

Penerapan LSTM pada Prediksi Harga Saham BBKA: Akurasi dan Interpretabilitas Model

Rara Fazira ^{1,*}, Sriani ¹

¹ Program Studi Ilmu Komputer, Universitas Islam Negeri Sumatera Utara, Indonesia

* Correspondence: rarafazira27@gmail.com

Copyright: © 2025 by the authors

Received: 27 September 2025 | Revised: 31 Oktober 2025 | Accepted: 15 November 2025 | Published: 6 Desember 2025

Abstrak

Ketidakstabilan pasar keuangan akibat *volatility* dan korelasi *stock-bond* mendorong kebutuhan prediksi harga saham yang andal bagi *investment* dan *risk management*. Pendekatan *deep learning* sebelumnya bersifat *black box* dengan interpretabilitas rendah, menyulitkan *audit* dan pemahaman keputusan model. Tujuan penelitian adalah menganalisis penerapan algoritma LSTM untuk memprediksi harga penutupan harian saham BBKA.JK dan menjelaskan mekanisme gate internalnya dalam menghasilkan prediksi tersebut. Metode yang digunakan *quantitative experimental* dengan 1.390 sampel (19-09-2019 hingga 26-06-2025) dari *investing.com*, menggunakan *window* 30, 60, dan 90 hari. Hasil menunjukkan *window* 60 hari memberikan performa terbaik dengan *RMSE* 191,94 dan *MAE* 151,99, sedangkan *window* 30 hari terlalu sensitif terhadap fluktuasi harian dan 90 hari menyimpan informasi historis yang tidak lagi relevan. Kebaruan penelitian adalah analisis *gate-level interpretability* yang memetakan peran *forget gate*, *input gate*, dan *output gate* dalam pengelolaan memori dan aliran informasi, menjawab keterbatasan *black box* pada model sebelumnya. Analisis *gate activation* menunjukkan korelasi positif antara *input gate* dan *output gate* dengan fitur harga, serta korelasi negatif terhadap *volume* yang merepresentasikan mekanisme penyaringan informasi dan pengendalian memori terhadap aktivitas pasar tinggi. Temuan ini memperluas literatur *explainable deep learning in finance* dan meningkatkan transparansi serta keandalan model bagi *data-driven investment strategies* dan *risk management*.

Kata kunci: *deep learning* untuk keuangan; interpretabilitas model; long short-term memory; prediksi saham

Abstract

Financial market instability driven by volatility and stock–bond correlation increases the need for accurate stock price prediction for investment and risk management. Previous deep learning approaches act as black box models with low interpretability, hindering audit and model understanding. The purpose of this study is to analyze the application of the LSTM algorithm to predict the daily closing price of BBKA.JK shares and explain its internal gate mechanism in generating these predictions. The quantitative experimental method uses 1,390 samples (09/19/2019–06/26/2025) from investing.com with 30-, 60-, and 90-day windows. Results show that the 60-day window achieves the lowest RMSE 191.94 and MAE 151.99, while the 30-day window is overly sensitive to short-term fluctuations and the 90-day window retains irrelevant information. The novelty lies in gate-level interpretability analysis, which maps how the forget, input, and output gates manage memory and filter information, addressing black box limitations in prior models. Gate activation analysis shows a positive correlation between the input and output gates and price features, and a negative correlation with volume, representing adaptive information filtering under high market activity. This research expands explainable deep learning in finance and strengthens transparency and model trustworthiness for data-driven investment and risk management.



Keywords: *deep learning for finance; long short-term memory; model interpretability; stock prediction*

PENDAHULUAN

Pasar saham berperan sebagai barometer utama perekonomian sekaligus sarana investasi yang merepresentasikan ekspektasi pelaku pasar terhadap kondisi makroekonomi, kinerja industri, dan fundamental perusahaan. Tingkat *volatility* yang tinggi dan sifat *non-stationary* pasar keuangan menjadikan prediksi harga saham sebagai permasalahan yang rumit, sehingga penyelesaian konvensional sering gagal memberikan hasil yang akurat (Astudillo et al., 2025; Muhammad et al., 2024; Muhidin et al., 2025). Dalam dua tahun terakhir, dinamika global memperkuat risiko pasar dengan *equity volatility* meningkat pasca-invasi Rusia-Ukraina, indeks *VIX* mencapai 28,71 pada Juni 2022, harga minyak *Brent* turun dari rata-rata US\$100 per barel pada 2022 menjadi US\$83 pada 2023, dan korelasi positif saham-obligasi mengurangi efektivitas diversifikasi portofolio. *Bond volatility* bahkan sempat melampaui saham pada sebagian tahun 2023. Kapitalisasi pasar ekuitas global sempat menurun 16,2% pada 2022 sebelum meningkat kembali menjadi US\$126,7 triliun pada 2024. Kondisi tersebut menunjukkan pentingnya model prediksi yang akurat, adaptif, dan mudah dipahami cara kerjanya untuk mendukung *risk management* serta pengambilan keputusan investasi (Li et al., 2024).

Sebagai respons terhadap kondisi global yang semakin tidak stabil tersebut, penelitian ini menawarkan pendekatan baru dalam peramalan pasar domestik dengan mengombinasikan analisis *interpretability* internal dan evaluasi *horizon input* pada model *Long Short-Term Memory* (LSTM) (Attaulah & Soyusiawaty, 2025; Weber et al., 2024). Perubahan kondisi pasar yang cepat menuntut model yang tidak hanya akurat, tetapi juga mampu menjelaskan proses pengambilan keputusannya secara transparan (Černevicienė & Kabašinskas, 2024). Oleh karena itu, penelitian ini memilih PT Bank Central Asia Tbk (BBKA.JK) sebagai objek kajian karena perusahaan ini memiliki pengaruh besar terhadap pasar modal Indonesia. BBKA mencatat kapitalisasi pasar Rp1.193 triliun pada akhir 2024 dan meningkat menjadi Rp1.294 triliun per 22 Oktober 2024, dengan bobot 23,26% dalam *MSCI Indonesia Index* dan volume transaksi kuartalan yang konsisten tinggi. Likuiditas yang stabil tersebut merepresentasikan dinamika harga yang berfluktuasi dan berubah cepat, sekaligus relevan untuk menguji efektivitas model prediksi berbasis *time series* (Mahmoudi, 2025; Waqas & Humphries, 2024). Selain itu, kemampuan memproyeksikan pergerakan harga saham harian hingga jangka menengah berpengaruh langsung terhadap peningkatan efisiensi portofolio dan penguatan *risk management* lintas yurisdiksi (Beniwal et al., 2023; Mariam & Nurhaida, 2025).

Berbagai penelitian sebelumnya telah mengembangkan metode prediksi harga saham, tetapi hasil dan metodenya masih memiliki keterbatasan. Sebagai contoh, pada metode tradisional, penelitian Hartono & Widianoro (2024) menggunakan *Linear Regression* untuk memprediksi harga saham PT Unilever Indonesia, tetapi metode tersebut gagal menangkap pola *non-linear*, sehingga menghasilkan *RMSE* 56.699, menunjukkan keterbatasan model linear terhadap volatilitas pasar. Pada metode *deep learning*, Hastomo et al. (2021) menggabungkan LSTM dan *Gated Recurrent Unit* (GRU) dalam memprediksi saham *blue chip* termasuk BBKA selama pandemi COVID-19 dan memperoleh *RMSE* 1.120,65, tetapi penelitian ini tidak menganalisis mekanisme internal *gate* yang menjadi inti kemampuan memori jangka panjang LSTM. Penelitian lain oleh Kusuma (2024) menerapkan LSTM pada 17 perusahaan dengan hasil *MAPE* 2,6%, tetapi juga tidak mengevaluasi fungsi *gate* dalam arsitekturnya. Di sisi lain, penelitian Radfar (2025) menunjukkan bahwa model *Deep Neural Network* (DNN), termasuk LSTM, sering menghasilkan prediksi *false positive* dan tidak stabil pada kondisi pasar yang fluktuatif, sedangkan penelitian Bustos et al. (2025) menunjukkan belum ada algoritma *machine learning* maupun *deep learning* yang benar-benar stabil dan mudah diinterpretasikan dalam konteks prediksi harga saham. Secara teoretis, LSTM sendiri


dikembangkan dari *Recurrent Neural Network (RNN)* untuk mengatasi masalah *vanishing gradient* dan mempertahankan informasi jangka panjang melalui mekanisme *internal gate* (Bolboacă & Haller, 2024; Firouzjaee & Khalilian, 2024; Rahmadeyan & Mustakim, 2024), tetapi penelitian lainnya seperti Fuente et al. (2024), Giudici et al. (2024), dan Mahmoudi (2025) menunjukkan bahwa keterbatasan utama justru terletak pada minimnya eksplorasi terhadap *gate interpretability* dan konfigurasi model, bukan pada kelemahan algoritma itu sendiri.

Mengatasi keterbatasan dari penelitian sebelumnya, penelitian ini mengembangkan penyelesaian baru dengan menekankan dua aspek kebaruan, yaitu analisis *interpretability* internal *LSTM* dilakukan melalui pengukuran hubungan aktivasi *gate* dengan fitur harga dan volume untuk memahami proses pengambilan keputusan model, dan evaluasi *input horizon* dilakukan secara sistematis dengan membandingkan *window* 30, 60, dan 90 hari untuk menguji pengaruh panjang memori terhadap performa dan stabilitas prediksi (Bolboacă & Haller, 2024; Zhang et al., 2025). Pendekatan ini memungkinkan penggabungan antara akurasi kuantitatif dan transparansi kualitatif, sehingga model tidak hanya berfungsi sebagai alat prediksi, tetapi juga sebagai sistem yang dapat diaudit dan diinterpretasi (Giudici et al., 2024).

Tujuan penelitian ini adalah menganalisis penerapan algoritma *LSTM* dalam memprediksi harga penutupan harian saham PT Bank Central Asia Tbk (BBCA.JK) serta menjelaskan bagaimana mekanisme *gate* internalnya memproses informasi melalui aktivasi dan retensi *cell memory* dalam menghasilkan prediksi tersebut. Kontribusi penelitian ini adalah penyusunan kerangka evaluasi *input horizon* dan model *gate interpretability* yang dapat diaplikasikan pada pasar Indonesia. Sementara itu, kontribusi praktisnya mencakup pedoman penentuan *window size* optimal, pengembangan metrik *auditability* untuk mendukung manajemen risiko, dan penerapan model yang lebih transparan dalam analisis pasar keuangan yang dinamis.

METODE

Penelitian ini merupakan *single-case quantitative experimental study* yang menggunakan algoritma *Long Short-Term Memory (LSTM)* untuk memprediksi harga saham harian PT Bank Central Asia Tbk (BBCA.JK). Data sekunder periode 19 September 2019 hingga 26 Juni 2025 (1.390 sampel) diperoleh dari *investing.com*, mencakup fase pra-pandemi, pandemi, dan pasca-pandemi. Variabel independen terdiri dari Harga Pembukaan, Tertinggi, Terendah, Volume, dan Perubahan Persen, dengan harga penutupan sebagai variabel dependen. Kebaruan metodologis penelitian ini terletak pada integrasi analisis *gate-level interpretability* pada *LSTM* dan evaluasi *input horizon (window size)* secara simultan, untuk secara transparan dan terukur menjelaskan bagaimana *forget gate*, *input gate*, dan *output gate* memproses informasi multivariabel dari berbagai rentang waktu.



Gambar 1. Tahapan penelitian

Sebagaimana pada Gambar 1 setelah identifikasi masalah, tahapan penelitian meliputi *data preprocessing* yang mencakup penanganan *missing values*, pengurutan data kronologis, konversi tipe data yang relevan, dan pembagian data menggunakan *chronological split* menjadi 80% *train set* (19-09-2019 hingga 19-04-2024) dan 20% *test set* (22-04-2024 hingga 26-06-2025). Data dinormalisasi menggunakan *MinMaxScaler* karena data harga saham (fitur input)

dan target memiliki rentang nilai yang bervariasi, sehingga normalisasi ke skala 0-1 membantu model *LSTM* untuk belajar lebih stabil dan efektif, terutama karena *LSTM* sensitif terhadap skala input, serta *windowing* diterapkan dengan ukuran 30, 60, dan 90 hari untuk optimalisasi *input horizon*.

Model development dan *training* dilakukan menggunakan arsitektur *LSTM Sequential* dengan dua *LSTM layer* (64 dan 32 unit), diselingi *Dropout* (rate 0.1), dan diakhiri *Dense layer* berisi satu unit keluaran untuk prediksi. Pemilihan konfigurasi unit, *dropout*, dan *learning rate* 0.001 (untuk *optimizer Adam*) didasarkan pada keseimbangan kompleksitas model, pencegahan *overfitting*, serta stabilitas konvergensi yang terbukti empiris dalam pemodelan deret waktu keuangan. *Systematic optimization* seperti *Grid Search* atau *Bayesian Optimization* tidak diterapkan karena pendekatan tersebut berpotensi mengubah distribusi aktivasi dan dinamika internal *LSTM*, yang dapat mengganggu validitas analisis *gate-level interpretability* dan *memory retention* sebagai fokus utama penelitian ini. Model dikompilasi menggunakan fungsi *loss Mean Absolute Error (MAE)*. *Training process* dilakukan selama 100 *epochs* dengan *batch size* 32, menggunakan *EarlyStopping* (patience 10) dan *ModelCheckpoint* untuk menjaga generalisasi model.

Model evaluation dilakukan pada *test set* menggunakan metrik *Root Mean Squared Error (RMSE)* dan *Mean Absolute Error (MAE)* untuk tiga konfigurasi *window* (30, 60, 90 hari) guna mengidentifikasi model terbaik. Model dengan performa optimal digunakan untuk *prediction phase*, diikuti dengan analisis *gate-level* untuk meninjau peran *forget gate*, *input gate*, dan *output gate* dalam pengelolaan informasi historis, sehingga memberikan pemahaman mendalam tentang mekanisme internal model. Seluruh *source code* dan *dataset* akan dipublikasikan melalui repositori *GitHub* untuk mendukung transparansi dan *reproducibility* penelitian.

HASIL DAN PEMBAHASAN

Hasil

Analisis deskriptif terhadap variabel target harga penutupan BBKA.JK selama periode 2019 hingga 2025 menunjukkan bahwa harga saham memiliki rata-rata Rp7.914,41 dengan standar deviasi Rp1.488,96. Rentang harga saham berkisar dari nilai minimum Rp4.430,00 hingga maksimum Rp10.950,00, menghasilkan rentang total Rp6.520,00. Volatilitas sederhana yang dihitung berdasarkan data tersebut mencapai 18.81%, yang merepresentasikan fluktuasi harga yang signifikan selama periode observasi. Evaluasi performa model *LSTM* dilakukan pada *test set* (22 April 2024 hingga 26 Juni 2025) dengan 3 konfigurasi *window*, yaitu 30, 60, dan 90 hari. Metrik evaluasi yang digunakan adalah *RMSE* dan *MAE*, yang disajikan dalam skala harga aktual (IDR). Berdasarkan Tabel 1 rekapitulasi hasil evaluasi untuk setiap ukuran *window*, yakni perbandingan nilai *RMSE* dan *MAE*, model dengan ukuran *window* 60 hari menunjukkan performa terbaik dengan nilai kesalahan terendah pada kedua metrik.

Tabel 1. Evaluasi performa model lstm per ukuran *window*

Metrik (IDR)	Ukuran <i>Window</i>		
	30	60	90
RMSE	Rp193,83	Rp191,94	Rp193,54
MAE	Rp152,57	Rp151,99	Rp153,86


Model *LSTM* dengan ukuran *window* 60 hari, yang terbukti memiliki *best performance* berdasarkan nilai *RMSE* dan *MAE* terendah, digunakan untuk menghasilkan *prediction* harga saham BBKA.JK pada *test data*. Tabel 2 menampilkan 5 contoh dari 218 *sample* (24 Juli 2024 - 26 Juni 2025) perbandingan antara harga aktual dan hasil *prediction* model, disertai nilai *absolute error* dan *percentage error* untuk setiap tanggal

selama *testing period*. Berdasarkan hal ini, nilai MAE terbaik senilai Rp151,99 dibandingkan dengan harga rata-rata BBKA.JK senilai Rp7.914,41 menghasilkan *relative error* senilai 1,92%. Nilai ini berada jauh di bawah *relative accuracy threshold* 25% yang umum digunakan dalam penelitian *forecasting*, sehingga secara empiris menunjukkan bahwa konfigurasi *window* 60 hari mampu memberikan hasil *prediction* yang sangat presisi terhadap *actual data*.

Tabel 2. Lima contoh perbandingan harga aktual dan prediksi model lstm

Tanggal	Predicted Rp	Actual Rp	Error Rp	Percentage Error
2025-06-20	Rp9.018	Rp8.700	Rp318	3.6521
2025-06-23	Rp8.949	Rp8.625	Rp324	3.7528
2025-06-24	Rp8.789	Rp8.775	Rp14	0.1603
2025-06-25	Rp8.740	Rp8.600	Rp140	1.6287
2025-06-26	Rp8.708	Rp8.650	Rp58	0.6653

Aktivasi *gate* dari *forget gate*, *input gate*, dan *output gate*, *cell state*, dan *hidden state* berhasil diekstraksi dari *layer* LSTM pertama untuk setiap sampel dalam *test data* dan setiap *time step* dalam *window*. Bentuk (*shape*) data yang diekstraksi untuk setiap jenis aktivasi/*state* adalah (*number_of_sequences*, *window_size*, *number_of_lstm_units*), di mana *number_of_sequences* bervariasi tergantung *window_size* (lebih kecil untuk *window* yang lebih besar); *window_size* adalah 30, 60, atau 90; *number_of_lstm_units* adalah 64 (sesuai arsitektur model). Contoh *shape* data *gate activation* yang diekstraksi meliputi *window* 30 (248, 30, 64), *window* 60 (218, 60, 64), dan *window* 90 (188, 90, 64). Pada Gambar 2, dapat dilihat bagaimana rata-rata perilaku *Forget*, *Input*, *Output Gate*, dan *Cell State* dalam *window* 60 berubah dari waktu ke waktu di dalam urutan *input* untuk setiap konfigurasi model LSTM, yang mana hal ini juga terjadi pada *window* 30 dan 90.




Gambar 2. Rata-rata aktivasi gate dan cell state over time selama *window* 60

Korelasi antara rata-rata *gate activation* (*forget*, *input*, dan *output*) dan fitur *input* (Pembukaan, Tertinggi, Terendah, Vol, PerubahanPersen) dihitung menggunakan *Pearson coefficient* untuk setiap konfigurasi *window* 30, 60, dan 90 hari. Perhitungan dilakukan dengan membandingkan rata-rata *gate activation* terhadap rata-rata nilai fitur *input* pada setiap *time step* di seluruh sampel dan *neuron*. Hasilnya ditampilkan pada Tabel 3, yang menunjukkan nilai koefisien korelasi antara -1 dan 1 sebagai ukuran arah dan kekuatan hubungan *linear* antara keduanya. Secara umum, *input gate* dan *output gate* memiliki nilai korelasi lebih tinggi dibandingkan *forget gate*, yang menunjukkan tingkat keterkaitan yang lebih kuat antara *gate activation* tersebut dan variasi *input features* sepanjang urutan waktu dalam *window*.

Tabel 3. Analisis korelasi *input*-aktivasi gerbang untuk *window* 30, 60, 90

<i>Window</i>	<i>Gate</i>	<i>Pembukaan</i>	<i>Tertinggi</i>	<i>Terendah</i>	<i>Vol</i>	<i>Perubahan Persen</i>
30	Forget	0.47	0.48	0.47	-0.02	-0.08
	Input	0.56	0.57	0.55	-0.03	-0.08
	Output	0.42	0.41	0.39	-0.14	-0.27
60	Forget	0.35	0.35	0.36	-0.47	0.10
	Input	0.55	0.55	0.56	-0.59	-0.03
	Output	0.81	0.81	0.82	-0.69	-0.31
90	Forget	-0.13	-0.13	-0.13	0.15	0.11
	Input	0.49	0.49	0.49	-0.45	0.37
	Output	0.71	0.71	0.71	-0.68	0.41

Analisis *temporal sensitivity* atau *memory decay* dilakukan pada model LSTM dengan *window size* 60 hari, yang sebelumnya teridentifikasi memiliki *best performance*. Analisis ini menggunakan *cell state* berukuran (218, 60, 64), yang merepresentasikan 218 *test sequence* dengan panjang 60 *time step* dan 64 LSTM *units*. Korelasi antara *cell state* pada waktu *t* dan *cell state* pada waktu *t-k* dihitung untuk nilai *k* dari 1 hingga 59. Hasil analisis menunjukkan korelasi awal sebesar 0.8967 pada *k*=1 dan penurunan sebesar -0.1569 pada *k*=2.


Gambar 3. Memory retention (cell state correlation) vs time lag (*k*) - window 60

Pola peluruhan (*decay pattern*) yang ditampilkan pada Gambar 3 dimulai dengan penurunan tajam hingga sekitar *k*=10, kemudian bertransisi ke fase yang lebih lambat dan stabil mendekati nol pada rentang *k*=20-40, serta menunjukkan *small fluctuations* di sekitar titik 0 (nol) pada *k*>48, yang menggambarkan perubahan tingkat kesamaan *cell state* terhadap jarak waktu antar langkah dalam urutan data (*sequence*). Temuan ini menunjukkan bahwa memori model bersifat *short-term*, di mana pengaruh informasi *past data* menurun dengan cepat, sehingga model lebih menitikberatkan pada *recent price patterns* yang sesuai dengan dinamika market volatility.

Pembahasan

Hasil evaluasi performa model LSTM secara konsisten menunjukkan superioritas konfigurasi *window* 60 hari dibandingkan 30 dan 90 hari. Dengan nilai *RMSE* 191,94 dan *MAE* 151,99 (Tabel 1), model ini mencapai akurasi prediksi yang lebih tinggi dibandingkan penelitian sebelumnya (Hastomo et al., 2021). *Window* 60 hari terbukti mampu mencapai keseimbangan optimal antara *up-to-date information* dan catatan historis yang relevan, sehingga menjadikannya periode *look-back* paling efektif untuk mempelajari pola jangka menengah pada *financial time series*. *Window* 30 hari cenderung terlalu pendek dan rentan terhadap *daily noise*, sementara *window* 90 hari berpotensi memuat informasi yang sudah tidak relevan akibat pergeseran *market regime* seperti perubahan kebijakan moneter atau dinamika

global. Konsistensi ini diperkuat oleh mekanisme *early stopping* yang aktif pada *epoch* ke-69 untuk *window* 30 hari dan *epoch* ke-73 untuk *window* 90 hari, yang berfungsi mencegah *overfitting* dan memastikan model berhenti pada titik generalisasi terbaik. Validasi *post-hoc* dengan *inverse scaling* juga mengonfirmasi bahwa hasil terbaik pada skala normalisasi konsisten dengan performa pada skala harga aktual.

Analisis *input-activation correlation* (Tabel 3) memberikan *insight* mengenai mekanisme internal *gating LSTM* dalam memproses informasi. Pada *window* 60 hari, *output gate* menunjukkan korelasi positif tinggi terhadap fitur harga. Hal ini menunjukkan bahwa ketika sinyal harga menguat, model meningkatkan intensitas aktivasi untuk mentransfer informasi relevan dari *cell state* ke *hidden state*, sejalan dengan peran *adaptive gating* dalam pengaturan kapasitas memori dinamis (Kong et al., 2025). Sementara itu, *input gate* memiliki korelasi positif moderat dengan fitur harga, menunjukkan proses integrasi informasi baru secara proporsional terhadap kekuatan sinyal harga. Selain itu, korelasi negatif *input gate* (-0,59) dan *output gate* (-0,69) terhadap *volume* menunjukkan mekanisme *noise suppression* atau penyaringan informasi. Ini berarti model secara adaptif mengurangi pemrosesan informasi ketika aktivitas perdagangan (*trading activity*) meningkat tajam, yang sering kali diasosiasikan dengan *market noise* atau volatilitas berlebihan (Firouzjaee & Khalilian, 2024). *Forget gate* berkorelasi negatif terhadap *Volume* dan positif kecil terhadap *Perubahan Persen*, menunjukkan bahwa model cenderung mengurangi *old memory retention* saat aktivitas pasar tinggi, tetapi, tetap mempertahankan sensitivitas terhadap perubahan harga signifikan. Pola perilaku *gating* yang adaptif ini sejalan dengan teori *dynamic retention control* (Wang et al., 2023), di mana model secara dinamis menyesuaikan kapasitas memorinya terhadap volatilitas pasar.

Analisis *temporal sensitivity* atau *memory decay* pada *window* 60 hari (Gambar 3) juga memperkuat pemahaman tentang *internal memory management*. Korelasi *cell state* menunjukkan nilai awal yang tinggi ($r(k=1)=0.8967$) dengan penurunan tajam pada *initial lag*, diikuti fase *slow decay* hingga mendekati nol pada *lag* 20-40. Hal ini menunjukkan bahwa ketergantungan jangka pendek dipertahankan kuat, sementara informasi yang lebih lama direduksi secara bertahap, menjamin bahwa model tetap responsif terhadap informasi terbaru yang relevan untuk prediksi harian.

Jika dibandingkan dengan penelitian terdahulu oleh Hartono & Widianoro (2024), Hastomo et al. (2021), Kusuma (2024), penelitian ini memberikan kontribusi dengan memperluas literatur *explainable deep learning in finance*. Berbeda dari penelitian sebelumnya yang memiliki keterbatasan pada fokus akurasi prediksi, penelitian ini berupaya menangani isu tersebut melalui analisis *gate-level interpretability* kuantitatif yang menawarkan *mechanistic insight* terhadap cara kerja internal model *LSTM* dalam memproses data harga dan volume. Pendekatan ini memungkinkan pemahaman yang lebih transparan dan sistematis, sekaligus menjawab keterbatasan penelitian Bustos et al. (2025) dan Radfar (2025) terkait sifat *black box* pada model *deep learning* di bidang prediksi pasar keuangan.

Temuan mengenai perilaku *gating* yang adaptif dan optimalnya *window* 60 hari dalam penelitian ini secara teoritis mendukung serta memperluas teori *dynamic retention control* oleh Wang et al. (2023) dalam ruang lingkup *financial time series* yang bersifat *non-stationary*. Penelitian ini menunjukkan bahwa *LSTM* tidak hanya mampu menghasilkan prediksi yang akurat, tetapi juga dapat dimodelkan sebagai sistem adaptif yang secara cerdas menyeimbangkan *short-term memory* dan *long-term memory*. Model ini memperlihatkan kemampuan untuk secara otomatis memfilter *noise* dan mempertahankan *relevant signal*, memberikan landasan teoretis lebih lanjut bagi pengembangan *recurrent neural network* yang lebih transparan dan responsif terhadap dinamika pasar finansial yang kompleks. Dari perspektif praktis, konfigurasi *window* 60 hari dapat dijadikan acuan operasional yang presisi untuk pengembangan sistem prediksi harga saham *BBCA.JK*. Nilai akurasi tinggi dan *relative error* sebesar 1,92% (Tabel 2) menunjukkan potensi besar dalam meningkatkan efisiensi

alokasi modal dan perumusan strategi investasi berbasis data. Selain itu, interpretabilitas yang dihasilkan melalui analisis *gate-level* memiliki peran penting dalam meningkatkan *trustworthiness* model. Investor dapat memahami dasar keputusan model secara lebih jelas, sementara regulator dapat melakukan audit yang lebih transparan terhadap sistem prediksi, sebuah kebutuhan krusial di sektor keuangan. Model ini mendukung pengambilan keputusan investasi berbasis *medium-term horizon* dan memperkuat sistem manajemen risiko keuangan dengan informasi yang lebih akurat dan dapat dipertanggungjawabkan.

Meskipun memberikan kontribusi yang substansial, penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan. Model yang dikembangkan hanya memanfaatkan data harga dan volume historis BBKA.JK tanpa mempertimbangkan faktor *exogenous* seperti indikator makroekonomi, berita keuangan, atau sentimen pasar, yang secara teoretis dapat memengaruhi dinamika harga saham. Selain itu, proses *hyperparameter tuning* masih dilakukan secara terbatas melalui pendekatan *trial-and-error* alih-alih menggunakan metode optimisasi sistematis seperti *Grid Search* atau *Bayesian Optimization*. Kondisi ini menjadikan model berfokus pada keandalan analisis internal dan interpretabilitas, namun belum sepenuhnya mengeksplorasi ruang konfigurasi yang lebih luas dalam konteks generalisasi model.

SIMPULAN

Penelitian ini berhasil mengembangkan model prediksi harga saham PT Bank Central Asia Tbk (BBKA.JK) yang akurat (RMSE 191,94; MAE 151,99) menggunakan algoritma Long Short-Term Memory (LSTM) dengan mengidentifikasi konfigurasi *window* 60 hari sebagai periode *horizon input* yang optimal, menunjukkan keseimbangan efektif antara *short-term dependency* dan *middle-term context* dalam data finansial non-stasioner. Kebaruan penelitian ini terletak pada analisis *gate-level interpretability* yang memberikan pemahaman mekanistik tentang cara *input*, *forget*, dan *output gate* LSTM memproses serta mempertahankan informasi, dengan korelasi positif terhadap harga dan negatif terhadap volume. Pendekatan ini mendukung teori *dynamic retention control* sekaligus mengatasi keterbatasan *black box* pada Explainable AI in finance. Temuan ini secara praktis memperkuat dasar strategi investasi *medium-term* yang lebih transparan dan andal, meskipun masih terbatas pada data *harga-volume* historis dan penerapan *hyperparameter* berbasis *trial and error*. Penelitian selanjutnya disarankan untuk memasukkan variabel eksternal, menerapkan Bayesian optimization, dan mengeksplorasi *arsitektur attention* atau *Transformer* guna meningkatkan generalisasi dan ketahanan model terhadap perubahan *market regime*.

REFERENSI

- Astudillo, K., Flores, M., Soliz, M., Ferreira, G., & Varela-Aldás, J. (2025). A Hybrid GAS-ATT-LSTM Architecture for Predicting Non-Stationary Financial Time Series. *Mathematics*, 13(14), 1–29. <https://doi.org/10.3390/math13142300>
- Attaulah, D. T., & Soyusiawaty, D. (2025). Analisis Sentimen Program Makan Siang Gratis di Twitter/X menggunakan Metode BI-LSTM. *Edumatic: Jurnal Pendidikan Informatika*, 9(1), 294–303. <https://doi.org/10.29408/edumatic.v9i1.29725>
- Beniwal, M., Singh, A., & Kumar, N. (2023). Forecasting long-term stock prices of global indices: A forward-validating Genetic Algorithm optimization approach for Support Vector Regression. *Applied Soft Computing*, 145(9), 1–19. <https://doi.org/10.1016/j.asoc.2023.110566>
- Bolboacă, R., & Haller, P. (2024). Enhanced long short-term memory architectures for chaotic systems modeling: An extensive study on the Lorenz system. *Chaos*, 34(12), 1–22. <https://doi.org/10.1063/5.0238619>

- Bustos, O., Pomares-Quimbaya, A., & Stellan, R. (2025). Machine learning, stock market forecasting, and market efficiency: a comparative study. *International Journal of Data Science and Analytics*, 20(7), 6815–6839. <https://doi.org/10.1007/s41060-025-00854-4>
- Černevičienė, J., & Kabašinskas, A. (2024). Explainable artificial intelligence (XAI) in finance: a systematic literature review. *Artificial Intelligence Review*, 57(8), 1–45. <https://doi.org/10.1007/s10462-024-10854-8>
- Firouzjaee, J. T., & Khalilian, P. (2024). The Interpretability of LSTM Models for Predicting Oil Company Stocks: Impact of Correlated Features. *International Journal of Energy Research*, 2024(47), 1–18. <https://doi.org/10.1155/2024/5526692>
- Giudici, P., Piergallini, A., Recchioni, M. C., & Raffinetti, E. (2024). Explainable Artificial Intelligence methods for financial time series. *Physica A: Statistical Mechanics and Its Applications*, 655(12), 1–14. <https://doi.org/10.1016/j.physa.2024.130176>
- Hartono, P. C., & Widiantoro, A. D. (2024). Analisis Prediksi Harga Saham Unilever Menggunakan Regresi Linier dengan RapidMiner. *Journal of Computer and Information Systems Ampera*, 5(3), 2496–2775.
- Hastomo, W., Karno, A. S. B., Kalbuana, N., Nisfiani, E., & ETP, L. (2021). Optimasi Deep Learning untuk Prediksi Saham di Masa Pandemi Covid-19. *Jurnal Edukasi Dan Penelitian Informatika (JEPIN)*, 7(2), 133–140. <https://doi.org/10.26418/jp.v7i2.47411>
- Kong, Y., Wang, Z., Nie, Y., Zhou, T., Zohren, S., Liang, Y., Sun, P., & Wen, Q. (2025). Unlocking the Power of LSTM for Long Term Time Series Forecasting. *Applied Operations and Analytics (AOA)*, 39(8), 11968–11976. <https://doi.org/10.48550/arXiv.2408.10006>
- Kusuma, N. P. N. (2024). Prediksi Harga Saham Blue Chip Pada Indeks Idx30 Menggunakan Algoritma Recurrent Neural Network (RNN). *Jurnal Ekonomi & Bisnis*, 23(1), 90–97. <https://doi.org/https://doi.org/10.32722/eb.v23i1.6609>
- Fuente, L. A. D. la, Ehsani, M. R., Gupta, H. V., & Condon, L. E. (2024). Toward interpretable LSTM-based modeling of hydrological systems. *Hydrology and Earth System Sciences*, 28(4), 945–971. <https://doi.org/10.5194/hess-28-945-2024>
- Li, Q., Kamaruddin, N., Yuhani, S. S., & Al-Jaifi, H. A. A. (2024). Forecasting stock prices changes using long-short term memory neural network with symbolic genetic programming. *Scientific Reports*, 14(1), 1–24. <https://doi.org/10.1038/s41598-023-50783-0>
- Mahmoudi, A. (2025). Investigating LSTM-based time series prediction using dynamic systems measures. *Evolving Systems*, 16(2), 1–18. <https://doi.org/10.1007/s12530-025-09703-y>
- Mariam, S., & Nurhaida, I. (2025). Analisis Sentimen berbasis Deep Learning Terhadap Kesetaraan Gender di Bidang STEM: Perspektif dan Implikasinya. *Edumatic: Jurnal Pendidikan Informatika*, 9(1), 69–78. <https://doi.org/10.29408/edumatic.v9i1.29071>
- Muhammad, D., Ahmed, I., Naveed, K., & Bendeche, M. (2024). An explainable deep learning approach for stock market trend prediction. *Heliyon*, 10(21), 1–15. <https://doi.org/10.1016/j.heliyon.2024.e40095>
- Muhidin, A., Rilvani, E., & Naya, C. (2025). Model Hybrid Fuzzy Logic dan Deep Learning untuk Prediksi Harga Saham. *Edumatic : Jurnal Pendidikan Informatika*, 9(2), 522–531. <https://doi.org/10.29408/edumatic.v9i2.30890>
- Radfar, E. (2025). Stock market trend prediction using deep neural network via chart analysis: a practical method or a myth? *Humanities and Social Sciences Communications*, 12(1), 1–10. <https://doi.org/10.1057/s41599-025-04761-8>
- Rahmadayan, A., & Mustakim. (2024). Long Short-Term Memory and Gated Recurrent Unit for Stock Price Prediction. *Procedia Computer Science*, 234(1), 204–212. <https://doi.org/10.1016/j.procs.2024.02.167>

- Wang, C., Li, Y., Sun, X., Wu, Q., Wang, D., & Huang, Z. (2023). DeLELSTM: Decomposition-based Linear Explainable LSTM to Capture Instantaneous and Long-term Effects in Time Series. *International Joint Conferences on Artificial Intelligence*, 32(8), 4299–4307. <https://doi.org/10.24963/ijcai.2023/478>
- Waqas, M., & Humphries, U. W. (2024). A critical review of RNN and LSTM variants in hydrological time series predictions. *MethodsX*, 13(2), 1–19. <https://doi.org/10.1016/j.mex.2024.102946>
- Weber, P., Carl, K. V., & Hinz, O. (2024). Applications of Explainable Artificial Intelligence in Finance—a systematic review of Finance, Information Systems, and Computer Science literature. *Management Review Quarterly*, 74(2), 867–907. <https://doi.org/10.1007/s11301-023-00320-0>
- Zhang, Z., Wang, D., Mei, Y., Zhu, J., & Xiao, X. (2025). Developing an explainable deep learning module based on the LSTM framework for flood prediction. *Frontiers in Water*, 7(5), 1–6. <https://doi.org/10.3389/frwa.2025.1562842>