

**PREDIKSI PERGERAKAN HARGA SAHAM BERDASARKAN INDIKATOR
TEKNIKAL MENGGUNAKAN *LONG SHORT-TERM MEMORY***

SKRIPSI

**Oleh :
FADLIR ROHMAN
NIM. 18650077**



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**PREDIKSI PERGERAKAN HARGA SAHAM BERDASARKAN
INDIKATOR TEKNIKAL MENGGUNAKAN
*LONG SHORT-TERM MEMORY***

SKRIPSI

**Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)**

**Oleh :
FADLIR ROHMAN
NIM. 18650077**

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

HALAMAN PERSETUJUAN

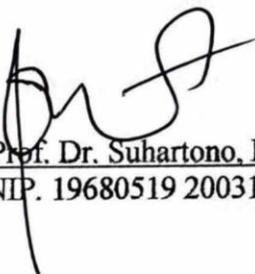
**PREDIKSI PERGERAKAN HARGA SAHAM BERDASARKAN
INDIKATOR TEKNIKAL MENGGUNAKAN
LONG SHORT-TERM MEMORY**

SKRIPSI

Oleh :
FADLIR ROHMAN
NIM. 18650077

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 5 Juni 2025

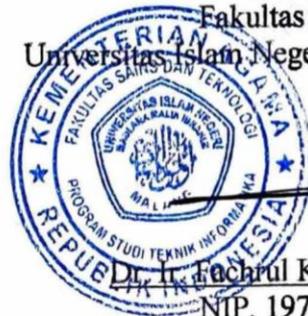
Pembimbing I,


Prof. Dr. Suhartono, M.Kom
NIP. 19680519 200312 1 001

Pembimbing II,


Dr. Syahiduz Zaman, M.Kom
NIP. 19700502 200501 1 005

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. H. Fachrul Kurniawan S.T., M.MT, IPU
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

**PREDIKSI PERGERAKAN HARGA SAHAM BERDASARKAN
INDIKATOR TEKNIKAL MENGGUNAKAN
LONG SHORT-TERM MEMORY**

SKRIPSI

Oleh :
FADLIR ROHMAN
NIM. 18650077

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 25 Juni 2025

Susunan Dewan Penguji

Ketua Penguji : Supriyono, M.Kom
NIP. 19841010 201903 1 012

Anggota Penguji I : Okta Qomaruddin Aziz, M.Kom
NIP. 19911019 201903 1 013

Anggota Penguji II : Prof. Dr. Suhartono, M.Kom
NIP. 19680519 200312 1 001

Anggota Penguji III : Syahiduz Zaman, M.Kom
NIP. 19700502 200501 1 005



Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi

Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. H. Fachrul Kurniawan S.T., M.MT, IPU
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Fadlir Rohman

NIM : 18650077

Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika

Judul Skripsi : Prediksi Pergerakan Harga Saham Berdasarkan Indikator Teknikal Menggunakan *Long Short-Term Memory*

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 25 Juni 2025

Yang membuat pernyataan,



Fadlir Rohman

NIM.18650077

HALAMAN MOTTO

“Pasti ada tantangan yang berat, Di setiap perjalanan yang hebat”

HALAMAN PERSEMBAHAN

Dengan penuh rasa syukur kepada Allah SWT atas segala rahmat dan kemudahannya, sehingga skripsi ini dapat terselesaikan dengan baik. Karya ini penulis persembahkan kepada:

Kedua Orang Tua

Atas doa, dukungan, dan kasih sayang yang tidak pernah henti.

Kakak, Adik dan Kerabat

Atas dukungan dan doa yang selalu menyertai.

Dosen pembimbing dan seluruh pengajar

Atas ilmu dan bimbingannya selama masa studi.

Teman-teman dan sahabat

Yang selalu kebersamaan dalam setiap perjalanan studi.

Diri Sendiri

Yang telah berusaha, bertahan dan semangat untuk terus melangkah.

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Alhamdulillah rabbilalamin, segala puji dan syukur senantiasa penulis panjatkan ke hadirat Allah SWT atas berkat Rahmat, serta hidayahNya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Prediksi Pergerakan Harga Saham Berdasarkan Indikator Teknikal Menggunakan *Long Short-Term Memory*” dengan baik dan lancar. Shalawat serta salam semoga tetap tercurah limpahkan kepada Nabi Muhammad SAW, yang telah membawa kita dari zaman kebodohan menuju zaman kebenaran yakni Islam dan zaman yang penuh dengan ilmu pengetahuan sebagaimana yang di rasakan pada saat ini. Dan semoga kita semua mendapat syafaatnya di hari akhir kelak, Amin.

Penulis mengucapkan rasa terima kasih yang begitu besar kepada seluruh pihak yang memberikan dukungan dan motivasi kepada penulis sehingga dapat menyelesaikan skripsi ini. Ucapan terima kasih ini penulis disampaikan kepada:

1. Prof. Dr. M. Zainuddin, M.A., selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang
2. Prof. Dr. Hj. Sri Harini, M.Si., selaku dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Dr. Ir. Fachrul Kurniawan, S.T., M.MT., IPU selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Prof. Dr. Suhartono, M.Kom selaku Dosen Pembimbing I dan Syahiduz Zaman, M.Kom selaku Dosen Pembimbing II yang telah memberikan

bimbingan, arahan, masukan, dan motivasi dalam proses penyusunan skripsi ini.

5. Supriyono, M.Kom dan Okta Qomaruddin Aziz, M.Kom selaku Dosen Penguji yang telah memberikan saran, kritik, bimbingan beserta masukan untuk menyempurnakan skripsi ini.
6. Seluruh dosen dan staf Program Studi Teknik Informatika, atas segala ilmu, bantuan, dan sarana prasarana yang telah disediakan sepanjang perjalanan akademik.
7. Bapak Suryanto dan Ibu Fatimah selaku kedua orang tua penulis atas cinta, doa, dukungan tanpa henti; serta kakak, adik penulis yang selalu memberikan semangat
8. Orang terdekat yang menjadi sumber semangat, sarana berdiskusi, dan bertukar pikiran. Pejuang S.Kom yang telah membersamai penulis sejak awal perkuliahan.
9. Saudara Teknik Informatika khususnya UFO '18 yang telah menjadi bagian dari perjalanan akademik serta senantiasa saling mendukung.
10. Seluruh pihak yang tidak dapat penulis sebutkan satu per satu atas bantuannya selama masa studi berlangsung.
11. Untuk diri sendiri, Fadlir Rohman, yang telah melalui banyak proses jatuh, bangkit, lelah, namun tetap berjalan. Terima kasih telah bertahan sejauh ini, terus belajar, dan tidak menyerah. Semoga tetap konsisten dalam hal baik, terus berproses, dan tidak lupa tujuan awal. Ingat, segala sesuatu butuh waktu, dan selama terus melangkah, tidak ada usaha yang sia-sia. Percayalah, kerja keras

dan doa tidak pernah mengkhianati hasil. Tidak ada kata terlambat untuk menciptakan kehidupan yang kamu inginkan.

Penulis menyadari bahwa skripsi ini masih memiliki kekurangan. Penulis sangat mengharapkan masukan serta kritik yang membangun sebagai perbaikan kedepannya. Penulis berharap agar skripsi ini tidak hanya bermanfaat bagi para pembaca, namun juga dapat memberikan kontribusi bagi ilmu dan teknologi di masyarakat. *Wassalamu'alaikum Warahmatullahi Wabarakatuh.*

Malang, 25 Juni 2025

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
HALAMAN MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	xi
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xiv
ABSTRAK	xv
ABSTRACT	xvi
مستخلص البحث	xvii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Batasan Masalah	6
1.4 Tujuan Penelitian	6
1.5 Manfaat Penelitian	7
BAB II STUDI PUSTAKA	6
2.1 Penelitian Terkait	6
2.2 Saham	10
2.3 Indikator Teknikal	10
2.3.1 <i>Moving Average (MA)</i>	11
2.3.2 <i>Moving Average Convergence Divergence (MACD)</i>	12
2.3.3 <i>Relative Strength Index (RSI)</i>	13
2.4 <i>Long Short-Term Memory</i>	14
2.5 Evaluasi Model	19
2.5.1 <i>Mean Squared Error (MSE)</i>	19
2.5.2 <i>Mean Absolute Error (MAE)</i>	19
2.5.3 <i>Confusion Matrix</i>	20
BAB III DESAIN DAN IMPLEMENTASI	22
3.1 Studi Literatur	23
3.2 Pengumpulan Data	23
3.3 Perancangan Model	25
3.4 <i>Preprocessing Data</i>	26
3.5 Pembagian Data	28
3.6 Pembangunan Arsitektur dan Pelatihan Model LSTM	29
3.6.1 <i>Hyperparameter Tuning</i>	32

3.7 Uji Coba Pada Data Testing.....	32
3.7.1 Skenario Uji Coba	32
3.7.2 Implementasi Prediksi	34
3.8 Evaluasi Model	34
BAB IV HASIL DAN PEMBAHASAN	35
4.1 Hasil	35
4.1.1 <i>Preprocessing</i> Data	35
4.1.2 Pelatihan Model.....	37
4.1.3 Evaluasi Kinerja Model.....	42
4.2 Pembahasan.....	47
4.2.1 Interpretasi Hasil Prediksi Harga.....	47
4.2.2 Evaluasi Akurasi Arah Pergerakan.....	48
4.2.3 Kelebihan dan Keterbatasan Model.....	49
4.3 Integrasi Nilai Islam.....	50
4.3.1 Muamalah Ma'allah.....	51
4.3.2 Muamalah Ma'allah.....	52
BAB V KESIMPULAN DAN SARAN	54
5.1 Kesimpulan	54
5.2 Saran	55
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 2.1 Arsitektur LSTM.....	15
Gambar 2.2 <i>forget gate</i> LSTM. Sumber: (Olah, 2015).....	15
Gambar 2.3 <i>input gate</i> LSTM. Sumber: (Olah, 2015).....	16
Gambar 2.4 Memperbarui <i>cell state</i> pada LSTM. Sumber: (Olah, 2015).....	17
Gambar 2.5 <i>Output gate</i> LSTM. Sumber: (Olah, 2015).....	18
Gambar 3.1 Tahapan Penelitian.....	22
Gambar 3.2 Kode Pengumpulan Data Historis ADHI.....	24
Gambar 3.3 Perancangan Model.....	26
Gambar 3.4 Indikator Teknikal.....	27
Gambar 3.5 Arsitektur Model LSTM.....	29
Gambar 4.1 Fitur input.....	36
Gambar 4.2 Hasil Normalisasi.....	36
Gambar 4.3 Source Code Implementasi Sliding Window.....	37
Gambar 4.4 Grafik Hasil Tuning Hyperparameter.....	41
Gambar 4.5 Grafik Loss Selama Pelatihan Model.....	41
Gambar 4.6 Perbandingan Harga Aktual dan Prediksi pada Data testing.....	43
Gambar 4.7 Distribusi Kesalahan (Error) Prediksi Harga Saham.....	43
Gambar 4.8 Perbandingan Arah Pergerakan Harga Aktual dan Hasil Prediksi....	44
Gambar 4.9 Confusion Matrix Prediksi Arah Pergerakan Harga.....	45

DAFTAR TABEL

Tabel 2.1 Penelitian Terdahulu	9
Tabel 2.2 Penelitian Terdahulu	20
Tabel 3.1 Historical Data Saham	25
Tabel 3.2 Hyperparameter Tuning	32
Tabel 4.1 Top 10 Kombinasi Hyperparameter Model LSTM	38
Tabel 4.2 Contoh Hasil Prediksi pada Data Testing	46

ABSTRAK

Rohman, Fadlir. 2025. **Prediksi Pergerakan Harga Saham Berdasarkan Indikator Teknikal Menggunakan *Long Short-Term Memory***. Skripsi. Jurusan Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Prof. Dr. Suhartono, M.Kom (II) Syahiduz Zaman, M.Kom.

Kata kunci: Prediksi Harga Saham, *Long Short-Term Memory*, Indikator Teknikal, *Moving Average*, MACD, RSI, ADHI.

Prediksi pergerakan harga saham merupakan komponen kritis dalam pengambilan keputusan investasi pasar modal. Penelitian ini menganalisis efektivitas model *Long Short-Term Memory* (LSTM) dalam memprediksi pergerakan harga saham PT Adhi Karya Tbk (ADHI.JK) berbasis indikator teknikal *Moving Average* (MA), *Moving Average Convergence Divergence* (MACD), dan *Relative Strength Index* (RSI). Data historis harga saham periode Januari 2020–Januari 2025 diproses melalui normalisasi *Min-Max Scaler* (0-1) dan transformasi *sliding window* (ukuran 30 hari). Model LSTM dioptimalkan dengan *grid search* untuk menentukan kombinasi hyperparameter optimal (hidden size: 64, num_layers: 1, learning rate: 0.01, batch size: 32). Evaluasi dilakukan pada dua skenario: (1) prediksi harga (regresi) menggunakan *Mean Squared Error* (MSE) dan *Mean Absolute Error* (MAE), serta (2) klasifikasi arah pergerakan harga (naik/turun) menggunakan *confusion matrix*. Hasil menunjukkan model mencapai akurasi tinggi pada prediksi harga dengan MSE 179,83 dan MAE Rp10,50 (skala aktual), mengindikasikan deviasi minimal dari harga aktual. Namun, klasifikasi arah pergerakan hanya mencapai akurasi 40,46% (*precision*: 58,60%, *recall*: 40,46%, *F1-score*: 42,12%) mengindikasikan perlunya pengembangan pendekatan klasifikasi eksplisit. Simpulan penelitian menyatakan LSTM efektif untuk prediksi numerik harga saham berbasis indikator teknikal, tetapi kurang optimal untuk klasifikasi arah. Rekomendasi mencakup pengembangan model klasifikasi terpisah atau *multitask learning* serta integrasi variabel fundamental untuk peningkatan akurasi arah pergerakan.

ABSTRACT

Rohman, Fadlir. 2025. **Stock Price Movement Prediction Based on Technical Indicators Using Long Short-Term Memory**. Thesis. Informatics Engineering Study Program. Faculty of Science and Technology. Universitas Islam Negeri Maulana Malik Ibrahim Malang. Advisor: (I) Prof. Dr. Suhartono, M.Kom (II) Syahiduz Zaman, M.Kom.

Keywords: Stock Price Prediction, Long Short-Term Memory, Technical Indicators, Moving Average, MACD, RSI, ADHI.

Stock price movement prediction is a critical component of capital market investment decision-making. This study analyzes the effectiveness of the Long Short-Term Memory (LSTM) model in predicting the stock price movement of PT Adhi Karya Tbk (ADHI.JK) using technical indicators: Moving Average (MA), Moving Average Convergence Divergence (MACD), and Relative Strength Index (RSI). Historical stock price data from January 2020 to January 2025 were processed via Min-Max Scaler normalization (0-1) and sliding window transformation (30-day window). The LSTM model was optimized through grid search to determine the optimal hyperparameters (hidden size: 64, num_layers: 1, learning rate: 0.01, batch size: 32). Evaluation covered two scenarios: (1) price prediction (regression) using Mean Squared Error (MSE) and Mean Absolute Error (MAE), and (2) movement direction classification (up/down) using a confusion matrix. Results indicate high accuracy in price prediction with MSE 179.83 and MAE IDR 10.50 (actual scale), reflecting minimal deviation from actual prices. However, movement direction classification achieved only 40.46% accuracy (precision: 58.60%, recall: 40.46%, F1-score: 42.12%), highlighting the need for explicit classification approaches. The study concludes that LSTM is effective for numerical stock price prediction using technical indicators but suboptimal for directional classification. Recommendations include developing a separate classification model or multitask learning and integrating fundamental variables to improve directional accuracy.

مستخلص البحث

الرحمن، فاضلير. 2025. تنبؤ حركة أسعار الأسهم استنادًا إلى المؤشرات الفنية باستخدام الشبكة العصبية طويلة الذاكرة. البحث الجامعي. قسم الهندسة المعلوماتية، كلية العلوم والتكنولوجيا بجامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرف الأول: ف. د. سوهارتونو، الماجستير؛ المشرف الثاني: شهيد الزمان، الماجستير.

الكلمات الرئيسية: تنبؤ أسعار الأسهم، الشبكة العصبية طويلة الذاكرة، المؤشرات الفنية، المتوسط المتحرك، مؤشر التقارب والتباعد للمتوسطات المتحركة، مؤشر القوة النسبية، شركة.

التنبؤ بحركة أسعار الأسهم هو عنصر حاسم في اتخاذ القرارات الاستثمارية في سوق رأس المال. يهدف هذا البحث إلى تحليل فعالية نموذج الذاكرة الطويلة القصيرة الأجل (LSTM) في التنبؤ بحركة أسعار أسهم شركة أدهي كاريا (ADHI) بناءً على المؤشرات الفنية مثل المتوسط المتحرك (MA)، تقارب وتباعد المتوسطات المتحركة (MACD)، ومؤشر القوة النسبية (RSI). تمت معالجة البيانات التاريخية لأسعار الأسهم خلال الفترة من يناير 2020 إلى يناير 2025 من خلال تطبيع (Min-Max Scaler 0-1) وتحويل نافذة الانزلاق (بحجم 30 يومًا). تم تحسين نموذج LSTM من خلال البحث الشبكي لتحديد المجموعة المثلى من المعلمات الفائقة (الحجم المخفي: 64، عدد الطبقات: 1، معدل التعلم: 0.01، حجم الدفعة: 32). تم إجراء التقييم في سيناريوهين: (1) التنبؤ بالأسعار (الانحدار) باستخدام متوسط الخطأ التربيعي (MSE) ومتوسط الخطأ المطلق (MAE)، و (2) تصنيف اتجاه حركة السعر (صعود/هبوط) باستخدام مصفوفة الارتباك. أظهرت النتائج أن النموذج حقق دقة عالية في التنبؤ بالأسعار مع MSE 179.83 و MAE 10.50 روية (بالقيمة الفعلية)، مما يشير إلى انحراف بسيط عن الأسعار الفعلية. ومع ذلك، لم يتجاوز تصنيف اتجاه الحركة دقة 40.46% (الدقة: 58.60%، الاستدعاء: 40.46%، F1-Score: 42.12%)، مما يشير إلى الحاجة إلى تطوير نهج تصنيف صريح. يخلص البحث إلى أن نموذج LSTM فعال للتنبؤ العددي لأسعار الأسهم بناءً على المؤشرات الفنية، ولكنه ليس الأمثل لتصنيف الاتجاه. تشمل التوصيات تطوير نموذج تصنيف منفصل أو التعلم متعدد المهام، بالإضافة إلى دمج المتغيرات الأساسية لتحسين دقة اتجاه الحركة.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Investasi pada pasar saham telah menjadi salah satu instrumen keuangan yang sangat diminati oleh masyarakat luas untuk meningkatkan nilai kekayaan dan sebagai jaminan terhadap ketidakpastian di masa depan. Pasar saham menawarkan potensi keuntungan yang signifikan, namun di sisi lain, pergerakan harga saham yang sangat dinamis juga menciptakan tantangan dan risiko yang substansial bagi investor. Fluktuasi harga yang cepat dan tidak terduga menuntut kemampuan analisis yang mendalam untuk pengambilan keputusan investasi yang tepat (Fauzan & Syafitri, 2022). Dalam konteks ini, prediksi harga saham menjadi salah satu area penelitian yang sangat krusial, terutama dengan kemajuan teknologi komputasi dan metode analisis data. Menurut Prachyachuwong & Vateekul (2021), akurasi prediksi yang tepat memungkinkan investor untuk membuat keputusan yang lebih bijak dalam mengelola portofolio mereka, meminimalkan risiko, dan mengoptimalkan potensi keuntungan.

Pergerakan harga saham dipengaruhi oleh berbagai faktor kompleks, termasuk kondisi ekonomi makro, politik dan sentimen pasar (Vargas et al., 2018). Hal ini menyebabkan sifat pasar saham yang non-linear dan stokastik yang sulit ditangkap oleh metode analisis tradisional, termasuk model statistik seperti model *Autoregressive Integrated Moving Average* (ARIMA) dan analisis teknikal konvensional. Keterbatasan ini timbul karena model-model konvensional tersebut seringkali bergantung pada asumsi stasioneritas dan linearitas data, asumsi yang

seringkali dilanggar oleh karakteristik data pasar keuangan yang terus berubah dan tidak dapat diprediksi. Hal ini menciptakan kesenjangan antara kebutuhan prediksi akurat dan kemampuan metode konvensional. Keterbatasan fundamental ini mengindikasikan bahwa metode tradisional memiliki batas inheren dalam mencapai akurasi prediksi, sehingga mendorong eksplorasi paradigma baru dalam analisis data keuangan (Raza et al., 2025).

Kemajuan di bidang *Artificial Intelligence* (AI) dan *Machine Learning* (ML), khususnya *Deep Learning* (DL) menawarkan solusi untuk mengatasi tantangan ini. Salah satu pendekatan yang menjanjikan adalah *Long Short-Term Memory* (LSTM), jenis khusus dari *Recurrent Neural Network* (RNN) yang dirancang secara eksplisit untuk memproses data urutan waktu. LSTM memiliki keunggulan dalam mempelajari dependensi jangka panjang dalam data serta mampu mengatasi masalah *vanishing gradient* yang sering terjadi pada jaringan saraf berulang tradisional, sehingga sangat cocok untuk memodelkan data historis seperti pergerakan harga saham (Hewamalage et al., 2021). Penelitian yang dilakukan pada (Chaudhary, 2025) mengkonfirmasi kinerja LSTM yang lebih unggul daripada model ML tradisional dan statistik dalam prediksi harga saham, LSTM telah mencapai akurasi prediksi yang signifikan, seperti *Mean Absolute Percentage Error* (MAPE) sebesar 2.72% pada saham-saham teknologi yang terdaftar di NASDAQ, secara substansial mengungguli model statistik tradisional seperti ARIMA. Hal ini menjadikan LSTM arsitektur yang andal untuk peramalan deret waktu keuangan.

Meskipun ML telah banyak diterapkan dalam prediksi harga saham, masih terdapat keterbatasan dalam literatur yang ada, terutama dalam menangkap kompleksitas non-linear data saham. Banyak penelitian ML sebelumnya hanya berfokus pada akurasi model tanpa mengevaluasi relevansi individual indikator teknikal sebagai *input feature*. Indikator teknikal seperti *Moving Average* (MA), *Moving Average Convergence Divergence* (MACD), dan *Relative Strength Index* (RSI) telah digunakan luas untuk menganalisis pola harga. MA menghaluskan fluktuasi harga untuk mengidentifikasi tren, sementara MACD mengukur divergensi antara dua MA untuk mendeteksi perubahan arah tren. RSI, di sisi lain, memberikan sinyal *overbought* atau *oversold* berdasarkan momentum harga (Daniswara et al., 2022). Integrasi indikator ini sebagai *input feature* dalam model LSTM memungkinkan sistem belajar dari pola historis yang terkait dengan perubahan harga. Penelitian Bustos & Pomares-Quimbaya (2020), menunjukkan bahwa indikator teknikal telah terbukti sebagai data yang paling prediktif untuk meningkatkan akurasi prediksi dibandingkan penggunaan data harga mentah. Oleh karena itu, penelitian ini mengusulkan integrasi tiga indikator teknikal (MA, MACD, RSI) ke dalam arsitektur LSTM untuk mengevaluasi pengaruhnya terhadap akurasi prediksi.

Sebagai studi kasus, PT Adhi Karya (Persero) Tbk (ADHI) yang merupakan salah satu perusahaan konstruksi terbesar di Indonesia yang terdaftar di Bursa Efek Indonesia. Saham ADHI memiliki volatilitas harga saham yang cukup tinggi, menjadikannya objek yang menarik dalam analisis prediksi harga saham. Selain itu, sektor konstruksi merupakan sektor yang sangat dipengaruhi oleh kebijakan

pemerintah, kondisi ekonomi makro, serta perkembangan infrastruktur di Indonesia, sehingga memiliki tantangan tersendiri dalam analisis pasar modal (Talumewo et al., 2023). Karakteristik ini menjadikan saham ADHI sebagai studi kasus ideal pada penelitian ini untuk menguji ketangguhan model LSTM dalam menghadapi lingkungan pasar yang dinamis dan kompleks, memperkuat generalisasi model untuk aset volatil lainnya.

Dengan pemilihan studi kasus ini, serta keseluruhan upaya dalam mengembangkan model prediksi yang akurat, juga dilandasi oleh perspektif filosofis yang lebih luas. Dalam Islam, prinsip perencanaan strategis dan pengelolaan sumber daya yang bijaksana sangat ditekankan dalam menghadapi ketidakpastian. Kisah Nabi Yusuf a.s. dalam Al-Qur'an, khususnya Surah Yusuf ayat 47-49, memberikan teladan yang relevan:

قَالَ تَزْرَعُونَ سَبْعَ سِنِينَ دَأَبًا فَمَا حَصَدْتُمْ فَذَرُوهُ فِي سُنْبُلِهِ ۖ إِلَّا قَلِيلًا مِّمَّا تَأْكُلُونَ ﴿٤٧﴾ ثُمَّ يَأْتِي مِنْ بَعْدِ ذَلِكَ سَبْعٌ شِدَادًا يَأْكُلْنَ مَا قَدَّمْتُمْ لَهُنَّ إِلَّا قَلِيلًا مِّمَّا تُحْصِنُونَ ﴿٤٨﴾ ثُمَّ يَأْتِي مِنْ بَعْدِ ذَلِكَ عَامٌ فِيهِ يُغَاثُ النَّاسُ وَفِيهِ يَعْرِضُونَ ۗ ﴿٤٩﴾

Dia (Yusuf) berkata, “Agar kamu bercocok tanam tujuh tahun (berturut-turut) sebagaimana biasa; kemudian apa yang kamu tuai hendaklah kamu biarkan di tangkainya kecuali sedikit untuk kamu makan (47). Kemudian setelah itu akan datang tujuh (tahun) yang sangat sulit, yang menghabiskan apa yang kamu simpan untuk menghadapinya (tahun sulit), kecuali sedikit dari apa (bibit gandum) yang kamu simpan (48). Setelah itu akan datang tahun, di mana manusia diberi hujan (dengan cukup) dan pada masa itu mereka memeras (anggur) (49).” (QS. Yusuf ayat 47-49).

Ayat-ayat ini mengisahkan tentang pentingnya pandangan ke depan, perencanaan jangka panjang, dan manajemen risiko yang cermat dalam menghadapi siklus ekonomi yang tidak dapat diprediksi. Nabi Yusuf memberikan interpretasi mimpi yang akurat dan strategi pengelolaan hasil panen yang efektif

untuk menghadapi masa paceklik (Musthofa, 2021). Hal ini menggarisbawahi nilai akurasi prediksi dan efisiensi dalam pengelolaan sumber daya, yang sangat relevan dengan upaya memprediksi pergerakan harga saham untuk pengambilan keputusan investasi yang lebih baik.

Dengan demikian, penelitian ini memiliki urgensi yang cukup penting, baik dari perspektif akademik maupun praktis, sejalan dengan landasan filosofis yang telah dijelaskan. Secara akademik, penelitian ini diharapkan berkontribusi pada pengembangan metode analisis data keuangan komputasi yang lebih canggih, dan akurat di bidang keuangan. Secara praktis, hasil penelitian ini berpotensi besar untuk membantu investor dalam membuat keputusan investasi yang lebih informasional dan strategis, serta meningkatkan manajemen risiko, yang pada gilirannya menciptakan nilai signifikan di berbagai industri. Penelitian ini bertujuan mengembangkan model prediksi harga saham berbasis indikator teknikal menggunakan LSTM, dengan harapan dapat mengisi kesenjangan yang ada dalam literatur, dan memberikan manfaat nyata bagi pengelolaan investasi.

1.2 Rumusan Masalah

Berdasarkan pada latar belakang masalah yang telah dipaparkan, rumusan masalah dalam penelitian ini adalah bagaimana penerapan metode *Long Short-Term Memory* (LSTM) dalam memprediksi pergerakan harga saham PT Adhi Karya (Persero) Tbk (ADHI) berdasarkan indikator teknikal?

1.3 Batasan Masalah

Adapun batasan masalah dalam penelitian ini adalah:

1. Penelitian ini hanya berfokus pada pergerakan harga saham PT Adhi Karya (Persero) Tbk (ADHI) yang terdaftar di Bursa Efek Indonesia.
2. Data historis yang digunakan mencakup periode Januari 2020 hingga Januari 2025, diambil dari platform *Yahoo Finance*.
3. Penelitian ini hanya menggunakan tiga indikator teknikal utama, yaitu *Moving Average (MA)*, *Moving Average Convergence Divergence (MACD)*, dan *Relative Strength Index (RSI)*, sebagai variabel *input* dalam model prediksi.
4. Model prediksi yang digunakan terbatas pada metode *Long Short-Term Memory (LSTM)* sebagai pendekatan machine learning untuk data time series.
5. Kinerja model akan diukur menggunakan metrik evaluasi tertentu, yaitu *Mean Squared Error (MSE)* dan *Mean Absolute Error (MAE)*.

1.4 Tujuan Penelitian

Sesuai dengan rumusan masalah yang telah dipaparkan maka tujuan dari penelitian ini adalah menganalisis efektivitas metode *Long Short-Term Memory (LSTM)* dalam memprediksi pergerakan harga saham PT Adhi Karya (Persero) Tbk (ADHI) dengan menggunakan indikator teknikal

1.5 Manfaat Penelitian

Manfaat penelitian ini di antaranya:

1. Bagi Investor dan Pedagang Saham: Penelitian ini dapat memberikan wawasan yang berguna bagi investor dan pedagang saham dalam membuat keputusan investasi yang lebih cerdas.
2. Bagi Pengembangan Metode Prediksi Saham: Penelitian ini berkontribusi pada pengembangan dan penerapan model prediksi harga saham menggunakan teknologi machine learning, khususnya LSTM.
3. Bagi Dunia Akademis: Penelitian ini dapat menjadi referensi bagi studi lebih lanjut di bidang analisis saham dan penerapan model machine learning dalam keuangan.
4. Bagi Pengambilan Keputusan Perusahaan: Hasil penelitian dapat membantu perusahaan atau lembaga keuangan untuk lebih memahami bagaimana indikator teknikal dapat digunakan dalam meramalkan tren pasar saham, yang pada gilirannya dapat membantu mereka dalam merancang kebijakan atau strategi yang lebih efektif.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Penelitian terkait digunakan sebagai referensi atau panduan, di mana teori-teori yang relevan dapat diambil untuk mendukung penelitian ini. Penelitian oleh Talumewo et al. (2023) melakukan peramalan harga penutupan saham harian ADHI untuk lima hari ke depan, dari tanggal 09 Januari 2023 hingga 13 Januari 2023, menggunakan data aktual yang berasal dari periode 09 Januari 2020 hingga 06 Januari 2023. Peramalan dilakukan dengan mengaplikasikan model *ARIMA-GARCH*. Hasil penelitian menunjukkan bahwa data yang digunakan mengandung unsur heteroskedastisitas, dan model terbaik yang diperoleh adalah *ARIMA(1,1,1)-GARCH(1,1)*.

Penelitian oleh Pipin et al., (2023) melakukan prediksi terhadap harga saham perusahaan *blue chip* yang ada di Indonesia dengan kode saham BBKA, BBRI, BMRI, ICBP, TLKM, UNVR. Penelitian ini menerapkan model RNN-LSTM dengan optimasi *Adaptive Moment Estimation* (Adam) dengan memanfaatkan data historis harga saham dan faktor teknikal. Pengujian dengan metrik MSE menunjukkan model menghasilkan prediksi mendekati harga saham aktual dengan nilai *loss* rendah (0,0109012) dan akurasi baik berdasarkan skor *Mean Percentage Error* (MAPE) sebesar 1,74%.

Disisi lain, penelitian oleh Saputra (2023) berupaya untuk meramalkan harga saham bank yang terdaftar pada indeks LQ45 dengan menggunakan metode LSTM. Metode evaluasi yang digunakan dalam sistem prediksi ini adalah MAPE

dalam bentuk *output* persentase. Berdasarkan analisis nilai evaluasi rata-rata dari setiap uji coba, uji coba 1 memiliki nilai evaluasi rata-rata sebesar 0,86%, uji coba 2 memiliki nilai rata-rata 0,70%, dan uji coba 3 memiliki nilai rata-rata 0,77%. Uji coba 2 yang menggunakan variabel *close*, RSI, MACD, dan MA memiliki nilai evaluasi yang lebih baik dengan rata-rata 0,70% dibandingkan uji coba 1 yang hanya menggunakan variabel *close* dan *open*, serta uji coba 3 yang menggunakan variabel *close*, *open*, RSI, MACD, dan MA.

Penelitian yang dilakukan oleh Setiawan et al. (2023) bertujuan untuk mengembangkan sistem analisis harga saham yang memanfaatkan algoritma LSTM. *Dataset* harga saham yang digunakan diperoleh dari *Yahoo Finance* dengan periode pengambilan data mulai 1 Januari 2015 hingga 1 Januari 2022. Sistem ini dibangun dengan menggunakan algoritma LSTM untuk menganalisis pergerakan harga saham. Berdasarkan data yang disajikan, komposisi data terdiri dari 70% data *training* dan 30% data *testing*. Pengujian menggunakan 10 *epoch* menunjukkan hasil yang lebih akurat dibandingkan dengan pengujian lainnya, dengan tingkat akurasi mencapai 99% dan selisih rata-rata harga prediksi dengan harga real close sebesar 5,587 USD.

Selanjutnya, Hanafiah et al. (2023) berfokus pada prediksi harga saham menggunakan metode RNN dengan pendekatan LSTM pada data saham BBNI. Penelitian ini hanya menggunakan data harga penutupan saham harian (*close*) untuk analisis. Dalam perancangan model LSTM, terdapat beberapa parameter yang dikonfigurasi, seperti *dropout*, *dense layer*, *activation function*, dan jumlah *neuron* yang digunakan. Proses pelatihan dilakukan menggunakan optimizer ADAM yang

disediakan oleh *framework Keras*. Pengujian dilakukan dengan menggunakan jumlah *epoch* 10 dan 20 serta *batch size* sebesar 32. Hasil pengujian menunjukkan bahwa nilai MAE dan MAPE digunakan untuk mengevaluasi performa model, dimana semakin rendah nilai MAE dan MAPE, semakin baik akurasi prediksi model. Hasil pengujian dengan *epoch* 10 menghasilkan nilai MAE sebesar 0.0286 dan MAPE sebesar 0.0488, sementara pengujian dengan *epoch* 20 menghasilkan nilai MAE sebesar 0.0150 dan MAPE sebesar 0.0257.

Khairunnisa et al. (2025) menggabungkan metode *Simple Moving Average* (SMA) dan LSTM untuk memprediksi harga saham empat perusahaan tambang yang terdaftar di LQ45. Hasil pengujian menunjukkan bahwa integrasi SMA tidak selalu berkontribusi pada peningkatan akurasi prediksi. Pada perusahaan ANTM, penambahan SMA sedikit menurunkan MAPE dari 5,01% menjadi 4,92%. Namun, pada perusahaan INCO dan PTBA, penambahan SMA justru menyebabkan peningkatan akurasi, dengan MAPE INCO meningkat dari 5,55% menjadi 6,33%, dan MAPE PTBA meningkat dari 6,72% menjadi 7,52%. Sementara itu, ADRO menunjukkan perubahan kecil dalam MAPE, yang meningkat dari 3,74% menjadi 3,86%.

Penelitian yang akan dilakukan nantinya memiliki tujuan untuk melakukan prediksi pergerakan harga saham ADHI menggunakan metode LSTM. Penelitian ini juga berfokus untuk mengeksplorasi pengaruh indikator teknikal seperti MA, MACD dan RSI yang berperan sebagai variabel *input*. Dengan mengintegrasikan indikator-indikator tersebut, peneliti berupaya mengkaji pengaruhnya terhadap performa model dalam memprediksi harga saham.

Tabel 2.1 Penelitian Terdahulu

No	Peneliti (Tahun)	Judul	Metode	Hasil Penelitian
1	Pipin et al. (2023)	Prediksi Saham Menggunakan <i>Recurrent Neural Network</i> (RNN-LSTM) dengan Optimasi <i>Adaptive Moment Estimation</i>	RNN-LSTM	Penggunaan RNN-LSTM yang dioptimalkan dengan algoritma Adam mampu memahami pola temporal serta hubungan non-linear dalam data. Model ini berhasil menghasilkan prediksi yang mendekati nilai sebenarnya dari harga saham, dengan nilai MSE sebesar 0,0109012 dan MPE sebesar 1,74%.
2	Saputra (2023)	<i>Stock Prediction System Using Teknikal Indicators With the Lstm Method</i>	LSTM	Pengujian menggunakan variabel <i>Close</i> , RSI, MACD, dan MA menghasilkan evaluasi rata-rata 0,70% pada uji coba 2, lebih baik daripada uji coba lainnya
3	Setiawan et al. (2023)	Sistem Analisa Harga Saham Menggunakan Algoritma <i>Long Short Term Memory</i> (LSTM)	LSTM	Akurasi 99% dengan selisih rata-rata harga prediksi dengan harga real close sebesar 5,587 USD
4	Hanafiah et al. (2023)	Penerapan Metode <i>Recurrent Neural Network</i> dengan Pendekatan <i>Long Short-Term Memory</i> (LSTM) Untuk Prediksi Harga Saham	LSTM	Pengujian dengan <i>epoch</i> 10 menghasilkan MAE 0.0286 dan MAPE 0.0488, <i>epoch</i> 20 menghasilkan MAE 0.0150 dan MAPE 0.0257
5	Khairunnisa et al. (2025)	Pemodelan Prediktif Harga Saham Menggunakan <i>Simple Moving Average</i> Dengan Metode <i>Long Short-Term Memory</i>	SMA dan LSTM	Integrasi SMA tidak selalu meningkatkan akurasi; beberapa perusahaan menunjukkan penurunan MAPE setelah penambahan SMA

2.2 Saham

Saham adalah salah satu instrumen keuangan yang diperdagangkan di pasar modal. Sebagai bentuk bukti kepemilikan suatu perusahaan, saham memberikan hak bagi pemegangnya untuk memperoleh keuntungan melalui pembagian dividen dan peningkatan nilai saham di pasar. Saham terdiri dari dua kategori utama, yakni saham biasa (*common stock*) dan saham preferen (*preferred stock*). Pemilik saham biasa memiliki hak untuk memberikan suara dalam rapat umum pemegang saham serta peluang memperoleh dividen yang lebih tinggi. Sementara itu, saham preferen memiliki keunggulan dalam prioritas pembagian dividen, meskipun tidak menyertakan hak suara dalam rapat umum pemegang saham.(Handini, 2024).

Harga saham dipengaruhi oleh beberapa faktor, baik itu internal maupun eksternal. Faktor-faktor yang mempengaruhi harga saham antara lain kinerja perusahaan, kondisi ekonomi makro, sentimen pasar, dan bahkan kebijakan pemerintah .Oleh karena itu, analisis pergerakan harga saham menjadi penting untuk membantu investor menentukan keputusan investasi yang lebih tepat (Veronica & Pebriani, 2020).

2.3 Indikator Teknikal

Indikator Teknikal adalah hasil ekstraksi dari deret harga saham dimasa lalu dengan menerapkan rumus matematika (Htun et al., 2023). Indikator teknikal merefleksikan informasi yang tersembunyi dalam pergerakan harga saham indikator tersebut diantaranya, *Moving Average* (MA), *Moving Average Convergence Divergence* (MACD) dan *Relative Strength Index* (RSI). Indikator teknikal ini membantu investor untuk memperkirakan arah pergerakan harga saham

melalui analisis pola historis pergerakan harga (Daniswara et al., 2022). Dengan demikian, penggunaan alat analisis teknikal menjadi salah satu pendekatan yang umum diterapkan dalam upaya memprediksi harga saham.

2.3.1 *Moving Average* (MA)

Moving Average (MA) merupakan salah satu indikator teknikal yang paling umum digunakan dalam menganalisis pergerakan harga saham. Indikator ini berfungsi untuk meratakan fluktuasi harga saham dalam jangka waktu tertentu, sehingga mempermudah dalam mengidentifikasi arah tren harga. Terdapat beberapa varian dari indikator ini, dua di antaranya yang paling sering digunakan adalah *Simple Moving Average* (SMA) dan *Exponential Moving Average* (EMA) (Saiful Hasan et al., 2024).

Indikator SMA dihitung dengan cara menjumlahkan harga penutupan saham dalam periode tertentu, kemudian dibagi dengan jumlah periode tersebut. Misalnya, SMA 10 hari diperoleh dari rata-rata harga penutupan selama 10 hari terakhir. SMA memberikan bobot yang sama terhadap semua data harga penutupan dalam periode tersebut, yang bisa memberikan sinyal yang lebih lambat terhadap perubahan tren.

$$SMA_t = \frac{1}{N} \sum_{i=0}^{N-i} P_{t-i} \quad (2.1)$$

Keterangan:

SMA_t = *Simple Moving Average* pada waktu t

P_{t-i} = Harga penutupan pada waktu $t-i$

N = Jumlah periode

Sementara itu, indikator EMA memberikan bobot lebih besar pada harga terbaru, sehingga indikator lebih cepat merespon perubahan harga dibandingkan dengan SMA.

$$EMA_t = P_t \times \alpha + EMA_{t-1} \times (1 - \alpha) \quad (2.2)$$

$$\alpha = \frac{2}{N + 1} \quad (2.3)$$

Keterangan:

α = Smoothing factor

EMA_t = Exponential *Moving Average* pada waktu t

P_t = Harga penutupan pada waktu t

MA digunakan untuk mengidentifikasi tren harga jangka pendek atau panjang, serta untuk membantu mengkonfirmasi sinyal beli atau jual yang dihasilkan oleh indikator teknikal lainnya (Saiful Hasan et al., 2024).

2.3.2 *Moving Average Convergence Divergence (MACD)*

Moving Average Convergence Divergence (MACD) merupakan indikator teknikal yang digunakan untuk mengidentifikasi perubahan dalam kekuatan, arah, momentum, dan durasi tren harga saham. Perhitungan MACD dilakukan dengan cara mengurangkan EMA periode 26 dengan EMA periode 12. Hasil perhitungan ini menghasilkan garis MACD yang dapat dianalisis lebih lanjut dengan signal line, yang merupakan EMA dari garis MACD itu sendiri, biasanya dengan periode 9 hari (Saiful Hasan et al., 2024).

$$MACD = EMA_{12} - EMA_{26} \quad (2.4)$$

Keterangan:

EMA_{12} = Exponential *Moving Average* 12 periode

EMA_{26} = Exponential *Moving Average* 26 periode

Ketika garis MACD memotong ke atas garis signal line, ini dianggap sebagai sinyal beli, sementara jika garis MACD memotong ke bawah garis signal

line, ini dianggap sebagai sinyal jual. Selain itu, perbedaan antara garis MACD dan signal line juga memberikan informasi mengenai kekuatan tren, di mana semakin besar jarak antara keduanya, semakin kuat tren yang sedang berlangsung. MACD juga digunakan untuk mengidentifikasi kondisi *divergence* dan *convergence*, yang dapat memberikan petunjuk penting mengenai perubahan arah harga saham (Saiful Hasan et al., 2024).

2.3.3 *Relative Strength Index (RSI)*

Relative Strength Index (RSI) adalah indikator momentum yang memiliki fungsi untuk mengukur kecepatan dan perubahan pergerakan harga dalam periode tertentu. RSI dikembangkan oleh J. Welles Wilder pada tahun 1978 dan biasanya dihitung dalam periode 14 hari.

$$RSI = 100 - \left(\frac{100}{1 + RS} \right) \quad (2.5)$$

$$RS = \frac{\text{Average Gain over } N \text{ periods}}{\text{Average Loss over } N \text{ periods}} \quad (2.6)$$

Keterangan:

Average Gain = Rata-rata kenaikan harga dalam N periode.

Average Loss = Rata-rata penurunan harga dalam N periode

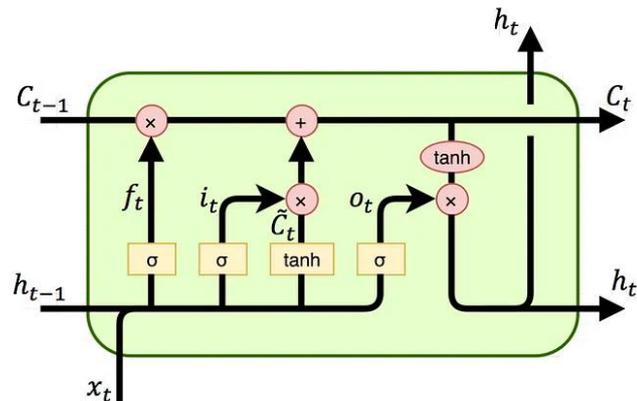
RSI memiliki rentang nilai antara 0 dan 100, dengan nilai di atas 70 menunjukkan bahwa saham berada dalam kondisi *overbought* (terlalu dibeli), dan nilai di bawah 30 menunjukkan kondisi *oversold* (terlalu dijual). RSI memberikan informasi penting mengenai kekuatan tren yang sedang berlangsung. Ketika RSI berada di atas 70, ini mengindikasikan bahwa saham mungkin sudah terlalu mahal dan harga bisa berbalik turun. Sebaliknya, ketika RSI berada di bawah 30, harga saham dianggap sudah terlalu murah dan bisa berbalik naik. RSI juga dapat

digunakan untuk mengidentifikasi pola divergensi antara harga saham dan indikator RSI, yang dapat menjadi tanda awal dari pembalikan tren (Saiful Hasan et al., 2024).

2.4 *Long Short-Term Memory*

Long Short-Term Memory (LSTM) adalah varian dari *Recurrent Neural Network* (RNN) yang dirancang untuk menghadapi tantangan utama dalam memproses data sekuensial, yakni *vanishing* dan *exploding gradients*. Hal ini terjadi karena gradien yang digunakan dalam pelatihan jaringan saraf cenderung mengeksponensialkan nilainya (*explode*) atau menghilang (*vanish*) saat melalui banyak time step, sehingga menghambat kemampuan model dalam mempelajari ketergantungan jangka panjang (Goodfellow et al., 2016). LSTM pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber (1997) dengan arsitektur yang memiliki kemampuan dalam mengendalikan aliran informasi melalui suatu komponen memori internal yang disebut *cell state*, serta mekanisme gerbang (*gates*) yang mengatur proses penyimpanan dan pembaruan informasi.

Setiap unit LSTM memiliki tiga gerbang utama, yaitu *forget gate*, *input gate*, dan *output gate*, yang masing-masing berfungsi untuk mengatur informasi mana yang akan dilupakan, ditambahkan ke dalam memori, dan dikeluarkan sebagai hasil. Selain itu, terdapat *cell state* (C_t) sebagai komponen utama yang mengalir secara longitudinal di antara unit waktu dan membawa informasi penting, serta *hidden state* (h_t) yang menjadi representasi keluaran pada setiap *time-step*.

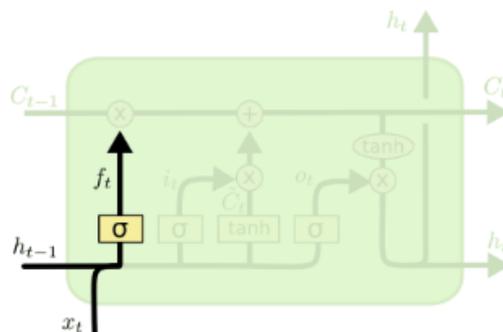


Gambar 2.1 Arsitektur LSTM
Sumber: (Olah, 2015)

Arsitektur LSTM terdiri dari empat komponen utama yang saling berinteraksi melalui operasi linier dan nonlinier. Setiap komponen tersebut memiliki perannya masing masing, berikut ini adalah proses setiap tahapan yang dilakukan pada setiap gerbang yang menyusun LSTM.

a. *Forget gate*

Memutuskan informasi mana yang akan dilupakan dari *cell state* sebelumnya (C_{t-1}). Gate ini menerima *input* dari *hidden state* sebelumnya (h_{t-1}) dan *input* saat ini (x_t), kemudian menghasilkan nilai antara 0 dan 1 melalui fungsi sigmoid (σ) untuk setiap elemen dalam sel memori. Nilai 1 berarti menyimpan memori, sedangkan nilai 0 berarti menghapus memori.



Gambar 2.2 *forget gate* LSTM.
Sumber: (Olah, 2015)

Adapun formula untuk *forget gate* ditunjukkan pada persamaan (2.7).

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.7)$$

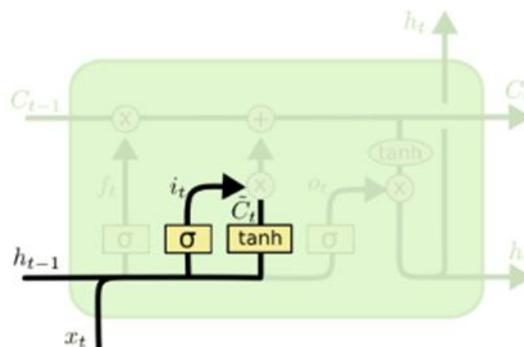
Keterangan:

- f_t = *output* dari *forget gate* pada waktu t
- σ = fungsi aktivasi *sigmoid*
- W_f = bobot *forget gate*
- h_{t-1} = status *output* dari timestep sebelumnya
- x_t = *input* pada timestep t
- b_f = bias dari *forget gate*

b. *Input gate*

Memutuskan informasi mana yang akan disimpan ke dalam *cell state*.

Terdiri dari dua bagian yaitu lapisan *sigmoid* (σ) yang menentukan nilai mana yang akan diperbarui, dan lapisan *tanh* yang menghasilkan vektor kandidat nilai baru yang dapat ditambahkan ke *cell state* (\tilde{C}_t).



Gambar 2.3 *input gate* LSTM.
Sumber: (Olah, 2015)

Persamaan (2.8) digunakan untuk menghitung *input gate* dan persamaan (2.9) untuk kandidat baru.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.8)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (2.9)$$

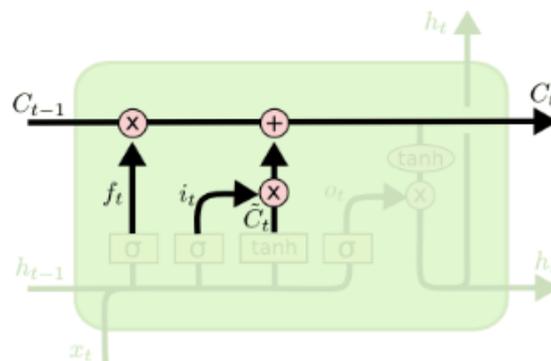
Keterangan:

- i_t = *input gate* pada waktu t
- W_i = bobot *input gate*
- h_{t-1} = hasil dari *hidden state* sebelumnya
- x_t = *input* ke- t

- b_i = bias dari *input gate*
 \tilde{C}_t = kandidat yang ditambah ke *cell state* yang diperbarui.
 \tanh = fungsi *tanh*
 W_c = bobot *cell state* yang diperbarui
 b_c = bias operasi *cell state* yang diperbarui

c. Pembaruan *Cell State*

Pembaruan *cell state* (C_t) dilakukan dengan menggabungkan informasi lama yang relevan dengan informasi baru yang penting. Nilai (f_t) dari *forget gate* menentukan seberapa banyak informasi dari *cell state* sebelumnya (C_{t-1}) yang harus dipertahankan, sedangkan nilai (i_t) dari *input gate* mengatur seberapa besar informasi baru yang akan ditambahkan. Operasi ini melibatkan perkalian yang kemudian dijumlahkan untuk membentuk *cell state* baru, sebagaimana ditunjukkan oleh simbol “ \times ” dan “ $+$ ” dalam diagram alur LSTM serta dirumuskan pada Persamaan (2.10)



Gambar 2.4 Memperbarui *cell state* pada LSTM.
 Sumber: (Olah, 2015)

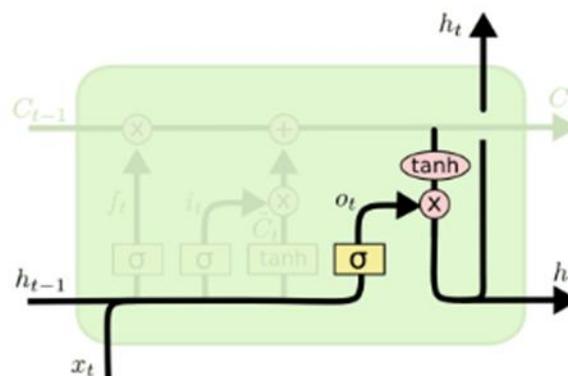
$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (2.10)$$

Keterangan:

- C_t = *cell state* pada waktu ke- t
 f_t = *forget gate*
 C_{t-1} = *cell state* pada *time step* sebelumnya
 \tilde{C}_t = nilai *cell state* baru pada hasil perhitungan *input gate*

d. *Output Gate*

Mengatur informasi mana yang akan dikeluarkan sebagai *output*. *Output gate* menerima masukan gabungan dari *hidden state* sebelumnya dan *input* saat ini, yang diproses menggunakan fungsi aktivasi sigmoid untuk menghasilkan nilai (o_t). Selain itu, *gate* ini juga memanfaatkan *cell state* yang telah diperbarui (C_t), yang kemudian dikenakan fungsi aktivasi tanh untuk membentuk vektor representasi baru. Hasil dari fungsi tanh selanjutnya dikalikan dengan (o_t), menghasilkan hidden state baru (h_t) yang berperan sebagai output aktual dari unit LSTM. Proses perkalian ini digambarkan melalui lingkaran berwarna merah muda dengan simbol “×” yang terletak antara fungsi tanh dan (o_t), menunjukkan bahwa hanya informasi yang relevan dan signifikan yang diloloskan sebagai output. Adapun mekanisme dari *output gate* secara matematis dijelaskan pada Persamaan (2.11) dan (2.12).



Gambar 2.5 *Output gate* LSTM.
Sumber: (Olah, 2015)

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.11)$$

$$h_t = o_t * \tanh(C_t) \quad (2.12)$$

Keterangan:

- o_t = *output* dari *output gate* pada waktu t
- W_o = bobot *output gate*
- h_{t-1} = hasil *output* pada *time step* ke- t

x_t = input pada time step ke- t
 b_o = bias output gate
 h_t = output pada time step ke- t

2.5 Evaluasi Model

2.5.1 Mean Squared Error (MSE)

Mean Squared Error (MSE) adalah salah satu metrik yang digunakan untuk mengukur seberapa baik sebuah model dalam memprediksi nilai atau estimasi. MSE menghitung rata-rata dari kuadrat selisih antara nilai prediksi model dan nilai aktual. Nilai MSE yang lebih rendah menunjukkan tingkat akurasi prediksi model yang lebih tinggi.. Pada dasarnya, MSE menghitung seberapa besar kesalahan yang terjadi dalam prediksi model dengan menghitung perbedaan (*error*) antara nilai prediksi dan nilai aktual, kemudian mengkuadratkan nilai perbedaan tersebut untuk menghindari nilai negatif. Setelah itu, nilai kesalahan tersebut dirata-ratakan untuk mendapatkan nilai MSE (Ardika et.al, 2023). Rumus untuk menghitung MSE adalah sebagai berikut (Kurniawan et al., 2023).

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.13)$$

Keterangan:

n = jumlah data (jumlah observasi atau titik data)
 y_i = nilai aktual (data yang sebenarnya) pada titik data ke- i
 \hat{y}_i = nilai prediksi (nilai yang diprediksi oleh model) pada titik data ke- i

2.5.2 Mean Absolute Error (MAE)

Mean Absolute Error (MAE) mengukur rata-rata dari selisih absolut antara nilai prediksi dan nilai aktual. Tidak seperti metrik yang mempertimbangkan arah kesalahan, MAE hanya fokus pada besarnya deviasi tanpa memperhatikan apakah prediksi tersebut lebih tinggi atau lebih rendah dari nilai sebenarnya. Dengan

demikian, MAE memberikan gambaran yang objektif mengenai seberapa besar kesalahan rata-rata yang dilakukan oleh model dalam proses prediksi. (Ardika et.al, 2023). Adapun rumus umum untuk menghitung MAE dapat dituliskan sebagai berikut.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.14)$$

Keterangan:

n = jumlah data (jumlah observasi atau titik data)

y_i = nilai aktual (data yang sebenarnya) pada titik data ke- i

\hat{y}_i = nilai prediksi (nilai yang diprediksi oleh model) pada titik data ke- i

2.5.3 Confusion Matrix

Confusion Matrix adalah metode evaluasi yang digunakan dalam masalah klasifikasi untuk mengukur performa model dengan membandingkan hasil prediksi dengan data aktual. *Confusion Matrix* direpresentasikan dalam bentuk tabel yang menggambarkan jumlah prediksi yang benar dan salah untuk setiap kategori dalam suatu masalah klasifikasi (Alghifari et al., 2022).

Tabel 2.2 *Confusion Matrix*

		Predicted	
		Positive	Negative
Actual	Positive	True Positive (TP)	False Negative (FN)
	Negative	False Positive (FP)	True Negative (TN)

Dengan menggunakan *Confusion Matrix*, berbagai metrik evaluasi dapat dihitung untuk menilai performa model klasifikasi secara lebih mendalam, di antaranya:

1. *Accuracy* yang merupakan rasio antara jumlah prediksi yang benar dengan total jumlah data, dihitung dengan persamaan:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.15)$$

2. *Precision* merupakan rasio antara jumlah prediksi positif yang benar dengan total jumlah prediksi positif. Ini mengukur seberapa akurat model dalam memprediksi kelas positif.:

$$Precision = \frac{TP}{TP + FP} \quad (2.16)$$

3. *Recall* merupakan Rasio antara jumlah prediksi positif yang benar dengan total jumlah data yang sebenarnya positif. Ini mengukur seberapa baik model dapat mendeteksi kelas positif.

$$Recall = \frac{TP}{TP + FN} \quad (2.17)$$

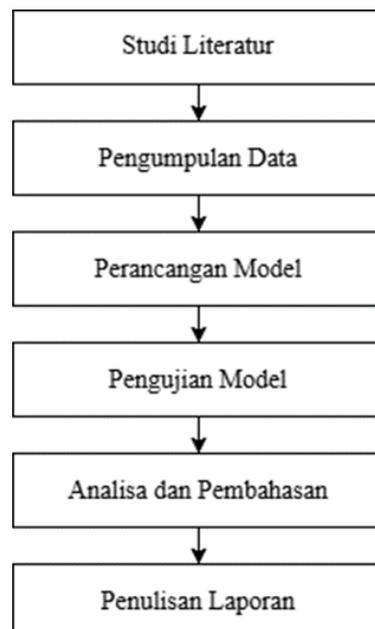
4. *F1-score* merupakan ukuran gabungan dari *precision* dan *recall*, yang merupakan rata-rata harmonik dari kedua metrik tersebut. Perhitungan ini berguna saat terjadi ketidakseimbangan kelas.

$$F1_{score} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.18)$$

BAB III

DESAIN DAN IMPLEMENTASI

Pada bab ini, akan dibahas mengenai tahapan-tahapan penelitian yang akan dilakukan secara sistematis dan berurutan. Proses penelitian mencakup beberapa langkah, dimulai dari studi literatur untuk memahami konsep dan teori yang relevan, dilanjutkan dengan pengumpulan data historis harga saham yang akan digunakan. Selanjutnya dilakukan perancangan model, yang mencakup pemilihan fitur *input* dan perancangan arsitektur LSTM yang akan digunakan dalam pelatihan model. Setelah model dirancang, dilakukan pengujian model untuk menilai performa model. Hasil pengujian kemudian dianalisis, guna mengevaluasi akurasi dan efektivitas model berdasarkan metrik evaluasi yang digunakan. Tahap akhir adalah penulisan laporan, yang mendokumentasikan seluruh proses, temuan, serta kesimpulan yang diperoleh selama pelaksanaan penelitian.



Gambar 3.1 Tahapan Penelitian

3.1 Studi Literatur

Dalam tahap ini, dilakukan kajian literatur yang berkaitan dengan topik penelitian, khususnya yang berfokus pada prediksi harga saham menggunakan metode LSTM dan indikator teknikal. Kajian mencakup pemahaman mengenai konsep harga saham dan faktor-faktor yang mempengaruhi pergerakannya dipasar modal. Selain itu, mempelajari berbagai jenis indikator teknikal yang umum digunakan dalam analisis saham, seperti MA, MACD, RSI, serta peran masing-masing dalam membantu memprediksi pergerakan harga saham.

Selanjutnya, dipelajari konsep dasar LSTM sebagai salah satu arsitektur jaringan saraf buatan yang dirancang untuk menangani data berurutan seperti data saham, serta bagaimana keandalannya dalam melakukan prediksi. Terakhir, dilakukan telaah terhadap metode evaluasi performa model prediksi, di antaranya MSE, MAE, dan *Confusion Matrix*, yang digunakan untuk mengukur tingkat akurasi dan ketepatan hasil prediksi yang dihasilkan oleh model.

3.2 Pengumpulan Data

Tahapan pengumpulan data dalam penelitian ini bertujuan untuk memperoleh *dataset* historis harga saham yang diperlukan untuk analisis dan pelatihan model prediksi menggunakan *Long Short-Term Memory* (LSTM). Berikut adalah tahapan pengumpulan data yang dilakukan:

1. Menentukan Sumber Data

Data historis harga saham akan diambil dari sumber terpercaya, seperti *Yahoo Finance*, yang menyediakan informasi lengkap tentang harga saham,

termasuk harga pembukaan (*open*), harga penutupan (*close*), harga tertinggi (*high*), harga terendah (*low*), dan volume perdagangan.

2. Pemilihan Periode Waktu

Periode data yang akan dikumpulkan disesuaikan dengan kebutuhan penelitian, misalnya data historis selama lima tahun terakhir untuk memberikan cakupan waktu yang cukup untuk analisis tren dan pelatihan model. Dalam penelitian ini, data yang digunakan mencakup periode dari 2 Januari 2020 hingga 24 Januari 2025.

3. Menentukan Saham yang Dikaji

Saham yang akan dianalisis dalam penelitian ini dipilih berdasarkan relevansi dan ketersediaan data. Sebagai contoh, penelitian ini fokus pada saham PT Adhi Karya (Persero) Tbk (kode saham: ADHI.JK).

4. Penggunaan *Library Python* untuk Mengunduh Data

Data historis akan diunduh menggunakan *library Python* seperti *yfinance*. *Library* ini memungkinkan pengambilan data saham secara langsung dengan format yang mudah diolah untuk analisis lebih lanjut. Contoh kode untuk mengunduh data:

```
import yfinance as yf
data = yf.download('ADHI.JK', start='2020-01-02', end='2025-01-24')
```

Gambar 3.2 Kode Pengumpulan Data Historis ADHI

5. Validasi Data

Data yang telah diunduh akan diperiksa kelengkapannya, seperti ketersediaan semua kolom yang dibutuhkan (harga penutupan, volume perdagangan, dll.). Selain itu, data akan diperiksa untuk mendeteksi adanya nilai

yang hilang (*missing values*) atau anomali, seperti *outlier*, yang dapat memengaruhi hasil analisis.

6. Transformasi dan Penyimpanan Data

Data yang telah dikumpulkan akan disimpan dalam format yang sesuai, seperti file CSV, untuk mempermudah pengolahan lebih lanjut.

Tabel 3.1 Historical Data Saham

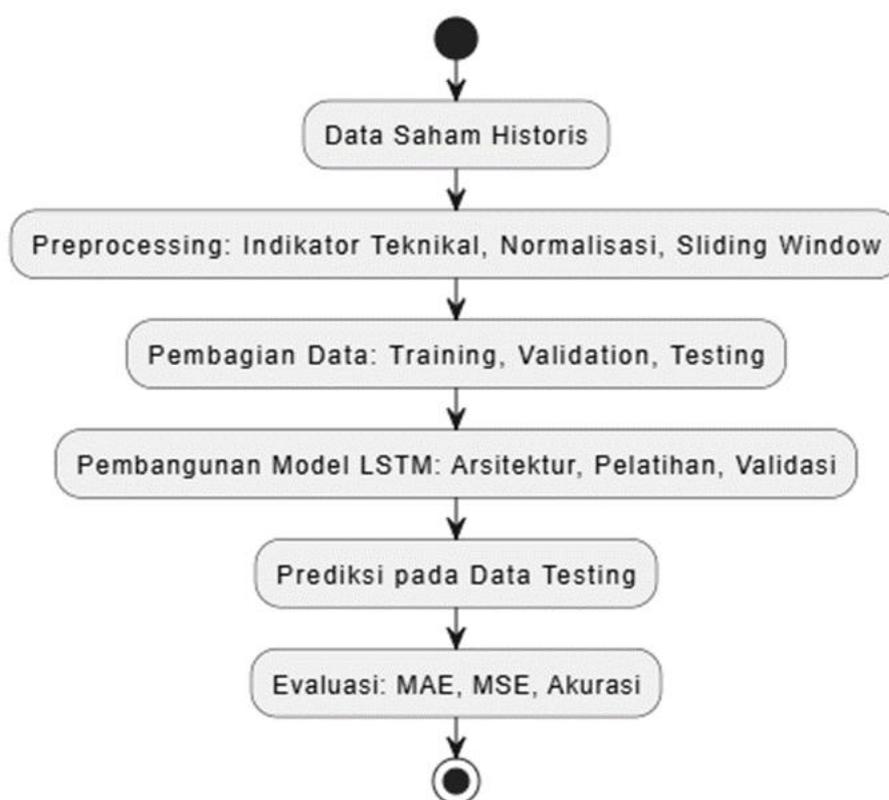
Date	Close	High	Low	Open	Volume
2020-01-02	1039,10	1056,86	1025,78	1047,98	5584982
2020-01-03	1074,63	1079,07	1043,54	1043,54	14759428
2020-01-06	1052,42	1074,63	1052,42	1074,63	14202885
...
2025-01-22	228,00	242,00	228,00	234,00	21798100
2025-01-23	228,00	236,00	228,00	230,00	12503900
2025-01-24	224,00	232,00	224,00	232,00	4446800

Tabel 3.1 memuat beberapa kolom dengan penjelasan sebagai berikut, *Close* menunjukkan harga penutupan saham pada akhir periode perdagangan, *High* mencerminkan harga tertinggi yang dicapai saham selama periode tersebut, *Low* menunjukkan harga terendah yang dicapai saham dalam periode perdagangan, *Open* merupakan harga pembukaan saham pada awal periode perdagangan, dan *Volume* menunjukkan jumlah total saham yang diperdagangkan selama periode tersebut.

3.3 Perancangan Model

Perancangan model dibagi menjadi beberapa tahap, dimulai dari pengumpulan data saham historis, kemudian *preprocessing* data dengan melakukan perhitungan indikator teknikal sebagai fitur tambahan, normalisasi dan penerapan

sliding window. Setelah itu, data dibagi menjadi tiga bagian yaitu data *training*, *validation* dan *testing*. Arsitektur LSTM dibangun dan dilatih menggunakan data pelatihan dengan validasi untuk meningkatkan generalisasi model. Setelah model terlatih, dilakukan prediksi terhadap data *testing* guna melihat kemampuan model dalam melakukan generalisasi terhadap data baru dan terakhir hasil prediksi dievaluasi untuk mengukur performa model.



Gambar 3.3 Perancangan Model

3.4 *Preprocessing Data*

Pada tahap *preprocessing* yaitu mempersiapkan data sebelum diolah dengan tujuan untuk meningkatkan kualitas data menjadi baik, terstruktur, dan sesuai dengan kebutuhan prediksi (Abdi et al., 2023). Beberapa tahapan *preprocessing* data dalam penelitian ini:

1. Pembentukan Indikator Teknikal

Perhitungan indikator teknikal bertujuan untuk mengolah data saham historis yang telah dikumpulkan sebelumnya menjadi fitur-fitur yang lebih informatif, yang nantinya dapat digunakan oleh model. Pengolahan dilakukan dengan menggunakan bantuan *library Technical Analysis (ta)* yang disediakan oleh *Python*. *Library* ini dirancang untuk rekayasa fitur dari kumpulan data deret waktu keuangan, khususnya menggunakan data *open*, *close*, *high*, *low* dan *volume*. Berikut adalah indikator teknikal yang diolah dari data saham historis.

Date	SMA_20	SMA_50	MACD	MACD_signal	MACD_histogram	RSI
2020-03-11	738.028268	880.305212	-80.754057	-69.289038	-11.465019	18.818224
2020-03-12	722.708188	869.825388	-87.267716	-72.884773	-14.382942	16.504940
2020-03-13	707.610138	858.723878	-91.022269	-76.512272	-14.509996	17.595839
2020-03-16	691.845996	848.066431	-92.926579	-79.795134	-13.131446	17.595839
2020-03-17	671.419220	836.076802	-98.673112	-83.570729	-15.102383	14.337127

Gambar 3.4 Indikator Teknikal

Gambar 3.4 menampilkan data hasil perhitungan indikator teknikal yang meliputi SMA dengan periode 20 dan 50. Indikator lainnya adalah MACD yang merupakan selisih antar EMA 12 dan 26, dan MACD_signal adalah garis sinyal yang biasanya merupakan EMA 9-hari dari nilai MACD. Sedangkan MACD_histogram adalah selisih antara MACD dan MACD_signal. Indikator terakhir adalah RSI untuk periode waktu 14 hari.

2. Normalisasi Data

Normalisasi data adalah proses mengubah data ke dalam rentang seragam untuk menghilangkan perbedaan skala antar fitur, sehingga tidak ada fitur yang

mendominasi dan model dapat memperoleh informasi secara seimbang (Purnamasari et al., 2025). Pada penelitian ini, normalisasi dilakukan menggunakan metode *Min-Max Scaler* (skala 0-1), sesuai dengan persamaan berikut.

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3.1)$$

Keterangan:

- x = Nilai data asli
- x_{\min} = Nilai minimum dari fitur dalam *dataset*
- x_{\max} = Nilai maksimum dari fitur dalam *dataset*
- x' = Nilai data setelah dinormalisasi

3. Segmentasi Data

Segmentasi data dilakukan dengan teknik *sliding window* dengan ukuran jendela 30 hari dan *step size* 1 hari diterapkan untuk membentuk struktur data sekuensial yang sesuai dengan karakteristik temporal pasar saham. Setiap jendela data mencakup rangkaian fitur historis (seperti harga penutupan, indikator teknikal, dan volume) selama 30 hari berturut-turut, dengan output berupa nilai harga saham pada hari ke-31. Secara matematis, struktur *input-output* dapat direpresentasikan sebagai:

$$\text{Input: } [X_{t-29}, X_{t-28}, \dots, X_t] \rightarrow \text{Output: } [X_{t+1}]$$

Proses ini dilakukan secara iteratif dengan menggeser jendela satu hari ke depan setiap kali, sehingga menghasilkan overlap 29 hari antar jendela. Overlap ini memastikan model dapat mempelajari pola berkelanjutan dan mengurangi risiko kehilangan informasi temporal.

3.5 Pembagian Data

Dataset dibagi dengan rasio 70:15:15 untuk *training*, *validation*, dan *testing*. Pembagian ini memastikan model dapat dilatih dengan data yang cukup (70%),

dioptimalkan melalui validasi (15%), dan diuji pada data independen (15%). Rasio dipilih berdasarkan studi sebelumnya yang menunjukkan keseimbangan optimal antara kapasitas generalisasi dan pencegahan *overfitting* (Pahlevi, 2023).

3.6 Pembangunan Arsitektur dan Pelatihan Model LSTM

Model LSTM yang digunakan dalam penelitian ini memiliki beberapa lapisan utama yang dikembangkan dengan *library PyTorch*. Arsitektur awal ini berperan sebagai titik acuan mendasar untuk mendefinisikan struktur model dan memungkinkan proses pelatihan awal dapat dijalankan. Inisialisasi ini juga secara implisit mendefinisikan ruang pencarian untuk penyesuaian *hyperparameter* selanjutnya, yang dirancang untuk memproses data deret waktu dan menemukan pola-pola penting untuk prediksi harga saham. Konfigurasi model didasarkan pada serangkaian lapisan yang diatur secara sekuensial, memungkinkan aliran informasi yang terstruktur dari *input* hingga output prediksi.

Layer (type:depth-idx)	Output Shape	Param #
StockLSTM	[32, 1]	--
└ LSTM: 1-1	[32, 30, 64]	18,944
└ Sequential: 1-2	[32, 1]	--
└ Linear: 2-1	[32, 32]	2,080
└ ReLU: 2-2	[32, 32]	--
└ Dropout: 2-3	[32, 32]	--
└ Linear: 2-4	[32, 1]	33
Total params: 21,057		
Trainable params: 21,057		
Non-trainable params: 0		

Gambar 3.5 Arsitektur Model LSTM

Arsitektur model LSTM yang diterapkan dalam penelitian ini dirancang dengan beberapa komponen utama yang saling terintegrasi. Struktur dari model ini

ditunjukkan pada Gambar 3.6, yang memberikan gambaran menyeluruh mengenai alur dan hubungan antar bagian dalam model tersebut.

1. Lapisan Masukan (*Input Layer*)

Lapisan ini merupakan titik awal masuknya data yang telah diproses ke dalam model. Data masukan adalah *sequence* dari fitur-fitur saham yang telah dinormalisasi dan dibentuk menggunakan teknik *sliding window*. Dimensi masukan yang diharapkan oleh model adalah (*batch_size*, *sequence_length*, *num_features*), di mana *sequence_length* merepresentasikan jumlah langkah waktu historis yang diamati (misalnya, 30 hari), dan *num_features* adalah jumlah jumlah fitur *input* (*Close*, *Volume*, MA, MACD, RSI).

2. Lapisan LSTM (*LSTM Layer*)

Ini adalah lapisan inti dari arsitektur model, yang dirancang khusus untuk menangani dependensi jangka panjang dalam data sekuensial. Lapisan LSTM ini dikonfigurasi dengan 64 unit tersembunyi (*hidden units*) (Dopi, 2023). Jumlah unit ini menentukan kapasitas model untuk belajar dan menyimpan informasi dari urutan masukan. Output dari lapisan LSTM ini diatur untuk menghasilkan *hidden state* dari langkah waktu terakhir dari setiap *sequence* masukan, yang kemudian akan diteruskan ke lapisan selanjutnya. Pengaturan ini relevan karena prediksi yang dicari adalah nilai tunggal untuk langkah waktu berikutnya, bukan sebuah *sequence* output.

3. Jaringan Sekuensial (*Output Layer*)

Jaringan *Sequential* memperoleh *output* dari lapisan LSTM dan melakukan pemrosesan terakhir yang diperlukan untuk menghasilkan prediksi harga saham.

Jaringan ini terdiri dari beberapa lapisan yang tersusun secara berurutan. Pertama, terdapat lapisan linear yang mereduksi jumlah neuron dari 64 menjadi 32 *neuron*, dengan total 2.080 parameter yang dapat dilatih. Selanjutnya, fungsi aktivasi *Rectified Linear Unit* (ReLU) diterapkan untuk menambahkan sifat non-linearitas ke dalam model, memungkinkan pembelajaran terhadap pola-pola kompleks dan non-linear yang umum pada data harga saham (Howard & Gugger, 2020). Untuk mengurangi risiko *overfitting*, digunakan lapisan *dropout* yang secara acak menonaktifkan beberapa *neuron* selama pelatihan, sehingga model terdorong untuk mempelajari representasi yang lebih kuat dan tidak bergantung pada neuron tertentu (Howard & Gugger, 2020). Terakhir, lapisan linear kedua mereduksi dimensi dari 32 neuron menjadi satu *neuron*, yang berfungsi sebagai output akhir berupa prediksi harga saham.

Konfigurasi statis ini membentuk kerangka dasar di mana model akan belajar dan beroperasi. Pada proses pelatihan, data mengalir dari *input layer* melalui lapisan LSTM, kemudian diproses oleh jaringan sekuensial hingga menghasilkan prediksi. Selanjutnya, bobot model diperbarui secara iteratif menggunakan *optimizer* Adam dengan fungsi *loss* MSE, memanfaatkan 70% data *training* dalam iterasi *epoch*. Performa model dipantau menggunakan 15% data *validation*, dengan penerapan *early stopping* yang menghentikan pelatihan jika *validation loss* tidak membaik dalam sejumlah *epoch* berturut-turut. Pendekatan ini memastikan model tidak hanya menguasai pola data pelatihan tetapi juga mempertahankan kemampuan generalisasi terhadap data baru.

3.6.1 *Hyperparameter Tuning*

Sebagai tahap penyempurnaan model *hyperparameter tuning* dilakukan untuk mengoptimalkan performa dengan mencari kombinasi *hyperparameter* terbaik. Dalam penelitian ini, metode *Grid Search* digunakan untuk menguji berbagai kombinasi *hyperparameter* model LSTM. Metode ini melibatkan pengujian setiap kemungkinan kombinasi *hyperparameter* yang telah ditentukan. *Hyperparameter* yang akan diuji dalam penelitian ini ditunjukkan pada Tabel 3.2.

Tabel 3.2 Hyperparameter Tuning

<i>Hyperparameter</i>	<i>Value</i>
<i>hidden_size</i>	[32, 64, 128]
<i>num_layer</i>	[1, 2, 3]
<i>learning_rate</i>	[0.001, 0.01]
<i>batch_size</i>	[16, 32, 64]

Total 54 kombinasi diuji untuk menentukan konfigurasi optimal. Evaluasi didasarkan pada *validation loss* MSE. Proses ini memastikan model mencapai performa tertinggi tanpa *overfitting*.

3.7 Uji Coba Pada Data Testing

3.7.1 Skenario Uji Coba

Penelitian ini melakukan dua skenario untuk menguji performa model dalam dua aspek. Pertama prediksi harga saham dalam bentuk numerik menggunakan pendekatan regresi, dan yang kedua adalah klasifikasi arah pergerakan harga (naik/turun) berdasarkan hasil regresi, dengan mempertimbangkan selisih antara nilai prediksi dan harga aktual.

1. Prediksi Harga Saham (Nilai Numerik)

Skenario pertama bertujuan untuk mengukur kemampuan model dalam melakukan prediksi harga saham dalam bentuk nilai numerik. Model LSTM dikonfigurasi sebagai model regresi, dengan output berupa prediksi harga penutupan satu hari ke depan. Data yang digunakan telah melalui tahap *preprocessing*, termasuk pembentukan indikator teknikal (MA, MACD, RSI) dan normalisasi menggunakan *Min-Max Scaler* (0-1). Proses prediksi dilakukan dengan teknik *sliding window* (ukuran 30 hari), di mana model memanfaatkan data historis 30 hari sebelumnya untuk memprediksi satu langkah waktu selanjutnya.

2. Prediksi Arah Pergerakan Harga (Naik/Turun)

Skenario kedua bertujuan untuk menentukan arah pergerakan harga (naik atau turun) dengan menginterpretasikan hasil prediksi numerik dari model regresi. Pendekatan ini tidak menggunakan model klasifikasi terpisah, melainkan menilai selisih antara harga prediksi dengan harga saat ini (*delta prediksi*) sebagai dasar pengambilan keputusan.

Arah diklasifikasikan menggunakan ambang batas (*threshold*) yang bersifat adaptif, yaitu ditentukan berdasarkan deviasi standar perubahan harga selama 30 hari terakhir (volatilitas historis). Jika delta prediksi melebihi threshold, maka dianggap sebagai sinyal "naik", sedangkan jika tidak, dianggap sebagai "turun". Pendekatan ini disebut *volatility-based thresholding*, dan dirancang agar sensitif terhadap kondisi pasar yang berbeda, lebih selektif saat volatilitas tinggi, dan lebih responsif saat pasar tenang

3.7.2 Implementasi Prediksi

Seluruh skenario uji coba dilakukan pada subset data *testing*, yang terdiri dari 15% bagian terakhir dari dataset secara kronologis. Model yang digunakan adalah model hasil optimasi hyperparameter, yang telah dilatih ulang menggunakan konfigurasi terbaik. Hasil prediksi pada data *testing* dianalisis untuk mengukur performa dari masing-masing skenario

3.8 Evaluasi Model

Evaluasi model dilakukan secara terpisah untuk dua skenario prediksi, dengan metrik yang disesuaikan untuk mengukur performa secara komprehensif.

1. Evaluasi Prediksi Harga Saham (Regresi)

Pada skenario regresi, membandingkan hasil prediksi harga saham dengan harga aktual. Tingkat kesalahan diukur menggunakan *Mean Squared Error* (MSE) dan *Mean Absolute Error* (MAE). MSE memberikan bobot lebih besar terhadap kesalahan yang besar, sedangkan MAE mengukur rata-rata selisih absolut antara nilai prediksi dan aktual. Selain itu, hasil evaluasi akan divisualisasikan dalam bentuk grafik perbandingan harga aktual dan prediksi untuk menilai pola tren yang berhasil ditangkap oleh model.

2. Evaluasi Prediksi Pergerakan Harga (Klasifikasi Naik/Turun)

Pada skenario klasifikasi, arah yang diperoleh dari hasil prediksi regresi melalui mekanisme *threshold* adaptif dibandingkan dengan label aktual untuk menghitung metrik evaluasi klasifikasi, yang mencakup *Confusion Matrix*, *accuracy*, *precision*, *recall*, dan *F1-score*.

BAB IV

HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil implementasi dan pembahasan dari model prediksi pergerakan harga saham berdasarkan indikator teknikal menggunakan metode *Long Short-Term Memory* (LSTM). Penjelasan mencakup pengujian model dalam dua skenario utama, yaitu prediksi harga saham secara numerik dan klasifikasi pergerakan harga (naik/turun), serta evaluasi performa model berdasarkan metrik evaluasi yang telah ditentukan. Selain itu, bab ini juga mengintegrasikan perspektif nilai-nilai Islam dalam konteks penggunaan teknologi kecerdasan buatan untuk mendukung keputusan investasi yang adil, transparan, dan bertanggung jawab.

4.1 Hasil

4.1.1 *Preprocessing Data*

Tahap awal dalam proses pembangunan model prediksi dilakukan melalui tahapan *preprocessing dataset*, yang bertujuan untuk mempersiapkan data historis harga saham agar sesuai dengan struktur *input* yang dibutuhkan oleh model *Long Short-Term Memory* (LSTM).

1. Indikator Teknikal dan Fitur *Input*

Perhitungan indikator teknikal yang dilakukan. Berdasarkan hasil perhitungan tersebut, sejumlah fitur yang dianggap relevan dipilih dan ditetapkan sebagai variabel *input* yang akan digunakan dalam pelatihan model.

```

Data columns (total 8 columns):
#   Column              Non-Null Count  Dtype
---  -
0   Close                1179 non-null   float64
1   Volume               1179 non-null   int64
2   SMA_20               1179 non-null   float64
3   SMA_50               1179 non-null   float64
4   MACD                 1179 non-null   float64
5   MACD_signal          1179 non-null   float64
6   MACD_histogram       1179 non-null   float64
7   RSI                  1179 non-null   float64
dtypes: float64(7), int64(1)
memory usage: 82.9 KB

```

Gambar 4.1 Fitur *input*

2. Normalisasi Data

Normalisasi data menggunakan metode *Min-Max Scaling*, yang mengubah skala fitur numerik (seperti harga penutupan, volume, dan indikator teknikal) ke dalam rentang antara 0 hingga 1. Tujuan dari normalisasi ini adalah untuk memastikan bahwa semua fitur memiliki skala yang seragam, sehingga model dapat mempelajari pola dari data secara optimal tanpa bias terhadap fitur dengan nilai yang lebih besar.

	Close	Volume	SMA_20	SMA_50	MACD	MACD_signal	MACD_histogram	RSI
0	0.249152	0.027467	0.391089	0.542383	0.142407	0.142872	0.524749	0.100210
1	0.220228	0.041107	0.379930	0.533756	0.120095	0.129622	0.495073	0.072422
2	0.223121	0.036791	0.368933	0.524617	0.107235	0.116255	0.493781	0.085527
3	0.223121	0.000000	0.357451	0.515844	0.100712	0.104159	0.507801	0.085527
4	0.179735	0.015868	0.342572	0.505974	0.081028	0.090246	0.487757	0.046381

Gambar 4.2 Hasil Normalisasi

3. Penerapan *Sliding Window*

Selanjutnya, dilakukan proses segmentasi data dengan teknik *sliding window*, yaitu dengan membentuk jendela waktu sepanjang 30 hari sebagai *input* (X) untuk memprediksi harga saham pada hari ke-31 sebagai *output* (y). Struktur

sekuensial ini disesuaikan dengan karakteristik temporal data pasar saham, yang sangat bergantung pada pola historis.

```
# Membuat sequences dengan sliding window
X, y = [], []
for i in range(self.sequence_length, len(features_scaled)):
    X.append(features_scaled[i-self.sequence_length:i])
    y.append(features_scaled[i, 0]) # Prediksi harga penutupan (index 0)
```

Gambar 4.3 Source Code Implementasi Sliding Window

Setelah data dibentuk menjadi format sekuensial, dilakukan pembagian *dataset* menjadi tiga bagian. *Training set* sebesar 70% dari total data, yaitu sebanyak 804 sampel, digunakan untuk melatih model agar dapat mempelajari pola dari data historis. *validation set* sebesar 15% atau sebanyak 172 sampel digunakan untuk memantau performa model selama proses pelatihan serta berfungsi sebagai mekanisme untuk mencegah terjadinya *overfitting*. Sementara itu, *testing set* sebesar 15% atau 173 sampel digunakan untuk mengevaluasi kemampuan generalisasi model terhadap data baru yang belum pernah digunakan dalam proses pelatihan sebelumnya.

4.1.2 Pelatihan Model

Pada tahap pelatihan model, dilakukan serangkaian pengujian terhadap berbagai kombinasi hyperparameter guna memperoleh konfigurasi yang menghasilkan performa terbaik. Parameter yang divariasikan mencakup *learning rate*, *batch size*, jumlah unit pada hidden layer (*hidden_size*), serta jumlah layer LSTM (*num_layers*). Proses *tuning* dilakukan menggunakan metode *grid search*, yang secara sistematis menguji seluruh kemungkinan kombinasi parameter. Total

sebanyak 54 konfigurasi diuji untuk menilai pengaruh masing-masing kombinasi terhadap performa model.

Data latih digunakan untuk mengoptimalkan bobot model, sedangkan data validasi berperan dalam memantau performa model terhadap data yang tidak dilibatkan langsung dalam proses pembelajaran. Untuk mencegah *overfitting*, diterapkan teknik *early stopping* dengan *patience* = 20, yaitu menghentikan pelatihan secara otomatis apabila tidak terjadi peningkatan performa pada data validasi selama 20 *epoch* berturut-turut.

Proses evaluasi terhadap 54 kombinasi hyperparameter mengidentifikasi sepuluh konfigurasi terbaik berdasarkan validation loss MSE. Tabel 4.1 menyajikan kombinasi-kombinasi tersebut beserta nilai *validation loss*-nya, diurutkan berdasarkan peringkat

Tabel 4.1 Top 10 Kombinasi Hyperparameter Model LSTM

Rank	Hidden Size	Num Layers	Lr	Batch Size	Val Loss
1	64	1	0.01	32	0.000076
2	64	1	0.01	64	0.000080
3	64	1	0.01	16	0.000082
4	128	1	0.01	16	0.000085
5	64	2	0.01	16	0.000097
6	32	1	0.01	32	0.000097
7	64	3	0.01	32	0.000108
8	128	2	0.01	16	0.000116
9	32	1	0.01	16	0.000128
10	32	2	0.01	32	0.000140

Diperoleh bahwa kombinasi dengan *hidden_size* sebesar 64, *num_layer* sebanyak 1, *learning rate* 0.01, dan *batch size* 32 menghasilkan performa terbaik, dengan nilai average validation loss sebesar 0.000076. Pemilihan kombinasi ini menunjukkan beberapa implikasi penting terhadap performa model

Ukuran *hidden_size* sebesar 64 unit ditentukan sebagai yang terbaik. Ini mengimplikasikan bahwa model memiliki kapasitas yang cukup untuk menangkap pola dan koneksi temporal dalam data indikator teknikal tanpa menjadi terlalu kompleks dan rentan terhadap overfitting. Dibandingkan dengan ukuran yang lebih besar (misalnya, 128), 64 mungkin merupakan kompromi yang baik antara kemampuan representasi dan generalisasi pada set data saat ini. Kapasitas kurang dari 64 (misalnya, 32) mungkin tidak cukup untuk menangkap semua informasi penting.

Temuan ini menunjukkan bahwa, tergantung pada indikator teknikal yang digunakan, sebuah model LSTM dengan *Num_Layer* 1 sudah cukup untuk mensimulasikan deret waktu harga saham. Menambah jumlah layer (misalnya, 2 atau 3) mungkin tidak secara signifikan meningkatkan performa. Namun, hal ini dapat menyebabkan tantangan pelatihan (seperti masalah *vanishing gradient*) atau kompleksitas yang berlebihan, yang meningkatkan *validation loss*. Hal ini menunjukkan bahwa dataset dan fitur yang digunakan mungkin tidak memerlukan struktur representasi yang lebih kompleks. Hal ini juga dapat mengimplikasikan bahwa, dengan jumlah data yang tersedia, model yang lebih dangkal akan lebih cepat dilatih dan lebih kecil kemungkinannya untuk mengalami overfitting dibandingkan dengan model yang lebih dalam.

Laju pembelajaran sebesar 0.01 dinilai sebagai yang paling efektif. Laju ini tidak terlalu tinggi untuk menyebabkan osilasi atau melampaui batas minimum global, tetapi cukup untuk memungkinkan model belajar dengan cepat dan keluar dari lembah *loss* yang dangkal. Hal ini menunjukkan bahwa stabilitas pelatihan dan

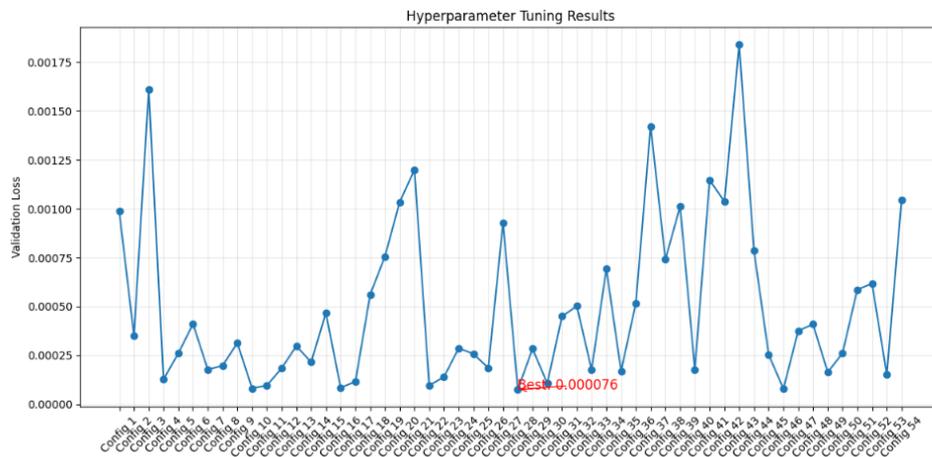
kecepatan konvergensi seimbang. Laju pembelajaran yang lebih rendah akan sangat memperlambat proses pelatihan, sementara laju yang lebih besar mungkin akan membuat model “melompat-lompat” di sekitar nilai minimum dan gagal konvergen secara optimal.

Penggunaan ukuran *batch* 32 menunjukkan keefektifan dalam mencapai keseimbangan antara generalisasi dan akurasi estimasi gradien. Ukuran *batch* ini cukup besar untuk menghasilkan estimasi gradien yang secara akurat mencerminkan distribusi data dan cukup kecil untuk memasukkan sedikit *noise* untuk membantu model menghindari minimum lokal dan meningkatkan ketahanan. Ukuran *batch* yang terlalu kecil (misalnya, 8 atau 16) dapat menyebabkan gradien yang terlalu *noise*, sementara ukuran *batch* yang terlalu besar (misalnya, 64 atau 128) dapat menyebabkan model terjebak pada minimum lokal dan menghasilkan generalisasi yang kurang optimal.

Secara keseluruhan, kombinasi optimal ini mewakili model yang cukup kompleks untuk mengidentifikasi pola yang berarti, namun cukup sederhana untuk dilatih secara cepat dan digeneralisasi secara efektif pada data baru. *Validation loss* yang sangat rendah (0.000076) untuk kombinasi ini menunjukkan bahwa model ini memiliki kapasitas prediksi yang baik pada data validasi, yang merupakan indikasi kuat dari kemungkinan kinerja yang baik pada data uji.

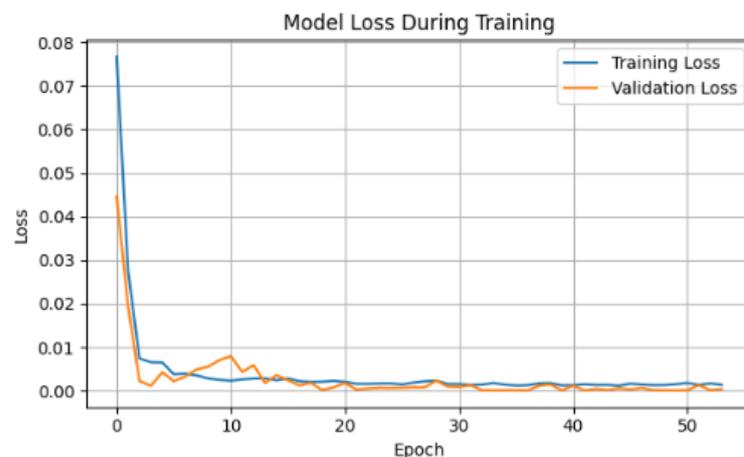
Hasil tuning secara visual dapat dilihat pada Gambar 4.4 yang memperlihatkan nilai *loss* validasi untuk seluruh kombinasi *hyperparameter*. Titik terendah pada grafik menandakan kombinasi terbaik yang terletak pada konfigurasi

ke-27, sedangkan beberapa titik menunjukkan loss yang jauh lebih tinggi, menandakan sensitivitas performa model terhadap pemilihan parameter.



Gambar 4.4 Grafik Hasil Tuning Hyperparameter

Setelah kombinasi hyperparameter optimal teridentifikasi, model dilatih ulang menggunakan konfigurasi tersebut (*hidden size: 64, num_layers: 1, learning rate: 0.01, batch size: 32*) pada data training. Pelatihan ini dilakukan dengan memanfaatkan seluruh data *training* dan memantau *validation loss* dengan menerapkan early stopping guna mencegah overfitting. Model hasil pelatihan ulang inilah yang kemudian digunakan untuk evaluasi pada data testing.



Gambar 4.5 Grafik Loss Selama Pelatihan Model

Gambar 4.5 menunjukkan grafik *loss* selama proses pelatihan, di mana baik nilai *training loss* maupun *validation loss* mengalami penurunan tajam pada awal *epoch*. Setelah sekitar *epoch* ke-10, nilai *loss* mulai stabil, dengan fluktuasi ringan pada *validation loss* yang masih berada dalam rentang rendah. Nilai *training loss* secara konsisten rendah dan tidak menunjukkan penurunan yang terlalu ekstrem, yang mengindikasikan bahwa model tidak mengalami *overfitting*. Selain itu, *validation loss* tidak mengalami peningkatan yang signifikan yakni konsisten di sekitar angka 0 dan tetap sejalan dengan *training loss*, sehingga menunjukkan bahwa kemampuan generalisasi model terhadap data yang tidak dilibatkan dalam pelatihan cukup baik.

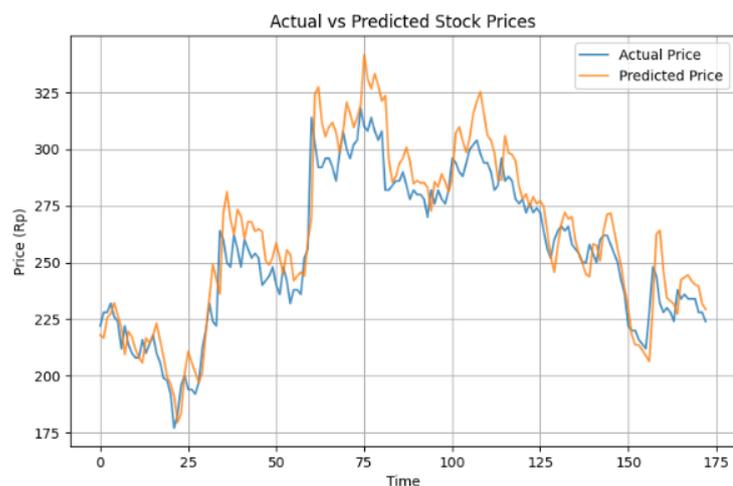
4.1.3 Evaluasi Kinerja Model

Setelah proses pelatihan model selesai dilakukan, tahap selanjutnya adalah menguji kemampuan generalisasi model terhadap data pengujian. Evaluasi ini dilakukan berdasarkan dua skenario utama yang telah dijelaskan dalam Bab III, yaitu prediksi harga saham dalam bentuk numerik (*regresi*) dan klasifikasi arah pergerakan harga (*naik/turun*) yang diturunkan dari hasil prediksi *regresi*.

1. Evaluasi Prediksi Harga Saham (*Regresi*)

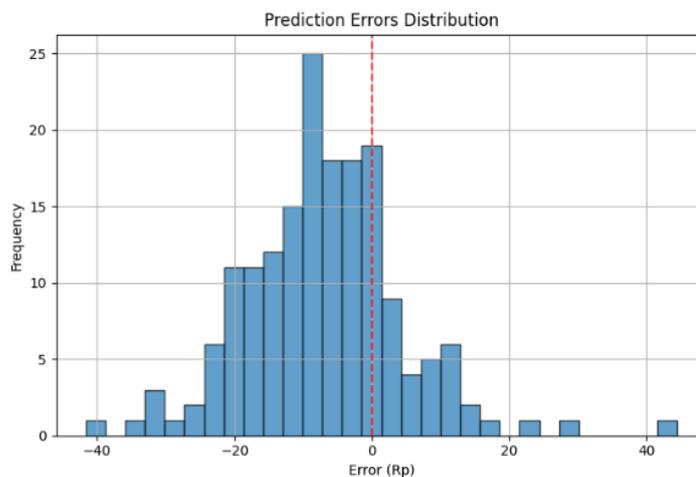
Model LSTM diuji menggunakan data pengujian untuk memprediksi harga penutupan saham, dengan evaluasi kinerja dilakukan menggunakan dua metrik utama, yaitu MS) dan MAE. Dalam skala data yang telah dinormalisasi (0–1), model menghasilkan nilai MSE sebesar 0.000076 dan MAE sebesar 0.006842. Sementara itu, dalam skala harga asli (*Rupiah*), diperoleh nilai MSE sebesar 179,83 dan MAE sebesar 10,50. Nilai MAE sekitar \pm Rp10 menunjukkan bahwa rata-rata

kesalahan prediksi harian sangat kecil, yang mencerminkan performa model yang cukup baik dalam memprediksi pergerakan harga saham.



Gambar 4.6 Perbandingan Harga Aktual dan Prediksi pada Data *testing*

Visualisasi prediksi terhadap harga aktual ditunjukkan pada Gambar 4.6 memperlihatkan keselarasan pola tren, dimana tidak terdapat deviasi signifikan yakni rata-rata kesalahan prediksi hanya sekitar sepuluh rupiah dari harga aktual, dan deviasi maksimum terbatas pada rentang Rp15–Rp20 pada beberapa bagian titik.

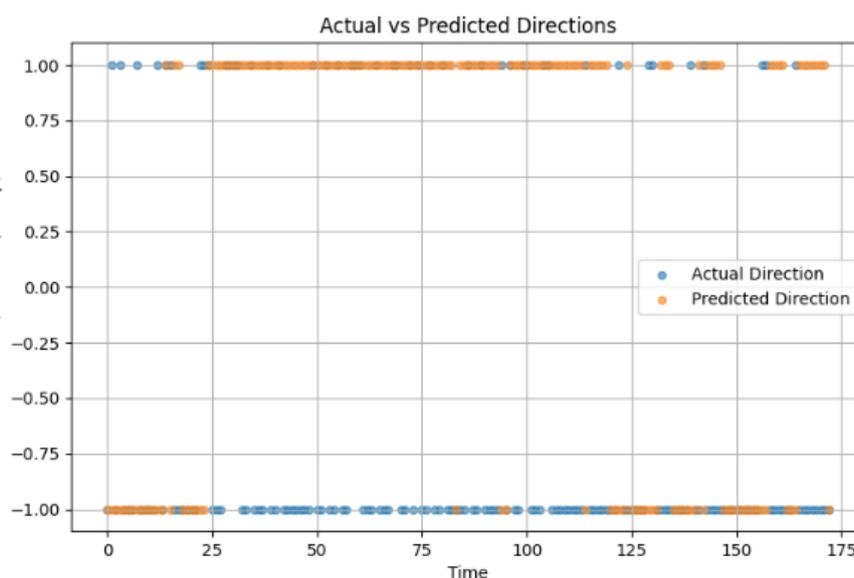


Gambar 4.7 Distribusi Kesalahan (*Error*) Prediksi Harga Saham

Untuk mengamati stabilitas prediksi secara lebih mendalam, dilakukan analisis terhadap distribusi kesalahan (*error*). Pada Gambar 4.7 menunjukkan histogram dari selisih antara harga prediksi dan harga aktual dalam satuan Rupiah. Distribusi error memperlihatkan bahwa sebagian besar kesalahan berada dalam rentang ± 20 . Puncak distribusi tampak sedikit bergeser ke arah kiri (nilai negatif) menunjukkan bias sistematis minor, dimana model cenderung melakukan underestimasi yaitu memprediksi harga lebih rendah dari nilai aktual.

2. Evaluasi Prediksi Arah Pergerakan Harga (Klasifikasi)

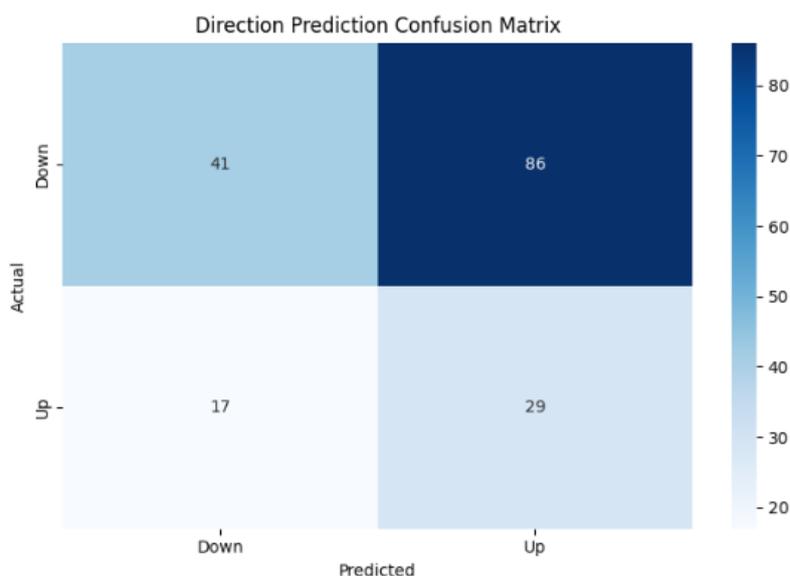
Selain memprediksi nilai harga saham, model juga dievaluasi berdasarkan kemampuannya melakukan klasifikasi arah pergerakan harga (naik atau turun). Arah pergerakan ditentukan berdasarkan selisih antara prediksi regresi dan harga aktual, menggunakan ambang batas adaptif sebesar Rp3,62, yang dihitung dari deviasi standar perubahan harga selama 30 hari terakhir.



Gambar 4.8 Perbandingan Arah Pergerakan Harga Aktual dan Hasil Prediksi

Gambar 4.7 memperlihatkan perbandingan antara arah aktual dan prediksi terhadap waktu. Arah dikodekan sebagai 1 untuk “naik” dan -1 untuk “turun”. Terlihat bahwa sebagian besar hasil prediksi mengikuti arah dominan, namun terjadi banyak ketidaksesuaian terutama pada area transisi atau pergerakan harga yang cenderung datar.

Hal ini diperkuat oleh *confusion matrix* pada Gambar 4.8, yang menunjukkan bahwa dari total 173 data, model hanya berhasil mengklasifikasikan 41 data “turun” dan 29 data “naik” secara benar. Sementara itu, kesalahan prediksi arah naik saat seharusnya turun (*false positive*) mencapai 86 kasus.



Gambar 4.9 *Confusion Matrix* Prediksi Arah Pergerakan Harga

Secara kuantitatif, evaluasi klasifikasi menghasilkan nilai *directional accuracy* sebesar 40,46%, *precision* sebesar 58,60%, *recall* sebesar 40,46%, dan *F1-score* sebesar 42,12%. Hasil ini menunjukkan bahwa meskipun *precision* relatif lebih tinggi (prediksi arah naik sering benar), akurasi dan *recall* secara keseluruhan masih rendah, terutama karena model sering salah dalam mengidentifikasi arah

yang sebenarnya turun. Hal ini mengindikasikan bahwa pendekatan klasifikasi berbasis hasil regresi dan *threshold* belum mampu menangkap dinamika arah pergerakan secara konsisten.

Untuk memberikan gambaran lebih rinci tentang hasil prediksi, Tabel 4.2 menampilkan sepuluh contoh hasil prediksi model terhadap data testing. Tabel ini membandingkan harga sebenarnya (*True Price*) dengan harga prediksi (*Predicted Price*), arah pergerakan sebenarnya (*True Direction*) dengan arah prediksi (*Predicted Direction*), serta menunjukkan apakah prediksi arah sesuai (*Direction Match*).

Tabel 4.2 Contoh Hasil Prediksi pada Data *Testing*

No	True Price	Predicted Price	True Direction	Predicted Direction	Direction Match
1	222.00	218.02	Down	Down	Yes
2	228.00	216.77	Up	Down	No
3	228.00	225.66	Down	Down	Yes
4	232.00	227.48	Up	Down	No
5	226.00	232.08	Down	Down	Yes
6	224.00	226.54	Down	Down	Yes
7	212.00	221.39	Down	Down	Yes
8	222.00	209.46	Up	Down	No
9	214.00	219.52	Down	Down	Yes
10	210.00	217.23	Down	Down	Yes

Berdasarkan Tabel 4.2, ditampilkan sampel dari hasil prediksi arah pergerakan harga saham model LSTM dibandingkan dengan arah sebenarnya. Secara keseluruhan, model menghasilkan 173 prediksi, dengan 70 di antaranya sesuai dengan arah aktual, sehingga menghasilkan *directional accuracy* sebesar 40.46%. Dari 46 data dengan arah aktual naik (*Up*), model berhasil mengidentifikasi dengan benar sebanyak 29 kali (63.04%). Sedangkan Dari 127

data dengan arah aktual turun (*Down*), model hanya berhasil memprediksi dengan benar sebanyak 41 kali (32.28%).

4.2 Pembahasan

Berdasarkan hasil yang diperoleh pada subbab sebelumnya, model LSTM berbasis indikator teknikal (MA, MACD, RSI) menunjukkan dua karakteristik kinerja yang berbeda, akurasi numerik yang tinggi dalam memprediksi harga (dengan MAE Rp10.50), namun di sisi lain memiliki keterbatasan dalam mengklasifikasikan arah pergerakan harga (akurasi 40.46%). Perbedaan kinerja ini memerlukan analisis mendalam mengenai mekanisme prediksi model, faktor-faktor yang mempengaruhi hasil, serta implikasi praktisnya dalam konteks analisis pasar saham. Pembahasan akan difokuskan pada tiga aspek utama. (1) interpretasi hasil prediksi harga, (2) evaluasi akurasi klasifikasi arah pergerakan, dan (3) identifikasi kelebihan dan keterbatasan model secara menyeluruh.

4.2.1 Interpretasi Hasil Prediksi Harga

Model LSTM dalam penelitian ini menunjukkan performa prediksi harga yang sangat baik pada skenario regresi. Hasil prediksi tidak hanya akurat secara rata-rata (sebagaimana ditunjukkan oleh nilai MAE yang rendah yakni 10,50), tetapi juga stabil secara distribusi. Selain itu, grafik perbandingan harga prediksi dan aktual pada Gambar 4.6 memperlihatkan bahwa model dapat mengikuti pola tren harga secara konsisten.

Temuan ini selaras dengan hasil penelitian (Saputra, 2023), yang menunjukkan bahwa kombinasi LSTM dengan indikator teknikal seperti MA, RSI,

dan MACD menghasilkan nilai MAPE terbaik pada uji coba 2 sebesar 0,70%, dibandingkan uji coba lain yang tidak menyertakan semua indikator. Meskipun metrik evaluasi yang digunakan berbeda MAPE dan bukan MAE, secara umum hasil menunjukkan bahwa pemanfaatan indikator teknikal memperbaiki performa prediktif LSTM.

Selain itu, (Setiawan et al., 2023) juga melaporkan tingkat akurasi tinggi saat memprediksi harga saham dengan LSTM, dengan akurasi mencapai 99% dan selisih harga rata-rata sekitar USD 5,587. Namun, perbandingan ini harus dilihat secara kontekstual, mengingat model tersebut menggunakan dataset saham luar negeri dan pengukuran berbasis harga absolut dalam mata uang asing.

Dengan demikian, hasil yang diperoleh dalam penelitian ini memperkuat temuan sebelumnya bahwa model LSTM sangat efektif dalam menangkap pola temporal pada data pasar saham, terutama jika didukung oleh fitur teknikal yang relevan.

4.2.2 Evaluasi Akurasi Arah Pergerakan

Berbeda dari hasil regresi, performa model dalam mengklasifikasikan arah pergerakan harga masih belum optimal. Akurasi yang rendah menunjukkan bahwa model kesulitan dalam membedakan secara konsisten antara kondisi naik dan turun, terutama dalam situasi pasar yang datar atau fluktuatif ringan.

Penyebab utama dari rendahnya akurasi klasifikasi kemungkinan besar berasal dari cara menentukan arah pergerakan harga yang hanya didasarkan pada hasil prediksi angka (regresi) dan batas ambang tertentu (*threshold*). Dengan cara

ini, model tidak benar-benar dilatih untuk mengenali arah naik atau turun secara langsung, melainkan hanya fokus pada meminimalkan selisih angka prediksi.

Keterbatasan ini sejalan dengan temuan (Khairunnisa et al., 2025), yang menyajikan bahwa integrasi indikator teknikal seperti Simple Moving Average (SMA) ke dalam model LSTM tidak selalu meningkatkan akurasi. Bahkan pada beberapa saham seperti INCO dan PTBA, penambahan indikator justru menurunkan MAPE, yang menunjukkan bahwa peningkatan kompleksitas *input* tidak otomatis memperbaiki performa klasifikasi.

Lebih lanjut, penggunaan pendekatan berbasis regresi untuk menentukan arah pergerakan tidak memberikan optimasi eksplisit terhadap metrik klasifikasi. (Talumewo et al., 2023) sebelumnya menggunakan model ARIMA-GARCH untuk meramalkan harga ADHI, namun tanpa pendekatan klasifikasi arah. Hal ini menunjukkan bahwa arah pergerakan memang merupakan aspek yang lebih sulit diprediksi dibandingkan nilai harga itu sendiri, terutama dengan model berbasis regresi.

Oleh karena itu, pendekatan klasifikasi eksplisit, atau alternatif seperti *multitask learning*, perlu dipertimbangkan dalam pengembangan model ke depan. Pendekatan ini memungkinkan model untuk secara bersamaan belajar memprediksi harga dan arah, dengan loss function yang disesuaikan untuk masing-masing tugas.

4.2.3 Kelebihan dan Keterbatasan Model

Model LSTM memiliki keunggulan dalam mempelajari pola sekuensial dalam data historis saham. Hasil evaluasi regresi yang stabil dan akurat menunjukkan bahwa model mampu menangkap pola-pola temporal secara efektif.

Penggunaan indikator teknikal seperti MA, MACD, dan RSI juga turut meningkatkan kualitas prediksi harga. Selain itu, proses normalisasi, sliding window, dan tuning hyperparameter yang sistematis berkontribusi terhadap kestabilan model selama pelatihan. Hasil evaluasi menunjukkan bahwa model tidak mengalami overfitting, yang mengindikasikan generalisasi yang baik terhadap data baru.

Namun, kemampuan model dalam mengklasifikasikan arah pergerakan harga masih terbatas. Hal ini disebabkan oleh pendekatan regresi yang tidak dirancang khusus untuk klasifikasi arah, serta ketergantungan pada ambang batas yang sensitif terhadap fluktuasi harga. Selain itu, model belum mempertimbangkan variabel eksternal seperti sentimen pasar atau data fundamental, yang dapat berpengaruh terhadap prediksi arah harga.

4.3 Integrasi Nilai Islam

Pelaksanaan penelitian ini didasari prinsip-prinsip Islam yang tercermin dalam ayat-ayat Al-Qur'an. Pendekatan ini diharapkan menumbuhkan kesadaran akan pentingnya etika dalam berinvestasi dan tanggung jawab mengelola harta secara halal sebagai amanah Allah. Dua aspek utama muamalah Islam yang diintegrasikan adalah bergantung kepada Allah (tawakkal) dan berlaku adil kepada sesama. Dengan demikian penelitian ini menghubungkan keimanan kepada Allah dalam usaha (muamalah Ma'allah) dan keadilan dalam interaksi sosial ekonomi (muamalah Ma'annas) sebagai kerangka berpikir penelitian.

4.3.1 Muamalah Ma'allah

Muamalah Ma'allah menekankan sikap tawakkal atau berserah diri kepada Allah setelah melakukan usaha. Allah berfirman dalam QS At-Talaq ayat 3:

وَيَرْزُقُهُ مِنْ حَيْثُ لَا يَحْتَسِبُ وَمَنْ يَتَوَكَّلْ عَلَى اللَّهِ فَهُوَ حَسْبُهُ ۗ إِنَّ اللَّهَ بَالِغُ أَمْرِهِ ۗ قَدْ جَعَلَ اللَّهُ لِكُلِّ شَيْءٍ قَدْرًا

“Dan menganugerahkan kepadanya rezeki dari arah yang tidak dia duga. Siapa yang bertawakkal kepada Allah, niscaya Allah akan mencukupkan (keperluan)-nya. Sesungguhnya Allahlah yang menuntaskan urusan-Nya. Sungguh, Allah telah membuat ketentuan bagi setiap sesuatu”. (QS At-Talaq 65:3).

Tafsir Ibnu Katsir dan Prof. Quraish Shihab menegaskan bahwa ayat ini menjelaskan hakikat tawakkal yakni berserah diri sepenuhnya kepada Allah setelah berupaya, Allah lah yang pada akhirnya mengatur rezeki dan hasil usaha hamba-Nya. Ayat ini menegaskan janji Allah bahwa orang yang telah berikhtiar maksimal kemudian menyerahkan hasil usahanya kepada-Nya akan diberi kecukupan rezeki.

Prinsip tawakkal berarti setiap langkah dalam investasi dilakukan dengan sebaik-baiknya, disertai keyakinan bahwa Allah-lah penentu hasil akhir usaha. Dengan mengintegrasikan nilai ini, proses penerapan model LSTM dan indikator teknikal adalah bagian dari ikhtiar ilmiah dan produktif, namun hasil yang diberikan pasar tetap disandarkan kepada Allah, karena percaya bahwa Allah akan mencukupi semua kebutuhan sesuai kehendak-Nya. Pemahaman muamalah Ma'allah secara logis melengkapi muamalah Ma'annas di bawah ini, yaitu bagaimana berlaku adil kepada sesama dalam setiap transaksi.

4.3.2 Muamalah Ma'allah

Muamalah Ma'anās menekankan keharusan berlaku adil dan jujur kepada sesama dalam urusan ekonomi. Sebagaimana Firman Allah dalam QS An-Nisa' ayat 29:

يَا أَيُّهَا الَّذِينَ آمَنُوا لَا تَأْكُلُوا أَمْوَالَكُمْ بَيْنَكُمْ بِالْبَاطِلِ إِلَّا أَنْ تَكُونَ تِجَارَةً عَنْ تَرَاضٍ مِّنْكُمْ وَلَا تَقْتُلُوا أَنْفُسَكُمْ إِنَّ اللَّهَ كَانَ بِكُمْ رَحِيمًا ﴿٢٩﴾

“Wahai orang-orang yang beriman, janganlah kamu memakan harta sesamamu dengan cara yang batil (tidak benar), kecuali berupa perniagaan atas dasar suka sama suka di antara kamu. Janganlah kamu membunuh dirimu. Sesungguhnya Allah adalah Maha Penyayang kepadamu” (QS An-Nisa 4:29).

Ayat ini menjadi landasan penting bagi etika bermuamalah. yang menegaskan larangan mengambil harta orang lain dengan cara batil dan hanya mengizinkan transaksi yang terjadi atas dasar kesepakatan sukarela (suka sama suka). Kata batil oleh Al-Syaukani dalam kitabnya Fath Al-Qadir, diterjemahkan *ma laisa bihaqqin* (segala apa yang tidak benar). Bentuk batil ini sangat banyak. Dalam konteksnya ayat yang terdapat di atas, sesuatu dapat dikatakan batil dalam jual beli apabila dilarang dan tidak sesuai syara'. Adapun perdagangan yang batil jika di dalamnya terdapat unsur *maisir* dan *gharar* (Sundari & Ridwan, 2022).

Dalam konteks penelitian prediksi harga saham, prinsip tersebut tetap relevan, bahwa transaksi saham harus dilakukan dengan prinsip kehati-hatian dan menghindari spekulasi berlebihan, ketidakpastian (*gharar*). Penggunaan model LSTM untuk memprediksi pergerakan harga saham bertujuan meningkatkan transparansi dan akurasi informasi bagi investor. Dengan demikian, keputusan jual beli dapat diambil berdasarkan analisis data yang jelas dan jujur, bukan sekadar spekulasi. Pendekatan prediksi harga ini diharapkan membantu meminimalisir

unsur ketidakpastian dan mendukung transaksi saham yang dilakukan secara adil atas dasar suka sama suka, sesuai pedoman ayat tersebut.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil pengujian dan evaluasi pada data saham ADHI dan indikator teknikal (MA, MACD dan RSI) sebagai fitur, model LSTM menunjukkan kinerja yang sangat baik dalam skenario prediksi harga (regresi). Dengan konfigurasi terbaik (*hidden size* 64, *num_layers* 1, *lr* 0.01, *batch size* 32), model mencapai nilai MSE sebesar 179,83 dan MAE sebesar Rp10,50 dalam skala harga asli, menandakan bahwa prediksi yang dihasilkan sangat dekat dengan nilai aktual. Evaluasi visual memperkuat temuan ini, di mana grafik prediksi dan aktual menunjukkan pola yang sejajar dan konsisten. dan distribusi error yang relatif simetris serta terpusat di sekitar nol dan berada dalam rentang ± 20 menunjukkan bahwa model memiliki bias sistematis minor, namun cukup memiliki stabilitas dan akurasi yang baik.

Untuk skenario klasifikasi arah pergerakan (naik/turun), hasil evaluasi menunjukkan bahwa pendekatan klasifikasi arah yang didasarkan pada selisih hasil regresi terhadap harga aktual, dengan menggunakan *adaptive threshold* sebesar Rp3,62 menghasilkan akurasi arah sebesar 40,46%, *precision* sebesar 58,60%, *recall* sebesar 40,46%, dan F1-score sebesar 42,12%. *Confusion matrix* menunjukkan bahwa kesalahan klasifikasi masih dominan, khususnya pada prediksi arah naik. Hal ini mengindikasikan bahwa meskipun model efektif dalam memprediksi nilai harga, pendekatan klasifikasi arah berbasis regresi masih

memiliki keterbatasan, terutama dalam menghadapi fluktuasi harga yang mendekati ambang batas klasifikasi.

Secara keseluruhan, dapat disimpulkan bahwa model LSTM yang dibangun memiliki kapabilitas kuat dan terbukti efektif dalam melakukan prediksi harga saham berbasis data historis dan indikator teknikal, khususnya dalam konteks regresi. Meskipun, untuk klasifikasi arah pergerakan harga, pendekatan yang digunakan belum cukup memadai. Model LSTM ini juga memperlihatkan potensi besar untuk diterapkan sebagai dasar dalam sistem pendukung keputusan investasi berbasis kecerdasan buatan.

5.2 Saran

Merujuk pada hasil dan kesimpulan yang telah diperoleh, penulis menyadari bahwa penelitian ini masih memiliki beberapa keterbatasan. Oleh karena itu, guna meningkatkan kualitas hasil dan memperbaiki kekurangan dalam performa model pada penelitian ini, berikut disampaikan beberapa saran yang dapat dijadikan acuan untuk penelitian selanjutnya:

1. Peningkatan Arsitektur Model

Model LSTM yang digunakan dalam penelitian ini dapat dikembangkan lebih lanjut dengan menerapkan arsitektur yang lebih kompleks, seperti *Attention-LSTM* atau *Bidirectional LSTM*, agar mampu menangkap pola dependensi jangka panjang dan pendek secara lebih efektif.

2. Penggunaan Model Klasifikasi Langsung

Untuk prediksi arah pergerakan harga, disarankan penggunaan model klasifikasi terpisah daripada pendekatan yang mengklasifikasikan arah

berdasarkan selisih hasil prediksi regresi, agar optimasi model secara langsung diarahkan pada metrik klasifikasi seperti akurasi dan F1-score.

3. Penambahan Variabel Kontekstual

Akurasi model dapat ditingkatkan dengan memasukkan variabel tambahan seperti data fundamental perusahaan, sentimen pasar, atau berita ekonomi. Integrasi data eksternal ini dapat memberikan konteks yang lebih kaya terhadap dinamika harga saham.

4. Evaluasi Lintas Sektor dan Saham Syariah

Penelitian serupa dapat diterapkan pada saham dari sektor industri lain maupun saham-saham yang termasuk dalam indeks syariah. Hal ini dapat memperluas generalisasi hasil sekaligus berkontribusi terhadap pengembangan ekosistem keuangan syariah berbasis teknologi.

5. Pengembangan Aplikasi Berbasis Prediksi

Untuk meningkatkan nilai guna penelitian, hasil model prediksi dapat diintegrasikan ke dalam sistem aplikasi atau dashboard berbasis web, sehingga dapat digunakan langsung oleh investor, analis, atau pengguna umum dalam proses pengambilan keputusan investasi.

Dengan pengembangan yang berkelanjutan, penelitian ini diharapkan dapat menjadi landasan bagi penerapan kecerdasan buatan dalam sistem prediksi saham yang lebih akurat, adaptif, dan etis untuk mendukung keputusan investasi yang cerdas.

DAFTAR PUSTAKA

- Abdi, F., Hakim, E., & Fariza, A. (2023). Pengembangan Analisis Teknikal Untuk Trading Bursa Saham dengan Long Short Term Memory. *Jurnal Media Informatika Budidarma*, 7, 985–993. <https://doi.org/10.30865/mib.v7i3.6153>
- Alghifari, D. R., Edi, M., & Firmansyah, L. (2022). Implementasi Bidirectional LSTM untuk Analisis Sentimen Terhadap Layanan Grab Indonesia. *Jurnal Manajemen Informatika (JAMIKA)*, 12(2), 89–99. <https://doi.org/10.34010/jamika.v12i2.7764>
- Bustos, O., & Pomares-Quimbaya, A. (2020). Stock market movement forecast: A Systematic review. *Expert Systems with Applications*, 156. <https://doi.org/10.1016/j.eswa.2020.113464>
- Chaudhary, R. (2025). *Advanced Stock Market Prediction Using Long Short-Term Memory Networks: A Comprehensive Deep Learning Framework*. <http://arxiv.org/abs/2505.05325>
- Daniswara, D. A., Widjanarko, H., & Hikmah, K. (2022). the Accuracy Test of Technical Analysis of Moving Average, Bollinger Bands, and Relative Strength Index on Stock Prices of Companies Listed in Index Lq45. *Indikator: Jurnal Ilmiah Manajemen Dan Bisnis*, 6(2), 16. <https://doi.org/10.22441/indikator.v6i2.14806>
- Dopi, G. Y. (2023). Prediksi Harga Saham Menggunakan Metode Long Short Term Memory [Universitas Gadjah Mada]. In *Perpustakaan Universitas Gadjah Mada*. <https://etd.repository.ugm.ac.id/penelitian/detail/220508>
- Fauzan, M., & Syafitri, N. (2022). Analisis Teknikal Pergerakan Harga Saham Untuk Mengambil Keputusan Investasi Pada Saham Sub Sektor Telekomunikasi Yang Terdaftar Di Bursa Efek Indonesia. *Jurnal Analisis Manajemen*, 8(1), 26–45.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. *Nature*, 29(7553), 1–73. <http://deeplearning.net/>
- Hanafiah, A., Arta, Y., Nasution, H. O., & Lestari, Y. D. (2023). Penerapan Metode Recurrent Neural Network dengan Pendekatan Long Short-Term Memory (LSTM) Untuk Prediksi Harga Saham. *Bulletin of Computer Science Research*, 4(1), 27–33. <https://doi.org/10.47065/bulletincsr.v4i1.321>
- Handini, S. (2024). The Impact of Financial Literacy, Investment Knowledge, and Investment Motivation on Investment Decisions. *West Science Journal Economic and Entrepreneurship*, 2(02), 194–210. <https://doi.org/10.58812/wsjee.v2i01.553>
- Hewamalage, H., Bergmeir, C., & Bandara, K. (2021). Recurrent Neural Networks for Time Series Forecasting: Current status and future directions. *International*

Journal of Forecasting, 37(1), 388–427.
<https://doi.org/10.1016/j.ijforecast.2020.06.008>

Howard, J., & Gugger, S. (2020). *Deep Learning for Coders with fastai and PyTorch*. O'Reilly Media.

Htun, H. H., Biehl, M., & Petkov, N. (2023). Survey of feature selection and extraction techniques for stock market prediction. *Financial Innovation*, 9(1).
<https://doi.org/10.1186/s40854-022-00441-7>

Khairunnisa, A., Muflikhah, L., & Setiawan, B. D. (2025). *Pemodelan Prediktif Harga Saham Menggunakan Simple Moving Average Dengan Metode Long Short-Term Memory*. 9(3), 1–10.

Kurniawan, P. M., Almais, A. T. W., Hariyadi, M. A., Yaqin, M. A., & Suhartono. (2023). Prediction of Civil Servant Performance Allowances Using the Neural Network Backpropagation Method. *International Journal on Informatics Visualization*, 7(3), 673–680. <https://doi.org/10.30630/joiv.7.3.1698>

Musthofa, K. (2021). *Belajar Investasi dari Nabi Yusuf, Tafsir Surah Yusuf Ayat 47-49*. Tafsiralquran.Id. <https://tafsiralquran.id/belajar-investasi-dari-nabi-yusuf-tafsir-surah-yusuf-ayat-47-49/>

Olah, C. (2015). *Understanding LSTM Networks*.
<https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

Pahlevi, M. R. (2023). Prediksi Harga Forex Menggunakan Algoritma Long Short-Term Memory. *JNANALOKA*, 69–76.
<https://doi.org/10.36802/jnanaloka.2022.v3-no2-69-76>

Pipin, S. J., Purba, R., & Kurniawan, H. (2023). Prediksi Saham Menggunakan Recurrent Neural Network (RNN- LSTM) dengan Optimasi Adaptive Moment Estimation. *Journal of Computer System and Informatics (JoSYC)*, 4(4), 806–815. <https://doi.org/10.47065/josyc.v4i4.4014>

Prachyachuwong, K., & Vateekul, P. (2021). Stock trend prediction using deep learning approach on technical indicator and industrial specific information. *Information (Switzerland)*, 12(6). <https://doi.org/10.3390/info12060250>

Purnamasari, P., Imamudin, M., Zaman, S., & Syauqi, A. (2025). *Clustering of Post-Disaster Building Damage Levels Using Discrete Wavelet Transform and Principal Component Analysis*. 3(1), 33–44.
<https://doi.org/10.30996/jitcs.12270>

Raza, S. B., Yadav, Y., & Yaduwanshi, J. (2025). Stock Market Prediction Using LSTM. *International Research Journal of Modernization in Engineering, Technology and Science*, 07(04), 3227–3233. <https://doi.org/https://www.doi.org/10.56726/IRJMETS72492>

Saiful Hasan, Siti Nurhasanah, & Wahyu Purbo Santoso. (2024). Analisis Teknikal Menggunakan Moving Average (MA), Moving Average Convergence-

Divergence (MACD), dan Relative Strength Index (RSI) Untuk Mengoptimalkan Dalam Pengambilan Keputusan Investasi Pada Saham Sektor Manufaktur Index LQ45 BEI Tahun 2022-2023. *El-Mal: Jurnal Kajian Ekonomi & Bisnis Islam*, 5(4), 3318–3334. <https://doi.org/10.47467/elmal.v5i4.2029>

Saputra, R. A. (2023). Stock Prediction System Using Teknikal Indicators With the Lstm Method. *International Journal on Information and Communication Technology (IJoICT)*, 9(1), 27–43. <https://doi.org/10.21108/ijoict.v9i1.713>

Satria, A., Badri, R. M., & Safitri, I. (2023). Prediksi Hasil Panen Tanaman Pangan Sumatera dengan Metode Machine Learning. *Digital Transformation Technology*, 3(2), 389–398. <https://doi.org/10.47709/digitech.v3i2.2852>

Setiawan, D., Stefani, K., Shandy, Y. J., & Patra, C. A. F. (2023). Sistem Analisa Harga Saham Menggunakan Algoritma Long Short Term Memory (LSTM). *Media Informatika*, 21(3), 264–279. <https://doi.org/10.37595/mediainfo.v21i3.159>

Sundari, A., & Ridwan, A. H. (2022). Tafsir Dan Hadist Sukuk Obligasi Syariah (Mengungkap Konsep Transaksi Kebatilan Dalam Qs. An- Nisa : 29). *Fair Value: Jurnal Ilmiah Akuntansi Dan Keuangan*, 4(6), 2464–2472. <https://doi.org/https://doi.org/10.32670/fairvalue.v4i6.1034>

Talumewo, S., Nainggolan, N., & Langi, Y. A. R. (2023). Penerapan Model ARIMA-GARCH Untuk Peramalan Harga Saham PT Adhi Karya (Persero) Tbk (ADHIJK). *D'Cartesian*, 12(2), 56–61. <https://doi.org/10.35799/dc.12.2.2023.49783>

Vargas, M. R., dos Anjos, C. E. M., Bichara, G. L. G., & Evsukoff, A. G. (2018). Deep Learning for Stock Market Prediction Using Technical Indicators and Financial News Articles. *2018 International Joint Conference on Neural Networks (IJCNN)*, 1–8. <https://doi.org/10.1109/IJCNN.2018.8489208>

Veronica, M., & Pebriani, R. A. (2020). Pengaruh Faktor Fundamental Dan Makro Ekonomi Terhadap Harga Saham Pada Perusahaan Industri Properti Di Bursa Efek Indonesia. *Islamic Banking : Jurnal Pemikiran Dan Pengembangan Perbankan Syariah*, 6(1), 119–138. <https://doi.org/10.36908/isbank.v6i1.155>