

**IMPLEMENTASI ALGORITMA *LONG SHORT-TERM
MEMORY* DALAM PEMBELAJARAN MESIN UNTUK
MEMPREDIKSI HARGA SAHAM PT ASTRA
INTERNASIONAL TBK**

SKRIPSI

**Sebagai salah satu persyaratan guna memperoleh gelar Sarjana Komputer
(S.Kom)**



ZAHRANI ANINDITA SAHARA

NIM : 3337210048

PROGRAM STUDI INFORMATIKA

FAKULTAS TEKNIK

UNIVERSITAS SULTAN AGENG TIRTAYASA

2025

LEMBAR PERNYATAAN KEASLIAN SKRIPSI

Saya yang bertanda tangan di bawah ini :

Nama : Zahrani Anindita Sahara
NIM : 3337210048
Perguruan Tinggi : Universitas Sultan Ageng Tirtayasa
Program Studi : Informatika
Jenjang : Strata 1 (S1)

Dengan ini menyatakan bahwa Tugas Akhir/Skripsi saya yang berjudul “Implementasi Algoritma *Long Short-Term Memory* (LSTM) dalam Pembelajaran Mesin untuk Memprediksi Harga Saham PT Astra Internasional Tbk (ASII.JK)” adalah benar-benar hasil karya saya yang asli dan bukan hasil menjiplak karya orang lain, kecuali dinyatakan melalui rujukan yang benar dan dapat dipertanggung jawabkan. Skripsi ini belum pernah diterbitkan/dipublikasikan dimanapun dan dalam bentuk apapun. Apabila dikemudian hari ditemukan bahwa pernyataan yang saya buat adalah palsu, maka saya bersedia diproses secara hukum dan kelulusan saya dari Universitas Sultan Ageng Tirtayasa dibatalkan/dicabut.

Cilegon, 30 Juli 2025



Zahrani Anindita Sahara

3337210048

LEMBAR PENGESAHAN

Judul Skripsi : Implementasi Algoritma *Long Short-Term Memory* dalam Pembelajaran Mesin untuk Memprediksi Harga Saham PT Astra Internasional Tbk
Nama : Zahrani Anindita Sahara
NIM : 3337210048

Disetujui oleh,

Pembimbing,



Prof. Dr. Ir. Supriyanto, M.Sc. IPM.
NIP. 197605082003121002



Arif Rahman, S.Kom., M.Kom.
NIP. 199304202024061001

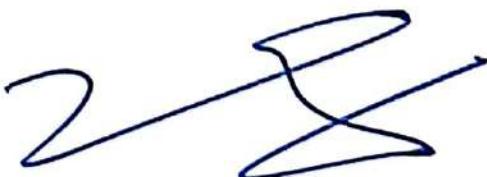
Mengetahui,

Dekan Fakultas Teknik

Ketua Program Studi Informatika



Prof. Dr. Jayanudin, S.T., M.Eng.
NIP. 197808112005011003



Nanang Krisdianto, S.T., M.Kom.
NIP. 197504092006041004

PRAKATA

Segala puji dan syukur penulis ucapkan kehadiran Allah SWT atas limpahan nikmat, rahmat dan karunia-Nya yang telah dicurahkan kepada penulis. Berkat anugerah tersebut, penulis berhasil menyelesaikan Skripsi berjudul “Implementasi Algoritma *Long Short-Term Memory* dalam Pembelajaran Mesin untuk Memprediksi Harga Saham PT Astra Internasional Tbk” ini. Skripsi ini disusun dalam upaya memenuhi salah satu persyaratan mencapai gelar Sarjana Komputer pada Program Studi Informatika Universitas Sultan Ageng Tirtayasa. Penulis sangat sadar bahwa penulisan Skripsi tidak akan berjalan lancar tanpa adanya bimbingan dan dukungan banyak pihak. Oleh sebab itu, terima kasih penulis sampaikan kepada :

1. Bapak Nanang Krisdianto, ST., M.Kom., selaku Ketua Prodi Informatika Fakultas Teknik Universitas Sultan Ageng Tirtayasa yang telah memberikan arahan dan dukungannya dalam menyelesaikan studi ini;
2. Bapak Prof. Dr. Ir. Supriyanto, M.Sc., IPM., selaku Dosen Pembimbing 1, yang telah membimbing, memberi saran juga masukannya kepada penulis dalam menyelesaikan Skripsi;
3. Bapak Arief Rahman, S.Kom., M.Kom., selaku Dosen Pembimbing 2 yang telah membimbing, memberi saran juga masukannya kepada penulis dalam menyelesaikan Skripsi;
4. Bapak dan Ibu dosen Prodi Informatika Universitas Sultan Ageng Tirtayasa yang telah membimbing penulis dalam menuntut ilmu sejak awal perkuliahan hingga akhir saat ini;
5. Orang tua yang tak henti memberikan doa dan dukungannya kepada penulis dalam prosesnya menyelesaikan penulisan Skripsi ini;
6. Rekan-rekan Prodi Informatika Universitas Sultan Ageng Tirtayasa Angkatan 2021 yang telah mendukung dan memberi motivasi luar biasa dalam penyelesaian Skripsi ini.

Penulis juga memahami bahwa penulisan Skripsi ini masih belum sempurna. Oleh karena itu, penulis sangat menerima masukan dari pembaca apabila terdapat kekurangan ataupun kesalahan dalam penulisan Skripsi ini. Akhir kata, semoga

Skripsi ini dapat memberikan manfaat dan kontribusi baik secara akademik maupun praktis, khususnya dalam bidang *machine learning*.

Cilegon, 30 Juli 2025



Zahrani Anindita Sahara

**IMPLEMENTASI ALGORITMA *LONG SHORT-TERM
MEMORY* DALAM PEMBELAJARAN MESIN UNTUK
MEMPREDIKSI HARGA SAHAM PT ASTRA
INTERNASIONAL TBK**

Zahrani Anindita Sahara

RINGKASAN

Latar Belakang : Penelitian ini dilatar belakangi oleh adanya peningkatan jumlah investor di pasar modal Indonesia, khususnya pada instrumen saham yang menjadi perhatian dalam bidang keuangan dan investasi. Meningkatnya minat masyarakat dalam berinvestasi saham yang memiliki risiko tinggi, menuntut adanya pendekatan analisis berupa prediksi harga saham yang dapat membantu investor dalam mengambil keputusan. Berdasarkan penelitian-penelitian terdahulu yang membahas tentang prediksi harga saham, banyak yang membuktikan bahwa algoritma *Long Short-Term Memory* (LSTM) memiliki dasar teoritis yang kuat dalam menangani data deret waktu seperti harga saham, dan juga terbukti akurat dalam memprediksi harga saham. Oleh karena itu, penelitian ini dilakukan dengan tujuan membangun model prediksi harga saham PT Astra Internasional Tbk (ASII.JK) dengan mengimplementasikan algoritma LSTM, dengan harapan dapat memberikan kontribusi praktis untuk membantu investor dalam memprediksi harga saham ASII.JK.

Perumusan Masalah : Berdasarkan latar belakang yang telah diuraikan, penelitian ini merumuskan masalah terkait penerapan algoritma *Long Short-Term Memory* (LSTM) dalam prediksi harga saham. Dua hal utama yang menjadi masalah dalam penelitian ini adalah, bagaimana pengimplementasian algoritma LSTM dalam membangun model prediksi harga saham PT Astra Internasional Tbk (ASII.JK), serta bagaimana performa dari model LSTM tersebut dalam memprediksi harga saham ASII.JK.

Tujuan Penelitian : Tujuan utama dari penelitian ini adalah untuk menyelesaikan permasalahan yang sudah dirumuskan, yaitu terkait penerapan algoritma LSTM dalam memprediksi harga saham ASII.JK. Tujuannya adalah untuk memberikan pemahaman lebih dalam mengenai pengimplementasian algoritma LSTM dalam membangun model prediksi harga saham, serta untuk mengevaluasi kinerja model tersebut dalam memprediksi harga saham ASII.JK dengan menghitung metrik evaluasi MAPE, RMSE, dan MAE.

Metode Penelitian : Penelitian ini menggunakan pendekatan kuantitatif dengan mengimplementasikan algoritma LSTM. Data historis harga saham ASII.JK pada periode 31 Oktober 2019-30 Oktober 2024 dikumpulkan secara sekunder melalui *Yahoo Finance* menggunakan *library yfinance*. Proses *Exploratory Data Analysis*

(EDA) meliputi perhitungan ringkasan statistik, visualisasi distribusi fitur untuk mengidentifikasi *outlier*, analisis tren harga saham, serta korelasi antar fitur untuk melihat hubungan linier antar variabel dilakukan untuk menambah informasi mengenai data. Beberapa tahapan pra-pemrosesan data dilakukan, seperti normalisasi menggunakan metode *Min-Max scaler*, pembagian data dengan *TimeSeriesSplit* sebanyak 5 *fold*, serta pembentukan *sequence* dan target menggunakan *TimeSeriesGenerator* dengan panjang urutan 10. Model LSTM dibangun dengan dua *layer* LSTM (150 dan 100 unit), dua *dense layer* (50 unit ReLU dan 1 unit *output*), *dropout* 10%, dan dikompilasi menggunakan fungsi *loss* MSE serta *optimizer* Adam (*learning rate* 0.001). Model akan dievaluasi menggunakan metrik evaluasi berupa MAPE, RMSE, dan MAE. Model akan diuji dengan mengaplikasikannya untuk memprediksi harga saham ASII.JK selama 7 hari setelah tanggal 31 Oktober 2024, dan hasilnya juga akan dievaluasi menggunakan metrik MAPE, RMSE, dan MAE.

Hasil Penelitian : Hasil penelitian menunjukkan bahwa algoritma LSTM berhasil diterapkan untuk membangun model prediksi harga saham ASII.JK dengan performa yang cukup baik, dengan menghasilkan nilai MAPE sebesar 1.42%, RMSE 94.16, dan MAE 70.26. Angka tersebut menunjukkan bahwa model memiliki akurasi prediksi yang baik pada data uji. Hasil dari pengaplikasian model untuk memprediksi harga saham ASII.JK selama 7 hari setelah tanggal 31 Oktober 2024 juga menghasilkan nilai metrik evaluasi yang baik, yaitu MAPE sebesar 1.31%, RMSE 72.36, dan MAE 66.06. Namun dari grafik hasil visualisasi harga prediksi dan harga aktual dari prediksi harga saham selama 7 hari, terlihat bahwa grafik harga prediksi tidak dapat memproyeksikan fluktuasi pasar ekstrem yang terjadi pada harga aktual. Hasil ini memberikan wawasan baru mengenai efektivitas LSTM dalam memproyeksikan tren harga saham, serta menunjukkan bahwa model berpotensi untuk menambah pertimbangan investor sebelum membuat keputusan investasi, meskipun masih belum responsif terhadap fluktuasi pasar yang ekstrem.

Kesimpulan : Berdasarkan hasil yang telah diperoleh, kesimpulan dari penelitian ini adalah, algoritma LSTM dapat diimplementasikan secara efektif dalam membangun model prediksi untuk memprediksi harga saham ASII.JK. Hasil pemodelan menunjukkan performa yang cukup baik dengan menghasilkan nilai metrik evaluasi yang rendah, yang menunjukkan kesalahan prediksi kecil. Model juga mampu diaplikasikan untuk memberikan prediksi aktual selama 7 hari setelah periode observasi dengan menghasilkan prediksi harga yang tidak terlalu jauh dari harga aktualnya, meskipun masih belum mampu menangkap fluktuasi pasar yang ekstrem.

Kata Kunci : *Long Short-Term Memory, Machine learning, MAPE, Prediksi saham, PT Astra International Tbk*

Implementasi Algoritma *Long Short-Term Memory* dalam Pembelajaran Mesin untuk Memprediksi Harga Saham PT Astra Internasional Tbk

Zahrani Anindita Sahara

ABSTRAK

Penelitian ini bertujuan untuk membangun model prediksi dengan menerapkan algoritma *Long Short Term-Memory* (LSTM) dalam memprediksi harga saham PT Astra Internasional Tbk (ASII.JK). Penelitian menggunakan data historis harga saham ASII.JK selama 5 tahun sejak 31 Oktober 2019 hingga 31 Oktober 2024. Model LSTM dibangun dengan konfigurasi optimal yang terdiri dari dua *layer* (150 dan 100 unit), *dense layer* (50 unit), *batch size* 32, *epoch* 400, *dropout* 0.1, dan *learning rate* 0.001. Model dievaluasi menggunakan tiga metrik evaluasi berupa *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Error* (MAE). Hasilnya menunjukkan performa yang baik dengan nilai MAPE sebesar 1,42%, RMSE sebesar 94.16, dan MAE sebesar 70.26. Untuk melihat sejauh mana model mampu memprediksi data yang belum pernah dilihatnya, dilakukan prediksi nyata pada saham ASII.JK selama 7 hari setelah tanggal 31 Oktober 2024. Hasilnya menunjukkan bahwa model cukup efektif dalam memprediksi harga saham ASII.JK dengan tingkat kesalahan rendah. Ditunjukkan dengan nilai MAPE sebesar 1.31%, RMSE 72.36, dan MAE 66.06. Dari hasil tersebut, model terbukti mampu mengikuti arah tren harga saham dan memberikan proyeksi yang cukup akurat, juga berpotensi menjadi alat bantu yang efektif dalam mendukung pengambilan keputusan investasi saham.

Kata kunci : *Long Short-Term Memory*, *Machine learning*, MAPE, Prediksi saham, PT Astra International Tbk

Implementasi Algoritma *Long Short-Term Memory* dalam Pembelajaran Mesin untuk Memprediksi Harga Saham PT Astra Internasional Tbk

Zahrani Anindita Sahara

ABSTRACT

This study aims to develop a prediction model by implementing the Long Short-Term Memory (LSTM) algorithm to forecast the stock price of PT Astra International Tbk (ASII.JK). The research utilizes historical stock price data of ASII.JK over a 5-year period from October 31, 2019, to October 31, 2024. The LSTM model was built using an optimal configuration consisting of two layers (150 and 100 units), a dense layer (50 units), a batch size of 32, 400 epochs, a dropout rate of 0.1, and a learning rate of 0.001. The model was evaluated using three performance metrics: Mean Absolute Percentage Error (MAPE), Root Mean Square Error (RMSE), and Mean Absolute Error (MAE). The results show good performance with a MAPE of 1.42%, an RMSE of 94.16, and an MAE of 70.26. To assess the model's ability to predict unseen data, a real forecast was conducted for 7 days beyond October 31, 2024. The prediction results indicate that the model is quite effective in forecasting ASII.JK stock prices with a low error rate, evidenced by a MAPE of 1.31%, an RMSE of 72.36, and an MAE of 66.06. These findings demonstrate that the model can capture the direction of the stock price trend and provide fairly accurate projections, making it a potentially useful tool to support stock investment decision-making.

Keywords : *Long Short-Term Memory, Machine learning, MAPE, Stock prediction, PT Astra International Tbk*

DAFTAR ISI

HALAMAN JUDUL	ii
LEMBAR PERNYATAAN KEASLIAN SKRIPSI	ii
LEMBAR PENGESAHAN	iii
PRAKATA.....	iv
ABSTRAK	viii
DAFTAR ISI	x
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xiii
DAFTAR LAMPIRAN	xiv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	3
1.3 Batasan Masalah	3
1.4 Tujuan Penelitian	3
1.5 Manfaat Penelitian	4
1.6 Sistematika Penulisan	4
BAB 2 TINJAUAN PUSTAKA	5
2.1 Penelitian Terdahulu	5
2.2 Keterkaitan Penelitian.....	7
2.3 PT Astra Internasional Tbk (ASII.JK)	7
2.4 Prediksi Harga Saham.....	8
2.5 Pembelajaran Mesin.....	8
2.6 <i>Long Short-Term Memory (LSTM)</i>	13
2.7 Python	17
2.8 <i>Min-Max Scaler Normalization</i>	17
2.9 <i>TimeSeriesSplit Cross Validation</i>	18
2.10 MAPE, RMSE, dan MAE.....	19
BAB III METODOLOGI	21
3.1 Jenis Penelitian dan Sumber Data.....	21
3.2 Perangkat dan Sumber Daya Penelitian.....	21
3.3 Alur Penelitian	22
3.4 Pengumpulan Data.....	23
3.5 <i>Exploratory Data Analysis (EDA)</i>	23
3.6 Pra-Pemrosesan Data	23
3.6.1 Normalisasi Data.....	23
3.6.2 Pembagian Data	24
3.6.3 Pembentukan <i>Sequence</i> dan Target	26
3.7 Pemodelan LSTM.....	27
3.7.1 Arsitektur Model	27
3.7.2 Kompilasi dan Pelatihan	28
3.7.3 Visualisasi <i>Loss</i>	28
3.8 Evaluasi & Analisis Hasil Pemodelan	28
3.9 Prediksi Harga Saham.....	28
3.10 Evaluasi & Analisis Hasil Prediksi	29

BAB IV HASIL DAN PEMBAHASAN	30
4.1 Pengumpulan Data.....	30
4.2 <i>Exploratory Data Analysis (EDA)</i>	31
4.2.1 Ringkasan Statistik.....	31
4.2.2 Visualisasi Distribusi Data Setiap Fitur	31
4.2.3 Visualisasi Tren Harga Saham	33
4.2.4 Korelasi Antar Fitur.....	34
4.3 Pra-Pemrosesan Data	35
4.3.1 Normalisasi Data.....	35
4.3.2 Pembagian Data	36
4.3.3 Pembentukan <i>Sequence</i> dan Target	36
4.4 Pemodelan LSTM.....	37
4.5 Evaluasi dan Analisis Hasil Pemodelan.....	39
4.6 Prediksi Harga Saham.....	40
BAB V KESIMPULAN DAN SARAN	43
5.1 Simpulan	43
5.2 Saran	43
DAFTAR PUSTAKA.....	44
LAMPIRAN.....	48

DAFTAR GAMBAR

Gambar 1 <i>Steps of Machine Learning</i>	9
Gambar 2 Diagram Klasifikasi Teknik <i>Machine Learning</i>	9
Gambar 3 <i>Supervised Learning</i>	10
Gambar 4 <i>Unsupervised Learning</i>	11
Gambar 5 <i>Reinforcement Learning</i>	12
Gambar 6 <i>Forget Gate Layer</i>	14
Gambar 7 <i>Input Gate Layer</i>	14
Gambar 8 Pembaruan <i>Gate Layer</i>	15
Gambar 9 <i>Output Gate Layer</i>	16
Gambar 10 Arsitektur Model LSTM.....	17
Gambar 11 <i>TimeSeriesSplit Cross Validation</i>	19
Gambar 12 Alur Penelitian.....	22
Gambar 13 Normalisasi Data	24
Gambar 14 Pembagian Data	25
Gambar 15 Pembentukan <i>Sequence</i> dan Target	26
Gambar 16 Arsitektur Model LSTM yang Digunakan	27
Gambar 17 Hasil Visualisasi Distribusi Data Tiap Fitur	32
Gambar 18 Hasil Visualisasi Tren Harga Saham	33
Gambar 19 Heatmap Korelasi Antar Fitur	34
Gambar 20 Grafik <i>Training & Validation Loss</i>	37
Gambar 21 Grafik Perbandingan Harga Prediksi & Aktual Pengujian Model	38
Gambar 22 Grafik Perbandingan Harga Prediksi dan Aktual selama 7 Hari.....	41

DAFTAR TABEL

Tabel 1 Penelitian Terkait.....	5
Tabel 2 Kriteria Penilaian MAPE	19
Tabel 3 Perangkat dan Sumber Daya	21
Tabel 4 Hasil Unduhan Data Historis Harga Saham ASII.JK	30
Tabel 5 Data Historis Harga Saham ASII.JK setelah Adj Close Dihapus.....	30
Tabel 6 Hasil Perhitungan Ringkasan Statistik Data Saham ASII.JK.....	31
Tabel 7 Data Saham ASII.JK Setelah Dinormalisasi	35
Tabel 8 Ukuran Tiap Fold Hasil Pembagian	36
Tabel 9 Kombinasi Parameter Terbaik	37
Tabel 10 Perbandingan Harga Prediksi & Harga Aktual Model	38
Tabel 11 Perbandingan Harga Saham Prediksi dan Aktual selama 7 Hari.....	40
Tabel 1 Lampiran 2 Parameter Eksperimen	49
Tabel 2 Lampiran 3 Harga Prediksi & Harga Aktual	50

DAFTAR LAMPIRAN

Lampiran 1 - Data Historis ASII.JK.....	48
Lampiran 2 - Parameter Eksperimen.....	49
Lampiran 3 - Harga Prediksi & Harga Aktual.....	50
Lampiran 4 - Kode Program Model Prediksi Harga Saham ASII.JK	52

BAB I

PENDAHULUAN

1.1 Latar Belakang

Kustodian Sentral Efek Indonesia (KSEI) melaporkan adanya kenaikan jumlah investor di pasar modal yang semula sebesar 11% dari 12,17 juta investor pada tahun 2023, meningkat menjadi 13,45 juta investor hingga 9 Agustus 2024 [1]. Hal itu menunjukkan bahwa tren investasi terus mengalami peningkatan setiap tahunnya. Menurut informasi dari KSEI, pada tahun 2023 jumlah investor pada saham dan surat berharga lainnya tercatat sebesar 5.255.571. Jumlahnya terus mengalami kenaikan sejak awal tahun 2024 sampai pada September 2024, yaitu mencapai 6.016.307 [2]. Hal ini menggambarkan bahwa semakin banyak masyarakat yang menganggap penting investasi, dan salah satu instrumen investasi yang dipilih untuk menginvestasikan asetnya adalah saham. Saham menjadi salah satu instrumen yang diminati karena imbal hasilnya yang menarik. Namun disamping imbal hasil yang menarik, investasi saham juga memiliki risiko yang tinggi. Karena itulah saham dikenal dengan istilah *high gain high risk*, dimana selain berpotensi untuk memberikan *gain* yang besar, terdapat risiko kerugian yang besar juga [3]. Hal itu membuat para investor mempertimbangkan untuk melakukan analisis terlebih dahulu sebelum membuat keputusan dalam berinvestasi saham. Salah satu analisis yang dilakukan adalah analisis teknikal, dimana para investor melakukan prediksi untuk melihat dan menganalisis pergerakan harga saham di masa depan. Harga saham yang sangat fluktuatif dan hubungannya yang kompleks dengan berbagai faktor yang memengaruhi, membuat proses prediksi harga saham menjadi sangat krusial. Karena itu, para peneliti berupaya keras untuk menciptakan model yang dapat diandalkan dalam memprediksi harga saham, karena dengan model yang andal, risiko dalam membuat keputusan yang kurang tepat dalam berinvestasi saham menjadi minim.

Hingga saat ini banyak penelitian mengenai prediksi harga saham yang menerapkan berbagai algoritma pembelajaran mesin yang berbeda. Salah satu algoritma yang sedang banyak digunakan untuk memprediksi harga saham adalah

Long Short-Term Memory (LSTM). Beberapa penelitian telah membuktikan bahwa algoritma LSTM efektif dan akurat dalam memprediksi harga saham jangka panjang, karena kemampuannya dalam menangkap pola pada data deret waktu [4]. Diantaranya adalah penelitian A. Rosyd, A. Irma Purnamasari, and I. Ali (2024), hasil prediksi memperlihatkan tingkat akurasi yang tinggi dengan nilai MAPE sebesar 0.71%, RMSE sebesar 40.85, dan MSE sebesar 6662.76 [5]. Penelitian lainnya yaitu penelitian Putra, Daffa Khalish Hardy (2024) di mana hasil menunjukkan model LSTM lebih unggul dalam memprediksi saham Alfamidi dibandingkan model ARIMA dengan menghasilkan RMSE terendah sebesar 15,00, dan akurasi tertinggi sebesar 99.5% [6]. Penelitian-penelitian tersebut menyarankan untuk mengekplorasi model LSTM lebih lanjut pada saham-saham yang lain, guna memastikan bahwa model tidak hanya unggul dalam memprediksi saham tertentu. Oleh karena itu, peneliti berencana melakukan eksplorasi model LSTM lebih lanjut pada saham PT Astra Internasional Tbk (ASII.JK). Diharapkan penelitian ini dapat membangun model LSTM yang juga memberikan prediksi akurat, dan dapat memperkuat posisi LSTM sebagai model yang andal dalam memprediksi harga saham.

Penelitian akan dilakukan dengan menggunakan data historis harga saham ASII.JK yang ditarik dari *website* resmi *Yahoo Finance* menggunakan *library* yfinance. Variabel yang akan digunakan sebagai *input* berupa Harga Pembuka (*Open Price*), Harga Tertinggi (*High Price*), Harga Terendah (*Low Price*), Harga Penutup (*Close Price*), dan Volume. Sedangkan variabel yang akan dijadikan target adalah harga penutupan saham (*Close*) dihari berikutnya. Peneliti memilih menggunakan saham PT Astra Internasional karena saham ini memiliki *market cap* yang besar, sehingga berpengaruh di pasar modal Indonesia. Hal itu menjadikan sahamnya menarik untuk diprediksi dalam rangka memahami tren ekonomi yang lebih luas. Penelitian ini akan menghasilkan model prediksi yang akan dievaluasi menggunakan nilai *Mean Absolute Percentage Error* (MAPE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Error* (MAE) untuk mengukur tingkat keakuratannya dalam memprediksi harga saham. Ketiga metrik evaluasi ini dipilih karena paling sering digunakan [7].

1.2 Rumusan Masalah

Berdasar pada latar belakang yang telah diuraikan sebelumnya, permasalahan yang menjadi fokus dalam penelitian ini yaitu :

1. Bagaimana pengimplementasian algoritma LSTM dalam membangun model prediksi untuk memprediksi harga saham ASII.JK?
2. Bagaimana performa model LSTM yang telah dibangun dalam memprediksi harga saham ASII.JK?

1.3 Batasan Masalah

Beberapa batasan masalah yang membuat penelitian memiliki ruang lingkup yang jelas diantaranya :

1. Penelitian ini hanya berpusat pada penerapan model LSTM.
2. Penelitian ini hanya menggunakan data historis harga saham ASII.JK.
3. Penelitian ini hanya mengambil data historis harga saham ASII.JK dari *website* resmi *Yahoo Finance*, dan hanya menggunakan data sejak 31 Oktober 2019 hingga 31 Oktober 2024.
4. Penelitian ini hanya akan menilai akurasi prediksi model LSTM menggunakan nilai MAPE, RMSE, dan MAE sebagai ukuran utama kinerja model.
5. Penelitian ini hanya akan melakukan prediksi harga saham 7 hari ke depan sejak tanggal 31 Oktober 2024 sebagai bentuk nyata pengaplikasian model dalam memprediksi harga saham.
6. Hasil penelitian ini hanya terbatas pada analisis performa model berdasarkan dataset dan rentang waktu tertentu.

1.4 Tujuan Penelitian

Mengacu pada rumusan masalah, tujuan penelitian ini adalah :

1. Untuk mengimplementasikan algoritma LSTM pada model prediksi harga saham ASII.JK.
2. Untuk mengevaluasi kinerja model LSTM yang telah dibangun dengan mengukur tingkat akurasinya menggunakan metrik evaluasi MAPE, RMSE, dan MAE.

1.5 Manfaat Penelitian

Beberapa manfaat yang didapat dari penelitian ini antara lain :

1. Berkontribusi dalam pengembangan model prediksi harga saham, khususnya dalam penerapan algoritma LSTM.
2. Menambah pertimbangan investor dalam mengambil keputusan investasi saham agar dapat meminimalisir risiko dan memaksimalkan keuntungan.
3. Dapat digunakan sebagai dasar pengembangan aplikasi prediksi saham.

1.6 Sistematika Penulisan

Sistematika penulisan pada penelitian ini mencakup lima bab, dimulai dengan Bab I Pendahuluan yang menguraikan latar belakang penelitian, rumusan masalah, tujuan, manfaat, serta batasan-batasan masalah yang mendefinisikan fokus pada studi ini. Kemudian Bab II Tinjauan Pustaka yang menyajikan dasar teori yang mendasari penelitian, diantaranya mencakup teori, model, dan penelitian terdahulu yang relevan untuk mengidentifikasi *research gap* dan kontribusi yang diusulkan. Bab III Metodologi Penelitian yang berisi rincian pendekatan penelitian mulai dari pengumpulan data hingga proses analisis. Lalu Bab IV Hasil dan Pembahasan yang memaparkan hasil penelitian, analisis data, dan interpretasi dari temuan-temuan yang dicapai, serta mengaitkan hasilnya dengan rumusan masalah dan tujuan penelitian. Terakhir adalah Bab V Kesimpulan dan Saran yang berisi rangkuman temuan utama dan evaluasi dari hasil model serta saran-saran untuk penelitian lanjutan, perbaikan metode, ataupun penerapan praktis dari hasil penelitian.

BAB 2

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Tabel 1 merangkum beberapa penelitian terdahulu yang berkaitan dengan topik penelitian ini.

Tabel 1 Penelitian Terkait

No	Nama dan Tahun	Judul	Subjek	Hasil
1	Abdul Rosyd, Ade Irma Purnamasari, dan Irfan Ali (2024) [5]	Penerapan Metode <i>Long Short-Term Memory</i> (LSTM) dalam Memprediksi Harga Saham PT Bank BCA	Saham BCA (Low)	LSTM efektif dalam menganalisis dan memprediksi pergerakan harga saham dengan nilai MAPE sebesar 0.71%, RMSE sebesar 40.85, dan MSE sebesar 6662.76.
2	Putra dan Daffa Khalish Hardy (2024) [6]	Analisis Perbandingan Model Prediksi Harga Saham melalui LSTM dan ARIMA	Saham AMRT dan MIDI (Close)	LSTM lebih akurat dengan RMSE terendah 15,00 dan akurasi 99.5% untuk saham Alfamidi.
3	Julian, Roby, dan Muhammad Rizky Pribadi (2021) [8]	Peramalan Harga Saham Pertambangan pada BEI Menggunakan <i>Long Short-Term Memory</i> (LSTM)	Saham ANTM, TINS, INCO (Close)	RMSE terkecil: TINS (31.76 pada epoch 200), RMSE terbesar: INCO (139.67 pada epoch 50).

No	Nama dan Tahun	Judul	Subjek	Hasil
4	Budiprasetyo, Gunawan, Mamluatul Hani'ah, dan Darin Zahira Aflah (2023) [9]	Prediksi Harga Saham Syariah Menggunakan Algoritma <i>Long Short-Term Memory</i> (LSTM)	Saham ANTM, ERAA, KLBF, SMGR, WIKA	MAPE terbaik: KLBF (1.51%), SMGR (1.83%), ERAA (2.24%). LSTM menghasilkan prediksi akurat pada berbagai pola <i>time step</i> dan <i>epoch</i> .
5	Kwanda, Kevin, Dyah Erny Herwindiati, dan Manatap Dolok Lauro (2024) [10]	Perbandingan LSTM dan <i>Bidirectional LSTM</i> pada Sistem Prediksi Harga Saham Berbasis <i>Website</i>	Saham PT BRI (Persero) Tbk, PT Adaro Energy Indonesia Tbk, PT BCA Tbk, PT Aneka Tambang Tbk, dan PT Timah Tbk, PT Bank Mandiri (Persero) Tbk.,	Model LSTM menunjukkan kinerja yang sedikit lebih baik dibandingkan dengan model BiLSTM dalam memprediksi harga saham PT Bank Rakyat Indonesia (BBRI), dengan perbedaan sekitar 0,14% pada nilai MAPE dan 0,0009 pada nilai MAE.
6	Arfan, Adhib, dan Lussiana ETP. (2020) [11]	Perbandingan Algoritma <i>Long Short-Term Memory</i> dengan SVR pada Prediksi Harga Saham di Indonesia	Saham UNVR.JK, KAEF.JK, dan GGRM.JK	LSTM berhasil memprediksi harga saham untuk periode 2017–2019 dengan akurasi yang tinggi dan tingkat <i>error</i> yang rendah, serta menunjukkan nilai <i>loss</i> yang lebih unggul dibandingkan algoritma SVR.

Dari penelitian-penelitian terdahulu yang disajikan pada Tabel 1, dapat dilihat bahwa algoritma *Long Short-Term Memory* (LSTM) secara konsisten menunjukkan performa yang unggul dalam melakukan prediksi harga saham. Penelitian-penelitian tersebut mendukung pemilihan algoritma LSTM sebagai algoritma yang akan diimplementasikan dalam pembangunan model prediksi pada penelitian ini. Diharapkan penelitian ini dapat memberikan hasil yang sebanding atau lebih baik dari penelitian-penelitian sebelumnya.

2.2 Keterkaitan Penelitian

Penelitian kali ini memiliki keterkaitan dengan penelitian-penelitian terdahulu yang juga menerapkan algoritma *Long Short-Term Memory* (LSTM) dalam melakukan prediksi harga saham. Namun penelitian ini memperluas penerapan algoritma LSTM dalam memprediksi harga saham PT Astra Internasional Tbk (ASII.JK) yang belum banyak dibahas dalam literatur sebelumnya. Dengan mengimplementasikan dua lapisan LSTM dan evaluasi menyeluruh menggunakan metrik evaluasi MAPE, RMSE, dan MAE, penelitian ini diharapkan dapat berkontribusi dalam menambah wawasan baru mengenai penerapan LSTM serta menambah perspektif baru terhadap prediksi harga saham pada sektor otomotif.

2.3 PT Astra Internasional Tbk (ASII.JK)

PT Astra Internasional adalah salah satu perusahaan terbesar di industri otomotif di Indonesia. Perusahaan multinasional ini didirikan pada tahun 1957, kegiatannya berada di berbagai kota di Indonesia dengan total lebih dari 200 anak perusahaan, mitra dan usaha patungan, serta lebih dari 200.000 karyawan [12]. Kinerja saham PT Astra Internasional Tbk (ASII.JK) pada kuartal III tahun 2024 cukup baik dengan kenaikan pendapatan sebesar 2,2% menjadi Rp246,3 triliun dan kenaikan laba bersih sebesar 0,63% menjadi Rp25,85 triliun apabila dibandingkan dengan periode yang serupa pada tahun sebelumnya [13]. Pergerakan saham ASII cukup stabil di rentang Rp4.900 – Rp4.940 dengan volume harian 17,9 juta per lembar [14]. Namun harga tersebut menunjukkan penurunan sebesar 8,44% dalam setahun kemarin karena adanya fluktuasi pasar dan tantangan sektor otomotif [15]. Saham ASII yang mencerminkan industri otomotif Indonesia dan merupakan perusahaan

yang berpengaruh di pasar modal Indonesia, membuat saham ini penting untuk dijadikan studi kasus.

2.4 Prediksi Harga Saham

Prediksi harga saham adalah proses yang melibatkan analisis dan penentuan nilai harga suatu saham. Prosesnya sering dilakukan dengan memprediksi harga numerik atau memprediksi arah harga. Dalam prediksi harga numerik, untuk memprediksi harga sebenarnya dari suatu saham digunakan model pembelajaran seperti regresi, sedangkan dalam prediksi arah harga, digunakan model pembelajaran seperti *classifier* dalam memprediksi arah naik turunnya pergerakan harga saham [16].

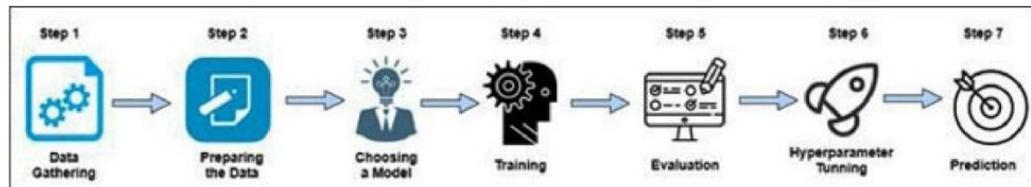
Saham sendiri merupakan instrumen keuangan yang menunjukkan hak milik individu maupun organisasi pada sebuah entitas bisnis. Hal ini berarti setiap investor saham memiliki bagian dari suatu perusahaan tersebut. Berdasarkan sejumlah karya ilmiah, harga saham merepresentasikan nilai sebuah perusahaan dan mencatatkan kekayaan yang dimiliki oleh perusahaan penerbitnya [5]. Saham memiliki kaitan yang searah dan berkesinambungan dengan tingkat *return* yang diharapkan dari suatu investasi, sehingga risiko yang dihadapi oleh seorang investor cukup besar [17].

Harga saham sangat fluktuatif sepanjang waktu, hal itu dipengaruhi oleh level penawaran dan permintaan pada saham itu sendiri. Selain itu, beberapa faktor lain yang juga ikut mempengaruhi perubahan harga saham menurut Ginting & Munthe pada tahun 2017 adalah laba per lembar saham, tingkat suku bunga, jumlah kas dan dividen yang dibagikan, kebijakan distribusi dividen, jumlah laba yang di peroleh, serta tingkat risiko dan imbal hasilnya [18].

2.5 Pembelajaran Mesin

Pembelajaran Mesin/*Machine Learning* merupakan cabang *Artificial Intelligent*. Teknik pembelajaran mesin mencakup beberapa bidang interdisipliner seperti matematika, statistik, jaringan saraf buatan, data mining, dan kecerdasan buatan. Pembelajaran mesin dapat dianggap sebagai suatu metode pemrograman komputer yang memanfaatkan data historis untuk membuat model, dan memungkinkan proses pembelajaran dengan tujuan mencapai performa terbaik dalam menggali

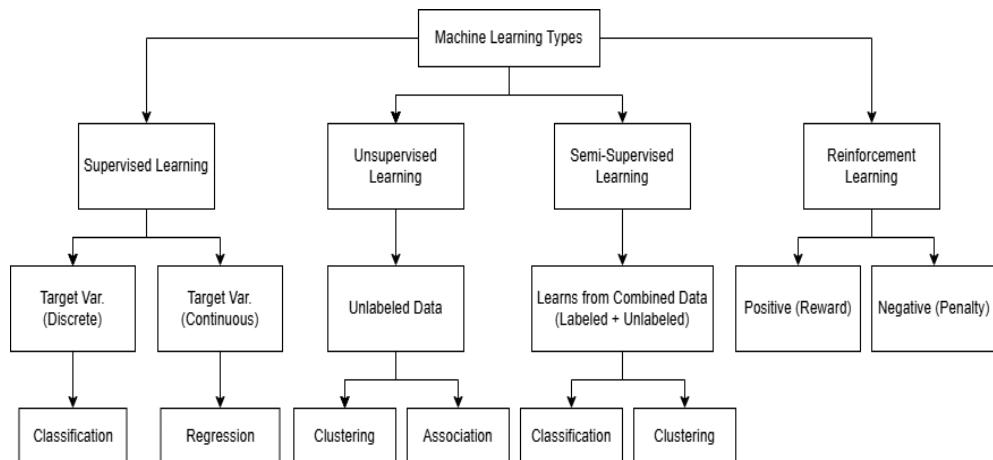
informasi dari suatu kumpulan data [3]. Terdapat 7 langkah pada proses pembelajaran mesin yang disajikan pada Gambar 1.



Gambar 1 *Steps of Machine Learning*

Sumber : [19]

Proses pembelajaran mesin didasarkan pada berbagai algoritma dalam mengatasi persoalan data. Ilmuwan data menyatakan bahwa tak ada satu pun jenis algoritma yang paling cocok untuk semua jenis masalah. Jadi, algoritma yang digunakan pada pembelajaran mesin bergantung pada jenis masalah yang ingin dipecahkan [20]. Algoritma pembelajaran mesin dibagi menjadi empat kategori, yaitu *Supervised*, *Unsupervised*, *Semi-supervised*, dan *Reinforcement* [21].

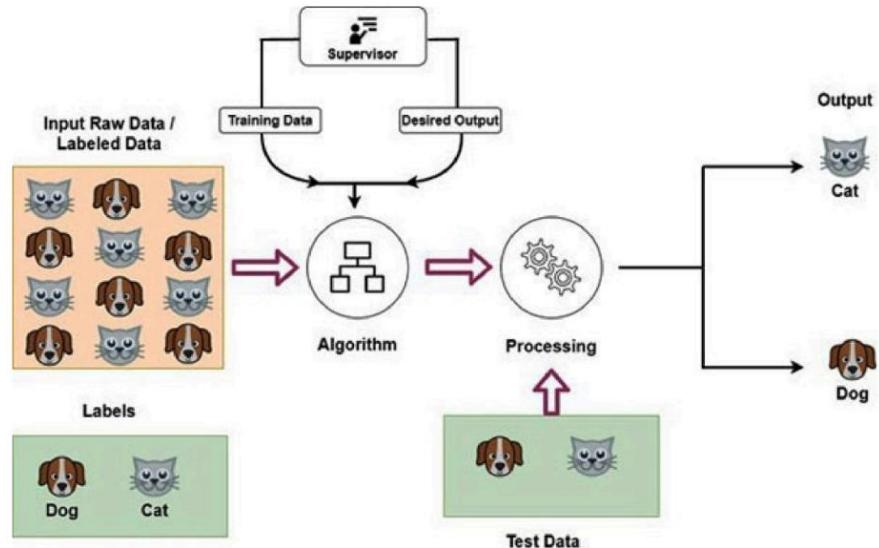


Gambar 2 Diagram Klasifikasi Teknik *Machine Learning*

a. *Supervised Learning*

Supervised Learning adalah metode pembelajaran mesin yang memetakan *input* ke *output* menggunakan data pelatihan berlabel. Tugas utamanya adalah melakukan klasifikasi dan regresi, dimana klasifikasi dilakukan untuk memisahkan data dan regresi untuk menyaring data [21]. Selama proses pelatihan, algoritma mencari pola dalam data *input* dan menghubungkannya dengan *output* yang diinginkan. Setelah dilatih,

algoritma dapat menerima data baru yang belum pernah dikenali sebelumnya dan memprediksi label atau *output* untuk data tersebut berdasarkan apa yang telah dipelajari [19].

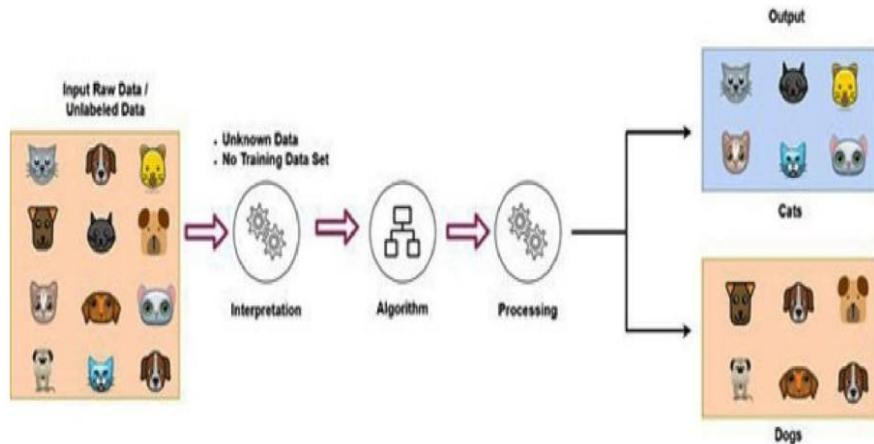


Gambar 3 *Supervised Learning*
Sumber : [19]

Gambar 3 menunjukkan kumpulan gambar kucing dan anjing yang sudah diberi label. Gambar-gambar ini beserta labelnya akan diberikan kepada model agar model dapat belajar untuk membedakan keduanya. Jika model mempelajarinya dengan baik, maka model dapat mengidentifikasi gambar baru yang tanpa label [19].

b. *Unsupervised Learning*

Unsupervised Learning adalah metode pembelajaran mesin yang digunakan untuk pengelompokan, estimasi kepadatan, pembelajaran fitur, pengurangan dimensi, aturan asosiasi, dan deteksi anomali. Metode ini menganalisis data tidak berlabel tanpa intervensi manusia [21]. Berbeda dengan *Supervised Learning*, pembelajaran ini hanya tersedia data *input* tanpa *output* yang sesuai. Dalam metode ini, pengguna tidak perlu mengarahkan atau mengawasi model, karena tidak ada jawaban benar atau panduan dari pengawas. Algoritma akan secara otomatis mempelajari data, menemukan pola, dan mengelompokkan data berdasarkan kesamaan [19].



Gambar 4 *Unsupervised Learning*
Sumber : [19]

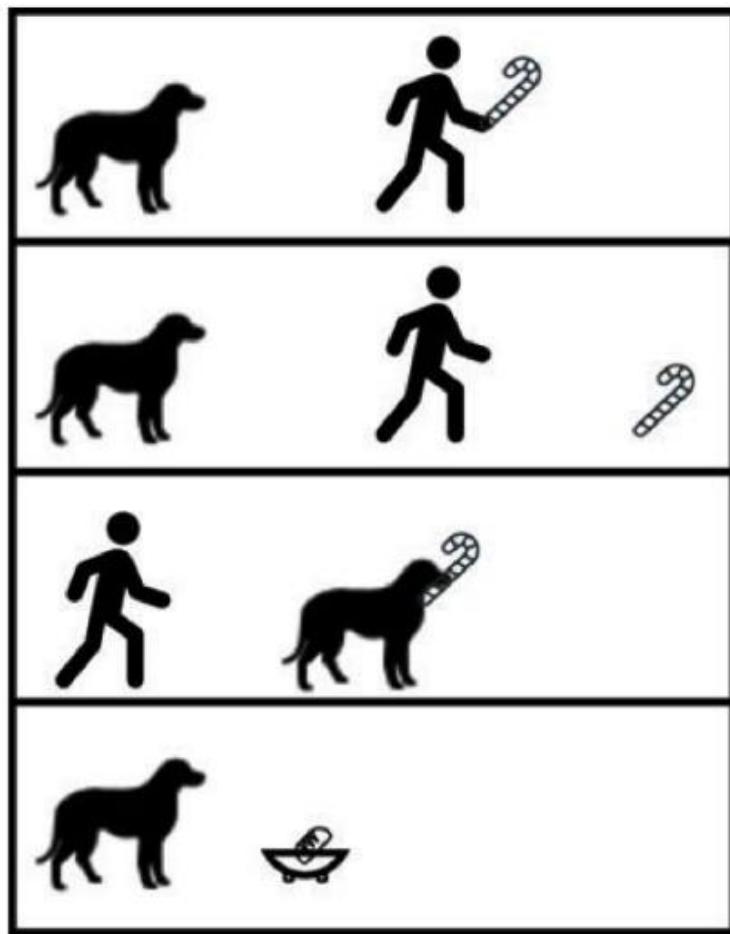
Gambar 4 menunjukkan kumpulan gambar berbagai jenis kucing dan anjing. Algoritma *Unsupervised Learning* akan mencoba memahami fitur-fitur pada gambar tersebut tanpa pelatihan sebelumnya. Tugasnya adalah mengelompokkan gambar-gambar tersebut ke dalam grup berdasarkan kesamaan yang ditemukan [19].

c. *Semi-Supervised Learning*

Semi-Supervised Learning merupakan metode gabungan antara *supervised* dan *unsupervised* yang dapat beroperasi pada data berlabel dan tidak berlabel. Metode ini bertujuan untuk meningkatkan akurasi prediksi dibandingkan jika hanya menggunakan data berlabel [21].

d. *Reinforcement Learning*

Reinforcement Learning merupakan teknik pembelajaran mesin yang memungkinkan agen *software* dan mesin secara otomatis mengevaluasi perilaku optimal dalam konteks tertentu untuk meningkatkan efisiensinya [21]. Mesin atau agen belajar sendiri melalui pengalaman tanpa memerlukan data berlabel. Dalam *Reinforcement Learning*, agen menggunakan proses coba-coba, jika agen mencoba langkah yang berhasil, maka agen akan mendapatkan hadiah, sebaliknya untuk setiap kesalahan, agen akan mendapatkan penalti [19].



Gambar 5 *Reinforcement Learning*
Sumber : [19]

Contohnya seperti pada Gambar 5, *Reinforcement Learning* diibaratkan seperti mengajari seekor anjing. Karena anjing tidak memahami bahasa manusia, maka kita menciptakan situasi dan melihat bagaimana ia merespons. Jika responnya benar, kita memberinya hadiah, seperti roti. Ketika menghadapi situasi serupa, anjing akan mengulangi tindakan yang sama untuk mendapatkan hadiah. Dari pengalaman ini, anjing belajar apa yang harus dilakukan dan menghindari respon yang menghasilkan pengalaman negatif [19]. Pembelajaran ini efektif untuk melatih model AI yang meningkatkan otomatisasi dan efisiensi dalam sistem kompleks seperti robotika, kendaraan otonom, manufaktur, dan logistik rantai pasokan [21].

2.6 Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah pengembangan dari arsitektur *Recurrent Neural Network* (RNN) yang pertama kali dikenalkan oleh Hochreiter & Schmidhuber (1997). LSTM merupakan spesial unit RNN yang dirancang untuk mengatasi masalah keterkaitan jangka panjang, di mana LSTM memiliki sistem *internal* yang dikenal sebagai *cell states* dan *gates* yang berfungsi mengatur memori untuk setiap input yang diterima. Terdapat empat jenis *gates* yaitu *forget gate*, *input gate*, *cell gate*, dan *output gate* [11]. Proses LSTM diantaranya adalah sebagai berikut : [6]

1. Inisialisasi

Inisialisasi dalam konteks LSTM merupakan tahap awal di mana sistem menyiapkan nilai-nilai awal sebelum memproses data *input* untuk dua komponen penting, yaitu *Cell State* (C_{t-1}) dan *Hidden State* (h_{t-1}). Kedua komponen tersebut diinisialisasi dengan nilai tertentu agar sistem dapat mulai memproses urutan data yang diberikan.

2. *Time Step*

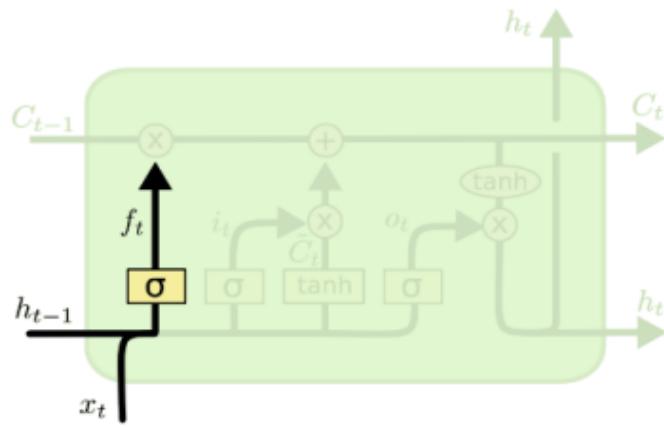
Time Step adalah proses di mana model memproses urutan data dalam langkah waktu satu per satu. Setiap *Time Step* menerima *input* baru dan informasi dari *Hidden State* sebelumnya, untuk menghasilkan prediksi atau pembaruan informasi pada langkah waktu berikutnya.

3. *Input* dan *Hidden State* Sebelumnya

Ini adalah tahap di mana model menerima dua jenis informasi pada setiap *Time Step*, yaitu *input* saat ini (x_t) dan *Hidden State* sebelumnya (h_{t-1}). *Input* saat ini merupakan data baru yang masuk pada *Time Step* saat ini, sedangkan *Hidden State* sebelumnya adalah informasi yang dibawa dari langkah waktu sebelumnya.

4. *Forget Gate*

Forget Gate adalah proses untuk menentukan informasi apa saja yang perlu dihilangkan dari *Cell State* sebelumnya (C_{t-1}). Penentuan dilakukan dengan melakukan perkalian elemen-elemen antara keluaran dari *Forget Gate* dan *Cell State* sebelumnya. Rumus *Forget Gate* dapat dilihat pada Persamaan 1.



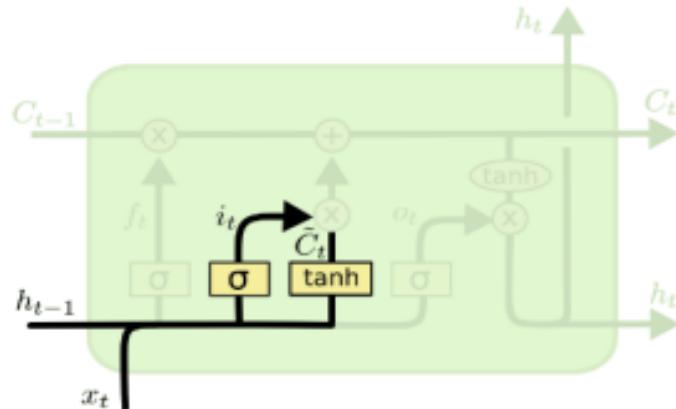
Gambar 6 *Forget Gate Layer*
Sumber : [22]

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

Proses ini memungkinkan model melupakan informasi yang tidak lagi relevan, sehingga hanya akan ada informasi penting yang digunakan dalam prediksi selanjutnya.

5. *Input Gate*

Input Gate adalah proses untuk menetapkan informasi baru apa saja yang akan dimasukkan ke dalam *Cell State*.



Gambar 7 *Input Gate Layer*
Sumber : [22]

Prosesnya melibatkan dua langkah, yaitu :

1. Penentuan nilai calon baru (\tilde{C}_t) yaitu dengan cara mengolah *input* menggunakan fungsi aktivasi \tanh . Rumusnya dapat diamati pada Persamaan 2.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

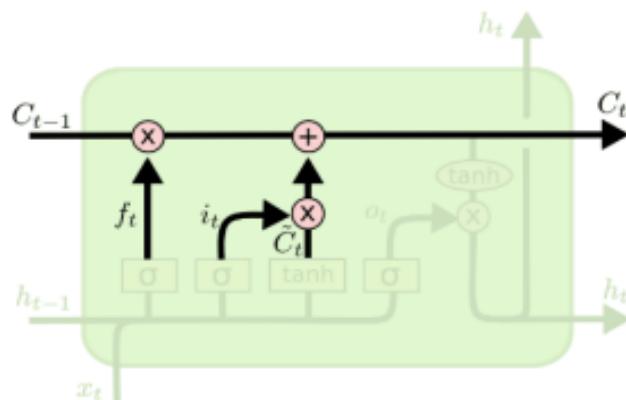
2. Melakukan perkalian antara nilai C_{t-1} dengan keluaran dari *Input Gate*. Rumus dapat dilihat pada Persamaan 3.

$$C_t = \tanh(W_c \cdot [h_{t-1} - 1, x_t] + b_c) \quad (3)$$

Proses ini memungkinkan model untuk menyesuaikan informasi relevan yang perlu disimpan dan dipelajari.

6. Pembaruan *Cell State*

Pembaruan *Cell State* adalah proses di mana *Cell State* yang baru, dihitung dengan menjumlahkan hasil dari *Forget Gate* dan *Input Gate*. Rumus pembaruan *Gate* dapat dilihat pada Persamaan 4.



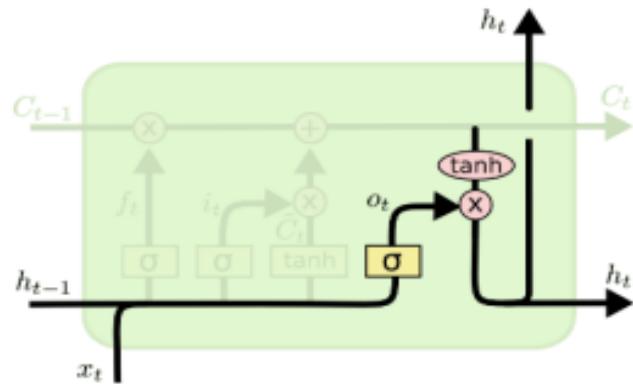
Gambar 8 Pembaruan *Gate Layer*
Sumber : [22]

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

Pembaruan ini memungkinkan model mempertahankan data yang relevan dan menghapus data yang tidak relevan, sehingga model dapat mempelajari pola dalam data sekuensial.

7. *Output Gate*

Output Gate adalah proses menetapkan nilai *Hidden State* yang diperoleh pada *Time Step* saat ini.

Gambar 9 *Output Gate Layer*

Sumber : [22]

Prosesnya terdiri dari dua langkah, yaitu :

1. Penentuan nilai *Hidden State* baru (h_t) yaitu dengan cara mengolah *Cell State* yang sudah diperbarui menggunakan fungsi aktivasi \tanh .
2. Melakukan perkalian antara nilai hasil dengan keluaran dari *Output Gate* dengan rumus pada Persamaan 5.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

Hidden State yang dihasilkan oleh *Output Gate* ini berfungsi sebagai *output* model untuk *Time Step* tersebut, dan akan digunakan sebagai *input* untuk *Time Step* berikutnya.

8. *Output* dan *Hidden State*

Output dan *Hidden State* adalah proses di mana model LSTM menghasilkan dua komponen penting setelah memproses *input* pada *Time Step* tertentu, yaitu hasil keluaran LSTM pada *Time Step* saat ini (y_t) dan *Hidden State* yang telah diperbarui (h_t). Rumus pembaruan *Hidden Cell* dapat dilihat pada Persamaan 6.

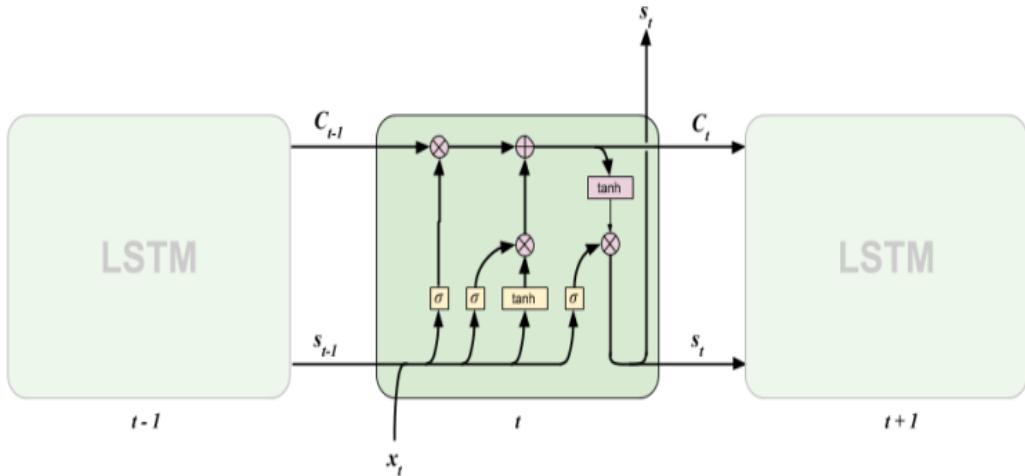
$$h_t = o_t * \tanh(C_t) \quad (6)$$

Proses ini berfungsi untuk menghasilkan hasil pada *Time Step* tersebut dan mempertahankan informasi penting untuk proses prediksi selanjutnya.

9. Iterasi

Iterasi adalah proses pengulangan langkah-langkah pemrosesan pada setiap *Time Step* hingga seluruh urutan data selesai diproses.

Gambar 10 merupakan arsitektur LSTM yang memberikan representasi visual tentang cara kerja *output gate*, *input gate*, dan *forget gate* yang memungkinkan sel mempertahankan informasi penting sambil mengatur arus informasi [23].



Gambar 10 Arsitektur Model LSTM
Sumber :[8]

2.7 Python

Python tumbuh dari bahasa yang disebut ABC, yang dikembangkan di Belanda pada tahun 1980-an sebagai alternatif untuk BASIC. Bahasa ini dirancang untuk membantu para ilmuwan memanfaatkan mikrokomputer, yang merupakan teknologi baru pada saat itu. Python adalah bahasa pemrograman yang bekerja dengan cara ditafsirkan, berbeda dengan bahasa pemrograman seperti C atau FORTRAN yang memerlukan proses kompilasi. Dalam python, kode hanya bisa dijalankan jika ada interpreter Python yang aktif. Interpreter ini berfungsi sebagai penghubung antara kode program dan sistem tempat program tersebut dijalankan. Tugasnya adalah menerjemahkan instruksi dari kode Python agar bisa dipahami dan dijalankan oleh sistem, sekaligus dapat menangani hal-hal teknis terkait *platform* tersebut [24].

2.8 Min-Max Scaler Normalization

Normalisasi merupakan teknik yang digunakan untuk menjamin bahwa semua data memiliki ukuran yang sama. Teknik normalisasi *Min-Max Scaler* menjadi salah satu normalisasi terbaik untuk meningkatkan kinerja pengklasifikasian [25].

Normalisasi *Min-Max Scaler* sangat berguna dalam mengatasi masalah pada data berdimensi tinggi. *Min-Max Scaler* sendiri adalah metode normalisasi yang mengubah semua nilai menjadi rentang 0 hingga 1. Proses normalisasinya dapat dilihat pada Persamaan 7 dan 8 [26].

$$X_{std} = \frac{(x - x.\min)}{(x.\max - x.\min)} \quad (7)$$

Keterangan :

X_{std} = Hasil normalisasi terhadap data x

x = Data x

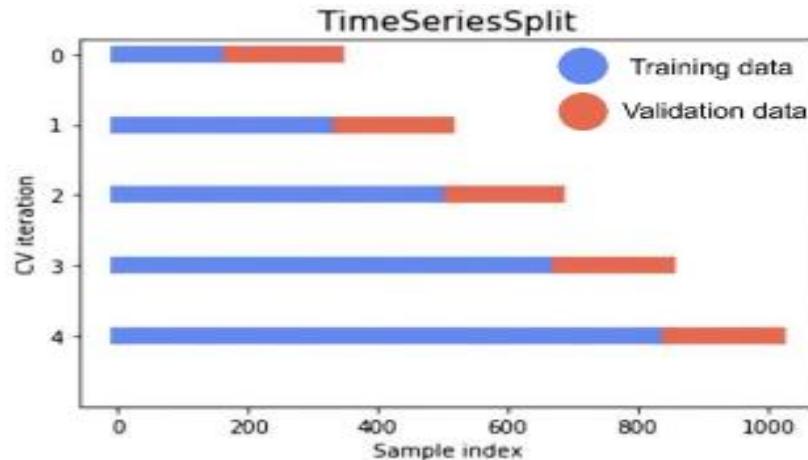
$x.\min$ = Data minimum yang terdapat pada x

$x.\max$ = Data maximum yang terdapat pada x

Dengan menerapkan teknik normalisasi *Min-Max Scaler*, data yang memiliki rentang nilai sangat berbeda dapat diselaraskan menjadi skala yang seragam.

2.9 TimeSeriesSplit Cross Validation

TimeSeriesSplit Cross Validation merupakan metode validasi yang banyak digunakan dalam analisis data *time series* untuk mempertahankan keteraturan temporal data. Metode ini membagi data *time series* menjadi beberapa lipatan (*fold*) dengan tetap menjaga urutan waktu [27]. Pada setiap lipatan, ukuran data pelatihan bertambah seiring bertambahnya waktu. Namun, kondisi ini dapat menyebabkan *hyperparameter* yang optimal pada lipatan kecil menjadi kurang sesuai untuk seluruh dataset. Untuk mengurangi dampaknya, dapat diberikan bobot berbentuk linier, kuadratik, atau pola lain pada setiap lipatan berdasarkan ukuran data latihnya, agar lipatan dengan data latih lebih besar memiliki pengaruh lebih besar dalam pemilihan model [28].



Gambar 11 *TimeSeriesSplit Cross Validation*
Sumber : [28]

2.10 MAPE, RMSE, dan MAE

Mean Absolute Percentage Error (MAPE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Error* (MAE) merupakan metrik evaluasi yang paling sering digunakan [7], yang dimanfaatkan untuk mengetahui hasil kerja model. MAPE mengukur persentase rata-rata kesalahan prediksi, di mana semakin kecil nilainya maka semakin baik kinerja modelnya. Formula MAPE dapat dilihat pada Persamaan 9 [5].

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{test} - predictions}{y_{test}} \right| \times 100 \quad (8)$$

Untuk kriteria penilaianya menurut Chang et al. (2007), terbagi menjadi 4 kategori yang disajikan pada Tabel 2 [29].

Tabel 2 Kriteria Penilaian MAPE

Nilai MAPE	Akurasi Prediksi
< 10%	Sangat baik
10% - 20%	Baik
20% - 50%	Cukup
>50%	Buruk

RMSE mengevaluasi sejauh mana model mampu memprediksi nilai yang sebenarnya, semakin rendah nilainya maka semakin baik kualitas prediksinya. Formula RMSE dapat dilihat pada Persamaan 10 [5].

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{test} - predictions)^2} \quad (9)$$

Menurut Normah et.al. tahun 2022, semakin rendah nilai RMSE maka hasil prediksi dianggap semakin baik [30].

MAE mengambil nilai absolut pada setiap nilainya untuk menghilangkan nilai-nilai negatif. Untuk mengevaluasi model prediksi, MAE memberikan gambaran rata-rata error dari keseluruhan data secara intuitif [31]. Formula MAE dapat dilihat pada Persamaan 11.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_{test} - predictions| \quad (10)$$

Menurut Suryanto (2019), kemampuan model dalam melakukan prediksi juga dianggap semakin baik jika nilai MAE semakin kecil [30].

BAB III

METODOLOGI

3.1 Jenis Penelitian dan Sumber Data

Penelitian ini mengaplikasikan pendekatan kuantitatif dengan metode yang melibatkan pemrosesan angka dan algoritma matematis pada data historis saham PT Astra Internasional Tbk (ASII.JK). Peneliti memilih pendekatan ini untuk mengembangkan dan menerapkan berbagai model sistematis, teori, dan hipotesis yang terkait dengan fenomena yang sedang berlangsung.

Data yang dipakai dalam studi ini termasuk kategori data sekunder yang didapat dari *website* resmi *Yahoo Finance*, berupa data historis harga saham ASII.JK sejak tanggal 31 Oktober 2019 sampai dengan 31 Oktober 2024. Variabel yang dimanfaatkan dalam studi ini diantaranya adalah Harga Pembuka (*Open Price*), Harga Tertinggi (*High Price*), Harga Terendah (*Low Price*), Harga Penutup (*Close Price*), dan Volume [32].

3.2 Perangkat dan Sumber Daya Penelitian

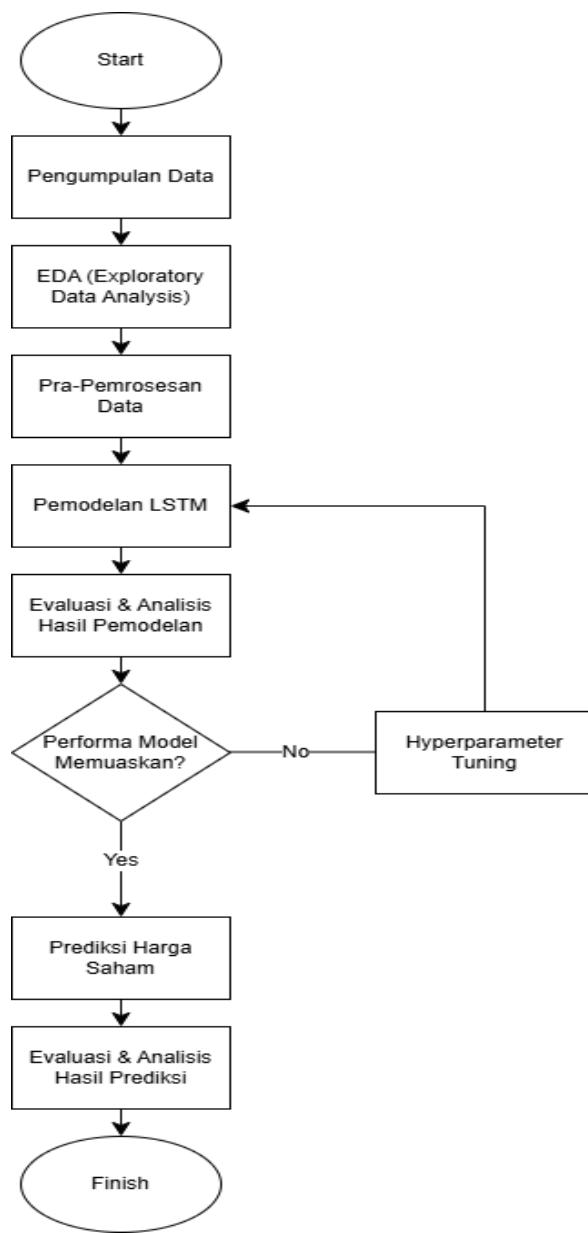
Dalam penelitian ini, berbagai perangkat dan sumber daya digunakan untuk mendukung proses penelitian mulai dari analisis data hingga implementasi model prediksi. Tabel 3 merangkum semua perangkat dan sumber daya yang dimanfaatkan dalam penelitian ini.

Tabel 3 Perangkat dan Sumber Daya

Jenis	Detail
Laptop	VivoBook ASUS X415MA_A416MA dengan prosesor Intel Celeron N4020 CPU @ 1.10 GHz, RAM 4 GB, sistem operasi 64-bit, x64-based processor.
Python	Versi 3.10.0
TensorFlow/Keras	Versi 2.10.0
Scikit-learn	Versi 1.4.2

3.3 Alur Penelitian

Penelitian ini mengawali prosesnya melalui pengumpulan data yang dilanjutkan dengan proses *Exploratory Data Analysis* (EDA), dan pra-pemrosesan data. Kemudian tahap pemodelan akan dilakukan dimana model LSTM akan dilatih sebelum akhirnya di evaluasi dan dianalisis. Setelah performa model dirasa sudah optimal, akan dilakukan prediksi harga saham untuk 7 hari ke depan sejak tanggal 31 Oktober 2024 untuk melihat sejauh mana model mampu memprediksi data baru yang belum pernah diproses sebelumnya. Gambar 12 adalah gambaran mengenai tahap-tahap yang akan dilalui pada penelitian ini.



Gambar 12 Alur Penelitian

3.4 Pengumpulan Data

Proses pengumpulan data dimulai dengan mengakses data historis harga saham ASII.JK di *Yahoo Finance* sejak tanggal 31 Oktober 2019 sampai dengan 31 Oktober 2024 menggunakan *library yfinance*. Penelitian ini berfokus pada penggunaan variabel Harga Pembuka (*Open Price*), Harga Tertinggi (*High Price*), Harga Terendah (*Low Price*), Harga Penutup (*Close Price*), dan Volume sebagai input [32]. Variabel ‘*Close*’ di sini akan berperan ganda, yaitu digunakan juga sebagai target untuk memprediksi harga penutupan saham di hari - hari berikutnya [33].

3.5 Exploratory Data Analysis (EDA)

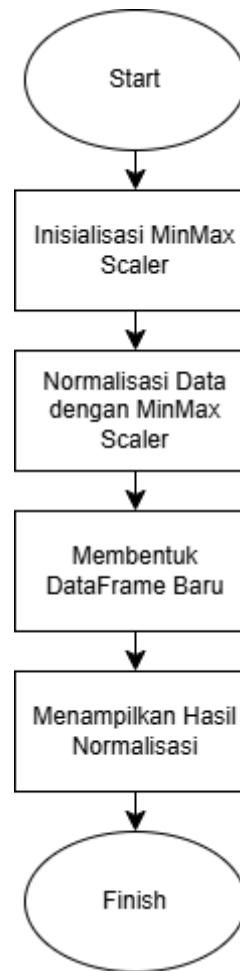
Proses *Exploratory Data Analysis* (EDA) dilakukan untuk memahami karakteristik data harga saham sebelum model *machine learning* diterapkan. Dengan melakukan proses ini, kita dapat mengetahui apakah semua data yang digunakan memang diperlukan, dan apakah fitur yang kita pilih sudah cukup baik untuk dapat digunakan dalam model [34]. Pada penelitian ini, proses EDA yang dilakukan diantaranya adalah menghitung ringkasan statistik data harga saham ASII.JK untuk memahami karakteristik dasar data, memvisualisasikan distribusi data dari setiap fitur untuk mengidentifikasi potensi *outlier*, memvisualisasikan tren harga saham untuk memahami pergerakan harga saham, dan melihat korelasi antar fitur untuk mengidentifikasi hubungan linier antar variabel.

3.6 Pra-Pemrosesan Data

Pada tahap pra-pemrosesan data, data akan diolah agar memiliki format yang sesuai, menghilangkan potensi bias dalam skala fitur, serta membentuk struktur yang sesuai untuk model LSTM yang akan diterapkan. Beberapa langkah yang akan dilakukan dalam tahap pra-pemrosesan data pada penelitian ini adalah :

3.6.1 Normalisasi Data

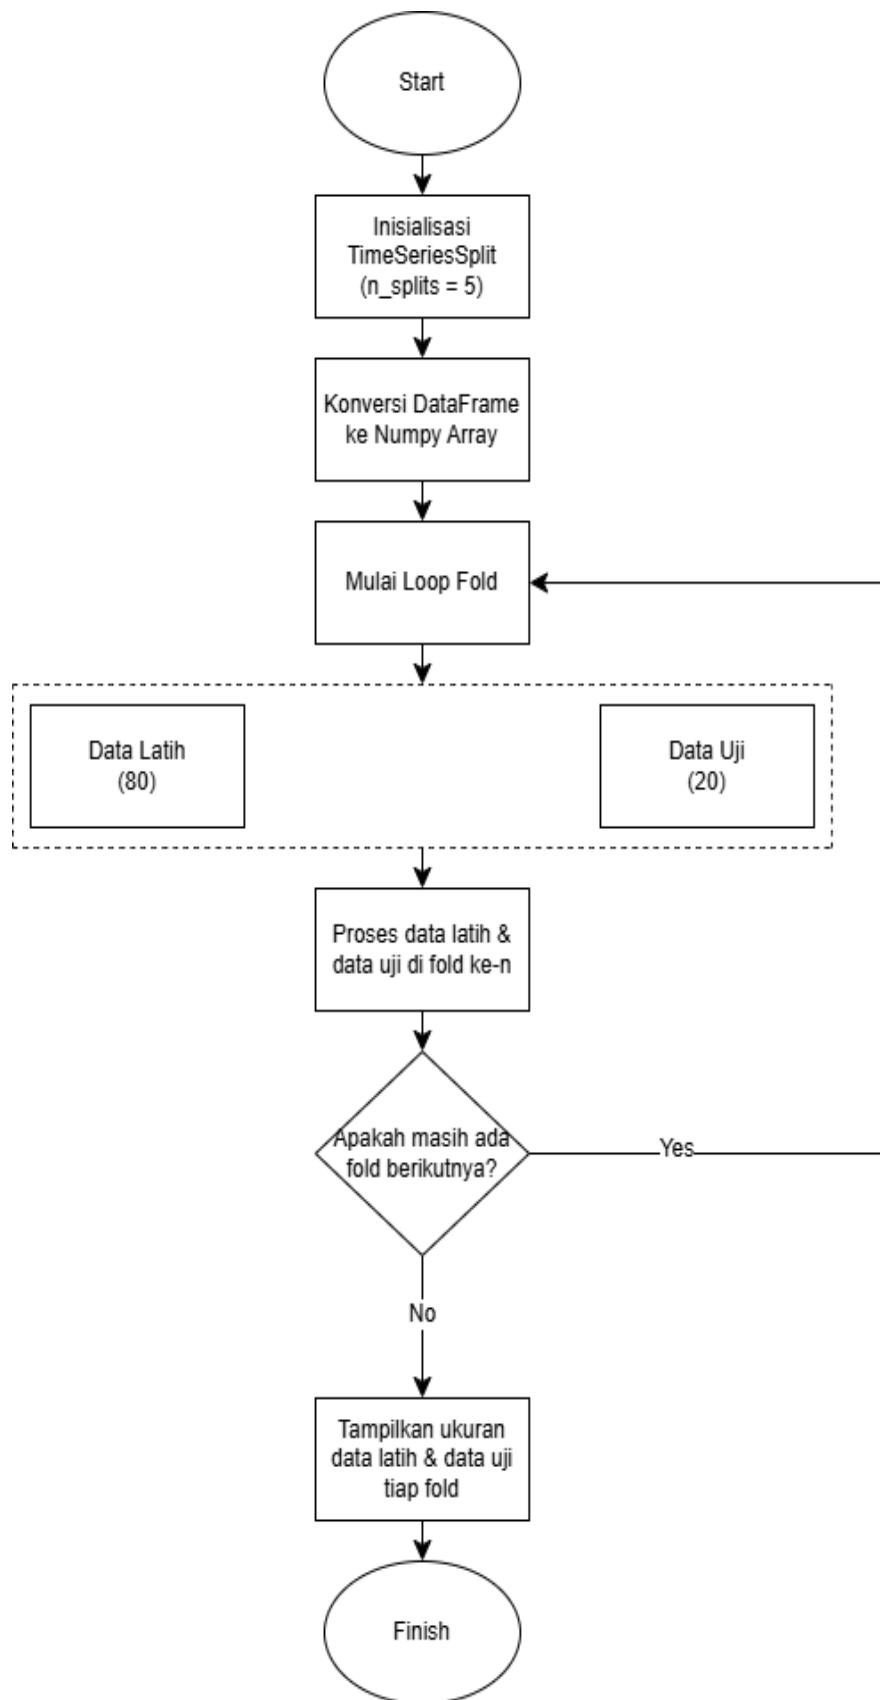
Normalisasi data akan dilakukan menggunakan teknik *MinMax Scaler* untuk menyelaraskan skala semua fitur pada rentang 0 hingga 1. Transformasi ini membuat semua fitur memiliki skala yang sebanding tanpa mengubah distribusi relatif data antar fitur.



Gambar 13 Normalisasi Data

3.6.2 Pembagian Data

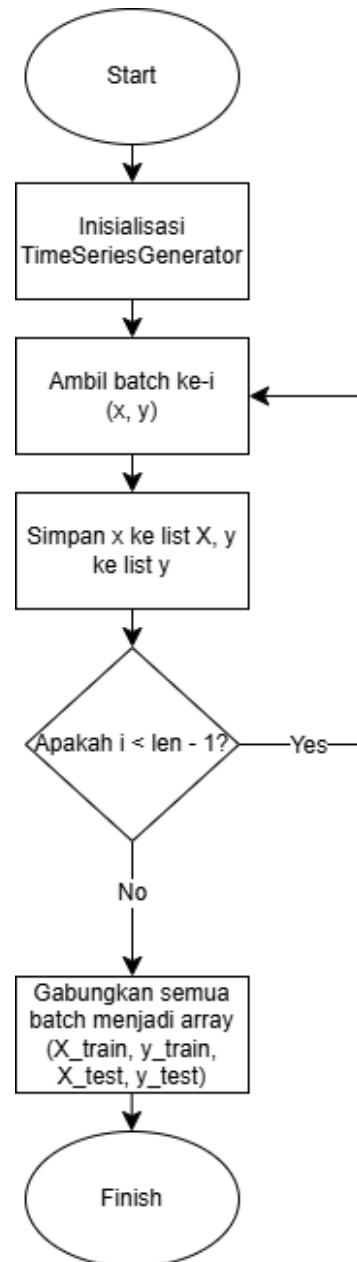
Pembagian data akan dilakukan untuk memisahkan data menjadi data latih (*training set*) dan data uji (*testing set*). Data akan dibagi dengan rasio pembagian sebesar 80 (data latih) : 20 (data uji) menggunakan metode *TimeSeriesSplit Cross Validation* sebanyak 5 *fold*. Data latih akan digunakan dalam tahap pelatihan model, sedangkan data uji akan digunakan dalam tahap pengujian untuk mengevaluasi performa model dalam memprediksi harga saham ASII.JK.



Gambar 14 Pembagian Data

3.6.3 Pembentukan *Sequence* dan Target

Data perlu diubah ke dalam bentuk *sequence* (urutan waktu) karena LSTM hanya bisa memproses data dalam *sequence*. Tujuannya adalah agar model dapat mempelajari pola dari data historis harga saham secara berurutan. Proses pembentukan *sequence* akan dilakukan menggunakan *TimeSeriesGenerator* yang akan secara otomatis membagi data menjadi *sequence* sepanjang n langkah waktu tertentu dan menentukan target pada langkah ke (n+1).



Gambar 15 Pembentukan *Sequence* dan Target

3.7 Pemodelan LSTM

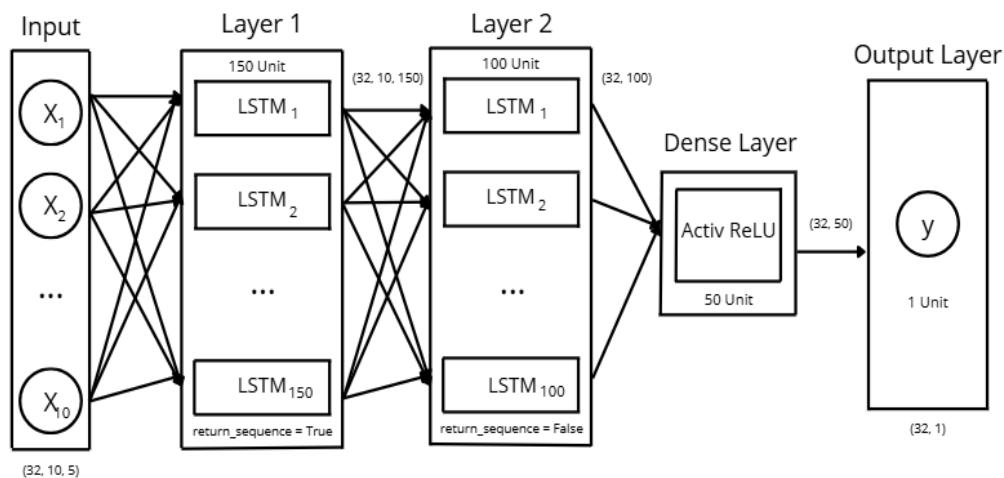
Model LSTM akan dibangun menggunakan *Sequential API* dari Keras. Data yang akan digunakan adalah data yang telah melewati tahap pra-pemrosesan data sebelumnya. Beberapa bagian dari proses pemodelan LSTM adalah :

3.7.1 Arsitektur Model

Struktur arsitektur yang akan digunakan meliputi 2 *Layer LSTM* dan 2 *Dense Layer* dengan rincian sebagai berikut :

- **LSTM Layer Pertama**, terdiri dari 150 unit neuron, *return_sequence=True*, dan *Dropout* sebesar 10%. Layer ini menggunakan fungsi aktivasi *tanh* secara *default*.
- **LSTM Layer Kedua**, terdiri dari 100 unit neuron, *return_sequence=False*, dan *Dropout* sebesar 10%.
- **Dense Layer Pertama**, terdiri dari 50 neuron dengan fungsi aktivasi ReLU.
- **Dense Layer Kedua (*Output Layer*)**, terdiri dari 1 neuron tanpa fungsi aktivasi.

Visualisasi arsitektur model LSTM yang digunakan, ditunjukkan pada Gambar 16.



Gambar 16 Arsitektur Model LSTM yang Digunakan

Gambar 16 menggambarkan alur data dari *input time series* hingga menghasilkan *output* berupa prediksi harga saham pada *output layer*.

3.7.2 Kompilasi dan Pelatihan

Model akan dikompilasi menggunakan fungsi *loss Mean Squared Error* (MSE) dan menggunakan Adam sebagai *optimizer* [5] dengan *learning rate* 0.001. Model akan dilatih menggunakan data latih selama 400 *epoch* dengan *batch size* sebesar 32. Selama proses pelatihan, model akan divalidasi menggunakan data uji untuk memantau performa model.

3.7.3 Visualisasi *Loss*

Visualisasi grafik *training loss* dan *validation loss* terhadap jumlah *epoch* juga akan ditampilkan untuk mengetahui performa pelatihan model. *Training loss* akan merepresentasikan kesalahan yang terjadi ketika model memprediksi nilai target dari data pelatihan, sedangkan *validation loss* akan menunjukkan kesalahan prediksi model terhadap data validasi yang tidak terlihat selama pelatihan. Dengan grafik ini, dapat diketahui apakah model mengalami *overfitting*, *underfitting*, atau telah mencapai kondisi pelatihan yang optimal.

3.8 Evaluasi & Analisis Hasil Pemodelan

Evaluasi & analisis dari hasil proses pemodelan akan dilakukan untuk menilai performa model dalam memprediksi harga saham. Hasil perhitungan metrik evaluasi utama berupa MAPE, RMSE, dan MAE dianalisis untuk menilai kinerja model. Jika hasil perhitungan metrik evaluasi menunjukkan nilai yang memuaskan, maka model dapat dinyatakan layak untuk digunakan dalam memprediksi harga saham ASII.JK dan dapat digunakan untuk analisis lebih lanjut. Namun jika hasil evaluasi menunjukkan bahwa performa model masih kurang optimal, maka *hyperparameter tuning* akan dilakukan untuk mengoptimalkan model dan meningkatkan hasil prediksi. Jumlah parameter akan diatur ulang dan model akan kembali di latih dan diuji hingga menghasilkan performa yang sesuai dengan yang diharapkan.

3.9 Prediksi Harga Saham

Untuk melihat sejauh mana model mampu menggeneralisasi dan memprediksi data yang benar-benar belum pernah dilihat sebelumnya, dilakukan prediksi harga

saham berdasarkan data historis terbaru yang tersedia. Proses ini dilakukan dengan mengambil n data terakhir dari data historis, mengubahnya ke dalam bentuk *sequence* untuk dijadikan input, dan memberikannya ke model LSTM untuk menghasilkan prediksi harga saham selama 7 hari ke depan sejak tanggal 31 Oktober 2024. Kemudian hasil prediksi akan diubah ke skala aslinya agar nilainya dapat dibandingkan langsung dengan harga yang sebenarnya melalui tabel perbandingan. Hasil perbandingan akan divisualisasikan melalui grafik perbandingan yang menyajikan harga aktual dan harga prediksi. Proses ini dilakukan untuk menilai kemampuan model dalam memprediksi harga saham ASII.JK dalam konteks dunia nyata.

3.10 Evaluasi & Analisis Hasil Prediksi

Hasil perbandingan antara harga aktual dan harga prediksi harga saham selama 7 hari setelah tanggal 31 Oktober 2024 akan dinilai performanya melalui perhitungan metrik evaluasi MAPE, RMSE, dan MAE. Hasil perhitungan akan dievaluasi dan dianalisis untuk menilai keandalan model dalam menghadapi data baru yang belum pernah dilihat sebelumnya. Jika hasil menunjukkan kesalahan prediksi yang rendah, maka model LSTM dapat dianggap efektif dan layak digunakan sebagai alat bantu dalam proses prediksi harga saham. Namun sebaliknya, jika hasil menunjukkan kesalahan yang tinggi, maka perlu dilakukan *hyperparameter tuning* dan pelatihan ulang pada model LSTM.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Pengumpulan Data

Data yang diambil dari website resmi *Yahoo Finance* dengan library *yfinance* mulai tanggal 31 Oktober 2019 hingga 31 Oktober 2024 terdiri dari 1212 data dengan 7 kolom berupa *Date*, *Adj Close*, *Close*, *High*, *Low*, *Open*, dan *Volume* yang dapat dilihat pada Tabel 4.

Tabel 4 Hasil Unduhan Data Historis Harga Saham ASII.JK

Date	Adj Close	Close	High	Low	Open	Volume
2019-10-31	5092.718750	6950.0	6975.0	6825.0	6950.0	26502100
2019-11-01	4982.804199	6800.0	6975.0	6725.0	6975.0	17213000
2019-11-04	4909.528320	6700.0	6825.0	6700.0	6800.0	19339100
2019-11-05	5056.080078	6900.0	6950.0	6750.0	6775.0	42041800
2019-11-06	5019.442871	6850.0	6975.0	6825.0	6975.0	29565500
...
2024-10-24	5275.000000	5275.0	5300.0	5200.0	5300.0	50777100
2024-10-25	5225.000000	5225.0	5275.0	5200.0	5275.0	27247500
2024-10-28	5250.000000	5250.0	5250.0	5125.0	5250.0	40165900
2024-10-29	5125.000000	5125.0	5250.0	5125.0	5250.0	45247600
2024-10-30	5200.000000	5200.0	5200.0	5050.0	5125.0	33200300

Karena penelitian hanya berfokus pada variabel *Close*, *High*, *Low*, *Open*, dan *Volume*, maka kolom *Adj Close* tidak akan disertakan dalam proses pemodelan. Kolom *Adj Close* dihapus untuk menyederhanakan data serta menghindari duplikasi informasi, karena kolom *Close* sendiri sudah mencerminkan harga penutupan aktual dari saham ASII.JK. Data setelah dilakukan penghapusan kolom *Adj Close* dapat dilihat pada Tabel 5.

Tabel 5 Data Historis Harga Saham ASII.JK setelah *Adj Close* Dihapus

Date	Close	High	Low	Open	Volume
2019-10-31	6950.0	6975.0	6825.0	6950.0	26502100
2019-11-01	6800.0	6975.0	6725.0	6975.0	17213000
2019-11-04	6700.0	6825.0	6700.0	6800.0	19339100
2019-11-05	6900.0	6950.0	6750.0	6775.0	42041800
2019-11-06	6850.0	6975.0	6825.0	6975.0	29565500
...
2024-10-24	5275.0	5300.0	5200.0	5300.0	50777100
2024-10-25	5225.0	5275.0	5200.0	5275.0	27247500
2024-10-28	5250.0	5250.0	5125.0	5250.0	40165900
2024-10-29	5125.0	5250.0	5125.0	5250.0	45247600
2024-10-30	5200.0	5200.0	5050.0	5125.0	33200300

4.2 Exploratory Data Analysis (EDA)

4.2.1 Ringkasan Statistik

Perhitungan ringkasan statistik data saham ASII.JK yang mencakup jumlah data, rata-rata, minimum, maksimum, standar deviasi, dan nilai Q1, Q2, dan Q3 dapat dilihat pada Tabel 6.

Tabel 6 Hasil Perhitungan Ringkasan Statistik Data Saham ASII.JK

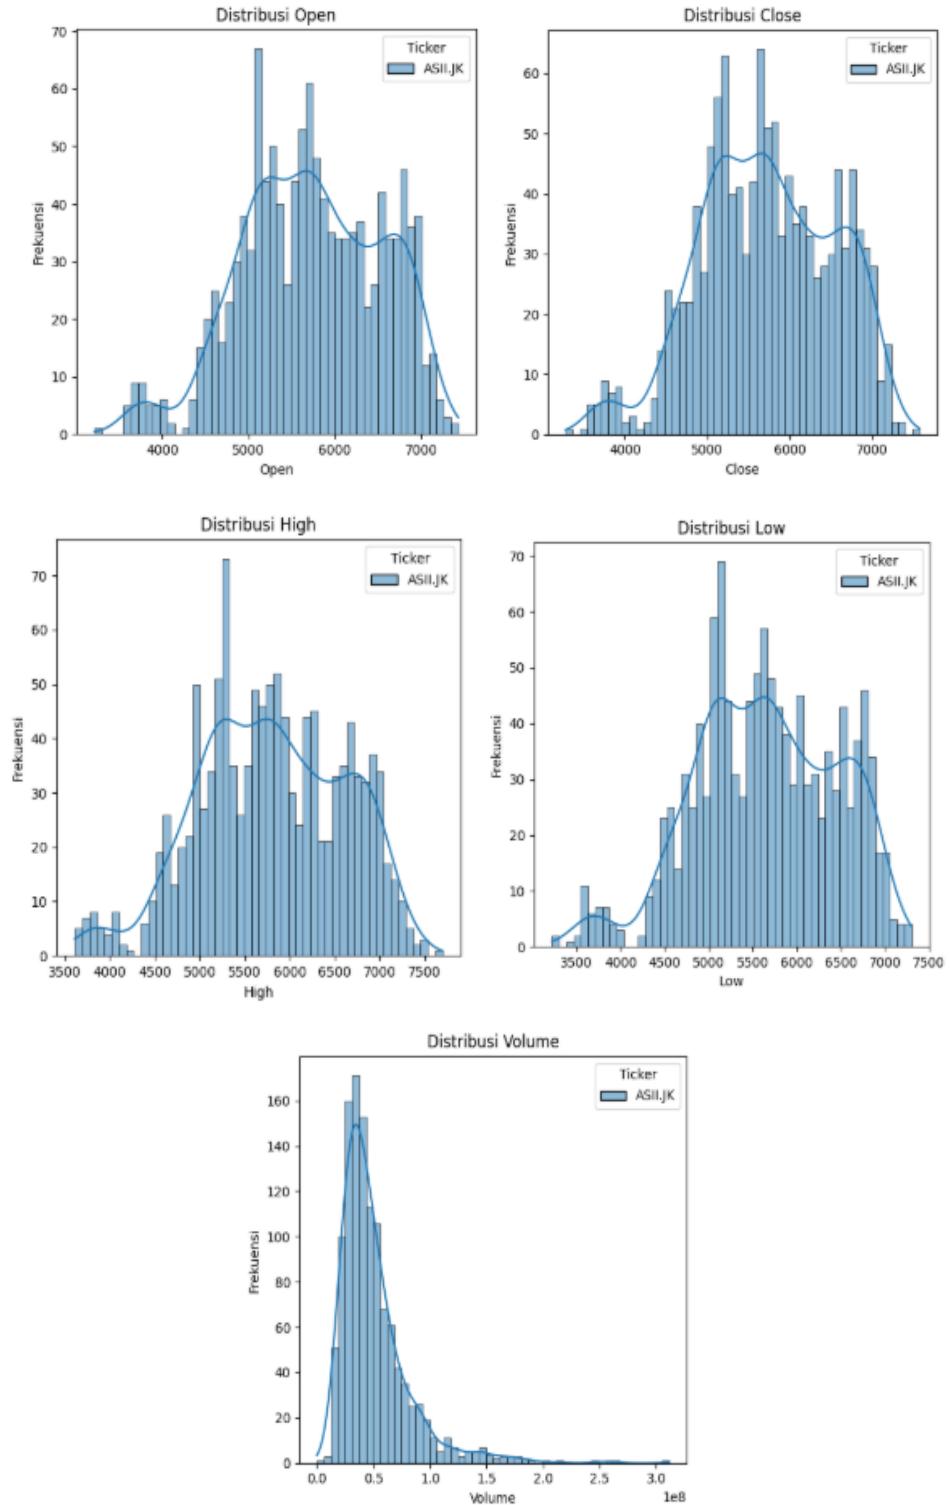
	<i>Close</i>	<i>High</i>	<i>Low</i>	<i>Open</i>	<i>Volume</i>
count	1212.00000	1212.000000	1212.000000	1212.000000	1.212000e+03
mean	5712.89604	5789.434818	5642.301980	5722.537129	5.071528e+07
std	806.53774	807.384599	801.119019	804.578108	3.208633e+07
min	3280.00000	3610.000000	3220.000000	3220.000000	0.000000e+00
25%	5150.00000	5225.000000	5075.000000	5150.000000	3.060080e+07
50%	5700.00000	5775.000000	5650.000000	5700.000000	4.236680e+07
75%	6350.00000	6450.000000	6300.000000	6375.000000	6.034048e+07
max	7575.00000	7700.000000	7300.000000	7425.000000	3.114024e+08

Berdasarkan hasil perhitungan ringkasan statistik data saham ASII.JK diatas, disimpulkan bahwa harga saham ASII.JK pada periode 31 Oktober 2019 hingga 31 Oktober 2024 menunjukkan pola pergerakan yang cukup stabil dengan fluktuasi yang moderat. Hal ini ditunjukkan oleh nilai rata-rata pada harga *Close*, *Open*, *High*, dan *Low* yang berada pada kisaran angka 5600 hingga 5800, dan standar deviasi yang berada pada kisaran 800-an, menandakan adanya pergerakan harga yang dinamis namun masih dalam rentang yang wajar. Median dari harga saham juga relatif dekat dengan nilai rata-rata, yang mengindikasikan distribusi data yang tidak terlalu mencolok terhadap *outlier*. Namun pada fitur Volume terlihat adanya variasi besar dengan standar deviasi yang cukup tinggi dan nilai minimum sebesar nol, yang kemungkinan besar disebabkan oleh hari-hari tanpa transaksi atau pencatatan data yang kosong. Hasil-hasil tersebut menunjukkan bahwa data historis harga saham ini cukup representatif dan siap digunakan untuk proses analisis lebih lanjut dan pemodelan prediksi harga saham.

4.2.2 Visualisasi Distribusi Data Setiap Fitur

Gambar 17 merupakan visualisasi distribusi data selama periode pengamatan untuk fitur *Open*, *High*, *Low*, *Close*, dan *Volume* yang divisualisasikan melalui histogram

dan KDE plot untuk mengidentifikasi pola sebaran dan potensi *outlier* pada data historis harga saham ASII.JK.

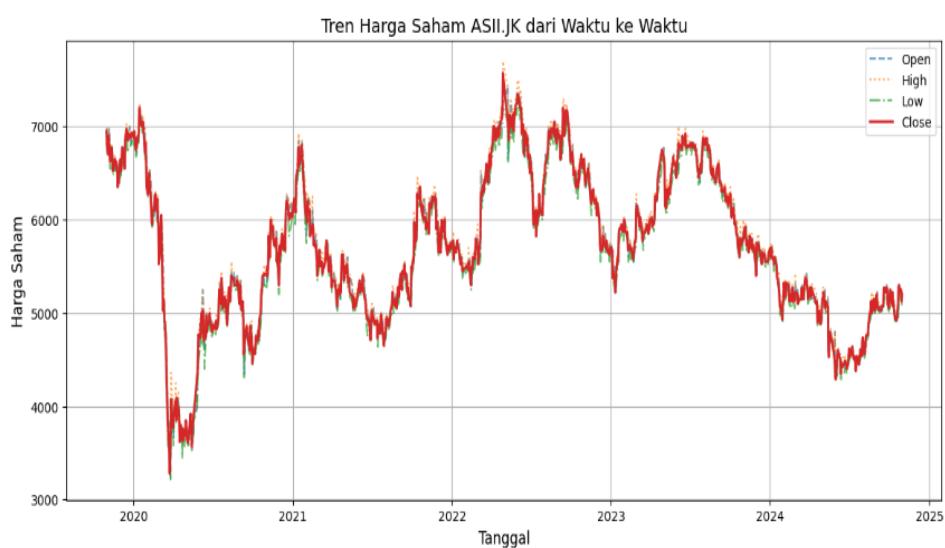


Gambar 17 Hasil Visualisasi Distribusi Data Tiap Fitur

Berdasarkan hasil visualisasi pada Gambar 16, disimpulkan bahwa sebagian besar fitur memiliki pola distribusi yang cenderung mendekati bentuk distribusi normal meskipun terlihat sedikit asimetris. Misal distribusi *Close* dan *Open*, menunjukkan penyebaran yang relatif simetris dengan konsentrasi frekuensi tertinggi berada pada rentang harga 5000-6000, yang menunjukkan bahwa nilai tersebut merupakan harga yang paling sering terjadi dalam periode pengamatan. Fitur *High* dan *Low* juga memiliki pola serupa, meskipun dengan sedikit *skewness* positif. Sedangkan fitur Volume tampak memiliki *skewness* positif yang tinggi dengan puncak distribusi pada volume transaksi rendah, yang menandakan bahwa sebagian besar hari perdagangan memiliki volume yang lebih kecil, namun juga terdapat beberapa hari dengan volume yang sangat tinggi. Hal ini mencerminkan volatilitas yang cukup tinggi dalam aktivitas perdagangan saham ASII.JK.

4.2.3 Visualisasi Tren Harga Saham

Gambar 18 merupakan visualisasi tren pergerakan harga saham ASII.JK dari waktu ke waktu. Visualisasi tersebut menggambarkan fluktuasi dan pola historis harga saham selama periode pengamatan.



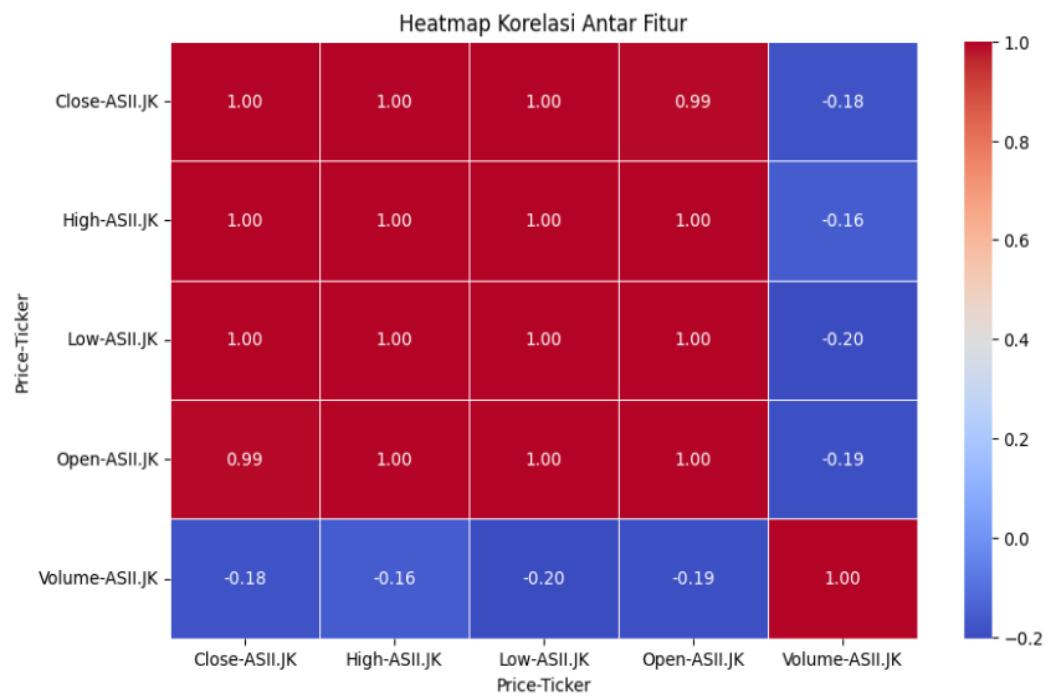
Gambar 18 Hasil Visualisasi Tren Harga Saham

Berdasarkan hasil visualisasi tren harga saham ASII.JK diatas, terlihat bahwa pergerakan harga saham mengalami fluktuasi yang signifikan pada periode 2019 hingga 2024. Di awal tahun 2020, harga saham mengalami penurunan tajam

yang kemungkinan besar disebabkan oleh dampak pandemi COVID-19. Namun setelah periode tersebut, harga saham menunjukkan tren pemulihan yang cukup kuat dan mencapai puncaknya di awal tahun 2022. Memasuki tahun 2023 hingga 2024, tren harga saham cenderung menurun dan bergerak lebih stabil di kisaran yang lebih rendah dibandingkan tahun-tahun sebelumnya. Hal ini menunjukkan bahwa saham ASII.JK memiliki volatilitas yang cukup tinggi dan tren pergerakan harga yang dipengaruhi oleh berbagai kondisi pasar baik domestik maupun global.

4.2.4 Korelasi Antar Fitur

Gambar 19 menyajikan *heatmap* korelasi antar fitur harga saham, yang menunjukkan tingkat hubungan linier antar fitur *Open*, *High*, *Low*, *Close*, dan Volume dalam data historis ASII.JK.



Gambar 19 *Heatmap* Korelasi Antar Fitur

Dari *heatmap* korelasi antar fitur saham ASII.JK diatas, ditarik kesimpulan bahwa ada korelasi positif sangat kuat antara fitur *Close*, *High*, *Low*, dan *Open*, dengan nilai korelasi yang mendekati 1.00. Hal ini menunjukkan bahwa pergerakan harga penutupan (*Close*) sangat erat kaitannya dengan harga pembukaan (*Open*), harga tertinggi (*High*), dan harga terendah (*Low*). Sementara itu, fitur Volume menunjukkan korelasi negatif yang sangat lemah terhadap semua fitur harga,

dengan tingkat korelasi dalam rentang -0.16 hingga -0.20. Ini menunjukkan bahwa pengaruh volume perdagangan terhadap pergerakan harga saham ASII.JK tidak sebesar fitur harga lainnya. Fitur dengan korelasi tinggi terhadap target prediksi cenderung lebih relevan untuk digunakan dalam algoritma pembelajaran mesin. Namun fitur volume akan tetap digunakan dalam proses pemodelan, karena volume dapat memberikan konteks tambahan terhadap dinamika harga, khususnya dalam mendekripsi potensi perubahan tren atau volatilitas pasar.

4.3 Pra-Pemrosesan Data

4.3.1 Normalisasi Data

Normalisasi data dilakukan menggunakan metode *MinMaxScaler*, seluruh fitur numerik pada data historis saham ASII.JK yaitu *Open*, *High*, *Low*, *Close*, dan *Volume*, telah diubah skala nilainya ke dalam rentang antara 0 hingga 1. Proses ini bertujuan untuk menyamakan skala antar fitur sehingga tidak ada fitur yang mendominasi proses pemodelan karena perbedaan satuan atau skala nilai. Hasil normalisasi dapat dilihat pada Tabel 7.

Tabel 7 Data Saham ASII.JK Setelah Dinormalisasi

<i>Date</i>	<i>Open</i>	<i>High</i>	<i>Low</i>	<i>Close</i>	<i>Volume</i>
2019-10-31	0.887039	0.822738	0.883578	0.854482	0.085106
2019-11-01	0.892985	0.822738	0.859069	0.819558	0.055276
2019-11-04	0.851367	0.786064	0.852941	0.796275	0.062103
2019-11-05	0.845422	0.816626	0.865196	0.842841	0.135008
2019-11-06	0.892985	0.822738	0.883578	0.831199	0.094943
...
2024-10-24	0.494649	0.413203	0.485294	0.464494	0.163059
2024-10-25	0.488704	0.407090	0.485294	0.452852	0.087499
2024-10-28	0.482759	0.400978	0.466912	0.458673	0.128984
2024-10-29	0.482759	0.400978	0.466912	0.429569	0.145303
2024-10-30	0.453032	0.388753	0.448529	0.447031	0.106615

Dari tabel hasil normalisasi diatas, terlihat bahwa setiap nilai pada kolom-kolom tersebut kini berada dalam batas rentang normalisasi, misal nilai *Open* pada tanggal 31 Oktober 2019 adalah sekitar 0.87, dan nilai *Volume* berada pada kisaran yang jauh lebih kecil seperti 0.085, menandakan bahwa *Volume* memiliki variasi yang lebih tinggi dalam data aslinya. Normalisasi ini sangat penting untuk mendukung kinerja algoritma pembelajaran mesin yang sensitif terhadap skala data.

4.3.2 Pembagian Data

Proses pembagian data dilakukan menggunakan metode *TimeSeriesSplit Cross-Validation* sebanyak *5 fold*. Data historis harga saham ASII.JK dibagi menjadi beberapa *fold* secara berurutan berdasarkan waktu. Teknik ini digunakan untuk menjaga urutan waktu dalam data *time series*, sehingga informasi dari masa depan tidak “bocor” ke dalam data pelatihan (*data leakage*). Ukuran data latih dan data uji tiap *fold* dapat dilihat pada Tabel 8.

Tabel 8 Ukuran Tiap *Fold* Hasil Pembagian

<i>Fold</i>	<i>Train Size</i>	<i>Test Size</i>
1	202	202
2	404	202
3	606	202
4	808	202
5	1010	202

Setiap *fold* terdiri dari data latih (*train*) dan data uji (*test*) dengan ukuran data uji tetap sebanyak 202 baris, sementara ukuran data latih bertambah secara progresif mulai dari 202 hingga 1010 baris. *Fold* yang akan diaplikasikan pada tahap pelatihan dan pengujian model hanyalah *fold* terakhir, di mana data latih terdiri dari 1010 observasi dan data uji terdiri dari 202 observasi. Strategi ini bertujuan untuk meniru kondisi prediksi dunia nyata, di mana model dilatih menggunakan data historis dan diuji pada data yang lebih baru, sekaligus menjaga validitas evaluasi model prediktif.

4.3.3 Pembentukan *Sequence* dan Target

Proses pembentukan *sequence* data dan target dilakukan menggunakan *TimeseriesGenerator* dari *library* TensorFlow Keras. Tujuannya adalah untuk menyiapkan data dalam bentuk urutan (*sequence*) yang sesuai untuk model LSTM. Pada penelitian ini, panjang *sequence* sebesar 10 [35], yang artinya model akan mempelajari pola dari 10 data sebelumnya untuk memprediksi harga penutupan (*Close*) pada hari berikutnya. Data latih dan data uji yang sudah dipisahkan pada tahap sebelumnya, dikonversi dari bentuk generator ke dalam *array Numpy* menggunakan *looping* agar dapat langsung digunakan dalam proses pelatihan model. Proses ini menghasilkan *X_train*, *y_train*, *X_test*, dan *y_test* yang masing-

masing berisi data *sequence* dan label target yang siap digunakan dalam pelatihan model LSTM.

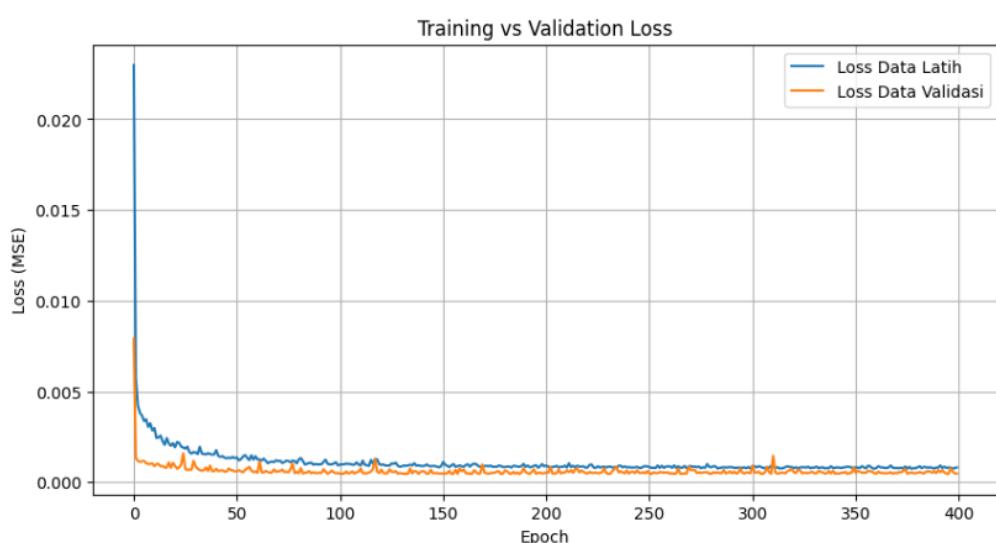
4.4 Pemodelan LSTM

Proses pelatihan model dilakukan berulang kali dengan berbagai kombinasi jumlah parameter berbeda dalam setiap percobaan. Hal itu dilakukan untuk mencari konfigurasi terbaik yang dapat memberikan hasil prediksi terbaik. Tiga kombinasi parameter yang memiliki hasil metrik evaluasi terendah disajikan pada Tabel 9.

Tabel 9 Kombinasi Parameter Terbaik

<i>Layer 1</i>	<i>Layer 2</i>	<i>Dense</i>	<i>Batch Size</i>	<i>Epochs</i>	<i>Dropout</i>	<i>LR</i>	<i>MAPE</i>	<i>RMSE</i>	<i>MAE</i>
150	100	50	32	400	0.1	0.001	1.42%	94.16	70.26
150	75	50	32	350	0.2	0.0005	1.44%	94.73	70.52
200	150	64	32	400	0.1	0.0003	1.45%	96.30	71.34

Dari ketiga kombinasi parameter diatas, kombinasi yang menghasilkan nilai metrik evaluasi terendah ada pada konfigurasi dengan jumlah *batch size* sebesar 32, *epochs* 400, *dropout* 0.1, dan *learning rate* 0.001, yang menghasilkan nilai MAPE sebesar 1.42%, RMSE sebesar 94.16, dan MAE sebesar 70.26. Grafik *training* dan *validation loss* dari konfigurasi dengan parameter tersebut dapat dilihat pada Gambar 20.



Gambar 20 Grafik *Training & Validation Loss*

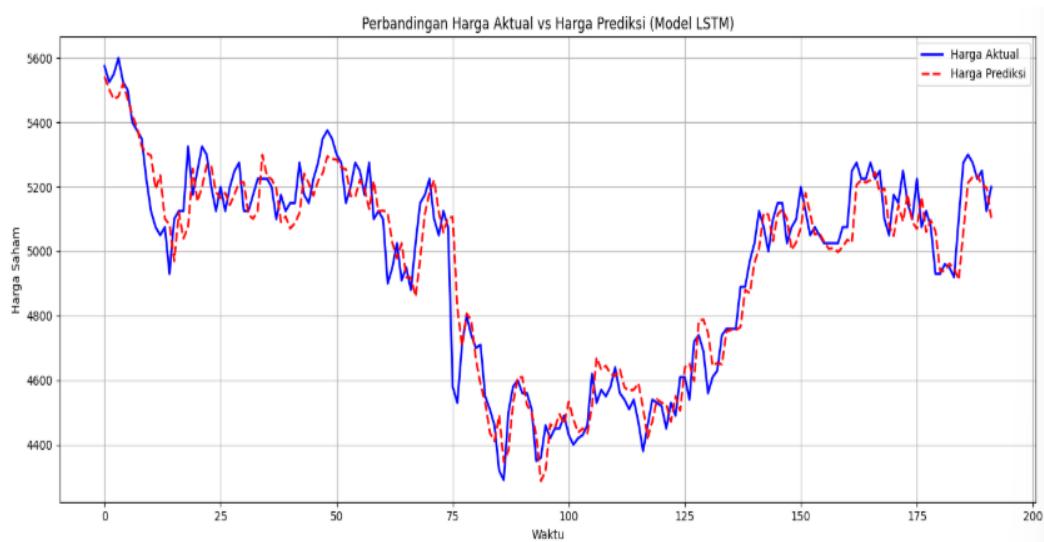
Grafik diatas menunjukkan bahwa proses pelatihan model cukup baik dan stabil tanpa adanya indikasi *overfitting* maupun *underfitting*. Hal ini terlihat dari nilai *loss* yang terus menurun secara signifikan pada awal pelatihan dan kemudian menjadi stabil seiring bertambahnya *epoch*. Secara keseluruhan, performa model mencerminkan hasil pelatihan yang optimal dan konsisten.

Untuk memvalidasi modelnya, dilakukan perbandingan antara harga prediksi dan harga aktual yang disajikan pada Tabel 10 di bawah ini.

Tabel 10 Perbandingan Harga Prediksi & Harga Aktual Model

No	Tanggal	Harga Prediksi	Harga Aktual
1	09/01/2024	5542.061896	5575.0
2	10/01/2024	5502.436891	5525.0
3	11/01/2024	5472.231477	5550.0
4	12/01/2024	5480.703605	5600.0
5	15/01/2024	5520.892839	5525.0
...
188	24/10/2024	5229.736830	5275.0
189	25/10/2024	5235.455402	5225.0
190	28/10/2024	5205.323076	5250.0
191	29/10/2024	5198.236302	5125.0
192	30/10/2024	5103.738943	5200.0

Dari data yang disajikan pada tabel diatas, terlihat bahwa harga prediksi memiliki selisih yang relatif kecil terhadap harga aktual. Hal ini didukung oleh grafik perbandingan yang ditampilkan pada Gambar 21.



Gambar 21 Grafik Perbandingan Harga Prediksi & Aktual Hasil Pengujian Model

Dari grafik diatas terlihat bahwa arah pergerakan (naik atau turun) maupun titik-titik perubahan tren pada garis prediksi (merah) memiliki tren yang sangat mirip dengan garis aktual (biru). Ini mengindikasikan bahwa model dapat menangkap pola historis harga dengan akurat, meskipun terdapat sedikit perbedaan nilai di beberapa titik. Model juga mampu memprediksi titik-titik penting seperti penurunan tajam di sekitar waktu ke-75 dan kenaikan signifikan setelah waktu ke-125 dengan cukup baik. Hal ini menunjukkan bahwa model LSTM yang digunakan memiliki kemampuan generalisasi yang baik dalam mempelajari pola waktu pada data harga saham.

4.5 Evaluasi dan Analisis Hasil Pemodelan

Berdasarkan hasil prediksi harga saham ASII.JK dari proses pemodelan, model LSTM yang telah dibangun menunjukkan kinerja yang memadai dalam melakukan prediksi harga saham ASII.JK dengan nilai MAPE, RMSE, dan MAE yang tergolong rendah. Nilai-nilai tersebut diperoleh dari perhitungan menggunakan rumus MAPE pada persamaan 8, RMSE pada persamaan 9, dan MAE pada persamaan 10 sebagai berikut :

1. *Mean Absolute Percentage Error (MAPE)*

$$\begin{aligned} \text{MAPE} &= \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{\text{test}} - \text{predictions}}{y_{\text{test}}} \right| \times 100 \\ &= \frac{1}{192} \cdot 2.7357 \cdot 100 = 1,42\% \end{aligned}$$

2. *Root Mean Squared Error (RMSE)*

$$\begin{aligned} \text{RMSE} &= \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{\text{test}} - \text{predictions})^2} \\ &= \sqrt{\frac{1702212}{192}} = \sqrt{8865.686} = 94.16 \end{aligned}$$

3. *Mean Absolute Error (MAE)*

$$\begin{aligned} \text{MAE} &= \frac{1}{n} \sum_{i=1}^n |y_{\text{test}} - \text{predictions}| \\ &= \frac{13490.30815}{192} = 70.26 \end{aligned}$$

Dari hasil perhitungan, nilai MAPE yang diperoleh sebesar 1,42%, yang mana jika mengacu pada Tabel 2, nilai tersebut berada pada kategori “sangat baik” karena berada di bawah 10%. Selain itu, RMSE sebesar 94.16 (IDR) tergolong baik, karena menurut Normah et al. (2022), semakin rendah nilai RMSE maka prediksi model dianggap semakin akurat [30]. Nilai MAE sebesar 70.26 (IDR) juga tergolong baik karena menurut Suryanto (2019), semakin kecil nilai MAE, maka kemampuan model dalam melakukan prediksi juga semakin baik [30]. Hasil perhitungan MAPE, RMSE, dan MAE tersebut menunjukkan bahwa model LSTM ini cukup handal dalam melakukan prediksi harga saham ASII.JK karena kesalahan prediksi relatif kecil. Jika dalam proses pelatihannya model belum menghasilkan performa yang baik, maka *hyperparameter tuning* akan terus dilakukan dengan mengkombinasikan jumlah parameter lainnya guna meningkatkan kinerja model secara keseluruhan.

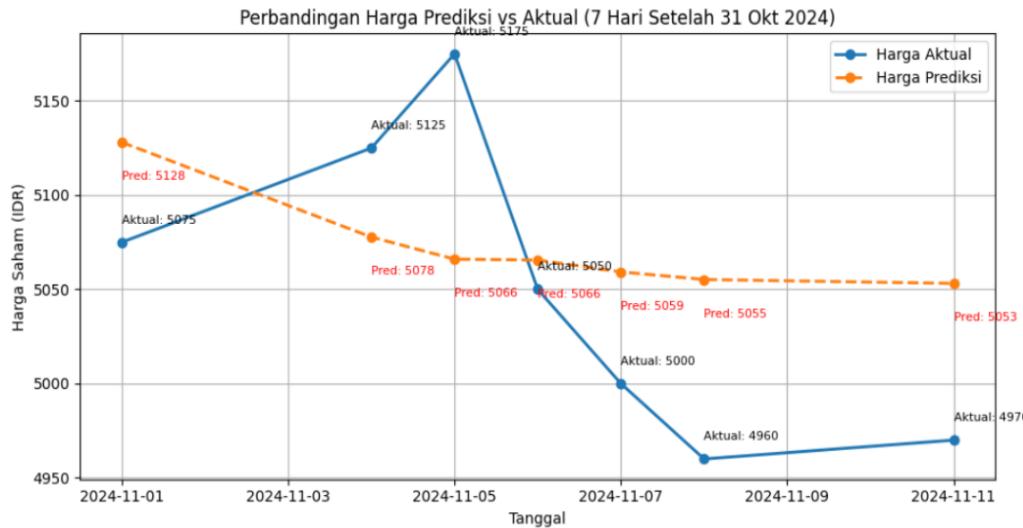
4.6 Prediksi Harga Saham

Prediksi Harga Penutupan Saham ASII.JK 7 hari ke depan sejak tanggal 31 Oktober 2024 disajikan pada Tabel 11 yang juga berisikan harga aktualnya.

Tabel 11 Perbandingan Harga Saham Prediksi dan Aktual selama 7 Hari

Tanggal	Harga Prediksi	Harga Aktual
2024-11-01	5128.050680	5075
2024-11-04	5077.753721	5125
2024-11-05	5066.036000	5175
2024-11-06	5065.541788	5050
2024-11-07	5059.259116	5000
2024-11-08	5055.221197	4960
2024-11-11	5053.151422	4970

Berdasarkan Tabel 11, hasil prediksi menunjukkan pola yang relatif stabil dengan fluktuasi kecil di sekitar rentang 5053 hingga 5128. Jika dibandingkan dengan harga aktualnya, harga prediksi cenderung sedikit lebih tinggi pada sebagian besar tanggal, meskipun perbedaannya tidak terlalu signifikan. Untuk memvisualisasikan perbandingan dari harga prediksi dan harga aktual saham ASII.JK diatas, disajikan grafik yang dapat dilihat pada Gambar 22.



Gambar 22 Grafik Perbandingan Harga Prediksi dan Aktual selama 7 Hari

Hasil perbandingan diatas menunjukkan bahwa model mampu menangkap arah tren penurunan, namun tidak sepenuhnya mengikuti fluktuasi jangka pendek yang terjadi pada data aktual. Terlihat dari garis berwarna oranye (harga prediksi) yang perubahannya lebih halus dibandingkan garis berwarna biru (harga aktual) yang naik-turunnya lebih tajam. Hal itu menunjukkan bahwa model lebih andal dalam memproyeksikan tren jangka pendek yang stabil, namun kurang responsif terhadap pergerakan pasar yang bersifat tiba-tiba dan fluktuatif.

4.7 Evaluasi dan Analisis Hasil Prediksi

Perbandingan harga prediksi dan harga aktual harga saham ASII.JK selama 7 hari setelah tanggal 31 Oktober 2024 dievaluasi menggunakan metrik evaluasi yang sama yaitu MAPE, RMSE, dan MAE. Perhitungan metrik evaluasi tersebut dilakukan dengan rumus MAPE pada persamaan 8, RMSE pada persamaan 9, dan MAE pada persamaan 10 sebagai berikut :

1. Mean Absolute Percentage Error (MAPE)

$$\begin{aligned} \text{MAPE} &= \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{test} - predictions}{y_{test}} \right| \times 100 \\ &= \frac{1}{7} \cdot 0.0917 \cdot 100 = 1,31\% \end{aligned}$$

2. Root Mean Squared Error (RMSE)

$$\begin{aligned}
 \text{RMSE} &= \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{test} - predictions)^2} \\
 &= \sqrt{\frac{36656.47}{7}} = \sqrt{5236.64} = 72.36
 \end{aligned}$$

3. Mean Absolute Error (MAE)

$$\begin{aligned}
 \text{MAE} &= \frac{1}{n} \sum_{i=1}^n |y_{test} - predictions| \\
 &= \frac{462.43}{7} = 66.06
 \end{aligned}$$

Perhitungan metrik evaluasi menghasilkan nilai MAPE sebesar 1.31%, RMSE sebesar 72.36 (IDR), dan MAE sebesar 66.06 (IDR). Hasil ini menunjukkan bahwa model prediksi yang digunakan cukup efektif dalam memberikan prediksi harga penutupan saham ASII.JK dengan tingkat kesalahan terhadap nilai aktual yang rendah (< 10%), yang mana nilai ini termasuk dalam kategori “sangat baik”. Selain itu nilai RMSE dan MAE juga tergolong rendah, sehingga memperkuat bahwa model mampu menghasilkan prediksi dengan baik. Karena menurut Normah et al. (2022) dan Suryanto (2019), semakin kecil nilai RMSE dan MAE, semakin baik pula model dalam menghasilkan prediksi.

BAB V

KESIMPULAN DAN SARAN

5.1 Simpulan

Berdasarkan temuan dari studi yang telah dilakukan terkait penerapan algoritma *Long Short-Term Memory* (LSTM) dalam memprediksi harga saham ASII.JK, ditarik kesimpulan bahwa pengimplementasian LSTM dilakukan dengan tahapan yang terstruktur mulai dari pengumpulan data historis saham ASII.JK periode 31 Oktober 2019 hingga 31 Oktober 2024 dari *Yahoo Finance*, hingga proses prediksi aktual yang dilakukan 7 hari kedepan sejak periode tersebut. Model LSTM dibangun dengan konfigurasi terbaik berupa dua *hidden layer* (150 dan 100 unit), satu *dense layer* (50 unit), *batch size* 32, 400 *epoch*, *dropout* 0.1, dan *learning rate* 0.001. Konfigurasi tersebut menghasilkan model prediksi dengan performa cukup baik yang ditunjukkan dengan hasil perhitungan metrik evaluasi berupa nilai MAPE sebesar 1.42%, RMSE sebesar 94.16, dan MAE sebesar 70.26.

Pada prediksi aktual 7 hari ke depan setelah periode data, model menghasilkan MAPE sebesar 1.31%, RMSE sebesar 72.36, dan MAE sebesar 66.06. Hasil tersebut membuktikan bahwa model mampu mengikuti arah tren dan efektif dalam memproyeksikan tren jangka pendek meskipun belum sepenuhnya responsif terhadap fluktuasi pasar yang tajam. Model LSTM ini dapat digunakan sebagai sarana pendukung dalam pengambilan keputusan investasi berbasis data historis harga saham dengan peluang pengembangan lebih lanjut.

5.2 Saran

Beberapa usulan untuk pengembangan penelitian selanjutnya yaitu, untuk meningkatkan akurasi prediksi dan sensitivitas terhadap fluktuasi harga yang tajam, disarankan untuk melakukan *tuning hyperparameter* yang lebih mendalam dengan cakupan kombinasi parameter yang lebih luas. Penggunaan fitur tambahan seperti indikator teknikal (*moving average*, *RSI*, *MACD*), data sentimen pasar, atau berita ekonomi juga dapat dipertimbangkan untuk memperkaya *input* model dan meningkatkan kemampuan prediktif. Selain itu, penerapan model *hybrid* juga dapat menjadi alternatif untuk memperbaiki ketahanan model terhadap volatilitas pasar.

DAFTAR PUSTAKA

- [1] Kontan.co.id, “Tren Investasi Digital Naik, 67% Masyarakat Indonesia Berencana Investasi Tahun Depan,” <https://investasi.kontan.co.id/news/tren-investasi-digital-naik-67-masyarakat-indonesia-berencana-investasi-tahun-depan>.
- [2] Kustodian Sentral Efek Indonesia (KSEI), “Statistik Pasar Modal Indonesia,” https://www.ksei.co.id/files/Statistik_Publik_September_2024_final.pdf.
- [3] P. Triya, N. Suarna, and N. D. Nuris, “Penerapan Machine Learning dalam Melakukan Prediksi Harga Saham PT Bank Mandiri (Persero) Tbk dengan Algoritma Linear Regression,” 2024.
- [4] N. Abdurrahman Burhani, D. Saepudin, and D. Adytia, “Prediksi Return Saham Berdasarkan Data Histori dan Data Fundamental Menggunakan LSTM.”
- [5] A. Rosyd, A. Irma Purnamasari, and I. Ali, “Penerapan Metode Long Short Term Memory (LSTM) dalam Memprediksi Harga Saham PT Bank Central Asia,” 2024.
- [6] D. K. H. Putra, “Sekolah Tinggi Teknologi Terpadu Nurul Fikri Analisis Perbandingan Model Prediksi Harga Saham melalui Pendekatan Long-Short Term Memory (LSTM) Dan Autoregressive Integrated Moving Average (ARIMA) (Studi Kasus,” 2024.
- [7] J. P. Lai, Y. M. Chang, C. H. Chen, and P. F. Pai, “A survey of machine learning models in renewable energy predictions,” Sep. 01, 2020, *MDPI AG*. doi: 10.3390/app10175975.
- [8] R. Julian and M. R. Pribadi, “Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM),” *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 8, no. 3, 2021, [Online]. Available: <http://jurnal.mdp.ac.id>
- [9] G. Budiprasetyo, M. Hani’ah, and D. Z. Aflah, “Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM),” *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 8, no. 3, pp. 164–172, Jan. 2023, doi: 10.25077/teknosi.v8i3.2022.164-172.
- [10] K. Kwanda, D. E. Herwindati, M. D. Lauro, and K. K. C. Id, “Perbandingan LSTM dan Bidirectional LSTM pada Sistem Prediksi Harga Saham Berbasis Website,” *R2J*, vol. 7, no. 1, 2024, doi: 10.38035/rrj.v7i1.

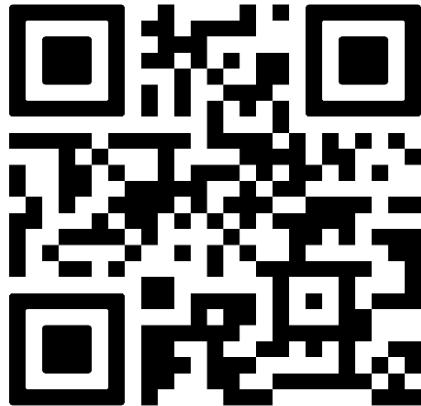
- [11] A. Arfan and L. ETP, “Perbandingan Algoritma Long Short-Term Memory dengan SVR Pada Prediksi Harga Saham di Indonesia,” *PETIR*, vol. 13, no. 1, pp. 33–43, Mar. 2020, doi: 10.33322/petir.v13i1.858.
- [12] Zakiyatul Miskiyah, Arif Zunaidi, Sodiq Almustofa, and Mahrus Suhardi, “Kebijakan Fiskal dalam Perspektif Ekonomi Makro Islam,” *Istithmar : Jurnal Studi Ekonomi Syariah*, vol. 6, no. 1, pp. 69–83, Jun. 2022, doi: 10.30762/istithmar.v6i1.33.
- [13] Kontan.co.id, “Cermati Rekomendasi Saham Astra International (ASII) yang Cetak Kinerja Stabil,” https://investasi.kontan.co.id/news/cermati-rekomendasi-saham-astra-international-asii-yang-cetak-kinerja-stabil?utm_source=chatgpt.com#google_vignette.
- [14] Trading View, “Astra Internasional,” <https://id.tradingview.com/symbols/IDX-ASII/>?
- [15] Bisnis.com, “Prospek Cerah Saham Astra (ASII) saat Suku Bunga Murah 2025,” <https://market.bisnis.com/read/20241126/189/1819053/prospek-cerah-saham-astra-asii-saat-suku-bunga-murah-2025>.
- [16] M. Zulfani, A. Dapadeda, A. Jaya Yogyakarta, J. Babarsari No, K. Sleman, and D. Istimewa Yogyakarta, “Prediksi Harga Saham Menggunakan Algoritma Neural Network,” vol. 18, no. 1, 2024, doi: 10.47111/JTI.
- [17] R. Ernayani *et al.*, “Literature Review: Prospects of Increasing Interest Rates on Firm Value and Stock Returns / Literature Review: Prospek Peningkatan Suku Bunga terhadap Nilai Perusahaan dan Return Saham”.
- [18] S. la Tansa Mashiro Rangkasbitung, “The Asia Pacific Journal of Management Studies Faktor-Faktor yang Mempengaruhi Harga Saham: Peran Kinerja Perusahaan Makanan dan Minuman di Indonesia”.
- [19] Dr. R. Doshi, Dr. K. K. Hiran, R. K. Jain, and Dr. K. Lakhwani, *Machine Learning*, First. India: BPB Publications, 2022.
- [20] B. Mahesh, “Machine Learning Algorithms - A Review,” *International Journal of Science and Research (IJSR)*, vol. 9, no. 1, pp. 381–386, Jan. 2020, doi: 10.21275/art20203995.
- [21] I. H. Sarker, “Machine Learning: Algorithms, Real-World Applications and Research Directions,” May 01, 2021, Springer. doi: 10.1007/s42979-021-00592-x.

- [22] R. Dwi, W. Santosa, M. Arif Bijaksana, and A. Romadhony, “Implementasi Algoritma Long Short-Term Memory (LSTM) untuk Mendeteksi Penggunaan Kalimat Abusive Pada Teks Bahasa Indonesia.”
- [23] M. Rizvi and M. Mahdi, “Stock Prediction Web-App based on Python-Streamlit Using Data Analysis and Machine Learning,” *International Research Journal of Modernization in Engineering Technology and Science*, Sep. 2023, doi: 10.56726/irjmets43978.
- [24] J. Unpingco, *Python programming for data analysis*. Springer International Publishing, 2021. doi: 10.1007/978-3-030-68952-0.
- [25] M. Shantal, Z. Othman, and A. A. Bakar, “A Novel Approach for Data Feature Weighting Using Correlation Coefficients and Min–Max Normalization,” *Symmetry (Basel)*, vol. 15, no. 12, Dec. 2023, doi: 10.3390/sym15122185.
- [26] B. Deepa and K. Ramesh, “Epileptic seizure detection using deep learning through min max scaler normalization,” *Int J Health Sci (Qassim)*, pp. 10981–10996, May 2022, doi: 10.53730/ijhs.v6ns1.7801.
- [27] P. K. Choudhary, N. Innan, M. Shafique, and R. Singh, “HQNN-FSP: A Hybrid Classical-Quantum Neural Network for Regression-Based Financial Stock Market Prediction,” Mar. 2025, [Online]. Available: <http://arxiv.org/abs/2503.15403>
- [28] S. F. Thiel, “Usage of Wastewater Data as an Early Indicator for Hospitalization Forecasting in Pandemic Situations,” 2024.
- [29] A. Novia Rahma, I. Suryani, and Y. Sari, “Penerapan Logika Fuzzy dalam Menentukan Jumlah Peserta BPJS Kesehatan Menggunakan Fuzzy Inference System Sugeno,” vol. 1, no. 3, p. 2020, 2020, doi: 10.46306/lb.v1i3.
- [30] A. T. Nurani, A. Setiawan, and B. Susanto, “Perbandingan Kinerja Regresi Decision Tree dan Regresi Linear Berganda untuk Prediksi BMI pada Dataset Asthma,” *Jurnal Sains dan Edukasi Sains*, vol. 6, no. 1, pp. 34–43, May 2023, doi: 10.24246/juses.v6i1p34-43.
- [31] A. P. Meriani and A. Rahmatulloh, “Perbandingan Gated Recurrent Unit (GRU) dan Algoritma Long Short Term Memory (LSTM) Linear Regression dalam Prediksi Harga Emas Menggunakan Model Time Series,” *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 1, Jan. 2024, doi: 10.23960/jitet.v12i1.3808.
- [32] S. Adsure, D. Jaisawaal, A. Shetty, D. Shinde, S. Mane, and A. Kulkarni, “Stock Market Prediction Using Machine Learning,” *IJARCCE*, vol. 12, no. 4, Apr. 2023, doi: 10.17148/IJARCCE.2023.124208.

- [33] R. N. Silalahi and M. Muljono, “Perbandingan Kinerja Metode Linear Regression, LSTM dan GRU Untuk Prediksi Harga Penutupan Saham Coco-Cola,” *Komputika : Jurnal Sistem Komputer*, vol. 13, no. 2, pp. 201–211, Oct. 2024, doi: 10.34010/komputika.v13i2.12265.
- [34] U. Javed *et al.*, “Exploratory data analysis based short-term electrical load forecasting: A comprehensive analysis,” *Energies (Basel)*, vol. 14, no. 17, Sep. 2021, doi: 10.3390/en14175510.
- [35] A. Kumar, A. Thomas, N. K. Todi, O. Olemyan, S. Tripathi, and V. Arora, “Comprehensive Prediction of Stock Prices Using Time Series, Statistical, Machine Learning, and Deep Learning Models,” 2022.

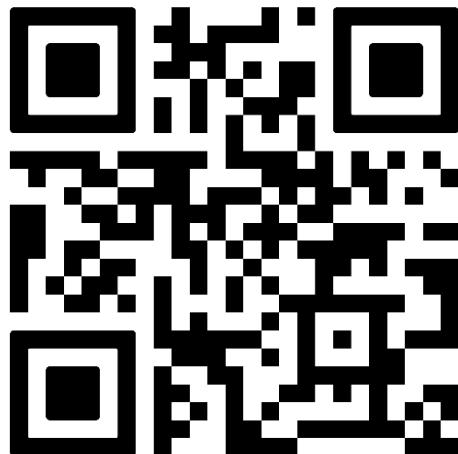
Lampiran 1 - Data Historis ASII.JK

Data historis harga saham PT Astra Internasional Tbk (ASII.JK) periode 31 Oktober 2019 - 31 Oktober 2024 dapat diakses dengan *scan QR code* di bawah ini :



<https://docs.google.com/spreadsheets/d/16BB6nr9vSd4Rk9bWEu8Qbux6D72IKz6t/edit?gid=211879374#gid=211879374>

Data historis harga saham PT Astra Internaisional Tbk (ASII.JK) periode 31 Oktober 2019 - 31 Oktober 2024 yang telah dinormalisasi dapat diakses dengan *scan QR code* di bawah ini :



<https://docs.google.com/spreadsheets/d/1dl9s8iEqIiPjbtI57dAjULLHhwmI6aW0edit?gid=1071243329#gid=1071243329>

Lampiran 2 - Parameter Eksperimen

Tabel 1 Lampiran 2 Parameter Eksperimen

No	Layer 1	Layer 2	Dense	BS	Epoch	DO	LR	MAPE	RMSE	MAE
1	150	100	50	32	250	0.3	0.001	1.80%	112.82	86.49
2	150	100	50	64	250	0.3	0.001	2.01%	123.33	98.96
3	150	100	50	32	300	0.3	0.001	1.66%	104.27	82.40
4	150	100	50	64	300	0.3	0.001	2.01%	123.33	98.96
5	128	64	32	64	250	0.2	0.001	1.56%	100.28	77.37
6	200	150	100	32	300	0.3	0.001	1.66%	104.27	82.40
7	150	100	50	64	250	0.3	0.0005	1.52%	98.44	74.40
8	100	50	25	32	200	0.4	0.001	1.46%	96.19	71.75
9	150	100	50	64	400	0.3	0.001	1.67%	105.58	80.88
10	150	100	50	64	250	0.1	0.001	1.54%	99.55	75.24
11	150	100	50	64	250	0.3	0.0001	2.10%	135.18	104.70
12	150	75	25	128	250	0.3	0.001	1.77%	112.28	87.22
13	100	75	50	32	300	0.2	0.001	1.66%	105.25	82.82
14	128	64	32	128	300	0.3	0.001	2.15%	132.81	107.88
15	200	150	100	64	400	0.4	0.001	1.71%	109.56	84.29
16	150	100	50	32	400	0.1	0.001	1.42%	94.16	70.26
17	100	50	25	64	200	0.3	0.0005	1.91%	122.44	94.00
18	128	64	32	64	350	0.2	0.001	1.88%	118.40	94.47
19	100	50	25	128	300	0.3	0.001	1.74%	112.32	85.61
20	150	75	25	32	250	0.2	0.0005	1.49%	97.09	72.72
21	128	100	50	32	400	0.1	0.0005	1.51%	98.11	73.20
22	150	75	50	32	350	0.2	0.0005	1.44%	94.73	70.52
23	100	64	50	64	400	0.1	0.001	1.63%	104.62	78.80
24	200	100	50	32	300	0.2	0.001	1.58%	100.95	77.61
25	150	100	64	32	400	0.1	0.0005	1.46%	95.82	71.93
26	128	75	64	32	400	0.1	0.0005	1.47%	96.32	72.41
27	100	64	32	16	400	0.1	0.001	1.56%	97.73	77.11
28	150	100	50	32	500	0.1	0.0005	1.61%	103.89	78.17
29	128	100	32	64	400	0.05	0.0005	1.57%	99.89	77.12
30	200	150	64	32	400	0.1	0.0003	1.45%	96.30	71.34

Lampiran 3 - Harga Prediksi & Harga Aktual

Tabel 2 Lampiran 3 Harga Prediksi & Harga Aktual

No	Tanggal	Harga Prediksi	Harga Aktual
1	09/01/2024	5542,061896	5575
2	10/01/2024	5502,436891	5525
3	11/01/2024	5472,231477	5550
4	12/01/2024	5480,703605	5600
5	15/01/2024	5520,892839	5525
6	16/01/2024	5471,871538	5500
7	17/01/2024	5422,738236	5400
8	18/01/2024	5383,515153	5375
9	19/01/2024	5325,319382	5350
10	22/01/2024	5304,764601	5225
11	23/01/2024	5297,514114	5125
12	24/01/2024	5192,91479	5075
13	25/01/2024	5236,129711	5050
14	26/01/2024	5101,542062	5075
15	29/01/2024	5082,464285	4930
16	30/01/2024	4969,71437	5100
17	31/01/2024	5119,744441	5125
18	01/02/2024	5040,083546	5125
19	02/02/2024	5075,374951	5325
20	05/02/2024	5256,220232	5175
21	06/02/2024	5154,404033	5250
22	07/02/2024	5199,269142	5325
23	12/02/2024	5267,512734	5300
24	13/02/2024	5262,973691	5200
25	15/02/2024	5183,856289	5125
26	16/02/2024	5164,948113	5200
27	19/02/2024	5181,031307	5125
28	20/02/2024	5143,971569	5200
29	21/02/2024	5177,047917	5250
30	22/02/2024	5214,096135	5275
31	23/02/2024	5214,403465	5125
32	26/02/2024	5113,333128	5125
33	27/02/2024	5101,191595	5175
34	28/02/2024	5125,542117	5225
35	29/02/2024	5299,452945	5225
36	01/03/2024	5232,961943	5225
37	04/03/2024	5223,312077	5200
38	05/03/2024	5194,996086	5100
39	06/03/2024	5091,459169	5175
40	07/03/2024	5108,144992	5125
41	08/03/2024	5071,080518	5150
42	13/03/2024	5087,153984	5150
43	14/03/2024	5118,92933	5275
44	15/03/2024	5240,701394	5175
45	18/03/2024	5210,573932	5150
46	19/03/2024	5172,761292	5225
47	20/03/2024	5218,485416	5275
48	21/03/2024	5242,704481	5350

49	22/03/2024	5294,89163	5375
50	25/03/2024	5286,582063	5350
51	26/03/2024	5285,144996	5300
52	27/03/2024	5260,670314	5275
53	28/03/2024	5253,882934	5150
54	01/04/2024	5172,344905	5200
55	02/04/2024	5168,748078	5275
56	03/04/2024	5222,000067	5250
57	04/04/2024	5195,453689	5175
58	05/04/2024	5131,313297	5275
59	16/04/2024	5218,012069	5100
60	17/04/2024	5123,224787	5125
61	18/04/2024	5127,332466	5100
62	19/04/2024	5118,240301	4900
63	22/04/2024	5026,451826	4950
64	23/04/2024	4978,355588	5025
65	24/04/2024	5024,811366	4910
66	25/04/2024	4920,167241	4950
67	26/04/2024	4918,235578	4880
68	29/04/2024	4859,513083	5025
69	30/04/2024	4977,433213	5150
70	02/05/2024	5116,383903	5175
71	03/05/2024	5182,440086	5225
72	06/05/2024	5221,133629	5100
73	07/05/2024	5121,848393	5050
74	08/05/2024	5058,688872	5125
75	13/05/2024	5103,684286	5075
76	14/05/2024	5106,330194	4580
77	15/05/2024	4824,079853	4530
78	16/05/2024	4706,01905	4710
79	17/05/2024	4806,799594	4800
80	20/05/2024	4786,245581	4740
81	21/05/2024	4666,85664	4700
82	22/05/2024	4585,883864	4710
83	27/05/2024	4531,28236	4550
84	28/05/2024	4437,111275	4510
85	29/05/2024	4411,750826	4460
86	30/05/2024	4491,413384	4320
87	31/05/2024	4347,051709	4290
88	03/06/2024	4381,264066	4500
89	04/06/2024	4528,09936	4580
90	05/06/2024	4607,865599	4600
91	06/06/2024	4610,248465	4560
92	07/06/2024	4523,323131	4560
93	10/06/2024	4499,596871	4510
94	11/06/2024	4429,166766	4350
95	12/06/2024	4287,82553	4360
96	13/06/2024	4317,578973	4460
97	14/06/2024	4463,392307	4420
98	19/06/2024	4451,782106	4450
99	20/06/2024	4494,885667	4450

100	21/06/2024	4464,561596	4490
101	24/06/2024	4533,319495	4430
102	25/06/2024	4478,923049	4400
103	26/06/2024	4438,095474	4420
104	27/06/2024	4450,009933	4430
105	28/06/2024	4435,285213	4460
106	01/07/2024	4518,657496	4620
107	02/07/2024	4670,889951	4530
108	03/07/2024	4632,863933	4570
109	04/07/2024	4644,500502	4550
110	05/07/2024	4620,1231	4580
111	08/07/2024	4612,972838	4640
112	09/07/2024	4633,714244	4560
113	10/07/2024	4577,79561	4540
114	11/07/2024	4568,230609	4510
115	12/07/2024	4570,225632	4540
116	15/07/2024	4590,585723	4470
117	16/07/2024	4515,466559	4380
118	17/07/2024	4421,117297	4460
119	18/07/2024	4471,917684	4540
120	19/07/2024	4540,712448	4530
121	22/07/2024	4530,281392	4520
122	23/07/2024	4525,572108	4450
123	24/07/2024	4471,727218	4530
124	25/07/2024	4549,623107	4490
125	26/07/2024	4505,418483	4610
126	29/07/2024	4639,544944	4610
127	30/07/2024	4651,756493	4540
128	31/07/2024	4597,778354	4720
129	01/08/2024	4785,044932	4740
130	02/08/2024	4788,084059	4690
131	05/08/2024	4746,927778	4560
132	06/08/2024	4645,193115	4610
133	07/08/2024	4653,66998	4630
134	08/08/2024	4649,321659	4740
135	09/08/2024	4752,507084	4760
136	12/08/2024	4756,563819	4760
137	13/08/2024	4756,131176	4760
138	14/08/2024	4764,840362	4890
139	15/08/2024	4879,878294	4890
140	16/08/2024	4870,1419	4970
141	19/08/2024	4963,809685	5025
142	20/08/2024	5009,275375	5125
143	21/08/2024	5118,011563	5075
144	22/08/2024	5114,227471	5000
145	23/08/2024	5031,708186	5100
146	26/08/2024	5114,96962	5150
147	27/08/2024	5129,565699	5150
148	28/08/2024	5100,964138	5025
149	29/08/2024	5004,411978	5075
150	30/08/2024	5028,22656	5100
151	02/09/2024	5073,596761	5200
152	03/09/2024	5180,858378	5125
153	04/09/2024	5116,959523	5050
154	05/09/2024	5052,111926	5075
155	06/09/2024	5055,986643	5050
156	09/09/2024	5030,007053	5025
157	10/09/2024	5007,725668	5025
158	11/09/2024	5009,456881	5025
159	12/09/2024	4998,024602	5025
160	13/09/2024	5013,162125	5075
161	17/09/2024	5035,977275	5075
162	18/09/2024	5027,427962	5250
163	19/09/2024	5206,383692	5275
164	20/09/2024	5220,718393	5225
165	23/09/2024	5213,683204	5225
166	24/09/2024	5220,735162	5275
167	25/09/2024	5244,645488	5225
168	26/09/2024	5181,381006	5250
169	27/09/2024	5195,740667	5100
170	30/09/2024	5079,15098	5050
171	01/10/2024	5047,881237	5175
172	02/10/2024	5143,841776	5150
173	03/10/2024	5092,698091	5250
174	04/10/2024	5177,473776	5150
175	07/10/2024	5091,122399	5100
176	08/10/2024	5069,967166	5225
177	09/10/2024	5168,754478	5075
178	10/10/2024	5060,385269	5125
179	11/10/2024	5095,843203	5075
180	14/10/2024	5062,634374	4930
181	15/10/2024	4937,525453	4930
182	16/10/2024	4940,005344	4960
183	17/10/2024	4961,625861	4950
184	18/10/2024	4947,60169	4920
185	21/10/2024	4911,89825	5100
186	22/10/2024	5060,03941	5275
187	23/10/2024	5213,18784	5300
188	24/10/2024	5229,73683	5275
189	25/10/2024	5235,455402	5225
190	28/10/2024	5205,323076	5250
191	29/10/2024	5198,236302	5125
192	30/10/2024	5103,738943	5200.0

Lampiran 4 - Kode Program Model Prediksi Harga Saham ASII.JK

File Model LSTM.ipynb

```
# Membangun model LSTM
model = Sequential()

#Layer Model
model.add(LSTM(units=150, return_sequences=True, input_shape=(X_train.shape[1],
X_train.shape[2])))
model.add(Dropout(0.1)) # Dropout 30% untuk mengurangi overfitting

model.add(LSTM(units=100, return_sequences=False))
model.add(Dropout(0.1))

model.add(Dense(units=50, activation='relu'))
model.add(Dense(units=1)) # Output: 1 nilai (prediksi harga)

# Kompilasi model
model.compile(optimizer=Adam(learning_rate=0.001), loss='mean_squared_error')

model.summary()

# Melatih model
history = model.fit(
    X_train,
    y_train,
    epochs=400,
    batch_size=32,
    validation_data=(X_test, y_test),
    verbose=1
)

# Prediksi dengan Data Test
y_pred = model.predict(X_test)

y_pred = y_pred.reshape(-1, 1)
y_test = y_test.reshape(-1, 1)

# Mengambil index kolom 'Close'
close_index = datahistoris_scaled.columns.get_loc('Close')

# Inverse transform ('Close')
y_pred_inverse = scaler.inverse_transform(
    np.hstack([
        np.zeros((len(y_pred), close_index)),
        y_pred,
        np.zeros((len(y_pred), datahistoris_scaled.shape[1] - close_index - 1))
    ])
[:, close_index]

y_test_inverse = scaler.inverse_transform(
```

```

np.hstack([
    np.zeros([len(y_test), close_index]),
    y_test,
    np.zeros([len(y_test), datahistoris_scaled.shape[1] - close_index - 1])
])
[:, close_index]

# Mengitung metrik evaluasi
mape = np.mean(np.abs((y_test_inverse - y_pred_inverse) / y_test_inverse)) * 100
rmse = np.sqrt(mean_squared_error(y_test_inverse, y_pred_inverse))
mae = mean_absolute_error(y_test_inverse, y_pred_inverse)

# Prediksi 7 Hari Kedepan setelah Tanggal 31 Oktober 2024
# Ambil 10 hari terakhir sebelum 31 Oktober 2024 untuk dijadikan sequence input prediksi
last_sequence = datahistoris_scaled[-sequence_length:].values

# Menyiapkan list untuk menyimpan prediksi dan label waktu
future_predictions = []
sequence = last_sequence.copy()

# Generate 7 hari prediksi
for _ in range(7):
    input_seq = sequence.reshape(1, sequence_length, X_train.shape[2])
    pred_scaled = model.predict(input_seq, verbose=0)[0][0]

    # Simpan hasil prediksi yang belum di-inverse
    future_predictions.append(pred_scaled)

    # Update sequence
    next_input = np.append(sequence[1:], [[*sequence[-1][:-3], pred_scaled, sequence[-1][4]]],
                           axis=0)
    sequence = next_input

# Inverse transform prediksi ('Close')
close_index = datahistoris_scaled.columns.get_loc('Close')
dummy_preds = np.zeros([len(future_predictions), len(columns_to_scale)])
dummy_preds[:, close_index] = future_predictions
future_prices = scaler.inverse_transform(dummy_preds)[:, close_index]

```