

**PENERAPAN *LONG SHORT-TERM MEMORY* PADA HARGA
ADJUSTED CLOSE KIMIA FARMA TBK**

NASKAH SKRIPSI

**OLEH:
FAJAR AKBAR SAMUDERA HARIONO
NIM. 200601110049**



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

**PENERAPAN *LONG SHORT-TERM MEMORY* PADA HARGA
ADJUSTED CLOSE KIMIA FARMA TBK**

NASKAH SKRIPSI

**Diajukan Kepada
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
untuk Memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Matematika (S.Mat)**

**Oleh
Fajar Akbar Samudera Hariono
NIM. 200601110049**

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

**PENERAPAN *LONG SHORT-TERM MEMORY* PADA HARGA
ADJUSTED CLOSE KIMIA FARMA TBK**

NASKAH SKRIPSI


Oleh
Fajar Akbar Samudera Hariono
NIM. 200601110049

Telah Diperiksa dan Disetujui untuk Diuji
Malang, 6 Februari 2025


Dosen Pembimbing I

Dosen Pembimbing II


Prof. Dr. Sri Harini, M.Si
NIP. 19731014 200112 2 002


Ach. Nashichuddin, M.A
NIP. 19730705 200003 1 002

Mengetahui,
Ketua Program Studi Matematika


Dr. Elly Susanti, M.Sc
NIP. 19741129 200012 2 005



**PENERAPAN *LONG SHORT-TERM MEMORY* PADA HARGA
ADJUSTED CLOSE KIMIA FARMA TBK**


NASKAH SKRIPSI

OLEH
Fajar Akbar Samudera Hariono
NIM. 200601110049

Telah Dipertahankan di Depan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
untuk Memperoleh Gelar Sarjana Matematika (S.Mat)
Tanggal, 3 Juni 2025

Ketua Penguji	: Abdul Aziz, M.Si.
Anggota Penguji 1	: Ria Dhea Layla Nur K., M.Si.
Anggota Penguji 2	: Prof. Dr. Sri Harini, M.Si.
Anggota Penguji 3	: Ach. Nashichuddin, M.A







Mengetahui,
Ketua Program Studi Matematika



Dr. Elly Susanti, M.Sc.
NIP. 19741129 200012 2 005

PERNYATAAN KEASLIAN TULISAN

Saya bertanda tangan di bawah ini

Nama : Fajar Akbar Samudera Hariono
NIM : 200601110049
Program Studi : Matematika
Fakultas : Sains dan Teknologi
Judul : Penerapan Long Short Term Memory pada Harga Adjusted
Close Kimia Farma TBK

menyatakan dengan sebenarnya bahwa skripsi yang saya tulis ini merupakan hasil karya sendiri, bukan pengambilan tulisan atau pemikiran orang lain yang saya akui sebagai pemikiran saya, kecuali dengan mencantumkan sumber cuplikan pada daftar rujukan di halaman terakhir. Apabila di kemudian hari terbukti skripsi ini adalah hasil jiplakan atau tiruan, maka saya bersedia menerima sanksi yang berlaku atas perbuatan tersebut.

Malang, 3 Juni 2025



Fajar Akbar Samudera Hariono

Nim. 200601110049

HALAMAN MOTO

“Tetaplah berjalan walaupun tidak tahu arah tujuan, tetaplah bernafas walaupun angin menghempas, tetap syukuri apa yang diberikan tuhan karena nikmat manalagi yang engkau dustakan”

HALAMAN PERSEMBAHAN

Skripsi ini penulis persembahkan kepada:

Kedua orang tua penulis, Ibu Munawaroh dan Alm. Ayah Moch Dadang Hariono yang memberikan dukungan dan doa dalam setiap keputusan yang penulis ambil.

Kakak Rizqy Faisal Habibi yang selalu menanyakan kabar penulis dan selalu mengirimkan dukungan kepada penulis. Teman teman seperjuangan yang membantu dan mendukung penulis supaya selesai mengerjakan skripsi ini.

Keluarga penulis yang belum bisa penulis sebutkan satu persatu.

KATA PENGANTAR

Assalamualaikum Warahmatullahi Wabarakatuh

Alhamdulillah, rasa syukur peneliti panjatkan kehadirat Allah Swt. Atas segala nikmat dan karunia-Nya sehingga proposal skripsi yang berjudul “Penerapan *Long Short Term Memory* Pada Harga *Adjusted Close* Saham Kimia Farma Tbk” dapat terampungkan dengan lancar. Sholawat serta salam semoga senantiasa tercurahkan kepada baginda Nabi Muhammad saw. yang telah membimbing umat Islam dari zaman jahiliah menuju zaman yang penuh peradaban dan pengetahuan.

Peneliti juga mengucapkan terima kasih kepada semua pihak yang ikut berpartisipasi dalam membantu, membimbing, dan memberikan arahan. Peneliti lebih khusus menyampaikan terima kasih kepada:

1. Prof. Dr. H. M. Zainuddin, M.A, selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Prof. Dr. Sri Harini, M.Si., selaku dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang dan selaku dosen pembimbing I yang senantiasa memberikan arahan dan bimbingan penulis dengan segala ilmu yang dimiliki serta nasihat dan motivasi dalam mengerjakan skripsi ini sampai akhir.
3. Dr. Elly Susanti, M.Sc., selaku Ketua Program Studi Matematika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Muhammad Nafie Jauhari, M.Si selaku dosen pembimbing II yang juga telah melimpahkan pengetahuan, bimbingan, nasihat, motivasi, dan saran yang membangun kepada peneliti.
5. Seluruh dosen Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang atas segala ilmu dan bimbingannya.
6. Ibu Munawaroh selaku ibu penulis dan Rizky Faisal selaku kakak penulis yang selalu memberikan motivasi, do’a, dan dukungan penuh dengan ikhlas secara moral dan materil.
7. Rekan seperjuangan satu angkatan dan bimbingan peneliti yang telah banyak membantu peneliti dan saling mendukung untuk berjuang bersama.

8. Teman-teman Program Studi Matematika angkatan 2020 yang selalu mendukung satu sama lain dalam rangka proses penyelesaian penelitian ini.
9. Seluruh pihak yang tidak dapat penulis sebutkan satu persatuyang telah memberikan do'a, dukungan, dan bantuan sehingga penulis bisa menyelesaikan skripsi ini.

Semoga Allah SWT. memberikan nikmat dan hidayah-Nya atas segala perbuatan baik yang telah diberikan kepada peneliti. Peneliti berharap dengan adanya skripsi akan dapat bermanfaat serta menambah ilmu pengetahuan.

Wassalamu'alaikum Warahmatullahi Wabarakatuh

Malang, 6 Februari 2025

Peneliti

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	iii
PERNYATAAN KEASLIAN TULISAN	v
HALAMAN MOTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR TABEL	xii
DAFTAR GAMBAR	xiii
DAFTAR LAMPIRAN	xiv
DAFTAR SIMBOL	xv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	6
1.3 Tujuan Penelitian	6
1.4 Manfaat Penelitian	6
1.5 Batasan Masalah	7
1.6 Definisi Istilah	8
BAB II KAJIAN TEORI	9
2.1 Teori Pendukung	9
2.1.1 <i>Recurrent Neural Network</i>	9
2.1.2 <i>Long Short-Term Memory</i>	10
2.1.3 <i>Machine Learning</i>	19
2.1.4 Saham	20
2.2 Kajian Topik dengan Teori Pendukung	22
2.3 Hukum Transaksi Jual Beli dalam Islam	30
BAB III METODE PENELITIAN	33
3.1 Jenis Penelitian	33
3.2 Data dan Sumber Data	33
3.3 Tahapan Penelitian	33
3.4 Flowchart	37
BAB IV HASIL DAN PEMBAHASAN	39
4.1 Deskripsi Data	39
4.2 <i>Preprocessing</i> Data	40
4.3 Alokasi Data	41
4.4 Kontruksi Model LSTM	42
4.5 Model Hasil LSTM	48
4.6 Prediksi Hasil Harga Saham	49
4.7 Validasi Model LSTM	50
4.8 Proses <i>Forecasting</i>	52
4.9 Analisa Hasil	54

4.10 Hubungan Transaksi Jual Beli Saham pada Model LSTM	54
BAB V KESIMPULAN DAN SARAN	56
5.1 Kesimpulan.....	56
5.2 Saran	57
DAFTAR PUSTAKA	58
LAMPIRAN.....	63

DAFTAR TABEL

Table 2.1 Parameter Model LSTM.....	24
Table 2.2 Kriteria setiap Persentase pada MAPE.....	29
Table 4.2 Evaluasi Akurasi dari Alokasi Data	41
Table 4.3 Parameter Model LSTM.....	42
Table 4.4 <i>Hidden Layer</i> pada Model LSTM dengan 3 <i>layer</i> model	42
Table 4.5 Hasil RMSE dan MAPE.....	50
Table 4.6 Tingkat Akurasi berbagai <i>Epoch</i>	51

DAFTAR GAMBAR

Gambar 2.1 Arsitektur RNN.....	9
Gambar 2.2 Arsitektur LSTM	11
Gambar 2.3 Kompartemen Lengkap LSTM.....	12
Gambar 2.4 Kondisi <i>Cell</i> Diawal Proses (Priyono, 2018)	12
Gambar 2.5 Notasi pada Arsitektur LSTM (Priyono, 2018)	13
Gambar 2.6 <i>Forget gate</i> (Priyono, 2018).	13
Gambar 2.7 <i>Input gate</i> (Priyono, 2018)	15
Gambar 2.8 Proses Pembaruan <i>Cell</i> (Priyono, 2018).....	17
Gambar 2.9 <i>Output gate</i> (Priyono, 2018).....	18
Gambar 3.1 Flowchart Tahapan Model LSTM	37
Gambar 4.1 Grafik Harga Adj Close Saham Kimia Farma.....	39
Gambar 4.2 Hasil Standarisasi Min-Max Scaling	40
Gambar 4.3 Ilustrasi Kompartemen LSTM dengan Parameter serta Hasil	47
Gambar 4.4 Validitas Model <i>Epoch</i> 50 dengan perbandingan 80:20.....	48
Gambar 4.5 Plot Prediksi Harga Saham Kimia Farma 2022-2024.....	49
Gambar 4.6 Hasil Prediksi dengan <i>Epochs</i> 40	53
Gambar 4.7 Prediksi 30 Hari dengan 40 <i>Epoch</i>	53

DAFTAR LAMPIRAN

Lampiran 1.1 Harga saham aktual Kimia Farma Tbk.....	63
Lampiran 1.2 Nilai Hasil Standarisasi dengan <i>Min-Max Scaling</i>	76
Lampiran 1.3 <i>Output</i> Nilai Prediksi dalam 30 Hari Pengamatan.....	76
Lampiran 1.4 Sintaks Python arsitektur LSTM	77

DAFTAR SIMBOL

Simbol yang peneliti gunakan pada penelitian ini adalah:

x_i	:	Variabel data ke- i , $i = 1,2,3, \dots n$
σ	:	Fungsi aktivasi <i>sigmoid</i>
f_t	:	Fungsi dari <i>forget gate</i> ke- t
W	:	Bobot dari variable
s_t	:	<i>State</i> pada waktu ke- t
x_{norm}	:	Data Standarisasi
$\min(x)$	:	Nilai terkecil variabel x
$\max(x)$	:	Nilai terbesar variabel x
x_t	:	Data hasil transformasi x ke- t , $t = 1,2,3, \dots n$
b	:	Bias dari sebuah fungsi
i_t	:	Fungsi dari <i>input gate</i> ke- t
$\tilde{C}_t$	:	Vektor <i>cell state</i>
C_t	:	<i>State</i> sebuah <i>cell</i> pada waktu ke- t
o_t	:	Fungsi dari <i>output gate</i> ke- t
S_t	:	<i>State</i> pada waktu ke- t
A_t	:	Nilai aktual pada waktu ke- t
F_t	:	Nilai hasil prediksi pada waktu ke- t
n	:	Banyaknya data

ABSTRAK

Hariono, Fajar Akbar Samudera. 2025. **Penerapan *Long Short Term Memory* pada Harga *Adjusted Close* Kimia Farma TBK**. Skripsi. Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang.
Pembimbing: (I) Prof. Dr. Sri Harini, M.Si. (II) Ach. Nashicuddin

Kata Kunci: LSTM, harga saham, Kimia Farma, prediksi, epochs, RMSE, MAPE.

Long Short-Term Memory (LSTM) adalah arsitektur berbasis pembelajaran mesin yang digunakan dalam memprediksi harga *Adjusted Close* saham PT Kimia Farma Tbk. LSTM dipilih karena kemampuannya dalam menangani data deret waktu serta mengatasi masalah *long-term dependency* dan *vanishing gradient* yang terdapat pada RNN. Metode penelitian dimulai dari tahapan *preprocessing* data, standarisasi menggunakan teknik *Min-Max Scaling*, pembentukan data sekuensial, pembagian data latih dan data uji dengan perbandingan 80:20, serta pembangunan model LSTM dengan berbagai variasi jumlah epoch (10 hingga 100). Evaluasi akurasi dilakukan menggunakan dua metrik utama, yaitu *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Hasil menunjukkan bahwa model LSTM mampu memprediksi harga saham dengan baik, dengan nilai terbaik dicapai pada epoch ke-70, yaitu RMSE sebesar 26,532 dan MAPE sebesar 4,8%. Temuan ini menunjukkan pentingnya pemilihan jumlah *epoch* yang tepat dalam proses pelatihan model, agar mampu mencapai keseimbangan antara akurasi dan kompleksitas model, sekaligus menghindari risiko *overfitting* yang dapat mengurangi generalisasi terhadap data baru. Secara keseluruhan, penerapan LSTM pada studi ini membuktikan efektivitasnya dalam memprediksi fluktuasi harga saham, serta memberikan kontribusi dalam pengembangan metode prediktif berbasis data historis di bidang keuangan.

ABSTRACT

Hariono, Fajar Akbar Samudera. 2025. **Application of Long Short-Term Memory on the Adjusted Close Price of Kimia Farma Tbk.** Undergraduate Thesis. Department of Mathematics, Faculty of Science and Technology, Universitas Islam Negeri Maulana Malik Ibrahim Malang. **Advisor:** (I) Prof. Dr. Sri Harini, M.Si., (II) Ach. Nashichuddin

Keywords: LSTM, stock price, Kimia Farma, prediction, epochs, RMSE, MAPE.

Long Short-Term Memory (LSTM) is a machine learning-based architecture used to predict the Adjusted Close stock prices of PT Kimia Farma Tbk. LSTM was chosen due to its capability in handling time series data and overcoming issues such as long-term dependency and vanishing gradients commonly found in Recurrent Neural Networks (RNN). The research methodology includes several stages, starting with data preprocessing, standardization using the Min-Max Scaling technique, sequential data formation, data splitting into training and testing sets with a ratio of 80:20, and building the LSTM model with various epoch settings ranging from 10 to 100. Accuracy evaluation was conducted using two main metrics: Root Mean Square Error (RMSE) and Mean Absolute Percentage Error (MAPE). The results showed that the LSTM model could predict stock prices effectively, with the best performance achieved at the 70th epoch, yielding an RMSE of 26,532 and a MAPE of 4,8%. These findings highlight the importance of selecting an appropriate number of epochs during model training to maintain a balance between accuracy and model complexity while avoiding overfitting, which can reduce generalization to new data. Overall, the application of LSTM in this study demonstrates its effectiveness in forecasting stock price fluctuations and contributes to the development of predictive methods based on historical data in the financial sector.

مستخلص البحث

على سعر الإغلاق المعدل لشركة كيميا (LSTM) هاريونو، فجر أكبر سامودرا (٢٠٢٥) تطبيق الذاكرة الطويلة القصيرة الأجل فارما. رسالة جامعة. قسم الدراسة الرياضيات، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج المشرفان) ١: (الأستاذة الدكتورة سري هاريني، الماجستير) ٢٠ (أحمد ناصح الدين

RMSE، MAPE، سعر السهم، كيميا فارما، التنبؤ، الحقب، LSTM: الكلمات المفتاحية

لقد رتقها على التعامل مع بيانات السلاسل الزمنية ومعالجة LSTM تم اختيار (PT Kimia Farma Tbk) كيميا فارما تبدأ منهجية البحث من مرحلة (RNN) مشكلات الاعتماد طويل المدى وتلاشي التدرج التي توجد في الشبكات العصبية المتكررة وتشكيل البيانات التسلسلية، وتقسيم البيانات إلى بيانات Min-Max ما قبل المعالجة للبيانات، والمعيار باستخدام تقنية مقياس مع اختلاف عدد الحقب (من ١٠ إلى ١٠٠). (يتم تقييم الدقة باستخدام LSTM تدريب وبيانات اختبار بنسبة ٨٠:٢٠، وبناء نموذج أظهرت النتائج أن نموذج (MAPE) ومتوسط نسبة الخطأ المطلق (RMSE) مقياسين رئيسيين، وهما متوسط الجذر التربيعي للخطأ بقيمة RMSE قادر على التنبؤ بسعر السهم بشكل جيد، حيث تم الوصول إلى أفضل القيم في الحقب رقم ٧٠، هي LSTM بنسبة ٢٠،٦٧٪ وتُظهر هذه النتائج أهمية اختيار عدد الحقب المناسب في عملية تدريب النموذج، لتحقيق MAPE ٢٧.٥٨٥ و الذي يمكن أن يقلل من التعميم للبيانات (overfitting) التوازن بين الدقة وتعقيد النموذج، وتجنب خطر الإفراط في التكيف في هذه الدراسة فعاليته في التنبؤ بتقلبات أسعار الأسهم، كما يساهم في تطوير أساليب LSTM الجديدة. بشكل عام، يثبت تطبيق تنبؤية تعتمد على البيانات التاريخية في المجال المالي.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Long Short Term Memory (LSTM) adalah pengembangan *Recurrent Neural Network* (RNN) yang dikembangkan oleh Hochreiter dan Schmidhuber pada tahun 1997 (Hochreiter & Schmidhuber, 1997). LSTM merupakan salah satu algoritma yang dirancang untuk mengenali pola dalam urutan data, seperti teks, suara, atau deret waktu, dengan penggunaan *loop* atau pengulangan di dalam strukturnya memungkinkan informasi untuk dipertahankan dan digunakan kembali pada waktu yang berbeda (Goodfellow dkk., 2016). LSTM memiliki struktur unik yang terdiri dari tiga gerbang utama yaitu *forget gate*, *input gate*, dan *output gate* dan adanya *cell state* yang memungkinkan model ini secara dinamis mengatur aliran informasi dan mempertahankan depedensi jangka panjang dalam data (Gers dkk., 1999).

LSTM adalah salah satu jenis pembelajaran mesin (*Machine Learning*) berbasis pendekatan RNN yang diperlukan untuk mempermudah analisa data dengan jumlah yang besar (Wisyalidin dkk., 2020). *Machine Learning* merupakan salah satu cabang dari kecerdasan buatan atau disebut *Artificial Inteligent* (AI) yang dikembangkan untuk secara mandiri mampu mempelajari dan menentukan keputusan tertentu berdasarkan data yang tersedia dan membuat keputusan berdasarkan data tanpa harus berulang kali di program manusia (Cholissodin dkk., 2020). Dalam penggunaannya, *Machine Learning* digunakan untuk mengumpulkan data, melatih model, prediksi, dan sebagainya (Mehtab dkk., 2020). Menurut Bishop, perkembangan teknologi dan ketersediaan data dalam jumlah besar telah

mendorong kemajuan signifikan dalam algoritma *Machine Learning*. Algoritma *Machine Learning* mempelajari pola data historis dan menggunakan pengetahuan tersebut untuk melakukan tugas seperti regresi, klasifikasi, maupun prediksi (Bishop dkk., 2006).

Jenis pembelajaran mesin dengan arsitektur LSTM juga secara khusus dikembangkan untuk mengatasi masalah *vanishing gradient* pada arsitektur RNN. Keterbatasan RNN terletak pada urutan data panjang yang menyebabkan gradien yang dihitung selama backpropagation menjadi sangat kecil atau sangat besar (Bengio dkk., 1994). Keterbatasan ini membuat nilai error menjadi pada hasil prediksi lebih besar. Keterbatasan tersebut dapat di atasi dengan kemampuan LSTM dalam menangkap pola temporal yang kompleks dan menangani data dengan fluktuasi tinggi menjadi instrumen penting dalam analisis data berbasis deret waktu (Brownlee, 2017). Stabilitas pada pelatihan model, LSTM dapat mengendalikan dan mempertahankan stabilitas gradien, bahkan dalam jaringan yang sangat dalam, memungkinkan model untuk berlatih lebih efisien dan efektif (Greff dkk., 2016).

Salah satu penerapan LSTM adalah untuk memprediksi harga saham yang merupakan contoh data deret waktu yang kompleks dan dipengaruhi oleh banyak faktor. Saham sendiri merupakan salah satu investasi paling umum dilakukan di pasar modal. Pada peran ekonomi, pasar modal memiliki peranan penting bagi perekonomian suatu negara, sebagaimana menyediakan sumber pendanaan bagi perusahaan, pasar saham juga memiliki fungsi sebagai indikator kesehatan ekonomi. Pasar saham yang stabil dan berkembang dapat menarik investasi asing dan mendorong pertumbuhan ekonomi (Mishkin & Eakins, 2012).

Merujuk pada penelitian yang membahas tentang prediksi harga saham dengan LSTM (Moghar dkk., 2020). Hasil penelitiannya dengan penerapan LSTM terhadap indeks harga saham adalah hasil pengujian model yang mampu melacak evolusi pada harga pembukaan pada asset GOOGLE dan NKE dengan *epochs* 12, 25, 50, dan 100. Pada penelitian (Rosyd dkk., 2024) yang berjudul “Penerapan Metode *Long Short Term Memory* Dalam Memprediksi Harga Saham PT Bank Central Asia”. Dengan RMSE sebesar 40.85, MAPE sebesar 0.71%, dan MSE sebesar 6662.76, hasil penelitian pada model LSTM dengan optimasi “Adam” menghasilkan grafik prediksi yang baik dengan kemiripan relatif tinggi dengan data nyata. Penelitian ini bertujuan untuk menerapkan model LSTM guna mengetahui keakuratan prediksi data deret waktu. Merujuk pada penelitian di atas, peneliti tertarik menggunakan *Long Short Term Memory* (LSTM) dengan pendekatan *Machine Learning* dengan judul “Penerapan *Long Short Term Memory* pada Harga Adjusted Close Saham PT Kimia Farma Tbk”. Fokus utama penelitian ini adalah untuk mengetahui kinerja LSTM untuk prediksi yang lebih akurat dan membuat keputusan terbaik dalam perdagangan saham.

Adapun penelitian mengenai penerapan LSTM dalam bidang ekonomi pada prediksi harga bahan pokok pada penelitian (Cahyani dkk., 2023). Hasil penelitiannya dengan penerapan LSTM terhadap harga bahan pokok adalah hasil evaluasi RMSE dengan nilai 0.0937, harga kualitas beras untuk kualitas rendah, didapatkan RMSE sebesar 0.049, harga minyak goreng diperoleh RMSE 0.0313. Pada penelitian (Dwika dkk., 2024) yang berjudul “Implementasi Algoritma LSTM untuk Prediksi Harga Cabai Merah Keriting di Yogyakarta”. Hasil penelitian

dengan penerapan LSTM terhadap harga cabai keriting adalah nilai MAPE sebesar 3.6995% dan akurasi sebesar 96.3005%.

Merujuk pada (DSN-MUI, 2024) mengenai transaksi jual beli saham, seperti Fatwa No. 40/DSN-MUI/X/2003: “Tentang Pasar Modal dan Pedoman Umum Penerapan Prinsip Syariah di Bidang Pasar Modal. Fatwa ini menjelaskan bahwa investasi di Pasar Modal Syariah diperbolehkan selama tidak melanggar prinsip Islam” dan Fatwa No. 135/DSN-MUI/V/2020: “Tentang Saham”. Transaksi perdagangan saham disahkan dan diperbolehkan dengan alasan syarat-syaratnya tidak dibuat buat dan saham yang diperjualbelikan adalah saham perusahaan manufaktur atau dagang. Adapun tiga unsur yang harus dilakukan dengan syariat guna menjadikan transaksi jual beli saham dianggap sah dan halal dilakukan, yaitu transaksi saham, saham yang diterbitkan, dan pengelolaan perusahaan atau penerbit saham.

Alasan dari menentukan transaksi saham yang baik sesuai syariat ialah guna tidak menjadikan transaksi merugikan orang lain dengan mengambil keuntungan melebihi takaran yang sudah ditentukan. Sebagaimana terdapat pada Qur'an surah An-Nisa didalam ayat 29, firman Allah *Subhanahu wa Ta'ala* yang berbunyi:

Allah Subhanahu wa Ta'ala berfirman:

يَا أَيُّهَا الَّذِينَ آمَنُوا لَا تَأْكُلُوا أَمْوَالَكُمْ بَيْنَكُمْ بِالْبَاطِلِ إِلَّا أَنْ تَكُونَ تِجَارَةً عَنْ تَرَاضٍ مِنْكُمْ

وَلَا تَقْتُلُوا أَنْفُسَكُمْ إِنَّ اللَّهَ كَانَ بِكُمْ رَحِيمًا

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

Makna ayat di atas menurut tim tafsir kementrian agama, ayat ini melarang untuk merampas harta milik sesama manusia secara curang (Dzalim), kecuali hal hal yang terjadi didasari atas kesepakatan bersama. Transaksi yang secara paksa dilakukan, tidak sah walupun ada penggantian atau bayarannya. Dalam upaya mendapatkan kekayaan, tidak diperkenankan ada unsur zalim dan kekejaman kepada orang lain, seperti pencurian, riba, perjudi, korupsi, penipuan, berbuat kecurangan, mengurangi timbangan, penyuapan, dan sebagainya (*Qur'an Kemenag*, 2024).

Melihat penerapan LSTM pada penelitian di atas, peneliti tertarik menggunakan harga saham PT Kimia Farma Tbk. PT Kimia Farma Tbk merupakan salah satu perusahaan farmasi tertua yang berada di Indonesia yang didirikan pada tahun 1817 (Kimia Farma Tbk, 2024a). Pada tahun 1957, perusahaan ini secara resmi menjadi Badan Usaha Milik Negara dengan nama PT Kimia Farma Persero, dimana perusahaan ini beroperasi dalam bidang medis dan farmasi. Pada tahun 2001, perusahaan ini telah terdaftar pada Bursa Efek Indonesia dan berubah status perusahaan menjadi perusahaan terbuka (Kimia Farma Tbk, 2024a). Tujuan utama didirikannya PT Kimia Farma, adalah untuk memproduksi dan menyediakan obat dan produk kesehatan bagi masyarakat Indonesia (Kimia Farma Tbk, 2024b). Berdasarkan penelitian dan latar belakang perusahaan di atas, peneliti tertarik untuk menerapkan *Long Short Term Memory* berbasis pendekatan *Machine Learning* pada harga saham PT Kimia Farma Tbk sebagai objek penelitian.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan di atas, rumusan masalah dapat dikemukakan sebagai berikut:

1. Bagaimana model LSTM diterapkan dalam prediksi harga *Adjusted Close* pada saham Kimia Farma?
2. Bagaimana perbedaan jumlah *epochs* memengaruhi akurasi pada pemilihan model LSTM dalam prediksi harga *Adjusted Close* saham Kimia Farma?

1.3 Tujuan Penelitian

Menurut penjelasan rumusan masalah di atas, peneliti memiliki tujuan untuk memperoleh informasi sebagai berikut:

1. Menganalisa hasil model LSTM dalam penerapannya memprediksi harga *Adjusted Close* pada saham Kimia Farma
2. Mengetahui bagaimana pengaruh perbedaan jumlah *epochs* pada akurasi model LSTM dalam prediksi harga *Adjusted Close* pada saham Kimia Farma

1.4 Manfaat Penelitian

Manfaat dari yang didapat dari penelitian ini diperoleh sebagai berikut:

1. Bagi Peneliti

Memberikan pengetahuan lebih bagi peneliti tentang penerapan LSTM untuk memodelkan prediksi harga saham PT Kimia Farma Tbk

2. Bagi Pembaca

Sebagai referensi wawasan materi *Machine Learning* terutama mengenai LSTM untuk memodelkan prediksi harga Saham PT Kimia Farma TBK.

3. Bagi Universitas

Sebagai bahan rujukan dalam pengaplikasian ilmu matematika dalam bidang statistika khususnya *Machine Learning* dan LSTM. Diharapkan penelitian ini akan memberikan kontribusi yang berarti dalam pemahaman model LSTM dalam analisis data deret waktu.

4. Bagi PT Kimia Farma Tbk

Sebagai bahan rujukan dalam memahami potensi penerapan model LSTM sebagai alat prediksi dalam memantau pergerakan harga saham perusahaan. Diharapkan perusahaan mampu mengambil keputusan strategis atas pengambilan keputusan terkait manajemen resiko dan perencanaan keuangan.

1.5 Batasan Masalah

Berdasarkan tujuan penelitian di atas, untuk tidak terjadi perluasan masalah sebagai berikut:

1. Peneliti membatasi jumlah *epoch* yang digunakan sebesar 10 hingga 100.
2. Jumlah *batch* yang digunakan hanyalah 4 batch.
3. Fungsi aktivasi dan aktivasi *reccurent* menggunakan bawaan dari library tensorflow LSTM berupa sigmoid dan tanh.
4. Optimizer yang peneliti gunakan adalah standar dari fungsi model sequential LSTM yaitu “Adam”.
5. Jumlah *neuron* pada *input layer* yang digunakan adalah sebesar 50 *neuron*.

1.6 Definisi Istilah

Berdasarkan rumusan masalah yang telah dipaparkan di atas, istilah yang didapat akan didefinisikan sebagai berikut:

Optimalisasi : Suatu proses untuk mencari atau menemukan nilai maksimum atau minimum suatu fungsi dengan mempertimbangkan beberapa batasan yang diberikan.

Epochs : Sebuah Hyperparameter dimana penentuan berapa kali algoritma yang berjalan melewati seluruh dataset melalui jaringan saraf.

Hyperparameter : Sebuah pembelajaran optimal yang menentukan detail proses pembelajaran.

Prediksi : Suatu proses sistematis untuk memperkirakan kejadian dimasa depan berdasarkan informasi tersimpan dari masa lalu hingga masa kini.


BAB II

KAJIAN TEORI

2.1 Teori Pendukung

2.1.1 *Recurrent Neural Network*

Salah satu jenis jaringan saraf yang digunakan dalam memproses urutan data adalah RNN. Sama selayaknya jaringan konvolutional, RNN merupakan jaringan saraf yang dikhususkan dalam memproses variabel nilai X sebagaimana jaringan konvolutional memproses sebuah gambar. RNN sendiri merupakan jaringan saraf yang khusus dalam memproses urutan nilai $x^1, \dots, x^\tau$. RNN dapat dibangun dengan berbagai cara, sebanyak hampir semua fungsi yang yang dianggap jaringan saraf *feedforward* (Goodfellow dkk., 2016). Bentuk arsitektur RNN dapat mengolah informasi hasil urutan data sebelumnya untuk mempengaruhi hasil informasi saat ini (Olah, 2015).



Gambar 2.1 Arsitektur RNN

Pada Gambar 2.1 di atas, RNN memiliki arsitektur yang tersusun dari layer atau lapisan seperti *input layer*, *hidden layer*, dan *output layer*. Lapisan-lapisan neuron tersebut saling terhubung, dimana *output* atau keluaran dari neuron pada waktu t yang tidak hanya mengandalkan pada periode tersebut, tetapi juga pada keluaran atau *output* dari suatu neuron pada waktu $t - 1$. Pada prosesnya, proses sebelah kiri adalah proses diagram RNN sebelum dibuka (*unrolled*) menuju proses sebelah kanan menjadi jaringan penuh (*full network*) sehingga detail proses dari arsitektur RNN menjadi lebih jelas.


Meskipun arsitektur RNN memiliki keunggulan dalam memproses urutan data, RNN memiliki sering menghadapi keterbatasan dalam urutan data panjang karena adanya *Vanishing Gradient*. Keterbatasan ini dikarenakan gradien yang dihitung selama *backpropagation* menjadi sangat kecil atau sangat besar sehingga menghambat prosesnya (Bengio dkk., 1994). Solusi untuk mengatasi masalah *vanishing gradient* adalah memodifikasi arsitektur RNN dengan model arsitektur yang khusus dirancang untuk menyimpan data dengan periode waktu yang panjang. Arsitektur tersebut adalah *Long Short Term Memory* (LSTM).

2.1.2 Long Short-Term Memory

Pada tahun 1977, terjadi adanya pengembangan RNN yang dikembangkan oleh Hochreiter dan Schmidhuber adalah LSTM. Pengembangan LSTM dirancang khusus untuk mengatasi masalah *vanishing gradient* dan mampu menyimpan data dan informasi dalam periode waktu yang begitu lama. LSTM memiliki struktur unik yang terdiri dari tiga gerbang utama yaitu *forget gate*, *input gate*, dan *output gate* dan *cell state*, yang memungkinkan model ini secara dinamis mengatur aliran


informasi dan mempertahankan depedensi jangka panjang dalam data (Gers dkk., 1999).

Pada arsitektur LSTM memungkinkan dalam setiap gerbang menyimpan bobot (*Weight*) dari suatu perhitungan lebih lama dari RNN, hal ini disebabkan LSTM memiliki sel sel yakni sebuah *node* yang memiliki *self reccurent*. Bobot pada LSTM diinisialisasi dengan metode *Glorot Uniform (Xavier Initialization)* yang bertujuan mencegah masalah gradien yang meledak atau menghilang. Inisialisasi ini dilakukan sebelum pelatihan dimulai sehingga membuat nilai bobot menjadi acak dalam rentang tertentu (Rosebrock, 2021).



Gambar 2.2 Arsitektur LSTM


Dari gambar 2.2, sebuah sel tidak hanya menerima masukan ke x_t , tapi juga menerima *state* sebelumnya S_{t-1} , dan sel sebelumnya C_{t-1} , yang dimana pada sel saat ini menghasilkan C_t dan S_t yang akan digunakan sel selanjutnya. Sel sel pada LSTM saling berhubungan dimana sel sebelumnya akan mempengaruhi hasil *output* pada sel saat ini, dan untuk sel saat ini akan digunakan untuk perhitungan pada sel selanjutnya.



Gambar 2.3 Kompartemen Lengkap LSTM

LSTM sendiri terbagi menjadi beberapa kompartemen bagian sebagaimana pada setiap prosesnya ada gerbang dan fungsi aktivasi yang dilalui. Adapun kompartemen bagian LSTM Adapun penjelasan setiap proses menurut (Priyono, 2018) dan ide ide kunci pada proses LSTM sebagaimana:

1. Cell State



Gambar 2.4 Kondisi *Cell* Diawal Proses (Priyono, 2018)


Dari jalur di atas, suatu nilai akan dipengaruhi oleh *Cell* lama dan akan diteruskan menuju *Cell* baru dengan adanya sedikit modifikasi yang terjadi. Dalam hal ini, *Cell* adalah sebuah vektor ($\tilde{C}_t$) dimana jumlah elemen akan ditentukan menyesuaikan model LSTM yang akan dirancang. Setiap elemen akan diposisikan sedemikian sehingga dapat digunakan untuk merekam suatu *input* atau masukan seperti suatu perekaman elemen dari subjek, pemrosesan bahasa alami untuk bahasa inggris dan sebagainya (Priyono, 2018). Fitur fitur ini terdapat pada proses latihan pada LSTM.

Adapun bentuk notasi pada LSTM sendiri



Gambar 2.5 Notasi pada Arsitektur LSTM (Priyono, 2018)

2. *Forget gate*



Gambar 2.6 *Forget gate* (Priyono, 2018).

Proses *forget gate* adalah proses penyimpanan suatu informasi yang diperlukan dan menghilangkan informasi yang tidak relevan. Proses ini dilakukan oleh *layer sigmoid* pada *layer forget gate*. Proses ini terdapat data masukan pada periode tertentu (x_t) dan hasil output pada sel sebelumnya (S_{t-1}). Pada gambar 2.5, proses S_{t-1} dan x_t memiliki hasil keluaran berupa 0 dan 1 yang dimana keluaran 0 akan membuang sebuah informasi, dan 1 akan mengambil dan menjadi informasi tersebut.

Fungsi *sigmoid* bertujuan mentransformasi nilai antara -1 dan 1 menjadi nilai 0 dan 1 untuk mengatur seberapa banyak informasi bisa lewat (Priyono, 2018). Adapun persamaan *forget gate* serta fungsi *sigmoid* dapat diuraikan dalam persamaan (2.1), Rumus fungsi *sigmoid* sebagai berikut (Liu, 2020):

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.1)$$

di mana:

$\sigma(x)$: Fungsi aktivasi *sigmoid*

e^{-x} : Eksponensial

Kemudian *forget gate* dengan persamaan:

$$f_t = \sigma(W_f \cdot [s_{t-1}, x_t] + b_f) \quad (2.2)$$

di mana:

f_t : *Forget gate*

σ : Fungsi aktivasi *Sigmoid*


W_f : Bobot dari *forget gate*

S_{t-1} : State pada waktu $t - 1$

x_t : Input pada waktu t

b_f : Bias dari *Forget gate*

3. *Input gate*



Gambar 2.7 *Input gate* (Priyono, 2018)

Pada proses *Input gate* adalah proses penentuan informasi mutakhir yang akan dimuat pada *Cell state*. Tahapan pada gerbang input terdiri dari dua bagian, yang pertama *layer sigmoid* yang akan menentukan nilai mana yang kita inginkan. Kemudian *layer tanh* membuat vektor baru yang berisi nilai dari kandidat baru. Lapisan tanh tersebut menghasilkan vektor *cell* baru, $\tilde{C}_t$. Nilai yang dihasilkan oleh lapisan tanh berupa -1 dan 1 yang mengandung semua nilai yang diperoleh dari S_{t-1} dan x_t . Kemudian penggabungan antara keduanya untuk memperbarui keadaan *state*. Adapun persamaan pada *input gate* dapat diuraikan dengan persamaan sebagai berikut:

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

di mana:

- i_t : *Input gate*
- σ : Fungsi aktivasi *Sigmoid*
- W_i : Bobot dari *input gate*
- S_{t-1} : *State* pada waktu $t - 1$
- x_t : *Input* pada waktu t
- b_i : Bias dari *input gate*

Kemudian menghitung *Cell* dengan rumus:

$$\tilde{C}_t = \tanh(W_C \cdot [S_{t-1}, x_t] + b_C) \quad (2.4)$$


di mana:

- $\tilde{C}_t$: *Cell state*
- W_C : Bobot dari *cell state*
- S_{t-1} : *State* sebelumnya atau *state* pada waktu $t - 1$
- x_t : *Input* pada waktu t
- b_C : Bias dari *cell state*

Kemudian fungsi tanh

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.5)$$

4. Cell Process



Gambar 2.8 Proses Pembaruan *Cell* (Priyono, 2018)

Setelah melalui dua gerbang (*forget gate* dan *input gate*), tahap ini adalah pembaruan *cell* sebelumnya atau *cell* lama ($\tilde{C}_{t-1}$) menjadi *cell* baru ($\tilde{C}_t$). Dengan mengalikan pada *cell* sebelumnya dengan f_t , menghilangkan informasi tidak relevan, kemudian ditambah dengan proses $i_t * \tilde{C}_t$. *Cell process* adalah pembaruan dari *cell* lama $\tilde{C}_{t-1}$ ke *cell* baru $\tilde{C}_t$ dengan melalui persamaan:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (2.6)$$

di mana:

C_t : *Cell state* yang baru


f_t : *Forget gate*

C_{t-1} : *Cell state* lama

i_t : *Input gate*

$\tilde{C}_t$: Kandidat *cell* untuk *cell state* yang baru pada waktu ke- t

5. Output gate



Gambar 2.9 Output gate (Priyono, 2018)

Pada tahap *Output gate*, menurut (Olah, 2015), terdapat 3 bagian, yang pertama adalah menjalankan *layer sigmoid* untuk menentukan bagian yang mana dari *cell state* untuk menuju pada *output*. Bagian ini digunakan untuk memutuskan informasi yang akan dihasilkan. Bagian kedua adalah meletakkan *cell state* melalui *tanh* (berfungsi mengubah nilai bernilai diantara -1 dan 1), dan bagian ketiga adalah mengalikannya dengan keluaran gerbang *sigmoid*, sehingga menghasilkan sebagian keluaran yang telah ditentukan sebelumnya. Adapun persamaan *output gate* dan state cell baru akan diuraikan sebagai berikut:

$$o_t = \sigma(W_o \cdot [s_{t-1}, x_t] + b_o) \quad (2.7)$$

di mana:

o_t : Output gate

- σ : Fungsi aktivasi *sigmoid*
 W_o : Bobot dari *output gate*
 S_{t-1} : *State* sebelumnya ata *state* pada waktu $t - 1$
 x_t : *Input* pada waktu ke t
 b_o : Bias pada *output gate*

$$S_t = o_t \cdot \tanh(C_t) \quad (2.8)$$

di mana:

- S_t : *State* saat ini
 o_t : *Output gate*
 C_t : Kandidat *cell* untuk *cell state* yang baru pada waktu ke- t

Gambar gambar di atas menunjukkan setiap proses pada arsitektur LSTM, Adapun penjelasan setiap proses dan ide ide kunci pada proses LSTM menurut (Priyono, 2018). LSTM adalah salah satu jenis pembelajaran mesin berbasis pendekatan RNN yang memerlukan untuk mempermudah analisa data dengan jumlah yang besar (Wisyalidin dkk., 2020).

2.1.3 *Machine Learning*

LSTM merupakan jenis *Machine Learning* berbasis pendekatan RNN yang diperlukan untuk mempermudah analisa data dengan jumlah yang besar (Wisyalidin dkk., 2020). *Machine Learning* sendiri merupakan salah satu cabarng dari kecerdasan buatan atau yang dikembangkan untuk secara mandiri mampu

mempelajari dan menentukan keputusan tertentu berdasarkan data yang tersedia dan mampu membuat keputusan berdasarkan data tanpa harus berulang kali di program manusia (Cholissodin dkk., 2020). Dalam penggunaannya, *Machine Learning* digunakan untuk mengumpulkan data, melatih model, prediksi, dan sebagainya (Mehtab dkk., 2020).

Machine Learning terjadi melalui 2 fase, yaitu fase pelatihan dan fase penerapan. Fase pelatihan (*training*) merupakan proses pemodelan dari algoritma yang dipelajari oleh sistem berdasarkan data yang dilatih. Disisi lain, fase penerapan (*application*) merupakan proses pemodelan yang dipelajari setelah melalui fase pelatihan dan digunakan untuk mengambil keputusan tertentu. Dalam pengaplikasian *Machine Learning* dalam LSTM, terdapat *Deep learning* yang dimana merupakan sub bagian dari *Machine Learning* yang mempunyai kemampuan untuk menangani dan menganalisa sejumlah besar data, terutama yang menggunakan jaringan saraf dengan banyak lapisan tersembunyi (Bhandari dkk., 2022). Salah satu penerapan *Machine Learning* dengan menggunakan algoritma LSTM adalah untuk memprediksi harga saham yang merupakan contoh data deret waktu yang kompleks dan dipengaruhi oleh banyak faktor.

2.1.4 Saham

Saham sendiri merupakan sarana investasi paling umum dilakukan oleh pada investor karena dapat menghasilkan *profit return* yang menarik. Saham sendiri memiliki pengertian dimana saham adalah suatu dokumen berharga yang mampu mewakili sebagian kepemilikan dari suatu perusahaan. Artinya, orang yang telah membeli saham, secara langsung orang tersebut memiliki sebagian

kepemilikan perusahaan yang telah dibelinya (Soebiantoro, 2021). Pasar saham memainkan peran penting dalam perekonomian suatu negara, sebagaimana menyediakan sumber pendanaan bagi perusahaan, pasar saham juga memiliki fungsi sebagai indikator kesehatan ekonomi. Pasar saham yang stabil dan berkembang dapat menarik investasi asing dan mendorong pertumbuhan ekonomi (Mishkin & Eakins, 2012). Saham sendiri diperdagangkan dalam pasar modal, dimana saham-saham perusahaan menjual belikan saham mereka kepada investor maupun publik. Dalam sejarahnya, pasar modal telah hadir bahkan sebelum Indonesia merdeka. Pasar modal atau bursa efek sudah ada sejak jaman kolonial Belanda, lebih akuratnya pada tahun 1912 yang didirikan dan dikelola oleh pemerintah Hindia Belanda demi kepentingan pemerintah kolonial (PT. Bursa Efek Indonesia, 2024).

Jenis jenis saham, menurut (Soebiantoro, 2021), saham biasa dan saham preferen. *Common stocks* atau disebut saham biasa adalah suatu saham yang dapat dibeli berdasarkan keuntungan dan kerugian perusahaan. Sedangkan mengenai saham preferen, yaitu jenis saham dengan nilai pembagian keuntungannya tergolong tetap, dan apabila perusahaan mengalami kerugian, maka para pemegang saham preferen memiliki prioritas utama dalam hal membagi hasil penjualan aset kekayaan perusahaan.

Adapun jenis saham berdasarkan kinerjanya, seperti *blue chip*, *income stocks*, *growth stock*. Saham *blue chip stocks* adalah suatu perusahaan besar yang telah dipercaya oleh investor. Saham ini cenderung memiliki harga stabil walaupun harga satuannya memiliki harga yang tinggi. Sedangkan *income stocks* adalah jenis saham yang diharapkan memberikan dividen yang tinggi, namun

juga memiliki resiko yang sama besarnya. Sementara itu *growth stock* adalah jenis saham yang memiliki perkembangan yang mengungguli jenis saham lain yang disektor yang sama. Harga saham ini bisa meningkat atau menurun beberapa kali dalam sehari.

Naik turunnya suatu harga saham dalam pasar modal biasanya dipengaruhi faktor faktor internal maupun eksternal. Adapun faktor internal seperti kinerja keuangan sebuah perusahaan, manajemen, maupun pengumuman dividen. Dalam faktor eksternal, harga saham dipengaruhi kondisi ekonomi seperti inflasi, suku bunga, dan pertumbuhan ekonomi suatu negara, adapun kebijakan pemerintah dan sentimen pasar (Toin & Sutrisno, 2016).

2.2 Kajian Topik dengan Teori Pendukung

Berdasarkan teori pendukung penelitian ini dapat dikaji melalui beberapa tahapan yang dapat disusun dari beberapa kerangka pikiran. Prediksi data deret waktu adalah salah satu bidang analisis data yang penting, terutama ketika memprediksi harga saham dengan karakteristik non-linear yang tidak berfluktuasi. Dalam penelitian ini, metode (LSTM) dapat digunakan sebagai pendekatan untuk prediksi harga saham karena kemampuannya dalam menangkap pola jangka panjang dalam data. Proses prediksi ini melibatkan beberapa tahapan yang dimulai *preprocessing* data dengan standarisasi data sebagai langkah pertama untuk mempermudah konvergensi model, kemudian menentukan periode prediksi sebagai dasar untuk pembentukan data pelatihan dan pengujian data, dan menentukan periode perkiraan sebagai konstruksi model LSTM dengan arsitektur yang dievaluasi berdasarkan jumlah *epoch* dan parameter lainnya untuk mengevaluasi

tahapannya. Setiap tahap dilakukan untuk memungkinkan model yang dihasilkan untuk memberikan hasil yang diprediksi pada tingkat akurasi yang optimal. Adapun teori pendukung dapat diuraikan sebagai berikut:

1. *Preprocessing Data*

Preprocessing data adalah tahap awal untuk mempersiapkan data sebelum pemodelan LSTM. Data mentah yang didapat perlu diproses terlebih dahulu jika terdapat data tidak valid, atau nilai yang hilang. Data yang sudah diproses akan dilakukan standarisasi data untuk mengubah skala data agar memiliki semua bobot yang sama, dan membantu mempercepat konvergensi model LSTM. Standarisasi yang dilakukan menggunakan *min-max scaling* dengan rumus matematika sebagai berikut:

$$x_{std} = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (2.9)$$

di mana:

- x_i : Data ke- i
- x_{std} : Data yang telah di standarisasi
- $\min(x)$: Nilai terkecil dari dataset x
- $\max(x)$: Nilai terbesar dari dataset x

2. Menentukan Periode Prediksi

Setelah melakukan standarisasi pada data, perlu ditentukan berapa urutan periode data yang dilihat dari masa lalu dan yang akan diprediksi kedepan. Tahap ini bertujuan untuk menentukan berapa jumlah prediksi yang akan dilakukan dengan menganalisa seberapa banyak dan bagaimana data historis

berjalan. Kemudian menjadikan data yang dilihat dari masa lalu menjadi x dan data yang akan diprediksi sebanyak n menjadi variabel y , dan mengubah x dan y menjadi sebuah *array*.

3. Kontruksi Model LSTM

Pada tahap ini pembuatan sebuah model yang dibuat berdasarkan parameter parameter yang ingin digunakan. Parameter yang akan digunakan disajikan dalam Tabel 2.1.

Table 2.1 Parameter Model LSTM

Parameter	Keterangan
Jumlah <i>input layer</i>	1 <i>neuron</i>
Jumlah <i>hidden layer</i>	2 <i>layer</i> dengan 50 neuron pada setiap layer
Jumlah <i>dense layer</i>	n_forecast
Nilai <i>batch size</i>	4
Nilai <i>epochs</i>	10~100
Fungsi aktivasi	<i>Sigmoid</i> , tanh
Optimizer	Adam
Bias	1

Parameter dalah sebuah komponen yang mempengaruhi proses pembelajaran model dan hasil akhir dari prediksi. Sehingga penentuan parameter pada *neural network* ditentukan terlebih dahulu sebagaimana:

(a) *Input layer*

Input layer berfungsi sebagai sebuah pintu masuk data dan tidak memiliki parameter yang mampu dilatih pada lapisannya. *Input layer* menyesuaikan jumlah fitur pada data sehingga ditentukan secara otomatis memiliki 1 neuron.

(b) *Hidden layer*

Hidden layer berfungsi untuk menangkap pola data historis secara sekuensial. Menurut penelitian (Febbi dkk., 2021) tidak ada formula atau rumus khusus dalam penentuan neuron pada hidden layer, penentuan neuron tergantung pada pengujian yang dilakukan.

(c) *Dense layer*

Dense layer digunakan untuk menghasilkan output dengan jumlah neuron sebanyak $n_forecast$ yang merepresentasikan periode prediksi yang dilakukan.

(d) *Batch size*

Batch size adalah parameter yang menentukan seberapa banyak data yang dikelompokkan untuk dilakukan proses prediksi model. Menurut (Kustiyo dkk., 2022) penggunaan jumlah batch senilai 16 mampu menghasilkan nilai MAPE sebesar 9%. Pada penelitian ini setelah melakukan eksperimen, didapatkan nilai batch sebesar 4.

(e) Nilai *epochs*

Nilai *epoch* ditentukan sebesar 10, 20, 30,... 100 adalah parameter yang ditentukan untuk menjawab rumusan masalah.

(f) Fungsi aktivasi *sigmoid* dan *tanh*

Dalam penelitian ini fungsi aktivasi sigmoid digunakan untuk membantu mestandarisasi nilai *output* dari *input* manapun dengan rentang 0 sampai 1. Kegunaan utama dari fungsi sigmoid adalah menjaga *output* atau nilai prediksi dalam rentang yang ditentukan, sehingga dapat menjaga efisiensi dan akurasi sebuah model (Kumar, 2020). Sedangkan pada fungsi aktivasi Tanh digunakan untuk memetakan nilai input yang lebih panjang dengan rentang -1 sampai 1. Hal ini membuat fungsi tanh lebih efektif menangani data yang bersifat simetris dibandingkan dengan fungsi sigmoid yang memiliki rentang 0 sampai 1. Fungsi aktivasi tanh digunakan dalam proses cell yang menuju state sebuah cell (Kumar, 2020).

(g) Optimizer

Optimizer Adam (Adaptive Moment Estimation) adalah metode optimalisasi yang menggabungkan keunggulan RMSProp dan momentum. RMSProp adalah teknik pengoptimalan berbasis gradien yang dikembangkan sebagai Teknik stokastik. RMSProp mampu menangani masalah dengan menggunakan rata-rata bergerak gradien kuadrat untuk menormalkan gradien. Standarisasi ini mampu menyeimbangkan momentum, dan mengurangi langkah untuk gradien besar agar tidak meledak dan meningkatkan langkah bagi gradien kecil untuk tidak menghilang (Kingma & Ba, 2014).

(h) Bias

Bias dalam model LSTM adalah sebuah parameter yang terdapat dalam setiap gate dan cell yang dipergunakan untuk membantu model dalam belajar pola pada data. Sebagaimana dalam LSTM terdapat bias dari *forget gate* (b_f), bias *input gate* (b_i), bias *output gate* (b_o), dan bias *cell state* (b_c). Nilai bias pada *forget gate* sendiri memiliki nilai bawaan senilai 1 sebagaimana nilai unit *forget bias* bias bernilai *True* (Keras.io, 2025) Adapun menurut penelitian dari (Gers dkk., 1999) mengenai "*Learning to Forget: Continual Prediction with LSTM.*" dengan menginisialisasi nilai bias pada *forget gate* ke nilai tinggi untuk meningkatkan penyimpanan memori. Menurut (Jozefowicz dkk., 2015) mengenai bias, menemukan bahwa berbagai konfigurasi nilai bias sendiri berpengaruh akan stabilitas model tersebut.

(i) Bobot

Pada setiap gerbang diberikan bobot masing masing dengan pengoptimalan dengan *glorot uniform/ xavier initialization*. Pengoptimalan bobot ini dilakukan demi menjaga agar tidak terjadi *vanishing gradien*, dan menjaga stabilitas dalam pelatihan model. Adapun persamaannya menurut (Glorot dkk., 2010) sebagai berikut:

$$W = \left[-\frac{\sqrt{6}}{\sqrt{n_{in} + n_{out}}}, \frac{\sqrt{6}}{\sqrt{n_{in} + n_{out}}} \right] \quad (2.10)$$

di mana:

W : Bobot dari Insialisasi Xavier

n_{in} : Neuron *input*

n_{out} : Neuron *output*

Jumlah neuron *input* (n_{in}) dan *output* (n_{out}) dalam LSTM bergantung pada arsitektur model yang digunakannya, neuron *input* sendiri ditentukan dari jumlah fitur yang tersedia ketika *input* data seperti harga saham harian, dimana hanya 1 fitur maka neuron *input* bernilai 1. Sedangkan untuk Neuron *output* ditentukan oleh jumlah lapisan yang sedang dihitung.

4. Prediksi Data

Tahap ini dilakukan setelah proses *test* berjalan dengan parameter yang ditentukan sebelumnya. Prediksi data ini mengubah skala yang telah ditransformasi sebelumnya menjadi bentuk semula untuk diprediksi. Hasil prediksi dari berbagai parameter yang ditentukan akan di visualisasi menjadi plot.

5. Evaluasi Akurasi

Proses evaluasi akurasi dilakukan untuk melihat tingkat keakuratan sebuah model dengan metode RMSE (*Root Mean Square Error*) dan MAPE (*Mean Absolute Percentage Error*). RMSE adalah akar kuadrat dari *Mean Square Error* dari semua kesalahan. Nilai RMSE sendiri jika mendekati 0 maka model dikatakan semakin baik. Adapun persamaan RMSE dan MAPE menurut (Boshnakov, 2016) sebagai berikut.

Persamaan RMSE:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (2.11)$$

di mana:

y_i : Nilai aktual
 $\hat{y}_i$: Nilai prediksi
 n : Jumlah data

Adapun MAPE merupakan rata rata absolut persentase antara nilai prediksi dengan nilai aktual. Adapun kriteria untuk MAPE yaitu:

Table 2.2 Kriteria setiap Persentase pada MAPE

Persentase	Kriteria
< 10%	Sangat Baik
10% – 20%	Baik
21% – 50%	Cukup
> 50%	Buruk

Adapun persamaan MAPE adalah sebagai berikut:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{n} \right| \quad (2.12)$$

di mana:

y_i : Nilai aktual
 $\hat{y}_i$: Nilai prediksi

n : Jumlah data

2.3 Hukum Transaksi Jual Beli dalam Islam

Dalam dunia bisnis, transaksi jual beli merupakan hal yang lumrah terjadi, sebagaimana transaksi dalam jangka pendek, atau transaksi jangka panjang. Dalam konteks saham, transaksi jangka panjang biasanya dilakukan guna memberikan profit atau keuntungan pada waktu dimasa depan. Pembelian ini dinamakan investasi, menurut (Suta, 2000) investasi adalah menempatkan sejumlah uang dengan harapan dapat dipertahankan, ditingkatkan nilainya, atau memberikan keuntungan yang positif. Kegiatan menukarkan antara barang dengan uang, antara benda dan barang lainnya dengan cara menyerahkan atau memindahkan hak kepemilikan kepada penggantinya dengan cara yang diperbolehkan (Suhendi, 2019). Sebagaimana dalam Islam, transaksi jual beli diatur sedemikian rupa sehingga transaksi yang dilakukan sah, halal dan tidak merugikan pihak lainnya yang terlibat transaksi ini.

Alasan dari menentukan transaksi yang baik sesuai syariat islam ialah guna tidak menjadikan transaksi merugikan orang lain dengan mengambil keuntungan melebihi takaran yang sudah ditentukan. Sebagaimana terdapat pada Al-Qur'an, pada surah An-Nisa ayat 29:

Allah Subhanahu wa Ta'ala berfirman:

يَا أَيُّهَا الَّذِينَ آمَنُوا لَا تَأْكُلُوا أَمْوَالَكُمْ بَيْنَكُمْ بِالْبَاطِلِ إِلَّا أَنْ تَكُونَ تِجَارَةً عَنْ تَرَاضٍ مِّنْكُمْ

وَلَا تَقْتُلُوا أَنْفُسَكُمْ ۚ إِنَّ اللَّهَ كَانَ بِكُمْ رَحِيمًا

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

Maksud dari ayat di atas menurut tim tafsir kemenag, ayat ini melarang mengambil harta milik orang lain secara curang (tidak benar), kecuali hal hal yang terjadi atas dasar kesepakatan bersama. Transaksi yang secara paksa dilakukan, tidak sah walupun ada penggantian atau bayarannya. Dalam upaya mendapatkan kekayaan, tidak diperkenankan ada unsur zalim dan kekejaman kepada orang lain, seperti pencurian, riba, perjudi, korupsi, penipuan, berbuat kecurangan, mengurangi timbangan, penyuapan, dan sebagainya (*Qur'an Kemenag*, 2024).

Secara ijma', para ulama pun sepakat akan halalnya jual beli. Begitu pula berdasarkan qiyas. Manusia tentu amat butuh dengan jual beli. Ada ketergantungan antara manusia dan lainnya dalam hal memperoleh uang dan barang. Tidak mungkin hal itu diberi cuma-cuma melainkan dengan timbal balik. Oleh karena itu berdasarkan hikmah, jual beli itu dibolehkan untuk mencapai hal yang dimaksud. Hukum asal jual beli itu hal, namun bisa keluar dari hukum asal jika terdapat pelanggaran-pelanggaran syari'at. Sehingga dikenal ada jual beli yang terlarang (Salim, 2017).

Adapun menurut hadist Nabi riwayat Ibnu Majah dari Ubaidah bin Shamit riwayat Ahmad dari Ibnu Abbas, dan riwayat Imam Malik dari Yahya:

لَا ضَرَرَ وَلَا ضِرَارَ {رَوَاهُ أَحْمَدُ، وَابْنُ مَاجَةَ¹ }.

Artinya: *“Tidak boleh membahayakan diri sendiri dan tidak boleh pula membahayakan orang lain.”*

Sebagaimana dalam pasar modal, transaksi saham sebuah perusahaan diperjualbelikan untuk publik, terlebih dahulu dianjurkan untuk mencari dan mengumpulkan berbagai informasi mengenai saham yang akan diperjualbelikan tersebut untuk menghindari kecurangan atau ketidakpastian. Adapun merujuk pada (DSN-MUI, 2024) mengenai transaksi jual beli saham, seperti Fatwa No. 40/DSN-MUI/X/2003: “Tentang Pasar Modal dan Pedoman Umum Penerapan Prinsip Syariah di Bidang Pasar Modal. Fatwa ini menjelaskan bahwa investasi di Pasar Modal Syariah diperbolehkan selama tidak melanggar prinsip Islam” dan Fatwa No. 135/DSN-MUI/V/2020: “Tentang Saham”. Saham yang diperjualbelikan adalah saham perusahaan dagang atau manufaktur dan syarat-syaratnya nyata, bukan rekayasa, maka hukum jual beli saham diperbolehkan. Adapun tiga unsur yang harus dilakukan dengan syariat guna menjadikan jual beli saham, penerbitan saham, dan manajemen perusahaan atau penerbit saham dianggap halal dan dapat dilakukan secara sah.

BAB III METODE PENELITIAN

3.1 Jenis Penelitian

Pada penelitian ini menggunakan jenis penelitian kuantitatif. Penelitian jenis kuantitatif ini berfungsi untuk mempermudah peneliti dalam penyusunan dan analisis data berupa angka, sehingga sesuai dengan yang diharapkan oleh peneliti. Dengan tujuan yang telah peneliti paparkan sebelumnya yaitu untuk mengetahui model LSTM dalam prediksi data harga *Adjusted Close* saham kimia farma, dan mengetahui tingkat akurasi model dengan menggunakan berbagai *epochs* yang telah ditentukan.

3.2 Data dan Sumber Data

Penelitian ini menggunakan data sekunder dimana data sekunder merupakan data penelitian tidak langsung yang diperoleh peneliti melalui media perantara (diperoleh atau dicatat oleh pihak lain) (Nur Indrianto, 2013). Data yang digunakan pada penelitian ini adalah data pada periode 6 Januari 2022 hingga 21 Oktober 2024, dimana penulis mengakses data harga saham PT Kimia Farma Tbk secara *online* melalui website (Yahoo Finance, 2024).

3.3 Tahapan Penelitian

Data harga saham PT Kimia Farma Tbk periode 6 Januari 2022 hingga 21 Oktober 2024 akan diolah oleh peneliti menggunakan *Long Short-Term Memory* dengan langkah-langkah sebagai berikut:

1. Persiapan data

Tahapan pertama yang dilakukan adalah mempersiapkan data harga saham yang terdiri dari fitur *Date* dan *Adjusted Close*.

2. *Preprocessing* data

Tahap *Preprocessing* adalah tahapan data sebelum diproses menjadi model LSTM. Tahapan ini adalah standarisasi data untuk mengubah skala data agar memiliki bobot dan bentuk data yang sama, hal ini guna membantu mempercepat konvergensi ke model LSTM. Standarisasi juga digunakan untuk meminimalisir kesalahan saat uji model, dengan menggunakan teknik standarisasi *min-max scaling* pada persamaan (2.9). Proses standarisasi data ditulis menggunakan bahasa pemrograman python dengan menghitung nilai minimum dan maximum dari array dataset harga saham kimia farma yang belum di standarisasi.

3. Alokasi Data

Data pada penelitian ini dialokasikan menjadi dua jenis, yaitu data *training* atau data pembelajaran dan data *testing* atau data uji. Pembagian data untuk model prediksi yang dibangun dibagi dengan perbandingan 80:20 dimana sebanyak 80% dari total data akan dijadikan data *training* dan 20% lainnya akan dijadikan data *testing*. Kombinasi ini dipilih berdasarkan hasil uji coba serta pertimbangan penulis setelah dilakukan percobaan terhadap beberapa perbandingan jumlah data *testing* dan data *training*.

4. Kontruksi Model LSTM

Pembangunan model LSTM terdiri dari 3 *layer* utama yaitu *input layer*, *hidden layer*, dan *output layer*. Dimana setiap layer memiliki perbedaan

fungsi, dimana *input layer* berfungsi sebagai menyimpan nilai masukan disetiap *node* nya. *Hidden layer* digunakan untuk mengurangi kesalahan yang muncul pada *output*. Dan *output layer* berfungsi untuk menampilkan hasil perhitungan system yang telah dilakukan (LeCun dkk., 2015). dilakukan dari data yang menuju *forget gate* dengan adanya fungsi aktivasi sigmoid, dengan persamaan (2.1) fungsi aktivasi sigmoid dan persamaan (2.2) *forget gate*. Setelah melalui *forget gate*, proses dilanjutkan dengan menuju *input gate* dengan persamaan (2.3), dan menuju vektor *cell state* dengan persamaan (2.4) kemudian melewati fungsi *reccurent tanh* dengan persmaan (2.5).

Setelah melalui fungsi *recurrent* data dari *forget layer* dan *input layer* menuju ke *cell state* lama untuk membuat *cell state* baru, kemudian dari *cell state* baru menuju *output gate* dengan persamaan sebagai berikut:

Persamaan (2.6) *cell process*, persamaan (2.7) *output gate* dan (2.8) state baru. *output gate* dan state cell baru

5. Model Hasil LSTM

Proses ini dilakukan pada *training* data dengan model LSTM yang dilakukan dengan menghitung semua fungsi unit unit gerbang pada setiap neuronnya. Data yang akan diproses secara urut melalui fungsi gerbang dari *forget gates*, *input gates*, dan *output gates*. Data kemudian melalui fungsi aktivasi, dan melakukan perulangan sebanyak *epochs* yang telah ditentukan.

6. Validasi Model LSTM

Proses validasi ini dilakukan menggunakan model dari data *training* pada data testing didapatkan dari hasil *Preprocessing* dan alokasi data yang

ditentukan, kemudian dilakukan evaluasi akurasi model.

7. Evaluasi Akurasi Model Hasil Testing

Hasil model LSTM yang sudah didapatkan akan dihitung nilai akurasi dengan RMSE dan MAPE, dimana RMSE adalah jumlah kesalahan kuadrat atau selisih antara nilai aktual dengan nilai prediksi yang didapatkan. Sedangkan MAPE adalah perhitungan rata rata dari selisih persentase nilai aktual dan nilai hasil prediksi.

8. Proses *Forecasting* 30 Hari Mendatang

Proses *forecasting* dilakukan dengan menentukan seberapa banyak data historis sebagai acuan *forecast* harga saham sebanyak 30 pengamatan kedepan. Sebelum adanya proses forecasting, diperlukan *Inverse Transforms* atau pengubahan skala menjadi semula, hal ini dilakukan agar bisa dilakukan visualisasi data dengan hasil *forecast*. Kemudian menggunakan model LSTM yang dengan parameter yang telah diuji dengan data latih dan dilakukan pemodelan harga saham kimia farma.


9. Visualisasi dan Analisa Hasil

Memvisualisasikan plot hasil prediksi yang telah diuji akurasi sebelumnya. Hasil yang terbentuk dibedakan dengan seberapa banyak *epochs* yang ditentukan. Kemudian dilakukan analisa dari berbagai visualisasi yang dipilih dan data prediksi yang tersedia


10. Output

Output yang dihasilkan pada proses LSTM adalah penerapa model LSTM sendiri pada harga saham Kimia Farma Tbk dan perbedaan *epochs* pada akurasi prediksi.

3.4 Flowchart



Gambar 3.1 Flowchart Tahapan Model LSTM



Gambar 3.1 Flowchart Tahapan Model LSTM


BAB IV

HASIL DAN PEMBAHASAN

4.1 Deskripsi Data

Pada penelitian ini menggunakan data harga Saham Kimia Farma yang diambil melalui situs Yahoo finance. Data yang diambil adalah data harian harga Saham Kimia Farma Tbk, pada periode 6 Januari 2022 sampai 20 Oktober 2024 sebanyak 671 data.

Harga Saham pada pasar modal dipengaruhi oleh faktor internal dan eksternal, yang membuat volatilitas harga cukup tinggi. Hal ini berpotensi mendapatkan keuntungan dalam jumlah yang besar, namun diiringi resiko yang sama besarnya. pergerakan harga saham selama 2 tahun dapat dilihat pada gambar 4.1 dimana gambar tersebut berupa diagram garis yang mencakup data *Adjusted Close*.




Gambar 4.1 Grafik Harga *Adj Close* Saham Kimia Farma

Pada gambar 4.1 di atas, dapat dilihat pada awal Juni tahun 2024 harga saham Kimia Farma mengalami penurunan yang signifikan pasca pandemi. Harga saham Kimia Farma terus merosot hingga ke nilai Rp 800,00 dari yang sebelumnya sekitar Rp 1.500,00. Namun ketika memasuki tahun 2024, harga saham Kimia Farma kembali naik dengan menyentuh angka lebih dari Rp 1.600,00 bahkan melebihi harga awal bulan Juni 2022, namun tetap kembali merosot sampai Oktober saat ini yang berada di angka Rp 700,00.

4.2 Preprocessing Data

Sebelum melakukan tahap kontruksi model, maka pada tahap ini dilakukan standarisasi data yang bertujuan mengubah skala data agar memiliki semua bobot yang sama dengan rentang 0 sampai 1 sehingga membantu mempercepat konvergensi ke model LSTM. Penggunaan teknik *min-max scaling* dengan persamaan (2.8) digunakan untuk menangani data yang hilang pada data *set* yang disiapkan agar meminimalisir *error* pada saat melakukan uji model prediksi.



Gambar 4.2 Hasil Standarisasi Min-Max Scaling

Gambar 4.2, merupakan hasil teknik standarisasi *Min-Max Scaling* mengubah skala data yang awalnya bernilai ratusan hingga ribuan rupiah menjadi nilai dengan 0 sampai 1. Hal ini guna mempermudah konvergensi dalam model sendiri.

4.3 Alokasi Data

Data pada penelitian ini dialokasikan menjadi dua jenis, yaitu data *training* atau data simulasi dan data *testing* atau data uji. Pembagian data untuk model prediksi yang dibangun dibagi menjadi 5 perbandingan. Alokasi data dilakukan dengan pengulangan dan evaluasi hingga ditemukan kombinasi yang paling baik. Kombinasi ini dipilih berdasarkan hasil uji coba serta pertimbangan penulis setelah dilakukan percobaan terhadap beberapa perbandingan jumlah data *testing* dan data *training*. Adapun tabel hasil uji coba terdapat nilai RMSE dan MAPE dengan menggunakan persamaan (2.11) dan (2.12) dilakukan kombinasi perbandingan yang ditunjukkan pada tabel 4.2 berikut:

Table 4.1 Evaluasi Akurasi dari Alokasi Data

Perbandingan	RMSE	MAPE
70:30	74,8858	5,30%
75:25	51,6195	6,15%
80:20	35,7825	3,57%
85:15	41,1517	5,16%
90:10	39,0649	3,83%

Pada tabel 4.1 didapatkan pembagian data untuk model prediksi yang dibangun dibagi dengan perbandingan 80:20 yang dimana sebanyak 80% dari total data akan dijadikan data *training* dan 20% lainnya akan dijadikan data *testing*.

4.4 Kontruksi Model LSTM

Pemodelan LSTM yang dibangun pada penelitian ini menggunakan lima *layer* dengan rincian 2 LSTM *layer*, 1 *dense layer*. Pada *layer* pertama yang menjadi input *layer* diisi sebanyak 50 *neuron* dengan pengulangan kembali bernilai *True*. Selanjutnya pada *dense layer* diisi dengan *neuron* $n_forecast$, dan diisi dengan 1 *neuron* pada *output layer*. Beberapa parameter yang digunakan merupakan *default* keras seperti fungsi *tanh* dan *sigmoid* serta bias *Optimizer*. Variabel lainnya merupakan variabel terpilih setelah dilakukan beberapa percobaan.

Table 4.2 Parameter Model LSTM

No.	Jenis	Uraian
1.	Lapisan	3
2.	Aktivasi <i>state</i>	Tanh
3.	Fungsi aktivasi pada <i>gate</i>	Sigmoid
4.	<i>Optimizer</i>	Adam
5.	Jumlah <i>Epochs</i>	10, 20, 30, ... 100
6.	Ukuran <i>Batch</i>	4
7.	Bias	1

Selanjutnya pada hidden layer LSTM diisi dengan keterangan sebagai berikut:

Table 4.3 *Hidden Layer* pada Model LSTM dengan 3 *layer* model

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 60, 50)	10.400
Lstm_1(LSTM)	(None, 50)	20.200

Layer (type)	Output Shape	Param #
dense(Dense)	(None, 1)	51

Berdasarkan tabel 4.4, diketahui:

1. Layer Pertama (lstm (LSTM))

Output Shape: (None, 60, 50) Artinya, layer ini memiliki 60 timestep (panjang data historis yang digunakan dalam satu input) dan 50 neuron pada *hidden layer*. Nilai None menunjukkan bahwa jumlah sampel (batch size) tidak ditentukan, sehingga model dapat menerima jumlah input data berapa pun saat pelatihan.

Param# (Parameter): 10.400 Parameter ini dihitung berdasarkan:

Param=(input+bias+unit) · unit

$$(1 + 1 + 50) \cdot 50 = 52 \cdot 50 = 2600$$

Karena layer ini menggunakan return_sequences=True, maka ada 4 gate dalam LSTM (*forget gate*, *input gate*, *cell state*, dan *output gate*), sehingga:

$$4 \cdot 2600 = 10.400$$

2. Layer Kedua (Lstm_1 (LSTM))

Output Shape: (None, 50) Layer ini menerima output dari layer sebelumnya sebagai input dan menghasilkan 50 output neuron.

Param # (Parameter): 20.200 Perhitungan parameter pada layer ini adalah:

$$(50 + 1 + 50) \cdot 50 = 101 \cdot 50 = 5050; 4 \cdot 5050 = 20.200$$

3. Layer Ketiga (dense (Dense))

Output Shape: (None, 1) Ini adalah layer output dengan 1 neuron yang merepresentasikan hasil prediksi harga saham.

Param# (Parameter): 51 Parameter pada layer Dense dihitung sebagai:

$$Neuron\ Input \cdot Neuron\ Output + Bias = 50 \cdot 1 + 1 = 51$$

Sebagai ilustrasi, adapun pembetulan model LSTM dengan melakukan perhitungan *foward pass* LSTM menurut (Budiprasetyo dkk., 2022) dengan pengamatan pertama sehingga mendapatkan perhitungan sebagai berikut:

1. Menentukan parameter

- Bobot ditentukan dengan *glorot uniform* dengan persamaan (2.10) didapatkan bobot dengan rentang berkisar $W \approx [-0,343; 0,343]$
- Bias pada *forget gate* bernilai 1 untuk menghindari penghapusan informasi secara agresif pada awal pelatihan.
- Bias pada gate lain ditentukan bernilai 1 sebagai stabilitas dan penyederhanaan penggunaan bias.
- *Hidden state* pada perhitungan pertama bernilai 0,01
- *Cell state* pada perhitungan pertama bernilai 0,01
- Nilai *input* pada pengamatan pertama $x_t = 0,846847$

2. Menghitung nilai aktivasi (y) setiap gerbang LSTM menggunakan persamaan (2.1) hingga (2.8)

- *Forget gate*

$$\begin{aligned} y_f &= (W_f \cdot [s_{t-1}, x_t] + b_f) \\ &= (0,25 \cdot 0,01 + 0,25 \cdot 0,846847 + 1 \end{aligned}$$

$$\begin{aligned}
 &= 0,0025 + 0,21171175 + 1 \\
 &= 1,21421175
 \end{aligned}$$

- *Input gate*

$$\begin{aligned}
 y_i &= (W_i \cdot [s_{t-1}, x_t] + b_i) \\
 &= (0,35 \cdot 0,01 + 0,35 \cdot 0,846847 + 1) \\
 &= 0,0035 + 0,29639645 + 1 \\
 &= 1,29989645
 \end{aligned}$$

- Kandidat *cell state*

$$\begin{aligned}
 y_c &= (W_c \cdot [s_{t-1}, x_t] + b_c) \\
 &= (0,65 \cdot 0,01 + 0,65 \cdot 0,846847 + 1) \\
 &= 0,0065 + 0,55045055 + 1 \\
 &= 1,55695055
 \end{aligned}$$

- *Output gate*

$$\begin{aligned}
 y_o &= (W_o \cdot [s_{t-1}, x_t] + b_o) \\
 &= (0,4 \cdot 0,01 + 0,4 \cdot 0,846847 + 1) \\
 &= 0,004 + 0,3387388 + 1 \\
 &= 1,3427388
 \end{aligned}$$

3. Menghitung aktivasi sigmoid dan tanh

- Aktivasi *forget gate*

$$\begin{aligned}
 f_t &= \sigma(y_f) \\
 &= \frac{1}{1 + e^{-1,21421175}} \\
 &= 0,77104332
 \end{aligned}$$

- Aktivasi *input gate*

$$\begin{aligned}
 i_t &= \sigma(y_i) \\
 &= \frac{1}{1 + e^{-1,29989645}} \\
 &= 0,78581755
 \end{aligned}$$

- Aktivasi *cell state*

$$\begin{aligned}
 \tilde{C}_t &= \tanh(y_c) \\
 &= \tanh(1,55695055) \\
 &= 0,91492979
 \end{aligned}$$

- Aktivasi *output gate*

$$\begin{aligned}
 o_t &= \sigma(y_o) \\
 &= \frac{1}{1 + e^{-1,3427388}} \\
 &= 0,79293997
 \end{aligned}$$

4. Update *cell state* dan *hidden state*


- *Cell state update*

$$\begin{aligned}
 C_t &= f_t * C_{t-1} + i_t * \tilde{C}_t \\
 &= 0,77104332 * 0,01 + 0,78581755 * 0,91492979 \\
 &= 0,7266783
 \end{aligned}$$

- *Hidden state update*

$$\begin{aligned}
 S_t &= o_t \cdot \tanh(C_t) \\
 &= 0,79293997 \cdot \tanh(0,7266783) \\
 &= 0,79293997 \cdot 0,621027 \\
 &= 0,492437
 \end{aligned}$$

Setelah dilakukan satu iterasi didapatkan *cell state* baru sebesar 0,7266783 dan *hidden state* sebesar 0,492437




Gambar 4.3 Ilustrasi Kompartemen LSTM dengan Parameter serta Hasil

Gambar diatas mengilustrasikan sebagaimana kompartemen lengkap LSTM dengan hasil yang dihitung secara manual. Perhitungan yang dilakukan adalah perhitungan pertama, dan hasil yang didapat akan dilanjutkan pada layer selanjutnya.

4.5 Model Hasil LSTM

Pada gambar 4.4 menunjukkan pola data Y_{train} dengan *epoch* sebanyak 70 yang diperoleh dari proses *training*. Pada grafiknya Y_{train} mengalami tren penurunan pada beberapa periode sepanjang proses *training* berlangsung. Pola data yang terbentuk dari pada grafik ini menjadi acuan untuk menganalisa dan mengevaluasi validitas model dengan penggunaan 70 *epoch* pada perbandingan data latih dan data uji sebesar 80:20.




Gambar 4.4 Validitas Model *Epoch* 70 dengan perbandingan 80:20

Data ini merupakan hasil praproses sebelum dilakukannya pengujian dan prediksi. Model yang digunakan pada proses *training* ini mengikuti arsitektur dasar LSTM sehingga mampu menangkap pola sekuensial pada data saham kimia farma. Pada validitasnya, dilakukan uji RMSE dan MAPE dimana nilai terendah menunjukkan akurasi terbaik yang didapatkan dari hasil pengujian pada gambar 4.5 dibawah.

4.6 Prediksi Hasil Harga Saham

Setelah proses *training* pada gambar 4.4, untuk mengilustrasikan perbandingan hasil prediksi dan nilai aktual ditunjukkan melalui gambar 4.5 yang ditampilkan dengan tiga warna grafik yaitu *train*, *val*, dan *predictions*. Warna biru menampilkan nilai aktual sebelum diproses, sedangkan warna hijau menampilkan data harga aktual sedangkan warna jingga menampilkan data harga hasil prediksi. Gambar yang ditunjukkan merupakan gambar harga Saham Kimia Farma yang telah melaui proses validasi prediksi model.



Gambar 4.5 Plot Prediksi Harga Saham Kimia Farma 2022-2024

Pada Gambar 4.5 memperlihatkan perbandingan grafik harga aktual dan prediksi LSTM terhadap harga saham Kimia Farma dengan nilai pada tes menggunakan jumlah *epoch* 70. Dapat dilihat tidak ada perbedaan signifikan antara harga aktual dan hasil prediksi. Sebagaimana hal ini menunjukkan bahwa hasil data pada tahun 2022 – 2024 memiliki error yang rendah dan hasil model yang akurat.

Harga saham Kimia Farma pada periode Mei 2024 hingga September 2024 mengalami penurunan. Sebagaimana hal ini dipengaruhi oleh kinerja keuangan PT Kimia Farma Tbk dimana menderita rugi bersih sebesar 226,78 miliar atau meroket 942,19% dibandingkan rugi bersih pada semester I 2023. Akibat lonjakan rugi bersih tersebut, maka per 30 Juni 2024 perseroan mencatatkan defisit saldo laba yang belum ditentukan penggunaannya sebesar Rp2,74 triliun atau meningkat 9,16% dibandingkan dengan defisit per 31 Desember 2023 yang sebesar Rp2,51 triliun. Dengan demikian, ekuitas KAEF per akhir Juni 2024 menjadi Rp5,93 triliun atau merosot 7,2% (Sary, 2024). Adapun emiten farmasi PT Kimia Farma Tbk melaporkan rugi bersih kepada pemilik entitas induk sebesar 421,8 miliar hingga kuartal III/2024. Kerugian emiten farmasi itu membengkak kendati membukukan pertumbuhan penjualan. Selain itu entitas anak BUMN mencatat penjualan produksi pihak ketiga sebesar 5,58 triliun hingga kuartal III/2024. Adapun beban pokok penjualan yang naik menjadi 5,51 triliun dan beban usaha 2,65 triliun sepanjang 9 bulan 2024 (Darwati, 2024). Hal tersebut menunjukkan adanya beban usaha dan meningkatnya beban pokok penjualan, dengan kerugian yang terus meningkat, menyebabkan sentimen negatif dalam kalangan investor.

4.7 Validasi Model LSTM

Setelah melakukan kontruksi dan plot hasil model, dilakukan evaluasi akurasi dengan RMSE dan MAPE pada data dari data tahun 2022-2024.

Table 4.4 Hasil RMSE dan MAPE

Akurasi	Nilai (2022-2024)
RMSE	26,532

MAPE	4,8%
------	------

Pada gambar 4.5 hasil akurasi yang didapatkan dari tahun 2022 – 2024 adalah RMSE 26,532 dan MAPE 4,8% dengan menggunakan 70 *Epoch*. Nilai RMSE maka semakin baik performansi modelnya jika nilai akurasi model mendekati 0, tidak harus menjadi 0 akan tetapi juga diukur antara nilai *real*, valid, dan prediksi pada hasil model tersebut. Kemudian untuk nilai MAPE juga akan semakin akurat jika persentase error nya semakin mendekati 0, kemudian dapat digunakan untuk menampilkan hasil akhir..

Dengan hasil akurasi dan model di atas, bentuk akurasi model tahun 2022-2024 memiliki hasil akurasi sebagaimana

Table 4.5 Tingkat Akurasi berbagai *Epoch*


Tingkat Akurasi dengan Berbagai <i>Epoch</i>	Model Evaluasi Akurasi	
	RMSE	MAPE
10	35,57454809034642	6,61%
20	31,21355882588401	5,51%
30	30,86371443760646	5,32%
40	27,58535508759086	4,84%
50	28,70926614219737	4,99%
60	29,86852176331175	5,06%
70	26,532731653249215	4,8%
80	30,852196720248735	5,08%
90	30,67896614807266	5,07%
100	29,00042281305565	4,95%

Pada tabel diatas ditunjukkan bahwa nilai RMSE dan MAPE pada epoch 70 memiliki tingkat akurasi senilai 26,532 dan 4,8% Nilai tersebut menunjukkan penggunaan *epoch* sebesar 70 pada proses *forecast*.


4.8 Proses *Forecasting*

Pada proses *forecasting*, dilakukan penentuan seberapa banyak titik historis yang digunakan sebagai acuan *forecasting*. Tidak ada ketentuan khusus seberapa banyak titik historis yang digunakan, peneliti menentukan titik historis sebanyak 60 pengamatan. Setelah ditentukan seberapa banyak data historis, dilakukan proses *Inverse Transforms* atau pengubahan skala menjadi semula agar bisa dilakukan visualisasi data dengan hasil prediksi.

Tahapan selanjutnya, dilakukan pembuatan model *forecast* saham kimia farma dengan menggunakan model yang telah tervalidasi, dengan sedikit modifikasi. Pada gambar 4.6, dapat dilihat bahwa hasil prediksi pada harga saham kimia farma secara visual. Pemilihan model dilakukan dengan melihat hasil akurasi terbaik dari berbagai *epoch* yang telah dilakukan evaluasi dan *output* yang terdapat pada model LSTM akan berbentuk nilai prediksi seperti pada gambar 4.7 dimana hasil *forecast* dilakukan selama 30 hari mendatang. Adapun kegunaan optimizer adam, yaitu memperbarui bobot jaringan secara efisien dengan menggabungkan momentum dan RMSProp. Adam bekerja secara adaptif dalam menyesuaikan *learning rate* sehingga proses konvergensi model menjadi lebih cepat.



Gambar 4.6 Hasil Prediksi dengan *Epochs* 70



Gambar 4.7 Forecast 30 Hari dengan 70 *Epoch*

Plot hasil peramalan pada gambar 4.6 menunjukkan grafik validasi dan prediksi nilai validasi model. Plot tersebut menunjukkan secara visual bahwa nilai prediksi memiliki kemiripan dengan validasi yang digunakan. Hasil ini menunjukkan bahwa prediksi mendatang nilai saham akan mengalami peningkatan.

4.9 Analisa Hasil

Secara nilai akurasi dari RMSE dan MAPE, jumlah *epochs* 70 memiliki akurasi yang cukup tinggi, sehingga *epochs* tersebut digunakan dalam kontruksi model prediksi LSTM. Secara visualisasi, hasil prediksi tersebut secara bertahap dalam 30 hari prediksi meningkat sedikit demi sedikit. Hal ini menunjukkan adanya kenaikan harga saham Kimia Farma selama 30 hari mendatang.

4.10 Hubungan Transaksi Jual Beli Saham pada Model LSTM

Transaksi jual beli saham merupakan aktivitas ekonomi yang penting dalam pasar modal. Pada konteks ini, sebuah model LSTM digunakan untuk memprediksi pergerakan harga saham berdasarkan data historis yang dimilikinya. Dalam transaksi jual beli saham sendiri, tindakan pengambilan dan pencarian informasi informasi penting, Allah menciptakan manusia dengan akal dan kemampuan memori yang memiliki peran untuk mengolah informasi. Memori manusia mencakup keterampilan, peristiwa, dan informasi faktual dan sintetik. Namun, memori jangka panjang dan jangka pendek membuat manusia kadang-kadang melupakannya. Hal ini dimodifikasi dan terapkan dalam sebuah model *Long Short-Term Memory*. LSTM adalah pengembangan dari *Recurrent Neural Network* yang merupakan jenis arsitektur jaringan saraf tiruan yang mengimitasi jaringan saraf manusia.

Hasil Analisis menggunakan model LSTM menunjukkan bahwa dalam penggunaan model tersebut untuk memprediksi harga saham dapat membantu mengurangi resiko pengambilan keputusan dan membantu Analisa transaksi jual beli sebuah saham. Adapun model LSTM bisa menjadi pedang bermata dua, sebagaimana model LSTM akan menjadi haram jika hasil prediksi model

digunakan untuk membohongi, membodohi, ataupun melakukan penawaran palsu kepada orang lain, sebagaimana menurut hadist Nabi riwayat Ibnu Majah dari Ubaidah bin Shamit riwayat Ahmad dari Ibnu Abbas, dan riwayat Imam Malik dari Yahya:

لَا ضَرَرَ وَلَا ضِرَارَ {رَوَاهُ أَحْمَدُ, وَابْنُ مَاجَةَ¹ }.

Artinya: *“Tidak boleh membahayakan diri sendiri dan tidak boleh pula membahayakan orang lain.”*

Hasil prediksi model ini sendiri merupakan salah satu probabilitas, hanya salah satu kemungkinan yang akan terjadi, bukan kejadian mutlak yang akan terjadi. Model ini sendiri memanfaatkan data historis untuk memprediksi pergerakan harga saham dimasa mendatang. Dalam pandangan Islam, hasil prediksi model LSTM dapat digunakan untuk mendukung keputusan investasi seperti kejujuran dan transparansi hasil prediksi, penggalan ilmu pengetahuan dari proses analisis data sebagaimana pada surah di atas untuk mempelajari pola pola di alam semesta ini salah satunya pola historis harga saham.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

1. Penerapan model LSTM pada prediksi harga saham Kimia Farma Tbk dilakukan melalui tahapan *preprocessing* data, pembentukan data sekuensial, standarisasi, pelatihan model, hingga evaluasi hasil prediksi. Model LSTM bertujuan untuk mengatasi *long-term dependency* dan menghindari permasalahan *vanishing gradient*. Hasil implementasi menunjukkan bahwa model LSTM mampu menghasilkan prediksi yang stabil dimana secara akurasi RMSE didapat sebesar 26,532 dan MAPE sebesar 4,8%, dalam kriteria nilai MAPE hal ini masuk dalam kategori sangat baik. Model ini juga dapat meramalkan tren harga saham selama 30 hari ke depan.
2. Perbedaan jumlah *Epochs* pada akurasi model LSTM dalam prediksi harga *Adjusted Close* pada saham Kimia Farma memiliki berpengaruh terhadap tingkat akurasi model LSTM, tetapi peningkatan jumlah *epoch* tidak selalu menghasilkan akurasi terbaik. Dalam penelitian ini dilakukan eksperimen dengan jumlah *epoch* dari 10 hingga 100. Hasil evaluasi menunjukkan bahwa *epoch* ke-70 memberikan hasil terbaik dengan nilai RMSE sebesar 26,532 dan MAPE sebesar 4,8%. Temuan ini mengindikasikan bahwa pemilihan *epoch* yang tepat sangat penting untuk menghindari *overfitting* atau *underfitting*, namun peningkatan jumlah *epoch* secara terus-menerus tidak menjamin peningkatan akurasi. Semakin meningkat jumlah *Epoch* yang digunakan tidak menjamin meningkatnya keakurasian.

5.2 Saran

1. Untuk hasil prediksi yang lebih akurat, penelitian selanjutnya dapat mempertimbangkan penambahan parameter teknikal atau fundamental lainnya, seperti volume perdagangan, indikator pasar, atau sentimen berita. Dan adapun melakukan tuning *hyperparameter* lebih mendalam, seperti variasi jumlah *epochs*, ukuran *batch*, jumlah *hidden layers*, serta kombinasi fungsi aktivasi, agar performa model dapat lebih optimal.
2. Penerapan model prediksi terhadap data saham sesungguhnya dapat lebih bermanfaat jika disertai dengan konteks eksternal seperti data makroekonomi, berita keuangan, atau indikator teknikal lainnya. Oleh karena itu, untuk penelitian lanjutan disarankan mengintegrasikan LSTM dengan fitur-fitur tambahan tersebut guna meningkatkan validitas dan ketepatan prediksi.

DAFTAR PUSTAKA

- Bengio, Y., Simard, P., neural, P. F.-I. transactions on, & 1994, undefined. (1994). Learning long-term dependencies with gradient descent is difficult. *ieeexplore.ieee.org* Y Bengio, P Simard, P Frasconi IEEE transactions on neural networks, 1994 • *ieeexplore.ieee.org*.
<https://ieeexplore.ieee.org/abstract/document/279181/>
- Bhandari, H. N., Rimal, B., Pokhrel, N. R., Rimal, R., Dahal, K. R., & Khatri, R. K. C. (2022). Predicting stock market index using LSTM. *Machine Learning with Applications*, 9, 100320. <https://doi.org/10.1016/J.MLWA.2022.100320>
- Bishop, C., & Nasrabadi, N. (2006). *Pattern recognition and machine learning*. <https://link.springer.com/book/9780387310732>
- Boshnakov, G. N. (2016). Introduction to Time Series Analysis and Forecasting, 2nd Edition, Wiley Series in Probability and Statistics, by Douglas C. Montgomery, Cheryl L. Jennings and Murat Kulahci (eds). Published by John Wiley and Sons, Hoboken, NJ, USA, 2015. Total number of pages: 672 Hardcover: ISBN: 978-1-118-74511-3, ebook: ISBN: 978-1-118-74515-1, etext: ISBN: 978-1-118-74495-6. *Journal of Time Series Analysis*, 37(6), 864–864. <https://doi.org/10.1111/jtsa.12203>
- Brownlee, J. (2017). *Long short-term memory networks with python: develop sequence prediction models with deep learning*.
[https://books.google.com/books?hl=id&lr=&id=m7SoDwAAQBAJ&oi=fnd&pg=PP1&dq=Brownlee,+J.+\(2017\).+Long+short-term+memory+networks+with+python:+develop+sequence+prediction+models+with+Deep+learning.+Machine+Learning+Mastery.&ots=vRJt8W8hNz&sig=v_BlbpgYmyHp9mpNst8V-ej0U38](https://books.google.com/books?hl=id&lr=&id=m7SoDwAAQBAJ&oi=fnd&pg=PP1&dq=Brownlee,+J.+(2017).+Long+short-term+memory+networks+with+python:+develop+sequence+prediction+models+with+Deep+learning.+Machine+Learning+Mastery.&ots=vRJt8W8hNz&sig=v_BlbpgYmyHp9mpNst8V-ej0U38)
- Budiprasetyo, G., Hani'ah, M., & Aflah, D. Z. (2022). Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM). *Jurnal Nasional Teknologi dan Sistem Informasi*, 8(3), 164–172.
<https://doi.org/10.25077/TEKNOSI.V8I3.2022.164-172>
- Cahyani, J., Mujahidin, S., & Fiqar, T. P. (2023). Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional. *Jurnal Sistem dan Teknologi Informasi (JustIN)*, 11(2), 346.
<https://doi.org/10.26418/JUSTIN.V11I2.57395>
- Cholissodin, I., Sutrisno, S., ... A. S.-F. I., & 2020, undefined. (2020). AI, machine learning and deep learning. *researchgate.net* I Cholissodin, S Sutrisno, AA Soebroto, U Hasanah, YI Febiola Fakultas Ilmu Komputer, Universitas Brawijaya, Malang, 2020 • *researchgate.net*.
https://www.researchgate.net/profile/Imam-Cholissodin/publication/348003841_Buku_Ajar_AI_Machine_Learning_Dee

p_Learning/links/61cdd217da5d105e550a9a4a/Buku-Ajar-AI-Machine-Learning-Deep-Learning.pdf

Darwati, E. (2024). *Rugi Kimia Farma (KAEF) Kian Membengkak Capai Rp421,8 Miliar hingga Kuartal III/2024*.

<https://market.bisnis.com/read/20241104/192/1813020/rugi-kimia-farma-kaef-kian-membengkak-capai-rp4218-miliar-hingga-kuartal-iii2024>

DSN-MUI. (2024). *Akad Jual Beli - DSN-MUI*. <https://dsnemui.or.id/akad-jual-beli/>

Dwika, A., Manajemen, D. A.-J. I., & 2024, undefined. (2024). Implementasi Algoritma LSTM untuk Prediksi Harga Cabai Merah Keriting di Yogyakarta. *journal.stmiki.ac.id* ARH Dwika, D Avianto *Jurnal Indonesia: Manajemen Informatika dan Komunikasi*, 2024 • *journal.stmiki.ac.id*, 5, 635–648. <https://doi.org/10.35870/jimik.v5i1.534>

Febbi, H. S., R Wijayatun Pratiwi, & M Putriyani. (2021). *Analisis Sentimen Pada Data Ulasan Twitter Dengan Menggunakan Long Short Term Memory*. <http://eprints.poltektegal.ac.id/979/>

Gers, F. A., Urgan Schmidhuber, J. J., & Cummins, F. (1999). *Learning to Forget: Continual Prediction with LSTM*. www.idsia.ch

Glorot, X., thirteenth, Y. B.-P. of the, & 2010, undefined. (2010). Understanding the difficulty of training deep feedforward neural networks. *proceedings.mlr.press* X Glorot, Y Bengio *Proceedings of the thirteenth international conference on, 2010* • *proceedings.mlr.press*. <http://proceedings.mlr.press/v9/glorot10a>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. 1–23. <https://mitpress.mit.edu/9780262035613/deep-learning/>

Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2016). LSTM: A search space odyssey. *ieeexplore.ieee.org* K Greff, RK Srivastava, J Koutník, BR Steunebrink, J Schmidhuber *IEEE transactions on neural networks and learning systems*, 2016 • *ieeexplore.ieee.org*. <https://doi.org/10.1109/TNNLS.2016.2582924>

Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/NECO.1997.9.8.1735>

Jozefowicz, R., ... W. Z.-... conference on machine, & 2015, undefined. (2015). An empirical exploration of recurrent network architectures. *proceedings.mlr.press* R Jozefowicz, W Zaremba, I Sutskever *International conference on machine learning*, 2015 • *proceedings.mlr.press*. <https://proceedings.mlr.press/v37/jozefowicz15.html>

Keras.io. (2025). *LSTM layer*. https://keras.io/api/layers/recurrent_layers/lstm/

- Kimia Farma Tbk. (2024a). *Kimia Farma | Sejarah Perusahaan*.
<https://www.kimiafarma.co.id/id/sejarah-kimia-farma>
- Kimia Farma Tbk. (2024b). *Kimia Farma | Visi & Misi*.
<https://www.kimiafarma.co.id/id/visi-dan-misi>
- Kingma, D. P., & Ba, J. L. (2014). Adam: A Method for Stochastic Optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*. <https://arxiv.org/abs/1412.6980v9>
- Kumar, S. (2020). *Comparison of Sigmoid, Tanh and ReLU Activation Functions - AITUDE*. <https://www.aitude.com/comparison-of-sigmoid-tanh-and-relu-activation-functions/>
- Kustiyo, A., Mukhlis, M., ICT, A. S.-B. I., & 2022, undefined. (2022). Model Recurent Neural Network untuk Peramalan Produksi Tebu Nasional. *ejournal-binainsani.ac.id* A Kustiyo, M Mukhlis, A Suharso BINA INSANI ICT JOURNAL, 2022•*ejournal-binainsani.ac.id*. <https://ejournal-binainsani.ac.id/index.php/BIICT/article/download/1744/1386>
- LeCun, Y., Bengio, Y., nature, G. H.-, & 2015, undefined. (2015). Deep learning. *nature.com* Y LeCun, Y Bengio, G Hinton nature, 2015•*nature.com*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Liu, H. (2020). Robot Systems for Rail Transit Applications. *Robot Systems for Rail Transit Applications*, 1–396. <https://doi.org/10.1016/B978-0-12-822968-2.01001-9>
- Mehtab, S., Sen, J., & Dutta, A. (2020). (PDF) *Stock Price Prediction Using Machine Learning and LSTM-Based Deep Learning Models*. https://www.researchgate.net/publication/344324240_Stock_Price_Prediction_Using_Machine_Learning_and_LSTM-Based_Deep_Learning_Models
- Mishkin, F. S., & Eakins, S. G. (2012). *Financial Markets and Institutions* (7th Edition). <https://dlib.neu.edu.vn/server/api/core/bitstreams/d63acaaf-7dcc-49ed-8991-026a57ee9c28/content>
- Moghar, A., science, M. H.-P. computer, & 2020, undefined. (2020). Stock market prediction using LSTM recurrent neural network. *Elsevier* A Moghar, M Hamiche Procedia computer science, 2020•Elsevier. <https://www.sciencedirect.com/science/article/pii/S1877050920304865>
- Olah, C. (2015). *Understanding lstm networks*. <https://research.google/pubs/understanding-lstm-networks/>
- Prijono, B. (2018). *Pengenalan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) – RNN Bagian 2 – Belajar Pembelajaran Mesin Indonesia*. <https://indoml.com/2018/04/13/pengenalan-long-short-term-memory-lstm-dan-gated-recurrent-unit-gru-rnn-bagian-2/>

- PT. Bursa Efek Indonesia. (2024). *Ikhtisar dan Sejarah BEI*.
<https://www.idx.co.id/id/tentang-bei/ikhtisar-dan-sejarah-bei/>
- Qur'an Kemenag*. (2024). <https://quran.kemenag.go.id/>
- Rosebrock, A. (2021). *Understanding weight initialization for neural networks - PyImageSearch*. <https://pyimagesearch.com/2021/05/06/understanding-weight-initialization-for-neural-networks/>
- Rosyd, A., Purnamasari, A., Teknik, I. A.-J. (Jurnal M., & 2024, undefined. (2024). Penerapan Metode Long Short Term Memory (LSTM) Dalam Memprediksi Harga Saham Pt Bank Central Asia. *ejournal.itn.ac.id* A Rosyd, AI Purnamasari, I AliJATI (Jurnal Mahasiswa Teknik Informatika), 2024•*ejournal.itn.ac.id*, 8(1).
<https://ejournal.itn.ac.id/index.php/jati/article/view/8440>
- Salim, M. (2017). JUAL BELI SECARA ONLINE MENURUT PANDANGAN HUKUM ISLAM. *Al Daulah : Jurnal Hukum Pidana dan Ketatanegaraan*, 6(2), 371–386. <https://doi.org/10.24252/ad.v6i2.4890>
- Sary, M. (2024). *Kerugian di 1H24 Meroket, Defisit Kimia Farma (KAEF) Bengkak Jadi Rp2,74 Triliun - Financial Review*.
<https://www.financialreview.id/korporasi/63413470616/kerugian-di-1h24-meroket-defisit-kimia-farma-kaef-bengkak-jadi-rp274-triliun>
- Soebiantoro, U. (2021). Perdagangan Saham yang Paling Moncer dalam Masa Pandemi Covid 19. *repository.upnjatim.ac.id* U Soebiantoro *Jurnal Ilmu Ekonomi Pembangunan*, 2021•*repository.upnjatim.ac.id*.
<https://repository.upnjatim.ac.id/1325/1/ugy.pdf>
- Suhendi, H. H. (2019). *Suhendi, H. H. (2019). Fiqh muamalah. - Google Scholar*.
https://scholar.google.com/scholar?hl=id&as_sdt=0%2C5&scioq=Mishkin%2C+F.+S.%2C+%26+Eakins%2C+S.+G.+%282012%29.+The+bond+market.+Financial+Markets+and+Institutions%2C+16%281%29%2C+320-322.&q=Suhendi%2C+H.+H.+%282019%29.+Fiqh+muamalah.&btnG=
- Suta, I. (2000). Menuju pasar modal modern. *cir.nii.ac.jp*.
<https://cir.nii.ac.jp/crid/1130282270357626496>
- Toin, D., & Sutrisno, S. (2016). Pengaruh Faktor Internal Dan Eksternal Terhadap Harga Saham Industri Perdagangan Eceran Di Bursa Efek Indonesia. *neliti.com*. <https://www.neliti.com/publications/357293/pengaruh-faktor-internal-dan-eksternal-terhadap-harga-saham-industri-perdagangan>
- Wisnyaldin, M. K., Maya Luciana, G., Pariaman, H., & Pembangunan Jawa Bali, P. (2020). Pendekatan LSTM untuk Memprediksi Kondisi Motor 10 kV pada PLTU Batubara. *jurnalitpln.id* MK Wisnyaldin, GM Luciana, H Pariaman *Kilat*, 2020•*jurnalitpln.id*, 9(2).
<https://doi.org/10.33322/kilat.v9i2.997>

Yahoo Finance. (2024). *PT Kimia Farma Tbk (KAEF.JK) Stock Historical Prices & Data - Yahoo Finance*.

<https://finance.yahoo.com/quote/KAEF.JK/history/?period1=1527811200&period2=1717113600&guccounter=1>

LAMPIRAN

Lampiran 1.1 Harga saham aktual Kimia Farma Tbk

Date	Adj Close	Date	Adj Close	Date	Adj Close
2022-06-02 00:00:00	1500	2023-03-02 00:00:00	1100	2023-12-22 00:00:00	1525
2022-06-03 00:00:00	1505	2023-03-03 00:00:00	1065	2023-12-27 00:00:00	1550
2022-06-06 00:00:00	1505	2023-03-06 00:00:00	1045	2023-12-28 00:00:00	1460
2022-06-07 00:00:00	1475	2023-03-07 00:00:00	1045	2023-12-29 00:00:00	1445
2022-06-08 00:00:00	1450	2023-03-08 00:00:00	1025	2024-01-02 00:00:00	1320
2022-06-09 00:00:00	1445	2023-03-09 00:00:00	1025	2024-01-03 00:00:00	1370
2022-06-10 00:00:00	1445	2023-03-10 00:00:00	1030	2024-01-04 00:00:00	1430
2022-06-13 00:00:00	1425	2023-03-13 00:00:00	1030	2024-01-05 00:00:00	1330
2022-06-14 00:00:00	1405	2023-03-14 00:00:00	970	2024-01-08 00:00:00	1275
2022-06-15 00:00:00	1375	2023-03-15 00:00:00	1020	2024-01-09 00:00:00	1185
2022-06-16 00:00:00	1380	2023-03-16 00:00:00	975	2024-01-10 00:00:00	1155
2022-06-17 00:00:00	1385	2023-03-17 00:00:00	980	2024-01-11 00:00:00	1090
2022-06-20 00:00:00	1370	2023-03-20 00:00:00	950	2024-01-12 00:00:00	1065
2022-06-21 00:00:00	1375	2023-03-21 00:00:00	935	2024-01-15 00:00:00	1045

Date	Adj Close	Date	Adj Close	Date	Adj Close
2022-06-22 00:00:00	1380	2023-03-24 00:00:00	930	2024-01-16 00:00:00	1095
2022-06-23 00:00:00	1375	2023-03-27 00:00:00	930	2024-01-17 00:00:00	1110
2022-06-24 00:00:00	1395	2023-03-28 00:00:00	915	2024-01-18 00:00:00	1035
2022-06-27 00:00:00	1410	2023-03-29 00:00:00	915	2024-01-19 00:00:00	995
2022-06-28 00:00:00	1380	2023-03-30 00:00:00	930	2024-01-22 00:00:00	990
2022-06-29 00:00:00	1365	2023-03-31 00:00:00	925	2024-01-23 00:00:00	995
2022-06-30 00:00:00	1330	2023-04-03 00:00:00	915	2024-01-24 00:00:00	970
2022-07-01 00:00:00	1310	2023-04-04 00:00:00	920	2024-01-25 00:00:00	970
2022-07-04 00:00:00	1265	2023-04-05 00:00:00	910	2024-01-26 00:00:00	915
2022-07-05 00:00:00	1255	2023-04-06 00:00:00	910	2024-01-29 00:00:00	930
2022-07-06 00:00:00	1250	2023-04-10 00:00:00	900	2024-01-30 00:00:00	935
2022-07-07 00:00:00	1270	2023-04-11 00:00:00	905	2024-01-31 00:00:00	935
2022-07-08 00:00:00	1300	2023-04-12 00:00:00	900	2024-02-01 00:00:00	955
2022-07-11 00:00:00	1355	2023-04-13 00:00:00	905	2024-02-02 00:00:00	920
2022-07-12 00:00:00	1405	2023-04-14 00:00:00	900	2024-02-05 00:00:00	910

Date	Adj Close	Date	Adj Close	Date	Adj Close
2022-07-13 00:00:00	1445	2023-04-17 00:00:00	920	2024-02-06 00:00:00	920
2022-07-14 00:00:00	1440	2023-04-18 00:00:00	905	2024-02-07 00:00:00	885
2022-07-15 00:00:00	1470	2023-04-26 00:00:00	905	2024-02-12 00:00:00	895
2022-07-18 00:00:00	1405	2023-04-27 00:00:00	895	2024-02-13 00:00:00	875
2022-07-19 00:00:00	1410	2023-04-28 00:00:00	895	2024-02-15 00:00:00	905
2022-07-20 00:00:00	1420	2023-05-02 00:00:00	890	2024-02-16 00:00:00	890
2022-07-21 00:00:00	1425	2023-05-03 00:00:00	890	2024-02-19 00:00:00	860
2022-07-22 00:00:00	1410	2023-05-04 00:00:00	880	2024-02-20 00:00:00	865
2022-07-25 00:00:00	1405	2023-05-05 00:00:00	865	2024-02-21 00:00:00	830
2022-07-26 00:00:00	1395	2023-05-08 00:00:00	850	2024-02-22 00:00:00	840
2022-07-27 00:00:00	1380	2023-05-09 00:00:00	850	2024-02-23 00:00:00	825
2022-07-28 00:00:00	1380	2023-05-10 00:00:00	855	2024-02-26 00:00:00	815
2022-07-29 00:00:00	1370	2023-05-11 00:00:00	855	2024-02-27 00:00:00	815
2022-08-01 00:00:00	1380	2023-05-12 00:00:00	840	2024-02-28 00:00:00	810
2022-08-02 00:00:00	1355	2023-05-15 00:00:00	855	2024-02-29 00:00:00	790

Date	Adj Close	Date	Adj Close	Date	Adj Close
2022-08-03 00:00:00	1375	2023-05-16 00:00:00	845	2024-03-01 00:00:00	775
2022-08-04 00:00:00	1420	2023-05-17 00:00:00	820	2024-03-04 00:00:00	790
2022-08-05 00:00:00	1410	2023-05-19 00:00:00	795	2024-03-05 00:00:00	725
2022-08-08 00:00:00	1415	2023-05-22 00:00:00	755	2024-03-06 00:00:00	740
2022-08-09 00:00:00	1400	2023-05-23 00:00:00	755	2024-03-07 00:00:00	745
2022-08-10 00:00:00	1400	2023-05-24 00:00:00	730	2024-03-08 00:00:00	775
2022-08-11 00:00:00	1390	2023-05-25 00:00:00	725	2024-03-13 00:00:00	790
2022-08-12 00:00:00	1395	2023-05-26 00:00:00	715	2024-03-14 00:00:00	795
2022-08-15 00:00:00	1395	2023-05-29 00:00:00	715	2024-03-15 00:00:00	785
2022-08-16 00:00:00	1390	2023-05-30 00:00:00	715	2024-03-18 00:00:00	770
2022-08-18 00:00:00	1380	2023-05-31 00:00:00	715	2024-03-19 00:00:00	765
2022-08-19 00:00:00	1385	2023-06-05 00:00:00	715	2024-03-20 00:00:00	760
2022-08-22 00:00:00	1395	2023-06-06 00:00:00	725	2024-03-21 00:00:00	775
2022-08-23 00:00:00	1420	2023-06-07 00:00:00	795	2024-03-22 00:00:00	965
2022-08-24 00:00:00	1480	2023-06-08 00:00:00	790	2024-03-25 00:00:00	925

Date	Adj Close	Date	Adj Close	Date	Adj Close
2022-08-25 00:00:00	1450	2023-06-09 00:00:00	785	2024-03-26 00:00:00	910
2022-08-26 00:00:00	1430	2023-06-12 00:00:00	785	2024-03-27 00:00:00	920
2022-08-29 00:00:00	1390	2023-06-13 00:00:00	785	2024-03-28 00:00:00	910
2022-08-30 00:00:00	1405	2023-06-14 00:00:00	780	2024-04-01 00:00:00	915
2022-08-31 00:00:00	1400	2023-06-15 00:00:00	775	2024-04-02 00:00:00	900
2022-09-01 00:00:00	1395	2023-06-16 00:00:00	775	2024-04-03 00:00:00	845
2022-09-02 00:00:00	1385	2023-06-19 00:00:00	770	2024-04-04 00:00:00	855
2022-09-05 00:00:00	1375	2023-06-20 00:00:00	825	2024-04-05 00:00:00	895
2022-09-06 00:00:00	1375	2023-06-21 00:00:00	815	2024-04-16 00:00:00	845
2022-09-07 00:00:00	1375	2023-06-22 00:00:00	795	2024-04-17 00:00:00	795
2022-09-08 00:00:00	1375	2023-06-23 00:00:00	785	2024-04-18 00:00:00	785
2022-09-09 00:00:00	1365	2023-06-26 00:00:00	780	2024-04-19 00:00:00	730
2022-09-12 00:00:00	1360	2023-06-27 00:00:00	780	2024-04-22 00:00:00	745
2022-09-13 00:00:00	1340	2023-07-03 00:00:00	790	2024-04-23 00:00:00	760
2022-09-14 00:00:00	1360	2023-07-04 00:00:00	845	2024-04-24 00:00:00	755

Date	Adj Close	Date	Adj Close	Date	Adj Close
2022-09-15 00:00:00	1355	2023-07-05 00:00:00	845	2024-04-25 00:00:00	745
2022-09-16 00:00:00	1330	2023-07-06 00:00:00	855	2024-04-26 00:00:00	735
2022-09-19 00:00:00	1315	2023-07-07 00:00:00	850	2024-04-29 00:00:00	745
2022-09-20 00:00:00	1320	2023-07-10 00:00:00	860	2024-04-30 00:00:00	755
2022-09-21 00:00:00	1320	2023-07-11 00:00:00	860	2024-05-02 00:00:00	725
2022-09-22 00:00:00	1315	2023-07-12 00:00:00	825	2024-05-03 00:00:00	735
2022-09-23 00:00:00	1315	2023-07-13 00:00:00	845	2024-05-06 00:00:00	755
2022-09-26 00:00:00	1285	2023-07-14 00:00:00	855	2024-05-07 00:00:00	740
2022-09-27 00:00:00	1290	2023-07-17 00:00:00	845	2024-05-08 00:00:00	715
2022-09-28 00:00:00	1270	2023-07-18 00:00:00	850	2024-05-13 00:00:00	710
2022-09-29 00:00:00	1265	2023-07-20 00:00:00	845	2024-05-14 00:00:00	720
2022-09-30 00:00:00	1250	2023-07-21 00:00:00	840	2024-05-15 00:00:00	715
2022-10-03 00:00:00	1240	2023-07-24 00:00:00	845	2024-05-16 00:00:00	710
2022-10-04 00:00:00	1240	2023-07-25 00:00:00	840	2024-05-17 00:00:00	725
2022-10-05 00:00:00	1235	2023-07-26 00:00:00	845	2024-05-20 00:00:00	755

Date	Adj Close	Date	Adj Close	Date	Adj Close
2022-10-06 00:00:00	1240	2023-07-27 00:00:00	840	2024-05-21 00:00:00	850
2022-10-07 00:00:00	1250	2023-07-28 00:00:00	835	2024-05-22 00:00:00	810
2022-10-10 00:00:00	1245	2023-07-31 00:00:00	850	2024-05-27 00:00:00	755
2022-10-11 00:00:00	1235	2023-08-01 00:00:00	900	2024-05-28 00:00:00	770
2022-10-12 00:00:00	1220	2023-08-02 00:00:00	875	2024-05-29 00:00:00	760
2022-10-13 00:00:00	1210	2023-08-03 00:00:00	870	2024-05-30 00:00:00	745
2022-10-14 00:00:00	1205	2023-08-04 00:00:00	880	2024-05-31 00:00:00	730
2022-10-17 00:00:00	1165	2023-08-07 00:00:00	855	2024-06-03 00:00:00	715
2022-10-18 00:00:00	1140	2023-08-08 00:00:00	845	2024-06-04 00:00:00	720
2022-10-19 00:00:00	1135	2023-08-09 00:00:00	820	2024-06-05 00:00:00	685
2022-10-20 00:00:00	1160	2023-08-10 00:00:00	830	2024-06-06 00:00:00	620
2022-10-21 00:00:00	1165	2023-08-11 00:00:00	830	2024-06-07 00:00:00	595
2022-10-24 00:00:00	1190	2023-08-14 00:00:00	835	2024-06-10 00:00:00	570
2022-10-25 00:00:00	1215	2023-08-15 00:00:00	850	2024-06-11 00:00:00	615
2022-10-26 00:00:00	1210	2023-08-16 00:00:00	845	2024-06-12 00:00:00	595

Date	Adj Close	Date	Adj Close	Date	Adj Close
2022-10-27 00:00:00	1190	2023-08-18 00:00:00	835	2024-06-13 00:00:00	595
2022-10-28 00:00:00	1190	2023-08-21 00:00:00	830	2024-06-14 00:00:00	585
2022-10-31 00:00:00	1200	2023-08-22 00:00:00	830	2024-06-19 00:00:00	560
2022-11-01 00:00:00	1190	2023-08-23 00:00:00	830	2024-06-20 00:00:00	560
2022-11-02 00:00:00	1190	2023-08-24 00:00:00	830	2024-06-21 00:00:00	570
2022-11-03 00:00:00	1185	2023-08-25 00:00:00	835	2024-06-24 00:00:00	570
2022-11-04 00:00:00	1195	2023-08-28 00:00:00	830	2024-06-25 00:00:00	575
2022-11-07 00:00:00	1200	2023-08-29 00:00:00	835	2024-06-26 00:00:00	590
2022-11-08 00:00:00	1195	2023-08-30 00:00:00	835	2024-06-27 00:00:00	575
2022-11-09 00:00:00	1195	2023-08-31 00:00:00	840	2024-06-28 00:00:00	575
2022-11-10 00:00:00	1185	2023-09-01 00:00:00	830	2024-07-01 00:00:00	595
2022-11-11 00:00:00	1190	2023-09-04 00:00:00	830	2024-07-02 00:00:00	590
2022-11-14 00:00:00	1485	2023-09-05 00:00:00	825	2024-07-03 00:00:00	615
2022-11-15 00:00:00	1385	2023-09-06 00:00:00	835	2024-07-04 00:00:00	660
2022-11-16 00:00:00	1405	2023-09-07 00:00:00	840	2024-07-05 00:00:00	645

Date	Adj Close	Date	Adj Close	Date	Adj Close
2022-11-17 00:00:00	1380	2023-09-08 00:00:00	845	2024-07-08 00:00:00	660
2022-11-18 00:00:00	1415	2023-09-11 00:00:00	865	2024-07-09 00:00:00	660
2022-11-21 00:00:00	1400	2023-09-12 00:00:00	855	2024-07-10 00:00:00	660
2022-11-22 00:00:00	1330	2023-09-13 00:00:00	840	2024-07-11 00:00:00	655
2022-11-23 00:00:00	1295	2023-09-14 00:00:00	835	2024-07-12 00:00:00	650
2022-11-24 00:00:00	1290	2023-09-15 00:00:00	830	2024-07-15 00:00:00	650
2022-11-25 00:00:00	1280	2023-09-18 00:00:00	840	2024-07-16 00:00:00	640
2022-11-28 00:00:00	1260	2023-09-19 00:00:00	830	2024-07-17 00:00:00	630
2022-11-29 00:00:00	1230	2023-09-20 00:00:00	835	2024-07-18 00:00:00	635
2022-11-30 00:00:00	1260	2023-09-21 00:00:00	825	2024-07-19 00:00:00	635
2022-12-01 00:00:00	1260	2023-09-22 00:00:00	825	2024-07-22 00:00:00	635
2022-12-02 00:00:00	1255	2023-09-25 00:00:00	820	2024-07-23 00:00:00	620
2022-12-05 00:00:00	1240	2023-09-26 00:00:00	820	2024-07-24 00:00:00	615
2022-12-06 00:00:00	1195	2023-09-27 00:00:00	820	2024-07-25 00:00:00	615
2022-12-07 00:00:00	1195	2023-09-29 00:00:00	805	2024-07-26 00:00:00	610

Date	Adj Close	Date	Adj Close	Date	Adj Close
2022-12-08 00:00:00	1175	2023-10-02 00:00:00	795	2024-07-29 00:00:00	610
2022-12-09 00:00:00	1165	2023-10-03 00:00:00	785	2024-07-30 00:00:00	605
2022-12-12 00:00:00	1160	2023-10-04 00:00:00	785	2024-07-31 00:00:00	585
2022-12-13 00:00:00	1150	2023-10-05 00:00:00	800	2024-08-01 00:00:00	590
2022-12-14 00:00:00	1150	2023-10-06 00:00:00	805	2024-08-02 00:00:00	595
2022-12-15 00:00:00	1150	2023-10-09 00:00:00	790	2024-08-05 00:00:00	580
2022-12-16 00:00:00	1140	2023-10-10 00:00:00	785	2024-08-06 00:00:00	585
2022-12-19 00:00:00	1120	2023-10-11 00:00:00	785	2024-08-07 00:00:00	590
2022-12-20 00:00:00	1130	2023-10-12 00:00:00	775	2024-08-08 00:00:00	590
2022-12-21 00:00:00	1135	2023-10-13 00:00:00	775	2024-08-09 00:00:00	590
2022-12-22 00:00:00	1135	2023-10-16 00:00:00	760	2024-08-12 00:00:00	585
2022-12-23 00:00:00	1125	2023-10-17 00:00:00	765	2024-08-13 00:00:00	605
2022-12-26 00:00:00	1140	2023-10-18 00:00:00	745	2024-08-14 00:00:00	610
2022-12-27 00:00:00	1095	2023-10-19 00:00:00	720	2024-08-15 00:00:00	610
2022-12-28 00:00:00	1085	2023-10-20 00:00:00	715	2024-08-16 00:00:00	615

Date	Adj Close	Date	Adj Close	Date	Adj Close
2022-12-29 00:00:00	1080	2023-10-23 00:00:00	710	2024-08-19 00:00:00	630
2022-12-30 00:00:00	1085	2023-10-24 00:00:00	710	2024-08-20 00:00:00	630
2023-01-02 00:00:00	1085	2023-10-25 00:00:00	725	2024-08-21 00:00:00	765
2023-01-03 00:00:00	1090	2023-10-26 00:00:00	730	2024-08-22 00:00:00	700
2023-01-04 00:00:00	1085	2023-10-27 00:00:00	730	2024-08-23 00:00:00	705
2023-01-05 00:00:00	1050	2023-10-30 00:00:00	715	2024-08-26 00:00:00	745
2023-01-06 00:00:00	1090	2023-10-31 00:00:00	720	2024-08-27 00:00:00	740
2023-01-09 00:00:00	1075	2023-11-01 00:00:00	700	2024-08-28 00:00:00	750
2023-01-10 00:00:00	1070	2023-11-02 00:00:00	700	2024-08-29 00:00:00	760
2023-01-11 00:00:00	1040	2023-11-03 00:00:00	700	2024-08-30 00:00:00	750
2023-01-12 00:00:00	1040	2023-11-06 00:00:00	790	2024-09-02 00:00:00	745
2023-01-13 00:00:00	1035	2023-11-07 00:00:00	785	2024-09-03 00:00:00	730
2023-01-16 00:00:00	1035	2023-11-08 00:00:00	800	2024-09-04 00:00:00	735
2023-01-17 00:00:00	1055	2023-11-09 00:00:00	760	2024-09-05 00:00:00	720
2023-01-18 00:00:00	1045	2023-11-10 00:00:00	760	2024-09-06 00:00:00	735

Date	Adj Close	Date	Adj Close	Date	Adj Close
2023-01-19 00:00:00	1040	2023-11-13 00:00:00	750	2024-09-09 00:00:00	720
2023-01-20 00:00:00	1165	2023-11-14 00:00:00	745	2024-09-10 00:00:00	750
2023-01-24 00:00:00	1105	2023-11-15 00:00:00	745	2024-09-11 00:00:00	740
2023-01-25 00:00:00	1090	2023-11-16 00:00:00	730	2024-09-12 00:00:00	740
2023-01-26 00:00:00	1095	2023-11-17 00:00:00	715	2024-09-13 00:00:00	735
2023-01-27 00:00:00	1110	2023-11-20 00:00:00	730	2024-09-17 00:00:00	750
2023-01-30 00:00:00	1100	2023-11-21 00:00:00	720	2024-09-18 00:00:00	755
2023-01-31 00:00:00	1050	2023-11-22 00:00:00	715	2024-09-19 00:00:00	755
2023-02-01 00:00:00	1070	2023-11-23 00:00:00	710	2024-09-20 00:00:00	745
2023-02-02 00:00:00	1070	2023-11-24 00:00:00	715	2024-09-23 00:00:00	755
2023-02-03 00:00:00	1090	2023-11-27 00:00:00	735	2024-09-24 00:00:00	750
2023-02-06 00:00:00	1090	2023-11-28 00:00:00	705	2024-09-25 00:00:00	765
2023-02-07 00:00:00	1080	2023-11-29 00:00:00	720	2024-09-26 00:00:00	765
2023-02-08 00:00:00	1055	2023-11-30 00:00:00	715	2024-09-27 00:00:00	815
2023-02-09 00:00:00	1060	2023-12-01 00:00:00	725	2024-09-30 00:00:00	845

Date	Adj Close	Date	Adj Close	Date	Adj Close
2023-02-10 00:00:00	1050	2023-12-04 00:00:00	835	2024-10-01 00:00:00	830
2023-02-13 00:00:00	1055	2023-12-05 00:00:00	1040	2024-10-02 00:00:00	780
2023-02-14 00:00:00	1040	2023-12-06 00:00:00	1015	2024-10-03 00:00:00	770
2023-02-15 00:00:00	1040	2023-12-07 00:00:00	965	2024-10-04 00:00:00	750
2023-02-16 00:00:00	1040	2023-12-08 00:00:00	1010	2024-10-07 00:00:00	725
2023-02-17 00:00:00	1045	2023-12-11 00:00:00	955	2024-10-08 00:00:00	720
2023-02-20 00:00:00	1045	2023-12-12 00:00:00	875	2024-10-09 00:00:00	720
2023-02-21 00:00:00	1040	2023-12-13 00:00:00	995	2024-10-10 00:00:00	710
2023-02-22 00:00:00	1040	2023-12-14 00:00:00	970	2024-10-11 00:00:00	725
2023-02-23 00:00:00	1075	2023-12-15 00:00:00	1015	2024-10-14 00:00:00	715
2023-02-24 00:00:00	1050	2023-12-18 00:00:00	1265	2024-10-15 00:00:00	725
2023-02-27 00:00:00	1055	2023-12-19 00:00:00	1580	2024-10-16 00:00:00	725
2023-02-28 00:00:00	1055	2023-12-20 00:00:00	1670	2024-10-18 00:00:00	725
2023-03-01 00:00:00	1180	2023-12-21 00:00:00	1510		

Lampiran 1.2 Nilai Hasil Standarisasi dengan *Min-Max Scaling*

Date	Harga saham aktual	y
2022-06-02 00:00:00	1.500	0,846847
2022-06-03 00:00:00	1.505	0,851351
2022-06-06 00:00:00	1.505	0,851351
2022-06-07 00:00:00	1.475	0,824324
2022-06-08 00:00:00	1.450	0,801802
⋮	⋮	⋮
2024-10-11 00:00:00	725	0,148649
2024-10-14 00:00:00	715	0,13964
2024-10-15 00:00:00	725	0,148649
2024-10-16 00:00:00	725	0,148649
2024-10-18 00:00:00	725	0,148649

Lampiran 1.3 *Output* Nilai Prediksi dalam 30 Hari Pengamatan

Tanggal	Prediksi
2024-10-21 00:00:00	728,6389
2024-10-22 00:00:00	732,1549
2024-10-23 00:00:00	736,2603
2024-10-24 00:00:00	741,0396
2024-10-25 00:00:00	746,5623
2024-10-28 00:00:00	752,868
2024-10-29 00:00:00	759,9691
2024-10-30 00:00:00	767,8552
2024-10-31 00:00:00	776,5015
2024-11-01 00:00:00	785,8716
2024-11-04 00:00:00	795,9196
2024-11-05 00:00:00	806,5928
2024-11-06 00:00:00	817,8317
2024-11-07 00:00:00	829,5721

Tanggal	Prediksi
2024-11-08 00:00:00	841,7423
2024-11-11 00:00:00	854,2632
2024-11-12 00:00:00	867,0494
2024-11-13 00:00:00	880,0095
2024-11-14 00:00:00	893,045
2024-11-15 00:00:00	906,0621
2024-11-18 00:00:00	918,9478
2024-11-19 00:00:00	931,5943
2024-11-20 00:00:00	943,8969
2024-11-21 00:00:00	955,751
2024-11-22 00:00:00	967,0607
2024-11-25 00:00:00	977,7394
2024-11-26 00:00:00	987,7111
2024-11-27 00:00:00	996,9158
2024-11-28 00:00:00	1005,309
2024-11-29 00:00:00	1012,865

Lampiran 1.4 Sintaks Python arsitektur LSTM

```
import math
import io
import numpy as np
import pandas as pd
import tensorflow as tf
import yfinance as yf
from keras.models import Sequential
from keras.layers import LSTM, Dense, Dropout
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
import seaborn as sns

# download the data
df = yf.download(tickers=['KAEF.JK'], start='2022-01-06', end='2024-10-21')
y = df['Close'].fillna(method='ffill')
y = y.values.reshape(-1, 1)

df.info()
df.isnull().sum()/len(df)

df = df.drop(['Open', 'High', 'Low', 'Volume'], axis=1)
print(df.dtypes)
#Membuat data frame baru dari adj close
```

```

data = df[['Close']].copy() # Create a new DataFrame
with 'Close'

# scale the data
scaler = MinMaxScaler(feature_range=(0, 1))
scaler = scaler.fit(y)
y = scaler.transform(y)

#Menghitung jumlah baris untuk data training
training_data_size=math.ceil(len(y)*.8)
training_data_size

#data yang telah di skala, di uji train
train_data = y[0:training_data_size, :]
#memisahkan Xtrain dan Ytrain
x_train = []
y_train = []

for i in range(50, len(train_data)):
    x_train.append(train_data[i-50:i, 0])
    y_train.append(train_data[i, 0])
    if i <= 51:
        print(x_train)
        print(y_train)

# generate the input and output sequences
n_lookback = 60 # length of input sequences
                (lookback period)
n_forecast = 30 # length of output sequences
                (forecast period)

# Convert x_train and y_train to NumPy arrays
x_train = np.array(x_train)
y_train = np.array(y_train)
# Reshape x_train to 3D for LSTM input
x_train = x_train.reshape(x_train.shape[0],
x_train.shape[1], 1)

# Model
model = Sequential()
model.add(LSTM(units=50, return_sequences=True,
input_shape=(n_lookback, 1)))
model.add(LSTM(units=50))
model.add(Dense(1)) # Dense layer untuk prediksi
beberapa nilai sekaligus

model.summary()

results = {}

```

```

for epoch_count in range(10, 101, 10):
    print(f"\n🔧 Training dengan epoch = {epoch_count}")

    model = Sequential()
    model.add(LSTM(units=50, return_sequences=False,
input_shape=(x_train.shape[1], x_train.shape[2])))
    model.add(Dense(1))
    model.compile(optimizer='adam',
loss='mean_absolute_percentage_error')

    history = model.fit(
        x_train, y_train,
        batch_size=4,
        epochs=epoch_count,
        verbose=1
    )

    final_loss = history.history['loss'][-1]
    results[epoch_count] = final_loss

#Data_test
test_data = y[training_data_size-50:, :]
#Membuat Xtest dengan Ytest
x_test = []
# Replace 'dataset' with 'y'
y_test = y[training_data_size:, :]
for i in range(50, len(test_data)):
    x_test.append(test_data[i-50:i, 0])

#konversi menjadi numpy array
x_test = np.array(x_test)
y_test = np.array(y_test)

#Mengubah data train menjadi bentuk yang diterima LSTM
x_test = np.reshape(x_test, (x_test.shape[0],
x_test.shape[1], 1))
x_test.shape

# prompt: buat kode untuk memprediksi model dengan variabel x_test

predictions = model.predict(x_test)
predictions = scaler.inverse_transform(predictions)

predictions

# prompt: menghitung akurasi dengan RMSE

```

```

# Evaluate the model using RMSE
rmse = np.sqrt(np.mean(((predictions -
scaler.inverse_transform(y_test)) ** 2)))
print('Root Mean Squared Error (RMSE):', rmse)

# Calculate MAPE
actual_values = scaler.inverse_transform(y_test)
mape = np.mean(np.abs((actual_values - predictions) /
actual_values)) * 100
print(f'Mean Absolute Percentage Error (MAPE):
{mape:.2f}%')

# Data untuk grafik
train = data[:training_data_size]
valid = data[training_data_size:]
valid['Predictions'] = predictions

# Prediksi 30 hari ke depan
future_predictions = []
last_60_days = test_data[-60:] # Ambil data 60 hari
terakhir dari test_data
current_input = last_60_days.reshape(1, 60, 1)

for _ in range(30): # Iterasi selama 30 hari
    # Prediksi nilai berikutnya
    next_prediction = model.predict(current_input)
    # Simpan hasil prediksi (dalam bentuk asli,
    sebelum scaling)
    future_predictions.append(next_prediction[0, 0])
    # Tambahkan prediksi ke input
    current_input = np.append(current_input[:, 1:,
:], [[[next_prediction[0, 0]]], axis=1])

# Transformasi kembali prediksi ke nilai asli
future_predictions =
scaler.inverse_transform(np.array(future_predictions)
.reshape(-1, 1))

# Tanggal untuk prediksi 30 hari ke depan
last_date = data.index[-1]
future_dates = pd.date_range(last_date +
pd.Timedelta(days=1), periods=30, freq='B')

# Buat DataFrame untuk hasil prediksi
future_df = pd.DataFrame({'Date': future_dates,
'Predictions': future_predictions.flatten()})
future_df.set_index('Date', inplace=True)

```

```

# Prediksi 30 hari ke depan
future_predictions = []
last_60_days = test_data[-60:] # Ambil data 60 hari
terakhir dari test_data
current_input = last_60_days.reshape(1, 60, 1)

for _ in range(30): # Iterasi selama 30 hari
    # Prediksi nilai berikutnya
    next_prediction = model.predict(current_input)
    # Simpan hasil prediksi (dalam bentuk asli,
    # sebelum scaling)
    future_predictions.append(next_prediction[0, 0])
    # Tambahkan prediksi ke input
    current_input = np.append(current_input[:, 1:,
    :], [[[next_prediction[0, 0]]]], axis=1)

# Transformasi kembali prediksi ke nilai asli
future_predictions =
scaler.inverse_transform(np.array(future_predictions)
.reshape(-1, 1))

# Tanggal untuk prediksi 30 hari ke depan
last_date = data.index[-1]
future_dates = pd.date_range(last_date +
pd.Timedelta(days=1), periods=30, freq='B')

# Buat DataFrame untuk hasil prediksi
future_df = pd.DataFrame({'Date': future_dates,
'Predictions': future_predictions.flatten()})
future_df.set_index('Date', inplace=True)

```

RIWAYAT HIDUP



Fajar Akbar Samudera Hariono, lahir di Pasuruan, 27 Agustus 2002, biasa dipanggil Fajar. Anak kedua dari dua bersaudara dari pasangan Bapak Moch Dadang Hariiono dan Ibu Munawaroh. Penulis tinggal di desa Watudandang, Kecamatan Prambom, Kabupaten Nganjuk.

Pendidikan dasar penulis tempuh di SD Negeri 1 Watudandang dari tahun 2008 dan lulus pada tahun 2014. Kemudian penulis menempuh pendidikan menengah pertama di SMP Negeri 1 Prambon yang lulus pada tahun 2017. Penulis kemudian menamatkan pendidikan menengah atas di SMA Negeri 1 Tanjunganom pada tahun 2020. Selanjutnya penulis melanjutkan studi Strata 1 di Universitas Islam Negeri Maulana Malik Ibrahim Malang dan mengambil Program Studi Matematika di Fakultas Sains dan Teknologi.

Selama menempuh pendidikan tinggi, penulis turut berkontribusi aktif dalam berbagai kegiatan baik internal maupun eksternal kampus, penulis juga bekerja paruh waktu sebagai salah satu kegiatan eksternal yang penulis lakukan.



KEMENTERIAN AGAMA RI
UNIVERSITAS ISLAM NEGERI
MAULANA MALIK IBRAHIM MALANG
FAKULTAS SAINS DAN TEKNOLOGI

Jl. Gajayana No.50 Dinoyo Malang Telp. / Fax. (0341)558933

BUKTI KONSULTASI SKRIPSI

Nama : Fajar Akbar Samudera Hariono
NIM : 200601110049
Fakultas/Jurusan : Sains dan Teknologi/ Matematika
Judul Skripsi : Penerapan Long Short-Term Memory pada Harga
Adjusted Close Saham Kimia Farma Tbk.
Pembimbing I : Prof. Dr. Sri Harini, M.Si
Pembimbing II : Ach. Nashichuddin, M.A

No	Tanggal	Hal	Tanda Tangan
1.	10 Juli 2024	Konsultasi Bab I, II, dan III	1.
2.	28 Agustus 2024	Konsultasi Kajian Agama	2.
3.	29 Agustus 2024	Konsultasi Revisi Kajian Agama	3.
4.	10 September 2024	ACC Kajian Agama Bab I dan II	4.
5.	12 September 2024	Konsultasi Revisi Bab III	5.
6.	26 September 2024	ACC Bab I, II, dan III	6.
7.	7 Oktober 2024	ACC Seminar Proposal	7.
8.	7 November 2024	Konsultasi Revisi Seminar Proposal	8.
9.	11 November 2024	Konsultasi Bab IV	9.
10.	14 November 2024	Konsultasi Bab V	10.
11.	12 Desember 2024	Konsultasi Kajian Agama Bab IV	11.
12.	17 Desember 2024	ACC Kajian Agama Bab IV	12.
13.	5 Maret 2025	ACC Bab IV dan V	13.
14.	20 Maret 2025	ACC Seminar Hasil	14.
15.	21 April 2025	Konsultasi Revisi Seminar Hasil	15.



**KEMENTERIAN AGAMA RI
UNIVERSITAS ISLAM NEGERI
MAULANA MALIK IBRAHIM MALANG
FAKULTAS SAINS DAN TEKNOLOGI**

Jl. Gajayana No.50 Dinoyo Malang Telp. / Fax. (0341)558933

No	Tanggal	Hal	Tanda Tangan
16.	15 Mei 2025	ACC Matriks Revisi Seminar Hasil	16. 
17.	19 Mei 2025	ACC Sidang Skripsi	17. 
18.	3 Juni 2025	ACC Keseluruhan	18. 

Malang, 3 Juni 2025

Mengetahui,

Ketua Program Studi Matematika




Dr. Elly Susanti, M.Sc.

NIP. 19741129 200012 2 005