

Apple Inc. (AAPL) stock price forecasting using a stacked long short-term memory model with Yahoo Finance data

Prayoga Sungkowo¹, Al-Khowarizmi²

^{1,2}Universitas Muhammadiyah Sumatera Utara, Indonesia

Email: prayogasungkowo12@gmail.com; alkhowarizmi@umsu.ac.id

ABSTRAK

Prediksi harga saham merupakan permasalahan deret waktu yang kompleks karena pergerakan harga bersifat dinamis dan dipengaruhi oleh pola temporal. Penelitian ini bertujuan mengimplementasikan dan mengevaluasi model *Long Short-Term Memory* (LSTM) untuk melakukan *forecasting* harga penutupan saham Apple Inc. (AAPL) berdasarkan data historis Yahoo Finance periode 2022–2024. Data dipraproses menggunakan *Min-Max Scaling*, kemudian ditransformasikan menjadi sekuens dengan *time step* 60 hari dan dibagi secara kronologis menjadi 80% data pelatihan dan 20% data pengujian. Model menggunakan dua lapisan LSTM dengan *dropout* 0,2, *optimizer* Adam, dan *loss function* *Mean Squared Error*. Hasil pengujian memperoleh *Root Mean Squared Error* (RMSE) sebesar 3,31 dan *Mean Absolute Error* (MAE) sebesar 2,68. Visualisasi hasil menunjukkan bahwa prediksi secara umum mampu mengikuti tren harga aktual, meskipun terdapat deviasi pada beberapa periode perubahan harga yang lebih tajam. Hasil ini menunjukkan bahwa LSTM dapat mempelajari pola temporal harga penutupan AAPL dan menghasilkan *forecasting* yang mendekati nilai aktual.

Kata Kunci: Long Short-Term Memory; prediksi harga saham; forecasting; deret waktu; Yahoo Finance

ABSTRACT

Stock price prediction is a complex time-series problem because price movements are dynamic and exhibit temporal patterns. This study aims to implement and evaluate a Long Short-Term Memory (LSTM) model for forecasting the closing price of Apple Inc. (AAPL) stock using historical data obtained from Yahoo Finance for the 2022–2024 period. The data were preprocessed using Min-Max Scaling, transformed into sequences with a 60-day time step, and chronologically divided into 80% training data and 20% testing data. The model employed two LSTM layers with a dropout rate of 0.2, the Adam optimizer, and Mean Squared Error as the loss function. The evaluation results yielded a Root Mean Squared Error (RMSE) of 3.31 and a Mean Absolute Error (MAE) of 2.68. The visualization indicates that the predicted values generally follow the actual price trend, although deviations occur during several periods of sharper price changes. These findings indicate that the LSTM model can learn temporal patterns in AAPL closing prices and generate forecasts that approximate the actual values.

Keyword: Long Short-Term Memory; stock price prediction; forecasting; time series; Yahoo Finance

Corresponding Author:

Prayoga Sungkowo,
Universitas Muhammadiyah Sumatera Utara,
Jl. Kapten Muchtar Basri No.3, Glugur Darat II, Kec. Medan Tim., Kota
Medan, Sumatera Utara 20238, Indonesia
Email: prayogasungkowo12@gmail.com



1. PENDAHULUAN

Pasar saham merupakan salah satu instrumen investasi yang banyak digunakan karena menawarkan potensi keuntungan, tetapi pergerakan harganya bersifat dinamis, kompleks, dan sulit diprediksi secara konsisten. Harga saham dapat dipengaruhi oleh berbagai faktor, seperti kondisi ekonomi makro, kebijakan pemerintah, kinerja perusahaan, serta sentimen pasar, sehingga membentuk data deret waktu yang memiliki

tingkat fluktuasi tinggi (Janiesch et al., 2021). Kondisi tersebut mendorong pengembangan berbagai pendekatan berbasis data untuk membantu analisis pasar dan mendukung proses pengambilan keputusan. Pemanfaatan pendekatan berbasis data dalam pasar modal juga telah diterapkan pada optimasi portofolio melalui integrasi teknik *data mining* dan optimasi kuantitatif, yang menunjukkan semakin luasnya penggunaan teknologi komputasional dalam analisis investasi (Nasution & Al-Khowarizmi, 2025). Studi tersebut menggunakan data teknikal dan fundamental saham LQ45 serta pendekatan komputasional untuk membangun strategi investasi berbasis data.

Seiring dengan perkembangan teknologi informasi, pendekatan berbasis *machine learning* (ML) semakin banyak digunakan dalam analisis dan *forecasting* harga saham karena mampu mempelajari pola dari data historis secara komputasional (Gao, 2021; Janiesch et al., 2021). Salah satu model yang banyak digunakan untuk pengolahan data sekuensial adalah *Long Short-Term Memory* (LSTM), yaitu pengembangan dari *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi permasalahan *vanishing gradient* dan mempertahankan informasi dalam urutan data yang lebih panjang (Sherstinsky, 2020). Karakteristik tersebut menjadikan LSTM relevan untuk data harga saham yang memiliki hubungan temporal dan pola yang berubah dari waktu ke waktu.

Berbagai penelitian telah menerapkan LSTM pada peramalan deret waktu dan harga saham. Li et al. (2023) menggunakan LSTM untuk menganalisis dan memprediksi saham sektor teknologi dengan memanfaatkan data Yahoo Finance. Switrayana et al. (2025) menunjukkan bahwa proses *data scaling* merupakan salah satu aspek penting yang dapat memengaruhi kinerja model *deep learning* dalam prediksi harga saham. Sementara itu, Alizadegan et al. (2025) menunjukkan kemampuan LSTM dan Bi-LSTM dalam memodelkan data deret waktu pada kasus prediksi konsumsi energi. Temuan-temuan tersebut memperlihatkan bahwa performa LSTM tidak hanya ditentukan oleh karakteristik model, tetapi juga oleh proses *preprocessing*, konfigurasi arsitektur, dan karakteristik dataset yang digunakan.

Pengembangan penelitian LSTM juga bergerak ke arah model yang lebih kompleks. Kulkarni et al. (2024) menerapkan LSTM dalam prediksi harga saham dan menunjukkan pentingnya konfigurasi model dalam menghasilkan prediksi yang sesuai dengan pola data. Pardeshi et al. (2023) mengembangkan pendekatan hibrida dengan menggabungkan LSTM dan *sequential self-attention*, sedangkan Chaudhary (2025) membahas pengembangan kerangka *deep learning* untuk meningkatkan kemampuan prediksi pasar saham. Pendekatan lain dikembangkan oleh Agarwal et al. (2025) melalui integrasi *Successive Variational Mode Decomposition* (SVMD) dan LSTM untuk meningkatkan kemampuan pemodelan pola deret waktu. Perkembangan tersebut menunjukkan bahwa penelitian *forecasting* saham tidak hanya berfokus pada penggunaan LSTM, tetapi juga pada konfigurasi dan pengembangan model yang sesuai dengan karakteristik data.


Meskipun berbagai pengembangan model telah dilakukan, implementasi LSTM standar tetap penting sebagai dasar untuk mengevaluasi kemampuan model dalam mempelajari pola harga saham berdasarkan data historis. Penelitian ini menggunakan harga penutupan harian Apple Inc. (AAPL) periode 1 Januari 2022 hingga 31 Desember 2024 yang diperoleh dari Yahoo Finance. Data yang digunakan berjumlah 753 hari perdagangan dan penelitian difokuskan pada variabel harga penutupan (*Close*). Yahoo Finance dipilih karena memungkinkan pengambilan data historis secara terprogram dan dapat diintegrasikan dengan pustaka Python seperti *yfinance* dalam alur pengolahan data dan pembangunan model (Andi & Kusuma, 2025; Li et al., 2023).

Berdasarkan kondisi tersebut, penelitian ini bertujuan mengimplementasikan dan mengevaluasi model *stacked Long Short-Term Memory* untuk *forecasting* harga penutupan saham Apple Inc. (AAPL) menggunakan data historis Yahoo Finance. Model dibangun dengan dua lapisan LSTM dan memanfaatkan *sliding window* 60 hari untuk memprediksi harga pada periode berikutnya. Kontribusi penelitian ini terletak pada evaluasi empiris implementasi *stacked LSTM* melalui alur terintegrasi yang mencakup akuisisi data, normalisasi, pembentukan data sekuensial, pelatihan, validasi, dan evaluasi menggunakan RMSE dan MAE pada data saham AAPL. Dengan demikian, penelitian ini tidak mengusulkan arsitektur LSTM baru, tetapi memberikan implementasi empiris dan terstruktur yang dapat menjadi dasar bagi pengembangan model *forecasting* saham yang lebih kompleks pada penelitian selanjutnya.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif eksperimental untuk mengimplementasikan dan mengevaluasi model *Long Short-Term Memory* (LSTM) dalam melakukan *forecasting* harga penutupan saham Apple Inc. (AAPL) berdasarkan data historis dari Yahoo Finance. LSTM dipilih karena kemampuannya dalam mempertahankan informasi pada urutan data yang panjang melalui mekanisme memori dan gerbang internal, sehingga sesuai untuk pemodelan data deret waktu (*time series*) yang memiliki ketergantungan temporal (Sherstinsky, 2020).

Secara umum, tahapan penelitian meliputi pengumpulan data, *preprocessing*, pembentukan dataset sekuensial, pembangunan dan pelatihan model LSTM, serta evaluasi menggunakan *Root Mean Squared Error* (RMSE) dan *Mean Absolute Error* (MAE), sebagaimana ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

A. Desain Penelitian

Penelitian dirancang sebagai eksperimen komputasional berbasis *supervised learning*. Model dilatih untuk memetakan urutan harga penutupan pada periode sebelumnya sebagai masukan terhadap harga penutupan pada periode berikutnya sebagai target. Tahapan eksperimen disusun secara berurutan mulai dari akuisisi data, *preprocessing*, pembentukan sekuens, pembangunan model, pelatihan, validasi, pengujian, hingga evaluasi model.

Model yang digunakan adalah *stacked LSTM* yang terdiri atas dua lapisan LSTM. Pendekatan tersebut digunakan untuk meningkatkan kapasitas model dalam mempelajari pola temporal pada data harga saham, sedangkan lapisan *dropout* diterapkan sebagai regularisasi untuk mengurangi kecenderungan *overfitting*. Penggunaan LSTM dalam pemodelan data sekuensial juga telah banyak diterapkan pada penelitian *forecasting* harga saham (Kulkarni et al., 2024; Li et al., 2023).

B. Sumber dan Karakteristik Data

Data penelitian diperoleh secara terprogram dari Yahoo Finance menggunakan pustaka Python *yfinance*. Yahoo Finance dipilih karena menyediakan data historis pasar saham yang dapat diakses dan diintegrasikan langsung dengan proses pengolahan data berbasis Python (Andi & Kusuma, 2025; Li et al., 2023).

Objek penelitian adalah saham Apple Inc. (AAPL) dengan periode data 1 Januari 2022 sampai 31 Desember 2024. Dataset terdiri atas 753 hari perdagangan. Data mentah mencakup atribut *Date*, *Open*, *High*, *Low*, *Close*, dan *Volume*, sedangkan variabel yang digunakan dalam pembangunan model dibatasi pada harga penutupan (*Close*).

Contoh struktur data ditampilkan pada Tabel 1.

Tabel 1. Contoh Dataset Saham AAPL

Date	Close	High	Low	Open	Volume
2022-01-03	178.6456	179.4996	174.4251	174.5429	104487900
2022-01-04	176.3783	179.5584	175.8090	179.2542	99310400
2022-01-05	171.6867	176.8397	171.4119	176.2900	94537600
2022-01-06	168.8207	172.0597	168.4673	169.5078	96904000
2022-01-07	168.9875	170.9211	167.8686	169.6942	86709100
...	...	...	...	...	...
2024-12-23	254.6557	255.0348	252.8401	254.1569	40858800
2024-12-24	257.5787	257.5886	254.6757	254.8752	23234700

Date	Close	High	Low	Open	Volume
2024-12-26	258.3967	259.4741	257.0100	257.5687	27237100
2024-12-27	254.9749	258.0775	252.4510	257.2095	42355300
2024-12-30	251.5931	252.8900	250.1466	251.6230	35557500

C. Preprocessing Data

Tahap *preprocessing* dilakukan untuk menyiapkan data agar dapat digunakan sebagai masukan model LSTM. Tahapan tersebut meliputi seleksi variabel, pemeriksaan data, normalisasi, pembentukan data sekuensial, dan pembagian dataset.

Pertama, hanya variabel harga penutupan (*Close*) yang digunakan dalam model. Pemilihan tersebut dilakukan karena harga penutupan banyak digunakan sebagai target dalam penelitian *forecasting* saham dan merepresentasikan harga pada akhir sesi perdagangan (Li et al., 2023; Switrayana et al., 2025).

Selanjutnya, data diperiksa terhadap kemungkinan nilai hilang atau tidak valid dan kolom tanggal disusun sebagai indeks deret waktu. Setelah tahap tersebut, nilai *Close* dinormalisasi ke rentang [0,1] menggunakan *MinMaxScaler*. Normalisasi digunakan untuk menyeragamkan skala input dan mendukung proses pelatihan jaringan saraf (Switrayana et al., 2025).

Data yang telah dinormalisasi selanjutnya diubah menjadi bentuk *supervised learning* menggunakan teknik *sliding window*. Panjang jendela ditetapkan sebesar 60 hari, sehingga 60 harga penutupan sebelumnya digunakan untuk memprediksi harga pada hari ke-61. Panjang jendela 60 hari dipilih untuk menyediakan konteks historis sekitar tiga bulan perdagangan dan mengacu pada penggunaan data sekuensial dalam penelitian LSTM untuk prediksi saham (Kulkarni et al., 2024; Chaudhary, 2025). Parameter ini merupakan konfigurasi penelitian dan bukan hasil optimasi komparatif.

Setelah pembentukan sekuens, dataset dibagi secara kronologis menjadi 80% data pelatihan dan 20% data pengujian. Hasil pembentukan data menghasilkan X_{train} berukuran (541, 60, 1) dan X_{test} berukuran (91, 60, 1).

D. Pembangunan dan Pelatihan Model LSTM

Model dibangun menggunakan TensorFlow dan API Keras dengan arsitektur *stacked LSTM*. Arsitektur terdiri atas dua lapisan LSTM dengan masing-masing 100 unit, dua lapisan *dropout* dengan *rate* 0,2, serta satu lapisan *Dense* dengan satu unit sebagai keluaran regresi. Konfigurasi lengkap ditunjukkan pada Tabel 2.

Tabel 2. Arsitektur Final Model LSTM

Parameter	Konfigurasi
LSTM Layer 1	100 unit, return_sequences=True
Dropout Layer 1	Rate 0.2
LSTM Layer 2	100 unit
Dropout Layer 2	Rate 0.2
Dense	1 unit
Optimizer	Adam
Loss Function	Mean Squared Error (MSE)
Maximum Epoch	50
Batch Size	32
Validation Set	10% dari data pelatihan
EarlyStopping	Patience 10 epoch

Model dikompilasi menggunakan *optimizer* Adam dan fungsi *loss* *Mean Squared Error* (MSE). Adam digunakan sebagai algoritma optimasi adaptif yang sesuai untuk pelatihan jaringan saraf, sedangkan MSE digunakan karena penelitian ini merupakan permasalahan regresi dengan keluaran berupa nilai harga kontinu.

Jumlah pelatihan ditetapkan maksimum 50 *epoch* sebagai batas atas proses pembelajaran. Mekanisme *EarlyStopping* dengan *patience* 10 digunakan agar pelatihan dapat dihentikan apabila *validation loss* tidak lagi mengalami perbaikan, sehingga jumlah *epoch* efektif ditentukan berdasarkan performa validasi model.

E. Evaluasi Model

Model yang telah dilatih diuji menggunakan data pengujian yang tidak digunakan selama proses pelatihan. Kinerja model dievaluasi menggunakan *Root Mean Squared Error* (RMSE) dan *Mean Absolute Error* (MAE). Kedua metrik digunakan untuk mengukur selisih antara harga aktual dan harga hasil prediksi, dengan nilai yang lebih kecil menunjukkan deviasi prediksi yang lebih rendah.

Secara matematis, RMSE dirumuskan sebagai:

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

sedangkan MAE dirumuskan sebagai:

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

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil implementasi model *Long Short-Term Memory* (LSTM) untuk melakukan *forecasting* harga penutupan saham Apple Inc. (AAPL) menggunakan data historis Yahoo Finance. Hasil penelitian mencakup proses *preprocessing*, pelatihan dan validasi model, evaluasi kuantitatif menggunakan RMSE dan MAE, serta analisis visual terhadap kesesuaian harga aktual dan hasil prediksi.

A. Hasil Preprocessing Data

Data historis saham AAPL yang diperoleh melalui pustaka *yfinance* terlebih dahulu melalui tahap seleksi dan pemeriksaan data sebelum digunakan dalam pelatihan model. Penelitian menggunakan harga penutupan (*Close*) sebagai satu-satunya variabel dalam pembentukan sekuens LSTM. Dataset yang digunakan mencakup periode 1 Januari 2022 hingga 31 Desember 2024 dengan total 753 hari perdagangan.

Nilai harga penutupan kemudian dinormalisasi ke dalam rentang $[0,1]$ menggunakan *MinMaxScaler*. Transformasi ini menghasilkan skala data yang seragam sehingga dapat digunakan sebagai masukan jaringan saraf. Penggunaan normalisasi dalam pemodelan harga saham berbasis *deep learning* juga didukung oleh Switrayana et al. (2025), yang menunjukkan bahwa metode *data scaling* berpengaruh terhadap kinerja model prediksi.

Tabel 3. Perbandingan Data Sebelum dan Sesudah Normalisasi

Date	Close	Close Normalized
2022-01-03	178.6456451	0.409144065
2022-01-04	176.3783264	0.392346052
2022-01-05	171.6867065	0.357586981
2022-01-06	168.8206940	0.336353391
2022-01-07	168.9875488	0.337589578
2022-01-10	169.0071411	0.337734732
2022-01-11	171.8437805	0.358750704
2022-01-12	172.2854309	0.362022784
...	...	...
2024-12-23	254.6557159	0.972284200
2024-12-24	257.5786743	0.993939688
2024-12-26	258.3966675	1.000000000
2024-12-27	254.9749298	0.974649178
2024-12-30	251.5930786	0.949593864


Tabel 3 menunjukkan bahwa nilai harga penutupan berhasil ditransformasikan ke rentang $[0,1]$. Hasil tersebut menunjukkan keberhasilan proses normalisasi, tetapi tidak digunakan sebagai dasar untuk menyatakan ada atau tidaknya *outlier*, karena *Min-Max Scaling* hanya mengubah skala data dan bukan merupakan metode deteksi *outlier*.

Setelah normalisasi, data dibentuk menjadi sekuens menggunakan *sliding window* sepanjang 60 hari. Setiap 60 harga penutupan digunakan sebagai input untuk memprediksi harga pada hari berikutnya. Setelah pembentukan sekuens, dataset dibagi secara kronologis menjadi 80% data pelatihan dan 20% data pengujian.

B. Hasil Pelatihan dan Validasi Model

Model yang digunakan merupakan *stacked LSTM* dengan dua lapisan LSTM yang masing-masing terdiri atas 100 unit. Setiap lapisan LSTM diikuti oleh *dropout* dengan *rate* 0,2, sedangkan lapisan keluaran menggunakan satu unit *Dense*. Konfigurasi tersebut sesuai dengan arsitektur yang telah dijelaskan pada Tabel 2.

Model dilatih menggunakan *optimizer* Adam dan *loss function* *Mean Squared Error* (MSE), dengan *batch size* 32 dan maksimum 50 epoch. Sebanyak 10% dari data pelatihan digunakan sebagai data validasi, sedangkan mekanisme *EarlyStopping* dengan *patience* 10 epoch diterapkan untuk memantau *validation loss*.




Gambar 2. Grafik Training dan Validation Loss Model LSTM

Berdasarkan Gambar 2, *training loss* dan *validation loss* mengalami penurunan yang tajam pada beberapa epoch awal, kemudian bergerak pada nilai yang relatif rendah dan stabil hingga akhir proses pelatihan. Kedua kurva juga menunjukkan pola yang relatif berdekatan tanpa divergensi yang besar. Kondisi tersebut menunjukkan bahwa selama proses pelatihan tidak terlihat indikasi *overfitting* yang kuat, meskipun grafik *loss* saja tidak dapat digunakan untuk menyatakan secara absolut bahwa model sepenuhnya bebas dari *overfitting*.

Pola penurunan *loss* menunjukkan bahwa proses optimasi berhasil menyesuaikan bobot model terhadap pola dalam data pelatihan. Penggunaan *dropout* sebesar 0,2 dan validasi selama proses pelatihan juga berfungsi sebagai bagian dari mekanisme regularisasi dan pemantauan kemampuan generalisasi model.

C. Hasil Prediksi Harga Saham

Setelah proses pelatihan selesai, model diuji menggunakan data pengujian untuk mengevaluasi kemampuan prediksi terhadap data yang tidak digunakan pada proses pelatihan. Gambar 3 menunjukkan perbandingan antara harga penutupan aktual saham AAPL dan hasil prediksi LSTM selama periode pengujian.



Gambar 3. Visualisasi Perbandingan Harga Aktual dan Prediksi LSTM

Secara visual, garis prediksi mengikuti pola umum pergerakan harga aktual. Model mampu mengikuti kecenderungan kenaikan maupun penurunan harga pada sebagian besar periode pengujian. Namun, terdapat beberapa bagian ketika garis prediksi menunjukkan respons yang lebih halus dibandingkan harga aktual, terutama ketika terjadi perubahan harga yang relatif tajam.

Karakteristik tersebut menunjukkan bahwa model dapat mempelajari pola temporal utama dari harga historis, tetapi mempunyai keterbatasan dalam mengikuti perubahan harga yang terjadi secara mendadak. Hal ini konsisten dengan sifat LSTM yang memanfaatkan informasi dari urutan data sebelumnya sehingga prediksi yang dihasilkan cenderung merefleksikan pola temporal yang telah dipelajari.

Evaluasi kuantitatif terhadap data pengujian disajikan pada Tabel 4.

Tabel 4. Hasil Evaluasi Kuantitatif Model LSTM

Metrik Evaluasi	Nilai
Root Mean Squared Error (RMSE)	3.31
Mean Absolute Error (MAE)	2.68

Nilai RMSE sebesar 3,31 menunjukkan besarnya kesalahan prediksi dengan penalti yang lebih besar terhadap deviasi yang tinggi, sedangkan MAE sebesar 2,68 menunjukkan bahwa rata-rata selisih absolut antara harga prediksi dan harga aktual adalah sekitar USD 2,68 pada data pengujian. Nilai ini konsisten dengan hasil utama yang dilaporkan dalam penelitian.

Penggunaan RMSE dan MAE memberikan dua perspektif terhadap kesalahan prediksi. MAE lebih mudah diinterpretasikan karena berada pada satuan harga yang sama dengan data aktual, sedangkan RMSE lebih sensitif terhadap kesalahan dengan magnitudo yang lebih besar. Oleh karena itu, kombinasi keduanya memberikan gambaran yang lebih lengkap mengenai performa model dibandingkan penggunaan satu metrik saja.

D. Analisis dan Pembahasan

Hasil penelitian menunjukkan bahwa konfigurasi *stacked LSTM* yang digunakan dapat mempelajari pola temporal harga penutupan saham AAPL dan menghasilkan prediksi yang secara umum mengikuti arah pergerakan harga aktual. Hasil tersebut didukung oleh visualisasi *actual versus predicted* serta nilai RMSE 3,31 dan MAE 2,68 pada data pengujian.

Kemampuan model dalam mengikuti pola harga sejalan dengan karakteristik LSTM yang dirancang untuk mempertahankan informasi dalam urutan data melalui mekanisme memori dan gerbang internal (Sherstinsky, 2020). Hasil ini juga sejalan dengan penelitian Li et al. (2023) dan Kulkarni et al. (2024) yang menunjukkan penerapan LSTM pada pemodelan harga saham berbasis data historis.

Proses *preprocessing* turut menjadi bagian penting dalam implementasi model. Normalisasi menggunakan *Min-Max Scaling* memastikan data berada dalam rentang yang seragam sebelum digunakan dalam proses pelatihan. Switrayana et al. (2025) juga menunjukkan bahwa metode *data scaling* dapat memengaruhi kinerja model *deep learning* pada prediksi harga saham. Namun, karena penelitian ini hanya menggunakan harga penutupan sebagai satu-satunya variabel input, kemampuan model tetap dibatasi oleh informasi historis yang terkandung dalam variabel tersebut.

Pada Gambar 3 terlihat bahwa model dapat mengikuti tren utama, tetapi prediksi cenderung lebih halus pada beberapa periode ketika harga aktual mengalami perubahan yang relatif tajam. Kondisi ini menunjukkan bahwa pergerakan harga yang dipengaruhi oleh informasi eksternal, sentimen pasar, peristiwa ekonomi, atau perubahan kondisi perusahaan tidak sepenuhnya dapat direpresentasikan hanya melalui pola historis harga penutupan. Oleh karena itu, hasil prediksi lebih tepat dipandang sebagai informasi tambahan berbasis pola historis, bukan sebagai jaminan terhadap pergerakan harga atau rekomendasi transaksi.

Hal tersebut juga berkaitan dengan implikasi praktis penelitian. Model LSTM dapat digunakan untuk membantu memberikan gambaran mengenai kecenderungan harga berdasarkan pola historis yang telah dipelajari. Namun, penerapannya dalam keputusan investasi tetap memerlukan pertimbangan terhadap faktor lain, termasuk kondisi fundamental, indikator teknikal, risiko pasar, dan informasi eksternal. Pendekatan berbasis data dalam pasar modal pada dasarnya juga dapat dikombinasikan dengan teknik analisis dan optimasi lain untuk mendukung proses pengambilan keputusan secara lebih sistematis (Nasution & Al-Khowarizmi, 2025).

4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan dan mengevaluasi model *Long Short-Term Memory* (LSTM) untuk *forecasting* harga penutupan saham Apple Inc. (AAPL) menggunakan data historis Yahoo Finance periode 1 Januari 2022 hingga 31 Desember 2024. Model *stacked LSTM* yang terdiri atas dua lapisan LSTM dengan *dropout* 0,2 mampu menghasilkan prediksi yang secara umum mengikuti tren harga aktual pada data pengujian. Evaluasi kuantitatif menghasilkan nilai *Root Mean Squared Error* (RMSE) sebesar 3,31 dan *Mean Absolute Error* (MAE) sebesar 2,68, sedangkan visualisasi menunjukkan bahwa prediksi cenderung mengikuti pola pergerakan harga, meskipun terdapat deviasi pada beberapa periode dengan perubahan harga yang lebih tajam. Hasil tersebut menunjukkan bahwa konfigurasi LSTM yang digunakan dapat mempelajari dependensi temporal dari data historis harga penutupan AAPL, tetapi belum dapat digunakan untuk menyimpulkan keunggulan empiris terhadap model lain karena penelitian ini tidak melakukan perbandingan langsung dengan *baseline* seperti ARIMA atau regresi linier. Penelitian juga masih terbatas pada penggunaan satu variabel input, yaitu harga penutupan, sehingga pengembangan selanjutnya dapat mencakup penambahan volume perdagangan, indikator teknikal, sentimen berita, dan variabel makroekonomi. Selain itu, evaluasi model hibrida seperti SVM-LSTM (Agarwal et al., 2025), Bi-LSTM (Alizadegan et al., 2025), atau mekanisme *attention* (Pardeshi et al., 2023; Chaudhary, 2025), serta optimasi *hyperparameter* seperti jumlah unit, *batch size*, *learning rate*, dan panjang *time step* dapat dilakukan untuk mengetahui konfigurasi yang lebih sesuai terhadap dinamika pasar yang lebih kompleks. Perbandingan kuantitatif dengan model statistik maupun *machine learning* lain juga disarankan agar kinerja LSTM dapat dinilai secara lebih objektif pada penelitian selanjutnya.

REFERENSI

- Agarwal, S., Sharma, S., Faisal, K. N., & Sharma, R. R. (2025). Time-series forecasting using SVM-D-LSTM: A hybrid approach for stock market prediction. *Journal of Probability and Statistics*, 2025(1), Article 9464938. <https://doi.org/10.1155/jpas/9464938>
- Alizadegan, H., Rashidi Malki, B., Radmehr, A., Karimi, H., & Ilani, M. A. (2025). Comparative study of long short-term memory (LSTM), bidirectional LSTM, and traditional machine learning approaches for energy consumption prediction. *Energy Exploration & Exploitation*, 43(1), 281–301. <https://doi.org/10.1177/01445987241269496>
- Andi, T., & Kusuma, C. J. C. (2025). Stock price forecasting using long short-term memory. *Internet of Things and Artificial Intelligence Journal*, 5(1), 187–193. <https://doi.org/10.31763/iota.v5i1.900>
- Chaudhary, R. (2025). Advanced stock market prediction using long short-term memory networks: A comprehensive deep learning framework. *arXiv*. <https://doi.org/10.48550/arXiv.2505.05325>
- Gao, Y., Wang, R., & Zhou, E. (2021). Stock prediction based on optimized LSTM and GRU models. *Scientific Programming*, 2021(1), Article 4055281. <https://doi.org/10.1155/2021/4055281>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Kulkarni, S. A., Gurav, S., Lahade, A., Gudavalekar, D., & Sangale, N. (2024). Stock price prediction using LSTM. *Indian Journal of Computer Science and Technology*, 3(1), 22–24. <https://doi.org/10.59256/indjst.20240301001>
- Li, Z., Yu, H., Xu, J., Liu, J., & Mo, Y. (2023). Stock market analysis and prediction using LSTM: A case study on technology stocks. *Innovations in Applied Engineering and Technology*, 2(1), 1–6. <https://doi.org/10.62836/iaet.v2i1.162>
- Nasution, M. A., & Al-Khowarizmi, A.-K. (2025). Data-driven portfolio optimization using K-means and Markowitz model: Evidence from LQ45 stocks. *Economic: Journal Economic and Business*, 4(2), 349–354. <https://doi.org/10.56495/ejeb.v4i2.1155>
- Pardeshi, K., Gill, S. S., & Abdelmoniem, A. M. (2023). Stock market price prediction: A hybrid LSTM and sequential self-attention based approach. *arXiv*. <https://doi.org/10.48550/arXiv.2308.04419>
- Sherstinsky, A. (2020). Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404, Article 132306. <https://doi.org/10.1016/j.physd.2019.132306>
- Switrayana, I. N., Hammad, R., Irfan, P., Sujaka, T. T., & Nasri, M. H. (2025). Comparative analysis of stock price prediction using deep learning with data scaling method. *Jurnal Teknologi Informasi dan Multimedia*, 7(1), 78–90. <https://doi.org/10.35746/jtim.v7i1.650>