

Analisis Perbandingan Kinerja Model GRU Dan LSTM Dalam Prediksi Harga Saham BBKA

Yoga Prasetya¹, Estu Sinduningrum^{2*}

^{1,2}*Teknik Informatika, Fakultas Teknologi Industri dan Informatika,
Universitas Muhammadiyah Prof. DR. HAMKA*

Email: ¹⁾ 2203015023@uhamka.ac.id ; ²⁾ estu.ningrum@uhamka.ac.id

How to Cite :

Prasetya, Y., Sinduningrum, E. (2026). Analisis Perbandingan Kinerja Model GRU Dan LSTM Dalam Prediksi Harga Saham BBKA. Jurnal Media Computer Science, 5(3)

ARTICLE HISTORY

Received [25 Juni 2026]

Revised [30 Juli 2026]

Accepted [31 Juli 2026]

KEYWORDS

BBKA, Deep Learning, Gated Recurrent Unit (GRU), Long Short-Term Memory (LSTM), Stock Price Prediction.

This is an open access article under the
[CC-BY-SA](#) license



ABSTRAK

Penelitian ini menganalisis secara komparatif kinerja model Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) dalam memprediksi harga penutupan saham PT Bank Central Asia Tbk (BBKA) menggunakan data historis periode 1 Januari 2019 hingga 30 April 2026. Kedua model dievaluasi menggunakan empat metrik, yaitu Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), dan Koefisien Determinasi (R^2). Dataset yang digunakan terdiri dari 1.780 data harga penutupan harian yang diperoleh dari Yahoo Finance, kemudian diproses melalui normalisasi Min-Max dan teknik windowing dengan ukuran jendela 60 hari. Model LSTM menggunakan tiga lapisan bertingkat (128→64→32 unit) dengan total 128.417 parameter, sedangkan model GRU menggunakan arsitektur yang setara dengan 96.993 parameter. Proses pelatihan dilakukan hingga maksimal 100 epoch dengan penerapan callback EarlyStopping dan ReduceLROnPlateau. Hasil penelitian menunjukkan bahwa model GRU memiliki kinerja yang lebih baik dibandingkan LSTM pada seluruh metrik evaluasi, dengan nilai RMSE sebesar 206,96 dibandingkan 255,45, MAE sebesar 163,56 dibandingkan 201,57, MAPE sebesar 2,09% dibandingkan 2,57%, serta R^2 sebesar 0,9325 dibandingkan 0,8972. Selain itu, GRU juga menunjukkan efisiensi komputasi yang lebih baik dengan waktu pelatihan yang lebih singkat, yaitu 54,87 detik dibandingkan 78,29 detik pada LSTM. Model GRU kemudian digunakan untuk memprediksi harga saham BBKA pada periode Mei-Agustus 2026, dengan proyeksi pemulihan bertahap dari Rp6.166,56 menjadi Rp6.727,84..

ABSTRACT

This study comparatively analyzes the performance of Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) models in predicting the closing price of PT Bank Central Asia Tbk (BBKA) stock using historical data from January 1, 2019 to April 30, 2026. Both models were evaluated using four metrics: Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), and Coefficient of Determination (R^2). The dataset consisted of 1,780 daily closing price records obtained from Yahoo Finance, processed through Min-Max normalization and windowing with a window size of 60 days. The LSTM model used three stacked layers (128→64→32 units) with 128,417 parameters, while the GRU model used an equivalent architecture with 96,993 parameters. Training was conducted for a maximum of 100 epochs with EarlyStopping and ReduceLROnPlateau callbacks. Results showed that GRU

outperformed LSTM across all evaluation metrics, with RMSE 206.96 vs 255.45, MAE 163.56 vs 201.57, MAPE 2.09% vs 2.57%, and R^2 0.9325 vs 0.8972. GRU also demonstrated better computational efficiency with shorter training time (54.87 vs 78.29 seconds). The GRU model was applied to forecast BBKA stock prices for May–August 2026, projecting a gradual recovery from Rp 6,166.56 to Rp 6,727.84.

PENDAHULUAN

Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence*) telah membawa transformasi signifikan di sektor keuangan, khususnya dalam analisis dan prediksi harga saham. Pasar saham merupakan indikator utama stabilitas ekonomi suatu negara karena pergerakan harganya mencerminkan kondisi makroekonomi, kebijakan moneter, dan sentimen investor yang saling berinteraksi secara kompleks (Rahayu & Khoirudin, 2023). Investasi saham menawarkan potensi imbal hasil tinggi, namun juga mengandung risiko besar akibat sifat data yang sangat fluktuatif dan non-linear sehingga sulit diprediksi dengan metode statistik konvensional (Furizal et al., 2025). Oleh karena itu, pengembangan sistem prediksi berbasis *deep learning* yang mampu mengidentifikasi pola tersembunyi dalam data historis menjadi kebutuhan yang semakin mendesak bagi investor maupun pelaku industri keuangan.

Di antara berbagai pendekatan *deep learning*, *Recurrent Neural Network* (RNN) menjadi fondasi utama pemodelan data sekuensial, namun memiliki kelemahan berupa *vanishing gradient problem* yang menyebabkan model kesulitan mempelajari dependensi jangka panjang (Furizal et al., 2025). Untuk mengatasi hal tersebut, *Long Short-Term Memory* (LSTM) diperkenalkan dengan mekanisme *gating* (*forget gate*, *input gate*, *output gate*) yang memungkinkan model secara selektif menyimpan dan melupakan informasi dalam rangkaian data panjang (Puteri, 2023). Sebagai alternatif yang lebih efisien, *Gated Recurrent Unit* (GRU) hadir dengan arsitektur lebih ringkas menggunakan dua *gate* (*update gate* dan *reset gate*), sehingga memiliki parameter lebih sedikit dan pelatihan lebih cepat namun tetap kompetitif secara akurasi (Nilsen, 2022). Kedua model ini telah banyak diterapkan dalam berbagai domain *time series forecasting*, termasuk prediksi harga komoditas, nilai tukar mata uang, dan harga saham di berbagai negara (Arwansyah et al., 2022; Larasati, Saadah, & Yunanto, 2024).

Sejumlah penelitian telah membuktikan efektivitas LSTM dan GRU dalam prediksi harga saham dengan hasil yang bervariasi. Budiharto (Budiharto, 2021) menerapkan LSTM untuk memprediksi harga saham Indonesia selama pandemi Covid-19 dan membuktikan ketangguhannya pada kondisi pasar ekstrem. (Harahap, Fitrie, Negeri, & Utara, 2021) dan (Arwansyah et al., 2022) menunjukkan bahwa GRU mampu menghasilkan prediksi akurat pada data keuangan sektor perbankan dengan efisiensi komputasi yang lebih baik dibandingkan model lainnya. (Larasati et al., 2024) menemukan bahwa LSTM memberikan hasil lebih stabil pada data dengan fluktuasi tinggi, sementara Arunkumar dkk. (Arunkumar, Kalaga, Mohan, Kumar, & Brenza, 2022) membuktikan bahwa model *deep learning* secara konsisten mengungguli metode statistik tradisional seperti ARIMA dan SARIMA dalam berbagai skenario peramalan. Temuan-temuan tersebut memperkuat posisi LSTM dan GRU sebagai dua model paling relevan untuk dikaji lebih lanjut dalam konteks prediksi harga saham di pasar modal Indonesia.

Meskipun penelitian mengenai prediksi harga saham BBKA menggunakan *deep learning* telah ada, terdapat kesenjangan yang perlu diisi. (Hariyanti, Putra, & Raharja, 2025) dan (Prayogi, Gata, & Kussanti, 2024) telah membandingkan LSTM dan GRU pada saham BBKA, namun menggunakan periode data yang lebih pendek dan belum mengevaluasi secara bersamaan menggunakan empat metrik. Puteri (Puteri, 2023) hanya membandingkan LSTM dengan BiLSTM tanpa menyertakan GRU, sedangkan Nilsen (Nilsen, 2022) membandingkan ketiga model pada saham LQ45 secara umum tanpa berfokus pada BBKA. Yongchareon (Yongchareon, 2025) menekankan bahwa evaluasi multi-metrik sangat penting untuk menghasilkan kesimpulan yang

objektif dalam studi komparatif model prediksi saham. Dengan demikian, penelitian yang secara khusus membandingkan LSTM dan GRU pada saham BBKA menggunakan data jangka panjang 2019–2026 dengan empat metrik evaluasi sekaligus masih sangat terbatas dan relevan untuk dilakukan.

PT Bank Central Asia Tbk (BBKA) dipilih sebagai objek penelitian karena merupakan salah satu *emiten blue chip* dengan kapitalisasi pasar terbesar di Bursa Efek Indonesia dan memiliki likuiditas perdagangan yang sangat tinggi, sehingga data historisnya kaya dan representatif untuk pemodelan prediktif (G. B. Suhandi, 2026). BBKA sebagai bank swasta terbesar di Indonesia juga memiliki sensitivitas tinggi terhadap indikator makroekonomi seperti suku bunga Bank Indonesia dan pertumbuhan kredit nasional, menjadikan pergerakan harganya mencerminkan dinamika perekonomian secara luas. Rentang data 2019–2026 yang digunakan dalam penelitian ini mencakup berbagai kondisi pasar ekstrem termasuk dampak pandemi Covid-19 tahun 2020 dan pemulihan ekonomi pasca-pandemi, sehingga model yang dihasilkan diuji pada skenario yang lebih beragam dan menantang (Budiharto, 2021). Karakteristik ini menjadikan saham BBKA sebagai objek yang sangat ideal untuk mengevaluasi kemampuan generalisasi model *deep learning* dalam menangkap pola temporal jangka panjang.

LANDASAN TEORI

Saham merupakan instrumen keuangan yang mewakili kepemilikan sebagian dari suatu perusahaan dan diperdagangkan di Bursa Efek Indonesia (BEI) sebagai salah satu instrumen investasi paling populer. Harga saham dipengaruhi oleh faktor internal seperti kinerja keuangan perusahaan maupun faktor eksternal seperti kondisi makroekonomi, suku bunga, dan sentimen pasar. PT Bank Central Asia Tbk (BBKA) merupakan salah satu *emiten blue chip* dengan kapitalisasi pasar terbesar di BEI, sehingga data historisnya kaya dan representatif untuk pemodelan prediktif (G. B. Suhandi, 2026).

Time series forecasting

Time series forecasting adalah metode prediksi yang memperkirakan nilai masa depan berdasarkan data historis yang terurut secara waktu. Data harga saham memiliki ketergantungan temporal (*temporal dependency*) sehingga nilai pada waktu tertentu dipengaruhi oleh nilai-nilai sebelumnya. Karakteristik penting dalam data *time series* harga saham meliputi *trend*, *seasonality*, serta fluktuasi yang bersifat non-linear dan sulit diprediksi dengan metode statistik konvensional seperti ARIMA (Furizal et al., 2025).

Deep learning

Deep learning adalah bagian dari machine learning yang menggunakan arsitektur jaringan saraf tiruan berlapis untuk mempelajari representasi data secara hierarkis. Keunggulan *deep learning* terletak pada kemampuannya melakukan *automatic feature learning* tanpa rekayasa fitur manual, menangkap pola non-linear yang kompleks, serta meningkat performanya seiring bertambahnya data (Sharma, Sharma, & Jindal, 2021). Dalam konteks prediksi *time series*, arsitektur yang paling relevan adalah *Recurrent Neural Network* (RNN) dan variannya, yang dirancang khusus untuk data sekuensial dengan mempertahankan informasi dari langkah waktu sebelumnya melalui *hidden state*. Namun, RNN standar mengalami masalah *vanishing gradient* yang menyebabkan kesulitan mempelajari dependensi jangka panjang (Furizal et al., 2025).

Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) dikembangkan untuk mengatasi masalah *vanishing gradient* pada RNN melalui mekanisme *gating* yang terdiri dari tiga gerbang utama: *forget gate*, *input gate*, dan *output gate*. Mekanisme ini memungkinkan LSTM untuk secara selektif menyimpan, memperbarui, dan mengeluarkan informasi dari *cell state* sehingga mampu menangkap pola jangka panjang dalam

data historis harga saham (Puteri, 2023). Keunggulan LSTM terletak pada fleksibilitas dalam mengontrol aliran informasi, meskipun arsitekturnya lebih kompleks dengan jumlah parameter yang lebih banyak dibandingkan variannya.


Gated Recurrent Unit

Gated Recurrent Unit (GRU) merupakan varian yang lebih ringkas dari LSTM, menggunakan hanya dua gerbang yaitu *update gate* dan *reset gate*, tanpa pemisahan antara *cell state* dan *hidden state*. Penyederhanaan ini menghasilkan model dengan jumlah parameter lebih sedikit sehingga lebih efisien secara komputasi, namun tetap kompetitif secara akurasi. Penelitian-penelitian terdahulu menunjukkan hasil yang bervariasi: GRU terbukti unggul dalam efisiensi pelatihan pada data perbankan (Harahap et al., 2021), sementara LSTM menunjukkan keunggulan pada data dengan fluktuasi sangat tinggi (Larasati et al., 2024). Pemilihan antara LSTM dan GRU bergantung pada karakteristik data dan sumber daya komputasi yang tersedia; evaluasi empiris menggunakan multi-metrik menjadi kunci untuk menghasilkan kesimpulan yang objektif.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental komparatif dengan membandingkan kinerja dua model *deep learning*, yaitu *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU), dalam memprediksi harga penutupan saham PT Bank Central Asia Tbk (BBCA). Seluruh tahapan

penelitian diimplementasikan menggunakan bahasa pemrograman Python 3.11.9 dengan library utama *TensorFlow/Keras*, *Pandas*, *NumPy*, *Matplotlib*, dan *Scikit-learn* (SUHARSONO, 2023), (Pannadhitthana Candra, 2025). Alur penelitian dimulai dari pengumpulan data, *preprocessing* data, pembentukan *sequence* (*windowing*), pembagian dataset, pemodelan GRU dan LSTM, konfigurasi dan strategi pelatihan, hingga evaluasi menggunakan metrik RMSE, MAE, MAPE, dan R^2 . Tahapan penelitian secara keseluruhan disajikan pada Gambar 1.



Gambar 1. Tahapan Penelitian

Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data sekunder berupa harga penutupan (*close price*) harian saham PT Bank Central Asia Tbk (BBCA) yang diperoleh dari *Yahoo Finance*. Dataset mencakup periode 1 Januari 2019 hingga 30 April 2026 dengan total 1.780 baris data harian. Setiap baris memuat enam kolom, yaitu *Date* (tanggal perdagangan), *Open* (harga pembukaan), *High* (harga tertinggi), *Low* (harga terendah), *Close* (harga penutupan), dan *Volume* (volume perdagangan). Dalam penelitian ini, hanya kolom *Close* yang digunakan sebagai variabel target prediksi karena harga penutupan merupakan indikator yang paling umum digunakan dalam analisis teknikal saham dan mencerminkan harga kesepakatan akhir dalam satu sesi perdagangan. Statistik deskriptif dataset disajikan pada Tabel 1.

Tabel 1. Statistik Deskriptif Dataset Harga Saham BBKA

Statistik	Close (Rp)	Open (Rp)	High (Rp)	Low (Rp)
Jumlah Data	1.780	1.780	1.780	1.780
Rata-rata	6.792,46	6.795,15	6.856,84	6.732,26
Minimum	3.668,60	3.685,17	4.043,73	3.581,65
Maksimum	10.060,58	10.014,64	10.060,58	9.899,80
Std. Deviasi	1.561,51	1.560,37	1.570,44	1.553,35

Preprocessing Data

Preprocessing data merupakan tahap krusial sebelum data digunakan untuk pelatihan model. Proses ini bertujuan memastikan kualitas dataset sehingga model dapat bekerja secara optimal (Furizal et al., 2025). Tahap *preprocessing* dalam penelitian ini meliputi tiga langkah utama.

Pertama, pembersihan data. Dilakukan pengecekan missing values pada seluruh kolom dataset. Hasil pengecekan menunjukkan tidak terdapat *missing values* maupun data duplikat pada seluruh kolom, sehingga dataset langsung dapat digunakan tanpa perlu imputasi. Selanjutnya dilakukan seleksi kolom target, yaitu hanya kolom *Close* yang dipertahankan untuk proses selanjutnya.

Kedua, normalisasi data. Normalisasi dilakukan menggunakan metode *Min-Max Scaling* dengan *MinMaxScaler* dari *library Scikit-learn* (Zahara & Sugianto, 2021). Metode ini mentransformasi seluruh nilai harga penutupan ke dalam rentang [0, 1] menggunakan persamaan:

$$X_{normalized} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Normalisasi sangat penting karena arsitektur LSTM dan GRU menggunakan fungsi aktivasi *sigmoid* dan *tanh* yang bekerja optimal pada rentang nilai [0, 1], sehingga proses konvergensi selama *training* menjadi lebih stabil dan efisien (Arwansyah et al., 2022).

Ketiga, pembentukan *sequence (windowing)*. Untuk keperluan prediksi *time series*, data perlu dibentuk menjadi *sequence* dengan panjang jendela waktu tertentu. Dalam penelitian ini digunakan *window size* = 60, artinya 60 hari data historis harga penutupan digunakan sebagai *input* (X) untuk memprediksi harga pada hari ke-61 (y). Data kemudian di-reshape ke format [*samples, time_steps, features*] = (n, 60, 1) yang diperlukan oleh model LSTM dan GRU di Keras.

Pembentukan Sequence (Windowing)

Pembentukan *sequence* atau *windowing* merupakan tahap transformasi data *time series* menjadi pasangan *input-output* yang dapat diproses oleh model *deep learning*. Pada penelitian ini digunakan *window size* = 60, artinya 60 hari data historis harga penutupan digunakan sebagai input (X) untuk memprediksi harga penutupan pada hari ke-61 (y). Pendekatan ini memungkinkan model untuk mempelajari pola temporal selama dua bulan perdagangan sebelum membuat prediksi.

Proses *windowing* menghasilkan total 1.720 sampel dari 1.780 data tersedia (1.780 – 60 = 1.720). Data kemudian di-reshape ke format tiga dimensi [*samples, time_steps, features*] = (1.720, 60, 1) sesuai dengan format input yang diperlukan oleh model LSTM dan GRU di Keras.

Pembagian Dataset

Pembagian dataset merupakan tahap penting untuk memastikan model dapat dievaluasi secara objektif menggunakan data yang tidak pernah dilihat selama pelatihan. Proses *windowing* menghasilkan total 1.720 sampel yang kemudian dibagi menjadi data latih dan data uji dengan proporsi 80%:20% secara kronologis (*sequential split*) tanpa pengacakan untuk mempertahankan sifat temporal data *time series*. Hasil pembagian dataset disajikan pada Tabel 2.

Tabel 2. Hasil Pembagian Dataset

Subset	Jumlah Sampel	Shape	Proporsi
Data Latih (Training)	1.376	(1.376, 60, 1)	80%
Data Uji (Testing)	344	(344, 60, 1)	20%
Total	1.720	—	100%

Model Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) merupakan varian yang lebih ringkas dari LSTM yang diperkenalkan oleh Kyunghyun Cho dkk. GRU menyederhanakan arsitektur LSTM dengan hanya menggunakan dua gerbang, yaitu *update gate* dan *reset gate*, tanpa pemisahan antara *cell state* dan *hidden state*. Penyederhanaan ini menghasilkan model dengan jumlah parameter lebih sedikit sehingga lebih efisien secara komputasi namun tetap mampu menangkap dependensi temporal jangka Panjang.

Update gate menentukan seberapa banyak informasi dari *hidden state* sebelumnya yang akan dipertahankan. Gerbang ini mirip dengan kombinasi forget gate dan input gate pada LSTM.

$$z_t = \sigma(W_z[h_{t-1}, x_t] + b_z) \quad (2)$$

Reset gate menentukan seberapa banyak informasi dari *hidden state* sebelumnya yang akan dilupakan saat menghitung kandidat *hidden state* baru.

$$r_t = \sigma(W_r[h_{t-1}, x_t] + b_r) \quad (3)$$

Kandidat *Hidden State Update*

$$\tilde{h}_t = \tanh(W_h[r_t \times h_{t-1}, x_t] + b_h) \quad (4)$$

Hidden state final merupakan kombinasi *linear* dari *hidden state* sebelumnya dan kandidat *hidden state*:

$$h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \quad (5)$$

Keterangan

- σ : adalah fungsi sigmoid
- $\tanh$: fungsi aktivasi hiperbolik
- $\times$ menunjukkan *element-wise multiplication*
- h_t : *hidden state* pada waktu ke- t
- x_t : input pada waktu ke- t
- W_z, W_r, W_h : adalah matriks bobot untuk masing-masing *gate*
- b_z, b_r, b_h : adalah bias untuk masing-masing *gate*

Kelebihan

- Arsitektur lebih sederhana dengan parameter lebih sedikit (lebih cepat untuk dilatih)
- Lebih efisien dalam penggunaan memori
- Performa kompetitif dengan LSTM pada banyak tugas
- Lebih cepat untuk konvergen dalam proses pelatihan.

Dalam penelitian ini, model GRU dibangun dengan arsitektur yang paralel dengan LSTM yaitu tiga lapisan GRU bertingkat (128→64→32 unit), masing-masing diikuti *Dropout* 0,2, dan *Dense layer* 1 unit sebagai output. Dengan hanya dua *gate*, total parameter GRU adalah 96.993, lebih sedikit dibandingkan LSTM (128.417), sehingga waktu pelatihan GRU secara inheren lebih singkat.

Model Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan arsitektur *deep learning* yang dikembangkan dari *Recurrent Neural Network* (RNN) untuk mengatasi permasalahan *vanishing gradient* pada pemodelan

data sekuensial jangka panjang. LSTM dirancang dengan mekanisme *gating* yang memungkinkan model secara selektif menyimpan, memperbarui, dan mengeluarkan informasi dari memori jangka panjang (*cell state*). Arsitektur LSTM terdiri dari tiga gerbang utama yang bekerja secara sinergis.

Forget Gate menentukan informasi apa yang harus dibuang dari *cell state*. *Forget gate* menghasilkan nilai antara 0 dan 1, dimana 0 berarti "hapus sepenuhnya" dan 1 berarti "pertahankan sepenuhnya".

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (6)$$

Input Gate ini menentukan informasi baru apa yang akan disimpan dalam *cell state*. *Input gate* terdiri dari dua bagian: layer sigmoid yang menentukan nilai mana yang akan diupdate, dan *layer tanh* yang membuat vektor kandidat nilai baru.

$$\begin{aligned} i_t &= \sigma(W_i \times [h_{t-1}, x_t] + b_i) \\ \tilde{c}_t &= \tanh(W_c \times [h_{t-1}, x_t] + b_c) \end{aligned} \quad (7)$$

Output Gate ini menentukan output berdasarkan *cell state* yang telah diupdate. *Output* adalah versi terfilter dari *cell state*.

$$\begin{aligned} o_t &= \sigma(W_o \times [h_{t-1}, x_t] + b_o) \\ h_t &= o_t \times \tanh(C_t) \end{aligned} \quad (8)$$

Cell State Update adalah kombinasi dari *Forget Gate* dan *Input Gate*

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{c}_t \quad (9)$$

Keterangan

- σ : adalah fungsi sigmoid
- $\tanh$: fungsi aktivasi hiperbolik
- h_t : hidden state pada waktu ke $-t$
- C_t : input pada waktu ke $-t$
- $\times$: menunjukkan *element-wise multiplication*
- W_f, W_i, W_c, W_o : adalah matriks bobot untuk masing-masing *gate*

Kelebihan

- Lebih fleksibel dalam mengontrol aliran informasi
- Mampu menangkap pola jangka panjang dalam data historis harga saham
- Lebih banyak digunakan dalam penelitian sehingga terdapat lebih banyak referensi.

Dalam penelitian ini, model LSTM dibangun menggunakan framework Keras dengan arsitektur tiga lapisan LSTM bertingkat (128→64→32 unit), masing-masing diikuti Dropout 0,2 untuk mencegah *overfitting*, dan diakhiri *Dense layer* dengan 1 unit sebagai *output* prediksi. Total parameter model LSTM adalah 128.417.

Konfigurasi dan Strategi Pelatihan

Kedua model dilatih menggunakan konfigurasi yang identik untuk memastikan perbandingan yang adil dan objektif. Parameter pelatihan yang digunakan adalah: optimizer Adam dengan learning rate = 0,001; loss function Mean Squared Error (MSE); batch size = 32; maksimal 100 epoch; dan validation split = 10% dari data latih. Random seed = 42 diterapkan pada seluruh proses komputasi untuk memastikan reproduisibilitas hasil.

Dua *callback* digunakan secara bersamaan selama proses pelatihan. Pertama, *EarlyStopping* dengan *patience* = 20 yang menghentikan pelatihan secara otomatis apabila nilai validation loss tidak membaik selama 20 epoch berturut-turut, dan secara otomatis mengembalikan bobot terbaik (*restore_best_weights* = True). Kedua, *ReduceLROnPlateau* dengan *factor* = 0,5 dan *patience* = 5 yang menurunkan learning rate sebesar 50% apabila *validation loss* stagnan selama 5 epoch, dengan batas *minimum learning rate* sebesar 0,00001. Kombinasi kedua *callback* ini memungkinkan model belajar secara adaptif sekaligus mencegah *overfitting*.

Metrik Evaluasi

Evaluasi kinerja model dilakukan menggunakan empat metrik yang umum digunakan dalam penelitian time series forecasting. Penggunaan beberapa metrik bertujuan memberikan penilaian yang lebih objektif dan menyeluruh terhadap performa model dari berbagai sudut pandang.

Root Mean Squared Error (RMSE) mengukur akar dari rata-rata kuadrat selisih antara nilai prediksi dan nilai aktual. RMSE memberikan penalti lebih besar terhadap kesalahan yang besar karena menggunakan operasi kuadrat, sehingga sensitif terhadap outlier. Semakin kecil nilai RMSE, semakin baik performa model. RMSE dirumuskan sebagai persamaan

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

- y_i nilai aktual ke- i
- $\hat{y}_i$ nilai prediksi ke- i
- n adalah jumlah data

Mean Absolute Error (MAE) mengukur rata-rata selisih absolut antara nilai prediksi dan nilai aktual. MAE bersifat robust terhadap outlier karena tidak menggunakan kuadrat, sehingga memberikan gambaran langsung mengenai seberapa besar rata-rata kesalahan prediksi dalam satuan Rupiah. MAE dirumuskan sebagai persamaan.

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

Mean Absolute Percentage Error (MAPE) MAPE mengukur persentase error rata-rata, sehingga lebih mudah untuk diinterpretasikan dan dapat dibandingkan antar dataset dengan skala berbeda. MAPE dirumuskan sebagai persamaan.

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

MAPE dinyatakan dalam persentase, sehingga:

- MAPE < 10% menunjukkan prediksi sangat akurat
- MAPE 10-20% menunjukkan prediksi baik
- MAPE 20-50% menunjukkan prediksi cukup
- MAPE > 50% menunjukkan prediksi kurang akurat

Coefficient of Determination (R^2) mengukur proporsi variansi pada data aktual yang dapat dijelaskan oleh model. Nilai R^2 berkisar antara 0 hingga 1, di mana nilai yang mendekati 1 menunjukkan model semakin mampu menjelaskan variasi data aktual. R^2 dirumuskan sebagai persamaan.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$
$$R^2 = 1 - (\text{SS residual} / \text{SS total})$$
$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

Dimana $\bar{y}$ adalah rata-rata dari nilai aktual.

Interpretasi R^2 :

$R^2 = 1$: Model sempurna (prediksi identik dengan aktual)

$R^2 = 0$: Model tidak lebih baik dari prediksi menggunakan rata-rata

$R^2 < 0$: Model lebih buruk dari prediksi menggunakan rata-rata

Nilai R^2 yang tinggi (mendekati 1) menunjukkan bahwa model mampu menjelaskan variabilitas data dengan baik.

HASIL DAN PEMBAHASAN

Hasil

Preprocessing dan Pembagian Dataset

Hasil *preprocessing* menunjukkan bahwa dataset akhir yang digunakan terdiri dari 1.780 data harga penutupan harian saham BBKA periode 2019–2026. Pengecekan menunjukkan tidak terdapat *missing values* maupun data duplikat pada seluruh kolom, sehingga tidak diperlukan penanganan tambahan. Setelah normalisasi *Min-Max Scaling*, seluruh nilai *close price* yang semula berada dalam rentang Rp 3.668,60 hingga Rp 10.060,58 berhasil ditransformasi ke dalam rentang [0, 1].

Proses *windowing* dengan *window size* = 60 menghasilkan total 1.720 sampel. Dataset kemudian dibagi secara kronologis menjadi 1.376 data latih (80%) dan 344 data uji (20%). Pembagian dilakukan secara sequential tanpa pengacakan untuk mempertahankan sifat temporal data *time series*, sehingga hasil evaluasi mencerminkan kondisi prediksi yang realistis.


Hasil Pelatihan Model LSTM

Proses pelatihan model LSTM berjalan selama 62 epoch dengan total waktu pelatihan 78,29 detik. *EarlyStopping* menghentikan pelatihan pada epoch ke-62 dan secara otomatis mengembalikan bobot terbaik dari epoch ke-42. *ReduceLROnPlateau* aktif beberapa kali selama proses pelatihan, menurunkan learning rate secara bertahap dari 0,001 hingga mencapai batas minimum 0,00001. Nilai *training loss* mengalami penurunan konsisten dari 0,015368 pada epoch pertama hingga 0,001870 pada epoch ke-62, sementara validation loss terbaik dicapai pada epoch ke-42 dengan nilai 0,000990. Hasil *Training Model LSTM* bisa dilihat pada tabel.

Tabel 3. Hasil Riwayat Training Model LSTM

Epoch	Training Loss	Validation Loss
1	0.015368	0.002805
2	0.003945	0.001474
3	0.003612	0.002396
4	0.003537	0.001871
5	0.002958	0.001231
10	0.003088	0.001019
20	0.002275	0.001905
30	0.002037	0.001031
50	0.002005	0.001015
62	0.001870	0.000990

Grafik riwayat pelatihan model LSTM (Gambar 2) menunjukkan kurva training loss dan validation loss yang menurun tajam pada epoch-epoch awal kemudian melandai dan stabil di sekitar nilai 0,002 untuk *training loss* dan 0,001 untuk validation loss. Pola konvergensi ini menunjukkan bahwa model berhasil mempelajari pola temporal data harga saham BBKA dengan baik tanpa indikasi overfitting yang signifikan.




Gambar 2. Grafik Training Loss dan Validation Loss Model LSTM

Hasil Training Model GRU

Proses pelatihan model GRU berjalan selama 42 epoch dengan total waktu pelatihan 54,87 detik, lebih singkat dibandingkan LSTM yang membutuhkan 78,29 detik. *EarlyStopping* menghentikan pelatihan pada epoch ke-42 dan mengembalikan bobot terbaik dari epoch ke-22. Nilai *training loss* akhir model GRU sebesar 0,002084 dengan *validation loss* terbaik sebesar 0,000740, lebih kecil dibandingkan *validation loss* terbaik LSTM sebesar 0,000990. Hasil Training Model GRU bisa dilihat pada Grafik riwayat pelatihan model GRU (Gambar 3) menunjukkan pola konvergensi yang serupa dengan LSTM, yaitu penurunan tajam di awal kemudian melandai dan stabil. Waktu pelatihan GRU yang lebih singkat (54,87 detik vs 78,29 detik) disebabkan arsitektur GRU yang lebih ringkas dengan jumlah parameter lebih sedikit (96.993 vs 128.417). Nilai *validation loss* terbaik GRU yang lebih kecil mengindikasikan bahwa GRU berhasil menemukan bobot yang lebih optimal pada data validasi.

Tabel 4. Hasil Riwayat Training Model GRU

Epoch	Training Loss	Validation Loss
1	0.019942	0.001403
2	0.003732	0.001359
3	0.003224	0.000694
4	0.003636	0.000849
5	0.003228	0.000698
10	0.002415	0.000641
20	0.002178	0.000627
30	0.002152	0.000681
42	0.002084	0.000740




Gambar 3. Grafik Training Loss dan Validation Loss Model GRU

Hasil Prediksi dan Evaluasi Model LSTM

Setelah pelatihan selesai, model LSTM digunakan untuk memprediksi harga penutupan saham BBKA pada 344 data uji. Hasil prediksi yang masih dalam skala normalisasi [0, 1] kemudian di-*inverse transform* menggunakan *MinMaxScaler* yang sama sehingga nilai prediksi kembali ke skala harga saham dalam satuan Rupiah. Selisih antara harga aktual dan prediksi LSTM berkisar antara Rp 23,58 hingga Rp 344,00.

Grafik perbandingan harga aktual dan prediksi LSTM (Gambar 4) menunjukkan bahwa kurva prediksi secara umum mampu mengikuti tren pergerakan harga aktual. Namun terdapat beberapa titik di mana model mengalami keterlambatan (*lag*) dalam merespons perubahan harga yang tajam, terutama pada periode penurunan harga yang signifikan di sepanjang tahun 2025 hingga awal 2026. Hasil evaluasi kuantitatif model LSTM disajikan pada Tabel 5.




Gambar 4. Grafik Prediksi vs Harga Aktual Model LSTM

Tabel 5. Hasil Evaluasi Model LSTM

	Nilai	Keterangan
RMSE	255,45	Deviasi rata-rata $\pm$ Rp 255,45
MAE	201,57	Kesalahan absolut rata-rata Rp 201,57
MAPE	2,57%	Kategori sangat akurat (< 10%)
R ²	0,8972	Menjelaskan 89,72% variansi data

Hasil Prediksi dan Evaluasi Model GRU

Model GRU menghasilkan prediksi yang lebih mendekati nilai aktual dibandingkan LSTM pada sebagian besar titik data uji. Selisih antara harga aktual dan prediksi GRU berkisar antara Rp 18,64 hingga Rp 291,37, secara umum lebih kecil dibandingkan selisih pada LSTM. Grafik perbandingan harga aktual dan prediksi GRU (Gambar 5) menunjukkan kemampuan yang lebih baik dalam mengikuti pergerakan harga aktual, dengan penyimpangan lebih kecil termasuk pada periode volatilitas tinggi di tahun 2025. Hasil evaluasi kuantitatif model GRU disajikan pada



Gambar 5. Grafik Prediksi vs Harga Aktual Model GRU

Tabel 6. Hasil Evaluasi Model GRU


Metrik	Nilai	Keterangan
RMSE	206,96	Deviasi rata-rata ± Rp 206,96
MAE	163,56	Kesalahan absolut rata-rata Rp 163,56
MAPE	2,09%	Kategori sangat akurat (< 10%)
R²	0,9325	Menjelaskan 93,25% variansi data

Perbandingan Kinerja Model LSTM dan GRU

Perbandingan kinerja menyeluruh antara kedua model disajikan pada Tabel 7 dan Gambar 6. Berdasarkan hasil evaluasi, model GRU terbukti unggul pada seluruh metrik dibandingkan LSTM.

Tabel 7. Perbandingan Kinerja Model LSTM dan GRU

Metrik	LSTM	GRU	Selisih	Model Terbaik
RMSE	255,45	206,96	48,49 (18,98%)	GRU
MAE	201,57	163,56	38,01	GRU
MAPE	2,57%	2,09%	0,48 poin	GRU
R²	0,8972	0,9325	0,0353	GRU
Waktu Latih	78,29 dtk	54,87 dtk	23,42 dtk (29,92%)	GRU
Jml. Parameter	128.417	96.993	31.424	GRU



mbar 6. Grafik Perbandingan Evaluasi LSTM vs GRU


Ga

Diksi Harga Saham BBKA Periode Mei-Agustus 2026

Sebagai implementasi lanjutan, model GRU yang terbukti memiliki kinerja terbaik digunakan untuk memprediksi harga penutupan saham BBKA pada periode Mei hingga Agustus 2026 menggunakan metode *iterative forecasting*. Prediksi dimulai dari Mei 2026 karena data aktual tersedia hingga akhir April 2026. Setiap hasil prediksi dimasukkan kembali sebagai input untuk memprediksi hari berikutnya secara berulang, dimulai dari 60 hari terakhir data aktual sebagai input awal. Hasil prediksi disajikan pada Tabel 8 dan Gambar 7.

Tabel 8. Prediksi Harga Saham BBKA Periode Mei-Agustus 2026

Periode	Harga Prediksi (Rp)	Keterangan
Mei 2026 (awal)	6.166,56	Titik prediksi terendah
Juni 2026	6.330,12	Tren kenaikan bertahap
Juli 2026	6.541,47	Tren kenaikan berlanjut
Agustus 2026	6.727,84	Titik prediksi tertinggi
Rata-rata periode	6.507,39	—
Prediksi terendah	6.130,95	—
Prediksi tertinggi	6.910,93	—



Gambar 7. Grafik Prediksi Harga Saham BBKA Periode Mei-Agustus 2026

Pembahasan

Penelitian ini berhasil membangun dan membandingkan kinerja model LSTM dan GRU dalam memprediksi harga penutupan saham BBKA menggunakan data historis periode 1 Januari 2019 hingga 30 April 2026. Secara keseluruhan, model GRU terbukti unggul dibandingkan LSTM pada seluruh metrik evaluasi. Model LSTM menunjukkan kinerja baik dengan MAPE 2,57% yang termasuk kategori sangat akurat (*highly accurate*) (Sharma et al., 2021) dan R^2 0,8972 yang berarti mampu menjelaskan 89,72% variasi data. Meskipun demikian, sekitar 10,28% variasi tidak dapat dijelaskan LSTM, mengindikasikan model belum sepenuhnya optimal menangkap kompleksitas fluktuasi harga BBKA dari kisaran Rp 9.500 di akhir 2024 hingga kisaran Rp 6.000 di April 2026.

Model GRU menunjukkan kinerja lebih unggul dengan MAPE 2,09% dan R^2 0,9325, artinya GRU mampu menjelaskan 93,25% variasi data aktual atau lebih tinggi 3,53 poin persentase dibandingkan LSTM. Keunggulan ini menarik dicermati karena arsitektur GRU justru lebih sederhana, hanya menggunakan dua *gate* (*update gate* dan *reset gate*) dengan parameter lebih sedikit (96.993 vs 128.417). Hal ini menunjukkan bahwa kesederhanaan arsitektur GRU memberikan kemampuan generalisasi yang lebih baik karena model tidak terlalu kompleks sehingga lebih mampu menangkap pola esensial data tanpa overfitting. Dari sisi efisiensi komputasi, GRU juga

lebih unggul dengan waktu pelatihan 54,87 detik dibandingkan LSTM 78,29 detik (lebih cepat 29,92%).

Temuan ini berbeda dari beberapa penelitian yang menyatakan LSTM lebih unggul seperti Hariyanti dkk. (Hariyanti et al., 2025) dan Puteri (Puteri, 2023), namun konsisten dengan Prayogi dkk. (Prayogi et al., 2024) dan Nilsen (Nilsen, 2022) yang menyatakan GRU mampu memberikan kinerja lebih baik pada data time series tertentu, khususnya ketika pola data dapat ditangkap secara efisien oleh arsitektur yang lebih sederhana. Yongchareon (Yongchareon, 2025) menekankan bahwa tidak ada model tunggal yang selalu superior pada semua konteks data, sehingga evaluasi empiris menggunakan multi-metrik seperti yang dilakukan dalam penelitian ini sangat penting untuk menghasilkan kesimpulan yang objektif. Hal ini juga sejalan dengan konsep Occam's Razor dalam pemodelan bahwa model lebih sederhana dengan performa setara atau lebih baik cenderung lebih disukai karena lebih efisien dalam implementasi.

Hasil prediksi harga BBKA periode Mei–Agustus 2026 menggunakan model GRU menunjukkan tren kenaikan bertahap dari Rp 6.166,56 pada Mei 2026 menuju Rp 6.727,84 pada Agustus 2026 dengan rata-rata prediksi Rp 6.507,39. Tren pemulihan ini mengindikasikan model memprediksi harga BBKA akan naik bertahap setelah periode penurunan di akhir 2025 hingga awal 2026. Namun perlu digarisbawahi bahwa prediksi berbasis *deep learning* bersifat probabilistik dan tidak memperhitungkan faktor eksternal seperti kebijakan moneter Bank Indonesia, kondisi makroekonomi global, maupun sentimen pasar yang dapat memengaruhi harga saham secara signifikan (Rahayu & Khoirudin, 2023).

Secara keseluruhan, penelitian ini membuktikan bahwa pendekatan *deep learning* berbasis recurrent *neural network* sangat potensial untuk prediksi harga saham di pasar modal Indonesia. Kedua model mampu menghasilkan MAPE di bawah 3% yang membuktikan efektivitas metode ini, khususnya pada saham *blue chip* seperti BBKA yang memiliki likuiditas tinggi dan data historis yang panjang. GRU terbukti menjadi pilihan yang lebih superior dibandingkan LSTM, baik dari sisi akurasi maupun efisiensi komputasi (Sharma et al., 2021), sehingga direkomendasikan sebagai model utama untuk prediksi harga saham di sektor perbankan Indonesia.

KESIMPULAN DAN SARAN

Kesimpulan

Penelitian ini berhasil membangun dan membandingkan kinerja model LSTM dan GRU dalam memprediksi harga penutupan saham PT Bank Central Asia Tbk (BBKA) menggunakan data historis periode 1 Januari 2019 hingga 30 April 2026 dengan total 1.780 data harian. Berdasarkan evaluasi komprehensif menggunakan empat metrik (RMSE, MAE, MAPE, dan R^2), model GRU terbukti secara konsisten unggul dibandingkan LSTM pada seluruh metrik. Model GRU menghasilkan RMSE 206,96, MAE 163,56, MAPE 2,09%, dan R^2 0,9325, sementara model LSTM menghasilkan RMSE 255,45, MAE 201,57, MAPE 2,57%, dan R^2 0,8972. Selain lebih akurat, GRU juga lebih efisien secara komputasi dengan waktu pelatihan 54,87 detik dibandingkan LSTM 78,29 detik dan jumlah parameter lebih sedikit (96.993 vs 128.417). Kedua model menghasilkan MAPE di bawah 3% yang termasuk dalam kategori prediksi sangat akurat. Model GRU selanjutnya digunakan untuk memprediksi harga saham BBKA periode Mei–Agustus 2026 dengan proyeksi tren kenaikan bertahap dari Rp 6.166,56 menuju Rp 6.727,84 dengan rata-rata Rp 6.507,39.

Penelitian ini juga memiliki beberapa keterbatasan. Pertama model hanya menggunakan variabel harga penutupan (close price) sebagai input tunggal tanpa mempertimbangkan fitur teknikal lain seperti volume perdagangan, harga tertinggi, atau terendah. Kedua, faktor eksternal yang dapat memengaruhi harga saham secara signifikan—seperti sentimen berita, kebijakan moneter Bank Indonesia, kondisi makroekonomi global, maupun peristiwa geopolitik—tidak diikutsertakan dalam model. Ketiga, cakupan penelitian terbatas pada satu emiten (BBKA) sehingga hasil tidak dapat digeneralisasi secara langsung untuk saham lainnya. Keempat, prediksi jangka

panjang periode Mei-Agustus 2026 menggunakan metode iterative forecasting berpotensi mengakumulasi kesalahan prediksi karena setiap output digunakan sebagai input berikutnya. Kelima, penelitian ini belum mengeksplorasi arsitektur lain seperti model hybrid LSTM-GRU, Transformer, atau model berbasis attention mechanism yang berpotensi memberikan akurasi lebih tinggi.

Saran

Berdasarkan keterbatasan yang telah diidentifikasi, beberapa saran untuk penelitian selanjutnya adalah: (1) mengeksplorasi model hybrid LSTM-GRU atau arsitektur Transformer yang berpotensi memberikan akurasi lebih tinggi; (2) menambahkan fitur eksternal seperti indikator teknikal (RSI, MACD, Bollinger Bands), sentimen berita, atau variabel makroekonomi sebagai input tambahan; (3) menguji generalisasi model pada saham-saham sektor lainnya di Bursa Efek Indonesia; serta (4) menggunakan metode direct *multi-step forecasting* sebagai alternatif *iterative forecasting* untuk menghasilkan prediksi jangka panjang yang lebih realistis.

DAFTAR PUSTAKA

- Arunkumar, K. E., Kalaga, D. V, Mohan, C., Kumar, S., & Brenza, T. M. (2022). Comparative analysis of Gated Recurrent Units (GRU), long Short-Term memory (LSTM) cells , autoregressive Integrated moving average (ARIMA), seasonal autoregressive Integrated moving average (SARIMA) for forecasting COVID-19 trends. *Alexandria Engineering Journal*, 61(10), 7585–7603. <https://doi.org/10.1016/j.aej.2022.01.011>
- Arwansyah, A., Suryani, S., SY, H., Usman, U., Ahyuna, A., & Alam, S. (2022). Time Series Forecasting Menggunakan Deep Gated Recurrent Units. *Digital Transformation Technology*, 4(1), 410–416. <https://doi.org/10.47709/digitech.v4i1.4141>
- Budiharto, W. (2021). Data science approach to stock prices forecasting in Indonesia during Covid-19 using Long Short-Term Memory (LSTM). *Journal of Big Data*, 8(1). <https://doi.org/10.1186/s40537-021-00430-0>
- Furizal, Ma'Arif, A., Kariyamin, Firdaus, A. A., Wijaya, S. A., Nakib, A. M., & Ningrum, A. F. (2025). Understanding Time Series Forecasting: A Fundamental Study. *Buletin Ilmiah Sarjana Teknik Elektro*, 7(3), 554–571. <https://doi.org/10.12928/biste.v7i3.13318>
- G. B. Suhandi, et al. (2026). *Jurnal Bisnis dan Akuntansi Unsurja Vol. 11, No.1, Januari 2026 p. 11(1), 176–187*. <https://doi.org/10.35968/jbau>
- Harahap, A. M., Fitrie, S., Negeri, I., & Utara, S. (2021). Implementasi Gated Recurrent Unit (Gru) Untuk Prediksi Harga Saham Bank. *JISTech (Journal of Islamic ...)*, 6(2), 42–49.
- Hariyanti, I., Putra, V. H. C., & Raharja, A. R. (2025). Prediksi Harga Saham Bbca Menggunakan Metode Long Short-Term Memory Dan Gated Recurrent Unit. *Jurnal Responsif: Riset Sains Dan Informatika*, 7(1), 11–18. <https://doi.org/10.51977/jti.v7i1.1901>
- Larasati, L., Saadah, S., & Yunanto, P. E. (2024). Recurrent Neural Networks (RNN) and Long Short-Term Memory (LSTM) Methods to Forecast Daily Turnover at BM Motor Ngawi. *Indonesian Journal of Artificial Intelligence and Data Mining*, 7(1), 141. <https://doi.org/10.24014/ijaidm.v7i1.27643>
- Nilsen, A. (2022). Perbandingan Model RNN, Model LSTM, dan Model GRU dalam Memprediksi Harga Saham-Saham LQ45. *Jurnal Statistika Dan Aplikasinya*, 6(1), 137–147. <https://doi.org/10.21009/jsa.06113>
- Pannadhitthana Candra, A. (2025). Analisis Data Menggunakan Python: Memperkenalkan Pandas dan NumPy. *Journal of Information System and Education Development*, 3(1), 11–16. <https://doi.org/10.62386/jised.v3i1.118>
- Prayogi, K., Gata, W., & Kussanti, D. P. (2024). Prediksi Harga Saham Bank Central Asia Menggunakan Algoritma Deep Learning GRU. *Jutisi: Jurnal Ilmiah Teknik Informatika Dan Sistem Informasi*, 13(1), 647. <https://doi.org/10.35889/jutisi.v13i1.1910>

- Puteri, D. I. (2023). Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah. *Euler: Jurnal Ilmiah Matematika, Sains Dan Teknologi*, 11(1), 35–43. <https://doi.org/10.34312/euler.v11i1.19791>
- Rahayu, E. P., & Khoirudin, R. (2023). *Analisis Minat Mahasiswa dalam Berinvestasi Saham di Pasar Modal Analysis of Student Interest in Investing Stocks in the Capital Market*. 14(28), 141–150.
- Sharma, N., Sharma, R., & Jindal, N. (2021). Machine Learning and Deep Learning Applications-A Vision ☆. *Global Transitions Proceedings*, 2(1), 24–28. <https://doi.org/10.1016/j.gltp.2021.01.004>
- SUHARSONO, S. (2023). Visualisasi Data Dari Data Ketidakhadiran Mahasiswa Menggunakan Pemrograman Python. *Jurnal Teknologi Informasi*, 2(2), 103. <https://doi.org/10.35308/jti.v2i2.8336>
- Yongchareon, S. (2025). AI-Driven Intelligent Financial Forecasting: A Comparative Study of Advanced Deep Learning Models for Long-Term Stock Market Prediction. *Machine Learning and Knowledge Extraction*, 7(3). <https://doi.org/10.3390/make7030061>
- Zahara, S., & Sugianto. (2021). Peramalan Data Indeks Harga Konsumen Berbasis Time Series Multivariate Menggunakan Deep Learning. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(1), 24–30. <https://doi.org/10.29207/resti.v5i1.2562>