

**PREDIKSI HARGA SAHAM TELKOM INDONESIA TBK (TLKM)
MENGUNAKAN LSTM DENGAN HYPERPARAMETER
TUNING DAN REGULASI MODEL**

SKRIPSI

Oleh :
RAFI RONALDA PURNAMA HAKIM
NIM. 210605110073



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

**PREDIKSI HARGA SAHAM TELKOM INDONESIA TBK (TLKM)
MENGUNAKAN LSTM DENGAN HYPERPARAMETER
TUNING DAN REGULASI MODEL**

SKRIPSI

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

Oleh:
RAFI RONALDA PURNAMA HAKIM
NIM. 210605110073

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

HALAMAN PERSETUJUAN

PREDIKSI HARGA SAHAM TELKOM INDONESIA TBK (TLKM) MENGUNAKAN LSTM DENGAN HYPERPARAMETER TUNING DAN REGULASI MODEL

SKRIPSI

Oleh :

RAFI RONALDA PURNAMA HAKIM

NIM. 210605110073

Telah Diperiksa dan Disetujui untuk Diuji:


Tanggal: 24 November 2025

Pembimbing I,



Prof. Dr. Muhammad Faisal, M.T
NIP. 19740510 200501 1 007

Pembimbing II,



Dr. M. Imamudin Lc, MA
NIP. 19740602 200901 1 010

Mengetahui,

Ketua Program Studi Teknik Informatika

Fakultas Sains dan Teknologi

Universitas Islam Negeri Maulana Malik Ibrahim Malang




Supriyono, M. Kom
NIP. 19841010 201903 1 012

HALAMAN PENGESAHAN

PREDIKSI HARGA SAHAM TELKOM INDONESIA TBK (TLKM) MENGUNAKAN LSTM DENGAN HYPERPARAMETER TUNING DAN REGULASI MODEL

SKRIPSI



Oleh :

RAFI RONALDA PURNAMA HAKIM
NIM. 210605110073

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 2 Desember 2025

Susunan Dewan Penguji

Ketua Penguji	: <u>Prof. Dr. Suhartono S.Si M.Kom</u> NIP. 196805192003121001
Anggota Penguji I	: <u>Supriyono, M. Kom</u> NIP. 19841010 201903 1 012
Anggota Penguji II	: <u>Prof. Dr. Muhammad Faisal, M.T</u> NIP. 19740510 200501 1 007
Anggota Penguji III	: <u>Dr. M. Imamudin Lc, MA</u> NIP. 19740602 200901 1 010

()
()
()
()

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



Supriyono, M. Kom
NIP. 19841010 201903 1 012

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Rafi RONALDA Purnama Hakim
NIM : 210605110073
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Prediksi Harga Saham Telkom Indonesia TBK
(TLKM) Menggunakan LSTM dengan
Hyperparameter Tuning dan Regulasi Model

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, 18 November 2025
Yang membuat pernyataan,



Rafi RONALDA Purnama Hakim
NIM. 210605110073

MOTTO

"hidup di dunia hanya menunggu waktu shalat"

HALAMAN PERSEMBAHAN

Alhamdulillah, Syukur dan puji yang tak terhingga penulis haturkan kehadirat Allah SWT, Sang Pencipta semesta alam. Berkat curahan rahmat, taufik, dan hidayah-Nya yang berkelanjutan, alhamdulillah, skripsi ini akhirnya dapat terselesaikan dengan lancar dan baik. Tak lupa, shalawat dan salam senantiasa terlimpah kepada junjungan kita, Nabi Besar Muhammad SAW.

Skripsi ini secara khusus penulis persembahkan bagi orang-orang terdekat yang selama ini menjadi sumber semangat dan sumber kekuatan utama dalam perjalanan hidup penulis. Terutama kepada kedua orang tua penulis tercinta, Bapak Eko Romdhani dan Ibu Pujiani. Tiada kata yang cukup untuk membalas segala cinta, kasih sayang, dukungan, baik moril maupun materiil, serta untaian doa tulus yang tak pernah terputus. Mereka adalah alasan terbesar di balik penyelesaian skripsi ini. Dari merekalah penulis memetik pelajaran berharga tentang ketulusan hati, kesabaran tanpa batas, dan kerja keras yang seolah tak mengenal lelah. Terima kasih juga penulis sampaikan kepada kakak-kakakku tersayang, Rimbadhani Rahmat Purnama Hakim dan Ramadhani Nur Hakim, yang selalu memberikan dorongan semangat dan mendukung perjuangan ini dengan caranya yang sederhana, namun penuh arti.

Sebagai penutup, penulis ingin memberikan apresiasi terdalam untuk diri sendiri. Terima kasih karena telah mampu bertahan melalui setiap tantangan dan berjuang tanpa menyerah. Terima kasih telah memegang teguh keyakinan bahwa setiap upaya, sekecil apa pun bentuknya, pasti akan membuahkan hasil yang manis pada akhirnya.

KATA PENGANTAR

Assalamualaikum Warahmatullahi Wabarakatuh

Dengan Menyebut Nama Allah yang Maha Pengasih lagi Maha Penyayang, segala puji bagi Allah Tuhan Semesta Alam. Atas segala rahmat dan karunia-Nya sehingga penulis mampu menyelesaikan skripsi dengan judul "Prediksi Harga Saham Telkom Indonesia TBK (TLKM) Menggunakan LSTM Dengan Hyperparameter Tuning Dan Regulasi Model". Sholawat serta salam semoga selalu tercurah limpahkan kepada Nabi Muhammad SAW yang telah membimbing umatnya dari zaman jahiliyah menuju zaman islamiyah yakni addinul islam, semoga kita mendapatkan syafaatnya di hari kiamat nanti, Aamiin.

Dalam penulisan skripsi ini, tak lepas dari peran dan dukungan kepada banyak pihak yang tak ternilai. Oleh karena itu, penulia ingin menyampaikan terima kasih kepada :

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si, selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Dr. Agus Mulyono, M.Kes, selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Supriyono, M. Kom, selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Prof. Dr. Muhammad Faisal, M.T selaku dosen pembimbing I yang telah memberikan arahan, bimbingan selama penulisan skripsi sehingga penulis dapat menyelesaikan skripsi dengan baik dan tepat waktu

5. Dr. M. Imamudin Lc, MA selaku Dosen Pembimbing II yang telah membimbing dan memberikan arahan serta masukan kepada penulis sehingga penulis dapat menyelesaikan skripsi ini.
6. Prof. Dr. Suhartono S.Si M.Kom selaku Penguji I dan Supriyono, M. Kom selaku Penguji II yang telah memberikan saran dan kritik selama proses pengujian skripsi ini.
7. Segenap dosen, laboran, dan jajaran staff Program Studi Teknik Informatika yang telah memberikan ilmu, pengetahuan, dan dukungan selama penulis menjalani studi hingga selesainya skripsi ini
8. Keluarga Kecil Penulis. Terima kasih kepada kedua orang tua tercinta Bapak Eko Romdhani dan Ibu Pujiani, serta kakak-kakakku, Rimbadhani Rahmat Purnama Hakim dan Ramadhani Nur Hakim. Dukungan, doa, dan kasih sayang kalian adalah kekuatan terbesar bagi penulis dalam menyelesaikan karya ini. Semoga Allah SWT selalu memberkahi kita semua.
9. Hakim's Family, Bapak Eko Romdhani, Ibu Pujiani, Mas Rimba, Mba Kak Elma, Mas Rama, Mba Desi, terima kasih sudah selalu ada, memberi semangat, dukungan, dan motivasi selama ini. Semoga kalian selalu diberikan kemudahan di segala urusan.
10. Kos Wisma Bambu, Rama, Charles, Zidan, terima kasih sudah selalu ada, memberi semangat, dukungan, dan motivasi yang sudah diberikan selama ini, terima kasih sudah hadir di kehidupan penulis.

11. Majelis Cab Malang, Topik, Abdi, Nasipa, terima kasih atas dukungan dan bantuannya. Semoga kelak kita semua dipertemukan kembali dalam kesuksesan masing-masing
12. Seluruh warga besar Teknik Informatika UIN Malang, khususnya angkatan 2021 "ASTER" yang telah memberikan dukungan dan bantuan kepada penulis.
13. Seluruh pihak yang telah terlibat, baik secara langsung maupun tidak langsung dari awal perkuliahan hingga akhir penulisan skripsi ini.
14. Diri sendiri, Rafi RONALDA PURNAMA HAKIM, terima kasih sudah berjuang sejauh ini. Terima kasih sudah berusaha semaksimal mungkin semoga segala harapan yang diimpikan bisa menjadi sebuah kenyataan.

Akhir kata, penulis menyadari bahwa skripsi ini masih memiliki kekurangan, baik dalam aspek keilmuan maupun penulisan. Oleh karena itu, penulis dengan senang hati menerima kritik dan saran yang membangun. Harapannya, skripsi ini dapat memberikan manfaat bagi berbagai pihak.

Wassalamu'alaikum warahmatullahi wabarakatuh.

Malang, 18 November 2025

Penulis

DAFTAR ISI

HALAMAN PENGAJUAN.....	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN.....	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI	xi
DAFTAR GAMBAR.....	xiii
DAFTAR TABEL	xiv
ABSTRAK	xv
ABSTRACT	xvi
المخلص.....	xvii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	6
1.3 Batasan Masalah	6
1.4 Tujuan Penelitian	7
1.5 Manfaat Penelitian	7
BAB II STUDI PUSTAKA.....	8
2.1 Penelitian Terdahulu	8
2.2 Prediksi	19
2.3 Saham	20
2.4 <i>Long Short-Term Memory (LSTM)</i>	23
2.5 Root Mean Square Error (RMSE).....	30
2.6 Mean Absolute Percentage Error (MAPE)	31
2.7 R-Squared	32
2.8 <i>Hyperparameter Tuning</i>	33
2.9 Teknik Regulasi Model.....	34
2.9.1 Teknik Early Stopping.....	35
2.9.2 Teknik Batch Normalization.....	35
BAB III METODE PENELITIAN	36
3.1 Desain Sistem	36
3.2 Pengumpulan Data.....	37
3.3 <i>Preprocessing</i>	37
3.4 Permodelan <i>Long Short-Term Memory</i>	39
3.5 <i>Hyperparameter Tuning</i>	42
3.6 Teknik Regulasi Model.....	42
3.7 Proses <i>Training</i>	43
3.8 Proses <i>Testing</i>	44
3.9 Evaluasi Kinerja Model	44
BAB IV HASIL DAN PEMBAHASAN	46
4.1 Deskripsi Data.....	46
4.1.1 Sumber dan Rentang Data	46
4.1.2 Statistik Deskriptif Data	47
4.1.3 Normalisasi Data (Scaling).....	48
4.1.4 Pembagian Data Latih dan Data Uji	48

4.2 Uji Coba Skenario 1.....	49
4.2.1 Arsitektur dan Konfigurasi Model Skenario 1.....	50
4.2.2 Hasil Tuning Hyperparameter	51
4.3 Uji Coba Skenario 2.....	56
4.3.1 Arsitektur dan Konfigurasi Model Skenario 2.....	57
4.3.2 Hasil Tuning Hyperparameter	58
4.4 Uji Coba Skenario 3.....	64
4.4.1 Arsitektur dan Konfigurasi Model Skenario 3.....	65
4.4.2 Hasil Tuning Hyperparameter	66
4.5 Analisis Kinerja Model Berdasarkan Variasi Time Step	71
4.6 Pembahasan	84
4.6.1 Validasi Efektivitas Model dan Teknik Optimalisasi	89
4.7 Integrasi Islam.....	91
4.7.1 Pilar <i>'Ilm</i> (Ilmu yang Bermanfaat)	93
4.7.2 Pilar <i>Mizan</i> (Keseimbangan)	94
4.7.3 Pilar <i>Hifzh al-Mal</i> (Penjagaan Harta)	96
4.7.4 Muamalah Ma'a-Allah	97
4.7.5 Muamalah Ma'a an-Nas	99
BAB V KESIMPULAN DAN SARAN	101
5.1 Kesimpulan	101
5.2 Saran	102
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 2.1 Stuktur Jaringan LSTM (Colah, 2015)	24
Gambar 2.2 Forgot Gate pada Jaringan LSTM (Colah, 2015)	25
Gambar 2.3 Input Gate pada Jaringan LSTM (Colah, 2015).....	27
Gambar 2.4 Output Gate pada Jaringan LSTM (Colah, 2015)	29
Gambar 3.1 Desain Sistem.....	36
Gambar 4.1 Hasil split data skenario 1	50
Gambar 4.2 Hasil Training dan loss validation skenario 1	53
Gambar 4.3 Visualisasi hasil prediksi skenario 1	54
Gambar 4.4 Visualisasi distribusi error absolut skenario 1	56
Gambar 4.5 Hasil split data skenario 2	57
Gambar 4.6 Hasil Training dan loss validation skenario 2	60
Gambar 4.7 Visualisasi hasil prediksi skenario 2	62
Gambar 4.8 Visualisasi distribusi error absolut skenario 2	64
Gambar 4.9 Hasil split data skenario 3	64
Gambar 4.10 Hasil Training dan loss validation skenario 3	68
Gambar 4.11 Visualisasi hasil prediksi skenario 3	69
Gambar 4.12 Visualisasi distribusi error absolut skenario 3	71
Gambar 4.13 Prediksi 30 hari kedepan rasio 80:20 time step 15.....	73
Gambar 4.14 Prediksi 30 hari kedepan rasio 80:20 time step 30.....	74
Gambar 4.15 Prediksi 30 hari kedepan rasio 80:20 time step 45.....	74
Gambar 4.16 Prediksi 30 hari kedepan rasio 80:20 time step 60.....	76
Gambar 4.17 Prediksi 30 hari kedepan rasio 90:10 time step 15.....	77
Gambar 4.18 Prediksi 30 hari kedepan rasio 90:10 time step 30.....	78
Gambar 4.19 Prediksi 30 hari kedepan rasio 90:10 time step 45.....	79
Gambar 4.20 Prediksi 30 hari kedepan rasio 90:10 time step 60.....	80
Gambar 4.21 Prediksi 30 hari kedepan rasio 70:30 time step 15.....	81
Gambar 4.22 Prediksi 30 hari kedepan rasio 70:30 time step 30.....	82
Gambar 4.23 Prediksi 30 hari kedepan rasio 70:30 time step 45.....	82
Gambar 4.24 Prediksi 30 hari kedepan rasio 70:30 time step 60.....	83

DAFTAR TABEL

Tabel 2.1 Penelitian Terkait	17
Tabel 3.1 Pembagian dataset.....	39
Tabel 4.1 Deskripsi data	46
Tabel 4.2 Statistik deskriptif data	47
Tabel 4.3 Hasil normalisasi.....	48
Tabel 4.4 Hasil Split Data	49
Tabel 4.5 Arsitektur dasar skenario 1	50
Tabel 4.6 Hasil ranking tuning parameter skenario 1	52
Tabel 4.7 Hasil tuning parameter terbaik skenario 1	52
Tabel 4.8 Hasil prediksi skenario 1	54
Tabel 4.9 Hasil evaluasi metrik skenario 1	55
Tabel 4.10 Arsitektur dasar skenario 2	58
Tabel 4.11 Hasil ranking tuning parameter skenario 2	59
Tabel 4.12 Hasil tuning parameter terbaik skenario 2	59
Tabel 4.13 Hasil prediksi skenario 2.....	61
Tabel 4.14 Hasil evaluasi metrik skenario 2	63
Tabel 4.15 Arsitektur dasar skenario 3	65
Tabel 4.16 Hasil ranking tuning parameter skenario 3	66
Tabel 4.17 Hasil tuning parameter terbaik skenario 3	67
Tabel 4.18 Hasil prediksi skenario 3.....	69
Tabel 4.19 Hasil evaluasi metrik skenario 3	70
Tabel 4.20 Hasil evaluasi metrik dengan tambahan time step	72
Tabel 4.21 Hasil error setiap skenario	84
Tabel 4.22 Klaster gambar	87

ABSTRAK

Hakim, Rafi RONALDA Purnama. 2025. **Prediksi Harga Saham Telkom Indonesia Tbk (TLKM) Menggunakan LSTM Dengan Hyperparameter Tuning Dan Regulasi Model**. Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Prof. Dr. Muhammad Faisal, M.T (II) Dr. M. Imamudin Lc, MA

Kata Kunci: *Long Short-Term Memory (LSTM)*, Prediksi Saham, *Hyperparameter Tuning*, Regulasi Model, Harga *Close*, Rasio.

Penelitian ini bertujuan mengimplementasikan model LSTM untuk memprediksi harga saham TLKM berdasarkan data historis harga *Close* selama empat tahun. Optimasi model difokuskan pada *Hyperparameter Tuning* dan regulasi dalam batasan penggunaan *single feature*. Metodologi melibatkan *preprocessing* data dan perancangan arsitektur simple LSTM, di mana tuning dilakukan menggunakan *Randomized Search* yang dikombinasikan dengan *Time Series Cross-Validation (TSCV)*. Untuk memastikan validitas pengujian, data dibagi ke dalam tiga skenario perbandingan (70:30, 80:20, 90:10) dengan tambahan variasi *time step* (15,30,45,60). Hasil komparasi *hyperparameter tuning* telah mengidentifikasi adanya dua kandidat model terbaik, yaitu model akurasi absolut terbaik (*time step* 60 hari, Rasio 80:20) dan model daya generalisasi terbaik (*time step* 60 hari, Rasio 70:30) model daya generalisasi unggul dengan R^2 sebesar 0,9781. Hasil eksperimen menunjukkan bahwa variasi *time step* 60, Rasio 80:20 mencapai kinerja optimal. Kinerja model terbaik divalidasi dengan metrik R^2 sebesar 0,8697, MAPE 1,63%, dan RMSE 61,69. Meskipun akurasi metrik tinggi, keterbatasan *single feature* menyebabkan prediksi cenderung garis mulus, menyoroti tantangan LSTM dalam menangkap volatilitas tinggi pasar finansial. Penelitian ini menegaskan pentingnya *Hyperparameter Tuning* dalam menghasilkan model prediksi yang efisien dan stabil.

ABSTRACT

Hakim, Rafi Ronalda Purnama. 2025. **Telkom Indonesia Tbk (TLKM) Share Price Prediction Using LSTM with Hyperparameter Tuning and Model Regulation.** Thesis. Informatics Engineering Study Program, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University, Malang. Supervisor: (I) Prof. Dr. Muhammad Faisal, M.T (II) Dr. M. Imamudin Lc, MA

Keywords: *Long Short-Term Memory (LSTM), Stock Prediction, Hyperparameter Tuning, Model Regulation, Close Price, Ratio.*

This study aims to implement an LSTM model to predict TLKM stock prices based on historical Close price data for four years. The optimization model focuses on Hyperparameter Tuning and regulation within the constraints of using a single feature. The methodology involves data preprocessing and simple LSTM architecture design, where tuning is performed using Randomized Search combined with Time Series Cross-Validation (TSCV). To ensure the validity of the test, the data is divided into three comparison scenarios (70:30, 80:20, 90:10) with additional time step variations (15,30,45,60). The results of the hyperparameter tuning comparison have identified two best model candidates, namely the best absolute accuracy model (time step 60 days, Ratio 80:20) and the best generalization power model (time step 60 days, Ratio 70:30) the superior generalization power model with R^2 of 0.9781. The experimental results show that the variation of time step 60, Ratio 80:20 achieves optimal performance. The best-performing model was validated with an R^2 of 0.8697, a MAPE of 1.63%, and an RMSE of 61.69. Despite its high accuracy, the limitation of a single feature causes the predictions to be linear, highlighting the challenges of LSTM in capturing the high volatility of financial markets. This study emphasizes the importance of hyperparameter tuning in producing efficient and stable prediction models.

Keywords: *Long Short-Term Memory (LSTM), Stock Prediction, Hyperparameter Tuning, Model Regulation, Close Price, Ratio.*

الملخص

حكيم، رافي رونالدا بورناما. 2025. التنبؤ بسعر سهم شركة تيلكوم إندونيسيا المحدودة (TLKM). باستخدام شبكات الذاكرة طويلة قصيرة المدى (LSTM) مع ضبط المتغيرات الفائقة وتنظيم النموذج. رسالة جامعية. برنامج دراسة هندسة المعلومات، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية بمالانج. المشرفان: (أ) الأستاذ الدكتور/ محمد فيصل، ماجستير في الهندسة (ب) الدكتور/ م. إمام الدين، ليسانس، ماجستير في الآداب.

الكلمات المفتاحية: الذاكرة طويلة قصيرة المدى ، التنبؤ بالسهم، ضبط المتغيرات الفائقة، تنظيم النموذج، سعر الإغلاق، النسبة.

تهدف هذه الدراسة إلى تطبيق نموذج LSTM للتنبؤ بأسعار أسهم TLKM استنادًا إلى بيانات أسعار الإغلاق التاريخية لأربع سنوات. وتركز الدراسة على تحسين النموذج من خلال ضبط المعلمات الفائقة والتحكم فيه ضمن قيود استخدام ميزة واحدة. تتضمن المنهجية معالجة البيانات المسبقة وتصميم بنية LSTM بسيطة، حيث يتم الضبط باستخدام البحث العشوائي مع التحقق المتقاطع للسلاسل الزمنية (TSCV). ولضمان صحة الاختبار، قُسمت البيانات إلى ثلاث سيناريوهات مقارنة (70:30، 80:20، 90:10) بفواصل زمنية مختلفة (15، 30، 45، 60). وقد حددت نتائج مقارنة ضبط المعلمات الفائقة نموذجين مرشحين كأفضل نموذجين، وهما: نموذج الدقة المطلقة الأفضل (فاصل زمني 60 يومًا، نسبة 80:20) ونموذج قوة التعميم الأفضل (فاصل زمني 60 يومًا، نسبة 70:30)، حيث حقق نموذج قوة التعميم الأفضل قيمة R^2 بلغت 0.9781. تُظهر النتائج التجريبية أن تغيير خطوة الزمن إلى 60، ونسبة 80:20، يحقق الأداء الأمثل. وقد تم التحقق من صحة النموذج الأفضل أداءً بمعامل تحديد (R^2) قدره 0.8697، ومتوسط الخطأ المطلق النسبي (MAPE) بنسبة 1.63%، وجذر متوسط مربع الخطأ (RMSE) بنسبة 61.69. على الرغم من دقته العالية، فإن الاعتماد على ميزة واحدة فقط يؤدي إلى تنبؤ خطي سلس، مما يُبرز تحديات نموذج LSTM في رصد تقلبات السوق المالية العالية. تؤكد هذه الدراسة على أهمية ضبط المعلمات الفائقة لإنتاج نماذج تنبؤ فعالة ومستقرة.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Pasar modal merupakan wadah bagi berbagai instrumen keuangan berjangka panjang yang dapat diperjualbelikan, termasuk saham. Saham menjadi salah satu pilihan investasi yang banyak diminati karena potensinya dalam meningkatkan pendapatan, termasuk sebagai sumber penghasilan tambahan atau *passive income* (Usmanovich Burkhanov & Mansur Qizi Eshmamatova, 2021). Perusahaan menerbitkan saham sebagai salah satu strategi untuk mendapatkan pendanaan guna mendukung kegiatan operasional dan pengembangan bisnis. Di Indonesia, aktivitas perdagangan saham di Bursa Efek Indonesia (BEI) terus menunjukkan perkembangan yang pesat, menarik minat banyak investor untuk terlibat aktif. Harga saham menjadi salah satu indikator penting yang diperhatikan investor, karena tingkat harga tersebut dapat menjadi acuan dalam mengambil keputusan untuk membeli, menjual, atau menahan saham demi meraih keuntungan yang optimal (Patriya, 2020).

Namun, investasi saham juga memiliki risiko yang cukup tinggi, terutama jika harga beli saham lebih mahal daripada harga jual, sehingga berpotensi menimbulkan kerugian. Meski demikian, saham tetap menawarkan peluang keuntungan yang besar apabila dikelola dengan baik. Untuk mengurangi risiko dan meningkatkan potensi keuntungan, investor perlu melakukan analisis mendalam terhadap pergerakan harga saham, termasuk memprediksi tren harga di masa depan

(Agustina, 2021). Hal ini sangat penting agar investor dapat membuat keputusan investasi yang lebih tepat dan strategis.

Fenomena fluktuasi harga saham ini juga mengingatkan kita akan pentingnya kehati-hatian dalam mengelola harta. Al-Qur'an dalam Surat Al-Baqarah ayat 188 menyebutkan:

وَلَا تَأْكُلُوا أَمْوَالَكُمْ بَيْنَكُمْ بِالْبَاطِلِ وَتُدْخِلُوا بِهَا إِلَى الْحُكَّامِ لِتَأْكُلُوا فَرِيقًا مِّنْ أَمْوَالِ النَّاسِ بِالْإِثْمِ وَأَنْتُمْ تَعْلَمُونَ^٤

"Dan janganlah sebagian kamu memakan harta sebagian yang lain di antara kamu dengan jalan yang batil dan (janganlah) kamu membawa (urusan) harta itu kepada hakim, supaya kamu dapat memakan sebagian daripada harta benda orang lain itu dengan (jalan berbuat) dosa, padahal kamu mengetahui." (QS. Al-Baqarah: 188).

Ayat QS. Al-Baqarah: 188 melarang umat Islam memakan harta orang lain *"dengan jalan yang batil"* (*bil-bāṭil*), yang merupakan dasar etika dalam mencari dan mengelola harta. Secara batil itu maksudnya dengan cara yang haram yang dilarang oleh agama seperti mencuri, merampas, memalak dan menipu (dalam Tafsir Al-Mukhtashar). Dalam Tafsir Muyassar disebutkan cara batil itu seperti sumpah dusta, *ghasab*, mencuri, menyuap, riba dan lain sebagainya (Nirwana, 2021). Segala bentuk transaksi saham yang didasarkan murni pada tebakan, spekulasi buta, tanpa didukung oleh analisis fundamental atau teknikal yang memadai, dan hanya bertujuan untuk mendapatkan keuntungan dari selisih harga dalam waktu singkat dikategorikan sebagai Spekulasi Murni (*Maisir*). Praktik ini berisiko merugikan pihak lain secara tidak adil dan karena itu jatuh dalam kategori pengambilan harta dengan cara batil.

Ayat ini mengingatkan kita agar tidak terjerumus dalam praktik yang tidak adil, seperti spekulasi yang bisa merugikan orang lain. Dalam dunia investasi,

terutama di pasar saham, sering kali ada godaan untuk mencari keuntungan dengan cara yang cepat dan berisiko tinggi, yang justru dapat menimbulkan kerugian besar. Oleh karena itu, penting bagi investor untuk menghindari keputusan investasi yang berdasarkan spekulasi tanpa dasar yang jelas dan lebih mengutamakan prediksi yang didasarkan pada data yang akurat dan sah. Prediksi harga saham yang akurat, yang menggunakan analisis data yang transparan dan berbasis fakta, bisa sangat membantu investor dalam mengambil keputusan yang lebih bijaksana dan lebih bertanggung jawab. Dengan menggunakan teknologi seperti AI dan *machine learning* untuk memprediksi pergerakan harga saham, investor dapat mengurangi ketergantungan pada spekulasi atau keputusan impulsif. Namun, dalam mengintegrasikan teknologi ini, sangat penting untuk memastikan bahwa penggunaan AI dan *machine learning* tetap berlandaskan pada prinsip-prinsip syariah. Teknologi ini harus digunakan dengan prinsip transparansi, keadilan, dan tanggung jawab sosial yang sejalan dengan nilai-nilai Islam.

Secara fundamental, upaya memprediksi pergerakan harga saham dan berinvestasi di pasar modal sejalan dengan anjuran fundamental dalam ajaran Islam mengenai persiapan masa depan dan tanggung jawab finansial. Allah *Subhanahu Wa Ta'ala* berfirman dalam Surah Al-Hasyr ayat 18:

يَا أَيُّهَا الَّذِينَ آمَنُوا اتَّقُوا اللَّهَ وَلْتَنْظُرْ نَفْسٌ مَّا قَدَّمَتْ لِغَدٍ وَاتَّقُوا اللَّهَ ۚ إِنَّ اللَّهَ خَبِيرٌ بِمَا تَعْمَلُونَ

“Hai orang-orang yang beriman, bertakwalah kepada Allah dan hendaklah setiap diri memperhatikan apa yang telah diperbuatnya untuk hari esok (akhirat), dan bertakwalah kepada Allah, sesungguhnya Allah Maha Mengetahui apa yang kamu kerjakan.” (QS. Al-Hasyr : 18).

Ayat QS. Al-Hasyr: 18 memerintahkan kaum beriman untuk *"bertakwalah kepada Allah dan hendaklah setiap diri memperhatikan apa yang telah diperbuatnya untuk hari esok"*. Imam Ibnu Katsir dalam tafsirnya menjelaskan perintah ini sebagai kewajiban untuk *muhasabah* (introspeksi) terhadap amal perbuatan yang telah dipersiapkan sebagai bekal di Hari Kiamat (hari esok).

Ayat ini memberikan landasan filosofis bagi penelitian ini, yang tidak hanya berfokus pada prediksi harga saham sebagai instrumen bisnis semata, namun juga sebagai bentuk usaha manusia untuk merencanakan masa depan finansial yang lebih baik, di mana setiap keputusan investasi harus dipertimbangkan secara matang dan didasarkan pada ketakwaan (prinsip syariah) untuk mencapai kemaslahatan di dunia dan akhirat.

Saham PT Telkom Indonesia (Persero) Tbk merupakan salah satu saham yang paling diminati di Bursa Efek Indonesia (BEI). Sebagai perusahaan telekomunikasi terbesar di Indonesia, Telkom memegang peran penting dalam pengembangan infrastruktur digital dan komunikasi nasional. Saham Telkom dikenal memiliki likuiditas tinggi dan termasuk dalam kategori saham yang stabil, sehingga menjadi pilihan utama bagi investor, baik retail maupun institusional. Namun, meskipun termasuk dalam saham yang dikenal stabil, harga saham Telkom tetap mengalami fluktuasi yang dipengaruhi oleh berbagai faktor, seperti kinerja keuangan perusahaan, perkembangan industri telekomunikasi, dan kondisi ekonomi makro. Fluktuasi harga saham ini menciptakan tantangan bagi investor dalam mengambil keputusan investasi yang tepat (Putri & Pratama, 2024). Oleh karena itu, prediksi harga saham Telkom menjadi sangat penting untuk membantu

investor meminimalkan risiko dan memaksimalkan potensi keuntungan. Harga saham memiliki data historis harian yang mencakup harga pembukaan (*open price*), harga tertinggi dan terendah dalam satu hari perdagangan (*high and low*), harga penutupan (*close price*), serta jumlah pembelian di hari itu (*volume*) (Chen, 2020). Data historis ini dapat dimanfaatkan untuk melakukan prediksi harga saham di masa depan, sehingga investor dapat mengambil keputusan yang lebih tepat dalam melakukan transaksi, baik itu membeli, menjual, atau menahan saham. Dengan demikian, prediksi harga saham menjadi alat penting untuk membantu investor meminimalkan risiko dan memaksimalkan peluang keuntungan.

Salah satu metode yang populer dalam prediksi deret waktu (*time series*) seperti harga saham adalah *Long Short-Term Memory* (LSTM) (Yadav et al., 2020). LSTM merupakan jenis jaringan saraf berulang (*Recurrent Neural Network*) yang dirancang untuk menangani data sekuensial dengan mempertahankan informasi jangka panjang. Namun, performa LSTM cukup bergantung pada pemilihan hyperparameter yang tepat, seperti jumlah lapisan, jumlah *neuron*, *learning rate*, dan lain-lain (Sabiri et al., 2023). Selain itu, untuk menghindari *overfitting*, diperlukan teknik regulasi model seperti teknik *early stopping* dan *batch normalization*. Oleh karena itu, *hyperparameter tuning* dan regulasi model menjadi aspek penting dalam meningkatkan akurasi prediksi harga saham.

Dengan demikian penelitian ini bertujuan untuk mengembangkan model prediksi harga saham Telkom Indonesia menggunakan LSTM dengan *hyperparameter tuning* dan regulasi model. Dengan memanfaatkan data historis harga saham, model ini diharapkan dapat memberikan prediksi yang lebih akurat

dan membantu investor dalam mengambil keputusan investasi yang lebih baik. Selain itu, penelitian ini juga diharapkan dapat memberikan kontribusi dalam pengembangan teknologi AI yang sesuai dengan nilai-nilai Islam.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dibahas, dapat disimpulkan rumusan masalah dalam penelitian ini adalah:

1. Bagaimana performa model prediksi harga saham Telkom Indonesia menggunakan metode *Long Short-Term Memory* (LSTM)?
2. Bagaimana pengaruh *hyperparameter tuning* dan regulasi model terhadap akurasi prediksi harga saham Telkom Indonesia?

1.3 Batasan Masalah

Berdasarkan penjelasan tersebut, maka ditetapkan batasan permasalahan untuk melakukan penelitian ini antara lain:

1. Data yang digunakan adalah data saham PT Telkom Indonesia TBK (TLKM) yang bersumber dari Investing.com dengan periode mulai dari 1 Januari 2021 – 1 Januari 2025.
2. Parameter data yang akan digunakan adalah data harga penutup harian saham (*close price*).
3. Pengukuran tingkat error pada program menggunakan perhitungan *Root Mean Square Error*, *Mean Absolute Percentage Error* dan *R-Squared*.

1.4 Tujuan Penelitian

Berdasarkan rumusan masalah diatas, tujuan dari penelitian ini adalah sebagai berikut:

1. Untuk mengetahui performa model prediksi harga saham Telkom Indonesia menggunakan metode *Long Short-Term Memory* (LSTM).
2. Untuk mengetahui pengaruh *hyperparameter tuning* dan regulasi model terhadap akurasi prediksi harga saham PT Telkom Indonesia Tbk.

1.5 Manfaat Penelitian

Manfaat dari penelitian ini adalah :

1. Bagi investor dan masyarakat

Penelitian ini diharapkan mampu membantu para investor ataupun menjadi referensi dalam mengambil keputusan untuk membeli, menjual, atau tetap bertahan pada saham yang telah dimilikinya.

2. Bagi akademisi dan peneliti

Penelitian ini diharapkan menjadi sarana pengembangan wawasan keilmuan, terutama pada ranah prediksi nilai saham dengan pendekatan jaringan saraf tiruan, sekaligus menjadi referensi untuk menyempurnakan penelitian di masa yang akan datang

BAB II

STUDI PUSTAKA

2.1 Penelitian Terdahulu

Pada penelitian yang dilakukan oleh Rosyd et al. (2024) tentang prediksi saham dengan LSTM, data yang digunakan sebagai objek adalah harga saham PT Bank Central Asia dengan rentang waktu 1 Januari 2020 hingga 30 Oktober 2023. Penelitian ini bertujuan untuk memberikan wawasan yang lebih baik kepada investor dalam pengambilan keputusan investasi dengan memanfaatkan teknologi data mining dan algoritma machine learning. Model yang digunakan dalam penelitian ini adalah LSTM, yang merupakan pengembangan dari *Recurrent Neural Network* (RNN) dan dirancang khusus untuk mengatasi masalah data yang memiliki hubungan temporal. Dalam implementasinya, model LSTM ini terdiri dari 2 hidden layer, di mana setiap lapisan memiliki unit sebanyak 50. Selain itu, terdapat juga *dense layer* yang memiliki *neuron* sebanyak 25, yang berfungsi untuk mengubah output dari hidden layer menjadi prediksi harga saham yang lebih akurat. Proses pelatihan model dilakukan dengan menggunakan data historis yang telah diproses dan dinormalisasi untuk mengurangi noise dan anomali. Hasil penelitian ini menunjukkan nilai error model LSTM dengan metrik RMSE sebesar 40.85, MAPE sebesar 0.71%, dan MSE sebesar 6662.76. Dengan hasil ini, dapat disimpulkan bahwa model LSTM yang diterapkan dalam penelitian ini berhasil memberikan prediksi yang akurat dan dapat diandalkan dalam analisis pergerakan harga saham PT BCA, sehingga mendukung pengambilan keputusan investasi yang lebih baik.

Pada penelitian yang penulis lakukan ialah menggunakan data harga saham dari PT Telkom Indonesia Tbk (TLKM). Kemudian penelitian ini menambahkan model LSTM dengan eksplorasi jumlah *layer*, jumlah *neuron*, *dropout rate*, dan teknik *hyperparameter tuning* untuk meningkatkan akurasi prediksi. Serta menambahkan metrik seperti *R-squared* (R^2) untuk menganalisis performa yang lebih akurat.

Pada penelitian yang dilakukan oleh Pratama dan Utama (2023) tentang prediksi harga Bitcoin dengan LSTM, data yang digunakan sebagai objek adalah harga Bitcoin dengan rentang waktu dari 1 Maret 2016 hingga 24 November 2018. Penelitian ini bertujuan untuk mengeksplorasi kemampuan model LSTM dalam memprediksi pergerakan harga *cryptocurrency* yang dikenal sangat *volatile*. Model yang digunakan dalam penelitian ini adalah LSTM dengan satu hidden layer, di mana parameter yang diterapkan adalah *epoch* sebesar 10 dan *learning rate* sebesar 0.001. Proses pelatihan model dilakukan dengan mengumpulkan data historis dan melakukan preprocessing untuk memastikan data dalam format yang sesuai untuk analisis. Hasil penelitian ini menunjukkan bahwa model LSTM yang diterapkan menghasilkan nilai error dengan metrik RMSE sebesar 77.74 dan MAE sebesar 278.33. Meskipun nilai RMSE tergolong tinggi, hal ini dapat dimaklumi mengingat fluktuasi harga Bitcoin yang sangat besar. Penelitian ini menegaskan bahwa LSTM dapat menjadi alat yang efektif dalam memprediksi harga Bitcoin, meskipun hasilnya masih dipengaruhi oleh volatilitas pasar yang tinggi.

Dalam penelitian ini, model LSTM digunakan untuk memprediksi harga saham PT Telkom Indonesia Tbk (TLKM), dengan penambahan eksplorasi

terhadap parameter-parameter seperti jumlah lapisan, jumlah *neuron*, *dropout rate*, serta pengoptimalan *hyperparameter* untuk memperoleh prediksi yang lebih tepat. Untuk menganalisis hasil performa model secara lebih rinci, metrik *R-squared* (R^2) akan digunakan.

Pada penelitian yang dilakukan oleh Berton et al. (2024) tentang prediksi harga saham PT Indosat Tbk dengan LSTM, data yang digunakan sebagai objek adalah harga saham harian dari 18 Maret 2004 hingga 25 November 2021. Penelitian ini bertujuan untuk menganalisis tingkat keakuratan model LSTM dalam meramalkan harga saham, yang merupakan salah satu aspek penting dalam pengambilan keputusan investasi. Model yang digunakan dalam penelitian ini melibatkan beberapa tahap, termasuk pengumpulan data, preprocessing untuk menghapus nilai null dan normalisasi, serta pemisahan data menjadi data latih dan data tes. Proses pelatihan model dilakukan dengan menggunakan data latih yang telah diproses, dan hasil prediksi dievaluasi menggunakan metrik seperti MAPE. Penelitian ini menunjukkan bahwa model LSTM dapat memberikan prediksi yang akurat, meskipun tidak disebutkan secara spesifik nilai metrik evaluasi yang dihasilkan. Dengan demikian, penelitian ini menekankan pentingnya pemodelan yang tepat dalam memprediksi harga saham untuk membantu investor dalam pengambilan keputusan investasi yang lebih baik.

Penelitian ini hanya memprediksi harga saham PT Telkom Indonesia Tbk (TLKM) menggunakan model LSTM. Penelitian ini akan melakukan eksperimen dengan mengatur jumlah lapisan, jumlah *neuron*, dan tingkat *dropout*, serta melakukan *tuning hyperparameter* untuk meningkatkan presisi prediksi. Di

sampling itu, metrik *R-squared* (R^2) akan ditambahkan untuk memberikan analisis performa yang lebih akurat dan terukur.

Pada penelitian yang dilakukan oleh Agusmawati et al. (2023) tentang perbandingan LSTM dan *Gated Recurrent Unit* (GRU) dalam memprediksi harga emas, data yang digunakan sebagai objek adalah harga emas harian dari 4 Januari 2000 hingga 2 September 2022. Penelitian ini bertujuan untuk mengevaluasi efektivitas kedua model deep learning dalam memprediksi harga komoditas yang sangat fluktuatif. Model LSTM yang digunakan dalam penelitian ini terdiri dari beberapa hidden layer, di mana hasil metrik evaluasi menunjukkan nilai MAE sebesar 0.0389, RMSE sebesar 0.0475, dan MAPE sebesar 5.2047% untuk model LSTM. Sementara itu, model GRU menunjukkan nilai MAE sebesar 0.0447, RMSE sebesar 0.0545, dan MAPE sebesar 6.0688%. Penelitian ini menemukan bahwa meskipun LSTM memiliki nilai error yang lebih rendah, GRU lebih efektif dalam memprediksi harga emas. Proses pelatihan model dilakukan dengan mengumpulkan data historis dan melakukan preprocessing untuk memastikan data dalam format yang sesuai untuk analisis. Hasil penelitian ini menunjukkan bahwa pemilihan model yang tepat sangat penting dalam analisis prediksi harga komoditas, dan memberikan wawasan yang berharga bagi investor dalam mengambil keputusan investasi yang lebih baik.

Pada penelitian ini LSTM digunakan sebagai metode dalam memprediksi saham dikarenakan berdasarkan uraian penelitian diatas LSTM lebih efektif dalam memodelkan data yang sangat fluktuatif karena struktur memori internalnya yang memungkinkan model untuk mempertahankan informasi penting lebih lama,

memberikan hasil prediksi yang lebih stabil. LSTM juga lebih fleksibel dalam hal tuning hyperparameter, yang memungkinkan penyesuaian yang lebih baik terhadap dataset besar dan kompleks seperti harga emas.

Pada penelitian yang dilakukan oleh Budiprasetyo et al. (2023) tentang prediksi harga saham syariah menggunakan algoritma *Long Short-Term Memory* (LSTM), data yang digunakan mencakup harga penutupan harian dari lima emiten syariah di Indonesia selama periode 2016 hingga 2021. Penelitian ini bertujuan untuk mengevaluasi efektivitas model LSTM dalam memprediksi harga saham syariah yang berfluktuasi. Model yang digunakan dalam penelitian ini melibatkan beberapa layer LSTM dengan masing-masing layer memiliki 96 *neuron*, serta satu *dense layer* untuk menghasilkan output prediksi. Hasil penelitian menunjukkan bahwa model LSTM dapat memberikan prediksi yang akurat dengan nilai MAPE yang bervariasi tergantung pada emiten yang dianalisis. Penelitian ini menekankan pentingnya pemilihan parameter yang tepat dalam model LSTM untuk mencapai hasil prediksi yang optimal, serta memberikan wawasan bagi investor dalam pengambilan keputusan investasi yang lebih baik.

Dalam penelitian ini, hanya memprediksi harga saham PT Telkom Indonesia Tbk (TLKM) dan dilakukan menggunakan model LSTM, dengan fokus pada penyesuaian jumlah lapisan, jumlah *neuron*, dan *dropout rate*. Penelitian ini juga mengimplementasikan teknik *hyperparameter tuning* untuk mendapatkan hasil prediksi yang lebih akurat. Sebagai tambahan, metrik *R-squared* (R^2) akan digunakan untuk menganalisis performa model dengan lebih detail dan tepat.

Pada penelitian yang dilakukan oleh Wu et al. (2023) tentang perbandingan model ARIMA dan LSTM dalam memprediksi harga saham, data yang digunakan adalah data historis harga saham Apple dari 1 April 2016 hingga 21 September 2020. Penelitian ini bertujuan untuk mengevaluasi kinerja kedua model dalam memprediksi harga saham yang sangat dinamis. Model LSTM yang digunakan dalam penelitian ini dirancang dengan beberapa hidden layer dan menggunakan data yang telah diproses untuk memastikan akurasi prediksi. Hasil penelitian menunjukkan bahwa model LSTM menghasilkan nilai RMSE sebesar 0.237, sedangkan model ARIMA menghasilkan nilai RMSE sebesar 3.261. Dengan demikian, penelitian ini menyimpulkan bahwa model LSTM lebih unggul dibandingkan dengan model ARIMA dalam hal akurasi prediksi harga saham, menunjukkan potensi LSTM sebagai alat yang lebih efektif dalam analisis pasar saham. Penelitian ini juga menyarankan untuk mempertimbangkan faktor eksternal yang dapat mempengaruhi harga saham dalam model prediksi di masa depan.

Penelitian ini menggunakan metode LSTM dalam memprediksi saham dikarenakan dalam penelitian yang dilakukan oleh Wu et al. (2023), LSTM menunjukkan performa yang lebih baik dengan nilai RMSE yang jauh lebih rendah dibandingkan ARIMA. LSTM dianggap lebih unggul dibandingkan dengan model ARIMA dalam prediksi harga saham karena kemampuannya untuk menangani data yang bersifat dinamis dan memiliki dependensi temporal yang panjang.

Liu (2024) melakukan penelitian mengenai prediksi harga saham menggunakan kombinasi CNN-GRU-XGBoost yang dioptimasi dengan *hyperparameter tuning* berbasis *Bayesian Search* untuk CNN-GRU dan *Random*

Search untuk XGBoost. Model ini memanfaatkan CNN untuk mengekstraksi fitur spasial dari data saham, GRU untuk menangkap dependensi jangka panjang dalam data *time series*, dan XGBoost untuk mengelola interaksi fitur kompleks serta mencegah *overfitting*. Data yang digunakan adalah Hang Seng Index selama lima tahun (2019–2024).

Hasil penelitian menunjukkan bahwa CNN-GRU-XGBoost memberikan performa terbaik dibandingkan model pembanding (XGBoost, LSTM, CNN-LSTM, CNN-GRU, dan CNN-LSTM-XGBoost). Nilai akurasi yang diperoleh mencapai 90,08%, dengan peningkatan signifikan pada metrik evaluasi: MAE = 0,0040, RMSE = 0,0053, dan $R^2 = 0,9964$, yang menandakan tingkat kesalahan prediksi yang sangat rendah dan kemampuan generalisasi yang kuat. Penelitian ini menegaskan bahwa penggabungan deep learning (CNN, GRU) dengan boosting tree (XGBoost), serta optimasi hyperparameter, mampu meningkatkan stabilitas dan efektivitas prediksi harga saham dibandingkan model tunggal.

Ismanto dan Vitriani (2023) melakukan penelitian mengenai prediksi harga saham dengan menggunakan LSTM yang dioptimasi melalui framework Optuna. Penelitian ini menggunakan data historis saham dari Nepal Stock Exchange (NEPSE) dengan periode 2012–2020. Dalam eksperimennya, penulis membangun empat variasi arsitektur model, yaitu dua model single LSTM dan dua model stacked LSTM. *Hyperparameter* yang dioptimasi meliputi optimizer (SGD, Adagrad, RMSprop, Nadam, Adamax, Adam), jumlah unit LSTM, *dropout rate*, jumlah *epoch*, *batch size*, serta *learning rate*. Hasil penelitian menunjukkan bahwa model single LSTM varian 1 dengan tuning *hyperparameter* otomatis melalui

Optuna menghasilkan performa terbaik dengan nilai RMSE = 7,21, yang lebih rendah dibandingkan tuning manual. Penelitian ini menegaskan bahwa penggunaan Optuna framework mampu meningkatkan efektivitas pencarian *hyperparameter* secara otomatis dan memberikan hasil prediksi yang lebih akurat dalam peramalan harga saham.

Ilemobayo et al. (2024) melakukan penelitian berbentuk tinjauan pustaka mengenai *hyperparameter tuning* dalam *machine learning*. Penelitian ini menekankan pentingnya tuning *hyperparameter* dalam meningkatkan performa dan kemampuan generalisasi model *machine learning*. Dalam kajiannya, penulis membahas berbagai teknik optimasi seperti *grid search*, *random search*, *Bayesian optimization*, *genetic algorithm*, *Hyperband*, *meta-learning*, hingga *AutoML*. Penelitian ini juga menyoroti peran penting *hyperparameter* seperti *learning rate*, *batch size*, jumlah lapisan, jumlah unit *neuron*, serta parameter regulasi dalam memengaruhi kinerja model, khususnya pada jaringan deep learning. Selain itu, Ilemobayo et al. (2024) juga menekankan adanya *trade-off* dalam *tuning hyperparameter*, seperti keseimbangan antara biaya komputasi dan peningkatan performa, risiko *overfitting*, serta masalah skalabilitas dan interpretabilitas model. Hasil kajian menunjukkan bahwa pemilihan teknik tuning yang tepat dapat meningkatkan akurasi, efisiensi, dan generalisasi model, serta membuka arah penelitian baru dalam pengembangan metode tuning yang lebih adaptif dan hemat sumber daya.

Hoque dan Aljamaan (2021) melakukan penelitian tentang pengaruh *hyperparameter tuning* pada berbagai model *machine learning* dalam peramalan

harga saham. Penelitian ini menggunakan data dari 11 perusahaan yang terdaftar di Saudi Stock Exchange (Tadawul) dan membandingkan delapan algoritma *machine learning* konvensional, yaitu *Decision Tree* (DT), *Support Vector Regression* (SVR), *K-Nearest Neighbour* (KNN), *Gaussian Process Regression* (GPR), *Stochastic Gradient Descent* (SGD), *Partial Least Squares Regression* (PLS), *Kernel Ridge Regression* (KRR), serta LASSO. Proses tuning dilakukan menggunakan *grid search* dengan pembagian data 80% training dan 20% testing. Evaluasi kinerja model menggunakan metrik *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE), serta uji statistik *Wilcoxon effect size* untuk membandingkan model sebelum dan sesudah tuning. Hasil penelitian menunjukkan bahwa SVR yang dituning memiliki performa terbaik dengan error terkecil di sebagian besar dataset, sementara KRR dan LASSO tampil baik meskipun tanpa tuning. Sebaliknya, *Decision Tree* dan KNN tetap menunjukkan performa rendah meskipun telah dituning. Penelitian ini menegaskan bahwa *hyperparameter tuning* dapat memberikan dampak signifikan terhadap peningkatan akurasi, namun efeknya bervariasi antarmodel; beberapa model sangat terbantu oleh tuning, sedangkan model lain justru mengalami degradasi performa.

Berdasarkan penelitian terdahulu, sebagian besar studi hanya memanfaatkan arsitektur LSTM standar dengan konfigurasi yang terbatas pada jumlah layer atau *neuron* tertentu, tanpa eksplorasi mendalam terhadap *hyperparameter* yang digunakan. Selain itu, penelitian sebelumnya juga jarang menekankan pentingnya teknik regulasi model untuk mencegah *overfitting*, sehingga hasil prediksi cenderung hanya terfokus pada data latih. Penilaian

performa model juga umumnya terbatas pada metrik RMSE dan MAPE, tanpa menggunakan metrik tambahan seperti R-Squared (R^2) yang dapat memberikan gambaran lebih komprehensif mengenai seberapa besar variasi data dapat dijelaskan oleh model. Oleh karena itu, penelitian ini menawarkan kebaruan dengan memfokuskan objek pada saham TLKM, sekaligus mengintegrasikan *hyperparameter tuning*, regulasi model (*early stopping*), serta evaluasi tambahan menggunakan R^2 . Dengan demikian, penelitian ini diharapkan dapat menghasilkan prediksi harga saham yang lebih akurat dan lebih dapat diandalkan dibandingkan penelitian terdahulu.

Tabel 2.1 Penelitian Terkait

Peneliti	Judul	Metode	Hasil
Budiprasetyo, G., Hani'ah, M., & Aflah, D. Z. (2023).	Prediksi Harga Saham Syariah Menggunakan Algoritma <i>Long Short-Term Memory</i> (LSTM)	<i>Long Short-Term Memory</i> (LSTM) dengan multiple layer (4 dan 8 layer) dan 96 neurons per layer.	Hasil penelitian menunjukkan bahwa LSTM dapat digunakan untuk memprediksi harga saham syariah dengan akurasi yang baik. Nilai MAPE terbaik untuk masing-masing emiten: ANTM (2,64), ERAA (2,24), KLBF (1,51), SMGR (1,83), dan WIKA (2,66).
Berton, F. T., Rowan, Islamy, M. A. A., Fitra, R. R., Dinata, I. G. A., & Yudistira, N. (2023).	Prediksi Harga Saham Indosat Menggunakan Algoritma LSTM	Algoritma <i>Long Short-Term Memory</i> (LSTM) untuk memprediksi harga saham PT Indosat Tbk.	Hasil penelitian menunjukkan bahwa model LSTM menghasilkan prediksi dengan MAPE sebesar 2.02%. Parameter terbaik yang ditemukan adalah hidden layer 16, LSTM layer 2, epoch 200, dan learning rate 0.05.
Rosyd, A., Purnamasari, A. I., & Ali, I. (2024).	Penerapan Metode Long Short-Term Memory (LSTM) dalam Memprediksi Harga Saham PT Bank Central Asia	Algoritma <i>Long Short-Term Memory</i> (LSTM) dengan optimasi "adam" untuk memprediksi harga saham PT Bank Central Asia.	Hasil penelitian menunjukkan bahwa model LSTM menghasilkan prediksi dengan tingkat akurasi yang baik, ditunjukkan oleh nilai RMSE sebesar 40.85, MAPE sebesar

Peneliti	Judul	Metode	Hasil
			0.71%, dan MSE sebesar 6662.76.
Pratama, M. L., & Utama, H. (2023).	Pendekatan Deep Learning Menggunakan Metode LSTM untuk Prediksi Harga Bitcoin	Algoritma <i>Long Short-Term Memory</i> (LSTM) dengan optimasi "adam" untuk memprediksi harga Bitcoin.	Hasil penelitian menunjukkan bahwa model LSTM menghasilkan prediksi dengan RMSE sebesar 77.74 dan MAE sebesar 278.33.
Wu, H., Chen, S., & Ding, Y. (2023)	Comparison of ARIMA and LSTM for Stock Price Prediction	ARIMA (Auto-regressive Integrated Moving Average) dan LSTM (<i>Long Short-Term Memory</i>) untuk memprediksi harga saham Apple.	Hasil penelitian menunjukkan bahwa model LSTM memiliki performa yang lebih baik dibandingkan ARIMA dalam memprediksi harga saham Apple. Nilai RMSE untuk LSTM adalah 0.237, sedangkan ARIMA memiliki RMSE sebesar 3.261.
Agusmawati, N. K., Khoiriyah, F., & Tholib, A. (2023).	Prediksi Harga Emas Menggunakan Metode LSTM dan GRU	Algoritma <i>Long Short-Term Memory</i> (LSTM) dan Gated Recurrent Unit (GRU) untuk memprediksi harga emas.	Hasil penelitian menunjukkan bahwa model LSTM menghasilkan nilai MAE 0.0389, RMSE 0.0475, dan MAPE 5.2047%, sedangkan model GRU menghasilkan MAE 0.0447, RMSE 0.0545, dan MAPE 6.0688%. LSTM memiliki nilai eror yang lebih rendah.
Liu (2024)	CNN-GRU-XGBoost stock price prediction model under hyperparameter-based optimisation	Hybrid CNN-GRU-XGBoost, <i>Bayesian Search</i> (CNN-GRU), Random Search (XGBoost)	Akurasi 90,08%, MAE = 0,0040, RMSE = 0,0053, $R^2 = 0,9964$. Model hybrid terbukti lebih unggul dibandingkan model tunggal.
Ismanto & Vitriani (2023)	LSTM Network Hyperparameter Optimization for Stock Price Prediction Using the Optuna Framework	LSTM (single & stacked) dengan hyperparameter tuning Optuna	Model single LSTM varian 1 terbaik, RMSE = 7,21. Optuna lebih efektif daripada tuning manual dalam meningkatkan akurasi prediksi.
Ilemobayo et al. (2024)	Hyperparameter Tuning in Machine Learning: A Comprehensive Review	Tinjauan pustaka berbagai metode tuning: Grid Search, Random Search, Bayesian, Genetic Algorithm, Hyperband, AutoML	Hyperparameter tuning meningkatkan akurasi & generalisasi model; ada trade-off antara performa, biaya komputasi, dan risiko overfitting.
Hoque & Aljamaan (2021)	Impact of Hyperparameter Tuning on Machine	8 algoritma ML (DT, SVR, KNN, GPR, SGD,	SVR dengan tuning terbaik; KRR & LASSO cukup baik meski tanpa

Peneliti	Judul	Metode	Hasil
	Learning Models in Stock Price Forecasting	PLS, KRR, LASSO) dengan Grid Search	tuning; DT & KNN tetap rendah performa meskipun dituning.

2.2 Prediksi

Prediksi adalah proses memperkirakan secara sistematis tentang sesuatu yang paling mungkin terjadi di masa depan berdasarkan informasi masa lalu dan saat ini untuk mengurangi kesalahan antara hasil yang diperkirakan dengan kenyataan yang terjadi. Prediksi tidak memberikan jawaban pasti, tetapi berusaha mendekati hasil yang mungkin terjadi (Alfiana et al., 2023).

Menurut *Kamus Besar Bahasa Indonesia* (KBBI), prediksi adalah hasil dari kegiatan memperkirakan atau meramal sesuatu di masa depan dengan memanfaatkan data historis. Prediksi sering digunakan sebagai input dalam proses perencanaan dan pengambilan keputusan, baik dalam bidang ekonomi, teknik, lingkungan, maupun kebijakan sosial.

Prediksi adalah suatu aktivitas yang bertujuan untuk memperkirakan peristiwa yang akan terjadi di masa depan. Dalam proses pengambilan keputusan, sering kali terdapat tantangan yang harus dihadapi, dan prediksi menjadi salah satu aspek penting yang perlu diperhatikan. Kualitas prediksi yang baik sangat bergantung pada penerapan langkah-langkah atau prosedur yang tepat (Irfan Syahroni, 2022). Secara umum, terdapat tiga langkah utama dalam melakukan peramalan yang efektif, yaitu:

1. Analisis Data Historis:

Langkah pertama adalah mengumpulkan dan menganalisis data dari masa lalu. Data ini menjadi dasar untuk memahami pola dan tren yang mungkin berulang di masa depan.

2. Pemilihan Metode:

Setelah data dianalisis, langkah selanjutnya adalah menentukan metode yang akan digunakan untuk melakukan prediksi. Metode ini bisa bervariasi, mulai dari analisis statistik sederhana hingga model yang lebih kompleks.

3. Proyeksi Data:

Langkah terakhir adalah memproyeksikan data historis menggunakan metode yang telah dipilih, sambil mempertimbangkan berbagai faktor yang dapat mempengaruhi perubahan di masa depan. Ini termasuk perubahan dalam kondisi ekonomi, sosial, atau lingkungan yang mungkin berdampak pada hasil yang diprediksi.

2.3 Saham

Saham merupakan salah satu instrumen keuangan yang paling populer di pasar modal saat ini. Sebagai surat berharga, saham menunjukkan bukti kepemilikan seseorang atau badan usaha dalam sebuah perusahaan. Dengan kata lain, saham adalah tanda penyertaan modal yang dimiliki oleh individu atau entitas dalam suatu perusahaan atau perseroan terbatas. Menerbitkan saham menjadi salah satu strategi yang dipilih perusahaan untuk mendapatkan pendanaan, dan ini menjadikan saham sebagai instrumen investasi yang menarik bagi banyak investor

karena potensi keuntungan yang dapat diperoleh (St. Petersburg State University et al., 2021).

Secara umum, saham dapat didefinisikan sebagai tanda kepemilikan yang menunjukkan seberapa besar kontribusi modal yang ditanamkan dalam perusahaan. Dengan demikian, besarnya kepemilikan saham seseorang atau badan usaha ditentukan oleh proporsi investasi yang dilakukan. Saham, sebagai surat tanda bukti kepemilikan, memainkan peran penting dalam dunia investasi dan keuangan, memberikan peluang bagi investor untuk berpartisipasi dalam pertumbuhan dan keuntungan perusahaan.

Saham PT Telkom Indonesia Tbk (TLKM) merupakan salah satu perusahaan terbesar dan paling berpengaruh di Indonesia dalam sektor telekomunikasi. Sebagai perusahaan dengan posisi dominan di pasar, saham TLKM menunjukkan kecenderungan yang stabil dan terus meningkat dalam jangka panjang, menjadikannya menarik untuk diteliti, terutama bagi para investor yang ingin memahami dinamika pasar saham di sektor telekomunikasi yang berkembang pesat (Muhammad Fauzan & Nova Syafitri, 2022). Dengan rekam jejak yang baik dalam hal kinerja keuangan dan pertumbuhan, TLKM menjadi salah satu saham pilihan di Bursa Efek Indonesia. Selain itu, ketersediaan data historis yang luas memberikan peluang untuk menerapkan berbagai teknik analisis dan model prediksi, seperti *Long Short-Term Memory* (LSTM), yang dapat membantu mempelajari lebih dalam tentang faktor-faktor yang mempengaruhi pergerakan harga saham perusahaan ini.

Kedudukan saham juga dikaji secara mendalam dari sudut pandang hukum Islam atau syariah. Dewan Syariah Nasional Majelis Ulama Indonesia (DSN-MUI) telah menetapkan bahwa secara prinsip, aktivitas investasi dan transaksi saham adalah halal dan diperbolehkan, dengan syarat utamanya adalah kepatuhan terhadap prinsip-prinsip syariah Islam. Kebolehan ini didasarkan pada konsep bahwa saham merupakan bukti kepemilikan modal dalam suatu perseroan, sejalan dengan kaidah fikih muamalah bahwa segala bentuk transaksi pada dasarnya dibolehkan kecuali ada dalil syar'i yang mengharamkannya.

Dasar utama dari legalitas saham syariah di Indonesia tertuang dalam Fatwa DSN-MUI Nomor 40/DSN-MUI/X/2003 tentang Pasar Modal dan Pedoman Umum Penerapan Prinsip Syariah di Bidang Pasar Modal, yang kemudian diperbarui dan dipertegas melalui Fatwa-fatwa lainnya, termasuk Fatwa DSN-MUI Nomor 135/DSN-MUI/V/2020 tentang Saham. Fatwa-fatwa ini menetapkan dua filter utama untuk menentukan suatu saham tergolong Saham Syariah:

1. Saringan Sektor Bisnis (Non-Haram): Emiten atau Perusahaan Publik yang menerbitkan saham dilarang melakukan kegiatan usaha yang bertentangan dengan prinsip syariah. Kegiatan yang dilarang meliputi usaha yang berkaitan dengan perjudian, jasa keuangan ribawi (seperti bank dan asuransi konvensional), memproduksi atau memperdagangkan barang/jasa yang diharamkan, serta kegiatan yang merusak moral atau bersifat mudarat.
2. Saringan Rasio Keuangan (Tingkat Utang): Untuk memastikan perusahaan tidak didominasi oleh unsur non-syariah, ditetapkan batasan rasio keuangan. Rasio utang berbasis bunga dibandingkan dengan total aset perusahaan


tidak boleh melebihi 45%, dan total pendapatan non-halal (seperti pendapatan bunga) dibandingkan dengan total pendapatan usaha dan pendapatan lainnya tidak boleh melebihi 10%.

Selain memenuhi kriteria emiten, pelaksanaan transaksi saham juga harus bebas dari praktik yang dilarang syariah, seperti *gharar* (ketidakpastian berlebihan), *maisir* (judi), *riba* (bunga), dan *risywah* (suap). Dengan demikian, investasi saham syariah mengharuskan setiap pelaku pasar untuk berpegang teguh pada prinsip kehati-hatian dan menghindari tindakan spekulasi atau manipulasi yang dapat merugikan pihak lain. Saham PT Telkom Indonesia Tbk (TLKM) sendiri, sebagai objek penelitian ini, secara rutin dikategorikan sebagai Saham Syariah yang memenuhi kriteria Otoritas Jasa Keuangan (OJK) dan DSN-MUI.

2.4 Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah salah satu arsitektur jaringan saraf yang telah mendapatkan perhatian luas dalam bidang kecerdasan buatan, khususnya dalam pengolahan data berurutan. Diperkenalkan oleh Sepp Hochreiter dan Jürgen Schmidhuber pada tahun 1997, LSTM dirancang untuk mengatasi masalah yang sering dihadapi oleh jaringan saraf tradisional, terutama terkait dengan fenomena *vanishing gradient*. Fenomena ini dapat menghambat proses pelatihan model ketika berhadapan dengan data berurutan yang panjang. Dengan kemampuan untuk menyimpan informasi dalam jangka waktu yang lama, LSTM telah menjadi pilihan utama dalam berbagai aplikasi, mulai dari pemrosesan bahasa alami hingga analisis deret waktu (Selle et al., 2022).

Kelebihan utama LSTM terletak pada kemampuannya untuk mengatasi masalah *vanishing gradient*, yang sering menjadi kendala dalam pelatihan jaringan saraf tradisional. Selain itu, LSTM juga mampu menangkap hubungan jangka panjang dalam data berurutan, yang sangat penting dalam banyak aplikasi. LSTM memiliki struktur yang berbeda dibandingkan dengan jaringan saraf konvensional. Arsitektur ini terdiri dari *memory cell* yang berfungsi untuk menyimpan informasi untuk periode waktu yang lebih lama. Selain itu, terdapat tiga *gate* utama yang mengatur aliran informasi dalam LSTM, yaitu *input gate*, *forget gate*, dan *output gate*. Masing-masing *gate* yang termasuk pada LSTM akan dijelaskan sebagai berikut:




Gambar 2.1 Struktur Jaringan LSTM (Colah, 2015)

a. *Forget Gate*

Forget Gate berfungsi untuk mengontrol informasi baru yang nantinya akan disimpan dalam *memory cell*. Gate ini merupakan lapisan sigmoid yang menerima nilai output dari langkah sebelumnya (waktu $t-1$) dan nilai input pada langkah saat ini (waktu t). Nilai-nilai ini kemudian digabungkan dan diproses melalui fungsi aktivasi sigmoid. Hasil dari fungsi sigmoid ini akan menghasilkan nilai antara 0 dan 1. Jika nilai yang

dihasilkan mendekati 1, maka informasi dari state sebelumnya akan tetap dipertahankan dan tidak ada perubahan yang terjadi. Sebaliknya, jika nilai yang dihasilkan mendekati 0, maka informasi dari state sebelumnya akan dihapus atau dilupakan.

Forgot gate memiliki peran krusial dalam menentukan informasi mana yang harus dihapus dari *memory cell*. Proses ini melibatkan beberapa langkah yang saling terkait. Pertama, *forgot gate* lupa menghitung aktivasi menggunakan fungsi sigmoid, yang menghasilkan nilai antara 0 dan 1. Nilai ini mencerminkan seberapa banyak informasi dari *memory cell* sebelumnya yang akan dilupakan.



Gambar 2.2 *Forgot Gate* pada Jaringan LSTM (Colah, 2015)

Persamaan yang digunakan untuk menghitung aktivasi *forgot gate* adalah:

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

Keterangan:

- f_t = Nilai forget gate pada time step t
- σ = Fungsi sigmoid
- W_f = Bobot forget gate
- h_{t-1} = Nilai output pada time step t-1
- x_t = Nilai input pada time step t


b_f = Bias forget gate

Setelah menghitung nilai aktivasi, informasi yang ada dalam *memory cell* akan diperbarui. Proses ini dilakukan dengan mengalikan nilai *memory cell* sebelumnya dengan output dari *forget gate*. Dengan demikian forget gate menghapus informasi yang tidak lagi diperlukan, sehingga meningkatkan efisiensi dalam pengolahan data berurutan (Zhang et al., 2021; Li et al., 2022). Dengan cara ini, hanya informasi yang relevan yang akan tetap ada dalam *memory cell*. Pembaruan *memory cell* dapat dinyatakan dengan persamaan berikut:

$$C_t = f_t \cdot c_{t-1} + i_t \cdot \tanh(x_t) \quad (2.2)$$

b. Input Gate

Input gate memiliki peran penting dalam mengontrol informasi baru yang akan disimpan dalam *memory cell*. Proses ini terdiri dari beberapa langkah yang saling terkait. Pertama, *input gate* menghitung aktivasi menggunakan fungsi sigmoid, yang menghasilkan nilai antara 0 dan 1. Nilai ini mencerminkan seberapa banyak informasi baru yang akan diterima dari input saat ini dan output dari langkah sebelumnya.



Gambar 2.3 *Input Gate* pada Jaringan LSTM (Colah, 2015)

Persamaan yang digunakan untuk menghitung aktivasi *input gate* adalah:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.3)$$

Keterangan:

- i_t = *input gate*
- σ = fungsi sigmoid
- W_i = nilai weight untuk *input gate*
- h_{t-1} = nilai output time step t-1
- x_t = nilai input pada time step ke t
- b_i = nilai bias pada input gate

Setelah menentukan seberapa banyak informasi baru yang akan diterima, *input gate* kemudian menghasilkan vektor calon memori. Proses ini dilakukan dengan menggunakan fungsi tanh, yang menghasilkan vektor yang berisi informasi baru yang akan ditambahkan ke dalam *memory cell*.

Persamaan untuk menghasilkan vektor calon memori adalah:

$$C'_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (2.4)$$

Keterangan:


- C'_t = Nilai yang akan masuk dalam memory cell baru
- $\tanh$ = Fungsi tanh
- W_c = Bobot pada operasi memory cell yang diperbarui
- h_{t-1} = Nilai output time step t-1

x_t = Nilai input pada time step ke t
 b_c = Bias operasi memory cell yang diperbarui

Selanjutnya, informasi baru yang telah dipilih oleh *input gate* akan ditambahkan ke *memory cell* yang ada. Dengan demikian, peran *input gate* adalah untuk mengontrol sejauh mana nilai baru dapat mengalir ke dalam *memory cell*. Ini dirancang untuk mencegah penyimpanan data yang tidak perlu, sehingga hanya informasi yang relevan yang akan disimpan. *Input gate* mengambil nilai output dari langkah sebelumnya dan nilai input baru, kemudian memprosesnya melalui lapisan sigmoid. Hasil dari fungsi sigmoid ini akan menghasilkan nilai antara 0 dan 1, yang menunjukkan seberapa banyak informasi baru yang akan disimpan dalam *memory cell* (Zhang et al., 2021; Li et al., 2022).

c. Output Gate

Output gate memiliki peran penting dalam menentukan informasi mana yang akan dikeluarkan dari *memory cell* untuk digunakan dalam langkah berikutnya. Proses ini terdiri dari beberapa langkah yang saling terkait. Pertama, *output gate* menghitung aktivasi menggunakan fungsi sigmoid, yang menghasilkan nilai antara 0 dan 1. Nilai ini mencerminkan seberapa banyak informasi dari *memory cell* yang akan dikeluarkan.



Gambar 2.4 *Output Gate* pada Jaringan LSTM (Colah, 2015)

Persamaan yang digunakan untuk menghitung aktivasi *output gate* adalah:

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

Keterangan:

- o_t = Nilai output gate pada time step t
- σ = Fungsi sigmoid
- W_o = Bobot output gate
- h_{t-1} = Nilai output pada time step t-1
- x_t = Nilai input pada time step t
- b_o = Bias forget gate

Setelah menentukan seberapa banyak informasi yang akan dikeluarkan, *output gate* kemudian menghasilkan output akhir. Proses ini dilakukan dengan mengalikan output dari *output gate* dengan fungsi tanh dari *memory cell*, yang memberikan hasil akhir yang akan digunakan dalam langkah berikutnya. Persamaan untuk menghasilkan output akhir adalah:

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

Keterangan:

- h_t = Output pada time step t
- o_t = Nilai output gate pada time step t
- $\tanh$ = Fungsi tanh
- C_t = Memory cell pada time step t

Dengan demikian, output gate berfungsi untuk mengendalikan seberapa banyak nilai yang ada dalam *memory cell* yang akan dihitung sebagai output. Ini memastikan bahwa hanya informasi yang relevan yang dikeluarkan untuk digunakan dalam proses selanjutnya (Zhang et al., 2021; Li et al., 2022).

2.5 Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) adalah metrik yang digunakan untuk mengukur perbedaan antara nilai aktual dan nilai yang diprediksi oleh model. Proses perhitungan RMSE dimulai dengan menghitung selisih antara data aktual dan prediksi, mengkuadratkan selisih tersebut, menjumlahkan hasil kuadrat, dan membaginya dengan jumlah total pengamatan sebelum akhirnya diakarkan. Dengan pendekatan ini, RMSE menghindari penggunaan nilai absolut yang tidak diinginkan dalam perhitungan matematis. Metrik ini sangat berguna dalam mengevaluasi kinerja model prediksi, termasuk model berbasis *Long Short-Term Memory* (LSTM), karena memberikan bobot lebih pada kesalahan yang lebih besar. Hal ini dapat membantu untuk memahami akurasi model dalam memprediksi nilai yang diharapkan. RMSE tidak hanya diterapkan dalam analisis data waktu, tetapi juga digunakan di berbagai bidang seperti meteorologi, kualitas udara, dan penelitian iklim, menjadikannya alat penting dalam pengembangan dan penilaian model prediksi yang efektif dan andal (Hodson, 2022; Ahmed et al., 2021).

Rumus RMSE dapat dinyatakan sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2}{n}} \quad (2.7)$$

Keterangan:

Y_i = Permintaan aktual pada periode t
 $\bar{Y}_i$ = Peramalan permintaan pada periode t
 n = Jumlah periode peramalan yang terlibat

Di mana Y_i adalah nilai aktual, $\bar{Y}_i$ adalah nilai yang diprediksi, dan (n) adalah jumlah total pengamatan. Proses perhitungan RMSE dimulai dengan menghitung selisih antara semua data aktual dan data hasil prediksi, kemudian mengkuadratkan selisih tersebut. Hasil kuadrat ini dijumlahkan dan dibagi dengan jumlah total pengamatan, sebelum akhirnya diakarkan.

2.6 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) adalah salah satu metrik yang digunakan untuk mengevaluasi akurasi model prediksi, termasuk dalam konteks model *Long Short-Term Memory* (LSTM). MAPE mengukur seberapa besar kesalahan prediksi model dalam bentuk persentase, sehingga memberikan gambaran yang lebih intuitif tentang kinerja model. Metrik ini sangat berguna karena mudah dipahami dan dapat digunakan untuk membandingkan kinerja model di berbagai skala.

Rumus untuk menghitung MAPE adalah sebagai berikut:

$$MAPE = \frac{\sum_{i=1}^n \frac{|\bar{Y}_i - Y_i|}{Y_i}}{n} * 100 \quad (2.8)$$

Keterangan:

Y_i = Permintaan aktual pada periode t
 $\bar{Y}_i$ = Peramalan permintaan pada periode t
 n = Jumlah periode peramalan yang terlibat

Proses perhitungan MAPE dimulai dengan menghitung selisih antara nilai aktual dan nilai yang diprediksi, kemudian membagi selisih tersebut dengan nilai aktual. Hasil ini diambil nilai absolutnya untuk menghindari kesalahan tanda, dan

kemudian dikalikan dengan 100 untuk mendapatkan persentase. Akhirnya, semua nilai persentase ini dijumlahkan dan dibagi dengan jumlah total pengamatan.

Salah satu keunggulan MAPE adalah kemampuannya untuk memberikan informasi yang jelas tentang relative error, sehingga memudahkan dalam menilai seberapa baik model dalam memprediksi nilai yang diharapkan. MAPE sering digunakan dalam berbagai bidang, termasuk ekonomi, keuangan, dan ilmu data, untuk menilai kinerja model prediksi. Dalam konteks LSTM, MAPE dapat membantu peneliti dan praktisi untuk memahami seberapa efektif model dalam menangkap pola dalam data dan memberikan prediksi yang akurat (Kourentzes et al., 2021; Ahmed et al., 2021).

2.7 R-Squared

R-squared (R^2) adalah metrik yang digunakan untuk mengevaluasi seberapa baik model prediksi, termasuk model *Long Short-Term Memory* (LSTM), dapat menjelaskan variasi dalam data. R^2 sering digunakan dalam analisis regresi untuk menilai kinerja model. Dalam konteks LSTM, R^2 dapat membantu memahami seberapa baik model dalam menangkap pola dalam data deret waktu. Nilai R^2 berkisar antara 0 hingga 1, di mana nilai yang lebih tinggi menunjukkan bahwa model lebih baik dalam menjelaskan variabilitas data. R^2 dihitung dengan rumus:

$$R^2 = 1 - \frac{\sum (Y_i - \hat{Y}_i)^2}{\sum (Y_i - \bar{Y}_i)^2} \quad (2.9)$$

Keterangan:

Y_i = Nilai aktual

$\bar{Y}_i$ = Nilai rata-rata

$\hat{Y}_i$ = Nilai prediksi

2.8 Hyperparameter Tuning

Hyperparameter tuning dalam model *Long Short-Term Memory* (LSTM) adalah langkah krusial yang bertujuan untuk mengoptimalkan parameter-parameter yang mengatur cara model dilatih dan strukturnya. Beberapa parameter penting yang perlu diperhatikan termasuk *learning rate*, *batch size*, jumlah lapisan, dan jumlah unit di setiap lapisan. Proses tuning yang dilakukan dengan baik dapat secara signifikan meningkatkan kinerja model serta kemampuannya untuk generalisasi pada data baru. Ada beberapa teknik yang umum digunakan dalam *hyperparameter tuning*. Contohnya, *grid search* melakukan pencarian menyeluruh melalui kombinasi *hyperparameter* yang telah ditentukan, sementara *random search* mengambil sampel secara acak dari kombinasi tersebut. Selain itu, *Bayesian optimization* memanfaatkan model probabilistik untuk menemukan kombinasi *hyperparameter* yang optimal dengan cara yang lebih efisien.

Setelah melakukan tuning, penting untuk mengevaluasi kinerja model menggunakan metrik seperti *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), dan *R-squared* (R^2). Metrik-metrik ini memberikan penjelasan tentang seberapa baik model dapat menjelaskan variasi dalam data yang ada. Proses ini penting untuk meningkatkan akurasi dan efisiensi model dalam memprediksi data, menjadikannya bagian integral dalam pengembangan model berbasis LSTM (Zhang & Wang, 2021; Hussain & Khan, 2022).

2.9 Teknik Regulasi Model

Teknik regulasi model dalam *machine learning* merujuk pada pendekatan yang digunakan untuk mencegah *overfitting*, sehingga model dapat bekerja dengan baik pada data baru yang belum pernah dilihat sebelumnya. *Overfitting* terjadi ketika model belajar terlalu banyak dari data pelatihan, sehingga terlalu mengingat detail dan *noise* dalam data tersebut, yang membuat kesulitan saat menghadapi data baru. Tujuan utama dari teknik regulasi ini adalah untuk mengurangi kesalahan pengujian tanpa meningkatkan kesalahan pelatihan, dan ini sangat penting untuk meningkatkan kinerja model dalam prediksi jangka panjang.

Model *deep learning*, seperti *Long Short-Term Memory* (LSTM), memiliki kapasitas belajar yang sangat tinggi. Kapasitas ini, jika tidak dikelola dengan baik, dapat menyebabkan fenomena yang dikenal sebagai *Overfitting*. *Overfitting* terjadi ketika model belajar pola data latih (*training data*) terlalu spesifik, termasuk *noise*, sehingga performanya menurun drastis ketika diuji dengan data baru (*testing data*) yang belum pernah dilihat sebelumnya.

Teknik regulasi model adalah serangkaian teknik yang diterapkan selama pelatihan model untuk mencegah *overfitting* dan meningkatkan kemampuan generalisasi model. Kemampuan generalisasi yang baik adalah kunci untuk memastikan bahwa model prediksi harga saham dapat diandalkan dalam skenario dunia nyata. Adapaun, dua teknik regulasi model utama yang biasa digunakan untuk menjaga keseimbangan dan akurasi model LSTM yaitu:

2.9.1 Teknik Early Stopping

Early Stopping adalah salah satu bentuk regulasi yang paling umum dan efektif, terutama dalam pelatihan jaringan saraf. Teknik ini bekerja dengan cara memantau performa model pada *validation dataset* (data validasi) secara berkala selama proses pelatihan (*epoch*) berlangsung. *early stopping* akan secara otomatis menghentikan proses pelatihan segera setelah performa model pada data validasi mulai stagnan atau memburuk ditandai dengan kenaikan pada *validation loss*.

2.9.2 Teknik Batch Normalization


Batch Normalization adalah teknik yang diterapkan untuk menstabilkan proses pembelajaran dalam jaringan saraf tiruan. Ia bekerja dengan menormalisasi input ke lapisan aktivasi berikutnya dengan menyesuaikan dan menskalakan aktivasi. *Batch Normalization* menghitung rata-rata dan varians dari input mini-*batch* dan menormalisasinya menjadi rata-rata nol dan varians satu. Parameter skala (*gamma*) dan pergeseran (*beta*) kemudian dipelajari selama pelatihan, memungkinkan jaringan untuk membatalkan normalisasi jika diperlukan.

BAB III

METODE PENELITIAN

3.1 Desain Sistem

Desain sistem yang digunakan dalam penelitian ini bertujuan untuk memberikan pemahaman tentang proses perancangan sistem yang dilakukan dalam penelitian ini. Desain sistem yang tercermin dalam Gambar 3.1 menggambarkan urutan langkah yang dimulai dari tahap *preprocessing data*. Pada tahap ini, dilakukan ekstraksi fitur, pembersihan data, normalisasi, dan pembagian data menjadi set latih dan uji. Setelah data siap, tahap selanjutnya adalah pembangunan model LSTM yang kemudian dioptimalkan melalui *hyperparameter tuning*. Selanjutnya, model tersebut dilatih dan diuji untuk menilai kinerjanya. Sistem ini bertujuan untuk memberikan solusi yang efektif dalam menghasilkan prediksi yang tepat, sesuai dengan kebutuhan yang telah ditentukan.



Gambar 3.1 Desain Sistem

3.2 Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diambil dari situs investing.com, khususnya mengenai saham PT Telkom Indonesia Tbk dengan kode saham TLKM. Adapun periode data yang akan dianalisis mencakup harga penutupan harian saham (close price) dari 1 Januari 2021 hingga 1 Januari 2025. Dataset ini berisi berupa informasi historis harga saham yang penting untuk memahami pergerakan harga di pasar. Data yang diambil terdiri dari 969 baris, dengan dua atribut utama yaitu “Date” dan “Close”, di mana tipe data masing-masing adalah datetime dan float. Penelitian ini bertujuan untuk memprediksi harga penutupan saham PT Telkom Indonesia Tbk (TLKM) dan format sumber data yang digunakan dalam penelitian ini memiliki format .csv.

3.3 Preprocessing

Preprocessing dalam konteks model *Long Short-Term Memory* (LSTM) adalah serangkaian langkah yang dilakukan untuk mempersiapkan data *time series* agar dapat digunakan secara efektif dalam pelatihan model. Proses ini penting karena kualitas data yang digunakan akan mempengaruhi kinerja model secara keseluruhan. Langkah pertama dalam preprocessing data adalah ekstraksi fitur yang merupakan langkah untuk memastikan bahwa data yang digunakan dalam model LSTM sudah relevan dan berkualitas. Proses ini dimulai dengan memilih fitur-fitur yang dianggap penting untuk prediksi dan kemudian mengubah data mentah menjadi informasi yang lebih berguna. Dalam konteks time-series, seperti analisis harga saham, fitur yang umumnya digunakan meliputi *High*, *Low*, *Open*, *Close*, *Adjusted Close*, dan *Volume*.

Kemudian langkah selanjutnya adalah Data cleaning karena kualitas data dapat mempengaruhi hasil analisis atau prediksi yang dihasilkan oleh model. Salah satu langkah dalam data *cleaning* adalah menangani *missing values* atau nilai yang hilang, yang dapat terjadi karena kesalahan dalam pengumpulan data atau karena data tidak tersedia untuk periode tertentu. Nilai yang hilang ini dapat diatasi dengan menghapus baris atau kolom yang mengandung *missing values*.

Kemudian terdapat normalisasi dalam *preprocessing* adalah langkah untuk memastikan bahwa data yang digunakan dalam model LSTM berada pada skala yang seragam. Proses ini mengubah nilai-nilai dalam dataset sehingga semuanya berada dalam rentang yang sama, yaitu antara 0 dan 1, dengan menggunakan teknik *Min-Max Scaling*. Dengan melakukan normalisasi, setiap fitur diberi bobot yang lebih seimbang, sehingga model dapat belajar dari semua fitur secara adil dan efisien. Selain itu, normalisasi membantu dalam mempercepat proses pelatihan model, karena data yang terstandarisasi mempercepat konvergensi algoritma. Adapun rumus dari Teknik normalisasi dengan *Min-Max Scaling* sebagai berikut;

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

Keterangan:

x' = Data setelah normalisasi
 x = Data sebelum normalisasi
 x_{min} = Nilai minimum dari dataset
 x_{max} = Nilai maksimum dari dataset

$$x_1 = \frac{x_1 - x_{min}}{x_{max} - x_{min}} = \frac{2710 - 2530}{4770 - 2530} = 180/2240 = 0.0803$$

$$x_2 = \frac{x_2 - x_{min}}{x_{max} - x_{min}} = \frac{2750 - 2530}{4770 - 2530} = 220/2240 = 0,0982$$

$$x_3 = \frac{x_3 - x_{min}}{x_{max} - x_{min}} = \frac{2740 - 2530}{4770 - 2530} = 210/2240 = 0,0937$$

$$x_4 = \frac{x_4 - x_{min}}{x_{max} - x_{min}} = \frac{2650 - 2530}{4770 - 2530} = 120/2240 = 0,0535$$

Langkah selanjutnya adalah split data untuk membagi dataset menjadi beberapa bagian yang digunakan untuk pelatihan dan pengujian model. Tujuan utama dari pembagian data ini adalah untuk memastikan bahwa model yang dilatih dapat dievaluasi secara objektif, tanpa terpengaruh oleh data yang digunakan selama pelatihan. Data latih digunakan untuk melatih model, sehingga model dapat belajar dari pola yang ada dalam data, sedangkan data uji digunakan untuk menguji kemampuan model dalam memprediksi data yang belum pernah dilihat sebelumnya. Untuk pembagian datasetnya disajikan pada Tabel 3.1.

Tabel 3.1 Pembagian dataset

Dataset	Data Latih	Data Uji
Jumlah data	90%	10%
	80%	20%
	70%	30%

3.4 Permodelan *Long Short-Term Memory*

Pada model LSTM, terdapat tiga jenis bobot yang bekerja di antara berbagai bagian dari jaringan. Pertama, ada bobot yang menghubungkan input layer ke hidden layer, yang bertugas untuk mengontrol informasi yang masuk ke dalam memori jangka pendek. Selanjutnya, ada bobot yang menghubungkan hidden layer ke output layer, yang berfungsi untuk menghasilkan output dari model. Terakhir, bobot yang menghubungkan hidden layer ke memory cell, serta memory cell kembali ke hidden layer, yang membantu LSTM memutuskan informasi mana yang perlu disimpan atau dilupakan di setiap langkah waktu melalui tiga komponen utama: forget gate, input gate, dan output gate. Selain bobot-bobot tersebut, ada

juga parameter pembelajaran yang perlu diatur, seperti *learning rate*, jumlah *epoch*, dan fungsi aktivasi. Proses pelatihan akan berhenti ketika kesalahan mencapai target yang ditetapkan atau jika jumlah iterasi yang diinginkan sudah tercapai.

Adapun perhitungan manualnya ialah sebagai berikut:

$$x_o = 2.71 \text{ (harga penutupan pada 30/12/2024)}$$

$$x_1 = 2.75 \text{ (harga penutupan pada 27/12/2024)}$$

menentukan nilai bobot (weights) dan bias secara manual:

- Forget Gate (f_o):

$$W_f = 0.5$$

$$b_f = 0.1$$

- Input Gate (i_o):

$$W_i = -0.2$$

$$b_i = 0.3$$

- Output Gate (o):

$$W_o = 0.8$$

$$b_o = 0.2$$

Menghitung forget gate:

$$f_o = \sigma(W_f \cdot x_o + b_f)$$

$$f_o = \sigma(0.5 \cdot 2.71 + 0.1)$$

$$f_o = \sigma(1.355 \cdot 0.1) = \sigma(1.455)$$

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

$$f_o = \frac{1}{1 + e^{-1.455}} = 0.811$$

Menghitung input gate:

$$i_0 = \sigma(W_i \cdot x_o + b_i)$$

$$i_0 = \sigma(-0.2 \cdot 2.71 + 0.3)$$

$$i_0 = \sigma(-0.542 + 0.3) = \sigma(-0.242)$$

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

$$i_0 = \frac{1}{1 + e^{0.242}} = 0.440$$

Menghitung memory cell:

c_{o-1} adalah 0, karena ini adalah time step pertama.

$$C_o = f_o \cdot c_{o-1} + i_o \cdot \tanh(x_o)$$

$$C_o = 0.811 \cdot 0 + 0.440 \cdot \tanh(2.71)$$

$$\tanh(2.71) = 0.993$$

$$C_o = 0.440 \cdot 0.993 = 0.437$$

Menghitung output gate

$$o_o = \sigma(W_o \cdot x_o + b_o)$$

$$o_o = \sigma(0.8 \cdot 2.71 + 0.2)$$

$$o_o = \sigma(2.168 + 0.2) = \sigma(2.368)$$

$$o_o = \frac{1}{1 + e^{-2.368}} = 0.915$$

Menghitung hidden state

$$h_o = o_o \cdot \tanh(C_o)$$

$$h_o = 0.915 \cdot \tanh(0.437)$$

$$\tanh(0.437) = 0.409$$

$$h_o = 0.915 \cdot 0.409 = 0.374$$

Berdasarkan perhitungan diatas maka time step pertama ($t=0$) dengan harga penutupan $x_o = 2.71$, mendapatkan hasil berikut:

- Forget Gate (f_o) = 0.811
- Input Gate (i_o) = 0.440
- Memory Cell (C_o) = 0.437
- Output Gate (o_o) = 0.915
- Hidden State (h_o) = 0.374

3.5 Hyperparameter Tuning

Untuk mengoptimalkan kinerja model, dilakukan *hyperparameter tuning* dengan metode random search. Beberapa hyperparameter utama yang dituning meliputi unit LSTM (32, 64, 100, 128), *batch size* (32, 64), *dropout rate* (0.1, 0.2, 0.3), *learning rate* (0.01, 0.005, 0.001, 0.0005), *epoch* (100, 150, 200), dan *activation* ('relu', 'tanh') (A. Khumaidi et al., 2022). Nilai-nilai tersebut tidak diuji secara menyeluruh, melainkan dipilih secara acak dari ruang pencarian yang telah ditetapkan. Dengan pendekatan ini, penelitian tetap dapat menemukan kombinasi *hyperparameter* yang baik tanpa harus menguji semua kemungkinan, sehingga lebih efisien dari sisi komputasi.

3.6 Teknik Regulasi Model

Setelah tahap perancangan arsitektur LSTM dan penentuan *hyperparameter* optimal melalui hyperparameter tuning, langkah selanjutnya adalah penerapan teknik regulasi model. Teknik ini diimplementasikan untuk keandalan model prediksi dengan mencegah *overfitting* pada data latih. Dalam penelitian ini, regulasi

model diimplementasikan melalui teknik *early stopping* yang terintegrasi langsung ke dalam arsitektur dan proses pelatihan.

Teknik Early Stopping diimplementasikan sebagai fungsi *callback* dalam proses pelatihan model. Parameter yang dipilih untuk dipantau adalah *validation loss*. *Validation loss* dihitung dari kinerja model pada data validasi, yang merupakan subset data latih yang tidak digunakan untuk pembaruan bobot (*weights*). Proses pelatihan dihentikan jika *Validation Loss* tidak menunjukkan perbaikan (penurunan) selama sejumlah *epoch* yang telah ditentukan (*patience*). Dalam penelitian ini, nilai *patience* ditetapkan sebesar 15, yang berarti pelatihan akan berhenti jika tidak ada penurunan *Validation Loss* dalam 15 *epoch* berturut-turut.

3.7 Proses *Training*

Proses *training* dalam model LSTM dimulai setelah data dipersiapkan melalui tahap *preprocessing*, yang mencakup ekstraksi fitur, pembersihan data, normalisasi, serta pembagian data menjadi set latih dan set uji. Setelah itu, arsitektur model LSTM dibangun dengan mendefinisikan beberapa aspek penting, seperti jumlah layer LSTM, jumlah unit *neuron*, serta parameter lainnya seperti *dropout* dan fungsi aktivasi. Setelah model terdefinisi, pelatihan dimulai dengan menggunakan data latih, yang membuat model untuk belajar dari pola yang ada dalam data. Selama pelatihan, algoritma optimasi *Adam* digunakan untuk meminimalkan error atau *loss function*, yang mengukur seberapa baik model dalam memprediksi data. Proses ini berlangsung melalui sejumlah iterasi atau *epoch*.

3.8 Proses *Testing*

Proses *testing* model LSTM dimulai setelah model selesai dilatih menggunakan data latih. Pada tahap ini, data uji yang telah dipisahkan sebelumnya digunakan untuk mengevaluasi kemampuan model dalam memprediksi data yang tidak pernah dilihat sebelumnya. Data uji ini tidak terlibat dalam pelatihan, sehingga memberikan gambaran yang lebih objektif mengenai kinerja model. Selama pengujian, model akan menghasilkan prediksi berdasarkan data uji, dan hasil prediksi ini kemudian dibandingkan dengan nilai aktual yang ada dalam data uji.

3.9 Evaluasi Kinerja Model

Evaluasi kinerja model merupakan tahapan krusial untuk menentukan tingkat akurasi dan keandalan prediksi yang secara komprehensif dapat diukur menggunakan tiga metrik utama, yakni Root Mean Squared Error (RMSE), Mean Absolute Percentage Error (MAPE), dan Koefisien Determinasi atau R-squared. Root Mean Squared Error bekerja dengan cara menghitung akar kuadrat dari rata-rata selisih kuadrat antara nilai prediksi dan nilai aktual, di mana metrik ini memberikan bobot atau penalti yang lebih besar pada kesalahan prediksi yang signifikan sehingga sangat efektif untuk mendeteksi adanya penyimpangan data yang ekstrem; oleh karena itu, semakin kecil nilai RMSE yang diperoleh, maka performa model dianggap semakin stabil dan akurat secara numerik. Di sisi lain, Mean Absolute Percentage Error memberikan gambaran mengenai rata-rata persentase kesalahan absolut terhadap nilai aktualnya, yang mana penggunaan skala persentase ini sangat membantu dalam mempermudah interpretasi bagi para

pengambil kebijakan karena memberikan pemahaman tentang seberapa besar penyimpangan terjadi dalam konteks relatif, sehingga nilai MAPE yang rendah secara langsung mencerminkan tingkat presisi model yang tinggi. Sebagai pelengkap, Koefisien Determinasi atau R-squared digunakan untuk menilai seberapa besar proporsi variabilitas dari variabel dependen yang dapat dijelaskan oleh variabel independen dalam model tersebut. Perpaduan ketiga metrik ini akan memberikan analisis yang mendalam dan menyeluruh mengenai kualitas model yang telah dibangun.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Deskripsi Data

Bagian ini menyajikan gambaran umum dan struktur data historis harga saham yang digunakan dalam penelitian. Data yang telah dimuat kemudian diinspeksi menggunakan fungsi `.info()` pada objek `DataFrame` di library `Pandas`. Hasil inspeksi ini menampilkan ringkasan mengenai jumlah baris, kolom, tipe data, dan status nilai non-null (tidak hilang), seperti yang ditunjukkan pada Tabel 4.1.

Tabel 4.1 Deskripsi data

Kolom	Jumlah
Date	969 (non-null)
Close	969 (non-null)
Open	969 (non-null)
High	969 (non-null)
Low	969 (non-null)
Volume	969 (non-null)
Change	969 (non-null)

4.1.1 Sumber dan Rentang Data

Data yang digunakan dalam penelitian ini merupakan data historis harga saham harian dari perusahaan PT Telekomunikasi Indonesia (Persero) Tbk. (TLKM). Data ini dikumpulkan dari platform data finansial publik yang terpercaya, yaitu `Investing.com`. Pemilihan data historis ini didasarkan pada kebutuhan untuk menganalisis dan memprediksi fluktuasi harga penutupan saham selama periode waktu yang signifikan.

Data yang berhasil dikumpulkan dan diproses memiliki rentang waktu observasi selama hampir empat tahun, yang terhitung mulai dari tanggal 1 Januari 2021 hingga 1 Januari 2025. Secara total, data set terdiri dari 969 entri harian, yang masing-masing merepresentasikan hari perdagangan bursa, dan mencakup tujuh fitur harga (*Open*, *High*, *Low*, *Close*, *Volume*, *Date*, dan *Change*). Kelengkapan data selama rentang waktu ini penting untuk melatih dan menguji model *Long Short-Term Memory* (LSTM) yang memerlukan urutan data yang panjang dan konsisten.

4.1.2 Statistik Deskriptif Data

Bagian ini menyajikan ringkasan statistik deskriptif dari variabel kunci yang akan menjadi target prediksi, yaitu harga penutupan harian (*Close Price*). Selain itu, ditampilkan pula visualisasi untuk menunjukkan tren historis pergerakan harga saham PT Telekomunikasi Indonesia (TLKM) selama periode penelitian. Untuk mendapatkan ringkasan statistik (rata-rata, standar deviasi, nilai minimum, dan maksimum), perlu menjalankan fungsi `.describe()` pada kolom `df['Close']` di source code yang dimiliki. Hasilnya akan disajikan pada Tabel 4.2.

Tabel 4.2 Statistik deskriptif data

Keterangan	Nilai
Jumlah	969
Rata-rata	3.712,94
Standar deviasi	516,30
Minimal	2.530,00
25%	3.300,00
50%	3.780,00
75%	4.080,00
Maksimal	4.770,00

Berdasarkan gambar tersebut, harga penutupan saham TLKM rata-rata berada pada kisaran Rp 3.712,94. Data menunjukkan variasi harga yang cukup signifikan, di mana harga terendah tercatat sebesar Rp 2.530,00 dan harga tertinggi mencapai Rp 4.770,00. Standar deviasi yang relatif kecil (Rp 516,30) menunjukkan bahwa sebagian besar data harga cenderung berdekatan dengan nilai rata-ratanya.

4.1.3 Normalisasi Data (Scaling)

Tahap normalisasi data merupakan langkah dalam pemrosesan awal data historis sebelum dimasukkan ke dalam model *Long Short-Term Memory* (LSTM). Normalisasi bertujuan untuk mengubah skala nilai fitur-fitur data ke dalam rentang tertentu tanpa mengubah distribusi atau bentuk dasar data tersebut. Dalam penelitian ini, normalisasi diterapkan pada variabel harga penutupan (*Close Price*) menggunakan rentang $[0, 1]$. Dengan demikian, seluruh nilai harga yang sebelumnya berada dalam rentang rupiah yang besar akan dipetakan ke dalam rentang $[0, 1]$. Adapun hasilnya akan disajikan pada Tabel 4.3.

Tabel 4.3 Hasil normalisasi

Data	Nilai
Pertama	0.428
Kedua	0.419
Ketiga	0.375
Keempat	0.383
Kelima	0.464

4.1.4 Pembagian Data Latih dan Data Uji

Setelah data historis saham dinormalisasi ke dalam rentang $[0, 1]$, langkah krusial berikutnya adalah membagi total data menjadi dua set terpisah yaitu data latih (*training set*) dan data uji (*testing set*). Pembagian ini dilakukan dengan

metode pembagian kronologis, memastikan bahwa data yang lebih awal digunakan untuk melatih model, dan data yang paling akhir digunakan untuk menguji kemampuan prediksi model. Untuk mengevaluasi bagaimana performa model dipengaruhi oleh kuantitas data pelatihan, penelitian ini menerapkan tiga skenario rasio pembagian data yang berbeda. Pendekatan ini bertujuan untuk mengidentifikasi rasio yang mengetahui keseimbangan terbaik antara data yang cukup untuk melatih bobot model dan data yang memadai untuk pengujian yang representatif. Total 969 entri data dibagi sesuai proporsi berikut tabel 4.4:

Tabel 4.4 Hasil Split Data

Skenario Uji	Proporsi Data Latih (Training)	Proporsi Data Uji (Testing)	Jumlah Entri Latih (dari 969)	Jumlah Entri Uji (dari 969)
Skenario 1	80%	20%	775	194
Skenario 2	70%	30%	678	291
Skenario 3	90%	10%	872	97

4.2 Uji Coba Skenario 1

Setelah tahap pembagian data dilakukan dengan memisahkan total 969 entri menjadi data latih dan data uji. Pembagian ini melibatkan dua aspek: penentuan rasio persentase dan konversi data menjadi sequence dengan *look_back*=60. Proporsi pembagian awal data dilakukan untuk menentukan besaran relatif dari data yang digunakan untuk pelatihan dan pengujian. Untuk skenario 1, data dibagi dengan rasio 80% untuk data latih dan 20% untuk data uji. Secara kasar, ini berarti 775 baris untuk pelatihan dan 194 baris untuk pengujian. Setelah data dibagi, dikonversi menjadi *sequence* 60 (*look_back*=60) untuk input model LSTM. Yang mana hasilnya akan ditampilkan pada Gambar 4.1 dibawah ini:

```

Rentang: 2021-01-04 → 2024-12-30 | n = 969
Distribusi tahun:
Date
2021    247
2022    246
2023    239
2024    237
Name: count, dtype: int64

=====

Total Data Mentah: 969 baris.
Rasio Awal (80:20):
Train/CV Data: 775 baris (hingga 2024-03-05)
Test Data    : 194 baris (mulai 2024-03-06)

=====

✅ Final Shapes (Setelah Pembuatan Sekuens LSTM):
Shapes: Train/CV: (715, 60, 1) (715,)
Shapes: Test: (134, 60, 1) (134,)

```

Gambar 4.1 Hasil split data skenario 1

4.2.1 Arsitektur dan Konfigurasi Model Skenario 1

Bagian ini menjelaskan bagaimana model *Long Short-Term Memory* (LSTM) dikonfigurasi parameter awal yang digunakan sebelum proses *tuning*. Model yang dikembangkan dalam penelitian ini mengadopsi struktur *Sequential* dengan satu lapisan LSTM tunggal (*Single-Layer LSTM*) yang terhubung langsung ke lapisan output (*Dense Layer*). Arsitektur ini dipilih karena kesederhanaan komputasi dan efektivitasnya dalam pemodelan deret waktu univariate. Adapun struktur model adalah sebagai berikut pada tabel 4.5:

Tabel 4.5 Arsitektur dasar skenario 1

Layer (type)	Output Shape	Param #
LSTM	50	10,400
Dropout	50	0
Dense	1	51

Arsitektur Dasarnya ialah model menggunakan kelas *Sequential* dari *TensorFlowKeras*. Kemudian terdapat satu lapisan LSTM dengan 50 units (neuron). Fungsi aktivasi yang digunakan untuk gerbang-gerbang internal adalah

ReLU (activation='relu'). Parameter `return_sequences` diatur ke False, yang berarti lapisan ini hanya mengembalikan output dari langkah waktu terakhir, sesuai untuk model prediksi satu langkah ke depan. Kemudian terdapat lapisan *Dropout* dengan nilai 0.2 (`dropout_rate=0.2`) disisipkan setelah lapisan LSTM.

4.2.2 Hasil Tuning Hyperparameter

Proses pencarian *hyperparameter* terbaik dilakukan menggunakan *Randomized Search Cross-Validation* (RSCV) yang diimplementasikan melalui `RandomizedSearchCV` dari pustaka `Scikit-learn`. Metode ini dipilih karena efisiensinya dalam mengeksplorasi ruang *hyperparameter* yang luas dibandingkan Grid Search, terutama pada model yang membutuhkan waktu pelatihan lama seperti LSTM. Untuk memastikan evaluasi yang adil dan valid pada data deret waktu (*time series*), proses *cross-validation* (CV) menggunakan teknik *Time Series Split* (TSCV). TSCV membagi data pelatihan menjadi 5 fold secara berurutan, memastikan bahwa data validasi selalu berada di masa depan relatif terhadap data pelatihan, sehingga mencegah data *leakage*.

Adapun ruang *hyperparameter* yang dieksplorasi meliputi unit LSTM (32, 64, 100, 128), *batch size* (32, 64), *dropout rate* (0.1, 0.2, 0.3), *learning rate* (0.01, 0.005, 0.001, 0.0005), *epoch* (100, 150, 200), dan *activation* ('relu', 'tanh'). Kemudian dilakukanlah tuning parameter menggunakan *Random Search* sesuai dengan ruang lingkup yang telah disediakan sebelumnya. Tabel 4.6 menampilkan lima kombinasi *hyperparameter* teratas dari total 10 iterasi yang diuji, diurutkan berdasarkan nilai *Avg_MSE* (Mean Squared Error) rata-rata terendah.

Tabel 4.6 Hasil ranking tuning parameter skenario 1

Rank	Avg_MSE	Std_MSE	Fit_Time (s)	Units	LR	Dropout	Batch	Epochs
1	0.001711	0.001893	186.09	128	0.01	0.2	32	200
2	0.002417	0.003021	108.18	100	0.01	0.3	32	100
3	0.003746	0.003891	106.42	32	0.01	0.2	64	150
4	0.004227	0.005092	175.71	100	0.005	0.2	32	150
5	0.004310	0.003068	102.26	100	0.001	0.1	64	100


Didapatkan bahwa best parameter atau parameter terbaik masuk kepada ('model__units': 128, 'model__learning_rate': 0.01, 'model__dropout_rate': 0.2, 'model__activation': 'tanh', 'epochs': 200, 'batch_size': 32). Selama proses tuning, setiap kombinasi juga diatur untuk menggunakan teknik early stopping (patience=15, monitor='val_loss') dan *Dropout* (0.2) sebagai langkah regulasi utama untuk mencegah *overfitting* secara dini.

Tabel 4.7 Hasil tuning parameter terbaik skenario 1

Parameter	Nilai
Model_unit	128
Model_LR	0.01
Model_dropout	0.2
Mode_activation	'tanh'
Epoch	200
Batch_size	32

Setelah menemukan *best parameter* atau parameter terbaik dari tahapan *tuning hyperparameter*, dilakukan pemantauan terhadap dua metrik evaluasi yaitu *training loss* dan *validation loss*. *Training loss* berfungsi mengukur tingkat kesalahan prediksi model terhadap data yang digunakan untuk pembaruan bobot, dengan target penurunan nilai secara berkelanjutan seiring bertambahnya iterasi. Sebaliknya, *validation loss* dihitung menggunakan data validasi, yang berfungsi

sebagai indikator independen untuk menilai kemampuan generalisasi model terhadap data yang tidak terlibat dalam proses pembelajaran. Pemantauan simultan terhadap kedua *loss* ini menjadi esensial untuk mendeteksi dini fenomena *overfitting*, sehingga menjamin model yang dihasilkan tidak hanya akurat pada data latih tetapi juga memadai saat diuji pada data yang belum pernah diproses sebelumnya.




Gambar 4.2 Hasil *Training* dan *loss validation* skenario 1

Setelah proses *training* selesai, maka tahapan yang berikutnya dijalankan adalah melakukan pengujian atau *testing* terhadap model. Pengujian yang dilakukan pada skenario ini dilakukan terhadap 194 data harga saham yang mana ini merupakan 20 persen dari rasio perbandingan yang ditentukan sebelumnya dan setelah melalui proses dikonversi menjadi *sequence* 60 (*look_back*=60) untuk input model LSTM maka akan berisi data mulai tanggal 2024-06-20 hingga 2024-12-30. Perbandingan hasil prediksi dan data aktual disajikan pada Tabel 4.8 dengan presentase error tiap prediksi.

Tabel 4.8 Hasil prediksi skenario 1

Data ke-	Aktual	Prediksi	Error_Rupiah	Percentage_Error (%)
0	2840.0	2769.35	70.64	2.48
1	2950.0	2809.92	140.07	4.74
...	...	...	...	...
67	3160.0	3172.57	12.57	0.39
68	3190.0	3168.79	21.20	0.66
...	...	...	...	...
132	2750.0	2725.84	24.15	0.87
133	2710.0	2787.92	77.92	2.87

Pada Gambar 4.3 ditampilkan grafik perbandingan antara data aktual dan hasil prediksi yang didapatkan dari pengujian oleh model A dengan skenario pembagian rasio data 80:20, untuk data aktual atau *ground truth* digambarkan dengan garis berwarna biru sementara hasil prediksi digambarkan dengan garis berwarna oranye.



Gambar 4.3 Visualisasi hasil prediksi skenario 1

Visualisasi merupakan langkah penting untuk memahami kualitas prediksi model secara intuitif. Bagian ini menyajikan perbandingan antara kurva harga

aktual dan kurva harga prediksi model LSTM terbaik pada data uji. Data uji adalah data yang sepenuhnya independen dan belum pernah digunakan selama proses pelatihan maupun tuning, sehingga visualisasi ini merepresentasikan kemampuan generalisasi model dalam skenario dunia nyata.

Analisis dari Gambar 4.3 memberikan beberapa kesimpulan kunci mengenai kinerja model. Terlihat kurva harga prediksi (Garis Oranye) tampak sangat erat mengikuti pergerakan kurva harga aktual (Garis Biru) di sepanjang periode data uji. Hal ini menunjukkan bahwa model LSTM yang telah di-tuning mampu menangkap pola dan tren jangka panjang pada data deret waktu harga saham secara efektif.


Kemudian kinerja model terbaik diukur menggunakan tiga metrik evaluasi utama: *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Metrik R^2 juga digunakan untuk mengukur proporsi variasi variabel dependen yang dapat dijelaskan oleh model. Berdasarkan hasil dari prediksi yang telah dilakukan oleh model A yang akan ditampilkan pada tabel 4.9, didapatkan nilai error metrik RMSE sebesar 61.69 dan MAPE sebesar 1.63%, dan R^2 sebesar 0.8697.

Tabel 4.9 Hasil evaluasi metrik skenario 1

Evaluasi	Nilai
RMSE	61.69
MAE	47.21
MAPE	1.63%
R^2	0.8697

Hasil analisis ini secara eksplisit menunjukkan bahwa model LSTM yang telah melalui proses *tuning* parameter memiliki tingkat akurasi yang sangat baik dengan nilai MAPE yang sangat rendah, yaitu hanya sebesar 1,63%. Perolehan nilai koefisien determinasi atau R^2 sebesar 0,8697 mengindikasikan bahwa sekitar 86,97% dari total variasi pergerakan harga saham pada set data uji dapat dijelaskan dan diprediksi secara akurat oleh model.

Untuk mendapatkan pemahaman yang lebih mendalam mengenai kualitas prediksi, dilakukan analisis terhadap *Distribusi Error Absolut* (selisih nilai aktual dan prediksi). Analisis ini penting untuk melihat seberapa sering dan seberapa besar kesalahan prediksi terjadi pada data independen. Distribusi Error Absolut ditampilkan dalam bentuk histogram pada Gambar 4.4. Mayoritas error absolut terkonsentrasi pada rentang nilai yang sangat rendah, membuktikan bahwa sebagian besar prediksi model berada sangat dekat dengan harga aktual.



Gambar 4.4 Visualisasi distribusi error absolut skenario 1

4.3 Uji Coba Skenario 2

Setelah tahap pembagian data dilakukan dengan memisahkan total 969 entri menjadi data latih dan data uji. Pembagian ini melibatkan dua aspek: penentuan rasio persentase dan konversi data menjadi sequence dengan *look_back*=60. Proporsi pembagian awal data dilakukan untuk menentukan besaran relatif dari data

yang digunakan untuk pelatihan dan pengujian. Untuk Skenario 1, data dibagi dengan rasio 90% untuk data latih dan 10% untuk data uji. Secara kasar, ini berarti 872 baris untuk pelatihan dan 97 baris untuk pengujian. Setelah data dibagi, ia dikonversi menjadi *sequence* 60 (*look_back*=60) untuk input model LSTM. Yang mana hasilnya akan ditampilkan pada Gambar 4.5:

```

Rentang: 2021-01-04 → 2024-12-30 | n = 969
Distribusi tahun:
  Date
2021    247
2022    246
2023    239
2024    237
Name: count, dtype: int64

=====

Total Data Mentah: 969 baris.
Rasio Awal (80:20):
Train/CV Data: 775 baris (hingga 2024-03-05)
Test Data      : 194 baris (mulai 2024-03-06)

=====

✅ Final Shapes (Setelah Pembuatan Sekuens LSTM):
Shapes: Train/CV: (715, 60, 1) (715,)
Shapes: Test: (134, 60, 1) (134,)

```

Gambar 4.5 Hasil split data skenario 2

4.3.1 Arsitektur dan Konfigurasi Model Skenario 2

Bagian ini menjelaskan bagaimana model *Long Short-Term Memory* (LSTM) dikonfigurasi parameter awal yang digunakan sebelum proses *tuning*. Model yang dikembangkan dalam penelitian ini mengadopsi struktur *Sequential* dengan satu lapisan LSTM tunggal (*Single-Layer LSTM*) yang terhubung langsung ke lapisan output (*Dense Layer*). Arsitektur ini dipilih karena kesederhanaan komputasi (*computational efficiency*) dan efektivitasnya dalam pemodelan deret waktu univariate. Adapun struktur model akan ditampilkan pada table 4.10:

Tabel 4.10 Arsitektur dasar skenario 2

Layer (type)	Output Shape	Param #
LSTM	50	10,400
Dropout	50	0
Dense	1	51

Arsitektur dasarnya ialah model menggunakan kelas `Sequential` dari `TensorFlowKeras`. Kemudian terdapat satu lapisan LSTM dengan 50 units (neuron). Fungsi aktivasi yang digunakan untuk gerbang-gerbang internal adalah `ReLU` (`activation='relu'`). Parameter `return_sequences` diatur ke `False`, yang berarti lapisan ini hanya mengembalikan output dari langkah waktu terakhir, sesuai untuk model prediksi satu langkah ke depan. Kemudian terdapat lapisan *Dropout* dengan laju 0.2 (`dropout_rate=0.2`) disisipkan setelah lapisan LSTM.

4.3.2 Hasil Tuning Hyperparameter

Proses pencarian *hyperparameter* terbaik dilakukan menggunakan *Randomized Search Cross-Validation* (RSCV) yang diimplementasikan melalui `RandomizedSearchCV` dari pustaka `Scikit-learn`. Metode ini dipilih karena efisiensinya dalam mengeksplorasi ruang *hyperparameter* yang luas dibandingkan `Grid Search`, terutama pada model yang membutuhkan waktu pelatihan lama seperti LSTM. Untuk memastikan evaluasi yang adil dan valid pada data deret waktu (*time series*), proses cross-validation (CV) menggunakan teknik *Time Series Split* (TSCV). TSCV membagi data pelatihan menjadi 5 fold secara berurutan, memastikan bahwa data validasi selalu berada di masa depan relatif terhadap data pelatihan, sehingga mencegah data *leakage*.

Adapun ruang *hyperparameter* yang dieksplorasi meliputi unit LSTM (32, 64, 100, 128), *batch size* (32, 64), *dropout rate* (0.1, 0.2, 0.3), *learning rate* (0.01, 0.005, 0.001, 0.0005), *epoch* (100, 150, 200), dan *activation* ('relu', 'tanh'). Kemudian dilakukanlah tuning parameter menggunakan random search sesuai dengan ruang lingkup yang telah disediakan sebelumnya. Tabel 4.11 menampilkan lima kombinasi *hyperparameter* teratas dari total 10 iterasi yang diuji, diurutkan berdasarkan nilai *Avg_MSE* (Mean Squared Error) rata-rata terendah.

Tabel 4.11 Hasil ranking tuning parameter


Rank	Avg MSE	Std MSE	Fit Time (s)	Units	LR	Dropout	Batch	Epochs
1	0.001166	0.000657	89.49	64	0.0100	0.2	64	150
2	0.001704	0.001016	167.28	128	0.0010	0.2	64	150
3	0.002163	0.000912	89.54	64	0.0100	0.1	64	100
4	0.002373	0.000693	122.35	128	0.0005	0.3	64	100
5	0.002476	0.001481	106.45	64	0.0010	0.3	64	150

Didapatkan bahwa best parameter atau parameter terbaik masuk kepada ('model__units': 64, 'model__learning_rate': 0.0100, 'model__dropout_rate': 0.2, 'model__activation': 'tanh', 'epochs': 150, 'batch_size': 65). Selama proses tuning, setiap kombinasi juga diatur untuk menggunakan teknik *early stopping* (patience=15, monitor='val_loss') dan *Dropout* (0.2) sebagai langkah regulasi utama untuk mencegah *overfitting* secara dini.

Tabel 4.12 Hasil tuning parameter terbaik

Parameter	Nilai
Model_unit	64
Model_LR	0.0100
Model_dropout	0.2
Mode_activation	'tanh'
Epoch	150
Batch_size	64

Setelah menemukan *best parameter* atau parameter terbaik dari tahapan *tuning hyperparameter*, dilakukan pemantauan terhadap dua metrik evaluasi yaitu *training loss* dan *validation loss*. *Training loss* berfungsi mengukur tingkat kesalahan prediksi model terhadap data yang digunakan untuk pembaruan bobot, dengan target penurunan nilai secara berkelanjutan seiring bertambahnya iterasi. Sebaliknya, *validation loss* dihitung menggunakan data validasi, yang berfungsi sebagai indikator independen untuk menilai kemampuan generalisasi model terhadap data yang tidak terlibat dalam proses pembelajaran. Pemantauan simultan terhadap kedua *loss* ini menjadi esensial untuk mendeteksi dini fenomena *overfitting*, sehingga menjamin model yang dihasilkan tidak hanya akurat pada data latih tetapi juga memadai saat diuji pada data yang belum pernah diproses sebelumnya.



Gambar 4.6 Hasil *Training* dan *loss validation* skenario 2


Setelah proses training selesai, maka tahapan yang berikutnya dijalankan adalah melakukan pengujian atau testing terhadap model. Pengujian yang dilakukan

pada skenario ini dilakukan terhadap 97 data harga saham yang mana ini merupakan 10 persen dari rasio perbandingan yang ditentukan sebelumnya dan setelah melalui proses dikonversi menjadi *sequence* 60 (*look_back*=60) untuk input model LSTM maka akan berisi data mulai tanggal 2024-11-05 hingga 2024-12-30. Perbandingan hasil prediksi dan data aktual disajikan pada Tabel 4.13 dengan presentase error tiap prediksi.

Tabel 4.13 Hasil prediksi skenario 2

Data ke-	Aktual	Prediksi	Error_Rupiah	Percentage_Error (%)
0	2770.0	2777.91	7.91	0.28
1	2740.0	2759.91	19.91	0.72
...	...	...	...	...
18	2680.0	2696.83	16.83	0.62
19	2820.0	2678.49	141.50	5.01
...	...	...	...	...
35	2750.0	2685.97	64.02	2.32
36	2710.0	2742.86	32.86	1.21

Pada Gambar 4.7 ditampilkan grafik perbandingan antara data aktual dan hasil prediksi yang didapatkan dari pengujian oleh model A dengan skenario pembagian rasio data 90:10, untuk data aktual atau *ground truth* digambarkan dengan garis berwarna biru sementara hasil prediksi digambarkan dengan garis berwarna oranye.



Gambar 4.7 Visualisasi hasil prediksi skenario 2

Visualisasi merupakan langkah penting untuk memahami kualitas prediksi model secara intuitif. Bagian ini menyajikan perbandingan antara kurva harga aktual dan kurva harga prediksi model LSTM terbaik pada data uji. Data uji adalah data yang sepenuhnya independen dan belum pernah digunakan selama proses pelatihan maupun tuning, sehingga visualisasi ini merepresentasikan kemampuan generalisasi model dalam skenario dunia nyata.

Analisis dari Gambar 4.7 memberikan beberapa kesimpulan kunci mengenai kinerja model. Terlihat kurva harga prediksi (Garis Oranye) tampak sangat erat mengikuti pergerakan kurva harga aktual (Garis Biru) di sepanjang periode data uji. Hal ini menunjukkan bahwa model LSTM yang telah di-tuning mampu menangkap pola dan tren jangka panjang pada data deret waktu harga saham secara efektif.

Kemudian kinerja model terbaik diukur menggunakan tiga metrik evaluasi utama: *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Metrik R^2 juga digunakan untuk


mengukur proporsi variasi variabel dependen yang dapat dijelaskan oleh model. Berdasarkan hasil dari prediksi yang telah dilakukan oleh model ini, didapatkan nilai error metrik RMSE sebesar 76.62 dan MAPE sebesar 2.06%, dan R^2 sebesar 0.2762.

Tabel 4.14 Hasil evaluasi metrik skenario 2

Evaluasi	Nilai
RMSE	76.62
MAE	55.80
MAPE	2.06%
R^2	0.2762

Hasil analisis ini menunjukkan bahwa model LSTM yang telah melalui tahap *tuning* memiliki tingkat akurasi yang cukup kompetitif dengan perolehan nilai MAPE sebesar 2,06%. Namun, nilai koefisien determinasi atau R^2 yang hanya sebesar 0,2762 mengindikasikan bahwa baru sekitar 27,62% dari total variasi pergerakan harga saham pada data uji yang dapat dijelaskan oleh model.

Untuk mendapatkan pemahaman yang lebih mendalam mengenai kualitas prediksi, dilakukan analisis terhadap *Distribusi Error Absolut* (selisih nilai aktual dan prediksi). Analisis ini penting untuk melihat seberapa sering dan seberapa besar kesalahan prediksi terjadi pada data independen. Distribusi Error Absolut ditampilkan dalam bentuk histogram pada Gambar 4.8. Mayoritas error absolut terkonsentrasi pada rentang nilai yang sangat rendah, membuktikan bahwa sebagian besar prediksi model berada sangat dekat dengan harga aktual.



Gambar 4.8 Visualisasi distribusi error absolut skenario 2

4.4 Uji Coba Skenario 3

Setelah tahap pembagian data dilakukan dengan memisahkan total 969 entri menjadi data latih dan data uji. Pembagian ini melibatkan dua aspek: penentuan rasio persentase dan konversi data menjadi sequence dengan *look_back*=60. Proporsi pembagian awal data dilakukan untuk menentukan besaran relatif dari data yang digunakan untuk pelatihan dan pengujian. Untuk Skenario 1, data dibagi dengan rasio 70% untuk data latih dan 30% untuk data uji. Secara kasar, ini berarti 678 baris untuk pelatihan dan 291 baris untuk pengujian. Setelah data dibagi, ia dikonversi menjadi *sequence* 60 (*look_back*=60) untuk input model LSTM. Yang mana hasilnya akan ditampilkan pada Gambar dibawah ini:

```

Rentang: 2021-01-04 → 2024-12-30 | n = 969
Distribusi tahun:
  Date
2021    247
2022    246
2023    239
2024    237
Name: count, dtype: int64

=====

Total Data Mentah: 969 baris.
Rasio Awal (80:20):
Train/CV Data: 775 baris (hingga 2024-03-05)
Test Data    : 194 baris (mulai 2024-03-06)

=====

✅ Final Shapes (Setelah Pembuatan Sekuens LSTM):
Shapes: Train/CV: (715, 60, 1) (715,)
Shapes: Test: (134, 60, 1) (134,)

```

Gambar 4.9 Hasil split data skenario 3

4.4.1 Arsitektur dan Konfigurasi Model Skenario 3

Bagian ini menjelaskan bagaimana model *Long Short-Term Memory* (LSTM) dikonfigurasi parameter awal yang digunakan sebelum proses *tuning*. Model yang dikembangkan dalam penelitian ini mengadopsi struktur *Sequential* dengan satu lapisan LSTM tunggal (*Single-Layer LSTM*) yang terhubung langsung ke lapisan output (*Dense Layer*). Arsitektur ini dipilih karena kesederhanaan komputasi (*computational efficiency*) dan efektivitasnya dalam pemodelan deret waktu univariate. Adapun struktur model adalah sebagai berikut:

Tabel 4.15 Arsitektur dasar skenario 3

Layer (type)	Output Shape	Param #
LSTM	50	10,400
Dropout	50	0
Dense	1	51

Arsitektur dasarnya ialah model menggunakan kelas *Sequential* dari *TensorFlowKeras*. Kemudian terdapat satu lapisan LSTM dengan 50 units (neuron). Fungsi aktivasi yang digunakan untuk gerbang-gerbang internal adalah ReLU (*activation='relu'*). Parameter *return_sequences* diatur ke *False*, yang berarti lapisan ini hanya mengembalikan output dari langkah waktu terakhir, sesuai untuk model prediksi satu langkah ke depan (*one-step-ahead prediction*). Kemudian terdapat lapisan *Dropout* dengan laju 0.2 (*dropout_rate=0.2*) disisipkan setelah lapisan LSTM.

4.4.2 Hasil Tuning Hyperparameter

Proses pencarian *hyperparameter* terbaik dilakukan menggunakan *Randomized Search Cross-Validation* (RSCV) yang diimplementasikan melalui *RandomizedSearchCV* dari pustaka *Scikit-learn*. Metode ini dipilih karena efisiensinya dalam mengeksplorasi ruang *hyperparameter* yang luas dibandingkan *Grid Search*, terutama pada model yang membutuhkan waktu pelatihan lama seperti *LSTM*. Untuk memastikan evaluasi yang adil dan valid pada data deret waktu (*time series*), proses *cross-validation* (CV) menggunakan teknik *Time Series Split* (TSCV). TSCV membagi data pelatihan menjadi 5 fold secara berurutan, memastikan bahwa data validasi selalu berada di masa depan relatif terhadap data pelatihan, sehingga mencegah data *leakage*.

Adapun ruang *hyperparameter* yang dieksplorasi meliputi unit *LSTM* (32, 64, 100, 128), *batch size* (32, 64), *dropout rate* (0.1, 0.2, 0.3), *learning rate* (0.01, 0.005, 0.001, 0.0005), *epoch* (100, 150, 200), dan *activation* ('relu', 'tanh'). Kemudian dilakukanlah tuning parameter menggunakan random search sesuai dengan ruang lingkup yang telah disediakan sebelumnya. Tabel 4.16 menampilkan lima kombinasi *hyperparameter* teratas dari total 10 iterasi yang diuji, diurutkan berdasarkan nilai *Avg_MSE* (Mean Squared Error) rata-rata terendah.

Tabel 4.16 Hasil ranking tuning parameter

Rank	Avg MSE	Std MSE	Fit Time (s)	Units	LR	Dropout	Batch	Epochs
1	0.002766	0.002988	89.23	100	0.010	0.3	32	100
2	0.003763	0.003794	59.51	100	0.001	0.1	64	100
3	0.004171	0.005317	114.21	100	0.005	0.2	32	150
4	0.004203	0.005370	155.16	100	0.001	0.3	32	200
5	0.004453	0.006983	158.05	128	0.010	0.2	32	200


Didapatkan bahwa best parameter atau parameter terbaik masuk kepada ('model__units': 100, 'model__learning_rate': 0.01, 'model__dropout_rate': 0.3, 'model__activation': 'tanh', 'epochs': 100, 'batch_size': 32). Selama proses tuning, setiap kombinasi juga diatur untuk menggunakan teknik *early stopping* (patience=15, monitor='val_loss') dan *Dropout* (0.3) sebagai langkah regulasi utama untuk mencegah *overfitting* secara dini.

Tabel 4.17 Hasil tuning parameter terbaik

Parameter	Nilai
Model_unit	100
Model_LR	0.01
Model_dropout	0.3
Mode_activation	'tanh'
Epoch	100
Batch_size	32

Setelah menemukan *best parameter* atau parameter terbaik dari tahapan *tuning hyperparameter*, dilakukan pemantauan terhadap dua metrik evaluasi yaitu *training loss* dan *validation loss*. *Training loss* berfungsi mengukur tingkat kesalahan prediksi model terhadap data yang digunakan untuk pembaruan bobot, dengan target penurunan nilai secara berkelanjutan seiring bertambahnya iterasi. Sebaliknya, *validation loss* dihitung menggunakan data validasi, yang berfungsi sebagai indikator independen untuk menilai kemampuan generalisasi model terhadap data yang tidak terlibat dalam proses pembelajaran. Pemantauan simultan terhadap kedua *loss* ini menjadi esensial untuk mendeteksi dini fenomena *overfitting*, sehingga menjamin model yang dihasilkan tidak hanya akurat pada data

latih tetapi juga memadai saat diuji pada data yang belum pernah diproses sebelumnya.



Gambar 4.10 Hasil *Training* dan *loss validation* skenario 3


Setelah proses pelatihan atau *training* selesai dilakukan secara menyeluruh, tahapan krusial berikutnya yang harus dijalankan adalah melakukan pengujian atau *testing* untuk memvalidasi performa model yang telah dibangun. Pengujian pada skenario spesifik ini dilakukan terhadap 231 baris data harga saham, yang merupakan representasi dari 30 persen rasio pembagian data uji yang telah ditentukan pada tahap awal penelitian. Setelah seluruh data tersebut melewati proses pra-pemrosesan dan dikonversi menjadi *sequence* dengan parameter *look_back* sebesar 60 sebagai input utama bagi model LSTM, maka set data uji ini secara kronologis mencakup rentang waktu mulai dari tanggal 10 Januari 2024 hingga berakhir pada 30 Desember 2024. Untuk memberikan gambaran mengenai akurasi model, perbandingan detail antara hasil prediksi dengan data aktual serta

persentase nilai galat atau *error* pada setiap titik prediksi disajikan secara sistematis pada Tabel 4.18.

Tabel 4.18 Hasil prediksi skenario 3

Data ke-	Aktual	Prediksi	Error_Rupiah	Percentage_Error (%)
0	4000.0	3890.53	109.46	2.73
1	3990.0	3930.71	59.28	1.48
...	...	...	...	...
115	3100.0	3169.36	69.36	2.23
116	3250.0	3110.90	139.09	4.27
...	...	...	...	...
229	2750.0	2695.80	54.19	1.97
230	2710.0	2767.08	57.08	2.10

Pada Gambar 4.11 ditampilkan grafik perbandingan antara data aktual dan hasil prediksi yang didapatkan dari pengujian oleh model A dengan skenario pembagian rasio data 70:30, untuk data aktual atau *ground truth* digambarkan dengan garis berwarna biru sementara hasil prediksi digambarkan dengan garis berwarna oranye.



Gambar 4.11 Visualisasi hasil prediksi skenario 3

Visualisasi merupakan langkah penting untuk memahami kualitas prediksi model secara intuitif. Bagian ini menyajikan perbandingan antara kurva harga aktual dan kurva harga prediksi model LSTM terbaik pada data uji. Data uji adalah data yang sepenuhnya independen dan belum pernah digunakan selama proses pelatihan maupun tuning, sehingga visualisasi ini merepresentasikan kemampuan generalisasi model dalam skenario dunia nyata.

Analisis dari Gambar 4.11 memberikan beberapa kesimpulan kunci mengenai kinerja model. Terlihat kurva harga prediksi (Garis Oranye) tampak sangat erat mengikuti pergerakan kurva harga aktual (Garis Biru) di sepanjang periode data uji. Hal ini menunjukkan bahwa model LSTM yang telah di-tuning mampu menangkap pola dan tren jangka panjang pada data deret waktu harga saham secara efektif.


Kemudian kinerja model terbaik diukur menggunakan tiga metrik evaluasi utama: *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Metrik R^2 juga digunakan untuk mengukur proporsi variasi variabel dependen yang dapat dijelaskan oleh model. Berdasarkan hasil dari prediksi yang telah dilakukan oleh model A, didapatkan nilai error metrik RMSE sebesar 67.15 dan MAPE sebesar 1.72%, dan R^2 sebesar 0.9781.

Tabel 4.19 Hasil evaluasi metrik skenario 3

Evaluasi	Nilai
RMSE	67.15
MAE	53.95
MAPE	1.72%
R^2	0.9781

Hasil analisis ini menunjukkan bahwa model LSTM yang telah melalui proses *tuning* parameter memiliki tingkat akurasi yang sangat mengesankan dengan nilai MAPE yang rendah, yaitu hanya sebesar 1,72%. Perolehan nilai koefisien determinasi atau R^2 sebesar 0,9781 mengindikasikan bahwa sekitar 97,81% dari total variasi pergerakan harga saham pada set data uji dapat dijelaskan dan diprediksi secara presisi oleh model.

Untuk mendapatkan pemahaman yang lebih mendalam mengenai kualitas prediksi, dilakukan analisis terhadap Distribusi Error Absolut (selisih nilai aktual dan prediksi). Analisis ini penting untuk melihat seberapa sering dan seberapa besar kesalahan prediksi terjadi pada data independen. Distribusi Error Absolut ditampilkan dalam bentuk histogram pada Gambar 4.12. Mayoritas error absolut terkonsentrasi pada rentang nilai yang sangat rendah, membuktikan bahwa sebagian besar prediksi model berada sangat dekat dengan harga aktual.



Gambar 4.12 Visualisasi distribusi error absolut skenario 3

4.5 Analisis Kinerja Model Berdasarkan Variasi Time Step

Bagian ini menyajikan hasil dari pengujian model Long Short-Term Memory (LSTM) untuk memprediksi harga saham TLKM dengan memvariasikan dua *hyperparameter* yakni *time step* dan Rasio Pembagian Data Pelatihan Pengujian. Pengujian ini bertujuan untuk mengetahui konfigurasi model yang paling optimal, yang diukur berdasarkan nilai metrik evaluasi terkecil pada data

testing. Variasi *time step* yang digunakan merepresentasikan jumlah hari historis yang digunakan untuk memprediksi satu harga hari berikutnya, yaitu 15, 30, 45, 60 hari. Sementara itu, rasio pembagian data yang diuji adalah 80:20, 70:30, 90:10. Total terdapat 12 skenario pengujian yang hasilnya dirangkum pada Tabel dibawah ini:


Tabel 4.20 Hasil evaluasi metrik dengan tambahan time step

No	Rasio	Timestep	RMSE	MAE	MAPE	R ²
1	80 : 20	15	76.39	60.85	2.11%	0.8302
2	80 : 20	30	75.49	60.86	2.11%	0.7883
3	80 : 20	45	72.68	55.57	1.92%	0.8065
4	80 : 20	60	61.69	47.21	1.63%	0.8697
5	90 : 10	15	63.94	49.48	1.75%	0.8733
6	90 : 10	30	63.55	48.83	1.74%	0.8453
7	90 : 10	45	65.77	51.94	1.88%	0.7790
8	90 : 10	60	76.62	55.80	2.06%	0.2762
9	70 : 30	15	68.20	51.50	1.68%	0.9795
10	70 : 30	30	97.87	79.23	2.62%	0.9592
11	70 : 30	45	73.01	55.22	1.82%	0.9765
12	70 : 30	60	67.15	53.95	1.72%	0.9781

Berdasarkan hasil yang disajikan pada Tabel Diatas, model dengan kinerja terbaik diidentifikasi melalui nilai RMSE terkecil. Model Optimal dicapai pada pilihan No. 4, dengan konfigurasi *time step* 60 hari dan Rasio Pembagian Data 80:20. Konfigurasi ini menghasilkan nilai RMSE terendah sebesar 61.69, MAE 47.21, dan MAPE 1.63%. Nilai koefisien determinasi R² juga menunjukkan nilai yang relatif tinggi, yaitu 0.8697. Meskipun No. 9 hingga 12 memiliki nilai R² yang sangat tinggi (sekitar 0.97), mereka juga memiliki RMSE yang lebih besar, menunjukkan bahwa model ini mungkin kurang robust dan lebih overfit pada data pelatihan yang lebih sedikit.


Analisis kinerja model *Long Short-Term Memory* (LSTM) berdasarkan variasi *time step* untuk mengidentifikasi konfigurasi *time step* yang memberikan

kapabilitas prediksi optimal terhadap data harga saham. Gambar 4.13 hingga Gambar 4.24 menyajikan visualisasi perbandingan antara harga aktual saham dengan harga prediksi yang dihasilkan oleh model untuk setiap skenario *time step* yang diujikan *time step* 15, 30, 45, dan 60.




Gambar 4.13 Prediksi 30 hari kedepan rasio 80:20 time step 15

Gambar 4.13 menyajikan visualisasi perbandingan harga aktual dan harga prediksi yang dihasilkan oleh model LSTM dengan konfigurasi Time Step 15 dengan rasio 80:20. Secara kualitatif, hasil prediksi pada skenario ini menunjukkan visual kesesuaian yang cukup baik, terlihat bahwa garis prediksi tidak sehalus hasil prediksi paling optimal. Performa visual ini dapat dibuktikan oleh metrik evaluasi yang menunjukkan nilai RMSE sebesar 76,39, MAPE sebesar 2,11%, dan R^2 sebesar 0,8302. Dengan mempertimbangkan perbandingan metrik, penggunaan 15 hari data historis sebagai *sequence input* tidak seoptimal Time Step 60 dengan rasio 80:20 dibuktikan dengan perbedaan nilai metrik evaluasi yang ada.




Gambar 4.14 Prediksi 30 hari kedepan rasio 80:20 time step 30

Gambar 4.14 menyajikan visualisasi perbandingan antara harga aktual dan harga prediksi yang dihasilkan oleh model LSTM dengan konfigurasi *time step* 30 serta penggunaan rasio data 80:20. Secara kualitatif, hasil prediksi menunjukkan tingkat kesesuaian, namun tercatat sedikit lebih rendah kualitasnya jika dibandingkan dengan konfigurasi *time step* 60 pada rasio yang sama. Sepanjang periode pengujian, garis prediksi terlihat masih mampu mengikuti tren pergerakan pasar secara umum, meskipun terdapat deviasi atau selisih yang lebih lebar pada titik-titik balik harga yang signifikan. Degradasi performa visual ini dikuatkan oleh hasil metrik evaluasi yang menunjukkan nilai RMSE sebesar 75,49, MAPE sebesar 2,11%, serta R^2 sebesar 0,7883. Dengan membandingkan hasil ini terhadap skenario terbaik, terlihat bahwa penggunaan 30 hari data historis sebagai *sequence input* memang menghasilkan akurasi yang memuaskan, namun belum mencapai batas kapabilitas optimal model dalam memitigasi kesalahan pada fluktuasi harga yang tajam.




Gambar 4.15 Prediksi 30 hari kedepan rasio 80:20 time step 45

Gambar 4.15 menyajikan visualisasi perbandingan antara harga aktual dan harga prediksi yang dihasilkan oleh model LSTM melalui konfigurasi *time step* 45 dengan pembagian rasio data 80:20. Secara kualitatif, hasil proyeksi pada skenario ini menunjukkan tingkat kesesuaian yang relatif buruk karena garis prediksi tampak kurang responsif terhadap perubahan harga mendadak, sehingga cenderung mengarah pada kondisi *underfitting*. Degradasi performa visual tersebut dikuatkan oleh hasil metrik evaluasi yang mencatat nilai RMSE sebesar 72,68, MAPE sebesar 1,92%, serta koefisien determinasi R^2 sebesar 0,8065. Meskipun angka-angka metrik ini menunjukkan tingkat akurasi yang secara umum masih dianggap memuaskan untuk prediksi deret waktu, namun efektivitasnya terbukti belum mampu menyamai atau mencapai batas kapabilitas optimal model jika dibandingkan dengan performa superior pada model *time step* 60 dengan rasio 80:20. Hal ini mengindikasikan bahwa pemilihan panjang sekuens input sebesar 45 hari belum cukup kuat dalam menangkap kompleksitas pola historis guna menghasilkan estimasi yang presisi pada titik fluktuasi harga.




Gambar 4.16 Prediksi 30 hari kedepan rasio 80:20 time step 60

Gambar 4.16 menyajikan visualisasi perbandingan yang komprehensif antara harga aktual dan harga prediksi yang dihasilkan oleh model LSTM dengan konfigurasi *time step* 60. Secara kualitatif, hasil prediksi pada skenario ini menunjukkan tingkat kesesuaian yang paling optimal (*Best Fit*) di antara keempat konfigurasi yang diuji, di mana garis prediksi mampu merepresentasikan pergerakan harga pasar dengan sangat presisi. Performa visual yang superior ini dikuatkan secara empiris melalui metrik evaluasi yang menunjukkan nilai RMSE sebesar 61,69, MAPE sebesar 1,63%, serta koefisien determinasi R^2 sebesar 0,8697, yang secara keseluruhan merupakan perolehan nilai terbaik dalam pengujian ini. Berdasarkan akumulasi bukti visual dan data kuantitatif tersebut, penggunaan 60 hari data historis sebagai *sequence input* terbukti menjadi parameter yang paling ideal untuk memprediksi harga saham TLKM. Konfigurasi ini berhasil menciptakan model yang tidak hanya akurat dalam menangkap fluktuasi harga, tetapi juga sangat stabil dalam meminimalkan galat prediksi dibandingkan skenario pengujian lainnya.




Gambar 4.17 Prediksi 30 hari kedepan rasio 90:10 time step 15

Gambar 4.17 menyajikan visualisasi perbandingan antara harga aktual dan harga prediksi model LSTM pada konfigurasi *time step* 15 dengan rasio pembagian data sebesar 90:10. Secara kualitatif, hasil prediksi pada skenario pengujian ini menunjukkan tingkat kesesuaian yang sangat baik, di mana arsitektur model berhasil menangkap pola temporal dari data jangka pendek secara efektif dan responsif terhadap fluktuasi harga. Konsistensi visual yang dihasilkan tersebut dikuantifikasi lebih lanjut melalui metrik evaluasi yang menunjukkan nilai RMSE sebesar 63,94, MAPE sebesar 1,75%, serta koefisien determinasi R^2 mencapai 0,8733. Dengan mempertimbangkan akumulasi bukti visual dan data kuantitatif tersebut, dapat disimpulkan bahwa penggunaan 15 hari data historis sebagai *sequence input* memang terbukti optimal untuk diterapkan pada skenario rasio 90:10. Namun demikian, performa ini secara komparatif masih sedikit berada di bawah capaian model dengan *time step* 60 pada rasio 80:20, sebagaimana dibuktikan oleh perbedaan margin pada nilai-nilai metrik evaluasi yang dihasilkan selama proses eksperimen.




Gambar 4.18 Prediksi 30 hari kedepan rasio 90:10 time step 30

Gambar 4.18 menyajikan visualisasi perbandingan antara harga aktual dan harga prediksi yang dihasilkan oleh model LSTM pada konfigurasi *time step* 30 dengan rasio pembagian data 90:10. Secara kualitatif, hasil prediksi pada skenario ini menunjukkan tingkat kesesuaian yang cenderung stabil, di mana pada sepanjang periode pengujian terlihat jelas bahwa garis prediksi mampu mengikuti tren pergerakan harga umum dengan cukup konsisten. Namun, meskipun mampu mempertahankan arah tren, model ini terlihat kurang responsif dan mengalami keterlambatan saat menghadapi fluktuasi harga yang bersifat tajam atau volatil. Performa visual tersebut dikuatkan oleh hasil metrik evaluasi yang menunjukkan nilai RMSE sebesar 63,55, MAPE sebesar 1,74%, serta koefisien determinasi R^2 sebesar 0,8453. Berdasarkan analisis tersebut, penggunaan 30 hari data historis sebagai *sequence input* memang masih memberikan kinerja yang solid dan andal, namun efektivitasnya secara komparatif masih berada di bawah akurasi *time step* 15 dengan rasio 90:10 yang lebih unggul dalam menangkap dinamika perubahan harga pada pembagian data ini.



Gambar 4.19 Prediksi 30 hari kedepan rasio 90:10 time step 45

Gambar 4.19 menyajikan visualisasi perbandingan antara harga aktual dan harga prediksi model LSTM pada konfigurasi *time step* 45 dengan rasio pembagian data 90:10. Secara kualitatif, hasil prediksi pada skenario ini menunjukkan ketidaksesuaian yang cukup signifikan dan terdapat kecenderungan fenomena *over-smoothing* yang sangat jelas terlihat. Sepanjang periode pengujian, garis prediksi cenderung tampak datar dan kurang mampu menyesuaikan diri dengan dinamika perubahan harga harian yang terjadi di pasar. Degradasi performa visual ini dikuatkan oleh hasil metrik evaluasi yang menunjukkan nilai RMSE sebesar 65,77, MAPE sebesar 1,88%, serta koefisien determinasi R^2 yang hanya mencapai 0,7790. Meskipun demikian, penggunaan 45 hari data historis sebagai *sequence input* sebenarnya masih memberikan kinerja yang cukup solid secara statistik, namun efektivitas dan tingkat akurasi terbukti tidak sebanding dengan *time step* 15 pada rasio 90:10. Ketidakmampuan model dalam menangkap volatilitas pada *time step* yang lebih panjang ini mengindikasikan adanya batasan dalam pemrosesan memori jangka panjang untuk data saham TLKM pada pembagian data tersebut.




Gambar 4.20 Prediksi 30 hari kedepan rasio 90:10 time step 60

Gambar 4.20 menyajikan visualisasi perbandingan antara harga aktual dan harga prediksi model LSTM pada konfigurasi *time step* 60 dengan rasio pembagian data 90:10. Secara kualitatif, hasil prediksi pada skenario ini menunjukkan kualitas prediksi terburuk dibandingkan seluruh skenario lainnya, bahkan mengindikasikan terjadinya fenomena *underfitting* yang ekstrem di antara konfigurasi yang diuji. Sepanjang periode pengujian, terlihat bahwa garis prediksi memiliki pola yang cenderung kaku, meskipun masih berupaya mereplikasi tren umum secara konsisten namun gagal menangkap fluktuasi harga yang krusial. Kegagalan model dalam memberikan prediksi yang akurat ini dikuatkan secara statistik oleh metrik evaluasi yang menunjukkan nilai RMSE sebesar 76,62, MAPE sebesar 2,06%, serta koefisien determinasi R^2 yang merosot tajam ke angka 0,2762. Dengan demikian, penggunaan 60 hari data historis sebagai *sequence input* terbukti kurang sesuai untuk peramalan harga saham pada pembagian data ini, sebagaimana dibuktikan oleh pemburukan nilai metrik yang sangat signifikan dibandingkan performa model-model pada konfigurasi sebelumnya.




Gambar 4.21 Prediksi 30 hari kedepan rasio 70:30 time step 15

Gambar 4.21 menyajikan visualisasi perbandingan antara harga aktual dan harga prediksi model LSTM pada konfigurasi *time step* 15 dengan rasio pembagian data 70:30. Secara kualitatif, hasil prediksi pada skenario ini menunjukkan tingkat kesesuaian yang sangat stabil, di mana arsitektur model berhasil mempertahankan akurasi prediksinya meskipun diuji pada set data uji yang cakupannya jauh lebih besar, yakni mencapai 30% dari total data. Sepanjang periode pengujian, terlihat bahwa garis prediksi bergerak relatif konsisten dalam mereplikasi tren data aktual secara presisi serta mampu menghindari gejala *overfitting* yang sering muncul pada pembagian data serupa. Konsistensi visual yang impresif ini dikuantifikasi oleh metrik evaluasi yang menunjukkan nilai RMSE sebesar 68,20, MAPE sebesar 1,68%, serta koefisien determinasi R^2 yang sangat tinggi sebesar 0,9795. Berdasarkan hasil tersebut, penggunaan 15 hari data historis sebagai *sequence input* terbukti memberikan performa yang sangat baik dan andal pada pembagian data ini, sebagaimana dibuktikan oleh capaian nilai metrik yang menunjukkan stabilitas model dalam jangka panjang.




Gambar 4.22 Prediksi 30 hari kedepan rasio 70:30 time step 30

Gambar 4.22 menyajikan visualisasi perbandingan harga aktual dan harga prediksi model LSTM pada konfigurasi *time step* 30 dengan rasio 70:30. Secara kualitatif, hasil prediksi menunjukkan kualitas prediksi terburuk di antara semua skenario, ditandai dengan garis yang hampir datar. Performa visual ini terlihat oleh metrik evaluasi yang menunjukkan nilai RMSE sebesar 97,87, MAPE sebesar 2,62%, dan R^2 sebesar 0,9592. Meskipun demikian, penggunaan 30 hari data historis sebagai *sequence input* memberikan kinerja yang memuaskan, tetapi tidak seefisien *time step* 15 dengan rasio 70:30.



Gambar 4.23 Prediksi 30 hari kedepan rasio 70:30 time step 45

Gambar 4.23 menyajikan visualisasi perbandingan harga aktual dan harga prediksi model LSTM pada konfigurasi *time step* 45 dengan rasio 70:30. Secara kualitatif, hasil prediksi pada skenario ini menunjukkan ketidaksesuaian yang signifikan dan gejala *underfitting*. Pada periode pengujian, terlihat bahwa garis prediksi cenderung sangat tumpul dan lambat merespons perubahan harga, mengindikasikan bahwa model gagal mengekstrak pola yang relevan dari *sequence input* yang terlalu panjang. Degradasi performa visual ini dikuatkan oleh metrik evaluasi yang menunjukkan nilai RMSE sebesar 73,01, MAPE sebesar 1,82%, dan R^2 sebesar 0,9765. Dengan mempertimbangkan bukti kuantitatif, penggunaan 45 hari data historis sebagai *sequence input* terbukti kurang optimal menyebabkan penurunan kinerja pada rasio ini.



Gambar 4.24 Prediksi 30 hari kedepan rasio 70:30 time step 60

Gambar 4.24 menyajikan visualisasi perbandingan harga aktual dan harga prediksi model LSTM pada konfigurasi *time step* 60 dengan rasio 70:30. Secara kualitatif akurasi sedikit menurun dibandingkan *time step* 15 dengan rasio 70:30. Pada periode pengujian, terlihat bahwa garis prediksi mampu mengikuti tren umum, tetapi terdapat deviasi yang lebih nyata pada fluktuasi harga yang tajam.

Kemampuan model dalam memprediksi dikuatkan oleh metrik evaluasi yang menunjukkan nilai RMSE sebesar 67.15, MAPE sebesar 1.72%, dan R^2 sebesar 0.9781. Dengan mempertimbangkan bukti kuantitatif, penggunaan 60 hari data historis sebagai *sequence input* terbukti cukup optimal namun dibanding dengan *time step* 15 rasio 70:30 masih kurang baik.

4.6 Pembahasan

Pembahasan ini menyajikan analisis dan interpretasi terhadap hasil-hasil yang telah diperoleh dari serangkaian uji coba model *Long Short-Term Memory* (LSTM) untuk memprediksi harga saham PT Telkom Indonesia Tbk (TLKM). Fokus pembahasan meliputi validasi kinerja prediksi model, efektivitas arsitektur LSTM, dan peran penting dari *hyperparameter tuning* serta teknik regulasi dalam mencapai akurasi optimal.

Setelah seluruh serangkaian skenario pengujian yang melibatkan berbagai konfigurasi arsitektur dan rasio pembagian data telah rampung dilaksanakan, langkah selanjutnya adalah mengevaluasi kinerja prediktif model secara komprehensif. Hasil dari evaluasi ini dirangkum dalam bentuk tabel, yang menampilkan secara terperinci perbandingan tingkat kesalahan yang diukur melalui metrik RMSE dan MAPE untuk setiap model yang diuji. Berikut ini adalah tabel 4.20 hasil perbandingan tingkat error untuk setiap model.

Tabel 4.21 Hasil error setiap skenario

Model	Splitting Data	RMSE	MAPE	R^2
Skenario 1	80:20	61.69	1.63%	0.8697
Skenario 2	90:10	76.62	2.06%	0.2762
Skenario 3	70:30	67.15	1.72%	0.9781

Hasil komparatif menunjukkan bahwa variasi rasio pembagian data memiliki dampak terhadap kemampuan model LSTM dalam menggeneralisasi. Skenario 3 (Rasio 70:30) terbukti menjadi konfigurasi terbaik dari segi nilai koefisien determinasi, ditandai dengan nilai koefisien determinasi (R^2) paling tinggi, yaitu 0.9781, dan error persentase terendah MAPE 1.72%. Nilai R^2 yang sangat mendekati 1.0 ini mengindikasikan bahwa model pada Skenario 3 memiliki kemampuan prediktif dan daya penjas yang superior, berhasil menangkap 97.81% variasi pergerakan harga saham TLKM pada data uji. Meskipun Skenario 3 memiliki RMSE yang sedikit lebih besar (67.15) dibandingkan Skenario 1, nilai R^2 dan MAPE yang sangat unggul menunjukkan bahwa secara keseluruhan, model ini memberikan kesesuaian dan keandalan prediksi persentase yang paling optimal.

Sebaliknya, Skenario 2 (Rasio 90:10) menghasilkan kinerja yang paling lemah, ditunjukkan oleh nilai R^2 yang sangat rendah, yaitu 0.2762. Meskipun teknik *early stopping* sudah diterapkan, kegagalan ini kemungkinan besar disebabkan oleh kelangkaan data uji yang hanya 10%. Dengan data latih yang sangat dominan (90%), data uji yang terlalu sedikit mungkin tidak merepresentasikan keseluruhan keragaman data, sehingga metrik evaluasi yang dihasilkan menjadi bias dan model gagal melakukan generalisasi secara efektif terhadap fluktuasi harga saham yang berbeda dari data latih.

Skenario 1 (Rasio 80:20) menempati posisi tengah diantara skenario pengujian dengan R^2 sebesar 0.8697 dan MAPE 1,63%. Meskipun cukup akurat, performanya secara masih berada di bawah skenario 3. Hal ini memperkuat temuan bahwa, untuk data TLKM yang diteliti, rasio 70% untuk training dan 30% untuk

testing adalah konfigurasi yang paling seimbang, memberikan data latih yang cukup untuk pembelajaran optimal sekaligus menyediakan data uji yang memadai dan representatif untuk validasi model.

Pengujian juga melibatkan kombinasi variasi rasio pembagian data (70:30, 80:20, 90:10) dan variasi panjang *time step* (15, 30, 45, 60 hari). Hasil menunjukkan bahwa perubahan pada kedua variabel ini secara signifikan memengaruhi akurasi dan daya generalisasi model.

Kinerja error absolut (RMSE dan MAE) terendah dicapai pada kombinasi *time step* 60 hari dan Rasio Pembagian Data 80:20. Konfigurasi ini menghasilkan metrik RMSE sebesar 61.69 dan MAPE sebesar 1.63%. Kinerja optimal pada *time step* 60 hari mengindikasikan bahwa model LSTM membutuhkan kedalaman memori yang cukup panjang untuk secara efektif menangkap tren jangka menengah pada pergerakan harga saham TLKM. Riwayat data yang lebih panjang ini memberikan konteks historis yang kaya, sehingga meminimalkan error dalam prediksi nilai absolut harga. Model dengan *time step* yang terlalu pendek (15 hari) menghasilkan error absolut yang lebih tinggi, mengonfirmasi bahwa pola harga saham TLKM tidak dapat diprediksi secara akurat hanya dengan mengandalkan riwayat data yang sangat minim.

Meskipun kombinasi *time step* 60 dengan Rasio 80:20 menghasilkan RMSE terendah, model dengan generalisasi terbaik dicapai pada konfigurasi *time step* 60 hari dengan rasio Pembagian Data 70:30. Konfigurasi ini menghasilkan nilai koefisien determinasi tertinggi R^2 sebesar 0.9781 dan nilai error persentase yang sangat rendah MAPE sebesar 1.82%. Nilai R^2 yang tinggi ini menunjukkan bahwa

model tersebut mampu menjelaskan 97.81% variasi pergerakan harga saham TLKM pada data uji. Kinerja superior pada rasio 70:30 menunjukkan bahwa menyediakan porsi data uji yang lebih besar (30%) dibandingkan rasio 90:10 (data uji 10%) memberikan penilaian kinerja yang lebih akurat. Artinya, model tersebut tidak hanya baik pada data latih, tetapi juga sangat baik dalam memprediksi data yang benar-benar baru.

Tabel 4.22 Klaster gambar

Klaster	Rentang Gambar	Keterangan
1	Gambar 4.13 – 4.16	Fokus pada pengaruh <i>time step</i> pada rasio 80:20 (menunjukkan perbaikan kinerja).
2	Gambar 4.17 – 4.20	Fokus pada rasio 90:10 (menunjukkan penurunan kinerja pada T=60).
3	Gambar 4.21 – 4.24	Fokus pada rasio 70:30 (menunjukkan fit yang sangat dekat, tetapi dengan RMSE yang lebih besar).

Pembahasan terhadap variasi *time step* menunjukkan adanya pola kinerja yang signifikan yang dipengaruhi oleh rasio pembagian data. Pengaruh *time step* harus dievaluasi per rasio, karena ukuran data pelatihan mempengaruhi kemampuan model untuk memproses urutan input yang panjang.

- Klaster 1 Rasio Data 80:20 (Gambar 4.13 – 4.16)

Pada rasio ini, model dilatih dengan data sebanyak (80%). Peningkatan *time step* dari 15 hari hingga 60 hari menunjukkan korelasi positif terhadap akurasi. Hal ini ditandai dengan penurunan nilai RMSE secara konsisten dari 76.39 menjadi 61.69. Hasil ini menguatkan asumsi bahwa pola harga saham TLKM memerlukan konteks historis jangka menengah (60 hari, atau dua bulan) agar model dapat mengekstrak fitur yang lebih stabil, bukan hanya *noise* harian, terutama ketika

model memiliki data pelatihan yang cukup. Gambar 4.16 menunjukkan visualisasi terbaik di klaster ini.

- Klaster 2 Rasio Data 90:10 (Gambar 4.17 – 4.20)

Pada Rasio 90:10 (Gambar 4.17 – 4.20), kinerja model menunjukkan sensitivitas tinggi terhadap kedalaman input. Model mencapai kinerja yang kompetitif pada *time step* 30 hari (RMSE 63.55). Namun, ketika *time step* ditingkatkan menjadi 60 hari, terjadi penurunan kinerja yang drastis (RMSE melonjak menjadi 76.62). Fenomena ini menunjukkan kegagalan generalisasi; *time step* yang terlalu panjang (60 hari) digabungkan dengan data uji yang relatif sedikit (10%) menyebabkan model tidak mampu memproses urutan input tersebut secara efektif.

- Klaster 3 Rasio Data 70:30 (Gambar 4.21 – 4.24)

Pada Rasio 70:30 (Gambar 4.21 – 4.24), model dilatih dengan data yang paling sedikit untuk pelatihan (70%). Kinerja model pada klaster ini relatif stagnan dengan RMSE terkecil 67.15. Meskipun klaster ini menghasilkan nilai R^2 yang sangat tinggi (sekitar 0.97), angka RMSE absolutnya tetap lebih besar dari Model Optimal (67.15). Model cocok dengan data pelatihan (70%) sehingga evaluasi R^2 pada data pengujian yang minim menjadi bias, namun error prediksi riil (RMSE) tetap lebih tinggi. Model ini tidak dipilih karena minimisasi error absolut lebih penting dalam prediksi pasar saham. Secara keseluruhan hasil dari prediksi masa depan memiliki pola yang hanya membaca tren, dimana prediksi yang dihasilkan dari penelitian ini hasilnya ialah garis tren.

4.6.1 Validasi Efektivitas Model dan Teknik Optimalisasi

Keberhasilan model (khususnya Skenario 3) dengan MAPE rendah 1.72% memvalidasi dua aspek krusial penelitian yaitu efektivitas arsitektur LSTM dimana model LSTM terbukti adaptif dan unggul dalam memproses data deret waktu finansial yang non-linear dan kompleks. Kemampuannya untuk mengingat pola pergerakan harga historis (dengan *look_back* yang telah ditetapkan) memungkinkan prediksi yang sangat akurat terhadap harga di masa depan. Kemudian keberhasilan *hyperparameter tuning* dan *early stopping* menjamin model memiliki struktur yang optimal, sementara teknik *early stopping* berhasil menjaga model dari kecenderungan *overfitting* yang ekstrem. Dengan menghentikan pelatihan tepat pada saat *loss validation* mulai stagnan atau meningkat, teknik ini memastikan bahwa model yang dipilih adalah model dengan kemampuan generalisasi terbaik di antara semua *epoch* pelatihan. Ini merupakan kunci mengapa model pada Skenario 3 dapat mempertahankan nilai R^2 setinggi itu pada data yang belum pernah dilihat sebelumnya.

Model dengan konfigurasi *time step* 60 hari dan rasio pembagian data 70:30 menghasilkan metrik daya generalisasi terbaik R^2 sebesar 0.9781 dan error persentase terendah MAPE sebesar 1.82%. Keunggulan ini divalidasi melalui dengan *time step* 60 hari terbukti menemukan titik optimal antara kedalaman memori dan relevansi pola. *Time step* ini menjamin model mampu membedakan antara tren signifikan dan *noise*. Kemudian dengan rasio 70:30, model diuji pada porsi data uji terbesar (30%), menjadikannya pengujian yang paling ketat dan objektif. Pencapaian R^2 setinggi 0.9781 pada data yang belum pernah dilihat

sebelumnya ini adalah kunci. Hal ini menunjukkan bahwa model benar-benar memahami hubungan antara input dan output dan bukan sekadar menghafal. Ini menegaskan bahwa model ini memiliki kemampuan generalisasi terbaik dan paling sukses dalam mencegah *overfitting*.

Keberhasilan model yang menggunakan *time step* 60 hari dengan Rasio Pembagian Data 80:20 divalidasi oleh pencapaian error absolut yang paling rendah RMSE sebesar 61.69 dan MAPE sebesar 1.63%. Pencapaian ini menegaskan bahwa penggunaan *time step* 60 hari mengonfirmasi bahwa pergerakan harga saham TLKM memiliki memori jangka menengah yang signifikan. Model LSTM terbukti paling efektif dalam meminimalkan error nilai absolut ketika diberi konteks historis yang paling kaya. Kedalaman memori ini membantu jaringan menstabilkan prediksi dengan mengandalkan tren yang lebih kuat dan mengabaikan fluktuasi harian yang bersifat noise. Kemudian rasio 80:20 memberikan porsi data latih yang memungkinkan model untuk mempelajari pola dan *noise* secara lebih mendalam. Hal ini sangat berkontribusi pada penurunan error RMSE karena model menjadi sangat familiar dengan data historis, menjadikannya model yang paling akurat dalam memprediksi nilai harga tunggal (titik data) di antara semua skenario yang diuji.

Hasil komparasi *hyperparameter tuning* telah mengidentifikasi adanya dua kandidat model terbaik, yaitu Model Akurasi Absolut Terbaik (*time step* 60 hari, Rasio 80:20) dan Model Daya Generalisasi Terbaik (*time step* 60 hari, Rasio 70:30). Model daya generalisasi unggul dengan R^2 sebesar 0.9781, menandakan adaptabilitas tinggi terhadap data baru (Malensang et al., 2013). Namun, untuk

tujuan prediksi harga saham yang bersifat aplikasi praktis, prioritas utama diberikan pada minimisasi *error* nilai absolut yang secara langsung diukur oleh RMSE. Oleh karena itu, Model LSTM dengan *time step* 60 hari dan Rasio Pembagian Data 80:20 ditetapkan sebagai Model Optimal. Dengan demikian, meskipun model R^2 tertinggi menunjukkan keandalan ilmiah yang kuat. Model RMSE terendah adalah yang paling efektif dan relevan untuk digunakan dalam prediksi harga di masa depan (Ismiyana Putri & Yudhi Putra, 2023). Perolehan ini didasarkan pada dua alasan utama:

(1) Model ini menghasilkan RMSE terendah sebesar 61.69, yang berarti model ini adalah yang paling akurat dalam memprediksi *nilai harga spesifik* TLKM. Dalam konteks investasi, meminimalkan selisih nilai absolut (RMSE) sangat krusial karena terkait langsung dengan potensi kerugian riil.

(2) Kombinasi *time step 60 hari* dengan porsi data latih terbesar (Rasio 80:20) terbukti mampu menstabilkan prediksi dan mengatasi fluktuasi harga saham, memberikan konteks historis yang kaya untuk mencapai *error* absolut terendah.

4.7 Integrasi Islam

Dalam penelitian ini, prediksi harga saham TLKM menggunakan metode *Long Short-Term Memory* (LSTM) tidak hanya berlandaskan pada prinsip-prinsip akademik dan teknologi, tetapi juga memiliki keterkaitan yang erat dengan nilai-nilai Islam. Penelitian ini tidak hanya diuji berdasarkan parameter akurasi teknis (RMSE atau MAE), tetapi juga memiliki landasan etis dan filosofis yang kuat dalam ajaran Islam. Integrasi keilmuan ini berpusat pada perintah fundamental untuk bersikap proaktif, cermat, dan bertanggung jawab terhadap masa depan. Prinsip

dasar yang menjiwai penelitian ini adalah mandat suci yang mengarahkan setiap individu untuk melaksanakan perencanaan, kehati-hatian, dan antisipasi, sebagaimana ditegaskan dalam firman Allah *Subhanahu Wa Ta'ala* dalam Surah Al-Hasyr ayat 18:

يَا أَيُّهَا الَّذِينَ آمَنُوا اتَّقُوا اللَّهَ وَلْتَنْظُرْ نَفْسٌ مَّا قَدَّمَتْ لِغَدٍ وَاتَّقُوا اللَّهَ ۚ إِنَّ اللَّهَ خَبِيرٌ بِمَا تَعْمَلُونَ

“Hai orang-orang yang beriman, bertakwalah kepada Allah dan hendaklah setiap diri memperhatikan apa yang telah diperbuatnya untuk hari esok (akhirat), dan bertakwalah kepada Allah, sesungguhnya Allah Maha Mengetahui apa yang kamu kerjakan.” (QS. Al-Hasyr : 18).

Perintah *"hendaklah setiap diri memperhatikan apa yang telah diperbuatnya untuk hari esok"* adalah esensi dari hubungan penelitian ini dengan Islam, khususnya dalam aspek perencanaan dan kehati-hatian dalam mengelola harta (*hifz al-mal*). Dalam konteks ayat tersebut, frasa *"memperhatikan apa yang telah diperbuatnya"* ditafsirkan sebagai kewajiban untuk menganalisis data dan fakta masa lalu (*data historis*), sementara frasa *"untuk hari esok"* merujuk pada keharusan merencanakan masa depan berdasarkan analisis tersebut. Kehati-hatian dalam mengelola harta diwujudkan dengan memastikan bahwa seluruh proses investasi terhindar dari praktik terlarang, terutama *gharar* (ketidakpastian berlebihan) dan *maisir* (judi).

Islam sebagai agama yang menyeluruh memandang setiap kegiatan (*amal*) manusia sebagai wujud Amanah, termasuk pengelolaan akal (*‘Aql*) dan harta (*Mal*). Oleh karena itu, ijtihad ilmiah ini diarahkan untuk mewujudkan *‘Ilm’* yang bermanfaat dan menopang salah satu tujuan syariah utama, yaitu *Hifzh al-Mal* (penjagaan harta). Pelaksanaan pemodelan menuntut ketelitian dan objektivitas

yang tinggi sebagai wujud penegakan *Mizan* (keseimbangan). Dalam bagian ini, akan dibahas bagaimana penelitian ini diintegrasikan dengan nilai-nilai Islam yang terkandung dalam Al-Qur'an dan Hadis, yang dielaborasi melalui tiga pilar konseptual: 1) Konsep *'Ilm* (Ilmu yang Bermanfaat), 2) Filosofi *Mizan* (Keseimbangan dan Akurasi), dan 3) Etika *Hifzh al-Mal* (Penjagaan Harta).

4.7.1 Pilar *'Ilm* (Ilmu yang Bermanfaat)

Pilar *'Ilm* ini berlandaskan pada kesadaran akan Amanah Ilahi, yaitu bahwa akal (*'Aql*) dan kemampuan berpikir yang dikaruniakan merupakan titipan yang harus dimanfaatkan secara optimal untuk mencari kebenaran dan ilmu yang berujung pada *Maslahah* (kemaslahatan). Dalam kerangka integrasi ini, seluruh aktivitas penelitian, termasuk upaya memprediksi pergerakan pasar modal, dipandang sebagai bagian dari usaha sungguh-sungguh yang bernilai ibadah.

Penggunaan model *Long Short-Term Memory* (LSTM) dalam penelitian ini merupakan aktualisasi dari Amanah Akal tersebut. LSTM mewakili puncak *ijtihad* manusia dalam mengembangkan perangkat analisis data yang mampu memahami pola kompleks (*time series*) di pasar modal. *Ijtihad* ini diarahkan pada perolehan data yang paling mendekati kebenaran ilmiah (*haqiqah*), sehingga mampu memberikan *'Ilm* (pengetahuan) yang dapat diandalkan oleh investor.

Selanjutnya, langkah teknis *Hyperparameter Tuning* dan *Regulasi Model* adalah manifestasi dari pelaksanaan Amanah Akal dengan standar tertinggi. Prosedur ini menjamin bahwa ilmu yang dihasilkan tidaklah sembarangan, melainkan telah melalui proses penyempurnaan yang ketat untuk mencapai akurasi optimal. Tujuannya adalah mentransformasi keputusan investasi dari ranah

spekulatif (*gharar*) yang berbasis tebakan, menjadi ranah tindakan yang berbasis pengetahuan. Hal ini selaras dengan perintah agama yang melarang tindakan tanpa dasar ilmu dan menuntut pertanggungjawaban atas setiap pengetahuan yang dimiliki:

وَلَا تَقْفُ مَا لَيْسَ لَكَ بِهِ عِلْمٌ إِنَّ السَّمْعَ وَالْبَصَرَ وَالْفُؤَادَ كُلُّ أُولَٰئِكَ كَانَ عَنْهُ مَسْئُولًا

"Dan janganlah kamu mengikuti apa yang kamu tidak mempunyai pengetahuan tentangnya. Sesungguhnya pendengaran, penglihatan dan hati, semuanya itu akan diminta pertanggungjawabannya." (QS. Al-Isra': 36)

Ayat ini memberikan dasar filosofis yang kuat bahwa '*Ilm*' yang dicapai melalui ijtihad metodologis (LSTM, Tuning, dan Regulasi) adalah manifestasi dari pertanggungjawaban ilmiah atas Amanah Akal (Anam & Yahiji, 2024). Oleh karena itu, hasil penelitian yang berupa model prediksi harga saham TLKM yang akurat adalah '*Ilm*' yang bermanfaat, yang secara fungsional melindungi investor dari spekulasi tak berdasar, karena pada nantinya semua yang ada akan diminta pertanggungjawaban.

4.7.2 Pilar *Mizan* (Keseimbangan)

Pilar *Mizan* berakar pada perintah universal dalam Islam yang menuntut keadilan (*'Adl*), keseimbangan, dan ketepatan dalam setiap timbangan atau ukuran. Dalam ranah keilmuan prediktif, *Mizan* diinterpretasikan sebagai Etika Objektivitas dan Keadilan Data, yang harus ditegakkan untuk memastikan hasil prediksi tidak bias dan memiliki validitas yang universal. Pilar ini menjamin bahwa ilmu yang dihasilkan memiliki standar Masalah yang valid. Penegakan *Mizan* Melalui Ketepatan Ukuran.

Tuntutan untuk mencapai *Mizan* ini diwujudkan melalui prosedur metodologis yang ketat untuk melawan ketidakadilan data yaitu ketika model terlalu percaya diri pada data pelatihan sehingga gagal melihat kenyataan di data pengujian. Inilah peran utama *Hyperparameter Tuning* dan Regulasi Model dalam arsitektur LSTM. *Hyperparameter Tuning* adalah *ikhtiar* metodologis untuk menemukan timbangan yang lurus yang stabil, memastikan model memiliki keseimbangan yang tepat antara kemampuan mengingat data historis dan kemampuan generalisasi ke masa depan (Zul Azimi et al., 2014).

Regulasi Model berfungsi sebagai kontrol etis. Regulasi mencegah model menjadi "tidak adil" (*ghairu 'adl*) atau melampaui batas (*thughyan*) dengan *overfitting* pada data tertentu. Ini adalah bentuk penegakan keadilan data, memastikan model berlaku objektif dan seimbang.

Melalui penegakan teknis ini, peneliti berupaya menjaga agar model selalu berada dalam batas-batas kebenaran ilmiah, sesuai dengan perintah yang menuntut ketepatan dalam setiap pengukuran:

وَأَوْفُوا الْكَيْلَ إِذَا كِلْتُمْ وَزَنُوا بِالْقِسْطَاسِ الْمُسْتَقِيمِ ۚ ذَٰلِكَ خَيْرٌ وَأَحْسَنُ تَأْوِيلًا

"Dan sempurnakanlah takaran apabila kamu menakar, dan timbanglah dengan timbangan yang lurus (tepat). Itulah yang lebih baik (bagimu) dan lebih baik akibatnya." (QS. Al-Isra': 35)

Ayat ini memberikan dasar filosofis bahwa proses *Tuning* dan Regulasi adalah wujud ketaatan untuk mencapai timbangan yang lurus dalam ranah ilmu komputasi. M. Quraish Shihab dalam tafsirnya, Tafsir Al-Misbah, menjelaskan bahwa perintah untuk menyempurnakan timbangan dan takaran ini memiliki makna yang luas. Bisa mencakup kewajiban untuk berlaku jujur dan adil dalam segala hal,

termasuk dalam penetapan standar dan metodologi ilmiah (Kholifah, 2023). Dengan menjamin *Mizan* dalam model, penelitian ini menghasilkan prediksi yang objektif, yang merupakan landasan bagi investor untuk mengambil keputusan yang adil dan bijaksana dalam mengelola aset.

4.7.3 Pilar *Hifzh al-Mal* (Penjagaan Harta)

Pilar *Hifzh al-Mal* ini merupakan manifestasi dari tanggung jawab sosial-ekonomi dalam Islam, di mana penjagaan harta merupakan salah satu tujuan utama yang harus dijaga. Penelitian ini berfungsi sebagai wujud nyata dari penunaian amanah harta bahwa modal yang diinvestasikan adalah titipan Ilahi yang wajib dikelola secara bijaksana (*rasyid*) dan hati-hati (*ihtiyat*). Model prediksi yang dihasilkan memiliki peran etis yang krusial dalam dua aspek: melindungi investor dari Spekulasi (*Maisir*) dan mencegah Pemborosan (*Tabdzir*) finansial. *Tabdzir* dalam konteks ini mencakup kerugian yang timbul akibat kelalaian atau pengambilan keputusan investasi tanpa dasar ilmiah yang kuat. Model LSTM yang diuji dengan *Tuning* dan Regulasi memberikan dasar ilmiah yang kuat, sehingga melindungi investor dari *Tabdzir* yang diakibatkan oleh spekulasi tak berdasar dan mengarahkan aktivitas di pasar modal ke ranah investasi berbasis analisis terukur. Hal ini sesuai dengan prinsip yang terkandung dalam Al-Qur'an:

وَلَا تُؤْتُوا السُّفَهَاءَ أَمْوَالَكُمُ الَّتِي جَعَلَ اللَّهُ لَكُمْ قِيَامًا

“Dan janganlah kamu serahkan kepada orang-orang yang belum sempurna akalnya, harta mereka (yang ada dalam kekuasaanmu) yang dijadikan Allah sebagai pokok kehidupan.” (QS. An-Nisa: 5).

Ayat ini menegaskan bahwa harta adalah pilar kehidupan yang harus dikelola oleh orang yang bijaksana (*rasyid*), bukan oleh orang yang lalai (*sufahā'*). Dengan demikian, model prediksi yang akurat berfungsi membantu investor untuk bertindak sebagai pihak yang *rasyid*, menunaikan kewajiban *Hifzh al-Mal*, dan menjauhkan harta yang menjadi amanahnya dari risiko yang bersifat spekulatif (Hilman, 2022).

Melalui integrasi nilai-nilai Islam dalam penelitian ini, dapat dipahami bahwa ilmu pengetahuan dan teknologi harus digunakan dengan tanggung jawab moral dan spiritual. Untuk mewujudkan '*Ilm*' yang bermanfaat dan menopang salah satu tujuan syariah utama, yaitu *Hifzh al-Mal* (penjagaan harta). Pelaksanaan pemodelan menuntut ketelitian dan objektivitas yang tinggi sebagai wujud penegakan *Mizan* (keseimbangan). Dengan demikian, penelitian ini tidak hanya memiliki nilai ilmiah, tetapi juga memiliki makna spiritual dan sosial yang lebih luas dalam Islam.

4.7.4 Muamalah Ma'a-Allah

Prinsip *muamalah mu'allah* (hubungan dengan Allah) menuntut seorang Muslim untuk mengelola harta dengan penuh tanggung jawab dan berdasarkan pada ilmu pengetahuan yang terverifikasi, bukan sekadar dugaan buta. Kewajiban untuk bertindak berdasarkan pengetahuan ini menjadi landasan etis dalam pengaplikasian metode prediksi canggih seperti LSTM, yang membedakan tindakan cerdas dari spekulasi. Pentingnya ilmu sebagai pemandu tindakan secara fundamental ditegaskan dalam firman Allah *subhanahu wa ta'ala* dalam Surah Az-Zumar ayat 9:

قُلْ هَلْ يَسْتَوِي الَّذِينَ يَعْلَمُونَ وَالَّذِينَ لَا يَعْلَمُونَ

"Katakanlah (wahai Muhammad): 'Apakah sama orang-orang yang mengetahui dengan orang-orang yang tidak mengetahui?' (QS. Az-Zumar: 9).

Menurut Tafsir Al-Misbah, ayat ini mengajarkan bahwa terdapat perbedaan derajat antara orang yang menggunakan ilmu dalam tindakannya dengan orang yang bertindak tanpa ilmu, di mana Allah meninggikan derajat orang yang berilmu (Shihab, 2002), bahwa Allah meninggikan derajat orang yang memperoleh dan menerapkan ilmu, menciptakan perbedaan hierarki yang jelas antara orang yang terpelajar dan orang bodoh (Nurlaila & Almuzammil, 2022). Dalam konteks pasar modal syariah, penelitian ini merupakan bentuk implementasi perintah ilmu tersebut:

1. Ikhtiar Berbasis Ilmu: Model LSTM dengan *hyperparameter tuning* dan *regulasi model* adalah alat ilmiah untuk mencapai derajat "orang-orang yang mengetahui". Akurasi tinggi yang dihasilkan adalah bukti bahwa keputusan investasi telah didasarkan pada analisis spekulasi.
2. Menghindari Gharar: Tindakan yang tidak didasari ilmu sering kali berujung pada praktik *gharar* (ketidakjelasan atau ketidakpastian berlebihan), yang dilarang keras oleh Nabi Muhammad *Shallallahu 'Alaihi Wasallam* yang mengutip hadis dari HR. Muslim dari Abu Hurairah

هَي رَسُوْلُ اللهِ صَلَّى اللهُ عَلَيْهِ وَسَلَّمَ عَنْ بَيْعِ الْخَصَاةِ وَعَنْ بَيْعِ الْعَرَرِ

"Rasulullah *Shallallahu 'Alaihi Wasallam* melarang jual beli dengan lemparan kerikil (*al-haşāh*) dan melarang jual beli (*al-gharar*). (HR. Muslim, No. 1513, dari Abu Hurairah).

Pemanfaatan LSTM berfungsi sebagai ikhtiar pencegahan terhadap *gharar*, menjadikan pengelolaan harta seorang muslim sesuai dengan tuntutan ilmu dan syariat.

4.7.5 Muamalah Ma'a an-Nas

Amalan *Muamalah Ma'a an-Nas* (hubungan antarmanusia) dalam penelitian ini diwujudkan melalui semangat amanah dan keadilan dalam transaksi ekonomi. Dalam pasar modal, hal ini berarti mencegah manipulasi dan memastikan informasi dapat diakses secara adil. Kontribusi ilmiah ini relevan dengan perintah Allah *Subhanahu wa Ta'ala* dalam Surah An-Nisa ayat 58

إِنَّ اللَّهَ يَأْمُرُكُمْ أَنْ تُؤَدُّوا الْأَمَانَاتِ إِلَىٰ أَهْلِهَا وَإِذَا حَكَمْتُمْ بَيْنَ النَّاسِ أَنْ تَحْكُمُوا بِالْعَدْلِ ۚ إِنَّ اللَّهَ نِعِمَّا يَعِظُكُمْ بِهِ ۚ إِنَّ اللَّهَ كَانَ سَمِيعًا بَصِيرًا

"Sesungguhnya Allah menyuruh kamu menyampaikan amanat kepada yang berhak menerimanya, dan (menyuruh kamu) apabila menetapkan hukum di antara manusia supaya kamu menetapkan dengan adil." (QS. An-Nisa: 58).

Menurut Syekh Wahbah Az-Zuhaili dalam kitab *Al-Fiqh al-Islami wa Adillatuhu*, beliau menjelaskan bahwa perintah untuk "menyampaikan amanat" dan "menetapkan dengan adil" pada ayat ini tidak terbatas pada urusan peradilan atau tata kelola negara saja, melainkan berlaku umum dalam segala aspek kehidupan dan transaksi (*muamalah*) (Nida Rofana Faridah et al., 2025). Penelitian ini mewujudkan muamalah ma'annas melalui dua kontribusi:

- Amanah Informasi: Penelitian ini memberikan informasi prediksi harga yang valid dan fair. Ini adalah bentuk tolong-menolong dengan memberikan alat yang membantu investor kecil memenuhi hak mereka atas informasi

yang adil, melawan ketidakseimbangan informasi (*asimetri informasi*) di pasar.

- Penegakan Keadilan (*Al-'Adl*): Hasil prediksi yang akurat membantu para investor mengambil keputusan tanpa merugikan pihak lain (seperti melalui *insider trading* atau manipulasi). Dengan demikian, teknologi LSTM diarahkan untuk mendukung keadilan ekonomi, yang sejalan dengan anjuran Nabi Muhammad *Sallallahu 'Alaihi Wasallam* yang diriwayatkan oleh Imam Ahmad yang berbunyi:

حَيْرُ النَّاسِ أَنْفَعُهُمْ لِلنَّاسِ

"Sebaik-baik manusia adalah yang paling bermanfaat bagi manusia" (HR. Ahmad, dihasankan oleh Al-Albani dalam Shahih Al-Jami', No. 3289).

Dengan demikian, penelitian ini diharapkan memiliki kontribusi dalam menegakkan prinsip muamalah dan menjadi sarana keberkahan di sisi Allah.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Model terbaik dari segi R-Squared (R^2) ialah model terbaik yang memiliki kemampuan tertinggi untuk menjelaskan variasi harga saham aktual adalah Skenario 3 (rasio 70:30, *time step* 60). Model ini mencapai nilai R^2 sebesar 0,9781. Angka ini menjadikannya model dengan daya generalisasi teoritis tertinggi. Kemudian model terbaik dari segi RMSE ialah model terbaik yang menghasilkan tingkat kesalahan prediksi rata-rata terendah adalah (Rasio 80:20, *time step* 60). Model ini mencatatkan nilai RMSE terendah sebesar 61,69, menegaskan bahwa model ini adalah yang paling akurat dan praktis dari perspektif *error* absolut.

Kedua model terbaik tersebut dicapai berkat kombinasi optimasi *hyperparameter* dan penggunaan teknik regulasi *early stopping*. Teknik ini berhasil menstabilkan proses pelatihan dan secara efektif mencegah *overfitting*. Dengan demikian, meskipun model R^2 tertinggi menunjukkan keandalan ilmiah yang kuat. Model RMSE terendah adalah yang paling efektif dan relevan untuk digunakan dalam prediksi harga di masa depan.

Berdasarkan hasil perancangan, implementasi, dan pengujian model *Long Short-Term Memory* (LSTM) yang telah dilakukan untuk memprediksi harga saham PT Telkom Indonesia Tbk (TLKM) dengan dataset empat tahun terakhir, penelitian ini menyimpulkan beberapa poin utama sebagai berikut:

1. Penelitian ini berhasil mengimplementasikan metode Long Short-Term Memory (LSTM) sebagai solusi untuk prediksi deret waktu harga saham, dengan menggunakan data tunggal (harga *Close*). Penerapan *Hyperparameter Tuning* melalui *Randomized Search* terbukti efektif dalam mengidentifikasi konfigurasi optimal model, khususnya dalam menentukan jumlah unit (memori), *dropout*, dan *learning rate* yang paling sesuai untuk data TLKM.
2. Secara keseluruhan, model LSTM yang telah disetel menunjukkan kemampuan yang memadai dalam menangkap tren harga saham TLKM jangka panjang. Namun, terdapat tantangan signifikan dalam memprediksi fluktuasi harga harian yang tajam. Keterbatasan hanya menggunakan harga *Close* sebagai input tunggal menyebabkan model cenderung menghasilkan garis prediksi yang lebih mulus, yang merefleksikan kesulitan model untuk menginternalisasi sinyal kompleks pasar tanpa adanya variabel independen tambahan.
3. Penelitian ini telah memenuhi tujuan utamanya, yaitu memprediksi harga saham TLKM dan menunjukkan peran penting *Hyperparameter Tuning* dan Regulasi Model dalam mengoptimalkan performa model pada kasus prediksi *time eries*.

5.2 Saran

Meskipun hasil penelitian ini menunjukkan validitas dan kontribusi yang signifikan dalam pemodelan prediksi harga saham TLKM, peneliti menyadari bahwa masih terdapat beberapa keterbatasan yang menjadi peluang besar untuk

eksplorasi lebih lanjut. Berdasarkan temuan dan tantangan yang dihadapi selama proses implementasi, berikut merupakan beberapa rekomendasi yang diajukan untuk penelitian di masa mendatang guna mengoptimalkan akurasi dan kinerja model:

1. Untuk meningkatkan akurasi model dalam melacak volatilitas dan pergerakan harga yang cepat, sangat disarankan bagi penelitian selanjutnya untuk memperluas lingkup input data. Hal ini dapat dilakukan dengan menambahkan variabel independen lain, seperti:
 - Data Pasar: Harga *Open*, *High*, *Low*, dan *Volume* perdagangan.
 - Indikator Teknikal: Indikator momentum (misalnya, MACD dan RSI) yang dapat memberikan sinyal *buy* atau *sell* yang lebih jelas kepada model.
2. Disarankan untuk melakukan perbandingan kinerja model LSTM dengan model *Time Series* lanjutan lainnya, seperti GRU (*Gated Recurrent Unit*) atau CNN-LSTM yang menggabungkan kemampuan ekstraksi fitur spasial (CNN) dan temporal (LSTM).
3. Walaupun *Randomized Search* telah digunakan, penelitian selanjutnya dapat mempertimbangkan penggunaan teknik optimasi yang lebih mendalam, seperti *Grid Search* (pada ruang parameter yang lebih kecil dan terfokus) atau *Bayesian Optimization* untuk menemukan kombinasi *hyperparameter* yang benar-benar optimal secara lebih efisien.
4. Hasil prediksi model ini sebaiknya tidak dijadikan sebagai satu-satunya dasar dalam pengambilan keputusan investasi. Para analis atau investor

disarankan untuk menggabungkan hasil prediksi model ini dengan analisis fundamental perusahaan dan sentimen pasar yang berlaku saat itu.

DAFTAR PUSTAKA

- Agustina, R. (2021). Analisis Fundamental, Acuan Investasi Saham Jangka Panjang. *DINAMIS: Jurnal Pengabdian Kepada Masyarakat*, 1(1), 14–25. <https://doi.org/10.33752/dinamis.v1i1.360>
- Alfiana, Lubis, R. F., Suharyadi, M. R., Utami, E. Y., & Sipayung, B. (2023). Manajemen Risiko dalam Ketidakpastian Global: Strategi dan Praktik Terbaik. *Jurnal Bisnis Dan Manajemen West Science*, 2(03), 260–271. <https://doi.org/10.58812/jbmws.v2i03.576>
- Anam, K., & Yahiji, K. (2024). Landasan Paradigmatis Islamisasi Ilmu Pengetahuan. *Educator (Directory Of Elementary Education Journal)*, 5(1), 39–48. <https://doi.org/10.58176/edu.v5i2.1546>
- Chen, L.-P. (2020). Using Machine Learning Algorithms on Prediction of Stock Price. *Journal of Modeling and Optimization*, 12(2), 84–99. <https://doi.org/10.32732/jmo.2020.12.2.84>
- Hilman, H. (2022). Implementasi Perencanaan Investasi Dalam Memilih Instrumen Investasi Di Pasar Modal Syariah. *Madani Syari'ah*, 5(2), 98–107. <https://doi.org/10.51476/madanisyariah.v5i2.389>
- Irfan Syahrani, M. (2022). PROSEDUR PENELITIAN KUANTITATIF. *eJurnal Al Musthafa*, 2(3), 43–56. <https://doi.org/10.62552/ejam.v2i3.50>
- Ismiyana Putri, D., & Yudhi Putra, M. (2023). Komparasi Algoritma Dalam Memprediksi Perubahan Harga Saham GOTO Menggunakan Rapidminer. *Jurnal Khatulistiwa Informatika*, 11(1), 14–20. <https://doi.org/10.31294/jki.v11i1.16153>
- Kholifah, V. N. (2023). Konsep Keadilan dalam Al-Qur'an Studi Komparasi Tafsir Al-Misbah dan Tafsir Marah Labid terhadap Ayat-Ayat Adil. *Qaf: Jurnal Ilmu Al-Qur'an Dan Tafsir*, 4(2), 127–159. <https://doi.org/10.59579/qaf.v4i2.4181>
- Malensang, J. S., Komalig, H., & Hatidja, D. (2013). Pengembangan Model Regresi Polinomial Berganda Pada Kasus Data Pemasaran. *Jurnal Ilmiah Sains*, 12(2), 149. <https://doi.org/10.35799/jis.12.2.2012.740>
- Muhammad Fauzan & Nova Syafitri. (2022). Analisa 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. [HTTPS://DOI.ORG/10.32520/JAM.V8I1.2121](https://doi.org/10.32520/JAM.V8I1.2121)
- Nida Rofana Faridah, Akhmad Sulthoni, & Indri Astuti. (2025). Trade Ethics in the Qur'an According to *Tafsir al-Munir* by Wahbah Az-Zuhaili. *Al-Shamela : Journal of Quranic and Hadith Studies*, 3(1), 18–35. <https://doi.org/10.61994/alshamela.v3i1.668>

- Nurlaila, N., & Almuzammil, M. (2022). Hubungan Ilmu dan Amal dalam Al-Qur'an. *TAFSE: Journal of Qur'anic Studies*, 7(2), 215–232. <https://doi.org/10.22373/tafse.v7i2.12844>
- Patriya, E. (2020). Implementasi Support Vector Machine Pada Prediksi Harga Saham Gabungan (IHSG). *Jurnal Ilmiah Teknologi Dan Rekayasa*, 25(1), 24–38. <https://doi.org/10.35760/tr.2020.25i1.2571>
- Putri, S. A., & Pratama, I. H. (2024). Pentingnya Pemahaman Literasi Pasar Modal, Harga Saham Dalam Memilih Keputusan Berinvestasi Pada Era Digital. *EKALAYA: Jurnal Ekonomi Akuntansi*, 2(1), 21–28. <https://doi.org/10.59966/ekalaya.v2i1.714>
- Sabiri, B., El Asri, B., & Rhanoui, M. (2023). Efficient Deep Neural Network Training Techniques for Overfitting Avoidance. In J. Filipe, M. Śmiałek, A. Brodsky, & S. Hammoudi (Eds.), *Enterprise Information Systems* (Vol. 487, pp. 198–221). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-39386-0_10
- Selle, N., Yudistira, N., & Dewi, C. (2022). Perbandingan Prediksi Penggunaan Listrik dengan Menggunakan Metode Long Short Term Memory (LSTM) dan Recurrent Neural Network (RNN). *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 9(1), 155–162. <https://doi.org/10.25126/jtiik.2022915585>
- St. Petersburg State University, Berezinets, I. V., Ilina, Y. B., St. Petersburg State University, Klyarovskaya, N. A., & 21 Skills, Inc. (2021). Equity crowdfunding: Determinants of company's success on a crowdfunding platform. *Vestnik of Saint Petersburg University. Management*, 20(2), 131–164. <https://doi.org/10.21638/11701/spbu08.2021.201>
- Usmanovich Burkhanov, A., & Mansur Qizi Eshmamatova, M. (2021). The Ways for Improvement of Investment Strategy in the Period of Digital Economy. *The 5th International Conference on Future Networks & Distributed Systems*, 655–662. <https://doi.org/10.1145/3508072.3508202>
- Yadav, A., Jha, C. K., & Sharan, A. (2020). Optimizing LSTM for time series prediction in Indian stock market. *Procedia Computer Science*, 167, 2091–2100. <https://doi.org/10.1016/j.procs.2020.03.257>
- Nirwana, A. (2021). *Tafsir Legislasi Kebatilan dalam Al Baqarah ayat 188*. <https://doi.org/10.31219/osf.io/kx2n5>