



# Pengembangan Sistem Prediksi Saham Menggunakan Model Hybrid Gated Recurrent Unit–Long Short-Term Memory Berbasis Integrasi Indikator Teknikal Konvensional

Fajar Hanggoro Dwi Aryanto, Rr. Hajar Puji Sejati, Fadil Indra Sanjaya\*

Fakultas Sains & Teknologi, Prodi Informatika, Universitas Teknologi Yogyakarta, Sleman, Indonesia

Email: <sup>1</sup>Hanggoro007@gmail.com, <sup>2</sup>hajarsejati@gmail.com, <sup>3</sup>fadil.indra@staff.uty.ac.id

Email Penulis Korespondensi: fadil.indra@staff.uty.ac.id

**Abstrak**—Prediksi harga saham merupakan aspek krusial dalam pengambilan keputusan investasi di pasar modal Indonesia. Penelitian ini bertujuan merancang arsitektur model *hybrid Gated Recurrent Unit–Long Short-Term Memory* (GRU–LSTM) yang diintegrasikan dengan indikator teknikal *Moving Average Convergence Divergence*, *Moving Average*, *Exponential Moving Average*, dan *Relative Strength Index* guna meningkatkan akurasi serta objektivitas prediksi. Selain itu, penelitian bertujuan mengoptimasi performa model melalui grid search dan mengimplementasikannya ke dalam aplikasi web berbasis Flask sebagai sistem pendukung keputusan bagi investor. Sistem dikembangkan menggunakan pendekatan *research and development* di Universitas Teknologi Yogyakarta. Data historis saham PT Bank Rakyat Indonesia (Persero) Tbk. (BBRI.JK) periode 2 Januari 2020 hingga 17 Oktober 2025 diambil melalui API Yahoo Finance sebagai dataset utama. Model dioptimasi untuk menentukan kombinasi hiperparameter terbaik. Evaluasi menggunakan metrik Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Hasil pengujian menunjukkan model mencapai MAE 0,0241, MSE 0,0012, RMSE 0,0346, dan MAPE 2,7%, yang mengindikasikan tingkat akurasi tinggi. Aplikasi web menyediakan fitur dashboard visualisasi interaktif, pengembangan model, serta dokumentasi edukasi. Temuan ini mengonfirmasi bahwa integrasi deep learning dengan indikator teknikal menjadi solusi efektif untuk analisis saham yang lebih terukur dan sistematis.

**Kata Kunci:** Prediksi Saham; GRU; LSTM; Hybrid GRU-LSTM; Analisis Teknikal

**Abstract**—Stock price prediction is a crucial aspect of investment decision-making in the Indonesian capital market. This study aims to design a hybrid Gated Recurrent Unit–Long Short-Term Memory (GRU–LSTM) model architecture integrated with technical indicators such as Moving Average Convergence Divergence, Moving Average, Exponential Moving Average, and Relative Strength Index to improve the accuracy and objectivity of predictions. Additionally, this study aims to optimize model performance through grid search and implement it into a Flask-based web application as a decision support system for investors. The system was developed using a research and development approach at the Yogyakarta University of Technology. Historical data on PT Bank Rakyat Indonesia (Persero) Tbk. (BBRI.JK) shares for the period from January 2, 2020, to October 17, 2025, was obtained through the Yahoo Finance API as the main dataset. The model was optimized to determine the best combination of hyperparameters. Evaluation was performed using the Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and Mean Absolute Percentage Error (MAPE) metrics. The test results show that the model achieved MAE 0.0241, MSE 0.0012, RMSE 0.0346, and MAPE 2.7%, indicating a high level of accuracy. The web application provides interactive visualization dashboard features, model development, and educational documentation. These findings confirm that the integration of deep learning with technical indicators is an effective solution for more measurable and systematic stock analysis.

**Keywords:** Stock Prediction; GRU; LSTM; Hybrid GRU-LSTM; Technical Analysis

## 1. PENDAHULUAN

Pasar modal Indonesia dalam dekade terakhir mengalami transformasi signifikan yang ditandai dengan pertumbuhan eksponensial jumlah investor domestik, peningkatan kapitalisasi pasar, dan diversifikasi instrumen investasi. Data dari Kustodian Sentral Efek Indonesia (KSEI) mencatat bahwa hingga kuartal ketiga tahun 2024, jumlah investor saham di Indonesia telah melampaui 15 juta akun, meningkat lebih dari 300% dibandingkan periode lima tahun sebelumnya. Pertumbuhan pesat ini tidak hanya mencerminkan meningkatnya literasi keuangan masyarakat, tetapi juga menunjukkan pergeseran paradigma investasi dari instrumen tradisional seperti properti dan emas menuju instrumen sekuritas yang menawarkan likuiditas dan potensi capital gain lebih dinamis. Di tengah gelombang demokratisasi investasi ini, saham-saham blue-chip seperti PT Bank Rakyat Indonesia (Persero) Tbk (BBRI.JK) tetap menjadi pilar portofolio banyak investor karena karakteristik fundamental yang kuat, likuiditas tinggi, dan historis pembayaran dividen yang konsisten. Saham perbankan, khususnya BBRI, sering dijadikan barometer kesehatan sektor finansial dan indikator sentimen pasar modal domestik.

Namun, kompleksitas dinamika pasar saham menciptakan tantangan analitis yang multidimensi bagi investor, baik pemula maupun berpengalaman. Volatilitas harga yang dipengaruhi oleh konvergensi faktor mikro dan makro—seperti kinerja kuartalan perusahaan, kebijakan moneter Bank Indonesia, fluktuasi nilai tukar rupiah, ketegangan geopolitik global, hingga tren investasi generasi muda—menuntut pendekatan analisis yang lebih canggih dan real-time. Dua sekolah analisis yang dominan, yaitu analisis fundamental dan teknikal, masing-masing memiliki keterbatasan operasional dalam konteks pasar Indonesia yang memiliki karakteristik unik. Analisis fundamental yang berfokus pada evaluasi laporan keuangan, prospek industri, dan manajemen perusahaan sering kali menghadapi kendala temporal karena jeda publikasi data kuartalan dan annual report (Agustina, 2021; Lestari, 2025). Sementara itu, analisis teknikal yang mengandalkan pola historis harga dan volume meskipun lebih responsif terhadap pergerakan jangka pendek, tetap rentan terhadap subjektivitas interpretasi dan bias psikologis trader (Dewi et al., 2025; Firdaus, 2021a).



Dalam ekosistem analisis teknikal kontemporer, tiga indikator utama telah menjadi standar praktik: Moving Average (MA) untuk identifikasi tren, Relative Strength Index (RSI) untuk deteksi kondisi jenuh beli/jual, dan Moving Average Convergence Divergence (MACD) untuk analisis momentum. Studi empiris oleh (Joshi, 2022) menunjukkan bahwa kombinasi ketiga indikator ini dapat meningkatkan akurasi sinyal perdagangan hingga 34% dibandingkan penggunaan indikator tunggal. Namun, implementasi manual analisis multimodal ini menuntut keahlian teknis yang mendalam, waktu analisis yang signifikan, dan konsistensi disiplin emosional—faktor-faktor yang sering kali tidak dimiliki investor retail dengan keterbatasan sumber daya. Disruptif teknologi finansial (fintech) dan revolusi kecerdasan buatan membuka frontier baru dalam otomatisasi analisis pasar melalui pendekatan komputasional yang menggabungkan keunggulan analisis teknikal tradisional dengan kapabilitas prediktif machine learning.

Di antara berbagai paradigma machine learning, deep learning untuk deret waktu (time series) telah membuktikan efektivitasnya dalam memodelkan kompleksitas non-linear dan dependensi temporal data finansial (Hwang et al., 2024). Arsitektur Long Short-Term Memory (LSTM) sebagai varian Recurrent Neural Network (RNN) secara khusus dirancang untuk mengatasi masalah vanishing gradient melalui mekanisme gate yang memungkinkan retensi memori jangka panjang—karakteristik krusial untuk mempelajari siklus pasar dan pola musiman (Luthfiansyah & Wasito, 2023). Varian yang lebih efisien secara komputasi, Gated Recurrent Unit (GRU), menawarkan performa komparatif dengan kompleksitas parameter lebih rendah, sehingga sesuai untuk implementasi real-time dengan sumber daya terbatas. Sinergi potensial antara kedua arsitektur ini dalam bentuk model hybrid GRU-LSTM belum banyak dieksplorasi dalam konteks prediksi harga saham Indonesia, khususnya dengan integrasi indikator teknikal sebagai feature engineering yang kontekstual.

Beberapa penelitian sejenis telah dilakukan untuk memprediksi harga saham menggunakan teknik deep learning. Misalnya, (Hwang et al., 2024) mengaplikasikan model LSTM tunggal untuk prediksi saham di pasar Korea Selatan, yang berhasil mencapai MAPE sekitar 3-5% tetapi terbatas pada data historis tanpa integrasi indikator teknikal tambahan. Sementara itu, (Luthfiansyah & Wasito, 2023) menggunakan GRU untuk saham di Indonesia, dengan fokus pada efisiensi komputasi, namun model tersebut tidak menggabungkan dengan LSTM untuk menangkap dependensi jangka panjang yang lebih kompleks. Penelitian lain oleh (Dewi et al., 2025) mengintegrasikan indikator teknikal seperti MA dan RSI dengan model RNN sederhana, tetapi tidak memanfaatkan arsitektur hybrid GRU-LSTM yang lebih canggih, sehingga akurasi prediksi masih rentan terhadap volatilitas tinggi di pasar emerging seperti Indonesia.

Meskipun penelitian-penelitian tersebut telah memberikan kontribusi signifikan, terdapat beberapa gap yang belum teratasi. Pertama, sebagian besar studi hanya menggunakan satu arsitektur RNN (baik LSTM atau GRU) tanpa mengintegrasikan keduanya dalam model hybrid, yang dapat mengakibatkan trade-off antara efisiensi dan kemampuan memori jangka panjang. Kedua, integrasi indikator teknikal seperti MACD, MA, EMA, dan RSI sering kali dilakukan secara parsial atau tidak optimal sebagai fitur input, sehingga model kurang mampu menangkap momentum pasar secara komprehensif. Ketiga, sedikit penelitian yang mengembangkan sistem berbasis web interaktif untuk investor retail di Indonesia, di mana aspek usability dan edukasi sering diabaikan. Perbedaan utama penelitian ini adalah pengembangan model hybrid GRU-LSTM yang terintegrasi penuh dengan indikator teknikal tersebut, diimplementasikan dalam aplikasi web Flask untuk meningkatkan aksesibilitas dan objektivitas analisis saham.

Tujuan penelitian ini adalah untuk mengembangkan aplikasi web prediksi harga saham yang mengintegrasikan model hybrid GRU-LSTM dengan analisis teknikal konvensional (MA, EMA, MACD, dan RSI) guna meningkatkan akurasi dan objektivitas prediksi. Secara spesifik, penelitian ini bertujuan: (1) membangun dan mengoptimalkan arsitektur model hybrid menggunakan data historis saham BBRIJK dari 2 Januari 2020 hingga 17 Oktober 2025; (2) mengevaluasi performa model dengan metrik MAE, MSE, RMSE, dan MAPE; (3) mengimplementasikan model dalam aplikasi web dengan fitur dashboard interaktif, training model, dan edukasi pengguna; serta (4) menganalisis efektivitas integrasi deep learning dengan indikator teknikal untuk analisis saham yang lebih terukur dan sistematis.

Penelitian ini hadir untuk menjawab celah akademis dan praktis tersebut dengan merancang sistem prediksi harga saham berbasis web yang mengintegrasikan model hybrid GRU-LSTM dengan indikator teknikal MA, RSI, dan MACD. Kerangka kerja yang diusulkan tidak hanya berfokus pada aspek pemodelan prediktif, tetapi juga pada dimensi usability melalui pengembangan aplikasi web interaktif menggunakan framework Flask. Dataset utama penelitian adalah data historis saham BBRIJK periode 2 Januari 2020 hingga 17 Oktober 2025 yang mencakup fase-fase pasar krusial seperti pandemi COVID-19, pemulihan ekonomi, dan ketidakpastian moneter global. Horizon prediksi ditetapkan 10 hari ke depan dengan target variabel harga penutupan (close price). Validasi model menggunakan metrik MAE, MSE, RMSE, dan MAPE untuk mengkuantifikasi error prediksi secara komprehensif.


Signifikansi penelitian ini bersifat dualistik: secara teoretis, penelitian berkontribusi pada pengembangan arsitektur hybrid yang mengoptimalkan trade-off antara akurasi dan efisiensi komputasional dalam pemodelan deret waktu finansial; secara praktis, penelitian menghasilkan prototipe aplikasi web yang dapat berfungsi sebagai decision support system bagi investor Indonesia. Dengan demokratisasi akses terhadap analisis prediktif canggih, sistem ini diharapkan dapat mengurangi asimetri informasi antara investor institusional dan retail, sekaligus berperan sebagai platform edukasi investasi berbasis data yang mendukung program literasi keuangan Otoritas Jasa Keuangan (OJK). Pada akhirnya, penelitian ini tidak hanya sekedar eksperimen teknikal, tetapi bagian dari upaya sistematis untuk mentransformasi budaya investasi Indonesia menuju paradigma yang lebih rasional, terdata, dan terinformasi.

## 2. METODOLOGI PENELITIAN

### 2.1 Kerangka Dasar Penelitian

Kerangka penelitian yang disusun secara sistematis untuk memandu seluruh proses pengembangan sistem prediksi harga saham, mulai dari identifikasi masalah hingga implementasi aplikasi web, secara visual dapat dilihat pada Gambar 1. Tahapan pertama dalam kerangka tersebut diawali dengan pengumpulan data historis saham BBRIJK dari platform Yahoo Finance melalui library yfinance. Data yang telah terkumpul kemudian masuk ke tahap pra-pemrosesan yang meliputi penanganan missing value, normalisasi, dan pembentukan time series window untuk menyiapkan input yang sesuai bagi model. Seiring dengan perancangan sistem, dilakukan ekstraksi fitur teknikal berupa indikator Moving Average (MA), Moving Average Convergence Divergence (MACD), dan Relative Strength Index (RSI) yang diintegrasikan sebagai variabel tambahan untuk memperkaya informasi temporal.

Setelah data siap, proses berlanjut pada pembangunan arsitektur model hybrid yang menggabungkan lapisan GRU dan LSTM. Model ini melalui tahap pelatihan dengan konfigurasi hyperparameter yang dioptimasi secara mendalam menggunakan teknik grid search. Performa dari model tersebut kemudian dievaluasi menggunakan metrik kesalahan prediksi seperti MAE, MSE, RMSE, dan MAPE, di mana hasil evaluasi digunakan untuk menyesuaikan kembali arsitektur guna meningkatkan akurasi. Tahap akhir dari kerangka pada Gambar 1 adalah implementasi model ke dalam sistem aplikasi web berbasis Flask. Seluruh rangkaian proses ini memastikan bahwa sistem yang dihasilkan tidak hanya fokus pada pemodelan, tetapi juga pada aspek fungsionalitas sebagai alat bantu keputusan investasi yang interaktif dan responsif bagi pengguna



Gambar 1. Kerangka Dasar Penelitian

### 2.2 Tahapan Penelitian

Tahapan penelitian ini disusun secara sistematis untuk memandu seluruh proses pengembangan sistem prediksi harga saham, mulai dari identifikasi masalah hingga implementasi aplikasi web. Proses dimulai dengan pengumpulan data historis saham BBRIJK dari platform Yahoo Finance menggunakan library yfinance. Data tersebut kemudian melalui proses pra-pemrosesan yang meliputi penanganan missing value, normalisasi, dan pembentukan time series window untuk mempersiapkan input yang sesuai bagi model.

Selanjutnya, dilakukan ekstraksi fitur teknikal berupa indikator Moving Average (MA), Moving Average Convergence Divergence (MACD), Exponential Moving Average (EMA) dan Relative Strength Index (RSI) yang dihitung berdasarkan data harga harian. Fitur-fitur ini diintegrasikan ke dalam dataset sebagai variabel tambahan untuk memperkaya informasi temporal. Tahap berikutnya adalah membangun arsitektur model hybrid yang menggabungkan lapisan GRU dan LSTM. Model tersebut dilatih menggunakan data latih dengan konfigurasi hyperparameter yang dioptimasi melalui teknik grid search.

Performa model dievaluasi menggunakan metrik kesalahan prediksi seperti MAE, MSE, RMSE, dan MAPE. Hasil evaluasi ini digunakan sebagai dasar untuk menyesuaikan arsitektur dan parameter guna meningkatkan akurasi prediksi secara berkelanjutan. Tahap akhir adalah implementasi model yang telah dilatih ke dalam aplikasi web berbasis Flask, yang memungkinkan pengguna mengakses prediksi melalui antarmuka yang interaktif dan responsif. Seluruh rangkaian tahapan ini, sebagaimana diilustrasikan pada Gambar 1, memastikan sistem tidak hanya unggul dalam pemodelan tetapi juga fungsional sebagai alat bantu keputusan investasi.

### 2.3 GRU

GRU atau *Gated Recurrent Unit* merupakan varian dari jaringan saraf berulang (*Recurrent Neural Network/RNN*) yang dikembangkan untuk mengatasi masalah *vanishing gradient* yang sering kali menghambat kemampuan RNN konvensional dalam mempelajari dependensi jangka panjang (Pirani et al., 2022; Silalahi & Muljono, 2024; Zhang & Yan, 2025). Berbeda dengan LSTM yang memiliki tiga gerbang (*gate*), GRU dirancang dengan struktur yang lebih sederhana yang hanya terdiri atas dua gerbang, yaitu *update gate* dan *reset gate*. *Update gate* berfungsi untuk mengontrol seberapa banyak informasi dari keadaan sebelumnya yang akan dipertahankan, sementara *reset gate* menentukan seberapa banyak informasi masa lalu yang perlu diabaikan. Karena kompleksitas arsitekturnya yang lebih rendah, GRU umumnya memiliki parameter yang lebih sedikit, sehingga lebih efisien secara komputasi dan lebih cepat dalam proses pelatihan dibandingkan dengan LSTM. Meskipun demikian, GRU tetap mampu menangkap pola temporal yang signifikan dalam data deret waktu, sehingga sering digunakan dalam aplikasi prediksi yang memerlukan kecepatan dan efisiensi sumber daya (Ghudafa Taufik Akbar et al., 2022; Silalahi & Muljono, 2024; Supriatna & Anggai, 2025a).



## 2.4 LSTM

LSTM atau Long Short-Term Memory adalah salah satu jenis RNN yang secara khusus dirancang untuk mengatasi keterbatasan RNN standar dalam menangani dependensi jangka panjang melalui mekanisme memory cell dan sistem gerbang yang kompleks. Arsitektur LSTM terdiri atas tiga gerbang utama, yaitu *input gate*, *forget gate*, dan *output gate*, yang masing-masing berfungsi untuk mengatur aliran informasi ke, dari dan di dalam *memory cell*. *Forget gate* memutuskan informasi mana dari keadaan sebelumnya yang perlu dihapus, *input gate* mengontrol informasi baru yang akan disimpan, dan *output gate* menentukan informasi yang akan diteruskan ke langkah waktu berikutnya (Hariyanti et al., 2025; Silalahi & Muljono, 2024; Supriatna & Anggai, 2025b). Mekanisme ini memungkinkan LSTM untuk secara selektif menyimpan dan mengakses informasi dalam rentang waktu yang panjang, sehingga sangat efektif untuk pemodelan data sekuensial dengan pola kompleks dan dependensi temporal yang jauh. Dalam konteks prediksi harga saham, LSTM mampu mengenali pola pergerakan harga yang dipengaruhi oleh faktor historis jangka panjang, menjadikannya pilihan yang kuat untuk analisis deret waktu finansial (Kwanda et al., 2024; Wang, 2025; Yu, 2025a, 2025b).

## 2.5 Model Hybrid GRU–LSTM

Model Hybrid GRU–LSTM merupakan integrasi dari dua arsitektur jaringan saraf berulang, yaitu GRU dan LSTM, yang digabungkan secara berurutan untuk memanfaatkan keunggulan masing-masing dalam satu kerangka pemodelan yang kohesif (Hariyanti et al., 2025). Pada model ini, lapisan GRU umumnya diletakkan di bagian awal untuk mengekstraksi pola jangka pendek dan menengah dari data sekuensial dengan efisiensi komputasi yang tinggi, sementara lapisan LSTM diposisikan setelahnya untuk menangkap dependensi jangka panjang dan menyimpan informasi penting yang relevan dengan konteks temporal yang lebih luas. Pendekatan hybrid ini tidak hanya menggabungkan kecepatan pelatihan dari GRU dan kemampuan memori dari LSTM, tetapi juga dapat mengurangi risiko *overfitting* melalui diversifikasi mekanisme pembelajaran temporal.

## 2.6 Indikator Teknikal

### 2.6.1 MA (Moving Average)

Moving Average (MA) merupakan salah satu indikator teknikal paling mendasar yang digunakan untuk mengidentifikasi arah tren dengan cara menghaluskan fluktuasi harga jangka pendek (Hyndman, 2025). MA dihitung dengan merata-ratakan harga penutupan saham dalam suatu periode waktu tertentu (Hyndman, 2025). Dalam penelitian ini, digunakan dua jenis MA yaitu Simple Moving Average (SMA) 20 hari dan SMA 50 hari, yang masing-masing merepresentasikan tren jangka menengah dan panjang. Rumus perhitungan SMA dapat dilihat pada persamaan berikut:

$$MA = \frac{(A1+A2+A3+\dots+An)}{n} \quad (1)$$

Di mana A adalah harga penutupan pada hari pertama dan n adalah jumlah periode. MA 20 hari memberikan sinyal tren yang lebih responsif terhadap pergerakan harga terkini, sedangkan MA 50 hari cenderung lebih stabil dan kurang terpengaruh oleh fluktuasi harian. Dengan membandingkan kedua MA ini, dapat diidentifikasi potensi perpotongan (*crossover*) yang sering dianggap sebagai sinyal perubahan tren oleh para analis teknikal.

### 2.6.2 EMA (Exponential Moving Average)

Exponential Moving Average (EMA) merupakan pengembangan dari MA yang memberikan bobot lebih besar pada data harga terbaru. Hal ini membuat EMA lebih responsif terhadap perubahan harga terkini dibandingkan dengan SMA. EMA dihitung dengan menggunakan formula *rekursif* yang memberikan faktor pembobotan (*smoothing factor*) terhadap data historis (Morales-Brotons et al., 2024). Rumus umum EMA adalah sebagai berikut:

$$EMA_t = (Hargat \times k) + (EMA_{t-1} \times (1 - k)) \quad (2)$$

$$k = \frac{2}{n+1} \quad (3)$$

Dimana  $P_t$  adalah harga pada waktu  $t$ ,  $EMA_{t-1}$  adalah nilai EMA sebelumnya, dan  $k$  adalah faktor *smoothing* yang dengan n adalah periode EMA. Dalam penelitian ini, EMA digunakan sebagai komponen dalam perhitungan MACD, yaitu dengan periode 12 hari dan 26 hari. Responsivitas EMA terhadap perubahan harga membuatnya sangat efektif untuk mendeteksi pergeseran momentum dalam waktu yang relatif singkat.

### 2.6.3 MACD (Moving Average Convergence Divergence)

Moving Average Convergence Divergence (MACD) adalah indikator momentum yang digunakan untuk mengidentifikasi perubahan kekuatan, arah, momentum, dan durasi suatu tren (Joshi, 2022). MACD dihitung dengan mengurangkan EMA 26 hari dari EMA 12 hari, yang menghasilkan garis MACD. Selanjutnya, garis sinyal (signal line) dihitung dari EMA 9 hari dari garis MACD tersebut. Rumus perhitungan MACD dapat dinyatakan sebagai berikut:

$$MACD = EMA12 - EMA26 \quad (4)$$



$$Signal\ Line = EMA\ 9\ (MACD) \tag{5}$$

Selisih antara garis MACD dan garis sinyal menghasilkan histogram MACD, yang menggambarkan konvergensi atau divergensi antara kedua garis tersebut. Jika garis MACD berada di atas garis sinyal, hal ini mengindikasikan momentum *bullish*, sedangkan posisi di bawah garis sinyal mengindikasikan momentum *bearish*. Dalam penelitian ini, nilai MACD dan garis sinyalnya diintegrasikan sebagai dua fitur terpisah untuk memberikan informasi yang lebih detail mengenai dinamika momentum harga.

### 2.6.4 RSI (Relative Strength Index)

*Relative Strength Index* (RSI) pertama kali diperkenalkan oleh J. Welles Wilder pada tahun 1978 sebagai indikator teknikal yang mengukur momentum pergerakan harga dengan rentang nilai 0 hingga 100%. RSI dikategorikan sebagai momentum *oscillator* atau *Price Momentum Indicator* yang membantu trader mengidentifikasi kondisi *overbought* (jenuh beli) dan *oversold* (jenuh jual) di pasar. Indikator ini menghitung kecepatan dan perubahan harga berdasarkan rata-rata kenaikan (gain) dan penurunan (loss) dalam periode tertentu, biasanya 14 hari (Firdaus, 2021b). Rumus RSI adalah sebagai berikut:

$$RSI = 100 - \frac{100}{1+RS} \tag{6}$$

$$RS = \frac{Rata-rata\ Gain}{Rata-rata\ Loss} \tag{7}$$

Nilai RSI di atas 70 umumnya dianggap sebagai kondisi *overbought*, sedangkan nilai di bawah 30 mengindikasikan kondisi *oversold*. Dalam penelitian ini, RSI dihitung dengan periode 14 hari dan dijadikan sebagai salah satu fitur input model. Dengan menyertakan RSI, model diharapkan dapat mengenali pola pergerakan harga yang terkait dengan kondisi psikologis pasar, sehingga prediksi yang dihasilkan lebih mencerminkan realitas dinamika trading.

## 3. HASIL DAN PEMBAHASAN

### 3.1 Dataset

Dataset yang digunakan dalam penelitian ini adalah data historis saham PT Bank Rakyat Indonesia (Persero) Tbk. (BBRI.JK) yang diperoleh dari Yahoo Finance melalui API publik. Rentang waktu data mencakup periode lima tahun, mulai tanggal 2 Januari 2020 hingga 17 Oktober 2025, sehingga mencerminkan dinamika pasar yang cukup panjang termasuk periode fluktuasi ekonomi. Data harian yang dikumpulkan meliputi harga pembukaan (Open), harga tertinggi (High), harga terendah (Low), harga penutupan (Close), dan volume perdagangan (Volume). Pemilihan saham BBRI didasarkan pada perannya sebagai saham blue-chip yang sering dijadikan acuan oleh investor di Bursa Efek Indonesia (Dandi & Kurniawan, 2025).

Sebelum digunakan untuk pemodelan, data mentah mengalami tahap pra-pemrosesan untuk memastikan kualitas dan kesiapan input. Tahapan tersebut meliputi pemeriksaan kelengkapan data, transformasi format tanggal, serta normalisasi nilai numerik menggunakan metode Min-Max Scaling ke dalam rentang [0,1]. Normalisasi dilakukan untuk menghindari dominasi fitur dengan skala besar dan mempercepat konvergensi selama pelatihan model. Selain itu, data deret waktu kemudian dibentuk menjadi sekuensial melalui pendekatan sliding window dengan panjang window tertentu, sehingga setiap sampel input merepresentasikan pola harga dalam periode historis yang telah ditetapkan. Proses ini menghasilkan struktur data tiga dimensi [samples, time steps, features] yang sesuai untuk pemrosesan oleh model GRU dan LSTM.

**Tabel 1.** Sample Dataset


Date	Open	High	Low	Close	Volume
2020-01-02	2954.129281	2960.843262	2927.273780	2960.843506	45886302
2020-01-03	2967.557129	2980.985090	2947.415367	2967.557129	91189705
2020-01-06	2927.274055	2947.415820	2900.418067	2933.987793	48648450
2020-01-07	2960.843375	2960.843375	2940.701613	2954.129395	114344885
2020-01-08	2940.701416	2954.129196	2913.845917	2940.701660	188929583
...	...	...	...	...	...
2025-10-13	3680.0	3710.0	3660.0	3660.0	181694400
2025-10-14	3640.0	3690.0	3550.0	3550.0	278639100
2025-10-15	3570.0	3590.0	3450.0	3500.0	468733500
2025-10-16	3500.0	3580.0	3480.0	3530.0	227629500
2025-10-17	3530.0	3570.0	3490.0	3500.0	244442400

Tabel 1 menunjukkan sampel dari dataset yang digunakan dalam penelitian ini, yang mencakup data harian saham BBRI.JK dari periode awal Januari 2020. Kolom-kolom dalam Tabel 1 meliputi *Date* (tanggal perdagangan), *Open* (harga pembukaan pada hari tersebut), *High* (harga tertinggi yang dicapai selama sesi perdagangan), *Low* (harga

terendah selama sesi), *Close* (harga penutupan pada akhir hari), *Adj Close* (harga penutupan yang telah disesuaikan untuk dividen, stock split, atau faktor lain), dan *Volume* (jumlah saham yang diperdagangkan pada hari itu). Sampel ini diambil dari lima hari perdagangan pertama yang tersedia setelah 2 Januari 2020 (mengingat kemungkinan libur pasar pada tanggal tersebut) dan 5 hari terakhir hingga tanggal 17 Oktober 2025 untuk mengilustrasikan struktur data mentah sebelum melalui proses pra-pemrosesan seperti normalisasi dan pembentukan window time series. Data dalam Tabel 1 menunjukkan fluktuasi harga tipikal di pasar saham, dengan volume perdagangan yang bervariasi, yang nantinya akan digunakan untuk menghitung indikator teknikal seperti Moving Average (MA), Exponential Moving Average (EMA), Moving Average Convergence Divergence (MACD), dan Relative Strength Index (RSI) sebagaimana dijelaskan dalam subbagian Indikator Teknikal berikutnya. Penggunaan data ini memastikan bahwa model hybrid GRU-LSTM dapat mempelajari pola temporal dari data historis yang representatif, sehingga meningkatkan akurasi prediksi harga saham.

### 3.2 Arsitektur Model

Perancangan model prediktif dalam penelitian ini menggunakan pendekatan hibrida yang menggabungkan berbagai lapisan jaringan saraf tiruan untuk mengekstraksi fitur deret waktu secara optimal. Struktur mendetail mengenai susunan lapisan, aliran data, dan konfigurasi unit dalam model tersebut diilustrasikan secara komprehensif pada Gambar 2.



**Gambar 2.** Arsitektur GRU-LSTM

Model yang diusulkan dalam penelitian ini merupakan arsitektur hybrid yang mengintegrasikan dua varian Recurrent Neural Network (RNN), yaitu Gated Recurrent Unit (GRU) dan Long Short-Term Memory (LSTM). Pemilihan pendekatan hybrid didasarkan pada pertimbangan komplementaritas kedua arsitektur; GRU dikenal efisien secara komputasi dengan struktur gerbang yang lebih sederhana, sedangkan LSTM memiliki kemampuan memori jangka panjang yang lebih kuat melalui mekanisme gerbang dan sel memori yang kompleks. Dengan menggabungkan keduanya, diharapkan model dapat menangkap pola temporal baik dalam jangka pendek maupun panjang secara lebih optimal.

Berdasarkan alur yang disajikan pada gambar 2, model ini mengintegrasikan dua varian Recurrent Neural Network (RNN), yaitu Gated Recurrent Unit (GRU) dan Long Short-Term Memory (LSTM), untuk memanfaatkan keunggulan masing-masing arsitektur. Proses dimulai dari tahap preprocessing data yang kemudian diumpankan melalui input layer menuju lapisan pertama, yaitu GRU layer. Pada lapisan ini, terdapat 96 unit GRU yang berfungsi sebagai ekstraktor fitur awal untuk menangkap pola temporal jangka pendek dan menengah dengan efisiensi komputasi yang tinggi.

Selanjutnya, sebagaimana terlihat pada gambar 2, output dari lapisan GRU diteruskan ke lapisan LSTM yang terdiri dari 32 unit untuk memproses dependensi jangka panjang dan menyimpan informasi penting dalam konteks temporal yang lebih luas. Untuk mencegah terjadinya overfitting, model menerapkan teknik dropout sebesar 0,2 pada setiap lapisan secara bertahap. Setelah melalui pemrosesan rekurens, data dilewatkan ke lapisan fully connected (Dense) dengan 24 unit untuk melakukan transformasi non-linear sebelum akhirnya mencapai output layer. Seluruh integrasi komponen dalam Gambar 2 dibangun menggunakan framework TensorFlow dan Keras, di mana proses pelatihan dioptimasi menggunakan optimizer Adam dan fungsi loss Mean Squared Error (MSE).

### 3.3 Tuning Model

Proses pengujian model dilakukan secara sistematis untuk mengevaluasi performa arsitektur *hybrid* GRU-LSTM melalui optimasi *hyperparameter*. Tahap *tuning* ini dilaksanakan sebanyak 50 kali percobaan (*trials*) menggunakan metode *grid search* dengan tujuan utama meminimalkan nilai *loss*. Perbandingan hasil dari berbagai kombinasi parameter yang diuji untuk mengamati pengaruhnya terhadap kinerja model disajikan secara mendalam pada tabel 2.

**Tabel 2.** Hasil Tuning Hiperparameter Terbaik Model Hybrid GRU-LSTM

Loss	GRU_Units	LSTM_Units	Dense_Units	Dropout_1	Dropout_2	Dropout_3	Learning_Rate
0.001561	96	48	24	0.2	0.1	0.15	0.006154
0.001786	32	48	16	0.3	0.2	0.10	0.005891
0.002238	64	48	16	0.4	0.1	0.05	0.002320
0.002414	32	48	32	0.1	0.4	0.10	0.001173
0.002689	64	16	8	0.3	0.1	0.10	0.003900

Berdasarkan data pada Tabel 2, dapat dianalisis bahwa variasi jumlah unit pada lapisan GRU, LSTM, dan *Dense* memberikan dampak langsung terhadap nilai *loss* yang dihasilkan. Konfigurasi dengan nilai *loss* terendah setelah pengaturan optimal dicapai pada percobaan dengan 96 unit GRU dan 48 unit LSTM yang menghasilkan skor 0,001561. Sebaliknya, data pada Tabel 2 menunjukkan bahwa nilai *loss* tertinggi sebesar 0,002689 terjadi ketika jumlah unit LSTM dikurangi menjadi 16 dan unit *Dense* menjadi 8. Hal ini mengonfirmasi bahwa kompleksitas model yang tidak memadai dapat menghambat kemampuan sistem dalam menangkap pola temporal yang rumit.

Melalui informasi yang tertera pada gambar 3, dapat diketahui bahwa konfigurasi terbaik (*Best Score*) mencapai nilai 0,0011405, yang menunjukkan kemampuan model dalam merepresentasikan pola data dengan tingkat kesalahan yang sangat rendah. Konfigurasi optimal tersebut, sebagaimana dirinci dalam gambar 3, terdiri atas penggunaan 96 unit GRU, 32 unit LSTM, dan 24 unit pada lapisan *Dense*. Selain itu, laporan pada gambar 3 menunjukkan nilai *dropout* yang konsisten sebesar 0,2 pada tiga lapisan berbeda untuk menjaga stabilitas model. Penggunaan *learning rate* sebesar 0,002907 juga terbukti paling efektif karena mampu mempercepat konvergensi tanpa menyebabkan terjadinya *overfit* selama proses pembelajaran.

```
FINAL SUMMARY REPORT:
=====
Ticker           : BBRI.JK
Total_Trials     : 50
Best_Trial_ID    : 1
Best_Score       : 0.0011404769029468298
Best_GRU_Units   : 96
Best_LSTM_Units  : 32
Best_Dense_Units : 24
Best_Dropout_1   : 0.2
Best_Dropout_2   : 0.2
Best_Dropout_3   : 0.2
Best_Learning_Rate : 0.002907389302816031
Final_MSE        : 30328.78410009101
Final_MAE        : 123.75880926983173
Final_MAPE       : 3.2854594604080356
Final_Accuracy   : 96.71454053959197
```

Gambar 3. Model Terbaik Hasil Grid Search

### 3.4 Pengujian Model

Hasil pengujian model terhadap data aktual saham BBRI.JK selama periode 13 hingga 24 Oktober 2025, seperti yang disajikan pada Tabel 3, memberikan gambaran nyata mengenai kinerja prediktif model hybrid GRU-LSTM. Secara kuantitatif, model menghasilkan prediksi dengan tingkat kesalahan (*error*) yang bervariasi, mulai dari -225 hingga +382 poin. Pola kesalahan menunjukkan bahwa pada lima hari pertama (13–17 Oktober 2025), model secara konsisten menghasilkan *overprediction* (kesalahan positif), dengan puncak kesalahan tertinggi pada tanggal 15 Oktober 2025 sebesar +382 poin. Sementara itu, pada lima hari berikutnya (20–24 Oktober 2025), model beralih menjadi *underprediction* (kesalahan negatif), dengan kesalahan terbesar pada tanggal 23 Oktober 2025 sebesar -225 poin.

Fenomena peralihan dari *overprediction* ke *underprediction* ini dapat diduga terkait dengan kemampuan model dalam merespons perubahan tren pasar yang terjadi di sekitar pertengahan periode pengujian. Data harga aktual menunjukkan penurunan dari 3660 (13 Oktober) menjadi 3500 (17 Oktober), namun model masih mempertahankan prediksi pada level yang lebih tinggi (sekitar 3668–3882). Kemudian, ketika harga aktual mulai mengalami pemulihan pada 20 Oktober (3680) dan terus meningkat, model justru memprediksi tren penurunan (sekitar 3583–3630). Pola ini mengindikasikan bahwa meskipun model mampu menangkap fluktuasi jangka pendek, responsnya terhadap perubahan tren jangka menengah (*trend reversal*) masih memiliki *lag* atau keterlambatan.

Secara umum, rata-rata *absolute error* dari sepuluh prediksi adalah sebesar 154,7 poin. Jika dikonversi ke dalam persentase terhadap harga rata-rata aktual (~3635), maka rata-rata kesalahan absolutnya sekitar 4,25%. Angka ini sedikit lebih tinggi dibandingkan hasil pengujian awal dengan data *dummy* (MAPE 2,7%), yang dapat disebabkan oleh kompleksitas dan volatilitas data riil yang lebih tinggi, serta kemungkinan adanya faktor eksternal (seperti sentimen pasar atau berita) yang tidak sepenuhnya tertangkap oleh fitur teknikal dan historis yang digunakan.

Meskipun terdapat deviasi, pola prediksi secara keseluruhan masih menunjukkan korelasi dengan pergerakan harga aktual. Model berhasil mendeteksi rentang fluktuasi harga dan memberikan sinyal arah pergerakan yang pada beberapa titik sesuai (misalnya prediksi penurunan setelah 20 Oktober sejalan dengan penurunan harga aktual pada 21–22 Oktober). Hasil ini mengonfirmasi bahwa integrasi indikator teknikal (MACD, MA, RSI) ke dalam model GRU-LSTM dapat memberikan informasi momentum dan tren yang bermanfaat untuk prediksi, namun masih diperlukan penyempurnaan lebih lanjut untuk meningkatkan ketepatan timing dan besaran prediksi, terutama dalam merespons peralihan tren.

Dari perspektif aplikasi, hasil prediksi yang ditampilkan pada antarmuka web (seperti yang dapat divisualisasikan pada halaman dashboard) dapat menjadi bahan pertimbangan tambahan bagi investor. Adanya informasi *error* yang transparan seperti pada tabel 3 juga memungkinkan pengguna untuk memahami tingkat ketidakpastian dari prediksi yang diberikan. Dengan demikian, sistem ini tidak hanya menyajikan angka prediksi, tetapi juga konteks evaluatif yang penting dalam pengambilan keputusan investasi yang berhati-hati.

**Tabel 3.** Pengujian Model

Tanggal	Harga Asli	Harga Prediksi	Error
2025-10-13	3660	3682	+82
2025-10-14	3550	3687	+137
2025-10-15	3500	3882	+382
2025-10-16	3530	3668	+138
2025-10-17	3500	3653	+153
2025-10-20	3680	3630	-50
2025-10-21	3760	3620	-140
2025-10-22	3700	3607	-93
2025-10-23	3820	3595	-225
2025-10-24	3750	3583	-167

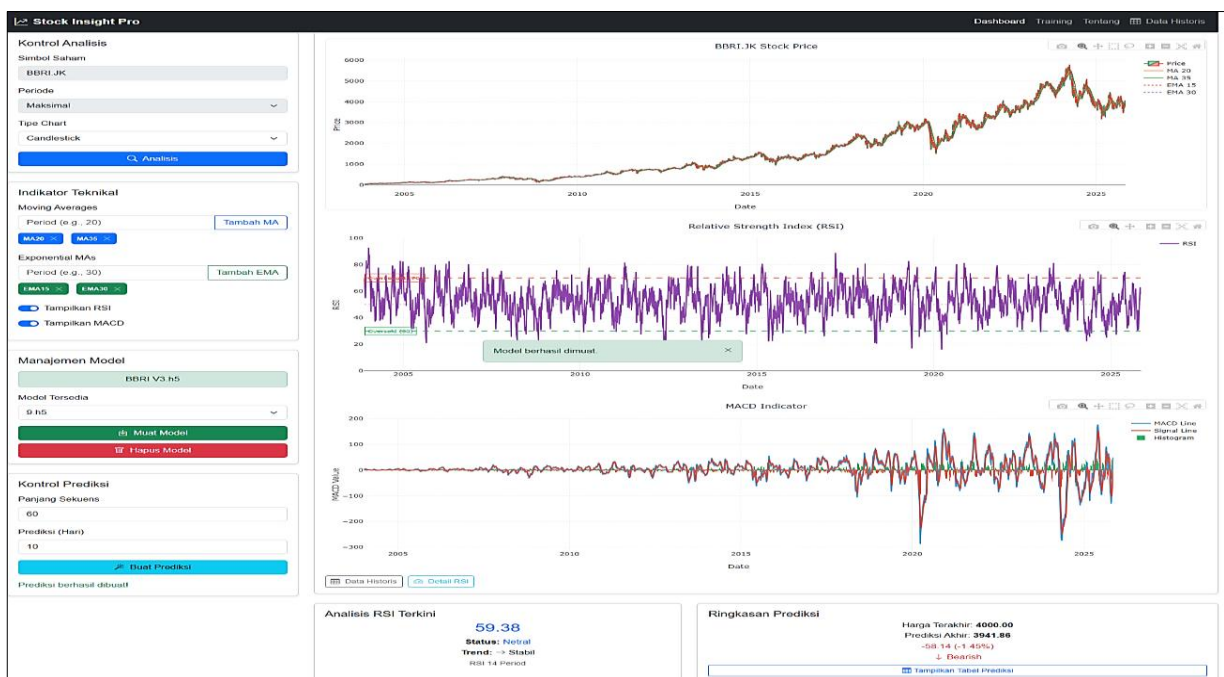
Berdasarkan data pada Tabel 3, model menghasilkan prediksi dengan tingkat kesalahan (error) yang bervariasi antara -225 hingga +382 poin. Analisis terhadap Tabel 3 menunjukkan pola overprediction pada lima hari pertama (13–17 Oktober 2025), di mana puncak kesalahan tertinggi terjadi pada tanggal 15 Oktober 2025 sebesar +382 poin. Sebaliknya, data pada Tabel 3 di periode lima hari berikutnya menunjukkan pergeseran menjadi underprediction, dengan kesalahan negatif terbesar pada tanggal 23 Oktober 2025 sebesar -225 poin. Secara keseluruhan, rata-rata kesalahan absolut dari sepuluh titik data pada Tabel 3 adalah sebesar 154,7 poin atau sekitar 4,25% dari harga rata-rata aktual. Meskipun terdapat deviasi, hasil pada tabel 3 mengonfirmasi bahwa integrasi indikator teknikal tetap mampu memberikan sinyal arah pergerakan yang bermanfaat.

### 3.5 Tampilan Halaman

Antarmuka pengguna dikembangkan dengan pendekatan responsive design yang memastikan kompatibilitas optimal pada berbagai perangkat, mulai dari desktop hingga perangkat mobile. Sistem ini terdiri dari tiga halaman utama yang saling terintegrasi: Dashboard, Halaman Training, dan Halaman Tentang, dengan navigasi yang konsisten melalui menu header untuk memfasilitasi pengalaman pengguna yang intuitif. Implementasi RESTful API menghubungkan frontend dengan backend, memungkinkan pertukaran data real-time tanpa perlu reload halaman secara keseluruhan, sehingga menciptakan pengalaman single-page application yang dinamis dan responsif.

#### 3.5.1 Halaman Dashboard

Halaman Dashboard yang ditampilkan pada Gambar 4 dirancang khusus untuk memudahkan pengguna dalam menggunakan fitur analisis dan prediksi yang disediakan. Halaman Dashboard berfungsi sebagai pusat kontrol utama sistem yang menyediakan akses terpadu untuk analisis saham dan visualisasi prediksi.



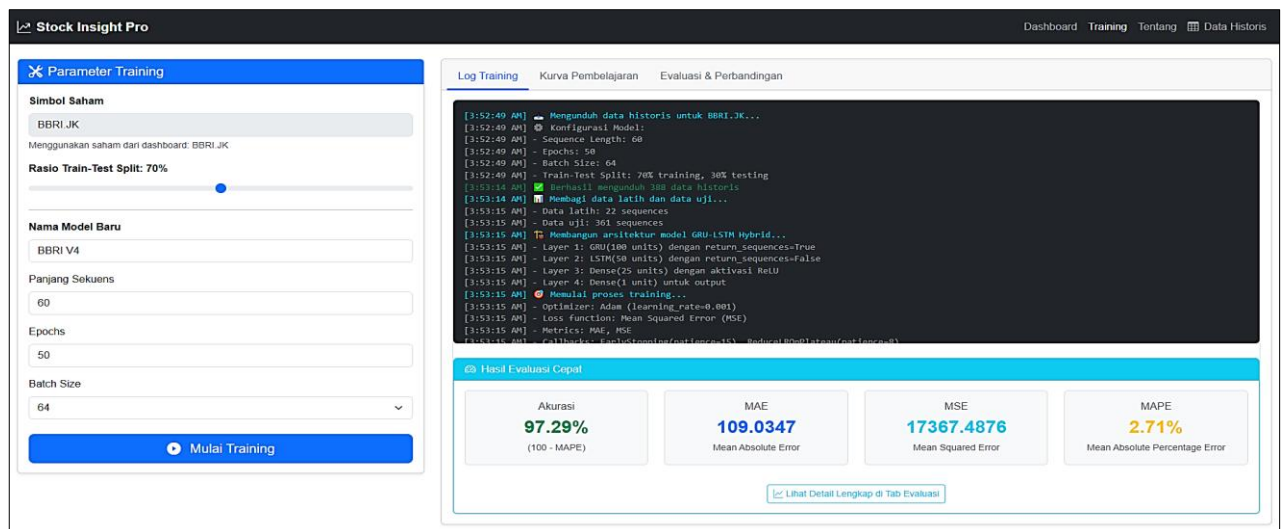
**Gambar 4.** Halaman Dashboard dan Prediksi

Antarmuka ini mengadopsi desain *split-panel layout* yang membagi area kerja menjadi dua bagian fungsional: panel kontrol kiri (30% lebar) dan panel visualisasi kanan (70% lebar). Panel kontrol kiri terdiri dari empat modul utama: (1) Kontrol Analisis untuk memasukkan simbol saham dan mengatur parameter periode serta tipe chart, (2)

Indikator Teknikal dengan konfigurasi *Moving Average*, *Exponential Moving Average*, *Relative Strength Index*, dan *Moving Average Convergence Divergence*, (3) Manajemen Model untuk memuat dan menghapus model LSTM/GRU yang telah dilatih, serta (4) Kontrol Prediksi untuk mengatur parameter prediksi seperti panjang sekuens dan jumlah hari prediksi. Panel visualisasi kanan menampilkan grafik interaktif menggunakan Plotly.js yang mendukung berbagai tipe visualisasi termasuk candlestick chart untuk data historis, line chart untuk prediksi, serta sub-chart untuk indikator teknikal RSI dan MACD. Fitur interaktif pada dashboard mencakup zoom dinamis, tooltip informasi detail, toggle visibility untuk berbagai layer data, dan pembaruan real-time berdasarkan parameter yang dikonfigurasi. Sistem ini juga mengintegrasikan modal window untuk menampilkan data tabel historis dan hasil prediksi dalam format terstruktur, dilengkapi dengan analisis statistik ringkas dan interpretasi sinyal perdagangan berbasis aturan teknikal.

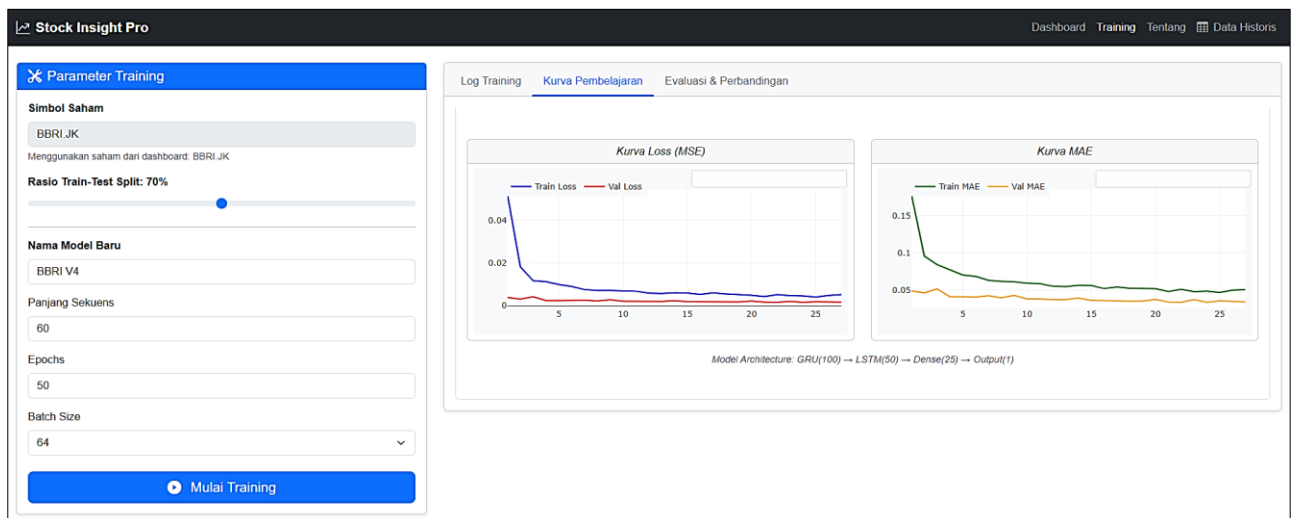
### 3.5.2 Halaman Training

Halaman Training dirancang khusus untuk proses pengembangan dan evaluasi model prediktif dengan pendekatan wizard-based interface yang memandu pengguna melalui tiga tahapan terstruktur.



Gambar 5. Halaman Training- Training Log

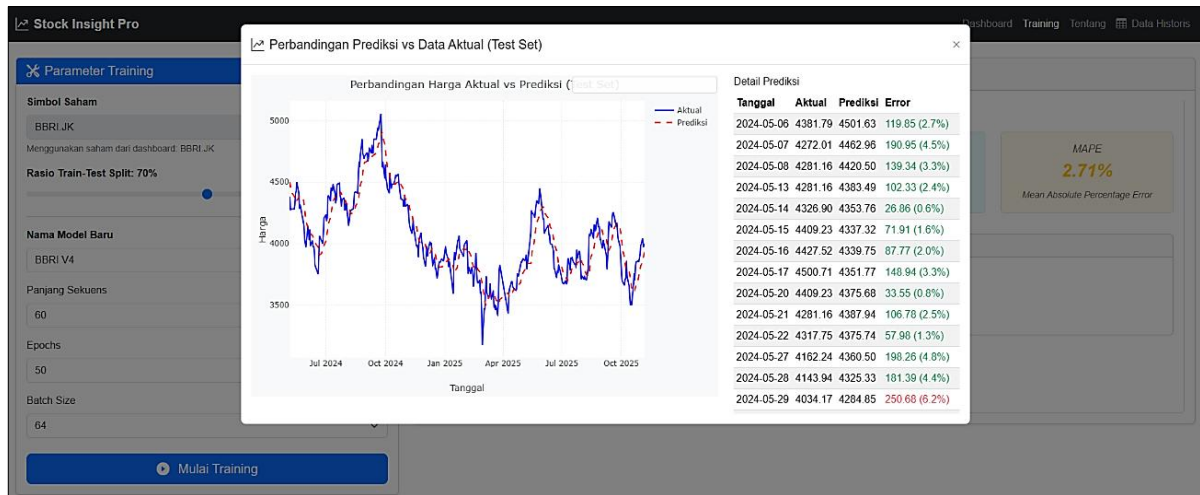
Panel pertama yang ditampilkan pada Gambar 5 adalah Training Log yang berfungsi sebagai konsol monitoring real-time dengan tampilan dark-themed console yang menampilkan kronologi proses training secara berurutan, mulai dari inialisasi data, ekstraksi fitur, progres iterasi epoch, hingga hasil evaluasi akhir. Log sistem mengintegrasikan format output yang terstruktur dengan timestamp implisit, level log yang berbeda (info, warning, error), dan kemampuan auto-scrolling untuk memastikan entri terbaru selalu terlihat. Setelah proses training selesai, secara otomatis muncul ringkasan metrik performa inti (MAE, MSE, RMSE, MAPE, Accuracy) dalam format *card-based dashboard* dengan *color-coded thresholds* untuk interpretasi visual yang intuitif.



Gambar 6. Halaman Training – Kurva Pembelajaran

Panel kedua yang ditampilkan pada Gambar 6 adalah Kurva Pembelajaran yang menyajikan visualisasi dinamis interaktif untuk analisis proses pembelajaran model menggunakan Plotly.js. Visualisasi ini menampilkan dual-trace

time-series dengan superimposisi antara training loss dan validation loss pada domain epoch yang sama, dilengkapi dengan shaded confidence interval yang merepresentasikan variabilitas antar batch. Fitur diagnostik mencakup early stopping indicator berupa garis vertikal merah dengan anotasi teks, learning rate reduction markers, serta multi-session overlay capability untuk perbandingan performa berbagai konfigurasi hyperparameter. Panel ini juga menyediakan statistical summary sidebar yang menghitung metrik derivatif seperti convergence rate dan overfitting index berdasarkan analisis rasio loss.



**Gambar 7.** Halaman Training – Visualisasi Testing

Panel ketiga yang ditampilkan pada Gambar 7 adalah Visualisasi Testing yang menghadirkan evaluasi komprehensif melalui pendekatan comparative analysis dengan tata letak split-panel. Sisi kiri menampilkan synchronized dual-trace visualization antara nilai aktual dan prediksi pada dataset testing, dilengkapi dengan error band transparan dan residual analysis subplot. Sisi kanan menyajikan sortable and filterable data table yang berisi detail perhitungan error untuk setiap titik waktu, dikategorikan berdasarkan *direction*. Sistem ini mengintegrasikan advanced statistical modules untuk menghitung metrik evaluasi seperti RMSE, MSE, MAPE, dan MAE.

### 3.5.3 Halaman Tentang

Halaman Tentang Seperti yang ditampilkan pada Gambar 8 dirancang sebagai pusat informasi yang menjelaskan teknologi dan cara kerja sistem prediksi harga saham secara komprehensif

**Tentang Dashboard Ini**

**Dashboard Analisis & Prediksi Saham Profesional**

Dashboard ini dirancang untuk memberikan wawasan mendalam tentang pergerakan harga saham, menganalisis tren historis menggunakan berbagai indikator teknis, dan memprediksi harga di masa depan dengan teknologi Deep Learning. Dibangun dengan fokus pada performa, interaktivitas, dan akurasi prediksi.

**Teknologi yang Digunakan**

- Python**: Sebagai bahasa pemrograman inti, Python digunakan untuk logika backend, pemrosesan data, dan implementasi model Deep Learning. Fleksibilitas dan ekosistem library yang kaya membuatnya pilihan ideal.
- Flask**: Framework web mikro untuk Python ini membentuk tulang punggung backend, menangani permintaan HTTP, routing, dan interaksi dengan model serta data API. Ringan dan mudah disesuaikan.
- yfinance**: Library Python untuk mengambil data historis saham dari Yahoo Finance secara real-time. Ini adalah sumber data utama untuk analisis dan pelatihan model.
- LSTM (Long Short-Term Memory)**: Jenis jaringan saraf berulang (RNN) yang dirancang khusus untuk memproses urutan data. Sangat efektif dalam memprediksi deret waktu seperti harga saham karena kemampuannya mempelajari dependensi jangka panjang.
- GRU (Gated Recurrent Unit)**: Merupakan varian RNN lain yang lebih sederhana dari LSTM, namun seringkali memberikan performa serupa. GRU mengurangi jumlah gerbang, membuatnya lebih cepat dilatih dan membutuhkan data yang lebih sedikit.
- TensorFlow / Keras**: Framework Deep Learning utama yang digunakan untuk membangun, melatih, dan mengevaluasi model LSTM dan GRU. Keras menyediakan API tingkat tinggi yang memudahkan pengembangan model.
- Scikit-learn**: Library fundamental untuk machine learning klasik di Python. Digunakan di sini untuk pre-processing data, seperti penskalaan (MinMaxScaler), yang krusial sebelum memasukkan data ke model Deep Learning.
- Plotly.js**: Library JavaScript interaktif untuk membuat visualisasi data. Digunakan untuk menampilkan grafik candlestick, garis, indikator teknis, dan hasil prediksi dengan fitur zoom dan hover yang kaya.
- Bootstrap 5**: Framework CSS populer yang digunakan untuk membangun antarmuka pengguna yang responsif dan modern. Memastikan tampilan dashboard konsisten dan estetis di berbagai perangkat.

**Gambar 8.** Halaman Tentang

Halaman ini menggunakan pendekatan "penjelasan berbasis kartu" yang memudahkan pengguna awam untuk memahami komponen teknis tanpa perlu latar belakang pemrograman. Setiap teknologi dijelaskan dalam kartu terpisah



yang berisi tiga elemen utama: ikon visual yang merepresentasikan fungsi teknologi, judul sederhana yang langsung menjelaskan peran teknologi, dan deskripsi ringkas yang menghubungkan teknologi tersebut dengan manfaat yang dirasakan pengguna. Misalnya, untuk menjelaskan LSTM dan GRU, sistem tidak menggunakan istilah teknis seperti *vanishing gradient* atau *gated mechanism*, tetapi menggambarannya sebagai "otak yang mengingat pola harga dari masa lalu untuk memprediksi masa depan". Penjelasan tentang indikator teknikal seperti RSI dan MACD disederhanakan menjadi konsep "alat pendeteksi momen beli dan jual" dengan analogi lampu lalu lintas (hijau untuk beli, merah untuk jual, kuning untuk hati-hati). Halaman ini juga menyajikan alur kerja sistem secara visual dengan diagram sederhana yang menunjukkan bagaimana data saham diambil, diolah oleh model, dan ditampilkan ke pengguna. Dengan pendekatan ini, Halaman Tentang tidak hanya berfungsi sebagai dokumentasi teknis, tetapi juga sebagai alat edukasi yang membantu investor pemula memahami dasar-dasar analisis saham digital dan memberikan transparansi tentang metode prediksi yang digunakan.

#### 4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem prediksi harga saham berbasis web yang mengintegrasikan model hybrid GRU-LSTM dengan indikator teknikal konvensional. Hasil implementasi menunjukkan bahwa arsitektur hybrid yang diusulkan mampu mencapai performa prediktif yang signifikan dengan nilai MAE sebesar 0,0241, MSE 0,0012, RMSE 0,0346, dan MAPE 2,7% pada pengujian menggunakan data saham BBRI.JK. Sistem ini secara efektif menjawab permasalahan utama penelitian terkait kebutuhan alat analisis saham yang objektif, interaktif, dan berbasis data dengan menyediakan tiga komponen fungsional yang terintegrasi. Halaman Dashboard berhasil menghadirkan analisis teknikal real-time melalui visualisasi interaktif yang memadukan data historis, indikator MA, RSI, MACD, serta hasil prediksi model dalam antarmuka yang responsif. Halaman Training memberikan lingkungan pengembangan model yang komprehensif dengan kemampuan monitoring real-time melalui training log, analisis kurva pembelajaran, dan evaluasi performa melalui visualisasi testing yang mendetail. Sedangkan Halaman Tentang berfungsi sebagai platform edukasi yang berhasil menyederhanakan konsep teknis kompleks menjadi penjelasan yang mudah dipahami oleh investor dengan berbagai tingkat keahlian. Namun, penelitian ini memiliki beberapa keterbatasan yang perlu diakui. Pertama, model hanya diuji pada saham blue-chip dengan karakteristik likuiditas tinggi sehingga generalisasi performa pada saham dengan volatilitas ekstrem atau kapitalisasi kecil masih perlu diverifikasi. Kedua, sistem belum mengintegrasikan faktor fundamental perusahaan dan sentimen pasar dari sumber berita atau media sosial yang dapat mempengaruhi harga saham secara signifikan. Ketiga, horizon prediksi yang diterapkan masih relatif pendek (10 hari) sehingga belum dapat memberikan pandangan jangka panjang yang diperlukan untuk strategi investasi tertentu. Keempat, antarmuka training meskipun telah dirancang secara komprehensif masih memerlukan pengetahuan dasar machine learning untuk pengoperasian optimal. Untuk penelitian selanjutnya, disarankan beberapa perbaikan dan pengembangan termasuk: perluasan cakupan pengujian pada berbagai sektor dan tipe saham, integrasi analisis sentimen dari sumber berita finansial, pengembangan model multi-horizon dengan kemampuan prediksi jangka menengah dan panjang, implementasi ensemble learning yang menggabungkan berbagai arsitektur deep learning, penambahan fitur backtesting untuk evaluasi strategi investasi berbasis sinyal sistem, serta penyederhanaan lebih lanjut antarmuka training dengan fitur guided wizard untuk pengguna non-teknis. Dengan pengembangan tersebut, sistem ini diharapkan dapat berkembang menjadi platform analisis investasi yang lebih komprehensif dan dapat diadaptasi secara luas oleh berbagai kalangan investor di Indonesia.

#### REFERENCES

- Agustina, R. (2021). Analisis Fundamental, Acuan Investasi Saham Jangka Panjang. *DINAMIS: Jurnal Pengabdian Kepada Masyarakat*, 1(1), 14–25. <https://doi.org/10.33752/dinamis.v1i1.360>
- Dandi, M. K., & Kurniawan, R. (2025). Sistem Rekomendasi Pemilihan Saham Blue-Chip di Bursa Efek Indonesia Menggunakan Fuzzy Mamdani. 6(5), 462–472. <https://doi.org/10.47065/tin.v6i5.8465>
- Dewi, P. K., Hutagalung, M., Dwi Pratama, V., & Afifah, Z. (2025). Analisis Teknikal Pergerakan Harga Saham Untuk Mengambil Keputusan Investasi pada Saham Sektor Telekomunikasi yang Terdaftar di Bursa Efek Indonesia: Studi Kasus Saham XL Axiata Tbk (EXCL).
- Firdaus, R. G. (2021a). Analisis Teknikal Saham Menggunakan Indikator RSI dan Bollinger Bands pada Saham Konstruksi. *Jurnal Pasar Modal Dan Bisnis*, 3(1), 15–26. <https://doi.org/10.37194/jpmb.v3i1.60>
- Ghudafa Taufik Akbar, M., Panggabean, S., & Noor, M. (2022). Perbandingan Prediksi Harga Saham Dengan Menggunakan LSTM GRU Dengan Transformer. 11(1).
- Hariyanti, I., Hafizh, V., Putra, C., Raharja, A. R., & Kunci, K. (2025). Prediksi Harga Saham Bbca Menggunakan Metode Long Short-Term Memory Dan Gated Recurrent Unit. *Jurnal Responsif: Riset Sains &*, 7. <https://ejurnal.ars.ac.id/index.php/jti>
- Hwang, J. S., Lee, S. S., Gil, J. W., & Lee, C. K. (2024). Determination of Optimal Batch Size of Deep Learning Models with Time Series Data. *Sustainability (Switzerland)*, 16(14). <https://doi.org/10.3390/su16145936>
- Hyndman, R. J. (2025). Moving Averages. In M. Lovric (Ed.), *International Encyclopedia of Statistical Science* (pp. 1559–1562). Springer Berlin Heidelberg. [https://doi.org/10.1007/978-3-662-69359-9\\_383](https://doi.org/10.1007/978-3-662-69359-9_383)



- Joshi, D. L. (2022). Use of Moving Average Convergence Divergence for Predicting Price Movements. *International Research Journal of MMC*, 3(4), 21–25. <https://doi.org/10.3126/irjmmc.v3i4.48859>
- Kwanda, K., Herwindiati, D. E., Lauro, M. D., & Id, K. K. C. (2024). Perbandingan LSTM dan Bidirectional LSTM pada Sistem Prediksi Harga Saham Berbasis Website. *R2J*, 7(1). <https://doi.org/10.38035/rj.v7i1>
- Lestari, Ari. (2025). Pengaruh Faktor-Faktor Fundamental terhadap Harga Saham (Penelitian Empiris Saham Sektor Manufaktur). *Co-Value Jurnal Ekonomi Koperasi dan kewirausahaan*. 15(9). doi: 10.59188/covalue.v15i9.5101.
- Luthfiansyah, R., & Wasito, B. (2023). Penerapan Teknik Deep Learning (Long Short Term Memory) dan Pendekatan Klasik (Regresi Linier) dalam Prediksi Pergerakan Saham BRI. In *Jurnal Informatika dan Bisnis* (Vol. 12, Issue 2).
- Morales-Brotons, D., Vogels, T., & Hendriks, H. (2024). *Exponential Moving Average of Weights in Deep Learning: Dynamics and Benefits*. <http://arxiv.org/abs/2411.18704>
- Pirani, M., Thakkar, P., Jivrani, P., Bohara, M. H., & Garg, D. (2022). A Comparative Analysis of ARIMA, GRU, LSTM and BiLSTM on Financial Time Series Forecasting. *2022 IEEE International Conference on Distributed Computing and Electrical Circuits and Electronics (ICDCECE)*, 1–6. <https://doi.org/10.1109/ICDCECE53908.2022.9793213>
- Silalahi, R. N., & Muljono, M. (2024). Perbandingan Kinerja Metode Linear Regression, LSTM dan GRU Untuk Prediksi Harga Penutupan Saham Coca-Cola. *Komputika: Jurnal Sistem Komputer*, 13(2), 201–211. <https://doi.org/10.34010/komputika.v13i2.12265>
- Supriatna, D., & Anggai, S. (2025a). *Analisis Prediksi Curah Hujan di Kota Tangerang Menggunakan Metode LSTM dan GRU*. <https://doi.org/10.55382/jurnalpustakaai.v5i2.1068>
- Wang, H. (2025). Enhancing Stock Price Forecasting Accuracy Using LSTM and Bi-LSTM Models. *ITM Web of Conferences*, 70, 04008. <https://doi.org/10.1051/itmconf/20257004008>
- Yu, Y. (2025a). LSTM-Based Time Series Prediction Model: A Case Study with YFinance Stock Data. *ITM Web of Conferences*, 70, 03015. <https://doi.org/10.1051/itmconf/20257003015>
- Zhang, J., & Yan, L. (2025). GRU-Enhanced Attention Mechanism for LSTM in Hybrid CNN-LSTM Models for Stock Prediction. *Journal of Global Trends in Social Science*, 2(3). <https://doi.org/10.70731/rzvs8j53>