

Comparative Study of LSTM and GRU Accuracy in Predicting BBRI Stock Closing Price

Rifqy Willy Akbari ^{1*}, Adam Prayogo Kuncoro ^{2*}, Abdul Jahir ^{3*}

* Informatika, Fakultas Ilmu Komputer, Universitas Amikom Purwokerto

rifqy.uchiha.1704@gmail.com ¹, adam@amikompurwokerto.ac.id ², abduljahir@amikompurwokerto.ac.id ³

Article Info

Article history:

Received 2025-12-05

Revised 2026-01-13

Accepted 2025-12-31

Keyword:

BBRI,
Deep learning,
Gated recurrent unit,
Long short-term memory,
Stock price forecasting.

ABSTRACT

Stock price forecasting plays an important role in supporting investment decision-making in volatile financial markets. This study compares the performance of Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) models in predicting the closing price of PT Bank Rakyat Indonesia (BBRI.JK) stock using daily closing price data from Yahoo Finance for the period November 2, 2020, to October 30, 2025. The research methodology includes data collection, preprocessing, model development, and evaluation. The results show that the GRU model outperforms LSTM in prediction accuracy, achieving an RMSE of 90.14, MAPE of 1.86%, and MAE of 68.89, while LSTM records an RMSE of 111.00, MAPE of 2.37%, and MAE of 87.55. In terms of computational efficiency, LSTM requires less training time (343.57 seconds) compared to GRU (471.98 seconds). The Diebold–Mariano test yields a DM statistic of 1.9949 with a p-value of 0.0461, indicating a statistically significant difference in predictive accuracy, where GRU produces lower prediction errors. This study provides empirical insights into the trade-off between accuracy and computational efficiency of deep learning models for stock price forecasting.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Dalam masa modernisasi saat ini, investasi saham kini menjadi bagian penting dalam aktivitas ekonomi masyarakat Indonesia seiring perkembangan teknologi digital. Berdasarkan data Kustodian Sentral Efek Indonesia (KSEI), jumlah investor pasar modal meningkat dari 7,49 juta pada 2021 menjadi 10,3 juta pada 2022 [1]. Namun demikian, volatilitas harga saham yang tinggi membuat investor sulit memprediksi pergerakan pasar secara akurat. Untuk itu, dibutuhkan pendekatan berbasis kecerdasan buatan yang mampu mengenali pola kompleks dalam data historis saham secara lebih efektif.

Dalam konteks peramalan deret waktu (*time series forecasting*), algoritma berbasis *Recurrent Neural Network* (RNN) dan turunannya telah banyak digunakan karena kemampuannya dalam memodelkan data berurutan. Dua varian RNN yang paling umum digunakan yaitu *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Kedua varian lanjutan dari RNN ini telah terbukti memberikan kinerja yang unggul dalam pemrosesan data berurutan seperti peramalan deret waktu, sebagaimana

dibuktikan dalam studi komparatif, dimana keduanya memiliki performa yang lebih unggul dibandingkan algoritma prediksi lain [2]. Sebagai pengembangan dari jaringan saraf rekuren, LSTM dirancang untuk menangkap ketergantungan jangka panjang dan pola temporal dalam data *time series*, sekaligus meminimalkan dampak *vanishing gradient* yang menjadi keterbatasan pada model RNN klasik [3].

Sejumlah penelitian terdahulu telah mengaplikasikan LSTM dalam konteks peramalan harga saham. Studi sebelumnya membandingkan dua algoritma yaitu *Long Short-Term Memory* (LSTM) dengan *Bidirectional Long Short-Term Memory* (BiLSTM) dalam peramalan saham, dan menyimpulkan bahwa pada performa dataset PT. Bank Rakyat Indonesia (BBRI), model LSTM memiliki hasil sedikit lebih unggul dibandingkan model BiLSTM, dengan perbedaan sekitar 0.14% dari sisi *Mean Absolute Percentage Error* (MAPE) dan 0,0009 dari sisi *Mean Absolute Error* (MAE) [4]. Temuan tersebut mengindikasikan bahwa arsitektur LSTM konvensional masih memiliki kapabilitas yang kompetitif dalam menangani data saham perbankan Indonesia, terutama untuk memodelkan pola historis jangka Panjang.

Di sisi lain, *Gated Recurrent Unit* (GRU) merupakan varian dari LSTM yang memiliki arsitektur lebih sederhana, karena hanya menggunakan dua gerbang, yaitu *update gate* dan *reset gate*, tanpa adanya sel memori terpisah. Penyederhanaan struktur ini menyebabkan jumlah parameter yang harus dipelajari oleh model GRU menjadi lebih sedikit dibandingkan LSTM, sehingga secara teoritis GRU memiliki keunggulan dalam hal efisiensi pelatihan dan kebutuhan komputasi. Kondisi tersebut menjadikan GRU sering dipilih sebagai alternatif LSTM pada permasalahan *time series forecasting* yang memerlukan waktu pelatihan yang lebih singkat atau sumber daya komputasi yang terbatas. Meskipun kedua metode memiliki sejumlah kesamaan dalam mekanisme pembelajaran sekuensial, perbedaan pada arsitektur dan mekanisme pengelolaan memori internal berpotensi memengaruhi hasil peramalan yang dihasilkan, baik dari sisi akurasi maupun stabilitas prediksi.

Studi sebelumnya mengenai peramalan saham BRI mengemukakan bahwa model GRU mampu memberikan performa yang lebih baik dibandingkan LSTM berdasarkan metrik evaluasi R^2 dan MAPE pada konfigurasi parameter tertentu [5]. Selain itu, penelitian lain yang menggunakan dataset saham BBKA menunjukkan bahwa model GRU yang dilatih dengan data historis mampu menghasilkan prediksi yang akurat berdasarkan evaluasi metrik RMSE, MAE, dan *R-squared* [6]. Dalam periode terkini, GRU semakin mendapatkan perhatian sebagai salah satu metode yang memiliki prospek baik dalam meramal fluktuasi harga saham, terutama pada data yang bersifat nonlinier dan volatil. Studi terkait menjelaskan bahwa penggabungan data setelah lapisan GRU dapat meningkatkan kemampuan representasi model, sehingga menjadikannya lebih efektif dalam menangani dataset yang kompleks dan bervariasi seperti data pasar saham [7]. Penelitian lain juga menunjukkan bahwa GRU tidak hanya mampu menghasilkan nilai kesalahan prediksi yang lebih rendah, tetapi juga menawarkan waktu komputasi yang lebih efisien dibandingkan LSTM [8]. Namun demikian, terdapat pula studi yang menegaskan bahwa keunggulan GRU atau LSTM tidak bersifat universal, melainkan sangat bergantung pada karakteristik data, periode pengamatan, serta konfigurasi model yang digunakan [9].

Salah satu pendekatan yang hingga saat ini paling banyak digunakan dalam peramalan harga saham ialah LSTM, meskipun GRU menunjukkan keunggulan dari sisi efisiensi dan arsitektur yang lebih sederhana. Hal ini disebabkan oleh kemampuan LSTM dalam mempertahankan dan mengelola informasi historis jangka panjang secara lebih eksplisit melalui mekanisme sel memori, yang pada beberapa kasus mampu meningkatkan akurasi prediksi secara signifikan [10]. Sebagai contoh, studi yang membahas penerapan model LSTM untuk meramalkan harga saham BBRI dan BBNI menunjukkan bahwa model LSTM menghasilkan performa yang baik dengan nilai MAE sebesar 0,0148 untuk saham BBNI dan 0,0140 untuk saham BBRI [11]. Adapun studi lain yang menerapkan LSTM pada saham BBKA dalam kerangka analisis teknikal juga membuktikan


bahwa model tersebut mampu mencapai tingkat akurasi yang tinggi, bahkan mendekati atau melampaui performa metode pembandingan seperti *Support Vector Regression* (SVR) dan *K-Nearest Neighbor* (KNN) [12]. Meskipun fokus objek dan pendekatan penelitian tersebut berbeda, temuan-temuan ini secara umum mendukung efektivitas algoritma LSTM dalam memodelkan data saham perbankan di Indonesia.

Meskipun sejumlah penelitian telah membandingkan performa LSTM dan GRU dalam meramal harga saham BBRI, sebagian besar studi masih terbatas pada data historis sebelum tahun 2025 dan belum secara eksplisit menyoroti aspek efisiensi pelatihan model. Padahal, pasca-pandemi COVID-19, pergerakan harga saham BBRI menunjukkan pola fluktuasi yang lebih dinamis dan kompleks akibat perubahan kebijakan ekonomi, kondisi pasar global, serta percepatan transformasi digital di sektor perbankan. Selain itu, masih terbatas penelitian yang menganalisis trade-off antara akurasi prediksi dan efisiensi komputasi, seperti waktu pelatihan dan kestabilan konvergensi model, pada kedua algoritma tersebut. Oleh karena itu, penelitian ini berfokus untuk mengisi kesenjangan penelitian dengan melakukan analisis komparatif terhadap performa dan efisiensi model LSTM dan GRU dalam peramalan harga penutupan saham BBRI pada periode lima tahun terakhir (2020–2025).

Saham perbankan dipilih sebagai objek penelitian karena memiliki peran strategis dalam menjaga stabilitas sistem keuangan nasional. Berdasarkan data Otoritas Jasa Keuangan (OJK) tahun 2024, kelompok bank besar menguasai hampir 50% aset industri perbankan nasional, sehingga pergerakan harga saham sektor ini mencerminkan dinamika ekonomi secara luas [13]. Penelitian ini menggunakan data harga penutupan saham sektor perbankan periode 2 November 2020 hingga 30 Oktober 2025 yang diperoleh dari platform Yahoo Finance untuk mengevaluasi dan membandingkan performa model LSTM dan GRU dari sisi akurasi prediksi dan efisiensi komputasi. Hasil penelitian diharapkan dapat memberikan gambaran empiris mengenai karakteristik kinerja kedua model dalam memodelkan data saham yang bersifat volatil, khususnya pada periode pasca-pandemi.

II. METODE

Pendekatan penelitian ini mengikuti tahapan dasar *data mining* yang telah disesuaikan untuk peramalan deret waktu, meliputi tahap Pengumpulan Data, Prapemrosesan Data, Pembuatan Model, dan Evaluasi Model. Pendekatan ini dipilih karena mampu menggambarkan alur penelitian secara sistematis, mulai dari pengolahan data mentah hingga evaluasi kinerja model peramalan. Alur lengkap tahapan penelitian dipaparkan dalam Gambar 1.



Gambar 1. Alur Tahapan Penelitian

A. Pengumpulan Data

Pada tahap ini, data yang digunakan dalam penelitian dikumpulkan dari sumber daring, yaitu *platform* Yahoo Finance. Data penelitian berupa harga historis saham BBRI.JK yang digunakan sebagai dasar dalam proses pemodelan. Periode data yang digunakan mencakup rentang waktu 2 November 2020 hingga 30 Oktober 2025, yang merepresentasikan kondisi pasar saham pada periode pasca-pandemi. Fokus penelitian diarahkan pada data harga penutupan (*closing price*), karena harga penutupan mencerminkan nilai akhir transaksi harian dan umum digunakan dalam penelitian peramalan harga saham.

B. Prapemrosesan Data

Tahap prapemrosesan data bertujuan untuk membangun dataset akhir yang siap digunakan pada proses pemodelan. Tahapan ini sangat penting untuk memastikan bahwa data yang digunakan memiliki kualitas yang sesuai dengan kebutuhan model *deep learning*. Langkah pertama yang dilakukan adalah pemilihan atribut harga penutupan (*close*) sebagai fitur utama dalam penelitian.

Selanjutnya, data dinormalisasi menggunakan metode MinMaxScaler ke dalam rentang $[0,1]$. Normalisasi dilakukan untuk menghindari dominasi nilai tertentu dan mempercepat proses konvergensi selama pelatihan model. Setelah proses normalisasi, dataset dibagi menjadi data latih dan data uji dengan rasio tertentu, di mana data latih digunakan untuk membangun model dan data uji digunakan untuk mengevaluasi kemampuan generalisasi model.

Tahap berikutnya adalah pembentukan urutan data (*sequence generation*) berdasarkan sejumlah periode sebelumnya (*look-back period*). Proses ini bertujuan untuk membentuk pola sekuensial yang dapat dipelajari oleh model LSTM dan GRU. Data kemudian disesuaikan ke dalam bentuk tiga dimensi (*reshape*), yaitu [jumlah sampel, jumlah

timestep, jumlah fitur], agar sesuai dengan format masukan yang dibutuhkan oleh kedua model berbasis RNN.

C. Pembuatan Model

Pada tahap pembuatan model, data yang telah melalui proses prapemrosesan digunakan untuk melatih dua algoritma *deep learning*, yaitu *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Kedua model digunakan untuk melakukan peramalan harga saham dalam jangka pendek dengan *horizon* peramalan selama 30 hari.

1) *Long Short-Term Memory (LSTM)*: *Long Short-Term Memory* (LSTM) merupakan algoritma yang diciptakan oleh Hochreiter dan Schmidhuber pada tahun 1997 dan dirancang untuk mengatasi permasalahan *vanishing gradient* pada RNN klasik [14]. LSTM bekerja secara berulang dengan mempertimbangkan informasi dari waktu sebelumnya dan waktu saat ini. Penelitian ini menggunakan arsitektur model LSTM untuk memodelkan pola historis harga saham dan menghasilkan peramalan harga saham dalam jangka pendek selama 30 hari. Model ini dipilih sebab LSTM memiliki kemampuan menyimpan informasi penting pada pola data serta mengatur aliran informasi melalui mekanisme gerbang. LSTM memiliki tiga *gate* utama, yaitu *forget gate*, *input gate*, dan *output gate*, yang berfungsi untuk menentukan informasi mana yang dipertahankan, diperbarui, atau dibuang selama proses pembelajaran [15]. Mekanisme ini memungkinkan LSTM menangkap ketergantungan jangka panjang dalam data deret waktu. Proses komputasi pada LSTM dapat dijelaskan melalui persamaan berikut [16]:

$$\begin{aligned}
 i_t &= \sigma(W_i X_t + U_i h_{t-1} + b_i) \\
 f_t &= \sigma(W_f X_t + U_f h_{t-1} + b_f) \\
 \tilde{c}_t &= \tanh(W_c X_t + U_c h_{t-1} + b_c) \\
 c_t &= i_t \cdot \tilde{c}_t + f_t \cdot c_{t-1} \\
 h_t &= o_t \cdot \tanh(c_t)
 \end{aligned}$$

Dimana:

i_t = *input gate*,

f_t = *forget gate*,

$\tilde{c}_t$ = *candidate state*,

c_t = *cell state*,

h_t = *hidden state*,

W dan U = bobot (*weights*),

b = bias, dan

X_t = nilai *input*.

2) *Gated Recurrent Unit (GRU)*: GRU merupakan varian yang lebih sederhana dari LSTM dengan hanya

menggunakan dua *gate*, yaitu *reset gate* dan *update gate*. Model GRU dipilih sebab dalam konteks peramalan, data sering memiliki *noise*, volatilitas tinggi, atau pola yang berubah-ubah dari waktu ke waktu. GRU dengan struktur lebih sederhana bisa lebih stabil terhadap *noise* / *overfitting* dibanding LSTM [17]. Model GRU diterapkan untuk mempelajari hubungan temporal antar data melalui mekanisme *gating* yang mampu menangkap pola sekuensial secara efisien. Persamaan matematis GRU dapat dijelaskan sebagai berikut [16]:

$$\begin{aligned} r_t &= \sigma(W_r X_t + U_r h_{t-1} + b_r) \\ z_t &= \sigma(W_z X_t + U_z h_{t-1} + b_z) \\ \tilde{h}_t &= \tanh(W_h X_t + U_h(r_t h_{t-1}) + b_h) \\ h_t &= z_t \tilde{h}_t + (1 - z_t) h_{t-1} \end{aligned}$$

Dimana:

r_t = *reset gate*,

z_t = *forget gate*,

$\tilde{h}_t$ = *candidate value*,

h_t = *output hidden state*,

W dan U = bobot (*weights*),

b = bias, dan

X_t = nilai *input*.

D. Evaluasi Model

Setelah model prediksi selesai dibangun, tahap selanjutnya adalah evaluasi model yang bertujuan untuk menilai kinerja model LSTM dan GRU dalam meramalkan harga penutupan saham. Evaluasi dilakukan untuk menilai performa model secara komprehensif, yang mencakup aspek akurasi prediksi, efisiensi pelatihan model dan uji signifikansi statistik.

Evaluasi akurasi dilakukan untuk mengukur tingkat kesalahan prediksi serta membandingkan performa model LSTM dan GRU secara objektif. Dalam penelitian ini, metrik yang digunakan meliputi *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *Mean Absolute Error* (MAE). Selain evaluasi kuantitatif, analisis visual digunakan untuk membandingkan hasil prediksi dengan data aktual guna menilai kesesuaian pola peramalan [18].

Selain mengevaluasi akurasi prediksi, penelitian ini juga mempertimbangkan aspek efisiensi pelatihan model. Evaluasi efisiensi dilakukan untuk mengetahui seberapa optimal model LSTM dan GRU dalam memanfaatkan sumber daya komputasi selama proses pelatihan.

Penelitian ini juga menerapkan Diebold-Mariano Test untuk menguji signifikansi statistik perbedaan kinerja antara model LSTM dan GRU. Uji ini digunakan untuk mengetahui apakah perbedaan akurasi prediksi yang dihasilkan oleh

kedua model bersifat signifikan secara statistik atau hanya terjadi akibat fluktuasi data semata.

1) *Root Mean Square Error (RMSE)*: RMSE digunakan untuk mengukur besarnya kesalahan prediksi dalam satuan yang sama dengan nilai aktual. Metrik ini memberikan penalti yang lebih besar terhadap kesalahan prediksi yang ekstrem, sehingga sensitif terhadap *outlier*. Rumus RMSE dinyatakan sebagai berikut:

$$RMSE = \sqrt{\frac{\sum (y'_i - y_i)^2}{n}}$$

Dimana:

y_i = nilai aktual ke- i ,

y'_i = nilai prediksi ke- i , dan

n = jumlah sampel dalam data

2) *Mean Absolute Percentage Error (MAPE)*: MAPE digunakan untuk mengukur rata-rata persentase kesalahan antara nilai aktual dan nilai prediksi. MAPE dinyatakan dalam bentuk persentase yang dimana memudahkan interpretasi kinerja model, karena alasan itulah peneliti menggunakan metrik ini. Rumus MAPE dijabarkan sebagai berikut.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|y'_t - y_t|}{y_t} \times 100$$

Dimana:

y_t = nilai aktual ke- t ,

y'_t = nilai prediksi ke- t , dan

n = jumlah sampel dalam data

3) *Mean Absolute Error (MAE)*: MAE digunakan untuk mengukur rata-rata nilai kesalahan absolut antara hasil prediksi dan nilai aktual. Berbeda dengan RMSE yang memberikan penalti lebih besar pada kesalahan ekstrem, MAE bersifat lebih robust terhadap *outlier* karena seluruh kesalahan diperlakukan secara linear. MAE dihitung menggunakan persamaan berikut:

$$MAE = \frac{1}{n} \sum_{t=1}^n |y'_t - y_t|$$

Dimana:

y_t = nilai aktual ke- t ,

y'_t = nilai prediksi ke- t , dan

n = jumlah sampel dalam data

4) *Analisis Proses Pelatihan dan Efisiensi Komputasi*: Efisiensi pelatihan model dievaluasi menggunakan beberapa indikator, yaitu waktu pelatihan (*training time*), jumlah *epoch* hingga konvergensi, serta kestabilan penurunan nilai loss selama proses pelatihan. Waktu pelatihan digunakan untuk mengukur durasi yang dibutuhkan model dalam

menyelesaikan proses pembelajaran, sedangkan jumlah *epoch* hingga konvergensi mencerminkan kecepatan model dalam mencapai kondisi pembelajaran yang stabil. Perbandingan efisiensi pelatihan antara LSTM dan GRU dilakukan dengan menggunakan konfigurasi lingkungan komputasi yang sama, sehingga perbedaan hasil yang diperoleh mencerminkan karakteristik intrinsik dari masing-masing arsitektur model. Analisis efisiensi ini bertujuan untuk melihat keseimbangan antara tingkat akurasi prediksi dan kebutuhan komputasi, serta memberikan gambaran empiris mengenai kelayakan penerapan kedua model dalam skenario peramalan harga saham.

5) *Diebold-Mariano Test*: Uji Diebold–Mariano (DM *Test*) merupakan metode statistik yang digunakan untuk menguji apakah terdapat perbedaan akurasi prediksi yang signifikan secara statistik antara dua model peramalan. Uji ini diperkenalkan oleh Diebold dan Mariano (1995) dan banyak digunakan dalam studi peramalan deret waktu, khususnya pada bidang ekonomi dan keuangan [19]. DM *Test* tidak hanya membandingkan nilai kesalahan prediksi secara deskriptif, tetapi juga mengevaluasi apakah perbedaan kesalahan tersebut bersifat signifikan secara statistik. Statistik DM *Test* dirumuskan sebagai:

$$DM = \frac{\bar{d}}{\sqrt{\frac{\hat{\sigma}_d^2}{T}}}$$

Dimana:

$\bar{d}$ = rata-rata selisih *loss*,

$\hat{\sigma}_d^2$ = varians dari d_t ,

T = jumlah observasi

Nilai statistik DM selanjutnya dibandingkan dengan distribusi normal standar untuk memperoleh nilai *p-value*. Jika nilai *p-value* lebih kecil dari tingkat signifikansi (umumnya $\alpha=0,05$), maka hipotesis nol ditolak dan dapat disimpulkan bahwa terdapat perbedaan performa prediksi yang signifikan antara kedua model.

III. HASIL DAN PEMBAHASAN

A. Pengumpulan Data

Data yang digunakan dalam penelitian ini diperoleh dari platform daring Yahoo Finance. Dataset yang diunduh mencakup variabel harga pembukaan (*open*), harga penutupan (*close*), harga tertinggi (*high*), harga terendah (*low*), serta volume perdagangan harian saham BBRI.JK. Periode data yang digunakan adalah selama lima tahun terakhir, yaitu dari 2 November 2020 hingga 30 Oktober 2025, dengan total sebanyak 1.204 entri data harian. Data hingga tahun 2025 diperlakukan sebagai data historis yang tersedia pada saat penelitian dilakukan dan digunakan untuk merepresentasikan kondisi pasar terkini.

Dalam penelitian ini, hanya variabel harga penutupan (*close*) yang digunakan sebagai objek peramalan. Pemilihan

harga penutupan didasarkan pada pertimbangan bahwa harga tersebut merepresentasikan nilai akhir konsensus pasar pada setiap hari perdagangan dan sering digunakan sebagai acuan utama dalam analisis teknikal serta evaluasi kinerja saham. Ringkasan harga penutupan pada awal dan akhir periode penelitian disajikan pada Tabel 1.

TABEL I
DATA HISTORIS HARGA PENUTUPAN SAHAM BBRI

Index	Tanggal	Harga Penutupan (Rupiah)
0	2020-11-02	2272.37
1	2020-11-03	2272.37
2	2020-11-04	2211.87
3	2020-11-05	2346.33
4	2020-11-06	2393.39
...	...	...
1199	2025-10-24	3710.46
1200	2025-10-27	3720.10
1201	2025-10-28	3710.46
1202	2025-10-29	3749.01
1203	2025-10-30	3768.28

Berdasarkan Tabel 1, harga saham BBRI menunjukkan kecenderungan peningkatan dari sekitar Rp2.272,37 (2 November 2020) pada awal periode menjadi Rp3.768,28 pada akhir periode (30 Oktober 2025). Rentang waktu yang cukup panjang ini memungkinkan model untuk mempelajari berbagai pola pergerakan harga, termasuk tren, fluktuasi, dan dinamika pasar yang terjadi selama periode pasca-pandemi.

B. Prapemrosesan Data

Tahap prapemrosesan diawali dengan ekstraksi kolom *close* (harga penutupan) sebagai fitur target prediksi. Kemudian peneliti melakukan transformasi data dengan langkah sebagai berikut:

1) *Normalisasi Data*: Data harga penutupan dinormalisasi menggunakan MinMaxScaler kedalam rentang [0,1]. Normalisasi dilakukan untuk menghindari dominasi nilai tertentu dan mempercepat proses konvergensi model selama pelatihan.

2) *Pembagian Dataset*: Dataset yang telah melalui proses normalisasi kemudian dibagi menjadi data latih dan data uji dengan rasio 80:20. Pembagian data dilakukan berdasarkan urutan waktu (*chronological split*), di mana data historis digunakan sebagai data latih dan data yang lebih baru digunakan sebagai data uji, sehingga dapat mencerminkan kondisi prediksi pada data yang belum pernah dilihat sebelumnya. Dari proses ini diperoleh 964 data latih dan 240 data uji. Data latih digunakan untuk membangun model prediksi, sedangkan data uji digunakan untuk mengevaluasi kemampuan generalisasi model.

3) *Pembuatan Sequence*: Pada tahap ini, data diubah menjadi rangkaian berurutan sepanjang 60 hari. Proses ini diperlukan karena model seperti LSTM dan GRU melakukan pembelajaran dari pola waktu. Model hanya bisa mengenali tren naik-turun, momentum, atau perubahan musiman jika data disajikan dalam bentuk urutan. Dengan menjadikan 60 hari sebagai satu jendela pengamatan, model mendapatkan konteks historis untuk memperkirakan nilai pada hari berikutnya. Pemilihan jendela pengamatan selama 60 hari dilakukan untuk menyeimbangkan kebutuhan konteks historis dan kompleksitas model.

4) *Transformasi ke Format Tiga Dimensi*: Selanjutnya data ditransformasi ke dalam struktur tiga dimensi yang terdiri dari jumlah sampel (*samples*), panjang urutan waktu (*timesteps*), dan banyaknya fitur (*features*). Bentuk ini selaras dengan cara kerja LSTM dan GRU yang membaca data secara bertahap dari satu langkah waktu ke langkah berikutnya. Dengan struktur tersebut, model dapat mengolah setiap timestep sebagai bagian dari pola yang lebih besar sehingga dapat mengenali tren, perubahan ritme, dan keterkaitan antarvariabel.

C. Pembuatan Model

Model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dibangun menggunakan arsitektur *Sequential* dengan tiga lapisan tersembunyi, masing-masing terdiri dari 50 unit *neuron*. Pada setiap lapisan ditambahkan *dropout* sebesar 20% untuk mengurangi risiko *overfitting*. *Output* dari lapisan terakhir kemudian diteruskan ke lapisan *Dense* untuk menghasilkan nilai prediksi harga penutupan saham.

Kedua model dikompilasi menggunakan *optimizer* Adam dengan *learning rate* sebesar 0,001 dan fungsi *loss* *Mean Squared Error* (MSE). Proses pelatihan dirancang dengan maksimum 120 *epoch* dan ukuran *batch* sebesar 32. Setelah proses pelatihan selesai, dilakukan visualisasi *loss* untuk melihat perbandingan antara *training loss* dan *validation loss*.

Arsitektur lengkap model LSTM dan GRU yang digunakan dalam penelitian ini disajikan pada Tabel 2 dan Tabel 3. Berdasarkan tabel tersebut, dapat diamati bahwa arsitektur LSTM memiliki jumlah parameter yang lebih besar dibandingkan GRU. Hal ini disebabkan oleh mekanisme gerbang pada LSTM yang terdiri dari *input gate*, *forget gate*, dan *output gate*, sehingga memungkinkan model menangkap ketergantungan jangka panjang secara lebih detail, namun dengan konsekuensi meningkatnya kompleksitas komputasi.

Sebaliknya, model GRU dirancang dengan arsitektur yang lebih sederhana karena hanya menggunakan dua gerbang utama, yaitu *reset gate* dan *update gate*. Struktur ini menyebabkan jumlah parameter pada GRU lebih sedikit dibandingkan LSTM, sehingga secara teoritis GRU memiliki efisiensi komputasi yang lebih baik dan lebih stabil dalam proses pelatihan, khususnya pada data deret waktu yang bersifat volatil.

TABEL II
ARSITEKTUR MODEL LSTM

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 60, 50)	10,400
dropout (Dropout)	(None, 60, 50)	0
lstm_1 (LSTM)	(None, 60, 50)	20,200
dropout_1 (Dropout)	(None, 60, 50)	0
lstm_2 (LSTM)	(None, 50)	20,200
dropout_2 (Dropout)	(None, 50)	0
dense (Dense)	(None, 25)	1,275
dense_1 (Dense)	(None, 1)	26

TABEL III
ARSITEKTUR MODEL GRU

Layer (type)	Output Shape	Param #
gru (GRU)	(None, 60, 50)	7,950
dropout (Dropout)	(None, 60, 50)	0
gru_1 (GRU)	(None, 60, 50)	15,300
dropout_1 (Dropout)	(None, 60, 50)	0
gru_2 (GRU)	(None, 50)	15,300
dropout_2 (Dropout)	(None, 50)	0
dense (Dense)	(None, 25)	1,275
dense_1 (Dense)	(None, 1)	26

D. Evaluasi Model

Evaluasi model dilakukan untuk menilai kinerja prediksi dan efisiensi komputasi dari model LSTM dan GRU yang telah dilatih. Evaluasi mencakup tiga aspek utama, yaitu pengukuran akurasi prediksi pada data uji, analisis proses pelatihan, dan uji signifikansi statistik.

1) *Evaluasi Akurasi Prediksi*: Evaluasi akurasi prediksi dilakukan menggunakan tiga metrik utama, yaitu *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE) dan *Mean Absolute Error* (MAE). Ketiga metrik ini digunakan untuk memberikan gambaran yang komprehensif mengenai tingkat kesalahan prediksi model, baik dalam satuan absolut maupun dalam bentuk persentase. Sebagaimana hasil dan perbandingan evaluasi kedua model dipaparkan pada Tabel 4.


TABEL IV
NILAI EVALUASI MODEL LSTM DAN GRU DALAM PERAMALAN HARGA PENUTUPAN SAHAM BBRI

Model	RMSE	MAPE	MAE
LSTM	111,00	2.37%	87,55
GRU	90,14	1.86%	68,89


Berdasarkan tabel tersebut, model GRU menghasilkan nilai RMSE sebesar 90,14, MAPE sebesar 1,86%, dan MAE sebesar 68,89. Sementara itu, model LSTM menghasilkan nilai RMSE sebesar 111,00, MAPE sebesar 2,37%, dan MAE sebesar 87,55. Nilai kesalahan yang lebih rendah pada seluruh metrik menunjukkan bahwa model GRU memiliki tingkat akurasi prediksi yang lebih baik dibandingkan model LSTM pada dataset yang digunakan dalam penelitian ini.

Keunggulan GRU pada metrik RMSE dan MAE mengindikasikan bahwa secara rata-rata prediksi yang dihasilkan memiliki deviasi yang lebih kecil terhadap nilai aktual. Selain itu, nilai MAPE yang lebih rendah menunjukkan bahwa kesalahan prediksi relatif terhadap harga aktual berada pada tingkat yang lebih kecil, sehingga prediksi GRU lebih mendekati kondisi pasar yang sebenarnya.

2) *Analisis Proses Pelatihan dan Efisiensi Komputasi:* Setelah proses pelatihan selesai, dilakukan visualisasi nilai *training loss* dan *validation loss* untuk masing-masing model sebagaimana ditunjukkan pada Gambar 2 dan Gambar 3.



Gambar 2. Visualisasi Nilai *Training-loss* dan *Validation Loss* Model LSTM



Gambar 3. Visualisasi Nilai *Training-loss* dan *Validation Loss* Model GRU

Berdasarkan grafik tersebut, terlihat bahwa kedua model menunjukkan pola penurunan *loss* yang konsisten seiring bertambahnya *epoch*. Hal ini menandakan bahwa model mampu mempelajari pola data historis dengan baik dan mencapai kondisi konvergensi yang stabil tanpa indikasi *overfitting* yang signifikan.

Dari sisi efisiensi komputasi, hasil pelatihan menunjukkan adanya perbedaan karakteristik antara kedua model. Model GRU mencapai kondisi konvergen pada *epoch* ke-100 dengan

waktu pelatihan sebesar 471.98 detik dan jumlah parameter sebanyak 119.555. Sementara itu, model LSTM memerlukan hingga 100 *epoch* untuk mencapai konvergensi, dengan waktu pelatihan sebesar 343.57 detik dan jumlah parameter sebesar 156.305. Perbandingan efisiensi komputasi kedua model disajikan pada Tabel 5.

TABEL V
PERBANDINGAN EFISIENSI KOMPUTASI MODEL

Model	Waktu Latih (detik)	Epoch Konvergen	Jumlah Parameter
GRU	471.98	100	119.555
LSTM	343.57	100	156.305

Hasil tersebut menunjukkan bahwa dari sisi waktu pelatihan, model LSTM memiliki efisiensi yang lebih baik dibandingkan GRU pada konfigurasi dan lingkungan komputasi yang digunakan dalam penelitian ini. Namun demikian, model GRU tetap memiliki keunggulan dari sisi kompleksitas arsitektur, yang ditunjukkan oleh jumlah parameter yang lebih sedikit dibandingkan LSTM. Jumlah parameter yang lebih rendah mengindikasikan potensi efisiensi memori dan peluang generalisasi yang lebih baik pada kondisi tertentu.

3) *Analisis Uji Signifikansi Menggunakan Diebold-Mariano Test:* Hasil pengujian Diebold-Mariano (DM Test) menunjukkan nilai statistik DM sebesar 1,9949 dengan nilai *p-value* sebesar 0,0461. Dengan menggunakan tingkat signifikansi $\alpha=0,05$, nilai *p-value* yang lebih kecil dari 0,05 mengindikasikan bahwa hipotesis nol ditolak.

Penolakan hipotesis nol menunjukkan bahwa terdapat perbedaan akurasi prediksi yang signifikan secara statistik antara model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dalam memprediksi harga penutupan saham PT Bank Rakyat Indonesia (BBRI.JK). Dengan kata lain, perbedaan nilai kesalahan prediksi yang dihasilkan oleh kedua model tidak terjadi secara kebetulan, melainkan mencerminkan perbedaan performa yang nyata.

Nilai statistik DM yang bernilai positif menunjukkan bahwa model GRU memiliki nilai *loss* yang lebih rendah dibandingkan model LSTM pada periode pengujian. Hal ini mengindikasikan bahwa secara statistik, model GRU memberikan performa prediksi yang lebih baik dibandingkan model LSTM, sejalan dengan hasil evaluasi menggunakan metrik RMSE, MAPE dan MAE yang menunjukkan keunggulan GRU dalam hal akurasi prediksi.

E. Analisis Hasil Prediksi

Bagian ini membahas hasil peramalan harga penutupan saham BBRI yang dihasilkan oleh model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU), baik pada periode historis maupun pada *horizon* prediksi 30 hari ke depan. Analisis dilakukan melalui visualisasi grafik untuk mengevaluasi kemampuan model dalam mengikuti pola data

aktual serta mengamati karakteristik tren yang dihasilkan oleh masing-masing model.

1) *Visualisasi Harga Aktual dan Prediksi*: Gambar 4 menunjukkan perbandingan antara harga penutupan saham BBRI aktual dengan hasil prediksi yang dihasilkan oleh model Long Short-Term Memory (LSTM) dan *Gated Recurrent Unit* (GRU) pada periode historis 2020–2025. Berdasarkan visualisasi tersebut, kedua model mampu mengikuti pola umum pergerakan harga saham, termasuk fase kenaikan dan penurunan harga. Hal ini mengindikasikan bahwa model LSTM dan GRU berhasil mempelajari karakteristik temporal dari data historis yang digunakan selama proses pelatihan. sebelumnya.



Gambar 4. Grafik Perbandingan Hasil Prediksi Model LSTM dan GRU dengan Harga Aktual Saham


Meskipun demikian, terdapat perbedaan karakteristik prediksi antara kedua model. Model GRU menghasilkan kurva prediksi yang relatif lebih halus dan stabil, dengan fluktuasi yang lebih kecil dibandingkan model LSTM. Sebaliknya, model LSTM menunjukkan respons yang lebih sensitif terhadap perubahan harga, sehingga menghasilkan prediksi dengan variasi yang lebih tinggi pada periode tertentu. Perbedaan ini menunjukkan bahwa GRU cenderung melakukan *smoothing* terhadap data historis, sedangkan LSTM lebih adaptif terhadap dinamika perubahan jangka pendek.

2) *Visualisasi Prediksi Selama 30 Hari ke Depan*: Hasil peramalan harga penutupan saham BBRI selama 30 hari ke depan disajikan pada Gambar 5 dan Gambar 6. Berdasarkan hasil tersebut, kedua model memprediksi arah pergerakan yang berbeda. Model GRU menunjukkan kecenderungan penurunan harga (*downtrend*) sepanjang periode prediksi, sedangkan model LSTM memprediksi adanya peningkatan harga (*uptrend*).

Model GRU menghasilkan nilai prediksi yang menurun secara bertahap, dari sekitar 3.751 Rupiah pada awal periode menjadi sekitar 3.678 Rupiah pada akhir periode prediksi. Pola ini menunjukkan bahwa GRU cenderung memberikan estimasi yang lebih konservatif dan stabil dalam merespons perubahan harga saham.

Sebaliknya, model LSTM memperlihatkan tren peningkatan harga yang cukup konsisten, dengan nilai prediksi meningkat

dari sekitar 3.751 Rupiah hingga mendekati 4.006 Rupiah. Hal ini mengindikasikan bahwa LSTM lebih sensitif terhadap pola kenaikan yang terdapat pada data historis, sehingga menghasilkan proyeksi harga yang lebih optimistis dibandingkan GRU.



Gambar 5. Grafik Perbandingan Prediksi Model Selama 30 Hari ke Depan

Tanggal	Prediksi GRU	Prediksi LSTM
2025-10-31	3751.299072	3755.938965
2025-11-01	3748.295654	3762.242188
2025-11-02	3743.262207	3766.952637
2025-11-03	3739.974121	3771.945557
2025-11-04	3737.609863	3778.226807
2025-11-05	3735.412842	3786.095947
2025-11-06	3733.240479	3795.458252
2025-11-07	3731.069580	3806.024902
2025-11-08	3728.875732	3817.427734
2025-11-09	3726.645996	3829.288818
2025-11-10	3724.379639	3841.266357
2025-11-11	3722.080811	3853.083008
2025-11-12	3719.755859	3864.539307
2025-11-13	3717.408936	3875.513184
2025-11-14	3715.044678	3885.953857
2025-11-15	3712.667236	3895.864502
2025-11-16	3710.278076	3905.288818
2025-11-17	3707.879883	3914.292480
2025-11-18	3705.474121	3922.947754
2025-11-19	3703.061279	3931.326904
2025-11-20	3700.642334	3939.489014
2025-11-21	3698.217773	3947.480957
2025-11-22	3695.787598	3955.333740
2025-11-23	3693.352295	3963.063477
2025-11-24	3690.912354	3970.674561
2025-11-25	3688.467529	3978.163574
2025-11-26	3686.018311	3985.521240
2025-11-27	3683.563965	3992.736084
2025-11-28	3681.104736	3999.796875
2025-11-29	3678.641602	4006.693848

Gambar 6. Peramalan Model GRU dan LSTM Selama 30 Hari ke Depan

Perbedaan hasil prediksi menunjukkan bahwa model GRU menghasilkan estimasi harga yang lebih stabil dengan kecenderungan penurunan (*downtrend*) secara bertahap, sedangkan model LSTM memprediksi adanya peningkatan harga (*uptrend*) yang berlangsung secara konsisten selama periode prediksi. Selisih nilai prediksi antara kedua model masih berada dalam rentang yang wajar, yang mengindikasikan bahwa perbedaan tersebut mencerminkan variasi sensitivitas model terhadap pola data historis, bukan ketidakstabilan proses pembelajaran. Perbedaan arah prediksi ini menegaskan adanya *trade-off* antara stabilitas prediksi dan responsivitas model terhadap perubahan tren harga saham.

Perlu ditekankan bahwa hasil peramalan 30 hari ke depan dalam penelitian ini bersifat eksperimental dan digunakan untuk mengevaluasi kemampuan model dalam mempelajari pola historis data. Prediksi yang dihasilkan tidak dimaksudkan sebagai rekomendasi investasi, mengingat pergerakan harga saham dipengaruhi oleh berbagai faktor eksternal yang tidak dimodelkan dalam penelitian ini. Selain itu, penggunaan pendekatan *recursive forecasting* berpotensi menyebabkan akumulasi kesalahan seiring bertambahnya *horizon* prediksi, sehingga hasil peramalan jangka menengah lebih tepat digunakan sebagai indikasi arah tren dibandingkan estimasi nilai harga absolut.

IV. KESIMPULAN

Penelitian ini membandingkan kinerja model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dalam memprediksi harga penutupan saham PT Bank Rakyat Indonesia (BBRI.JK) menggunakan data historis periode 2 November 2020 hingga 30 Oktober 2025. Hasil penelitian menunjukkan bahwa kedua model mampu mempelajari pola temporal data saham dan mengikuti tren pergerakan harga aktual dengan baik. Berdasarkan hasil evaluasi, model GRU menghasilkan nilai RMSE sebesar 90,14, MAPE sebesar 1,86%, dan MAE sebesar 68,89, sedangkan model LSTM menghasilkan RMSE sebesar 111,00, MAPE sebesar 2,37%, dan MAE sebesar 87,55. Nilai kesalahan yang lebih rendah pada seluruh metrik menunjukkan bahwa GRU memiliki akurasi prediksi yang lebih baik dibandingkan LSTM.

Akan tetapi dari sisi efisiensi komputasi, model LSTM menunjukkan kinerja yang lebih baik dibandingkan GRU. Model LSTM membutuhkan waktu pelatihan selama 343,57 detik dan mencapai kondisi konvergensi pada *epoch* ke-100 dengan jumlah parameter sebanyak 156,305. Di sisi lain, model GRU membutuhkan waktu pelatihan yang lebih lama, yaitu 471,98 detik, meskipun mencapai kondisi konvergensi pada *epoch* yang sama, dengan jumlah parameter yang lebih sedikit, yaitu 119.555. Hasil ini menunjukkan bahwa meskipun arsitektur GRU lebih sederhana dan memiliki kompleksitas parameter yang lebih rendah, pada konfigurasi dan lingkungan komputasi yang digunakan dalam penelitian ini, penyederhanaan arsitektur tersebut tidak secara langsung menghasilkan waktu pelatihan yang lebih cepat dibandingkan LSTM. Temuan ini mengindikasikan bahwa efisiensi komputasi tidak hanya dipengaruhi oleh jumlah parameter, tetapi juga oleh karakteristik implementasi model, dinamika proses pembelajaran, serta interaksi antara arsitektur model dan data yang digunakan.

Hasil uji signifikansi menggunakan Diebold–Mariano *Test* menunjukkan bahwa terdapat perbedaan akurasi prediksi yang signifikan secara statistik antara model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Nilai statistik DM sebesar 1,9949 dengan *p-value* 0,0461 ($< 0,05$) mengindikasikan bahwa hipotesis nol ditolak, sehingga perbedaan kinerja kedua model tidak terjadi secara kebetulan. Nilai statistik DM yang bernilai positif menunjukkan bahwa

model GRU menghasilkan nilai kesalahan prediksi yang lebih rendah dibandingkan model LSTM pada periode pengujian. Temuan ini selaras dengan hasil evaluasi menggunakan metrik RMSE, MAPE, dan MAE, di mana GRU secara konsisten menghasilkan nilai kesalahan yang lebih kecil. Dengan demikian, secara statistik dan empiris, model GRU terbukti memiliki performa prediksi yang lebih unggul dibandingkan LSTM dalam peramalan harga penutupan saham BBRI pada penelitian ini.

Sebagai pengembangan di masa mendatang, penelitian selanjutnya dapat mempertimbangkan penambahan variabel eksternal seperti volume perdagangan, indikator teknikal, indeks pasar, maupun sentimen berita keuangan untuk meningkatkan akurasi prediksi. Selain itu, eksplorasi model *hybrid* (CNN-LSTM, Attention-based RNN) atau optimasi *hyperparameter* dengan *Bayesian Optimization* atau *Optuna* metaheuristik juga dapat dilakukan guna memperoleh kinerja model yang lebih optimal.

DAFTAR PUSTAKA

- [1] E. Nurmutia, "KSEI: Investor Pasar Modal Indonesia Didominasi Milenial dan Gen Z," 2022. <https://www.liputan6.com/saham/read/5167129/ksei-investor-pasar-modal-indonesia-didominasi-milenial-dan-gen-z> (accessed Sep. 20, 2025).
- [2] A. Yunita *et al.*, "Performance analysis of neural network architectures for time series forecasting: A comparative study of RNN, LSTM, GRU, and hybrid models," *MethodsX*, vol. 15, p. 103462, Dec. 2025, doi: 10.1016/J.MEX.2025.103462.
- [3] S. Wu, "Predicting Stock Prices in the Electric Vehicle and Technology Sectors Using Long Short-Term Memory Models," *Adv. Econ. Manag. Polit. Sci.*, vol. 94, no. 1, pp. 148–156, Sep. 2024, doi: 10.54254/2754-1169/94/2024OX0183.
- [4] K. Kwanda, D. E. Herwindiati, M. D. Lauro, and K. K. C. Id, "Perbandingan LSTM dan Bidirectional LSTM pada Sistem Prediksi Harga Saham Berbasis Website," *Ranah Res. J. Multidiscip. Res. Dev.*, vol. 7, no. 1, pp. 26–35, Nov. 2024, doi: 10.38035/RRJ.V7I1.1255.
- [5] Y. Perdana, N. Raisa Hanum, A. Rabiula, and Y. Anzari, "Analisis Perbandingan Model Gru Dan Lstm Untuk Prediksi Harga Saham Bank Rakyat Indonesia," *J. Akad.*, vol. 17, no. 2, pp. 54–60, Jun. 2025, doi: 10.53564/AKADEMIKA.V17I2.1692.
- [6] K. Prayogi, W. Gata, and D. P. Kussanti, "Prediksi Harga Saham Bank Central Asia Menggunakan Algoritma Deep Learning GRU," *Jutisi J. Ilm. Tek. Inform. dan Sist. Inf.*, vol. 13, no. 1, pp. 647–658, May 2024, doi: 10.35889/JUTISI.V13I1.1910.
- [7] C. Li and G. Qian, "Stock Price Prediction Using a Frequency Decomposition Based GRU Transformer Neural Network," *Appl. Sci.* 2023, Vol. 13, Page 222, vol. 13, no. 1, p. 222, Dec. 2022, doi: 10.3390/AP13010222.
- [8] A. Nilsen, "Perbandingan Model RNN, Model LSTM, dan Model GRU dalam Memprediksi Harga Saham-Saham LQ45," *J. Stat. dan Apl.*, vol. 6, no. 1, pp. 137–147, 2022, doi: 10.21009/jsa.06113.
- [9] A. T. Haryono, R. Sarno, and K. R. Sungkono, "Stock price forecasting in Indonesia stock exchange using deep learning: a comparative study," *Int. J. Electr. Comput. Eng.*, vol. 14, no. 1, pp. 861–869, Feb. 2024, doi: 10.11591/ijece.v14i1.pp861-869.
- [10] M. Fahmi Julianto *et al.*, "Perbandingan Penerapan Algoritma Deep Learning Dalam Prediksi Harga Emas," *INTI Nusa Mandiri*, vol. 19, no. 1, pp. 71–76, Aug. 2024, doi: 10.33480/INTI.V19I1.5559.
- [11] Y. Prastyia, L. Pratama, and S. Zahara, "Prediksi Saham BBNi dan BBRI Menggunakan LSTM (Long Short Term Memory)," *SUBMIT J. Ilm. Teknol. Infomasi dan Sains*, vol. 4, no. 2, pp. 1–4,

- Dec. 2024, doi: 10.36815/SUBMIT.V4I2.3332.
- [12] F. A. El Hakim, A. Fariza, and S. Setiawardhana, "Pengembangan Analisis Teknikal Untuk Trading Bursa Saham dengan Long Short Term Memory," *J. MEDIA Inform. BUDIDARMA*, vol. 7, no. 3, p. 985, Jul. 2023, doi: 10.30865/MIB.V7I3.6410.
- [13] A. Laras, "Intip Kinerja Terbaru Bank-Bank Jumbo Penguasa Pasar RI," 2024. <https://finansial.bisnis.com/read/20241202/90/1820705/intip-kinerja-terbaru-bank-bank-jumbo-penguasa-pasar-ri?> Yahoo Finance. 2024. Bank Rakyat Indonesia (BBRI.JK) Stock Historical Data. From <https://finance.yahoo.com/>, diakses 16 September 2025. (accessed Sep. 20, 2025).
- [14] M. D. A. Carnegie and C. Chairani, "Perbandingan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) Untuk Memprediksi Curah Hujan," *J. MEDIA Inform. BUDIDARMA*, vol. 7, no. 3, p. 1022, Jul. 2023, doi: 10.30865/MIB.V7I3.6213.
- [15] F. N. Iman and D. Wulandari, "Prediksi Harga Saham Menggunakan Metode Long Short Term Memory," *Log. J. Ilmu Komput. dan Pendidik.*, vol. 1, no. 3, pp. 601–616, Apr. 2023, Accessed: Dec. 05, 2025. [Online]. Available: <https://journal.mediapublikasi.id/index.php/logic/article/view/1855>
- [16] D. Rathor and V. Rajpoot, "Stock Price Prediction Using LSTM and GRU," *www.irjmets.com @International Res. J. Mod. Eng.*, vol. 3839, doi: 10.56726/IRJMETS76910.
- [17] A. D. Huynh, T. K. Nguyen, A. D. Huynh, and T. K. Nguyen, "The Comparison of GRU and LSTM in Solar Power Generation Forecasting Application," *Int. J. Sci. Res. Arch.*, vol. 13, no. 1, pp. 1360–1370, Sep. 2024, doi: 10.30574/IJSRA.2024.13.1.1831.
- [18] C. S. Kudarihal, M. Gupta, and S. K. Gupta, "Time series analysis of AMI data and comparative energy demand forecasting using deep learning models in a smart grid scenario," *Eng. Res. Express*, vol. 7, no. 1, p. 015387, Mar. 2025, doi: 10.1088/2631-8695/adc350.
- [19] F. X. Diebold and R. S. Mariano, "Comparing predictive accuracy," *J. Bus. Econ. Stat.*, vol. 13, no. 3, pp. 253–263, 1995, doi: 10.1080/07350015.1995.10524599.