Prediksi Harga Saham Perbankan di Indeks LQ45 Menggunakan Model Long Short-Term Memory (LSTM) dengan Menggunakan Data Hybrid

Fatizanolo Buulolo[1*], Marlina Setia Sinaga[2]
[1,2] Matematika, Universitas Negeri Medan, Kota Medan, 20221, Indonesia
*Corresponding Author: fatibuulolo@unimed.ac.id

Abstrak

Penelitian ini bertujuan untuk memprediksi harga penutupan saham BBCA, BBNI, BBRI, BBTN, dan BMRI menggunakan model Long Short-Term Memory (LSTM) dengan Algoritma Genetika. Algoritma Genetika digunakan untuk mencari kombinasi fitur-fitur serta hyperparameter yang digunakan dalam jaringan. Setiap kandidat solusi (individu) dievaluasi berdasarkan fitness-nya, yaitu nilai validation loss terendah yang dicapai selama pelatihan. Evaluasi pada data uji menunjukkan performa prediksi harian yang sangat baik dengan MAPE berkisar 1,01–1,21% dan RMSE sesuai skala harga; untuk horizon satu bulan, RMSE meningkat seiring skala harga dan MAPE berada pada rentang 5,40–16,43% (sebagian besar <10%). Implikasi penelitian ini adalah bahwa pendekatan LSTM dapat berfungsi sebagai sistem pendukung keputusan investasi jangka pendek dan menengah, dengan potensi peningkatan akurasi lebih lanjut jika dikombinasikan dengan data non-historis (mis. sentimen berita).
Kata kunci: Long Short-Term Memory; Algoritma Genetika; Prediksi Saham Perbankan; Data Historis; Indikator Teknikal

Abstract

This study aims to predict the closing prices of BBCA, BBNI, BBRI, BBTN, and BMRI stocks using a Long Short-Term Memory (LSTM) model with Genetic Algorithm. The Genetic Algorithm was employed to search for combinations of input features and network hyperparameters. Each candidate solution was evaluated by its fitness, i.e., the lowest validation loss achieved during training. Evaluation on test data shows strong one-day-ahead performance with MAPE ranging from 1.01% to 1.21% and RMSE values consistent with the price scale; for the one-month horizon, RMSE increases with price scale and MAPE ranges from 5.40% to 16.43% (majority < 10%). The implication of this study is that an LSTM can serve as a decision-support system for short- and medium-term investments, with potential for further accuracy improvements if combined with non-historical data (e.g., news sentiment).
***Keywords**: Long Short-Term Memory; Genetic Algorithm; Banking Stock Prediction; Historical Data; Technical Indicators*

Citation: Buulolo, F., & Sinaga, M. S. (2025). Prediksi Harga Saham Perbankan di Indeks LQ45 Menggunakan Model Long Short-Term Memory (LSTM) dengan Menggunakan Data Hybrid. *Prodising Seminar Nasional Jurusan Matematika 2025*. 743 – 749.

PENDAHULUAN

Pergerakan harga saham yang sangat volatil dan dipengaruhi banyak faktor membuat tugas prediksi harga saham menjadi rumit dan berisiko bagi investor (Griffith et al., 2020). Jumlah investor ritel dari tahun 2019 hingga tahun 2022 mengalami kenaikan (Astuti, 2024). Kenaikan partisipasi pasar dan tingkat likuiditas yang lebih tinggi menuntut pengembangan metode prediksi yang lebih andal untuk mendukung pengambilan keputusan investasi. Kecerdasan buatan (AI) kini dianggap mampu menghasilkan prediksi yang lebih akurat daripada metode konvensi (Muhammad et al., 2024). Di antara indeks pasar yang mewakili saham likuid di Indonesia, daftar LQ45 termasuk beberapa saham sektor perbankan menjadi fokus karena perannya dalam stabilitas dan pertumbuhan pasar keuangan (Dwi Ceysa et al., 2024).

Penelitian modern pada prediksi pasar saham banyak memanfaatkan model jaringan saraf berulang seperti LSTM, sering kali dikombinasikan dengan sumber data hibrida (data historis, indikator teknikal, dan analisis sentimen). (Jing et al., 2021) Menggunakan analisis sentimen dan data historis saham pada model LSTM. (Lin et al., 2022; Lu et al., 2020; Wu et al., 2022) Menggunakan hibrida data seperti data historis, indikator teknikal dan analisis sentimen. (Haryono et al., 2024) menunjukkan bahwa model LSTM dan GRU lebih unggul dibandingkan CNN dan GCN dalam memprediksi saham BBCA, BBRI, dan BMR. (Hansun & Young, 2021) menggunakan model RNN-LSTM untuk memprediksi saham-saham indeks LQ45 sektor perbankan. (Wahab et al., 2024) Menggunakan model LSTM dalam memprediksi saham-saham di LQ45 sektor finansial. (Supri et al., 2023) Menggunakan model LSTM dalam memprediksi indeks saham yang berada di Asia.

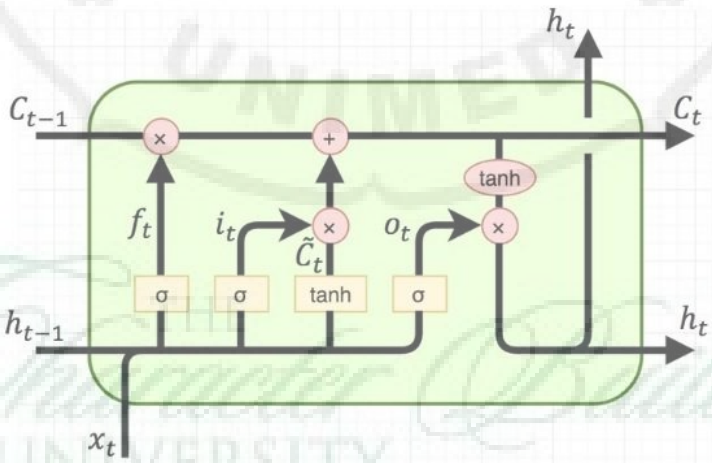
Beberapa studi juga menunjukkan keuntungan penggunaan seleksi fitur dan optimasi hyperparameter. (Zhou et al., 2022) menggunakan seleksi fitur sebelum model CNN–BiGRU, yang terbukti meningkatkan akurasi dan efisiensi model. (Wei et al., 2022) menggunakan TabNet untuk seleksi fitur sebelum LSTM, yang terbukti meningkatkan akurasi dibanding baseline. (Huiyong & Wang, 2025) menggunakan optimisasi evolusioner untuk seleksi fitur dan pemilihan hyperparameter LSTM, yang terbukti meningkatkan performa prediksi. Meskipun demikian, masih terdapat celah penelitian pada

penerapan simultan metode seleksi fitur dan optimasi hyperparameter yang terotomasi pada beberapa saham sektor perbankan LQ45 secara terpadu.

Artikel ini mengusulkan pendekatan yang menggabungkan Long Short-Term Memory dengan algoritma genetika. Pendekatan ini diharapkan meningkatkan kemampuan generalisasi model, memperkecil dimensionalitas input, serta mengurangi kebutuhan intervensi manual dalam pemilihan fitur. Penggunaan algoritma genetika dipilih karena kemampuannya menavigasi ruang solusi besar secara efisien tanpa asumsi linearitas, serta kemampuannya untuk menangani kombinasi fitur yang tidak mudah dieksplorasi oleh metode deterministik (Feng, 2024). Pendahuluan harus berisi (secara berurutan) latar belakang umum, kajian literatur terdahulu (*state of the art*) sebagai dasar pernyataan kebaruan ilmiah dari artikel, pernyataan kebaruan ilmiah, dan permasalahan penelitian atau hipotesis. Di bagian akhir pendahuluan harus dituliskan tujuan kajian artikel tersebut. Di dalam format artikel ilmiah tidak diperkenankan adanya tinjauan pustaka sebagaimana di laporan penelitian, tetapi diwujudkan dalam bentuk kajian literatur terdahulu (*state of the art*) untuk menunjukkan kebaruan ilmiah artikel tersebut. Ditulis dengan huruf Times New Roman, 11 pt, Regular, Jastified, spasi line 1,15.

Seleksi fitur sadalah proses pemilihan subset fitur (variabel) dari dataset yang paling relevan dan berpengaruh untuk digunakan dalam model prediksi atau analisis (Sarker, 2021). Menurut (Sarker et al., 2020) berikut adalah manfaat Feature Selection (FS): (1) mengatasi Masalah Dimensi Tinggi: Membantu menyelesaikan masalah data berdimensi tinggi dalam dataset kontekstual; (2) meningkatkan Pemahaman Data: Memberikan pemahaman yang lebih baik tentang data dan fitur yang signifikan; (3) meningkatkan Akurasi Prediksi: Memilih fitur paling relevan untuk menghasilkan model prediksi yang lebih akurat; (4) mengurangi Biaya Komputasi: Mengurangi jumlah fitur yang diproses sehingga menghemat waktu pelatihan dan penggunaan sumber daya komputasi; (5) menghindari *Overfitting*: Mengurangi risiko overfitting dengan menghapus fitur yang tidak relevan atau berlebihan; (6) membangun Model Kontekstual yang Efektif: Memilih jumlah fitur yang optimal untuk menciptakan model berbasis konteks yang lebih efektif dan akurat; dan (7) menyaring Fitur yang Tidak Signifikan: Menghapus fitur yang kurang signifikan, tidak relevan, atau redundan dengan menganalisis pola dan ketergantungan data.

Kemudian LSTM adalah struktur RNN yang khusus dirancang untuk menangkap ketergantungan temporal dengan memperkenalkan tiga gerbang yaitu gerbang lupa (*forget gate*), gerbang input (*input gate*), dan gerbang output (*output gate*) yang mengatur aliran informasi (Xu et al., 2024), ditunjukkan pada Gambar 1.



Gambar 1. Struktur Sederhana Sel LSTM

$$f_t = \sigma(W_f \bullet h_{t-1} + x_t + bf) \quad (1)$$
$$i_t = \sigma(W_i \bullet h_{t-1} + x_t + bi) \quad (2)$$
$$o_t = \sigma(W_o \bullet h_{t-1} + x_t + bo) \quad (3)$$
$$C_t = f_t * C_{t-1} + i_t \times g_t \quad (4)$$

f, *i*, dan *o* masing-masing merupakan vektor dari forget gate, input gate, dan output gate; *C* adalah vektor cell state; *x* dan *h* merupakan vektor input dan output; *W* melambangkan matriks bobot, dan *b* merupakan vektor bias untuk masing-masing gerbang (*f*, *i*, dan *o*). Subskrip *t* dan *t–1* menunjukkan waktu saat ini dan waktu satu langkah sebelumnya. Forget Gate (f_t): Gerbang ini memutuskan informasi mana yang harus dilupakan atau disimpan dengan memasukkan status tersembunyi sebelumnya h_{t-1} dan input saat ini x_t melalui fungsi sigmoid (σ). Semakin mendekati nilai satu, informasi cenderung disimpan, sedangkan nilai yang mendekati nol menunjukkan informasi tersebut diabaikan (Bataineh & Kaur,

2021). Input Gate (i_t): Gerbang ini memutuskan informasi mana yang akan ditambahkan ke dalam *cell state* (Hu et al., 2021). Output Gate (o_t): Gerbang output ini, *hidden state* sebelumnya h_{t-1} dan input saat ini x_t digunakan sebagai input untuk fungsi sigmoid, untuk menentukan informasi yang akan dibawa ke langkah berikutnya atau menjadi hasil output untuk lapisan berikutnya.

Metrik evaluasi digunakan untuk menilai kinerja model secara keseluruhan, terutama setelah pelatihan selesai. Metrik ini membantu memberikan pemahaman tentang seberapa baik model dapat melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya, sehingga metrik evaluasi lebih difokuskan pada penilaian performa dan interpretabilitas hasil (Terven et al., 2025). RMSE menunjukkan seberapa jauh prediksi menyimpang dari nilai aktual secara rata-rata. Nilai RMSE yang lebih rendah mencerminkan kinerja model yang lebih baik, karena selisih antara nilai prediksi dan nilai aktual menjadi lebih kecil (Terven et al., 2025).

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \quad (5)$$

Dimana; *n* merupakan banyaknya sampel; y_i merupakan nilai aktual ke-*I*; $\hat{y}_i$ merupakan nilai prediksi ke-i. Mean *Absolute Percentage Error* (MAPE) mengukur rata-rata kesalahan persentase dalam prediksi model dibandingkan dengan nilai sebenarnya. Statistik MAPE dapat diartikan sebagai berikut: ramalan dikatakan sangat akurat jika MAPE ≤ 10%, akurat jika MAPE berada di antara 10%–20%, cukup akurat jika MAPE berada di antara 20%–50%, dan tidak akurat jika MAPE > 50% (Jenčová et al., 2025).

$$MAPE = \frac{1}{n}\sum_{i=1}^{n}\frac{|y_i - \hat{y}_i|}{y_i} \times 100 \quad (6)$$

Dimana; *n* merupakan banyaknya sampel; y_i merupakan nilai aktual ke-*I*; dan $\hat{y}_i$ merupakan nilai prediksi ke-*i*

METODE PENELITIAN

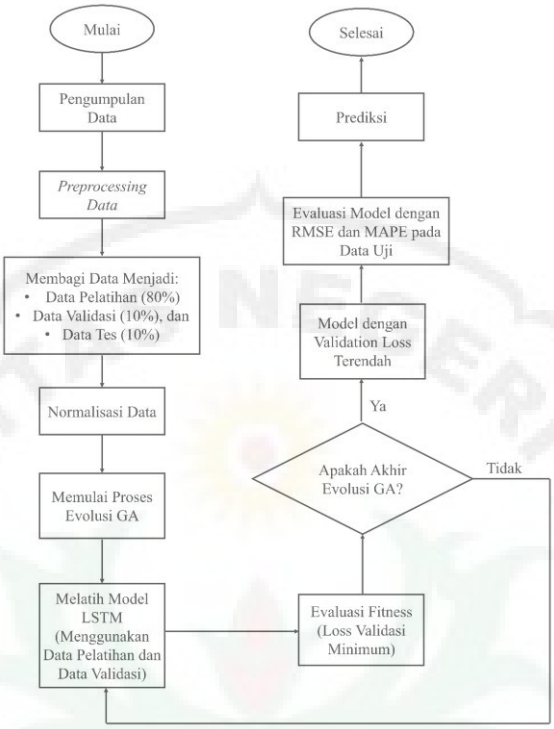
Prosedur penelitian ini dimulai dengan pengumpulan data historis harga saham dan indikator teknikal untuk saham perbankan LQ45 dalam rentang April 2010 hingga April 2025 Pada penelitian ini, digunakan beberapa indikator teknikal yaitu RSI, MACD, DPO, BIAS, Bollinger Bands, ROC, Momentum, Stochastic RSI, dan RVI. Seluruh indikator tersebut dipilih karena masing-masing memiliki kemampuan dalam merepresentasikan dinamika pergerakan harga berdasarkan komponen harga penutupan. Data mentah yang diperoleh kemudian dipersiapkan dengan langkah-langkah praproses: menghapus variabel yang memiliki korelasi tinggi untuk mengurangi redundansi, menangani nilai yang hilang agar tidak mengganggu pelatihan model, serta menyamakan ukuran sampel antar variabel sehingga setiap fitur mempunyai urutan waktu yang konsisten. Seluruh fitur kandidat yang tersisa dinormalisasi menggunakan Min-Max Scaling untuk mengatasi perbedaan skala antar variabel sebelum dimasukkan ke tahap pemodelan.

Pembagian data dilakukan secara berurutan waktu menggunakan skema *sliding window* sehingga sifat time-series tetap terjaga; proporsi yang digunakan adalah 80% untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian. Setiap sampel dibentuk menggunakan jendela input sepanjang 14 hari kerja untuk memprediksi harga satu hari kerja ke depan. Pada tahap pemodelan, dibangun arsitektur dasar LSTM yang terdiri dari dua lapis LSTM, satu lapis dropout, dan satu lapis dense. Seleksi fitur dan optimasi konfigurasi model dilakukan secara terpadu menggunakan Algoritma Genetika (GA): setiap individu pada populasi GA merepresentasikan konfigurasi lengkap yang meliputi jumlah neuron pada Layer 1 dan Layer 2, tingkat dropout, jumlah epoch pelatihan, serta vektor biner yang menunjukkan subset fitur yang dipilih.

Untuk setiap individu GA, model LSTM yang sesuai dilatih pada set pelatihan dan dievaluasi pada set validasi; nilai fitness individu ditentukan oleh nilai minimum validation loss yang tercapai selama proses pelatihan dengan menggunakan optimizer Adam. Untuk mencegah overfitting dan menghemat biaya komputasi, diterapkan mekanisme *early stopping* yang memantau metrik validation loss; pelatihan dihentikan lebih awal jika tidak terdapat perbaikan selama 10 epoch berturut-turut. Proses evolusi GA (meliputi seleksi, crossover, dan mutasi) dijalankan selama 50 generasi dengan ukuran populasi sebanyak 20 individu; laju mutasi ditetapkan 0,2 dan laju crossover 0,5. Elitisme diterapkan dengan mempertahankan 20% individu terbaik pada setiap generasi untuk menjamin transfer solusi berkualitas ke generasi berikutnya. Pada akhir proses pencarian, individu dengan nilai validation loss terendah dipilih sebagai model terbaik.

Model terbaik tersebut kemudian dievaluasi secara menyeluruh pada set pengujian menggunakan metrik kuantitatif MAPE dan RMSE untuk menilai akurasi dan presisi prediksi. Akhirnya, model terpilih digunakan untuk melakukan prediksi harga penutupan saham selama satu bulan ke depan. Seluruh eksperimen direplikasi beberapa kali

untuk mengestimasi variabilitas hasil, dan prosedur pelaksanaan serta parameter GA dicatat agar eksperimen dapat direproduksi.

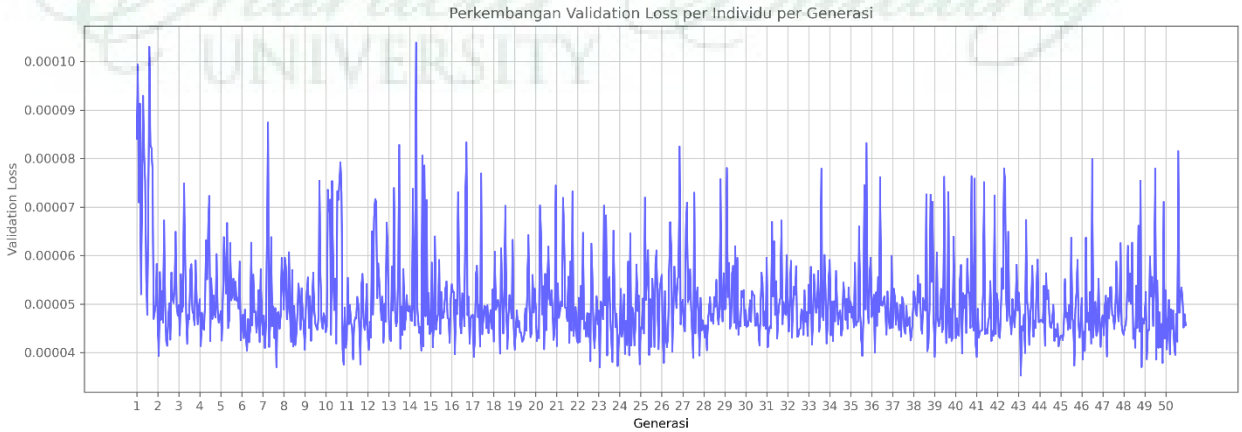


Gambar 1. Diagram Alir Penelitian

Berisi metode yang digunakan dalam pemecahan permasalahan termasuk metode analisis. Peralatan-peralatan yang dituliskan di bagian ini hanya berisi peralatan-peralatan utama saja dilengkapi dengan merk (misalnya: Furnace elektrik (Carbolite)). Komponen-komponen peralatan penunjang tidak perlu dituliskan. Rangkaian alat utama sebaiknya disajikan di bagian ini dilengkapi dengan keterangan gambar. Keterangan gambar diletakkan menjadi bagian dari judul gambar (*figure caption*) bukan menjadi bagian dari gambar. Metode-metode yang digunakan dalam penyelesaian penelitian dituliskan di bagian ini.

HASIL DAN PEMBAHASAN

Akhir evolusi Algoritma Genetika menghasilkan individu terbaik pada generasi ke-43 (individu 3), yang memiliki konfigurasi LSTM dengan dua lapisan berukuran 120 dan 156 neuron, tingkat dropout 0,13, serta jumlah epoch efektif 73 dari maksimum 83 (pelatihan dihentikan lebih awal karena tidak ada peningkatan selama 10 iterasi). Individu ini mencapai nilai validation loss terendah sebesar 0,0000353 dan memilih subset fitur yang terdiri dari BIAS, Close (harga penutupan), DPO, MACD, MOM, dan ROC. Temuan tersebut menunjukkan bahwa proses pencarian GA berhasil menemukan kombinasi hyperparameter dan fitur yang saling melengkapi sehingga menurunkan error validasi, yang mengindikasikan bahwa GA efektif dalam mengeksplorasi ruang solusi non-linier dan memilih fitur yang paling informatif untuk tugas ini.



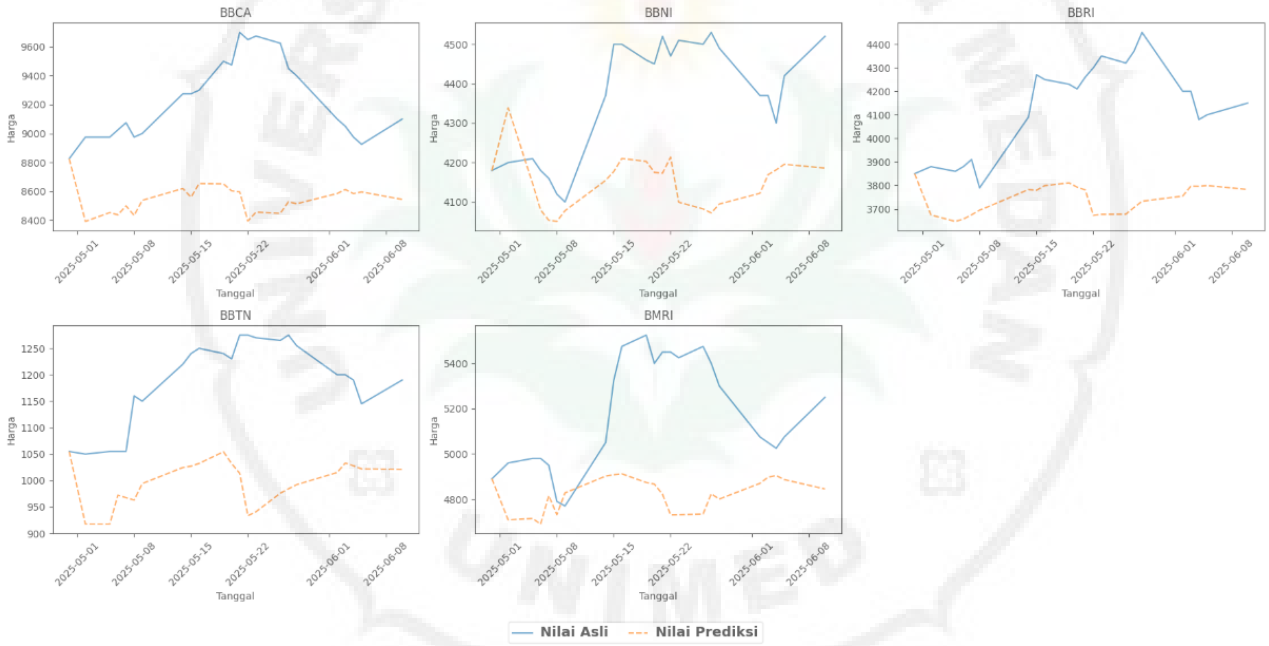
Gambar 3. Perubahan nilai *validation_loss* individu pada tiap generasi selama proses evolusi algoritma genetika

Evaluasi model pada kelima saham perbankan dilakukan setelah semua proses pelatihan selesai. Model yang sudah dilatih digunakan untuk memprediksi data uji yang telah disiapkan. Hasil evaluasi model ditampilkan pada tabel dibawah ini.

Tabel 1. Metrik Evaluasi Model Kelima Saham Perbankan

Saham Perbankan	RMSE	MAPE
BBCA	123.5184	1.0119%
BBNI	75.6223	1.1767%
BBRI	72.7966	1.1953%
BMRI	96.1470	1.1976%
BBTN	19.7353	1.2111%

Setelah evaluasi pada data uji, model terbaik yang diperoleh dari proses pencarian dengan algoritma genetika kemudian digunakan untuk menghasilkan prediksi harga penutupan selama 22 hari kerja ke depan (satu bulan). Prediksi multi-hari ini dibuat secara recursive (iteratif): model memprediksi satu hari ke depan menggunakan jendela input 14 hari, lalu nilai prediksi tersebut dimasukkan kembali sebagai bagian dari input untuk memprediksi hari berikutnya sampai tercapai horizon 22 hari.



Gambar 4. Grafik perbandingan antara nilai prediksi dan nilai asli harga

Gambar 4 menampilkan perbandingan visual antara nilai aktual (garis penuh biru) dan hasil prediksi model (garis putus-putus oranye) untuk kelima saham perbankan pada periode pengujian. Untuk perbandingan numerik dan ukuran kesalahan, lihat Tabel 2 yang memuat metrik evaluasi (RMSE dan MAPE) tiap saham.

Tabel 2. Metrik Evaluasi Hasil Prediksi Harga Saham Perbankan Untuk Periode Satu Bulan ke Depan

Perusahaan	RMSE	MAPE
BBNI	269.4475	5.400%
BBCA	768.1987	7.6995%
BMRI	440.4038	7.0958%
BBRI	437.6656	9.4846%
BBTN	211.0938	16.4320%

Secara ilmiah, kombinasi performa ini dapat dijelaskan oleh dua mekanisme utama. Pertama, seleksi fitur oleh GA mengeliminasi fitur-fitur yang berisik atau redundan sehingga input ke jaringan menjadi lebih padat dan informatif, menurunkan varians model dan mengurangi risiko overfitting. Kedua, konfigurasi arsitektur (kapasitas jaringan) bersama dengan dropout moderat dan mekanisme *early stopping* menempatkan model pada keseimbangan yang tepat antara kemampuan menangkap pola temporal dan kontrol kompleksitas, sehingga model dapat mempelajari pola jangka pendek tanpa menjadi terlalu sensitif terhadap noise historis. Analisis fitur yang terpilih memberikan wawasan ekonomi-teknikal: indikator seperti MOM, ROC, dan BIAS merepresentasikan sinyal momentum; MACD dan DPO berkaitan dengan perubahan tren dan dinamika siklus; sedangkan harga penutupan (Close) selalu menjadi indikator fundamental bagi prediksi harga jangka pendek.

Hasil eksperimen memperlihatkan dua temuan ilmiah utama. Pertama, pada prediksi satu hari ke depan model GA-LSTM menunjukkan performa sangat baik dengan MAPE berkisar 1,01–1,21% dan RMSE absolut yang tergantung pada skala harga masing-masing saham seperti ditunjukkan pada Tabel 1. Ini mengindikasikan bahwa kombinasi seleksi fitur dan penalaan hyperparameter oleh GA berhasil menyaring sinyal-sinyal relevan (momentum/volatilitas dan harga penutupan) sehingga model mampu menangkap pola jangka-pendek secara akurat. Kedua, ketika strategi prediksi diubah menjadi prediksi rekursif untuk horizon 22 hari kerja (satu bulan), terjadi penurunan tajam dalam akurasi: MAPE meningkat menjadi 5,40%–16,43% dan RMSE naik signifikan seperti ditunjukkan pada Tabel 2. Perbedaan ini menunjukkan bahwa meskipun model solid untuk horizon satu langkah, performa menurun seiring bertambahnya horizon prediksi.

Secara saintifik, fenomena penurunan akurasi pada prediksi multi-hari dapat dijelaskan oleh beberapa mekanisme yang saling berkaitan. Yang paling dominan adalah akumulasi kesalahan (*error propagation*) pada strategi rekursif: setiap prediksi satu langkah dimasukkan kembali sebagai input untuk memprediksi langkah berikutnya, sehingga kesalahan kecil awal cenderung terdifraksi dan membesar seiring iterasi. Selain itu terjadi *covariate shift* distribusi input pada saat pengujian multi-step (yang sekarang mengandung nilai prediksi) berbeda dari distribusi input saat pelatihan (didominasi oleh nilai aktual), sehingga model yang dilatih untuk satu-langkah cenderung kurang tahan terhadap kondisi input yang menyimpang. Dengan mempertimbangkan tolok ukur MAPE (Jenčová et al., 2025), mayoritas prediksi rekursif 22-hari berada pada kategori *sangat akurat* untuk saham BBNI, BBCA, BMRI, BBRI dan *akurat* untuk saham BBTN, sehingga secara kuantitatif model GA-LSTM mempertahankan kemampuan prediksi yang bermakna pada horizon satu bulan.

KESIMPULAN

Penelitian ini menunjukkan bahwa integrasi Algoritma Genetika (GA) dengan Long Short-Term Memory (LSTM) efektif untuk seleksi fitur dan penalaan hyperparameter pada tugas prediksi harga saham jangka pendek. GA menemukan konfigurasi optimal (arsitektur LSTM 120–156, dropout 0,13, epoch efektif 73, subset fitur: Close, BIAS, MOM, ROC, MACD, DPO) yang menghasilkan performa satu-langkah sangat baik (MAPE < 1,22% pada data uji), sehingga hipotesis bahwa GA meningkatkan kinerja LSTM terdukung untuk horizon 1 hari. Untuk prediksi rekursif 22 hari, akurasi menurun (MAPE 5,40%–16,43%), fenomena yang dapat dijelaskan oleh akumulasi kesalahan rekursif dan pergeseran distribusi input (covariate shift); meskipun demikian mayoritas prediksi 22-hari tetap berada pada kategori akurasi menurut tolok ukur yang digunakan. Keterbatasan utama adalah sensitivitas terhadap peristiwa eksogen dan kecenderungan error propagation pada strategi rekursif. Untuk penelitian selanjutnya disarankan menggabungkan LSTM dengan arsitektur lain (mis. CNN atau Transformer) agar dapat menangkap pola jangka panjang sekaligus sinyal jangka pendek, serta mempertimbangkan penggunaan data mingguan alih-alih harian untuk mengurangi jumlah iterasi prediksi dan menekan akumulasi error sehingga proyeksi jangka menengah menjadi lebih stabil.

UCAPAN TERIMA KASIH

Ucapan terima kasih terutama ditujukan kepada pemberi dana penelitian atau donatur. Ucapan terima kasih dapat juga disampaikan kepada pihak-pihak yang membantu pelaksanaan penelitian.

DAFTAR PUSTAKA

Altarabichi, M. G., Nowaczyk, S., Pashami, S., & Mashhadi, P. S. (2023). Fast Genetic Algorithm for feature selection — A qualitative approximation approach[Formula presented]. Expert Systems with Applications, 211.

Astuti, A. (2024). Analysis of Factors Influencing Stock Prices of Companies in the LQ45 Index: A Study Period From 2019 to 2022. JASa (Jurnal Akuntansi, Audit Dan Sistem Informasi Akuntansi), 8(2), 409–419.

Bataineh, A. al, & Kaur, D. (2021). Immunocomputing-Based Approach for Optimizing the Topologies of LSTM Networks. IEEE Access, 9, 78993–79004.

Dwi Ceysa, S., Demar Putri, J., Putri, D. A., & Siswajanthy, F. (2024). Peranan Perbankan dalam Perekonomian Indonesia. Jurnal Pendidikan Tambusai, 8(2), 25959–25964.

Feng, G. (2024). Feature selection algorithm based on optimized genetic algorithm and the application in high-dimensional data processing. PLoS ONE, 19(5).

Griffith, J., Najand, M., & Shen, J. (2020). Emotions in the Stock Market. Journal of Behavioral Finance, 21(1), 42–56.

Hansun, S., & Young, J. C. (2021). Predicting LQ45 financial sector indices using RNN-LSTM. Journal of Big Data, 8(1), 104.

Haryono, A. T., Sarno, R., & Sungkono, K. R. (2024). Stock price forecasting in Indonesia stock exchange using deep learning: A comparative study. International Journal of Electrical and Computer Engineering, 14(1), 861–869.

Huiyong, W., & Wang, Z. (2025). Stock market forecasting research based on GA-WOA-LSTM. PLOS ONE, 20(8).

Hu, H., Luo, H., & Deng, X. (2021). Health Monitoring of Automotive Suspensions: A LSTM Network Approach. Shock and Vibration, 2021.

Jenčová, S., Vašaničová, P., Košíková, M., & Miškufová, M. (2025). A Time Series Approach to Forecasting Financial Indicators in the Wholesale and Retail Trade. World, 6(1), 5.

Jing, N., Wu, Z., & Wang, H. (2021). A hybrid model integrating deep learning with investor sentiment analysis for stock price prediction. Expert Systems with Applications, 178, 115019.

Lin, Y. L., Lai, C. J., & Pai, P. F. (2022). Using Deep Learning Techniques in Forecasting Stock Markets by Hybrid Data with Multilingual Sentiment Analysis. Electronics (Switzerland), 11(21), 3513.

Lu, W., Li, J., Li, Y., Sun, A., & Wang, J. (2020). A CNN-LSTM-based model to forecast stock prices. Complexity, 2020(1), 6622927.

Muhammad, D., Ahmed, I., Naveed, K., & Bendechache, M. (2024). An explainable deep learning approach for stock market trend prediction. Heliyon, 10.

Sarker, I. H., Alqahtani, H., Alsolami, F., Khan, A. I., Abushark, Y. B., & Siddiqui, M. K. (2020). Context pre-modeling: an empirical analysis for classification based user-centric context-aware predictive modeling. Journal of Big Data, 7(1), 1–23.

Sarker, I. H. (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. SN Computer Science, 2(6), 420.

Supri, B., Rudianto, Abdurohim, Badriatul Mawadah, & Helmi Ali. (2023). Asian Stock Index Price Prediction Analysis Using Comparison of Split Data Training and Data Testing. JEMSI (Jurnal Ekonomi, Manajemen, Dan Akuntansi), 9(4), 1403–1408.

Terven, J., Cordova-Esparza, D. M., Romero-González, J. A., Ramírez-Pedraza, A., & Chávez-Urbiola, E. A. (2025). A comprehensive survey of loss functions and metrics in deep learning. Artificial Intelligence Review, 58(7), 195.

Wei, X., Ouyang, H., & Liu, M. (2022). Stock index trend prediction based on TabNet feature selection and long short-term memory. PLoS ONE, 17(12).

Wahab, A., Herdian, A., Wirawan, D., Jumaryadi, Y., Alam, S., & Fiade, A. (2024). Stock Prediction for Indonesia Stock Exchange with Long Short-Term Memory. Jurnal Ilmiah FIFO, 16(1), 96.

Wu, S., Liu, Y., Zou, Z., & Weng, T. H. (2022). S_I_LSTM: stock price prediction based on multiple data sources and sentiment analysis. Connection Science, 34(1), 44–62.

Xu, Y., Quan, R., Xu, W., Huang, Y., Chen, X., & Liu, F. (2024). Advances in Medical Image Segmentation: A Comprehensive Review of Traditional, Deep Learning and Hybrid Approaches. Bioengineering, 11(10).

Zhou, Q., Zhou, C., & Wang, X. (2022). Stock prediction based on bidirectional gated recurrent unit with convolutional neural network and feature selection. PLoS ONE, 17(2).