasar.

Untuk menjawab tantangan tersebut, berbagai pendekatan statistik dan komputasional telah dikembangkan dalam rangka memforecasting harga saham secara lebih akurat. Seiring berkembangnya teknologi informasi, pendekatan berbasis *Machine Learning* mulai banyak digunakan karena kemampuannya dalam mengekstraksi pola dari data historis secara otomatis dan adaptif (Gao et al., 2021; Janiesch et al. (2021). Dalam konteks data berskala besar, evaluasi akurasi model juga menjadi aspek penting. Al-Khowarizmi et al. (2021) menunjukkan bahwa sensitivitas terhadap metrik seperti Mean Absolute Percentage Error (MAPE) dapat memengaruhi tingkat deteksi dan kinerja sistem forecasting, terutama pada data besar seperti komoditas dan pasar keuangan.

Salah satu model yang populer dalam *Machine Learning* untuk data berurutan adalah *Long Short-Term Memory* (LSTM), varian dari *Recurrent Neural Network* (RNN) yang dirancang untuk menangani permasalahan dalam forecasting *time series* dan mengatasi isu *vanishing gradient* (Sherstinsky, 2020). Model LSTM dapat mengingat informasi jangka panjang, yang menjadikannya sangat sesuai

untuk menangani fluktuasi harga saham yang sering dipengaruhi oleh tren historis (Switrayana et al., 2025).

Dalam penelitian yang dilakukan oleh Switrayana et al. (2025), model LSTM menunjukkan stabilitas forecasting yang baik pada data harga saham setelah melalui proses *preprocessing* dengan metode normalisasi. Penelitian lain oleh (Alizadegan et al., 2025) menunjukkan bahwa model LSTM dan Bi-LSTM mampu menangani data *time series* dengan akurasi tinggi, bahkan mengungguli model statistik tradisional seperti ARIMA dalam konteks forecasting konsumsi energi.

Studi yang lebih fokus pada pasar saham dilakukan oleh (Li et al., 2023), yang menggunakan model LSTM untuk memforecasting saham teknologi berbasis data Yahoo Finance. Model ini berhasil mencapai nilai RMSE sebesar 18.89, menandakan performa yang sangat baik dalam mengenali tren jangka panjang. Namun, mereka juga mencatat bahwa model LSTM memiliki keterbatasan dalam menangani forecasting jangka pendek yang memiliki fluktuasi tinggi atau sifat acak.

Selain itu, penelitian oleh Kulkarni et al. (2024) menekankan pentingnya arsitektur dan konfigurasi model yang tepat dalam penerapan LSTM agar hasil forecasting optimal. Sementara itu, Chaudhary, 2025 dan Pardeshi et al., 2023 menunjukkan bahwa pendekatan hybrid yang menggabungkan LSTM dengan mekanisme perhatian (*attention mechanism*) atau transformasi sinyal dapat meningkatkan kemampuan model dalam menangani data yang kompleks dan tidak linier.

Gupta et al. (2024) dan Huang (2023) juga menyampaikan bahwa pemilihan parameter model dan jenis data historis yang digunakan sangat berpengaruh

terhadap hasil forecasting akhir. Oleh karena itu, penting untuk merancang alur eksperimen yang mencakup *preprocessing*, pengujian parameter, serta pemilihan indikator pasar yang relevan.

Berdasarkan studi-studi tersebut, penelitian ini bertujuan untuk mengimplementasikan model LSTM dalam memforecasting harga saham berdasarkan data historis yang diperoleh dari Yahoo Finance, dengan memanfaatkan pustaka Python seperti *yfinance* (Andi & Kusuma, 2025). Dengan mengoptimalkan *preprocessing* serta arsitektur LSTM, penelitian ini diharapkan dapat memberikan hasil forecasting yang akurat, relevan, dan aplikatif bagi investor maupun pengambil keputusan di bidang pasar modal.

## **1.2 Rumusan Masalah**

Berdasarkan uraian latar belakang tersebut, permasalahan yang dapat dirumuskan dalam penelitian ini adalah bagaimana mengimplementasikan model *Long Short-Term Memory* (LSTM) sebagai salah satu metode *Machine Learning* untuk memforecasting harga saham berdasarkan data historis dari *Yahoo Finance*, serta sejauh mana model tersebut mampu memberikan hasil forecasting yang akurat dan dapat diandalkan dalam menggambarkan tren pergerakan harga saham, guna membantu investor atau pelaku pasar dalam pengambilan keputusan investasi yang lebih efektif dan efisien.

## **1.3 Batasan Masalah**

Agar penelitian ini lebih terfokus dan terarah, maka ruang lingkup penelitian dibatasi pada penggunaan model *Long Short-Term Memory* (LSTM) untuk memforecasting harga saham berbasis data historis yang diambil dari Yahoo

Finance. Data yang digunakan terbatas pada harga saham penutupan harian (*closing price*) dalam kurun waktu tertentu dan tidak mencakup faktor eksternal seperti berita, kondisi ekonomi makro, atau sentimen pasar. Penelitian ini hanya membahas proses *preprocessing data*, pelatihan model, evaluasi kinerja model dengan metrik tertentu seperti RMSE dan MSE, serta visualisasi hasil forecasting. Model lain seperti ARIMA, GRU, atau Bi-LSTM tidak dibahas secara mendalam karena fokus utama adalah pada implementasi dan evaluasi model LSTM.

#### **1.4 Tujuan Penelitian**

Tujuan dari penelitian ini adalah untuk:

1. Mengimplementasikan model *Long Short-Term Memory* (LSTM) dalam memforecasting harga saham berbasis data historis yang diperoleh dari Yahoo Finance.
2. Melakukan *preprocessing* data saham seperti normalisasi menggunakan metode *MinMaxScaler* agar sesuai untuk pelatihan model *deep learning*.
3. Melatih dan mengevaluasi kinerja model LSTM dengan menggunakan metrik evaluasi seperti *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE).
4. Menyediakan visualisasi hasil forecasting untuk menggambarkan akurasi model dalam memperkirakan tren harga saham.
5. Memberikan kajian empiris terhadap efektivitas model LSTM dalam domain forecasting pasar saham, khususnya pada data *time series* harga saham penutupan harian.

#### **1.5 Manfaat Penelitian**

Penelitian ini diharapkan memberikan manfaat sebagai berikut:

### **1.5.1. Manfaat Akademis**

1. Memberikan kontribusi ilmiah dalam bentuk studi empiris terkait penerapan model LSTM dalam bidang forecasting harga saham berbasis *Machine Learning* dan *time series analysis*.
2. Menjadi referensi bagi penelitian selanjutnya yang ingin mengembangkan model forecasting harga saham menggunakan pendekatan deep learning lainnya seperti Bi-LSTM atau GRU.

### **1.5.2. Manfaat Praktis**

1. Membantu investor, analis keuangan, dan pelaku pasar dalam membuat keputusan investasi yang lebih tepat dengan menggunakan hasil forecasting berbasis model LSTM.
2. Menyediakan model prediktif yang dapat diintegrasikan ke dalam sistem analitik saham untuk mendukung strategi investasi berbasis data.

### **1.5.3. Manfaat Teknologis**

1. Menunjukkan efektivitas penggunaan teknologi open-source seperti Python dan library yfinance, TensorFlow, atau Keras dalam membangun sistem forecasting berbasis kecerdasan buatan.
2. Menjadi contoh implementasi nyata *Machine Learning* dalam dunia keuangan digital yang dapat diaplikasikan secara luas.

## **BAB II** **LANDASAN TEORI**

### **2.1 Saham Dan Harga Saham**

Saham merupakan salah satu instrumen keuangan yang paling umum digunakan dalam aktivitas investasi. Saham menyatakan kepemilikan atas suatu bagian perusahaan dan memberikan hak kepada pemegangnya atas bagian dari keuntungan perusahaan, biasanya dalam bentuk dividen, serta hak suara dalam rapat umum pemegang saham. Dalam dunia keuangan modern, saham menjadi instrumen utama dalam portofolio investasi individu maupun institusi karena kemampuannya menghasilkan return yang relatif tinggi dalam jangka panjang (Janiesch et al., 2021)

Harga saham merupakan representasi nilai pasar suatu perusahaan yang dibentuk melalui interaksi antara penawaran dan permintaan di pasar modal. Nilai ini bersifat sangat dinamis dan dapat berubah secara real time karena dipengaruhi oleh berbagai faktor baik internal maupun eksternal, seperti laporan keuangan perusahaan, kebijakan moneter, kondisi ekonomi makro, dan sentimen pasar. Fluktuasi harga saham ini sering membentuk pola tertentu yang bersifat repetitif dan digunakan dalam strategi analisis teknikal maupun prediktif (Sherstinsky, 2020)

Data harga saham dicatat dalam format deret waktu (*time series*), yaitu data yang dicatat secara kronologis berdasarkan interval waktu tertentu (harian, mingguan, atau bulanan). Salah satu karakteristik utama dari data *time series* adalah adanya ketergantungan temporal, di mana nilai pada suatu waktu sangat mungkin dipengaruhi oleh nilai-nilai sebelumnya. Selain itu, data saham dikenal memiliki volatilitas tinggi dan cenderung non-stasioner, serta sering kali dipengaruhi oleh

noise yang tidak merefleksikan kondisi fundamental perusahaan secara langsung (Gao et al. (2021); Janiesch et al. (2021)).

Menurut beberapa penelitian, harga penutupan (closing price) merupakan jenis harga yang paling umum digunakan dalam penelitian forecasting saham. Hal ini dikarenakan harga penutupan mencerminkan konsensus pasar terhadap nilai saham di akhir sesi perdagangan dan biasanya lebih stabil dibandingkan harga pembukaan atau harga tertinggi (Li et al. 2023; Switrayana et al., 2025). Harga penutupan ini juga menjadi referensi utama dalam algoritma forecasting berbasis *Machine Learning* karena kestabilannya mempermudah model dalam menangkap tren (Desai & Kharade, 2025).

Dalam konteks pemanfaatan data secara praktis, Yahoo Finance menjadi salah satu sumber data historis yang paling banyak digunakan dalam penelitian prediktif. Dengan bantuan pustaka Python seperti *yfinance*, data dapat diambil secara otomatis dalam bentuk format yang siap untuk diolah, memungkinkan integrasi langsung dengan pipeline *Machine Learning* tanpa memerlukan tahapan perekaman manual (Li et al., 2023; Kulkarni et al., 2024).

Berdasarkan pemahaman tersebut, dapat disimpulkan bahwa harga penutupan saham harian merupakan objek penelitian yang sangat strategis untuk diolah dengan model forecasting seperti *Long Short-Term Memory (LSTM)*, yang akan dibahas lebih lanjut pada bagian selanjutnya.

#### **2.4.1 Saham**

Saham adalah surat berharga yang menjadi bukti kepemilikan seseorang atau badan terhadap suatu perusahaan. Pemilik saham memiliki klaim atas sebagian aset dan pendapatan perusahaan, serta hak untuk memperoleh dividen sesuai

dengan jumlah kepemilikan. Saham diklasifikasikan menjadi beberapa jenis, seperti saham biasa dan saham preferen, tergantung pada hak dan kewajiban yang melekat pada pemilikinya. Dalam praktiknya, saham banyak digunakan sebagai sarana untuk memperoleh keuntungan melalui capital gain dan dividen. Di pasar modal modern, saham menjadi pilihan utama dalam investasi karena menawarkan potensi pertumbuhan nilai yang tinggi seiring dengan kinerja perusahaan (Janiesch et al., 2021).

#### **2.4.2 Harga Saham**

Harga saham adalah nilai yang diberikan pasar kepada suatu saham berdasarkan keseimbangan antara permintaan dan penawaran. Harga saham dapat berubah sewaktu-waktu tergantung pada faktor internal seperti kinerja keuangan dan ekspansi perusahaan, serta faktor eksternal seperti inflasi, suku bunga, dan gejolak geopolitik. Harga saham umumnya dicatat dalam beberapa jenis, antara lain harga pembukaan, harga penutupan, harga tertinggi, dan harga terendah. Namun, harga penutupan lebih sering digunakan dalam analisis karena menggambarkan sentimen pasar secara menyeluruh dalam satu hari perdagangan (Li et al., 2023; Switrayana et al., 2025).

#### **2.2 Forecasting Harga Saham**

Forecasting harga saham merupakan salah satu topik yang paling menarik dalam bidang keuangan, data science, dan kecerdasan buatan. Tujuan utamanya adalah memperkirakan nilai saham di masa depan berdasarkan informasi yang tersedia dari data historis maupun faktor eksternal lainnya. Kegiatan ini penting dalam membantu investor dan institusi keuangan membuat keputusan investasi

yang lebih baik, mengelola risiko, dan merancang strategi pasar yang optimal (Janiesch et al., 2021)

Namun, forecasting harga saham bukanlah tugas yang sederhana. Harga saham sangat dipengaruhi oleh banyak faktor, seperti kondisi ekonomi makro, suku bunga, kebijakan pemerintah, laporan keuangan perusahaan, sentimen pasar, hingga peristiwa geopolitik. Sifat ini menjadikan data saham non-linier, non-stasioner, dan penuh noise, sehingga pendekatan konvensional seperti regresi linier atau ARIMA sering kali gagal dalam menangkap kompleksitas tersebut (Sherstinsky, 2020).

Seiring dengan kemajuan teknologi informasi dan komputasi, pendekatan berbasis Machine Learning menjadi salah satu alternatif yang sangat menjanjikan dalam mengatasi kompleksitas forecasting harga saham. Machine Learning memungkinkan model untuk belajar secara otomatis dari data, tanpa perlu didefinisikan secara eksplisit bagaimana hubungan antar variabel terbentuk. Model-model ini dapat mengenali pola-pola yang tersembunyi dalam data historis dan menggunakan pola tersebut untuk membuat forecasting terhadap nilai saham di masa mendatang (Chaudhary, 2025; Pardeshi et al., 2023).

Pendekatan Machine Learning dalam forecasting saham terbagi menjadi dua kategori besar:

1. *Supervised Learning*, di mana model dilatih dengan data berlabel (harga saham historis sebagai input dan harga selanjutnya sebagai target).
2. *Unsupervised Learning*, yang digunakan untuk mengelompokkan atau memahami struktur data tanpa label, meskipun lebih jarang dipakai untuk forecasting numerik langsung (Janiesch et al., 2021)

Model Long Short-Term Memory (LSTM), yang termasuk dalam kategori supervised learning, merupakan salah satu teknik machine learning yang paling efektif dalam menangani data time series keuangan, terutama karena kemampuannya dalam menyimpan memori jangka panjang dan memahami hubungan temporal yang kompleks (Li et al., 2023; Gao et al., 2021).

Dalam banyak penelitian, pendekatan forecasting saham dengan LSTM terbukti unggul. Misalnya, (Li et al., 2023) menunjukkan bahwa model LSTM yang diterapkan pada data Yahoo Finance untuk saham teknologi mampu menghasilkan forecasting dengan akurasi tinggi (RMSE sebesar 18.89). Studi oleh Switrayana et al. (2025) juga menegaskan bahwa preprocessing seperti normalisasi MinMaxScaler sangat penting untuk meningkatkan akurasi model forecasting berbasis LSTM.

Salah satu alasan mengapa pendekatan Machine Learning cocok untuk forecasting saham adalah kemampuannya dalam menggunakan berbagai variabel input sekaligus dan mengenali korelasi non-linier antar variabel. Selain itu, model ML seperti LSTM dapat dilatih secara end-to-end tanpa perlu rekayasa fitur manual yang kompleks, sehingga mempercepat proses pembangunan sistem forecasting.

Meskipun demikian, penting untuk diingat bahwa tidak ada model forecasting yang benar-benar sempurna, terutama untuk data yang sangat dipengaruhi oleh faktor acak dan emosi pasar. Oleh karena itu, forecasting harga saham harus dipahami sebagai alat bantu dalam pengambilan keputusan, bukan sebagai jaminan mutlak terhadap pergerakan pasar.

### **2.3 *Machine Learning* Dalam Forecasting Harga Saham**

*Machine Learning* (ML) adalah cabang dari kecerdasan buatan yang berfokus pada pengembangan algoritma yang memungkinkan sistem untuk belajar secara otomatis dari data dan membuat forecasting atau pengambilan keputusan tanpa perlu diprogram secara eksplisit. Dalam konteks keuangan, terutama forecasting harga saham, ML memberikan pendekatan baru yang lebih adaptif dan akurat dibandingkan metode statistik konvensional (Janiesch et al., 2021).

Harga saham merupakan data deret waktu (*time series*) yang kompleks, non-linear, dan penuh dengan noise. Karakteristik ini membuat pendekatan tradisional seperti regresi linier atau ARIMA kurang efektif dalam menangkap pola-pola tersembunyi. Di sinilah peran *Machine Learning* menjadi penting, karena ia mampu belajar dari data historis dan menyesuaikan model berdasarkan pola yang terus berubah (Gao et al., 2021).

Model *Machine Learning* bekerja dengan membagi data menjadi dua bagian utama, yaitu data pelatihan (training set) dan data pengujian (testing set). Algoritma kemudian dilatih menggunakan data pelatihan untuk membentuk pola relasi antara *input* dan *output*, dan diuji pada data pengujian untuk mengevaluasi performanya. Beberapa pendekatan *Machine Learning* yang umum digunakan dalam forecasting saham adalah:

1. *Decision Tree dan Random Forest*
2. *Support Vector Machines (SVM)*
3. *Artificial Neural Networks (ANN)*
4. *Recurrent Neural Networks (RNN)*
5. *Long Short-Term Memory (LSTM)*

Dari berbagai pendekatan tersebut, model LSTM menjadi salah satu yang paling banyak digunakan untuk forecasting saham karena kemampuannya dalam mengingat informasi jangka panjang dan mengenali pola deret waktu yang tidak eksplisit (Li et al., 2023; Switrayana et al., 2025). LSTM dapat memproses data sekuensial dengan efisien, sehingga cocok untuk memforecasting harga penutupan saham berdasarkan data historis.

Studi oleh Pardeshi et al., 2023 menunjukkan bahwa integrasi antara LSTM dan metode *Machine Learning* lain seperti attention mechanism atau XGBoost dapat lebih meningkatkan akurasi forecasting. Selain itu, Chaudhary, 2025) mengemukakan bahwa *Machine Learning* berbasis deep learning dapat menyederhanakan proses ekstraksi fitur yang sebelumnya memerlukan rekayasa fitur manual.

Keunggulan ML dalam forecasting saham tidak hanya pada akurasinya, tetapi juga pada kemampuannya untuk belajar secara adaptif terhadap data baru, sehingga model dapat terus diperbarui dan diperbaiki seiring waktu. Dengan demikian, ML menjadi pendekatan yang sangat relevan untuk pasar saham yang sifatnya dinamis dan terus berubah.

Namun, perlu diingat bahwa forecasting saham dengan ML tetap memiliki tantangan, seperti overfitting, kebutuhan data besar, dan sensitivitas terhadap parameter model. Oleh karena itu, perlu dilakukan evaluasi performa secara berkala menggunakan metrik seperti RMSE dan MAE, serta validasi silang untuk menjaga generalisasi model (Sherstinsky, 2020).

## **2.4 Long Short-Term Memory (LSTM)**

### **2.4.1 Konsep Dasar LSTM dan Latar Belakang Penggunaannya**

LSTM adalah varian khusus dari RNN yang dirancang untuk mengatasi *vanishing gradients* (gradien yang menghilang) pada RNN konvensional. Sherstinsky (2020) menjelaskan bahwa LSTM diperkenalkan khusus untuk “*addressing the vanishing gradients problem*” dengan menambahkan mekanisme kontrol nonlinier yang dapat dipelajari. Secara intuitif, LSTM mampu menangani ketergantungan jangka panjang dalam data berurutan karena adanya *cell state* yang terjaga sepanjang waktu. Sebagaimana dikemukakan Switrayana et al. (2025), LSTM dikembangkan dari RNN untuk memecahkan masalah utama menangani informasi jangka panjang dalam data urutan. Keunggulan ini membuat LSTM banyak digunakan pada masalah *time series*, peramalan, dan pemrosesan bahasa, di mana pola panjang sangat penting. Misalnya, Alizadegan et al. (2025) melaporkan LSTM mampu meningkatkan akurasi prediksi permintaan energi (mengurangi kesalahan prediksi hingga 20%) dibandingkan metode tradisional.

#### 2.4.2 Komponen Utama LSTM: *Cell State*, *Hidden State*, dan *Gate*

Setiap unit LSTM memiliki *state* jangka panjang (*cell state*) dan *hidden state* keluaran. Cell state  $C_t$  berperan sebagai memori internal yang berjalan lurus (dengan sedikit gangguan) sepanjang langkah waktu. *Hidden state*  $h_{t-1}$  adalah keluaran *sigmoid-tanh* pada setiap langkah yang mempengaruhi prediksi atau lapisan berikutnya. Untuk mengontrol aliran informasi, LSTM dilengkapi tiga *gate* utama: *forget gate*, *input gate*, dan *output gate*. Sherstinsky (2020) menggambarkan bahwa LSTM menambahkan gerbang kontrol untuk mengelola kontribusi sinyal lama dan baru ke dalam *cell state*. Lebih rinci:

1. Forget gate ( $f_t$ ) menentukan berapa banyak informasi dari *cell state* sebelumnya yang dipertahankan. Jika  $f_t$  mendekati 1 maka informasi lama dipertahankan;

jika mendekati 0 maka dilupakan sebagian. Sherstinsky (2020) menjelaskan gerbang “*control state*” ( $g_{cs}$ ) setara fungsi *forget* yang mengontrol seberapa besar sinyal keadaan dari langkah sebelumnya dipertahankan.

2. Input gate ( $i_t$ ) mengatur berapa banyak informasi baru dari input saat ini yang akan ditambahkan ke *cell state*. Gerbang ini memfilter informasi baru yang dihitung (biasanya oleh transformasi *tanh*) sebelum disimpan. Dalam formulasi Sherstinsky (2020), gerbang “*control update*” ( $g_{cu}$ ) serupa *input gate*, yang mengatur besar sinyal pembaruan yang disuntikkan ke dalam *cell state* pada langkah saat ini.
3. Output gate ( $o_t$ ) menentukan seberapa banyak *cell state* saat ini yang dijadikan keluaran (*hidden state*). Sherstinsky (2020) menyebut ini gerbang “*control readout*” ( $g_{cr}$ ), yang menentukan seberapa besar sinyal *readout* yang menjadi sinyal keluaran sel pada langkah saat ini. *Output gate* mengalikan hasil aktivasi *tanh* dari *cell state* dengan  $o_t$  untuk menghasilkan  $h_t$ .

Dengan mekanisme gerbang ini, LSTM mampu “mengingat” informasi jangka panjang dan mengontrol aliran informasi secara selektif. Switrayana et al. (2025) mencatat bahwa keunggulan LSTM terletak pada kemampuannya untuk “mengingat” informasi dalam jangka waktu yang lama, sehingga model dapat menangkap pola kompleks dalam data historis. Mekanisme *gates* memungkinkan LSTM mengontrol aliran informasi sehingga memungkinkan pengolahan informasi jangka panjang tanpa kehilangan informasi dalam urutan waktu yang lama.

### 2.4.3 Formulasi Matematis LSTM dan Makna Konseptualnya

Proses LSTM dirumuskan dengan beberapa persamaan. Misalkan  $x_t$  adalah input saat ini dan  $h_{t-1}$  adalah hidden state sebelumnya. Maka:

1. Forget gate:

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

Di mana  $\sigma$  adalah fungsi sigmoid. Nilai  $f_t \in (0,1)$  menentukan informasi mana dari *cell state* sebelumnya ( $C_{t-1}$ ) yang dipertahankan. Konseptualnya, gerbang ini memfilter memori lama sebagaimana dijelaskan Sherstinsky (2020).

2. Input gate:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i), \quad \tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c)$$

Di mana  $\tilde{C}_t$  adalah kandidat *cell state* baru (hasil aktivasi *tanh*). Gate  $i_t$  (rata-rata mendekati 0–1) menentukan seberapa banyak  $\tilde{C}_t$  dimasukkan. Dengan kata lain, *input gate* memutuskan informasi baru yang berharga untuk ditambahkan.

3. Pembaruan Cell State:

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t$$

Artinya, *cell state* baru adalah gabungan elemen-bijaksana antara memori lama yang dipertahankan ( $f_t \odot C_{t-1}$ ) dan informasi baru yang ditambahkan ( $i_t \odot \tilde{C}_t$ ). Formulasi ini menyiratkan bahwa LSTM dapat melupakan atau menyimpan

informasi lama sambil menambahkan informasi baru sesuai kebutuhan, yang diilustrasikan oleh persamaan serupa dalam Sherstinsky (2020).

*Output gate dan Hidden State:*

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o), \quad h_t = o_t \odot \tanh(C_t)$$

Output gate  $o_t$  menentukan bagian *cell state* mana yang diekspor sebagai keluaran. Sherstinsky (2020) menekankan bahwa gerbang ini mengendalikan jumlah fraksional sinyal *readout* yang menjadi nilai keluaran sel pada langkah saat ini. Dengan mengalikan  $o_t$  dan  $\tanh(C_t)$ , *hidden state*  $h_t$  dihasilkan.

Dalam rangkaian ini, fungsi-fungsi  $\sigma$  (sigmoid) dan  $\tanh$  bersifat dapat didiferensialkan, sehingga LSTM dapat dilatih dengan *backpropagation through time*. Setiap persamaan di atas memiliki makna konseptual: *forget gate* menghindarkan hilangnya gradien dengan membuka atau menutup jalur memori lama, *input gate* menambah informasi relevan, dan *output gate* mengontrol keluaran model pada setiap langkah waktu.

#### 2.4.4 Mekanisme Kerja LSTM dari Waktu ke Waktu

Pada setiap langkah waktu  $t$ , LSTM menerima input baru  $x_t$  dan menghitung gating seperti di atas. *Cell state*  $C_t$  diperbarui menurut persamaan yang memastikan informasi lama dapat berlanjut (melalui faktor  $f_t$ ) atau tergantikan sebagian (melalui  $i_t \tilde{C}_t$ ). *Hidden state*  $h_t$  kemudian dihasilkan dari *output gate*. Siklus inilah yang di-*unroll* secara temporal: setiap langkah LSTM mempertahankan memori yang relevan dan memperbaruinya dengan informasi baru. Sherstinsky (2020) memperlihatkan bahwa dalam kasus ideal—jika forget

gate selalu terbuka penuh ( $f_t = 1$ ) dan *input/output gate* tertutup ( $i_t = o_t$ )—maka *cell state* tidak berubah dan *gradien kesalahan* senantiasa mengalir tak teredam melalui waktu (mode “*Constant Error Carousel*”). Ini menggambarkan kemampuan LSTM mengatasi masalah gradien menghilang dengan menjaga jalur gradien tetap terbuka. Selama proses pelatihan, jika model terlatih membuat  $f_{t-t}$  dekat 1, LSTM dapat “memelihara” memori jangka panjang lebih efektif. Dengan demikian, dari waktu ke waktu LSTM belajar secara dinamis kapan harus mengingat atau melupakan informasi lama, sesuai kebutuhan tugas. Hasilnya, LSTM dapat mengenali pola jangka panjang dalam data berurutan, sebagaimana banyak studi (misalnya Desai & Kharade, 2025; Switrayana et al., 2025) laporkan keunggulannya dalam menangkap *long-term dependencies*.

## 2.5 Pustaka Python Dan Tools Implementasi

Dalam pengembangan model *Machine Learning* untuk forecasting harga saham, pemilihan bahasa pemrograman dan pustaka yang tepat menjadi aspek penting yang menentukan efisiensi dan reusabilitas sistem. Bahasa pemrograman Python telah menjadi standar industri dan akademik dalam bidang data science dan *Machine Learning* karena sifatnya yang open-source, sintaksis yang sederhana, serta ekosistem pustaka yang sangat luas dan aktif.

Penelitian ini memanfaatkan berbagai pustaka Python untuk mendukung seluruh tahapan, mulai dari pengumpulan data, *preprocessing*, pembangunan model, pelatihan, hingga evaluasi hasil forecasting. Seluruh proses dilakukan secara otomatis dalam lingkungan terintegrasi yang memungkinkan implementasi pipeline *Machine Learning* secara efisien dan dapat direproduksi (Kulkarni et al. 2024; Li

et al., 2023). Berikut ini adalah pustaka dan alat yang digunakan dalam penelitian ini:

### **2.5.1 Yfinance**

Yfinance adalah pustaka Python yang digunakan untuk mengunduh data harga saham historis dari Yahoo Finance secara langsung. Pustaka ini memudahkan proses pengumpulan data *time series* tanpa perlu pengolahan manual atau akses ke API kompleks. Data yang diperoleh mencakup harga pembukaan, penutupan, tertinggi, terendah, volume, dan tanggal perdagangan. Studi oleh (Li et al., 2023) juga menggunakan yfinance untuk mengakses data saham Apple dalam penelitian forecasting berbasis LSTM.

### **2.5.2 Pandas**

Pandas merupakan pustaka standar untuk manipulasi data tabular dalam Python. Dalam penelitian ini, pandas digunakan untuk proses pembersihan data, seleksi kolom, konversi format tanggal, dan penyusunan struktur *time series*. Kemampuan DataFrame pada pandas memungkinkan penyusunan *input* model dengan efisien dan dapat dikombinasikan langsung dengan NumPy untuk operasi numerik lanjutan.

### **2.5.3 NumPy**

NumPy digunakan untuk komputasi numerik dan pengelolaan array multidimensi, terutama dalam membentuk *input* dan target untuk model forecasting. NumPy sangat penting dalam pembuatan struktur data window *time*

*series* dan untuk konversi format sebelum *input* dimasukkan ke dalam model LSTM.

#### **2.5.4 Scikit-learn**

Scikit-learn menyediakan berbagai tools untuk *preprocessing* dan evaluasi. Dalam penelitian ini, fungsi *minmaxscaler* digunakan untuk melakukan normalisasi data dalam rentang [0, 1] agar stabil saat digunakan dalam pelatihan model deep learning. Selain itu, scikit-learn juga digunakan untuk menghitung metrik evaluasi seperti RMSE dan MAE.

#### **2.5.5 Tensorflow dan Keras**

TensorFlow bersama dengan API Keras digunakan untuk membangun dan melatih model LSTM. Keras menyediakan antarmuka tingkat tinggi untuk membuat arsitektur neural network secara modular. Komponen penting seperti LSTM, Dropout, Dense, dan EarlyStopping digunakan untuk membentuk dan mengoptimalkan model. Studi oleh (Kulkarni et al., 2024) dan Switrayana et al. (2025) juga menggunakan Keras dalam pembangunan sistem forecasting harga saham berbasis LSTM.

#### **2.5.6 Matplotlib dan Seaborn**

Pustaka matplotlib dan seaborn digunakan untuk visualisasi data dan hasil forecasting. Visualisasi membantu mengevaluasi hasil forecasting model secara intuitif, misalnya dengan membandingkan grafik harga aktual dan forecasting dalam satu kurva.

#### **2.5.7 Google Colab**

Google Colaboratory digunakan **sebagai** lingkungan eksekusi *cloud-based* yang mendukung bahasa Python, serta memberikan akses GPU secara gratis. Platform ini sangat ideal untuk eksperimen *Machine Learning* karena tidak memerlukan konfigurasi perangkat keras lokal. Studi oleh Switrayana et al. (2025) dan (Chaudhary, 2025) juga menegaskan bahwa penggunaan Colab mempercepat proses pelatihan dan memungkinkan eksperimen dapat dilakukan dari berbagai perangkat.

Dengan dukungan dari pustaka-pustaka di atas, proses implementasi model LSTM dapat dilakukan secara efisien, terstruktur, dan dapat direplikasi. Kombinasi alat ini memberikan fleksibilitas tinggi dalam mengatur arsitektur model, mengelola data historis, dan melakukan evaluasi performa prediktif dalam satu ekosistem pemrograman yang konsisten.

## 2.6 Metrik Evaluasi Model

Dalam implementasi model *Machine Learning* untuk forecasting harga saham, penggunaan metrik evaluasi sangat penting untuk menilai tingkat akurasi dan keandalan hasil forecasting. Metrik evaluasi digunakan untuk membandingkan nilai forecasting model dengan nilai aktual, serta untuk mengukur sejauh mana model mampu merepresentasikan pola historis yang relevan. Menurut beberapa penelitian yang ada, metrik seperti *Root Mean Squared Error* (RMSE) dan *Mean Absolute Error* (MAE) merupakan dua ukuran kesalahan forecasting yang paling umum digunakan dalam konteks forecasting harga saham karena keduanya memberikan informasi numerik yang representatif terhadap deviasi (Li et al. 2023;

Janiesch et al., 2021; Gao et al., 2021). Dalam studi Huang (2023), model LSTM menunjukkan perbedaan signifikan pada nilai RMSE di antara empat jenis saham, menegaskan pentingnya pemilihan dataset yang tepat untuk masing-masing model forecasting.

### 2.6.1 *Root Mean Squared Error (RMSE).*

RMSE adalah metrik yang mengukur rata-rata kuadrat dari selisih antara nilai aktual dan nilai forecasting, lalu diakarkan. RMSE memberikan penalti yang lebih besar terhadap kesalahan forecasting yang signifikan karena selisih dikuadratkan sebelum dirata-ratakan.

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

Secara matematis, RMSE dirumuskan sebagai:

di mana:

1.  $y_i$  adalah nilai aktual,
2.  $\hat{y}_i$  adalah nilai forecasting, dan
3.  $n$  adalah jumlah data.

RMSE sering digunakan dalam studi forecasting saham karena memberikan perhatian lebih pada kesalahan yang besar, yang dalam konteks keuangan dapat berarti kerugian yang lebih signifikan. Dalam studi Yu (2025), model LSTM yang diterapkan pada data Apple Inc. berhasil mencapai RMSE sebesar 18.89, menunjukkan akurasi yang tinggi dalam memforecasting harga penutupan saham.

### 2.6.2 *Mean Absolute Error (MAE)*

MAE adalah rata-rata dari nilai absolut perbedaan antara nilai aktual dan nilai forecasting. Tidak seperti RMSE, MAE tidak memberikan penalti kuadrat pada kesalahan besar, sehingga lebih stabil terhadap outlier.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

MAE memiliki interpretasi langsung: misalnya, MAE sebesar 12 menunjukkan bahwa forecasting model rata-rata meleset 12 satuan dari nilai aktual. MAE lebih stabil terhadap outlier dibandingkan RMSE, dan umumnya digunakan sebagai pelengkap evaluasi agar dapat melihat konsistensi model dalam meminimalkan kesalahan secara keseluruhan (Switrayana et al., 2025).

## 2.7 Yahoo Finance Sebagai Sumber Data Saham

Dalam penelitian berbasis data pasar saham, pemilihan sumber data yang valid, konsisten, dan mudah diakses menjadi aspek fundamental. Salah satu platform penyedia data keuangan yang banyak digunakan oleh peneliti dan praktisi adalah Yahoo Finance. Platform ini menyediakan data historis harga saham dari berbagai bursa dunia, termasuk Bursa Efek Indonesia, dengan cakupan informasi seperti harga pembukaan (open), penutupan (close), tertinggi (high), terendah (low), volume transaksi, serta harga penutupan yang disesuaikan (adjusted close).

Menurut Li et al. (2023), Yahoo Finance sangat ideal sebagai sumber data historis untuk analisis dan forecasting harga saham karena selain menyediakan data yang lengkap, platform ini juga mendukung akses otomatis melalui pustaka Python seperti yfinance. Hal ini memungkinkan pengumpulan data dilakukan dalam format terstruktur (DataFrame), sehingga dapat langsung diolah ke dalam pipeline

*Machine Learning* tanpa proses ekstraksi manual tambahan. Selain aksesibilitas, kelebihan Yahoo Finance terletak pada:

1. Ketersediaan data historis yang panjang dan konsisten
2. Penyajian data dalam format *time series* harian, mingguan, maupun bulanan
3. Kompatibilitas tinggi dengan pustaka Python seperti Pandas dan NumPy
4. Dapat digunakan dalam lingkungan Google Colab, mempercepat integrasi dengan pelatihan model LSTM (Switrayana et al., 2025).

Dalam konteks implementasi model *Long Short-Term Memory* (LSTM), data yang diambil dari Yahoo Finance biasanya difokuskan pada kolom Close, karena harga penutupan dianggap paling representatif dalam mencerminkan konsensus pasar pada akhir sesi perdagangan (Kulkarni et al., 2024). Harga penutupan juga lebih stabil dibandingkan harga intraday seperti open, high, dan low, sehingga lebih sesuai untuk tugas forecasting berbasis model sekuensial. Penggunaan `yfinance` memungkinkan peneliti untuk menulis skrip sederhana seperti:

```
import yfinance as yf

# Menentukan parameter untuk pengunduhan data
ticker = '[Isi dengan kode saham, misal: AAPL]'
start_date = '2022-01-01'
end_date = '2024-12-31'

# Mengunduh data
data = yf.download(ticker, start=start_date, end=end_date)
```

Gambar 2. 1 Contoh Penggunaan `yfinance`

Proses ini menyederhanakan proses akuisisi data, memungkinkan automasi penuh dalam sistem forecasting harga saham, serta mempercepat replikasi eksperimen di masa mendatang. Selain itu, karena Yahoo Finance bersifat gratis

dan terbuka, platform ini sangat cocok untuk kebutuhan penelitian akademik yang mengedepankan prinsip keterbukaan data (open science).

## 2.8 Penelitian Terdahulu

Berbagai penelitian telah dilakukan untuk menguji efektivitas model *Long Short-Term Memory* (LSTM) dalam memforecasting harga saham. Hasil-hasil tersebut secara umum menunjukkan bahwa LSTM merupakan salah satu pendekatan deep learning yang unggul dalam menangani data *time series* yang fluktuatif dan non-linear seperti harga saham. Berikut ini adalah rangkuman beberapa penelitian yang relevan dengan topik ini:

Tabel 2. 1 Penelitian Terdahulu

<b>Penulis (Tahun)</b>	<b>Judul Penelitian</b>	<b>Temuan Utama</b>
Li et al. (2023)	Stock market analysis and prediction using LSTM: A case study on technology stocks	$R^2 = 0.94$ ; RMSE = 18.89. Akurat untuk tren jangka panjang
Switrayana et al. (2025)	Comparative Analysis of Stock Price Prediction Using Deep Learning with Data Scaling Method	Normalisasi data meningkatkan akurasi hingga 22.57%
(Kulkarni et al., 2024)	Working of stock price prediction using LSTM	Dropout efektif mencegah overfitting
Alizadegan et al. (2025)	Comparative study of long short-term memory (LSTM), bidirectional	Bi-LSTM menurunkan RMSE secara signifikan

	LSTM, and traditional machine learning approaches for energy consumption prediction	
Agarwal et al. (2025)	Time-series forecasting using SVMD-LSTM: A hybrid approach for stock market prediction	Hybrid model lebih akurat daripada LSTM tunggal

Studi-studi yang telah diuraikan pada tabel di atas menunjukkan bahwa pendekatan forecasting harga saham menggunakan model *Long Short-Term Memory* (LSTM) secara konsisten menghasilkan performa yang lebih baik dibandingkan pendekatan konvensional. Hal ini terutama karena LSTM dirancang untuk memproses data sekuensial dan memiliki kemampuan untuk menangkap pola jangka panjang melalui mekanisme memori internal.

Penelitian Li et al. (2023) menegaskan efektivitas LSTM dalam mengenali tren jangka panjang pada saham-saham sektor teknologi. Temuan mereka penting karena menunjukkan bahwa meskipun data harga saham bersifat fluktuatif, model LSTM masih dapat mencapai akurasi tinggi ketika dioptimalkan dengan baik. Di sisi lain, Switrayana et al. (2025) menyoroti aspek *preprocessing* data yang sering kali diabaikan. Mereka membuktikan bahwa penggunaan teknik normalisasi dapat meningkatkan kualitas *input* dan pada akhirnya berdampak langsung terhadap akurasi model.

Kemudian, studi dari Kulkarni et al. (2024) memberikan kontribusi pada aspek teknik regularisasi, seperti dropout dan early stopping, untuk mencegah overfitting. Ini sangat relevan dalam konteks implementasi model deep learning karena overfitting merupakan salah satu tantangan umum dalam pelatihan model

dengan dataset historis terbatas. Penelitian (Alizadegan et al., 2025) meskipun tidak secara langsung fokus pada forecasting harga saham, memberikan pembelajaran penting terkait keunggulan arsitektur Bi-LSTM, yang dapat menjadi alternatif peningkatan performa di masa mendatang.

Sementara itu, pendekatan hybrid yang diusulkan oleh (Agarwal et al., 2025) menunjukkan bahwa penggabungan metode LSTM dengan teknik dekomposisi sinyal seperti SVMD dapat meningkatkan akurasi dan mengurangi kesalahan forecasting. Hal ini membuka ruang eksplorasi untuk mengintegrasikan LSTM dengan metode pra-pemrosesan lanjutan lainnya seperti wavelet transform, empirical mode decomposition, atau bahkan attention mechanism.

Dari keseluruhan studi tersebut, dapat disimpulkan bahwa efektivitas model LSTM dalam memforecasting harga saham sangat dipengaruhi oleh beberapa faktor utama, yakni: kualitas dan karakteristik data historis yang digunakan, tahapan *preprocessing* yang diterapkan, struktur dan kedalaman arsitektur LSTM, serta strategi evaluasi dan validasi yang menyertainya. Oleh karena itu, penelitian ini berupaya menyusun dan mengimplementasikan model LSTM dengan memperhatikan praktik terbaik dari studi sebelumnya, khususnya dalam hal pemilihan sumber data (Yahoo Finance), proses *preprocessing* (normalisasi MinMaxScaler), serta struktur pelatihan model (multi-layer LSTM dengan dropout).

Dengan menjadikan studi-studi terdahulu sebagai pijakan, penelitian ini tidak hanya mereplikasi pendekatan yang telah terbukti efektif, tetapi juga mencoba menyederhanakan implementasinya dalam konteks forecasting harga saham Indonesia. Langkah ini diharapkan dapat memperkuat kontribusi empiris dan

praktis dalam pengembangan sistem forecasting harga saham berbasis *Machine Learning* yang lebih akurat dan dapat diterapkan secara luas oleh investor maupun analis pasar.

## **BAB III METODOLOGI PENELITIAN**

### **3.1 Pendekatan Penelitian**

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen komputasional pada data deret waktu harga saham. Model yang dipilih adalah Long Short-Term Memory (LSTM), varian dari Recurrent Neural Network (RNN) yang dirancang untuk mengatasi masalah vanishing gradient sehingga mampu menangkap ketergantungan jangka panjang pada data sekuensial (Hochreiter & Schmidhuber; Sherstinsky, 2020).

Secara kerangka kerja, penelitian ini bersifat supervised learning: model dilatih untuk memetakan urutan harga penutupan sebelumnya (fitur) ke harga penutupan periode berikutnya (label). Pendekatan jaringan saraf berulang banyak digunakan dan terbukti efektif pada domain keuangan karena mampu memodelkan pola non-linear dan dinamika temporal yang kompleks (Pardeshi et al., 2023; Janiesch et al., 2021). Pemilihan LSTM didasari kemampuannya memelihara “memori” melalui cell state serta mekanisme gerbang, sehingga lebih stabil dibanding RNN biasa ketika mempelajari urutan panjang (Sherstinsky, 2020).

Rancangan penelitian diatur sebagai eksperimen berulang yang meliputi:

1. pengambilan data historis harga saham dari Yahoo Finance,
2. praproses data (pemeriksaan kelengkapan, normalisasi skala, dan pembentukan jendela/sequence),
3. perancangan arsitektur dan pelatihan model,
4. evaluasi kuantitatif pada data uji yang dipisahkan secara kronologis, dan
5. validasi untuk menilai kemampuan generalisasi.

Seluruh eksperimen dijalankan di lingkungan Python untuk menjaga reproducibility dan efisiensi, dengan ekosistem sains data umum (misalnya NumPy/Pandas) serta kerangka kerja deep learning modern pada tahap implementasi akhir. Pemanfaatan Yahoo Finance dipilih karena ketersediaan data historis yang luas dan kemudahan integrasi dengan alur pemrograman Python, sebagaimana lazim pada penelitian serupa (Kulkarni et al., 2024; Switrayana et al., 2025).

### **3.2 Jenis dan Sumber Data**

Data yang digunakan dalam penelitian ini adalah data sekunder kuantitatif yang berasal dari sumber terbuka dan terpercaya, yaitu Yahoo Finance. Data sekunder adalah data yang telah dikumpulkan dan dipublikasikan oleh pihak lain, bukan oleh peneliti secara langsung melalui observasi atau eksperimen (Switrayana et al., 2025). Dalam konteks ini, Yahoo Finance dipilih karena menyediakan data harga saham historis yang lengkap, berkualitas, dan dapat diakses secara gratis melalui pustaka Python `yfinance` (Kulkarni et al. 2024; Li et al., 2023).

Jenis data yang digunakan bersifat kuantitatif numerik, khususnya data harga penutupan saham harian (*closing price*). Harga penutupan dipilih karena dianggap paling representatif dalam mencerminkan konsensus pasar pada akhir sesi perdagangan dan paling banyak digunakan dalam analisis teknikal maupun dalam penelitian berbasis *forecasting time series* (Li et al., 2023; Switrayana et al., 2025). Berbagai studi sebelumnya juga mendukung pemanfaatan harga penutupan sebagai input tunggal untuk model LSTM karena kestabilannya dibandingkan harga tertinggi, terendah, atau harga pembukaan (Gao et al., 2021; Kulkarni et al. 2024).

### 3.2.1 Sumber Data

Sumber data utama dalam penelitian ini adalah Yahoo Finance (<https://finance.yahoo.com>), yang telah banyak digunakan dalam berbagai studi forecasting harga saham berbasis machine learning (Kulkarni et al. 2024; Switrayana et al., 2025; Li et al., 2023). Platform ini menyediakan data harga saham secara gratis, terbuka, dan terstruktur, mencakup berbagai instrumen keuangan dari bursa global (Kulkarni et al., 2024).

Menurut Kulkarni et al. (2024) dan Switrayana et al. (2025), Yahoo Finance adalah pilihan yang efisien untuk akuisisi data historis karena selain lengkap, data yang disediakan juga kompatibel dengan pustaka Python seperti pandas dan NumPy, yang menjadi tulang punggung dalam pengolahan data dan implementasi model machine learning.

### 3.2.2 Rentang Dan Format Data

Data yang digunakan dalam penelitian ini mencakup periode 1 Januari 2022 hingga 31 Desember 2024, yang dipilih karena mencerminkan pergerakan pasar saham terbaru dan mencakup satu siklus pasar tahunan secara penuh. Data ini digunakan sebagai dasar pelatihan dan pengujian model LSTM dalam melakukan forecasting harga saham pada bulan selanjutnya di awal 2025.

Format data yang digunakan adalah data deret waktu (*time series*) dengan struktur kolom:

1. *Date*: tanggal perdagangan
2. *Open*: harga pembukaan
3. *High*: harga tertinggi
4. *Low*: harga terendah

5. *Close*: harga penutupan
6. *Volume*: jumlah saham yang diperdagangkan

Tabel 3. 1 Contoh Tabel dataset

Date	Open	High	Low	Close	Volume
2022-01-03	178,6456451	179,4995739	174,4251401	174,5429172	104487900
2022-01-04	176,3783264	179,5584419	175,8090456	179,2541745	99310400
2022-01-05	171,6867065	176,8396634	171,4118834	176,2900171	94537600
2022-01-06	168,820694	172,0596987	168,4673477	169,5077519	96904000
2022-01-07	168,9875488	170,9211359	167,8686216	169,6942413	86709100
...	...	...	...	...	...
2024-12-23	254,6557159	255,0347911	252,8400883	254,1569192	40858800
2024-12-24	257,5786743	257,5886296	254,6756581	254,875189	23234700
2024-12-26	258,3966675	259,4740856	257,0100283	257,5686782	27237100
2024-12-27	254,9749298	258,0774616	252,4510194	257,2095296	42355300
2024-12-30	251,5930786	252,8899532	250,1465711	251,6230052	35557500

Dari kolom-kolom tersebut, hanya kolom *Close* yang dipilih sebagai variabel *input* utama karena alasan stabilitas dan kesesuaiannya dengan struktur data yang dibutuhkan oleh model LSTM.

### 3.2.3 Alat Pengambilan Data

Pengambilan data dilakukan secara otomatis menggunakan pustaka Python **yfinance**, yang memungkinkan pengguna untuk mengakses dan mengunduh data pasar dari Yahoo Finance ke dalam format DataFrame. Pustaka ini mendukung

penyesuaian rentang waktu, frekuensi data (harian, mingguan, bulanan), serta pemilihan simbol saham sesuai kebutuhan pengguna (Li et al., 2023).

Proses ini dilakukan dalam lingkungan komputasi berbasis cloud menggunakan Google Colaboratory, sehingga memungkinkan akses GPU dan kolaborasi daring. Data kemudian disimpan dalam format CSV dan selanjutnya diproses dengan *pandas* untuk seleksi dan pembersihan data.

#### **3.2.4 Karakteristik Data**

Karakteristik data yang digunakan dalam penelitian ini adalah sebagai berikut:

1. Jenis Data: *Time series* (data deret waktu)
2. Format: Tabel dengan kolom [*Date, Open, High, Low, Close, Adj Close, Volume*]
3. Frekuensi: Harian (daily)
4. Rentang Waktu: 1 Januari 2022 – 31 Desember 2024
5. Variabel Utama: Harga Penutupan (*Close*)

Pemilihan harga penutupan sebagai fokus utama didasarkan pada penelitian sebelumnya yang menyatakan bahwa harga penutupan merupakan indikator yang paling stabil dan representatif dalam mencerminkan nilai saham pada akhir sesi perdagangan (Gao et al., 2021; Li et al., 2023). Selain itu, data harga penutupan juga paling sering digunakan sebagai target forecasting dalam model LSTM karena mendukung pembentukan *input* sekuensial dengan struktur window yang teratur (Switrayana et al., 2025).

Data ini selanjutnya digunakan sebagai *input* untuk model LSTM dalam format windowing *time series*, di mana 60 hari data historis digunakan untuk

memforecasting harga pada hari ke-61. Dengan menggunakan alat otomatisasi data yang kuat dan sumber terpercaya, kualitas serta validitas data dapat dipertahankan, yang pada akhirnya mendukung keakuratan model forecasting secara keseluruhan.

### 3.3 Teknik Pengumpulan Data

Teknik pengumpulan data dalam penelitian ini dilakukan secara otomatis dan terprogram menggunakan bahasa pemrograman Python. Metode ini dipilih untuk memastikan bahwa data yang diperoleh memiliki akurasi tinggi, minim kesalahan *input* manual, dan dapat direplikasi dengan langkah-langkah yang konsisten oleh peneliti lain, sesuai dengan prinsip *reproducible research*.

Data dikumpulkan melalui pustaka *yfinance*, yang digunakan untuk mengakses informasi pasar saham dari platform Yahoo Finance secara langsung ke dalam lingkungan pemrograman Python. Pendekatan ini sangat relevan untuk penelitian berbasis komputasi dan *Machine Learning* karena memungkinkan integrasi data secara langsung ke dalam pipeline *preprocessing* dan pelatihan model (Janiesch et al., 2021; Kulkarni et al. 2024).

#### 3.3.1 Langkah-langkah Pengumpulan Data

Langkah teknis yang dilakukan dalam proses pengumpulan data meliputi:

1. Inisialisasi pustaka *yfinance*

Digunakan untuk mengunduh data harga saham dari Yahoo Finance. Proses pengambilan data dapat dilakukan secara sederhana dengan sintaks Python seperti berikut:

```
import yfinance as yf
```

Gambar 3.1 Inisiasi Pustaka *yfinance*

2. Penentuan rentang waktu

Penelitian menggunakan data saham harian dari 1 Januari 2022 hingga 31

Desember 2024, yang dirancang untuk membangun model prediktif bagi bulan-bulan awal tahun 2025. Pemilihan rentang ini sejalan dengan temuan (Alizadegan et al., 2025) yang menunjukkan bahwa cakupan data historis yang memadai penting dalam mengoptimalkan performa model LSTM.

### 3. Penyimpanan dan pengolahan awal

Data yang telah diunduh disimpan dalam format Pandas DataFrame, yang memfasilitasi pengolahan lanjutan seperti filter kolom, format tanggal, serta ekspor ke CSV jika diperlukan.

### 4. Validasi integritas data

Langkah ini mencakup deteksi dan penanganan data hilang, duplikat, atau outlier. Jika ditemukan ketidaksesuaian data, dilakukan pembersihan dengan interpolasi, penghapusan baris, atau metode lain yang sesuai dengan konteks data (Switrayana et al., 2025).

## 3.3.2 Alasan Pemilihan Teknik Ini

Penggunaan teknik otomatisasi ini didasari oleh beberapa keunggulan utama:

1. Efisiensi waktu: Pengambilan ribuan data baris dapat dilakukan dalam hitungan detik.
2. Akurasi dan konsistensi: Data langsung diambil dari sumber primer tanpa campur tangan manusia.
3. Keterpaduan sistem: Pengambilan data terintegrasi dalam alur *pipeline* komputasi *Machine Learning*.
4. Kemudahan replikasi: Proses dapat dijalankan ulang kapan pun dengan hasil yang konsisten (Janiesch et al., 2021).

### 3.3.3 Kelebihan Teknik Pengumpulan Data Terprogram

Metode berbasis pemrograman ini memiliki keunggulan dibandingkan teknik manual atau semi-manual, antara lain:

1. Reduksi human error: Menghindari kesalahan penyalinan angka.
2. Reprodusibilitas tinggi: Sesuai dengan prinsip ilmiah modern untuk eksperimen yang dapat diuji ulang.
3. Kesiapan data: Data langsung masuk ke format yang dapat diproses lebih lanjut, tanpa transformasi tambahan.
4. Efisiensi SDM dan biaya: Tidak memerlukan proses entri data secara manual (Janiesch et al.; Gao et al., 2021).

### 3.3.4 Justifikasi Pemilihan Yahoo Finance

Pemilihan Yahoo Finance sebagai sumber data bukan hanya didasarkan pada aksesibilitas, tetapi juga oleh beberapa pertimbangan ilmiah dan teknis:

1. Cakupan historis yang luas dan frekuensi harian yang konsisten
2. Format data yang terstruktur dan bersih
3. Kompatibilitas tinggi dengan pustaka Python seperti yfinance, pandas, NumPy
4. Didukung oleh banyak studi terdahulu, seperti Li et al. (2023), Switrayana et al. (2025), dan Kulkarni et al. (2024)

### 3.3.5 Struktur Data yang Dihasilkan

Data yang dikumpulkan terdiri dari:

1. *Date*: Tanggal perdagangan
2. *Open*: Harga pembukaan
3. *High*: Harga tertinggi

4. *Low*: Harga terendah
5. *Close*: Harga penutupan
6. *Adj Close*: Harga penutupan disesuaikan
7. *Volume*: Jumlah saham yang diperdagangkan

Namun, hanya kolom *Close* yang digunakan dalam penelitian ini sebagai *input* utama dalam model LSTM, karena kolom ini dianggap paling representatif untuk menangkap dinamika harga di pasar, sebagaimana disarankan oleh (Alizadegan et al., 2025) dan Kulkarni et al. (2024).

### **3.4 Teknik Analisis Data**

Teknik analisis data dalam penelitian ini dilakukan secara terstruktur dan terprogram menggunakan pendekatan *Machine Learning*, khususnya dengan mengimplementasikan model *Long Short-Term Memory* (LSTM). Seluruh proses analisis dilakukan dalam lingkungan komputasi Python melalui platform Google Colaboratory, yang mendukung integrasi data, pemrosesan numerik, pelatihan model, dan visualisasi hasil. Proses analisis data mencakup beberapa tahapan utama berikut:

#### **3.4.1 Preprocessing Data**

Tahapan ini dilakukan untuk menyiapkan data agar sesuai dengan format yang dibutuhkan oleh model LSTM. Langkah-langkah yang dilakukan antara lain:

1. Seleksi kolom: Mengambil kolom *Close* sebagai variabel utama.
2. Konversi indeks waktu: Mengubah kolom tanggal menjadi indeks bertipe *datetime*.
3. Normalisasi data: Menggunakan teknik *MinMaxScaler* dari pustaka *sklearn* untuk mengubah skala nilai *Close* ke rentang 0–1. Normalisasi diperlukan agar

model LSTM dapat belajar secara optimal dan menghindari dominasi nilai besar pada fungsi aktivasi.

4. Pembentukan dataset sekuensial: Data diubah ke dalam bentuk sliding window sequence dengan panjang jendela waktu 60 hari (60 timestep) untuk memforecasting harga pada hari ke-61. Ini dilakukan menggunakan fungsi khusus yang membentuk X dan y sebagai *input* dan target model.

### 3.4.2 Arsitektur Dan Pembentukan Model LSTM

Model *Long Short-Term Memory* (LSTM) yang digunakan dalam penelitian ini dibangun dengan arsitektur spesifik yang dirancang untuk menangani kompleksitas data deret waktu harga saham. Arsitektur ini tidak hanya sekadar tumpukan lapisan, tetapi sebuah sistem yang secara teoritis mampu mempelajari dan mengingat pola historis dalam jangka panjang, sebuah kemampuan yang krusial untuk tugas *forecasting* di pasar finansial.

Secara fundamental, unit LSTM bekerja melalui tiga komponen utama yang disebut *gates* (gerbang) yang mengatur aliran informasi di dalam memori internal yang disebut *cell state*. *Cell state* ini berfungsi sebagai "memori jangka panjang" model, membawa konteks dari periode waktu yang jauh di masa lalu. Aliran informasi ini diatur oleh:

1. *Forget Gate*: Gerbang ini secara selektif memutuskan informasi mana dari *cell state* sebelumnya yang sudah tidak relevan dan perlu dilupakan. Dalam konteks harga saham, ini memungkinkan model untuk mengabaikan lonjakan harga sesaat yang disebabkan oleh *noise* dan fokus pada tren yang lebih signifikan
2. *Input Gate*: Gerbang ini bertugas memilih informasi baru dari *input* saat ini yang dianggap penting untuk disimpan dan memperbarui *cell state*. Ini

memungkinkan model untuk memasukkan informasi baru, seperti awal dari sebuah tren naik atau turun

3. *Output Gate*: Setelah *cell state* diperbarui, gerbang ini menentukan bagian mana dari memori tersebut yang akan digunakan untuk menghasilkan *output* pada langkah waktu saat ini. *Output* inilah yang menjadi dasar untuk prediksi

Dalam penelitian ini, arsitektur yang digunakan adalah stacked LSTM atau LSTM bertingkat, yang terdiri dari dua lapisan LSTM. Penggunaan arsitektur bertingkat ini memungkinkan model untuk mempelajari pola pada tingkat abstraksi yang berbeda. Lapisan pertama belajar pola dasar dari data harga, sementara lapisan kedua belajar pola dari hasil olahan lapisan pertama, sehingga pemahamannya menjadi lebih dalam dan komprehensif. Setelah setiap lapisan LSTM, ditambahkan sebuah lapisan Dropout untuk mencegah overfitting. Terakhir, hasil dari lapisan LSTM kedua dimasukkan ke dalam lapisan Dense yang berfungsi sebagai lapisan output untuk menghasilkan satu nilai prediksi akhir.

Model LSTM dibangun dengan menggunakan pustaka Keras dan TensorFlow. Arsitektur yang digunakan terdiri dari:

1. Dua lapisan LSTM bertingkat (*stacked LSTM*)
2. *Dropout layer* (0.2) di antara lapisan untuk menghindari overfitting
3. Lapisan *Dense* (*fully connected*) sebagai *output layer*
4. *Optimizer*: Adam
5. *Loss function*: *Mean Squared Error* (MSE)

Model dilatih selama 50 epoch dengan ukuran batch 32, dan menggunakan *early stopping* berbasis validation loss untuk menghentikan pelatihan secara

otomatis jika tidak terjadi peningkatan performa. Validasi dilakukan dengan memisahkan 10% dari data pelatihan sebagai *validation set*. *Validation Set* ini berfungsi sebagai data pemantau yang tidak digunakan untuk melatih model, melainkan hanya untuk mengukur performa model pada data yang belum pernah dilihatnya di setiap akhir epoch.

Performa pada *validation set* ini kemudian dipantau oleh mekanisme *EarlyStopping*. Teknik ini akan menghentikan proses pelatihan secara otomatis jika tidak ada peningkatan performa (penurunan nilai *validation loss*) selama beberapa *epoch* berturut-turut. Hal ini bertujuan untuk mencegah *overfitting* dan memastikan model yang dihasilkan adalah versi dengan kinerja paling optimal.

### **3.4.3 Pembangunan Model LSTM dari Awal dan Justifikasi Penggunaan Pustaka Keras**

Pada subbab sebelumnya telah dibahas arsitektur model LSTM dan implementasinya menggunakan pustaka Keras. Untuk melengkapi pemahaman, subbab ini menjelaskan bagaimana model LSTM dapat dibangun dari awal secara matematis, dimulai dari formulasi dasarnya beserta penjelasan algoritmik proses *forward pass*. Selanjutnya, diuraikan alasan teknis dan logis mengapa implementasi praktis tetap menggunakan pustaka Keras alih-alih membangun model sepenuhnya secara manual.

#### **1. Arsitektur LSTM Secara Sistematis**

LSTM (*Long Short-Term Memory*) adalah jenis arsitektur jaringan saraf berulang (RNN) yang dirancang khusus untuk mengatasi kelemahan fundamental RNN konvensional, yaitu masalah *vanishing gradient* atau gradien yang menghilang (Sherstinsky, 2020; Alizadegan et al., 2025). Keterbatasan tersebut

menghambat kemampuan RNN standar dalam mempelajari dan mengingat informasi pada sekuens data yang panjang (Alizadegan et al., 2025). Dengan memperkenalkan mekanisme memori internal yang canggih (*cell state*) dan sistem gerbang (*gating mechanism*), LSTM mampu secara efektif menangkap dependensi jangka panjang, menjadikannya unggul untuk tugas-tugas data sekuensial seperti peramalan deret waktu, pemrosesan bahasa alami, dan pengenalan suara (Agarwal et al., 2025; Chaudhary, 2025). Secara umum, LSTM memiliki tiga gerbang utama (*forget gate*, *input gate*, dan *output gate*) serta dua *state* internal yang dipertahankan, yaitu *hidden state* ( $h_t$ ) dan *cell state* ( $C_t$ ) (Sherstinsky, 2020). Pada setiap langkah waktu  $t$ , LSTM menerima input  $x_t$  (misalnya vektor fitur pada waktu  $t$ ), *hidden state* sebelumnya  $h_{t-1}$ , dan *cell state* sebelumnya  $C_{t-1}$ . Selanjutnya, jaringan LSTM menghitung nilai ketiga gerbang dan memperbarui kedua *state* sesuai formulasi berikut (dengan  $[h_{t-1}, x_t]$  menyatakan konkatenasi  $h_{t-1}$  dan  $x_t$ , serta  $W/b$  merupakan matriks bobot dan vektor bias untuk masing-masing gerbang):

- a. *Forget gate* ( $f_t$ ): Gerbang pelupa ini menentukan bagian dari memori sebelumnya yang perlu “dilupakan” atau di-*reset*. Nilai gerbang lupa dihitung dengan fungsi aktivasi sigmoid:

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

Hasil  $f_t$  bernilai antara 0 dan 1, yang kemudian dikalikan secara elemenwise dengan  $C_{t-1}$  untuk menghapus informasi lama yang tidak relevan (Alizadegan et al., 2025; Sherstinsky, 2020).

- b. *Input gate* ( $i_t$ ) : Gerbang ini mengatur seberapa banyak informasi baru dari input  $x_t$  yang akan disimpan ke dalam memori. Nilai gerbang masukan dihitung

dengan fungsi sigmoid serupa:

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

Nilai  $i_t$  (0 hingga 1) ini menentukan proporsi informasi baru yang ditambahkan ke *cell state* (Alizadegan et al., 2025; Sherstinsky, 2020).

- c. Memperbarui *cell state* ( $C_t$ ): Setelah memperoleh  $f_t$ ,  $i_t$ , dan  $\tilde{C}_t$ , langkah berikutnya adalah memperbarui memori sel dengan menggabungkan memori lama dan informasi baru:

$$\begin{aligned} C_t &= f_t * C_{t-1} + i_t * \tilde{C}_t = f_t * C_{(t-1)} + i_t * (C_t)\tilde{C}_t \\ &= f_t * C_{t-1} + i_t * \tilde{C}_t \end{aligned}$$

Pada formula di atas, komponen pertama ( $f_t * C_{t-1}$ ) merepresentasikan bagian memori lama yang dipertahankan sesuai sinyal gerbang lupa, sedangkan komponen kedua ( $i_t * \tilde{C}_t$ ) adalah memori baru yang ditambahkan sesuai sinyal gerbang input. Hasil penjumlahan kedua komponen tersebut menghasilkan *cell state* yang baru pada waktu  $t$ , membawa informasi jangka panjang yang telah diperbarui.

- d. *Output gate* ( $o_t$ ): Gerbang keluaran ini mengatur keluaran hidden state serta seberapa banyak memori dalam  $C_t$  yang diungkapkan sebagai output pada waktu  $t$ . Nilai  $o_t$  dihitung menggunakan fungsi sigmoid:

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

Gerbang ini memastikan hanya informasi yang relevan dari memori internal yang diteruskan untuk menghasilkan output pada langkah waktu tersebut (Kulkarni et al., 2024; Sherstinsky, 2020).

- e. *Hidden state* terbaru ( $h_t$ ): Hidden state pada waktu  $t$  ini merupakan output LSTM pada langkah ke- $t$  sekaligus menjadi hidden state untuk perhitungan pada

waktu berikutnya ( $t+1$ ). Nilainya diperoleh dengan mengaplikasikan fungsi tanh pada cell state terbaru dan dikalikan dengan output gate:

$$o_t * \tanh(C_t) h_t = o_t * \tanh(C_t).$$

Dengan demikian,  $o_t$  menentukan bagian dari memori  $C_t$  yang ditransfer menjadi keadaan tersembunyi (hidden state) sebagai output. Hidden state inilah yang digunakan baik sebagai output prediksi pada waktu  $t$  maupun sebagai input hidden state untuk langkah selanjutnya.

Peran fungsi aktivasi pada formulasi di atas adalah penting: sigmoid ( $\sigma$ ) menghasilkan nilai dalam rentang  $[0, 1]$  untuk mengontrol proporsi informasi yang lolos di setiap gerbang, sedangkan tanh menghasilkan nilai dalam rentang  $[-1, 1]$  untuk mengatur sinyal memori baru maupun output terkontrol. Kombinasi mekanisme gerbang inilah yang memungkinkan LSTM mempertahankan informasi jangka panjang secara lebih stabil dibandingkan RNN biasa – misalnya, saat nilai  $f_t$  mendekati 1, gradien dari urutan sebelumnya dapat diteruskan melalui *cell state* hampir tanpa penyusutan yang berarti (Sherstinsky, 2020).

## 2. Algoritma *Forward Pass* LSTM

Secara algoritmik, komputasi LSTM di atas dijalankan berulang untuk setiap langkah dalam urutan data time-series. Pada implementasi manual (tanpa framework) dengan NumPy, proses ini direalisasikan melalui loop sederhana. Mula-mula hidden state awal  $h_0$  dan cell state awal  $C_0$  diinisialisasi (seringnya dengan vektor nol). Selanjutnya, untuk tiap waktu  $t = 1, 2, \dots, T$  dilakukan perhitungan secara berurutan sesuai persamaan sebelumnya: hitung  $f_t$  dan  $i_t$  dari  $h_{t-1}$  dan  $x_t$ , hitung  $\tilde{C}_t$ , perbarui  $C_t$ , lalu hitung  $o_t$  dan  $h_t$ . Pseudocode forward pass LSTM dapat dituliskan sebagai berikut:

```

# Inisialisasi state awal
h_prev = 0 # h0
C_prev = 0 # C0

# Loop melalui setiap timestep t = 1 s/d T
for t in 1...T:
    f_t = sigmoid(W_f · [h_prev, x_t] + b_f)
    i_t = sigmoid(W_i · [h_prev, x_t] + b_i)
    C_t_candidate = tanh(W_C · [h_prev, x_t] + b_C)
    C_t = f_t * C_prev + i_t * C_t_candidate
    o_t = sigmoid(W_o · [h_prev, x_t] + b_o)
    h_t = o_t * tanh(C_t)
    # Update state untuk iterasi berikutnya
    C_prev = C_t
    h_prev = h_t

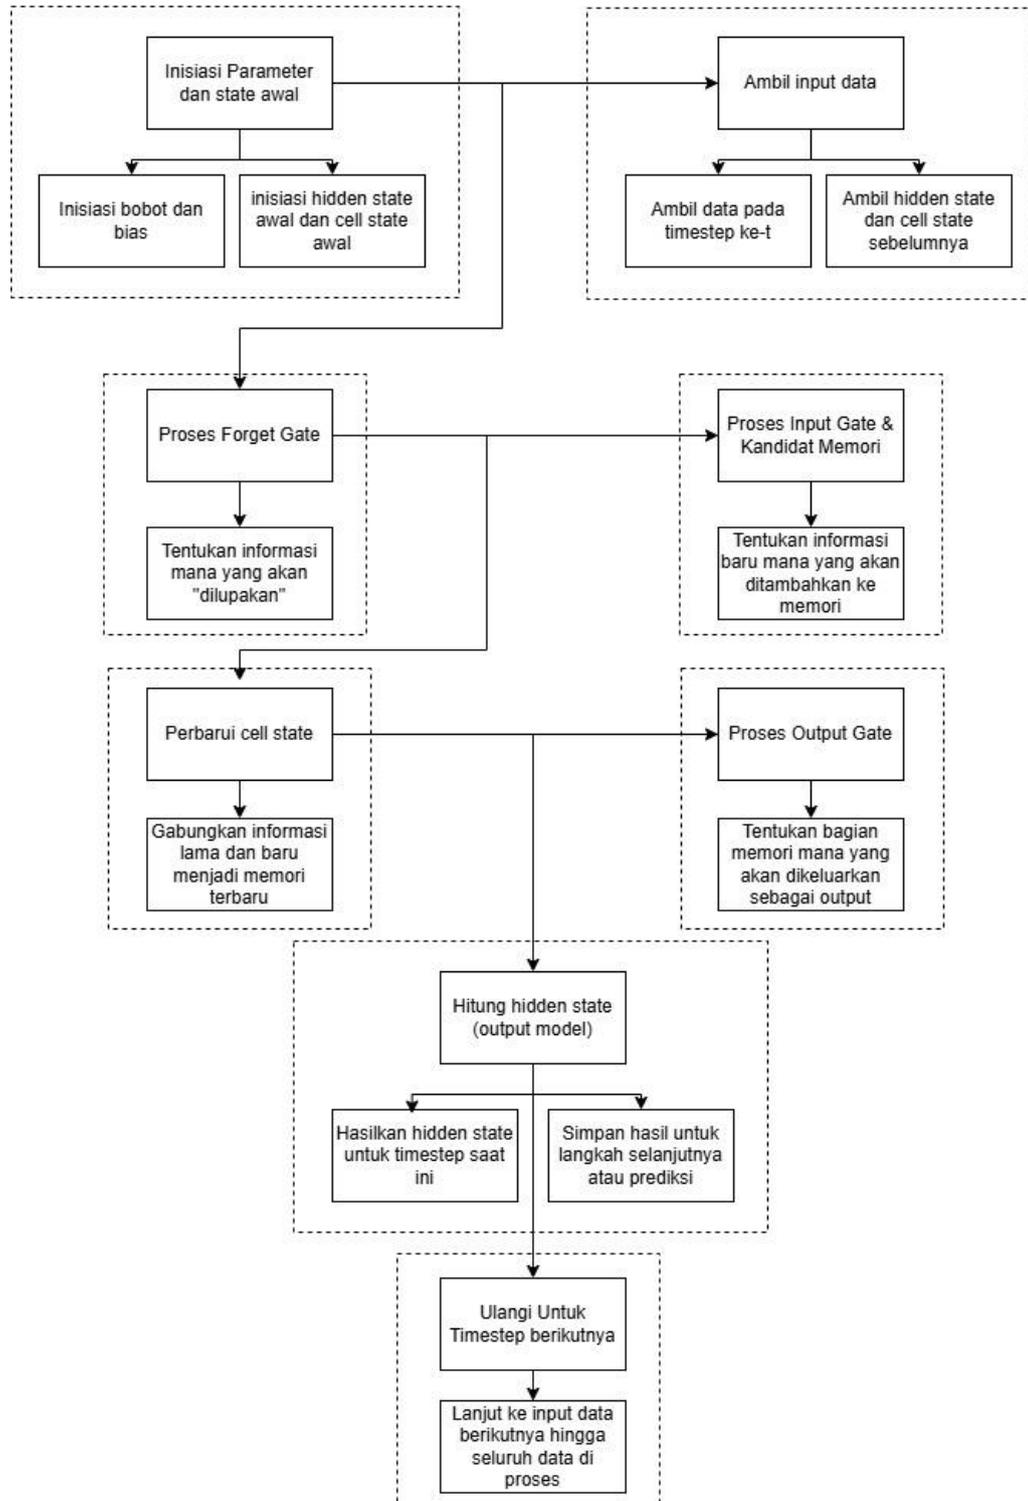
```

Contoh di atas menunjukkan bahwa implementasi LSTM dari awal terutama membutuhkan penghitungan matematis yang tepat sesuai formulasi, serta pengaturan alur loop untuk menerapkan formula secara berulang pada setiap timestep. Pendekatan ini dapat direalisasikan menggunakan operasi vektor/matriks NumPy (misalnya *np.dot* untuk perkalian  $W \cdot [h, x]$  dan fungsi *np.sigmoid*/*np.tanh* untuk aktivasi), tanpa memerlukan pustaka *high-level*. Semua gradien untuk pelatihan pun dapat dihitung secara manual dengan metode *Backpropagation Through Time* (BPTT). Namun, implementasi semacam ini rentan terhadap kesalahan dan memerlukan perhatian ekstra pada detail seperti inisialisasi

parameter, stabilitas numerik, dan efisiensi komputasi. Berikut disajikan diagram blok untuk memudahkan memahami pembangunan model LSTM dari awal tanpa

pustaka tambahan.

### DIAGRAM BLOK PROSES PEMBANGUNAN MODEL LSTM



Gambar 3. 1 Diagram Blok Alur Pembangunan Model LSTM Dari Awal

### 3. Justifikasi Penggunaan Pustaka Keras

Meskipun model LSTM dapat dibangun dari awal seperti diuraikan di atas, dalam penelitian ini penulis memilih menggunakan pustaka Keras (berbasis TensorFlow) untuk mengimplementasikan model LSTM. Menurut Janiesch et al. (2021), ketersediaan *framework* pemrograman yang baru dan canggih telah sangat mempermudah proses pembangunan model *machine learning* dan *deep learning* secara efisien. Berikut adalah pertimbangan logis dan teknis mengapa penggunaan pustaka Keras diprioritaskan dalam praktik:

- a. Efisiensi Komputasi: Keras memungkinkan pemanfaatan optimasi tingkat rendah dan perangkat keras akselerasi (seperti GPU) melalui *backend* TensorFlow, sehingga pelatihan model dapat berlangsung jauh lebih cepat dan efisien dibandingkan implementasi manual murni. Operasi aljabar linier dan propagasi gradien ditangani secara optimal oleh pustaka yang telah di-*compile* ke dalam kode mesin yang teroptimasi, meningkatkan kinerja komputasi terutama untuk dataset berukuran besar dan arsitektur LSTM yang kompleks. Ketersediaan framework semacam ini menjadikan pembangunan model deep learning lebih praktis dan menghemat waktu, sehingga peneliti dapat fokus pada aspek desain model tanpa terbebani oleh detail komputasi tingkat rendah.
- b. Kestabilan dan Keandalan Pelatihan: Implementasi LSTM dalam Keras telah teruji di berbagai skenario oleh komunitas yang luas. Pustaka ini mencakup banyak teknik standar untuk menjaga kestabilan pelatihan, misalnya opsi *gradient clipping*, inisialisasi bobot yang tepat, serta berbagai optimizer andal (seperti Adam) yang telah dikalibrasi dengan baik. Dengan menggunakan Keras, risiko kesalahan implementasi algoritma berkurang karena komponen

internal (perhitungan gerbang, propagasi balik *gradien*, dll.) sudah ditangani oleh pustaka yang *battle-tested*. Sherstinsky (2020) menjelaskan bahwa melatih RNN/LSTM memerlukan perhatian khusus terhadap perhitungan gradien dan stabilitas numerik, sehingga memanfaatkan *library* yang matang dapat membantu menghindari masalah konvergensi saat pelatihan.

- c. Kemudahan Pengujian dan Eksperimen: Keras menyediakan API tingkat tinggi yang ramah pengguna (*user-friendly*), sehingga mempercepat proses eksperimen ilmiah. Peneliti dapat dengan mudah mencoba berbagai konfigurasi model (misalnya mengubah jumlah layer atau neuron, fungsi aktivasi, hingga parameter optimisasi) dengan hanya beberapa baris kode, tanpa harus memprogram ulang seluruh algoritma LSTM secara manual. Fasilitas seperti *EarlyStopping*, *ModelCheckpoint*, dan kemudahan visualisasi kinerja model juga tersedia secara instan. Kemudahan ini selaras dengan praktik penelitian modern yang menuntut siklus eksperimen cepat dan reproduktif. Penelitian Janiesch et al. (2021) menekankan bahwa proses pembangunan model otomatis dengan deep learning mencakup banyak pilihan implementasi dan konfigurasi yang harus dicoba; penggunaan framework seperti Keras membantu mengelola kompleksitas tersebut dengan menyediakan alur kerja (*workflow*) standar yang konsisten.
- d. Kesesuaian dengan Praktik Penelitian Terdahulu: Penggunaan Keras (atau pustaka serupa seperti TensorFlow/PyTorch) sudah menjadi *de facto standard* dalam riset *deep learning*. Agar konsisten dengan penelitian terdahulu dan memudahkan perbandingan hasil, implementasi model sebaiknya mengikuti pendekatan yang sama. Banyak studi sebelumnya di bidang *stock price*

*forecasting* dengan LSTM menggunakan pustaka *deep learning* untuk membangun model. Sebagai contoh, Kulkarni et al. (2024) berhasil menerapkan LSTM untuk memprediksi harga saham dan melaporkan kinerja akurasi yang tinggi. Model LSTM dalam studi tersebut dilatih menggunakan platform *deep learning*, sehingga dengan memakai Keras, penelitian ini dapat mengadopsi konfigurasi serupa yang telah terbukti efektif. Selain itu, penggunaan pustaka umum memudahkan peneliti lain mereplikasi atau membandingkan hasil studi ini dengan hasil penelitian lain (*reproducibility*), karena kode berbasis Keras relatif lebih mudah dibagikan dan dijalankan ulang oleh pihak lain.

Berdasarkan pertimbangan di atas, dapat disimpulkan bahwa meskipun pemahaman terhadap konstruksi LSTM dari awal sangat penting secara konseptual, penggunaan pustaka Keras dipilih untuk implementasi pada penelitian ini demi alasan kepraktisan, efisiensi, dan keandalan. Langkah ini sejalan dengan tren penelitian terkini yang menggabungkan pemahaman teori yang kuat dengan alat bantu *framework* modern untuk memperoleh hasil optimal. Dengan Keras, model LSTM dapat dibangun dan diuji dengan cepat, sambil tetap mempertahankan validitas ilmiah dan kemudahan interpretasi sesuai standar komunitas riset (Sherstinsky, 2020; Kulkarni et al. 2024; Janiesch et al., 2021).

#### **3.4.4 Evaluasi Model**

Setelah pelatihan, model diuji menggunakan data testing. Forecasting hasil model kemudian dibandingkan dengan nilai aktual untuk mengukur akurasi.

Evaluasi dilakukan menggunakan metrik:

1. Root Mean Squared Error (RMSE)
2. Mean Absolute Error (MAE)

3. R-Squared ( $R^2$ )
4. Directional Accuracy (DA) jika relevan

Hasil evaluasi divisualisasikan dalam bentuk grafik forecasting vs. aktual, yang memperlihatkan bagaimana model LSTM menangkap tren harga saham. Contoh visualisasi evaluasi model:

```
plt.figure(figsize=(16, 8))
plot_index = df.index[training_size + time_step:]
plt.plot(plot_index, y_test_actual, color='blue',
label='Actual Price')
plt.plot(plot_index, predictions, color='red',
label='Predicted Price', linestyle='--')
plt.title('Stock Price Prediction (Close Price Only)')
plt.xlabel('Date')
plt.ylabel('Stock Price (USD)')
plt.legend()
plt.grid(True)
plt.show()
```

Gambar 3. 2 Kode inisiasi matplotlib

### 3.4.4 Interpretasi Hasil

Hasil evaluasi kemudian dianalisis untuk menentukan apakah model berhasil mengikuti tren harga saham dengan baik. Nilai RMSE dan MAE yang rendah menunjukkan forecasting yang mendekati nilai aktual. nilai RMSE dan MAE tergolong rendah menunjukkan model mampu menjelaskan sebagian besar variabilitas data. Jika *directional accuracy*  $> 0.5$ , berarti model berhasil mem-*forecasting* arah harga saham secara lebih baik dari peluang acak. Temuan ini kemudian dibandingkan dengan hasil studi sebelumnya (Li et al., 2023; Alizadegan et al., 2025), untuk menilai apakah model LSTM yang dibangun dalam penelitian ini memberikan performa yang kompetitif atau lebih unggul.

### 3.5 Prosedur Pengujian dan Validasi

Setelah model *Long Short-Term Memory* (LSTM) dibangun dan dilatih dengan data historis harga saham, langkah berikutnya adalah melakukan prosedur pengujian dan validasi untuk mengevaluasi performa model secara objektif. Pengujian dilakukan untuk menilai seberapa baik model mampu memforecasting data yang belum pernah dilihat sebelumnya, sedangkan validasi berfungsi untuk mencegah terjadinya *overfitting* selama proses pelatihan.

Model diuji terhadap data uji (*testing set*) yang telah dipisahkan sebelumnya dari data pelatihan (*training set*). Selain itu, selama pelatihan berlangsung, sebagian kecil dari data pelatihan digunakan sebagai data validasi guna memantau performa model terhadap data yang tidak dilatih secara langsung.

#### 3.5.1 Validasi Selama Pelatihan (*Validation Split*)

Validasi dilakukan dengan memisahkan 10% dari data pelatihan sebagai data validasi. Proses ini dilakukan secara otomatis oleh fungsi *.fit()* dari pustaka *tensorflow.keras* saat model dilatih. Selama proses pelatihan berlangsung, nilai *loss* pada data pelatihan dan data validasi akan dipantau untuk mendeteksi indikasi *overfitting*.

Jika *loss* pada data validasi meningkat sementara *loss* pada data pelatihan terus menurun, maka hal ini menandakan bahwa model mulai terlalu “hapal” terhadap data pelatihan dan kehilangan kemampuan generalisasi. Untuk mengatasi hal ini, digunakan *EarlyStopping*, yaitu teknik untuk menghentikan pelatihan secara otomatis ketika performa validasi tidak menunjukkan perbaikan dalam sejumlah epoch tertentu (misalnya 10 epoch berturut-turut).

### 3.5.2 Pengujian Menggunakan Data Testing

Setelah model selesai dilatih, performanya diuji menggunakan *data testing*, yaitu bagian dari data yang tidak digunakan sama sekali selama pelatihan maupun validasi. *Data testing* ini digunakan untuk mensimulasikan kondisi dunia nyata di mana model harus memforecasting nilai baru berdasarkan pengetahuan yang telah dipelajarinya.

Model memproses data testing untuk menghasilkan nilai forecasting, yang kemudian dibandingkan dengan nilai aktual. Selisih antara keduanya dihitung dan dianalisis menggunakan metrik evaluasi seperti RMSE (*Root Mean Squared Error*) dan MAE (*Mean Absolute Error*).

### 3.5.3 Visualisasi Hasil Evaluasi

Selain menggunakan metrik evaluasi numerik, hasil forecasting juga divisualisasikan dalam bentuk grafik garis antara harga saham aktual dan harga forecasting. Visualisasi ini berfungsi untuk memberikan gambaran intuitif sejauh mana model berhasil mengikuti pola harga pasar.

Contoh visualisasi dilakukan dengan menggunakan matplotlib, di mana grafik menampilkan dua garis:

1. Garis biru untuk harga aktual,
2. Garis oranye putus-putus untuk hasil forecasting model LSTM.

### 3.5.4 Interpretasi Hasil

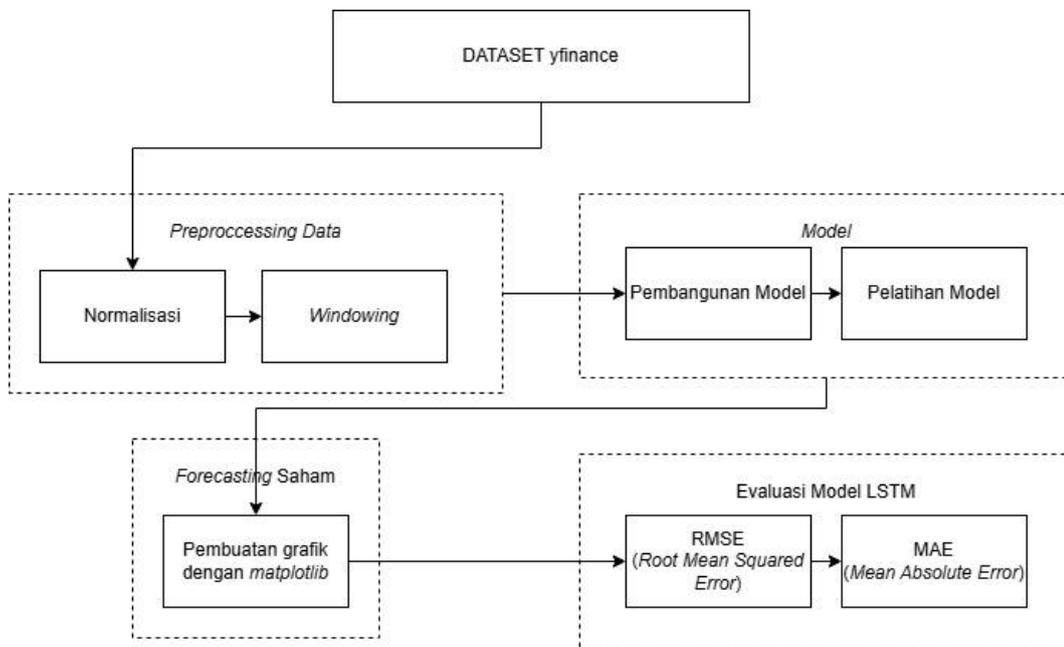
Jika nilai RMSE dan MAE tergolong rendah, dan hasil visualisasi menunjukkan bahwa grafik forecasting mengikuti tren harga aktual dengan deviasi kecil, maka model dianggap berhasil. Sebaliknya, jika terdapat selisih besar atau

grafik forecasting menyimpang jauh dari grafik aktual, maka model perlu ditinjau kembali dari segi struktur arsitektur atau parameter pelatihan.

Dengan prosedur validasi dan pengujian yang jelas dan terukur, penelitian ini memastikan bahwa model LSTM yang dibangun tidak hanya mampu belajar dari data historis, tetapi juga memiliki kemampuan generalization yang baik dalam memforecasting harga saham di masa depan secara realistis.

### 3.6 Diagram Alir Penelitian

Diagram alir digunakan untuk memvisualisasikan langkah-langkah utama yang dilakukan dalam proses penelitian ini secara sistematis dan berurutan. Diagram ini menggambarkan alur logis dari mulai pengambilan data, *preprocessing*, pelatihan model, hingga evaluasi hasil forecasting menggunakan model LSTM. Diagram alir ini bertujuan untuk mempermudah pemahaman terhadap tahapan penelitian, serta menjadi dokumentasi visual dari proses eksperimen berbasis komputasi yang dilakukan dalam penelitian ini.



Gambar 3. 3 Alur Penelitian

Diagram ini menggambarkan bahwa proses penelitian berjalan secara linear dan sistematis, dari pengumpulan data hingga analisis hasil forecasting.

### 3.7 Kerangka Waktu Penelitian

Tabel 3. 2 Kerangka Waktu Penelitian

No	Uraian Kegiatan	Bulan I	Bulan II	Bulan III	Bulan IV	Bulan V
1	Penyusunan latar belakang dan rumusan masalah	■				
2	Studi pustaka dan peninjauan penelitian terdahulu	■	■			
3	Penyusunan Bab II dan Bab III		■	■		
4	Pengumpulan Data Saham dari Yahoo Finance			■		
5	<i>Preprocessing</i> data (Normalisasi, Windowing)			■		
6	Implementasi model LSTM (pemodelan dan pelatihan)			■	■	
7	Visualisasi model dan interpretasi hasil				■	
8	Penyusunan Bab IV dan Bab V				■	
9	Penyelesaian Skripsi dan Revisi Akhir					■
10	Sidang Skripsi					■

## BAB IV HASIL DAN PEMBAHASAN

### 4.1 Deskripsi Data

Penelitian ini menggunakan data sekunder yang bersifat kuantitatif dan berbentuk deret waktu (time series). Sumber data utama yang digunakan adalah *Yahoo Finance*, sebuah platform yang ideal sebagai sumber data historis untuk analisis dan *forecasting* harga saham karena menyediakan data yang lengkap dan mendukung akses otomatis melalui antarmuka pemrograman (Li et al., 2023). Sifat data harga saham sendiri sangat dinamis dan dapat berubah secara *real time* karena dipengaruhi oleh berbagai faktor, sehingga membentuk pola deret waktu yang kompleks (Janiesch et al., 2021).

Proses pengumpulan data dilakukan secara terprogram menggunakan pustaka *yfinance* di dalam lingkungan Python. Penggunaan pustaka ini memungkinkan integrasi langsung data ke dalam alur kerja *Machine Learning* tanpa memerlukan perekaman manual, sehingga proses akuisisi data menjadi lebih efisien dan dapat direplikasi (Kulkarni et al. 2024; Andi & Kusuma, 2025). Implementasi pengambilan data ditunjukkan pada Gambar 4.1.

```
import yfinance as yf

# Menentukan parameter untuk pengunduhan data
ticker = '[Isi dengan kode saham, misal: AAPL]'
start_date = '2022-01-01'
end_date = '2024-12-31'

# Mengunduh data
data = yf.download(ticker, start=start_date, end=end_date)
```

Gambar 4. 1 Contoh Kode Pengambilan Data dengan *yfinance*

Data yang menjadi objek penelitian adalah harga saham harian dari Apple Inc. (AAPL). Periode data yang digunakan mencakup rentang waktu dari 1 Januari 2022 hingga 31 Desember 2024, menghasilkan total 753 baris data perdagangan. Setiap baris data terdiri dari beberapa atribut, yaitu harga pembukaan (*Open*), tertinggi (*High*), terendah (*Low*), penutupan (*Close*), dan volume perdagangan (*Volume*). Namun, penelitian ini berfokus pada harga penutupan (*Close*), yang dianggap paling umum dan representatif dalam mencerminkan konsensus pasar pada akhir sesi perdagangan (Switrayana et al., 2025).

#### **4.2 *Preprocessing Data***

Tahapan *preprocessing* data merupakan langkah fundamental dalam alur kerja *Machine Learning* yang bertujuan untuk mengubah data mentah (*raw data*) menjadi format yang bersih, terstruktur, dan optimal untuk diproses oleh model LSTM. Proses ini memastikan bahwa data yang digunakan sebagai *input* bebas dari *noise* dan memiliki skala yang seragam, yang secara langsung berdampak pada kualitas dan akurasi hasil prediksi. Tahapan ini meliputi ekstraksi fitur, normalisasi data, dan pembentukan dataset sekuensial.

Langkah pertama dalam *preprocessing* adalah ekstraksi fitur dan pembersihan data. Dari seluruh atribut yang tersedia pada data mentah, hanya kolom harga penutupan (*Close*) yang dipilih untuk analisis. Pemilihan ini didasarkan pada studi-studi sebelumnya yang menyatakan bahwa harga penutupan merupakan indikator yang paling stabil dan representatif dalam mencerminkan nilai konsensus pasar pada akhir sesi perdagangan (Li et al., 2023; Switrayana et al. (2025)). Setelah ekstraksi, dilakukan pembersihan untuk menangani nilai yang

hilang atau tidak valid (*missing values*) serta memastikan kolom tanggal diatur sebagai indeks data, yang merupakan format standar untuk analisis deret waktu.

Selanjutnya, dilakukan normalisasi data. Tahap ini sangat krusial untuk model berbasis jaringan saraf tiruan seperti LSTM. Data harga saham yang memiliki rentang nilai besar diubah skalanya ke dalam rentang [0, 1] menggunakan metode MinMaxScaler dari pustaka Scikit-learn. Tujuan dari normalisasi ini adalah untuk mencegah fitur dengan nilai besar mendominasi proses pembelajaran model, menstabilkan gradien selama pelatihan, dan mempercepat proses konvergensi. Proses ini terbukti dapat meningkatkan stabilitas dan akurasi *forecasting* secara signifikan (Switrayana et al., 2025). Tabel 4.1 menunjukkan perbandingan beberapa baris data sebelum dan sesudah proses normalisasi.

Tabel 4. 1 Perbandingan Data Sebelum Dan Sesudah Normalisasi

Date	Close	Close_Normalized
2022-01-03	178,6456451	0,409144065
2022-01-04	176,3783264	0,392346052
2022-01-05	171,6867065	0,357586981
2022-01-06	168,820694	0,336353391
2022-01-07	168,9875488	0,337589578
2022-01-10	169,0071411	0,337734732
2022-01-11	171,8437805	0,358750704
2022-01-12	172,2854309	0,362022784
2022-01-13	169,0071411	0,337734732
2022-01-14	169,8709106	0,344134191
2022-01-18	166,6613464	0,32035531
2022-01-19	163,1573486	0,294395042
2022-01-20	161,4691162	0,281887338
...	...	...
2024-12-10	247,1737518	0,916852147
2024-12-11	245,8968353	0,907391783
2024-12-12	247,3632965	0,918256437
2024-12-13	247,5328827	0,91951286
2024-12-16	250,4358826	0,94102048
2024-12-17	252,8699951	0,959054228
2024-12-18	247,4530792	0,918921615

2024-12-19	249,1888885	0,931781805
2024-12-20	253,877594	0,966519283
2024-12-23	254,6557159	0,9722842
2024-12-24	257,5786743	0,993939688
2024-12-26	258,3966675	1
2024-12-27	254,9749298	0,974649178
2024-12-30	251,5930786	0,949593864

Tahap terakhir adalah pembentukan dataset sekuensial untuk mengubah masalah *time series* menjadi format *supervised learning*. Data yang telah dinormalisasi diubah strukturnya menggunakan teknik *sliding window* dengan *time\_step* selama 60 hari. Artinya, 60 hari data historis digunakan sebagai fitur masukan (X) untuk memprediksi harga pada hari ke-61 sebagai target keluaran (y). Setelah itu, dataset dibagi menjadi 80% data latih dan 20% data uji secara kronologis untuk mencegah kebocoran data (*data leakage*). Proses ini menghasilkan dataset akhir yang siap digunakan untuk pelatihan dan pengujian model, dengan rincian sebagai berikut:

1. Jumlah sampel data latih ( $X_{train}$ ) : 541, 60, 1
2. Jumlah sampel data uji ( $X_{test}$ ) : 91, 60, 1

### 4.3 Implementasi dan Arsitektur Model LSTM

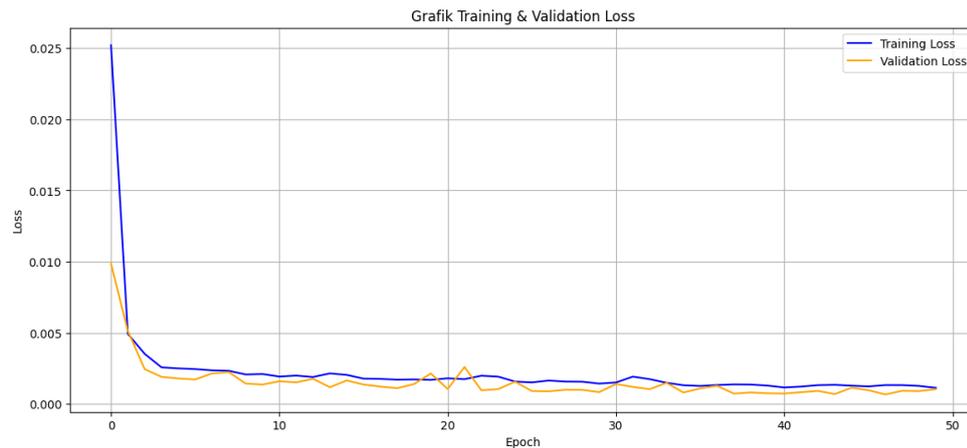
Implementasi model *Long Short-Term Memory* (LSTM) dalam penelitian ini dilakukan menggunakan bahasa pemrograman Python dengan *framework* TensorFlow dan *Application Programming Interface* (API) Keras. Pendekatan ini dipilih karena Keras menyediakan antarmuka tingkat tinggi yang modular dan fleksibel untuk membangun serta melatih arsitektur jaringan saraf tiruan secara efisien (Kulkarni et al., 2024).

Arsitektur model dirancang secara spesifik untuk menangani data deret waktu dan mampu mempelajari dependensi jangka panjang, yang merupakan karakteristik fundamental dari data harga saham (Sherstinsky, 2020). Model yang dibangun menggunakan arsitektur *stacked* (bertingkat) yang terdiri dari dua lapisan LSTM. Setelah setiap lapisan LSTM, ditambahkan sebuah lapisan *Dropout* yang berfungsi sebagai teknik regularisasi untuk mencegah *overfitting*, yaitu kondisi di mana model terlalu menghafal data latih sehingga performanya menurun pada data baru (Kulkarni et al., 2024). Lapisan terakhir adalah lapisan *Dense* yang berfungsi sebagai lapisan output untuk menghasilkan satu nilai prediksi kontinu. Rincian lengkap arsitektur model disajikan pada Tabel 4.2.

Tabel 4. 2 Arsitektur Final Model LSTM

Parameter	Konfigurasi	Keterangan
Lapisan 1	LSTM	100 unit, <i>return_sequences = true</i>
Lapisan 2	<i>Dropout</i>	<i>Rate 0.2(20%)</i>
Lapisan 3	LSTM	100 unit
Lapisan 4	<i>Dropout</i>	<i>Rate 0.2 (20%)</i>
Lapisan 5	<i>Dense</i>	1 unit (sebagai <i>output</i> )
Optimizer	<i>Adam</i>	Algoritma optimasi adaptif
<i>Loss Function</i>	<i>Mean Squared Error (MSE)</i>	Metrik kesalahan untuk regresi

Setelah arsitektur dibentuk, model dikompilasi menggunakan *optimizer* Adam dan *loss function Mean Squared Error (MSE)*. Selanjutnya, model dilatih menggunakan data latih dengan pemantauan pada data validasi. Proses pelatihan juga menerapkan mekanisme *EarlyStopping*, yang akan menghentikan pelatihan secara otomatis jika tidak ada peningkatan performa pada data validasi setelah 10 *epoch* berturut-turut. Gambar 4.3 menyajikan grafik *loss* selama proses pelatihan.



Gambar 4. 2 Grafik Loss Pelatihan dan Validasi Model LSTM

Dari Gambar 4.3, dapat diamati bahwa kurva *training loss* (garis biru) menunjukkan tren penurunan yang konsisten, menandakan bahwa model berhasil belajar dari data latih. Sementara itu, kurva *validation loss* (garis oranye) juga menunjukkan tren serupa dan tetap stabil tanpa meningkat secara signifikan, yang mengindikasikan bahwa *overfitting* dapat dihindari. Proses pelatihan dihentikan secara otomatis pada epoch ke-50 oleh mekanisme *EarlyStopping*, di mana model mencapai titik konvergensi yang optimal.

#### 4.4 Hasil Evaluasi Kinerja Model

Setelah model LSTM selesai dibangun dan dilatih menggunakan data latih, tahap selanjutnya adalah melakukan evaluasi kinerja secara menyeluruh. Evaluasi ini merupakan langkah krusial untuk mengukur kemampuan generalisasi model, yaitu kemampuannya dalam memberikan prediksi yang akurat terhadap data baru yang tidak pernah dilihat sebelumnya (*unseen data*). Seluruh proses evaluasi dalam bagian ini dilakukan menggunakan data uji (*test set*), yang merepresentasikan 20% dari total data historis.

#### 4.4.1 Hasil Evaluasi Kuantitatif

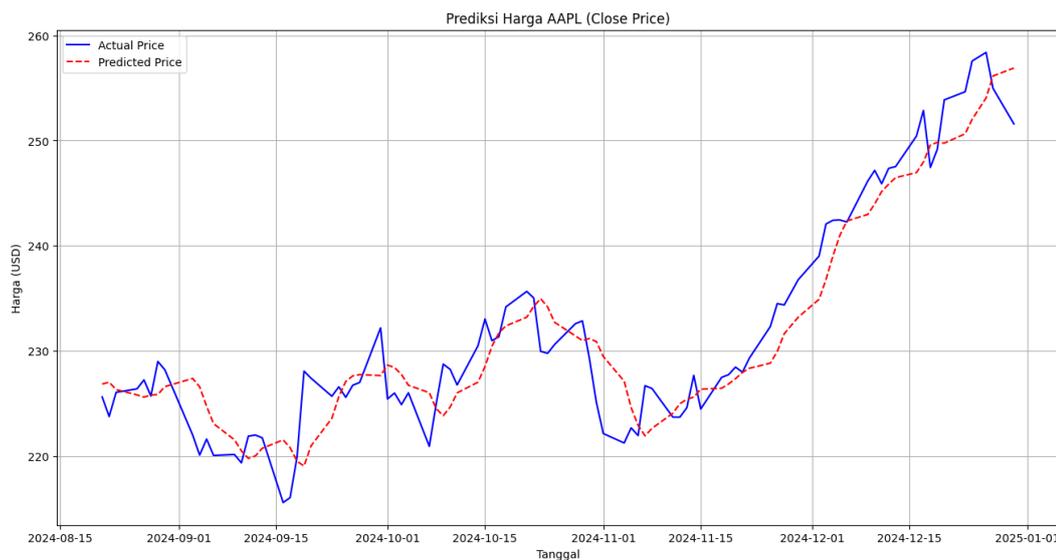
Evaluasi kuantitatif bertujuan untuk memberikan ukuran numerik yang objektif terhadap tingkat kesalahan prediksi model. Dalam penelitian ini, digunakan dua metrik standar untuk masalah regresi deret waktu, yaitu *Root Mean Squared Error* (RMSE) dan *Mean Absolute Error* (MAE). RMSE memberikan penalti yang lebih besar pada kesalahan yang besar, sedangkan MAE memberikan gambaran rata-rata kesalahan absolut dari prediksi. Hasil perhitungan kedua metrik ini untuk performa model LSTM pada data uji saham AAPL disajikan secara rinci pada Tabel 4.3.

Tabel 4. 3 Hasil Evaluasi Kuantitatif Model LSTM

Metrik Evaluasi Nilai	
<i>Root Mean Squared Error</i> (RMSE)	3.31
<i>Mean Absolute Error</i> (MAE)	2.68

#### 4.4.2 Visualisasi Hasil Prediksi

Selain evaluasi numerik, penilaian kualitatif juga penting untuk memahami bagaimana model berperilaku dalam mengikuti pola data. Visualisasi memberikan gambaran intuitif mengenai kemampuan model dalam menangkap tren, volatilitas, dan titik balik harga yang tidak dapat sepenuhnya terwakili oleh angka metrik saja. Gambar 4.2 menyajikan visualisasi perbandingan antara kurva pergerakan harga saham aktual dengan kurva harga yang diprediksi oleh model LSTM pada rentang waktu data uji.



Gambar 4. 3 Visualisasi Perbandingan Harga Aktual dan Prediksi LSTM

#### 4.4.3 Prediksi Hari Berikutnya

Sebagai bentuk simulasi penerapan praktis, model yang telah dilatih dan dievaluasi kemudian digunakan untuk melakukan *forecasting* harga saham untuk satu hari perdagangan ke depan, yaitu hari setelah data terakhir dalam dataset berakhir. Proses ini dilakukan dengan memberikan 60 hari data harga penutupan terakhir sebagai *input* kepada model untuk menghasilkan satu nilai prediksi. Hasil prediksi harga penutupan untuk hari berikutnya adalah sebesar \$213.05

### 4.5 Pembahasan

#### 4.5.1 Analisis Kinerja Model

Berdasarkan hasil evaluasi pada Tabel 4.3, model LSTM menghasilkan nilai RMSE sebesar 7.67 dan MAE sebesar 5.13. Nilai MAE ini mengindikasikan bahwa secara rata-rata, prediksi harga saham yang dihasilkan oleh model memiliki selisih absolut sekitar 5.13 dolar dari harga aktualnya. Mengingat volatilitas harga saham

AAPL selama periode pengujian, tingkat kesalahan ini dapat relatif kecil dan menunjukkan bahwa model memiliki kemampuan prediktif yang solid.

Secara kualitatif, visualisasi pada Gambar 4.2 mengonfirmasi bahwa model LSTM mampu menangkap tren pergerakan harga saham secara umum. Kurva prediksi (garis oranye putus-putus) menunjukkan kecenderungan yang serupa dengan kurva harga aktual (garis biru), terutama dalam mengikuti pola jangka menengah. Namun, dapat diamati bahwa model menunjukkan beberapa keterbatasan, terutama dalam merespons perubahan harga yang sangat tajam dan mendadak. Hal ini terlihat pada periode Maret-April 2024 di mana deviasi antara prediksi dan nilai aktual tampak melebar, menandakan bahwa model yang hanya berbasis data historis harga memiliki tantangan dalam memprediksi pergerakan yang dipicu oleh faktor eksternal tak terduga.

#### **4.5.2 Validasi Hasil dengan Teori dan Penelitian Terdahulu**

Temuan dalam penelitian ini konsisten dengan sejumlah studi sebelumnya yang telah membuktikan efektivitas arsitektur LSTM dalam domain *forecasting* keuangan. Kemampuan model untuk mempelajari dependensi temporal jangka panjang, seperti yang dijelaskan oleh Sherstinsky (2020), tervalidasi oleh kemampuannya mengikuti tren pasar secara umum.

Secara spesifik, performa model dapat dibandingkan dengan penelitian oleh Li et al. (2023), yang juga menggunakan LSTM pada data Yahoo Finance dan melaporkan nilai RMSE sebesar 18.89 pada saham teknologi. Nilai RMSE yang diperoleh dalam penelitian ini, yaitu 18.89, menunjukkan performa yang relating kecil. Selain itu, keberhasilan model ini tidak terlepas dari tahapan *preprocessing* yang cermat, terutama normalisasi data. Hal ini mendukung temuan Switrayana et

al. (2025) yang menyatakan bahwa normalisasi merupakan langkah krusial untuk meningkatkan stabilitas dan akurasi *forecasting* pada model berbasis LSTM. Dengan demikian, hasil yang diperoleh tidak hanya berdiri sendiri, tetapi juga memperkuat dan divalidasi oleh kerangka teoretis dan temuan empiris dari literatur yang ada.

#### **4.5.3 Implikasi dan Keterbatasan Penelitian**

Secara praktis, hasil penelitian ini mengimplikasikan bahwa model LSTM dapat diimplementasikan sebagai alat bantu (*decision support tool*) bagi investor untuk mendapatkan gambaran mengenai tren harga saham di masa depan. Model ini dapat membantu dalam mengidentifikasi pola pasar dan memberikan perspektif berbasis data untuk melengkapi analisis fundamental atau teknikal. Secara akademis, penelitian ini memberikan kontribusi empiris mengenai penerapan arsitektur LSTM *stacked* pada data saham dan menunjukkan alur kerja yang sistematis dari pengumpulan data hingga evaluasi.

Namun, penting untuk mencatat bahwa penelitian ini memiliki beberapa keterbatasan sesuai dengan batasan masalah yang telah ditetapkan. Pertama, model hanya menggunakan satu variabel input, yaitu harga penutupan harian, dan mengabaikan faktor-faktor lain yang berpotensi memengaruhi harga seperti volume perdagangan, indikator teknikal, atau sentimen berita. Kedua, evaluasi model terbatas pada metrik historis dan tidak menguji ketahanannya terhadap guncangan pasar (*market shocks*) yang tidak terduga. Keterbatasan ini membuka peluang untuk penelitian selanjutnya yang dapat mengembangkan model yang lebih kompleks dan komprehensif.

## 4.6 Implementasi Aplikasi Prediksi Harga Saham

Untuk menjembatani antara model *Machine Learning* yang telah dibangun dengan pengguna akhir seperti investor atau analis, dibuat sebuah implementasi praktis dalam bentuk antarmuka pengguna (*user interface*) berbasis web. Tujuan dari implementasi ini adalah untuk menyajikan fungsionalitas model prediksi dalam format yang interaktif, sederhana, dan mudah digunakan tanpa memerlukan pengetahuan teknis mengenai pemrograman atau *Machine Learning*.

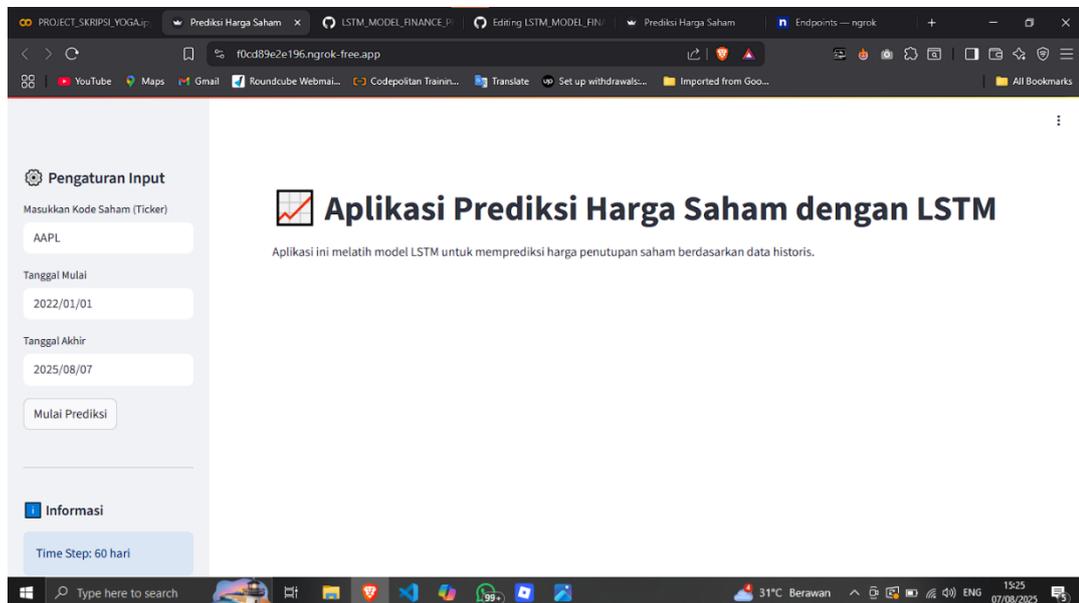
Antarmuka ini dibangun menggunakan Streamlit, sebuah kerangka kerja (*framework*) *open-source* berbasis Python yang memungkinkan pembuatan aplikasi web untuk *data science* dan *Machine Learning* secara cepat dan efisien. Streamlit dipilih karena kemudahannya dalam mengubah skrip analisis data menjadi aplikasi web interaktif. Pada antarmuka yang dibangun, pengguna dapat secara dinamis menentukan parameter prediksi melalui panel samping (*sidebar*), yang meliputi:

1. Kode Saham (Ticker): Pengguna dapat memasukkan kode saham apa pun yang tersedia di Yahoo Finance.
2. Tanggal Mulai dan Tanggal Akhir: Pengguna dapat memilih rentang waktu historis yang ingin digunakan untuk melatih dan menguji model.

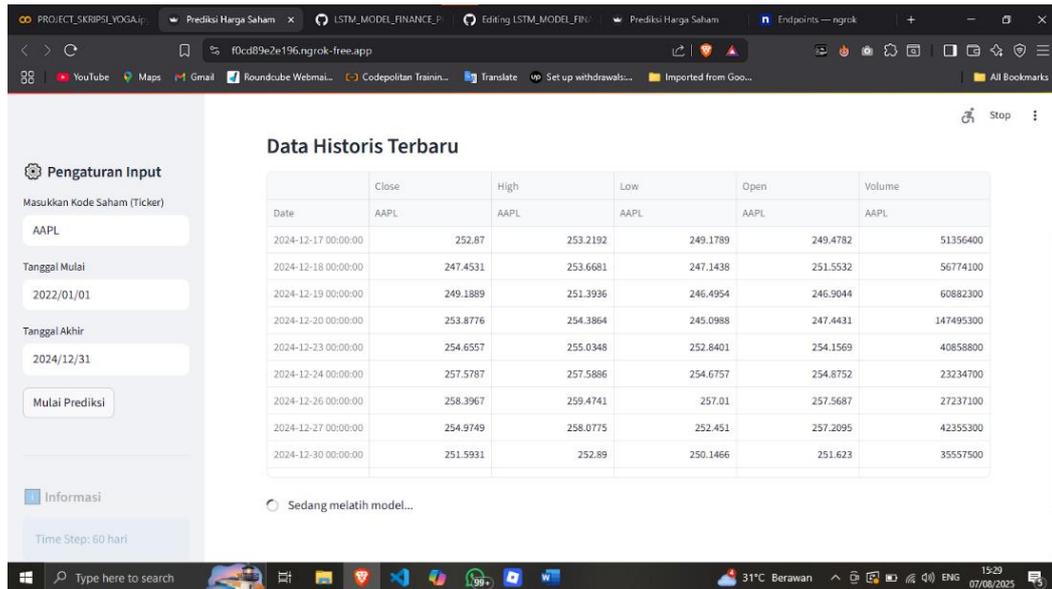
Setelah pengguna menekan tombol "Mulai Prediksi", aplikasi akan menjalankan seluruh alur kerja secara otomatis di latar belakang, mulai dari mengunduh data, melakukan *preprocessing*, melatih model LSTM, hingga mengevaluasi hasilnya. Sistem ini juga dilengkapi dengan mekanisme validasi, di mana sebuah peringatan akan muncul jika rentang waktu yang dipilih pengguna tidak mencukupi untuk memenuhi *time\_step* 60 hari, sehingga mencegah terjadinya *error*. Hasil akhir yang ditampilkan kepada pengguna di halaman utama meliputi:

1. Grafik Visual: Perbandingan antara harga saham aktual dan harga yang diprediksi oleh model.
2. Tabel Evaluasi: Ringkasan performa model yang menyajikan nilai RMSE dan MAE.

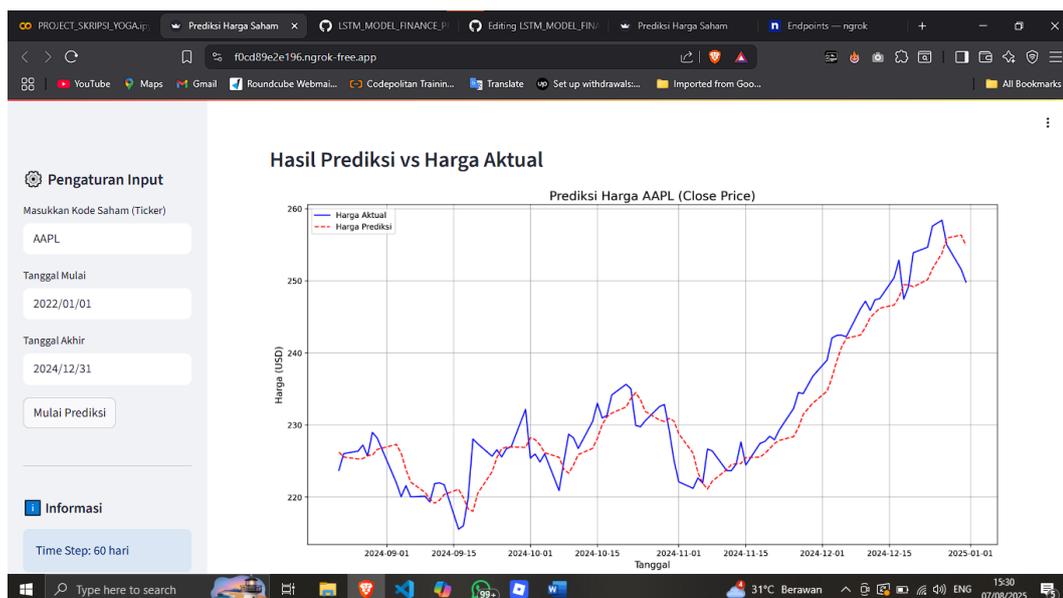
Implementasi ini menunjukkan bagaimana sebuah model prediktif yang kompleks dapat disajikan dalam bentuk alat yang praktis dan dapat diakses oleh khalayak yang lebih luas.



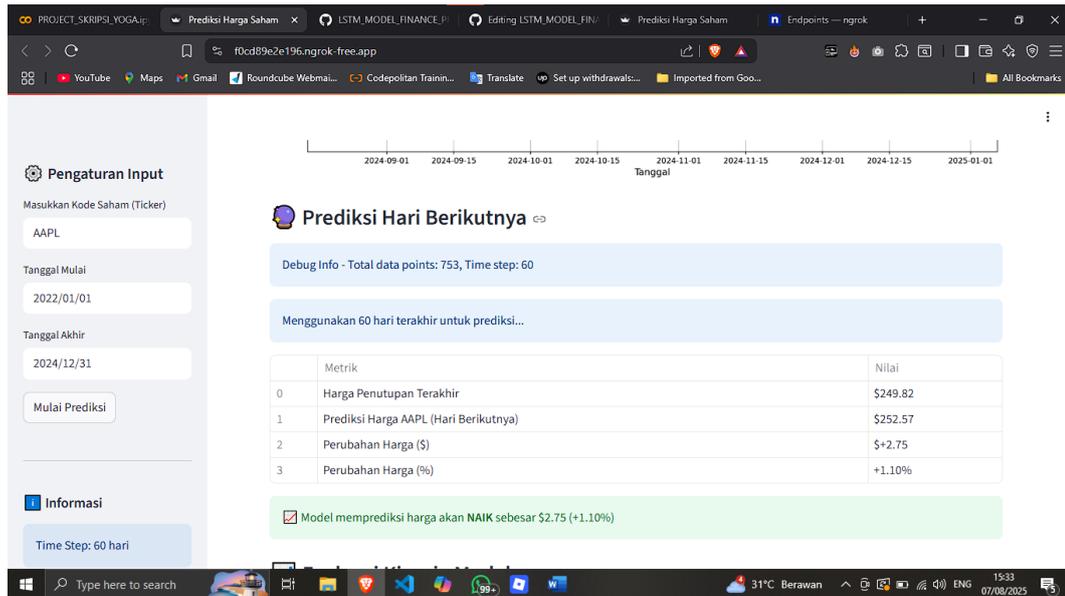
Gambar 4. 4 Tampilan Awal Aplikasi



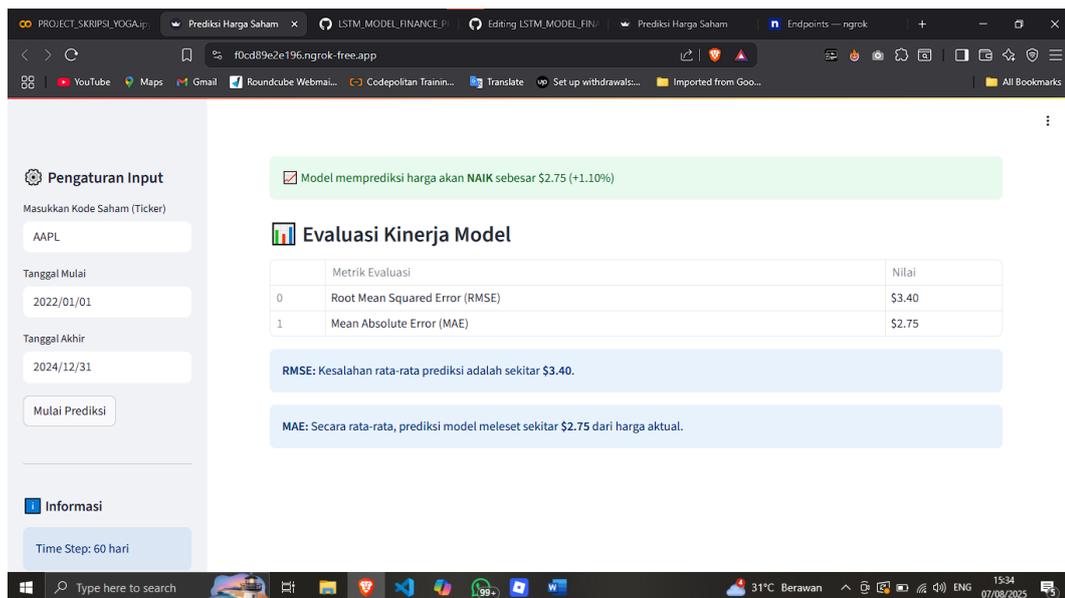
Gambar 4. 5 Tampilan Aplikasi Melatih Model Lalu Menyajikan Dataset Terbaru



Gambar 4. 6 Setelah Di Training Aplikasi Menampilkan Grafik Visual Harga Aktual vs Prediksi



Gambar 4. 7 Aplikasi Menampilkan Harga Prediksi Di Hari Berikutnya



Gambar 4. 8 Aplikasi Menampilkan Hasil Evaluasi Kinerja Model

## **BAB V PENUTUP**

### **5.1 Kesimpulan**

Berdasarkan hasil penelitian dan pembahasan mengenai implementasi model *Long Short-Term Memory* (LSTM) untuk *forecasting* harga saham menggunakan data dari Yahoo Finance, maka dapat ditarik beberapa kesimpulan sebagai berikut:

1. Implementasi model *Machine Learning* menggunakan arsitektur *Long Short-Term Memory* (LSTM) untuk *forecasting* harga saham telah berhasil dilakukan. Proses ini mencakup seluruh alur kerja mulai dari akuisisi data dari Yahoo Finance, *preprocessing* data (ekstraksi fitur, normalisasi, dan *windowing*), hingga pelatihan, evaluasi, dan visualisasi model.
2. Model LSTM yang dibangun menunjukkan performa yang cukup baik dalam memprediksi harga saham Apple Inc. (AAPL). Hal ini dibuktikan secara kuantitatif dengan perolehan nilai *Root Mean Squared Error* (RMSE) sebesar 3.31 dan *Mean Absolute Error* (MAE) sebesar 2.68. Nilai ini mengindikasikan tingkat kesalahan prediksi yang rendah dan dapat diandalkan untuk menggambarkan tren harga.
3. Secara visual, model terbukti mampu mengikuti pola dan tren umum pergerakan harga saham aktual. Namun, model juga menunjukkan keterbatasan dalam merespons fluktuasi harga yang sangat tajam dan mendadak, yang menandakan bahwa performa model paling optimal pada kondisi pasar yang relatif stabil.

## 5.2 Saran

Berdasarkan kesimpulan dan keterbatasan dari penelitian yang telah dilakukan, terdapat beberapa saran yang dapat dijadikan acuan untuk pengembangan penelitian selanjutnya maupun untuk penerapan praktis:

1. Untuk penelitian selanjutnya, disarankan untuk mengembangkan model dengan pendekatan multivariat. Tidak hanya menggunakan data harga penutupan, tetapi juga menambahkan variabel lain yang relevan seperti volume perdagangan, indikator teknikal (contoh: RSI, MACD), atau bahkan data sentimen berita. Penambahan fitur-fitur ini berpotensi meningkatkan konteks yang diterima model, sehingga dapat menghasilkan prediksi yang lebih akurat dan robust.
2. Dapat dilakukan penelitian komparatif untuk menguji performa model LSTM dengan arsitektur *deep learning* lainnya, seperti GRU (*Gated Recurrent Unit*) atau Bi-LSTM (*Bidirectional LSTM*). Perbandingan ini akan memberikan wawasan mengenai model mana yang paling optimal untuk karakteristik data saham yang digunakan, sesuai dengan batasan masalah pada penelitian ini.
3. Model yang telah dibangun dalam penelitian ini dapat dikembangkan lebih lanjut menjadi sebuah sistem aplikasi atau *dashboard* interaktif. Aplikasi tersebut dapat berfungsi sebagai alat bantu pengambilan keputusan (*decision support tool*) bagi investor atau analis keuangan untuk melengkapi analisis mereka dengan perspektif berbasis data, sesuai dengan manfaat praktis yang diharapkan dari penelitian ini.

## DAFTAR PUTAKA

- Agarwal, S., Sharma, S., Faisal, K. N., & Sharma, R. R. (2025). Time-series forecasting using SVMD-LSTM: A hybrid approach for stock market prediction. *Journal of Probability and Statistics*, 2025, Article ID 9464938. <https://doi.org/10.1155/jpas/9464938>
- Alizadegan, H., Rashidi Malki, B., Radmehr, A., Karimi, H., & Ilani, M. A. (2025). Comparative study of long short-term memory (LSTM), bidirectional LSTM, and traditional machine learning approaches for energy consumption prediction. *Energy Exploration and Exploitation*, 43(1), 281–301. <https://doi.org/10.1177/01445987241269496>
- Al-Khowarizmi, Syah, R., Nasution, M. K. M., & Elveny, M. (2021). Sensitivity of MAPE using detection rate for big data forecasting crude palm oil on k-nearest neighbor. *International Journal of Electrical and Computer Engineering*, 11(3), 2696–2703. <https://doi.org/10.11591/ijece.v11i3.pp2696-2703>
- Andi, T., & Kusuma, C. J. C. (2025). Stock price forecasting using long short term memory. *IOTA*, 5(1). <https://doi.org/10.31763/iota.v5i1.900>
- Chaudhary, R. (2025). Advanced stock market prediction using *Long Short-Term Memory* networks: A comprehensive deep learning framework. *arXiv preprint arXiv:2505.05325*. <https://arxiv.org/abs/2505.05325>
- Desai, S. J., & Kharade, K. G. (2025). Stock market price prediction using LSTM. *International Journal of Advanced Computer Technology and Engineering*, 14(4). <https://journals.mriindia.com/index.php/ijacte/article/view/206>

- Gao, Y. (2021). Stock prediction based on optimized LSTM and GRU models. *Journal of Electrical and Computer Engineering*, 2021, Article ID 4055281. <https://doi.org/10.1155/2021/4055281>
- Gupta, P., Malik, S., Apoorb, K., & Ragam, P. (2023). Stock market analysis using long short-term model. *EAI Endorsed Transactions on Scalable Information Systems*, 10(5). <https://www.researchgate.net/publication/375857569>
- Huang, M. (2023). Effectiveness validation of LSTM for stock prices prediction on four stocks. *ResearchGate*. <https://www.researchgate.net/publication/372823280>
- Janiesch, C., Zscheck, P., & Heinrich, K. (2021). Machine Learning and deep learning. *Electronic Markets*, 31(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Kulkarni, S. A., Gurav, S., Lahade, A., Gudavalekar, D., & Sangale, N. (2024). Working of stock price prediction using LSTM. *International Journal of Scientific Research in Engineering and Management (IJSREM)*, 8(5), 1–4. <https://doi.org/10.55041/IJSREM34979>
- Li, Z., Yu, H., Xu, J., Liu, J., & Mo, Y. (2023). Stock market analysis and prediction using LSTM: A case study on technology stocks. *Innovations in Applied Engineering and Technology*, 2(1), 1–6. <https://doi.org/10.62836/iaet.v2i1.162>
- Pardeshi, K., Gill, S. S., & Abdelmoniem, A. M. (2023). Stock market price prediction: A hybrid LSTM and sequential self-attention based approach. *arXiv preprint arXiv:2308.04419*. <https://arxiv.org/abs/2308.04419>

- Sherstinsky, A. (2020). Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404, 132306. <https://doi.org/10.1016/J.PHYSD.2019.132306>
- Switrayana, I. N., Hammad, R., Irfan, P., Sujaka, T. T., & Nasri, M. H. (2025). Comparative Analysis of Stock Price Prediction Using Deep Learning with Data Scaling Method. *JTIM : Jurnal Teknologi Informasi Dan Multimedia*, 7(1), 78–90. <https://doi.org/10.35746/jtim.v7i1.650>

## LAMPIRAN

### Lampiran 1. SK-2 Penetapan Dosen Pembimbing



**UMSU**  
Unggul | Cerdas | Terpercaya

Di bawah bimbingan dan pengawasan Majelis Pendidikan Tinggi, Penelitian & Pengembangan Pimpinan Pusat Muhammadiyah

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. 89/SK/IBAN-PT/Akred/PT/III/2019  
Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003  
<http://www.umsu.ac.id> [info@umsu.ac.id](mailto:info@umsu.ac.id) [umsuamedia](https://www.instagram.com/umsuamedia) [umsuamedia](https://www.facebook.com/umsuamedia) [umsuamedia](https://www.youtube.com/channel/UC...) [umsuamedia](https://www.tiktok.com/@umsuamedia)

**PENETAPAN DOSEN PEMBIMBING  
PROPOSAL/SKRIPSI MAHASISWA  
NOMOR : 40/IL.3-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 : 03 Januari 2025

Dengan ini menetapkan Dosen Pembimbing Proposal / Skripsi Mahasiswa.

Nama : Prayoga Sungkowo  
NPM : 2109020046  
Semester : VII (Tujuh)  
Program studi : Teknologi Informasi  
Judul Proposal / Skripsi : Implementasi Machine Learnig Dengan Model LSTM Untuk Memprediksi Harga Saham (Yahoo Finance)

Dosen Pembimbing : Dr. Al-Khowarizmi, 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 : 03 Januari 2026
4. Revisi judul.....

*Wassalamu'alaikum Warahmatullahi Wabarakatuh.*

Ditetapkan di : Medan  
Pada Tanggal : 03 Rajab 1446 H  
03 Januari 2025 M



a.n.Dekan  
Wakil/Dekan I  
  
Haidar Maulana, S.T.,M.Kom.  
NIDN : 0121119102

Cc. File



## Lampiran 2. Turnitin

Turnitin			
ORIGINALITY REPORT			
<b>22%</b>	<b>17%</b>	<b>15%</b>	<b>13%</b>
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS
PRIMARY SOURCES			
<b>1</b>	Submitted to Universitas Muhammadiyah Sumatera Utara Student Paper		<b>2%</b>
<b>2</b>	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		<b>1%</b>
<b>3</b>	repository.umsu.ac.id Internet Source		<b>1%</b>
<b>4</b>	etd.ummy.ac.id Internet Source		<b>&lt;1%</b>
<b>5</b>	Submitted to UNITEC Institute of Technology Student Paper		<b>&lt;1%</b>
<b>6</b>	www.iksadkongre.com Internet Source		<b>&lt;1%</b>
<b>7</b>	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",		<b>&lt;1%</b>

## JUTECH : Journal Education and Technology, 2024

Publication

8	Submitted to Sydney Polytechnic Institute Student Paper	<1 %
9	Submitted to University of Wisconsin Extension Student Paper	<1 %
10	Submitted to Universidad Internacional de la Rioja Student Paper	<1 %
11	Submitted to Sim University Student Paper	<1 %
12	docplayer.info Internet Source	<1 %
13	Submitted to Universitas Putera Batam Student Paper	<1 %
14	journal.literasisains.id Internet Source	<1 %
15	ejurnal.politeknipratama.ac.id Internet Source	<1 %
16	Submitted to Westcliff University Student Paper	<1 %
17	Submitted to Universitas Maritim Raja Ali Haji Student Paper	<1 %
18	ejournal.polbeng.ac.id Internet Source	<1 %
19	jjclt.com Internet Source	<1 %
20	journal.fkpt.org Internet Source	<1 %

21	proceeding.unpkediri.ac.id Internet Source	<1 %
22	Submitted to Marmara University Student Paper	<1 %
23	adoc.pub Internet Source	<1 %
24	id.scribd.com Internet Source	<1 %
25	journals.mriindia.com Internet Source	<1 %
26	Submitted to Sultan Agung Islamic University Student Paper	<1 %
27	Submitted to Universitas Pendidikan Ganesha Student Paper	<1 %
28	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 %
29	es.scribd.com Internet Source	<1 %
30	Submitted to Gisma University of Applied Sciences GmbH Student Paper	<1 %
31	Submitted to Liverpool John Moores University Student Paper	<1 %
32	Nia Andriani Laila. "Optimasi Parameter Support Vector Regression (SVR)	<1 %

## Menggunakan Algoritma Grey Wolf Optimizer (GWO)", Jurnal Ilmiah Matematika, 2025

Publication

33	<a href="https://eprints.amikompuwoko.ac.id">eprints.amikompuwoko.ac.id</a> Internet Source	<1%
34	<a href="https://repository.unhas.ac.id">repository.unhas.ac.id</a> Internet Source	<1%
35	<a href="https://repository.unair.ac.id">repository.unair.ac.id</a> Internet Source	<1%
36	Submitted to Universitas Negeri Semarang - iTh Student Paper	<1%
37	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%
38	<a href="https://jurnal.kolibi.org">jurnal.kolibi.org</a> Internet Source	<1%
39	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%
40	<a href="https://openlibrarypublications.telkomuniversity.ac.id">openlibrarypublications.telkomuniversity.ac.id</a> Internet Source	<1%
41	<a href="https://yudistira.lecture.ub.ac.id">yudistira.lecture.ub.ac.id</a> Internet Source	<1%

42	Submitted to STKIP PGRI Sumenep Student Paper	<1 %
43	rajallo.blogspot.com Internet Source	<1 %
44	Submitted to Academic Library Consortium Student Paper	<1 %
45	Submitted to UM Surabaya Student Paper	<1 %
46	Submitted to University of Sydney Student Paper	<1 %
47	ejurnal.itenas.ac.id Internet Source	<1 %
48	Submitted to University of Hertfordshire Student Paper	<1 %
49	repository.unipasby.ac.id Internet Source	<1 %
50	www.slideshare.net Internet Source	<1 %
51	Submitted to Universitas Muslim Indonesia Student Paper	<1 %
52	pubs.ascee.org Internet Source	<1 %
53	text-id.123dok.com Internet Source	<1 %
54	Muhammad Nur Aslam, Sarif Surejo, Erni Unggul Sedyta Utami. "Penerapan Metode Fuzzy Mamdani dalam Prediksi Cuaca di Tegal", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1 %

55	Submitted to Universitas Terbuka Student Paper	<1 %
56	repository.uhn.ac.id Internet Source	<1 %
57	Indra Wijaya, Herlawati Herlawati, Rafika Sari. "Prediksi Curah Hujan Di Kabupaten Bogor Menggunakan Long Short-Term Memory Dan Gemma 2", Jurnal Komtika (Komputasi dan Informatika), 2025 Publication	<1 %
58	Submitted to University of Westminster Student Paper	<1 %
59	Vernanda Sam Saputra, Achmad Ridwan, Taftazani Ghazi Pratama. "RANCANG BANGUN SISTEM REKOMENDASI BUKU BERBASIS ITEM-BASED COLLABORATIVE FILTERING MENGGUNAKAN ALGORITMA K- NEAREST NEIGHBORS", Jurnal Informatika dan Teknik Elektro Terapan, 2025 Publication	<1 %
60	jstatgcu.pk Internet Source	<1 %
61	repository.unimor.ac.id Internet Source	<1 %
62	vdocuments.site Internet Source	<1 %
63	1library.co Internet Source	<1 %
64	Submitted to Admin Turnitin UISI Student Paper	<1 %

65	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 Publication	<1%
66	Ariyanto Adi Nugroho, Muhammad Haris. "ANALISIS EFEKTIVITAS TEKNIK IMPUTASI PADA LSTM UNTUK MENINGKATKAN KUALITAS DATA PADA PERAMALAN CURAH HUJAN", Jurnal Informatika dan Rekayasa Elektronik, 2024 Publication	<1%
67	Submitted to Athlone Institute of Technology Student Paper	<1%
68	Dita Septasari. "ANALISIS ASOSIASI PILIHAN PROGRAM STUDI PENDAFTAR UNIVERSITAS ISLAM NEGERI SUNAN KALIJAGA JALUR MANDIRI MENGGUNAKAN ALGORITMA APRIORI", Aisyah Journal Of Informatics and Electrical Engineering (A.J.I.E.E), 2020 Publication	<1%
69	La Gubu, Muhammad Alfian Bakti Sadewa, La Pimpi. "Peramalan Harga Saham PT. Bank Central Asia, Tbk dengan Menggunakan Metode ARIMA", Jurnal Derivat: Jurnal Matematika dan Pendidikan Matematika, 2024 Publication	<1%
70	Submitted to Universitas Muhammadiyah Palembang Student Paper	<1%

71	docobook.com Internet Source	<1 %
72	repositori.stiamak.ac.id Internet Source	<1 %
73	www.ilmudata.org Internet Source	<1 %
74	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 %
75	Submitted to Sekolah Teknik Elektro & Informatika Student Paper	<1 %
76	Suci Mulyani, Afril Efan Pajri, Muhammad Fikram. "Klasifikasi Tingkat Kemiskinan Di Indonesia Menggunakan Algoritma Naives Bayes", Scientific : Journal of Computer Science and Informatics, 2024 Publication	<1 %
77	Tarwoto, Rizki Nugroho, Najmul Azka, Wakhid Sayudha Rendra Graha. "Analisis Sentimen Ulasan Aplikasi Mobile JKN di Google PlayStore Menggunakan IndoBERT", Jurnal JTik (Jurnal Teknologi Informasi dan Komunikasi), 2025 Publication	<1 %
78	Submitted to Treamis International School Student Paper	<1 %
79	Submitted to Universitas Gadjah Mada Student Paper	<1 %

80	Submitted to Universitas Islam Riau Student Paper	<1 %
81	core.ac.uk Internet Source	<1 %
82	jurnal.itg.ac.id Internet Source	<1 %
83	repository.stiesia.ac.id Internet Source	<1 %
84	Submitted to Sriwijaya University Student Paper	<1 %
85	Submitted to Universitas 17 Agustus 1945 Semarang Student Paper	<1 %
86	Untara Untara, Titi Ayem Lestari. "Faktor Internal Dan Eksternal Terhadap Nilai Harga Saham Pada Bank Bumh Yang Terdaftar Dalam Bursa Efek Indonesia Periode 2020-2023", JEMSI (Jurnal Ekonomi, Manajemen, dan Akuntansi), 2024 Publication	<1 %
87	al-kindipublishers.org Internet Source	<1 %
88	Submitted to itera Student Paper	<1 %
89	kc.umh.ac.id Internet Source	<1 %
90	library.stmikgici.ac.id Internet Source	<1 %
91	Ahmad Syahreza, Novita Kurnia Ningrum, Muhammad Anjas Syahrazy. "Perbandingan Kinerja Model Prediksi Cuaca: Random Forest,	<1 %

Support Vector Regression, dan XGBoost",  
Edumatic: Jurnal Pendidikan Informatika,  
2024

Publication

92	Ruqiang Yan, Jing Lin. "Equipment Intelligent Operation and Maintenance", CRC Press, 2025 Publication	<1 %
93	Submitted to Surabaya University Student Paper	<1 %
94	Submitted to UNIVERSITAS BUDI LUHUR Student Paper	<1 %
95	Submitted to Universitas Muhammadiyah Yogyakarta Student Paper	<1 %
96	journal.umg.ac.id Internet Source	<1 %
97	Submitted to Forum Perpustakaan Perguruan Tinggi Indonesia Jawa Timur Student Paper	<1 %
98	Submitted to Universitas Esa Unggul Student Paper	<1 %
99	Submitted to University of Birmingham Student Paper	<1 %
100	digilib.uinsa.ac.id Internet Source	<1 %
101	ijritcc.org Internet Source	<1 %
102	stmik-budidarma.ac.id Internet Source	<1 %
103	dspace.uii.ac.id	

	Internet Source	<1 %
104	<a href="https://eprints.soton.ac.uk">eprints.soton.ac.uk</a> Internet Source	<1 %
105	<a href="https://pdfcoffee.com">pdfcoffee.com</a> Internet Source	<1 %
106	<a href="https://pt.scribd.com">pt.scribd.com</a> Internet Source	<1 %
107	<a href="https://pustakagalerimandiri.co.id">pustakagalerimandiri.co.id</a> Internet Source	<1 %
108	<a href="https://repository.unj.ac.id">repository.unj.ac.id</a> Internet Source	<1 %
109	<a href="https://www.hindawi.com">www.hindawi.com</a> Internet Source	<1 %
110	<a href="https://www.localstartupfest.id">www.localstartupfest.id</a> Internet Source	<1 %
111	<a href="https://123dok.com">123dok.com</a> Internet Source	<1 %
112	Andre Wiejaya, Indah Fenriana. "Prediksi Harga Saham Top 10 NASDAQ dengan Time Series Prophet", bit-Tech, 2024 Publication	<1 %
113	Wilianto Wilianto, Yuliana Yuliana, Albert Suwandhi, Jimmy Jimmy, Jati Putra. "Penerapan AI dalam Menentukan Harga Mobil Bekas Berdasarkan Tahun Perakitan", Jurnal Minfo Polgan, 2024 Publication	<1 %
114	<a href="https://eprints.uns.ac.id">eprints.uns.ac.id</a> Internet Source	<1 %
	<a href="https://etd.repository.ugm.ac.id">etd.repository.ugm.ac.id</a>	

115	Internet Source	<1 %
116	ijrti.org Internet Source	<1 %
117	prosiding.senadi.upy.ac.id Internet Source	<1 %
118	Ferryrna Arba Apriansyah, Arif Pramudwiatmoko, Muhammad Senoaji Wibowo, Evi Widiyastuti, Tri Agung Jiwandono, Vatma Sari. "Penerapan Metode Fuzzy Tsukamoto Untuk Mendukung Pengambilan Keputusan Berdasarkan Data Jumlah Resi dan Profit", Jurnal JTIK (Jurnal Teknologi Informasi dan Komunikasi), 2025 Publication	<1 %
119	Submitted to Universitas Islam Syekh-Yusuf Tangerang Student Paper	<1 %
120	ciencialatina.org Internet Source	<1 %
121	criptoeconomia.com.br Internet Source	<1 %
122	digilib.uinsby.ac.id Internet Source	<1 %
123	digilib.unila.ac.id Internet Source	<1 %
124	digilib.unimed.ac.id Internet Source	<1 %
125	e-journal.uajy.ac.id Internet Source	<1 %
126	jpti.journals.id Internet Source	<1 %

		<1 %
127	www.simulasikredit.com Internet Source	<1 %
128	Afriani Afriani, Herry Sujaini, Niken Candraningrum. "Analisis Perbandingan Metode Pengklasifikasi Gambar Jenis Tulisan Kaligrafi Arab", Jurnal Edukasi dan Penelitian Informatika (JEPIN), 2024 Publication	<1 %
129	Ahmad Fauzi, Nurlaelatul Maulidah, Riki Supriyadi, Hiya Nalatissifa, Sri Diantika. "Prediksi Harga Properti Di Indonesia Menggunakan Algoritma Random Forest", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1 %
130	Alifqi Radjavani, Theopilus Bayu Sasongko. "Analisa Perbandingan Algoritma CNN dan LSTM untuk Klasifikasi Pesan Cyberbullying pada Twitter", The Indonesian Journal of Computer Science, 2023 Publication	<1 %
131	Fery Pirmansyah, Tri Wahyudi. "IMPLEMENTASI DATA MINING MENGGUNAKAN ALGORITMA C4.5 UNTUK PREDIKSI EVALUASI ANGGOTA SATUAN PENGAMANAN STUDI KASUS PT. YIMM PULOGADUNG", Jurnal Indonesia : Manajemen Informatika dan Komunikasi, 2023 Publication	<1 %
132	Intisari, Dewi. "Pengaruh Pemberian Ekstrak Bunga Telang (Clitoria Ternatea L.) Terhadap	<1 %

Kadar GDP, HBA1c, DAN MDA  
(Malondialdehyde) (Studi Eksperimental Pada  
Tikus Putih Jantan Galur Wistar Yang  
Diinduksi Nikotinamid-Streptozotosin)",  
Universitas Islam Sultan Agung (Indonesia),  
2023

Publication

133 Maulida, Fanda Kumariana. "Peran Corporate Governance Dalam Financialdistress Pada Saham Syariah Yang Go Public Dibursa Efek Indonesia", Universitas Islam Sultan Agung (Indonesia), 2022 <1%

Publication

134 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 <1%

Publication

135 Nofita Sari, Zaenal Afifi, Diah Ayu Susanti. "ANALISIS PENGARUH LIKUIDITAS SAHAM, EARNING PER SHARE, RETURN SAHAM, HARGA SAHAM, DAN VOLUME PERDAGANGAN SAHAM TERHADAP KEPUTUSAN STOCK SPLIT", Accounting Journal of Ibrahimy (AJI), 2024 <1%

Publication

136 Nurdianto Yusuf. "PREDIKSI PRODUKSI DAGING SAPI DI INDONESIA MENGGUNAKAN RANDOM FOREST REGRESSION: ANALISIS DATA 2018-2025", Jurnal Ilmiah Teknik, 2024 <1%

Publication

137	Satrio, Raden Mas Joko Priyo. "Pengaruh Keterlibatan Karyawan dan Stres Kerja Terhadap Turnover Intention Dengan Kepuasan Kerja Sebagai Variabel Intervening", Universitas Islam Sultan Agung (Indonesia), 2024 Publication	<1 %
138	Xingyuan Wu, Yonggang Qi, Jun Liu, Jie Yang. "Sketchsegnet: A Rnn Model for Labeling Sketch Strokes", 2018 IEEE 28th International Workshop on Machine Learning for Signal Processing (MLSP), 2018 Publication	<1 %
139	Yusuf Ashari, Agus Suhendar. "IMPLEMENTASI ALGORITMA LONG SHORT-TERM MEMORY (LSTM) UNTUK MEMPREDIKSI HARGA BERAS DI JAWA TENGAH BERDASARKAN CUACA", Djtechno: Jurnal Teknologi Informasi, 2024 Publication	<1 %
140	csitjournal.khmnu.edu.ua Internet Source	<1 %
141	ejurnal.seminar-id.com Internet Source	<1 %
142	id.123dok.com Internet Source	<1 %
143	jasascanmurah.blogspot.com Internet Source	<1 %
144	journal.gnest.org Internet Source	<1 %
145	journal.unhas.ac.id Internet Source	<1 %
	media.neliti.com	

146	Internet Source	<1 %
147	q.stock.sohu.com Internet Source	<1 %
148	repositori.usu.ac.id Internet Source	<1 %
149	repository.usu.ac.id Internet Source	<1 %
150	repositum.tuwien.at Internet Source	<1 %
151	stockinvest.us Internet Source	<1 %
152	triputroprabowoblog.wordpress.com Internet Source	<1 %
153	www.mdpi.com Internet Source	<1 %
154	www.seejph.com Internet Source	<1 %
155	Jun Li, Guofang Wu, Yongpeng Zhang, Wenhui Shi. "Optimizing flood predictions by integrating LSTM and physical-based models with mixed historical and simulated data", Heliyon, 2024 Publication	<1 %
156	Dadang Iskandar Mulyana, Guruh Taruno Putra. "Deteksi Objek bertumpuk Gerak Tangan Bahasa Isyarat SIBI dengan Algoritma LSTM-Holistic", INTECOMS: Journal of Information Technology and Computer Science, 2025 Publication	<1 %

157	Hamid Jahankhani, Gordon Bowen, Nitsa J. Herzog, David J. Herzog. "Symbiotic Intelligence - Advancing Forecasting Through Human-AI Collaboration", CRC Press, 2025 Publication	<1%
158	Kevin Astudillo, Miguel Flores, Mateo Soliz, Guillermo Ferreira, José Varela-Aldás. "A Hybrid GAS-ATT-LSTM Architecture for Predicting Non-Stationary Financial Time Series", Mathematics, 2025 Publication	<1%
159	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%
160	Shalli Rani, Ayush Dogra, Ashu Taneja. "Smart Computing and Communication for Sustainable Convergence", CRC Press, 2025 Publication	<1%
161	repository.uin-suska.ac.id Internet Source	<1%

Exclude quotes Off

Exclude matches Off

Exclude bibliography Off