



# Optimasi Hyperparameter Pada Model Hybrid Bidirectional LSTM-GRU Untuk Prediksi Harga Saham Bank

Adam Maulidin Duha\*, Anggyi Trisnawan Putra

Fakultas Matematika dan Ilmu Pengetahuan Alam, Program Studi Teknik Informatika, Universitas Negeri Semarang, Semarang, Indonesia

Email: <sup>1,\*</sup>maulidinadam74@students.unnes.ac.id, <sup>2</sup>anggyi.trisnawan@mail.unnes.ac.id

Email Penulis Korespondensi: maulidinadam74@students.unnes.ac.id

**Abstrak**—Prediksi harga saham di pasar modal Indonesia memiliki tingkat kompleksitas yang tinggi karena sangat dipengaruhi oleh volatilitas pasar dan sifat data deret waktu yang non-linear. Kesalahan dalam memprediksi tren harga dapat meningkatkan risiko investasi secara signifikan. Penelitian ini bertujuan untuk meningkatkan akurasi prediksi harga saham pada perusahaan perbankan blue chip (studi kasus pada salah satu bank BUMN terbesar) dengan mengatasi kelemahan model tunggal. Metode yang diusulkan adalah arsitektur Hybrid Deep Learning yang menggabungkan Bidirectional Long Short-Term Memory (Bi-LSTM) untuk menangkap ketergantungan jangka panjang dan Bidirectional Gated Recurrent Unit (Bi-GRU) untuk efisiensi komputasi. Untuk memastikan performa model yang maksimal, dilakukan optimasi hyperparameter secara otomatis menggunakan algoritma Hyperband yang menerapkan strategi adaptive resource allocation. Data yang digunakan adalah data historis perdagangan harian selama 10 tahun (2014–2024) yang telah melalui tahap normalisasi Min-Max dan pembentukan window size 60 hari. Hasil eksperimen menunjukkan bahwa algoritma Hyperband berhasil menemukan konfigurasi optimal pada 128 unit Bi-LSTM dan 32 unit Bi-GRU dengan fungsi aktivasi tanh. Evaluasi model pada data uji menunjukkan tingkat akurasi yang tinggi dengan nilai Root Mean Squared Error (RMSE) sebesar 171.41 Rupiah dan Mean Absolute Error (MAE) sebesar 142.53 Rupiah. Hasil ini membuktikan bahwa pendekatan hibrida yang dioptimasi secara sistematis mampu meminimalkan kesalahan prediksi jauh lebih baik dan dapat diandalkan untuk memodelkan dinamika harga saham yang fluktuatif.

**Kata Kunci:** Prediksi Harga Saham; Bidirectional LSTM; Bidirectional GRU; Optimasi Hyperparameter; Algoritma Hyperband

**Abstract**—Stock price prediction in the Indonesian capital market is highly complex due to the significant influence of market volatility and the non-linear nature of time-series data. Errors in predicting price trends can significantly increase investment risks. This study aims to enhance the accuracy of stock price prediction for blue-chip banking companies (a case study on one of the largest state-owned banks) by addressing the limitations of single models. The proposed method is a Hybrid Deep Learning architecture combining Bidirectional Long Short-Term Memory (Bi-LSTM) to capture long-term dependencies and Bidirectional Gated Recurrent Unit (Bi-GRU) for computational efficiency. To ensure maximal model performance, automatic hyperparameter optimization was performed using the Hyperband algorithm, which utilizes an adaptive resource allocation strategy. The data employed consists of 10 years of historical daily trading data (2014–2024), which underwent Min-Max normalization and a 60-day window size formation. Experimental results demonstrate that the Hyperband algorithm successfully identified the optimal configuration of 128 Bi-LSTM units and 32 Bi-GRU units with the tanh activation function. Model evaluation on the test data indicated a high level of accuracy, with a Root Mean Squared Error (RMSE) of IDR 171.41 and a Mean Absolute Error (MAE) of IDR 142.53. These results confirm that the systematically optimized hybrid approach is capable of minimizing prediction errors significantly better and is reliable for modeling fluctuating stock price dynamics.

**Keywords:** Stock Price Prediction; Bidirectional LSTM; Bidirectional GRU; Hyperparameter Optimization; Hyperband Algorithm

## 1. PENDAHULUAN

Pasar modal memegang peranan yang sangat vital dalam ekosistem finansial modern, tidak hanya sebagai sarana bagi perusahaan untuk memperoleh pendanaan jangka panjang, tetapi juga sebagai indikator utama kesehatan ekonomi suatu negara. Di Indonesia, pasar modal menjadi salah satu instrumen investasi yang paling diminati karena menawarkan potensi imbal hasil yang tinggi. Kinerja pasar modal sering kali merefleksikan valuasi dan prospek kerja emiten, serta menggambarkan tingkat kepercayaan investor terhadap stabilitas ekonomi nasional [1]. Kenaikan harga saham yang konsisten dalam pasar modal kerap diasosiasikan dengan peningkatan investasi di sektor riil dan pertumbuhan bisnis yang sehat. Namun, di balik potensi keuntungan tersebut, pasar modal memiliki karakteristik inheren yang menjadi tantangan utama bagi para investor, yaitu volatilitas yang tinggi dan sifat pergerakan harga yang non-linear [2]. Harga saham terbentuk dari interaksi yang sangat kompleks antara faktor internal perusahaan, sentimen pasar, hingga kondisi makroekonomi global yang dinamis [3].

Karakteristik data harga saham yang fluktuatif (*chaotic*) dan dipengaruhi oleh banyak variabel (multivariat) menyebabkan pergerakan harga dapat berubah secara drastis dalam waktu yang sangat singkat. Hal ini menjadikan harga saham sangat sulit untuk diprediksi dengan tingkat akurasi yang tinggi [4]. Ketidakmampuan dalam memprediksi tren harga secara akurat dapat berakibat fatal, mulai dari hilangnya peluang keuntungan hingga kerugian kapital yang signifikan. Oleh karena itu, prediksi harga saham bukan sekadar aktivitas spekulatif, melainkan merupakan elemen krusial dalam manajemen risiko dan strategi pengambilan keputusan investasi yang cerdas [5].

Dalam perkembangannya, berbagai pendekatan telah dilakukan untuk memecahkan masalah prediksi ini. Pada awalnya, pendekatan statistik konvensional seperti *Autoregressive Integrated Moving Average* (ARIMA) dan analisis teknikal menggunakan indikator seperti *Moving Average* (MA) banyak digunakan. Namun, metode-metode ini sering kali bekerja berdasarkan asumsi linearitas data, sehingga kurang mampu menangkap pola tersembunyi pada data harga saham



yang bersifat non-linear dan stokastik [6]. Keterbatasan ini mendorong pergeseran paradigma menuju pendekatan *Machine Learning* dan *Deep Learning*, khususnya *Artificial Neural Network* (ANN). ANN kemudian berevolusi menjadi *Recurrent Neural Network* (RNN) yang dirancang khusus untuk data deret waktu (*time-series*) karena memiliki kemampuan mengingat informasi dari data sebelumnya. Meskipun demikian, RNN standar memiliki kelemahan fundamental berupa masalah *vanishing gradient*, di mana model kehilangan kemampuan untuk mempelajari dependensi jangka panjang pada data yang memiliki rentang waktu panjang [7].

Untuk mengatasi kelemahan RNN, dikembangkan arsitektur yang lebih canggih, yaitu *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Kedua model ini menerapkan mekanisme gerbang (*gating mechanism*) yang berfungsi mengatur aliran informasi, memutuskan mana yang harus diingat dan mana yang harus dilupakan. Dalam beberapa tahun terakhir, penerapan LSTM dan GRU mendominasi penelitian prediksi saham. Namun, hasil akurasi yang diperoleh dari berbagai penelitian masih sangat bervariasi, mengindikasikan bahwa penggunaan model tunggal saja mungkin belum cukup untuk mencapai performa optimal.

Penelitian-penelitian terdahulu memberikan gambaran beragam mengenai efektivitas model ini. Farhadi dkk. [2] dalam penelitian terbarunya mengembangkan sistem gabungan (hibrida) LSTM-GRU pada pasar modal, dan hasilnya menunjukkan bahwa penggabungan model mampu menghasilkan evaluasi *Mean Squared Error* (MSE) yang 3% lebih baik dibandingkan hanya menggunakan model tunggal LSTM atau GRU secara terpisah. Temuan ini memperkuat argumen bahwa arsitektur hibrida memiliki potensi lebih besar dalam menangkap pola data yang kompleks. Di sisi lain, terjadi inkonsistensi temuan pada model tunggal. Studi komparasi oleh Satria [4] menunjukkan bahwa GRU memiliki nilai *Root Mean Squared Error* (RMSE) paling rendah (0.159) dibandingkan LSTM (0.165), yang menegaskan efisiensi GRU pada dataset tertentu. Sebaliknya, Dwiandiyanta dkk. [5] yang meneliti saham *blue chip* di Indonesia justru menemukan bahwa RNN memberikan RMSE terendah dibandingkan GRU dan LSTM. Perbedaan hasil yang signifikan ini menunjukkan bahwa performa model *Deep Learning* sangat sensitif terhadap karakteristik data spesifik dan konfigurasi parameter yang digunakan.

Selain perdebatan mengenai arsitektur model, aspek optimasi *hyperparameter* juga menjadi sorotan utama dalam literatur terkini. Mayoritas penelitian sebelumnya masih menentukan parameter model (seperti jumlah *neuron*, *learning rate*, dan *batch size*) secara manual atau *trial and error*. Metode ini sangat tidak efisien dan tidak menjamin ditemukannya konfigurasi terbaik. Liu dkk. [8] membuktikan bahwa penerapan optimasi otomatis pada model prediksi komoditas berhasil menekan nilai kesalahan secara signifikan. Hal serupa ditemukan oleh Febriyanti dkk. [9] yang menegaskan bahwa LSTM yang dioptimasi mampu memberikan prediksi yang jauh lebih presisi pada saham perbankan Indonesia.

Berdasarkan tinjauan literatur tersebut, teridentifikasi dua celah penelitian (*research gap*) utama yang belum banyak dieksplorasi secara bersamaan. Pertama, mayoritas penelitian yang ada masih menggunakan arsitektur satu arah (*unidirectional*). Arsitektur ini hanya memproses informasi dari masa lalu ke masa depan, sehingga berpotensi kehilangan konteks informasi yang lebih utuh dari urutan data waktu. Padahal, dalam analisis tren, memahami konteks dari dua arah (maju dan mundur) dapat memberikan gambaran yang lebih komprehensif. Kedua, belum banyak penelitian yang menggabungkan kekuatan arsitektur hibrida dengan metode optimasi *hyperparameter* berbasis *bandit algorithm* seperti *Hyperband*, yang dikenal jauh lebih efisien dibandingkan metode pencarian tradisional seperti *Grid Search*.

Penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan mengusulkan model Hybrid Bidirectional LSTM-GRU yang diperkuat dengan optimasi Hyperband. Pendekatan *Bidirectional* memungkinkan model untuk mempelajari pola pergerakan harga dari dua arah temporal sekaligus, meningkatkan kemampuan model dalam menangkap anomali dan tren kompleks. Sementara itu, penggabungan (hibrida) LSTM dan GRU bertujuan mensinergikan kemampuan manajemen memori jangka panjang milik LSTM dengan efisiensi komputasi milik GRU. Untuk memastikan model bekerja pada kapasitas maksimalnya, algoritma *Hyperband* digunakan untuk mencari konfigurasi *hyperparameter* yang paling optimal secara otomatis dan efisien.

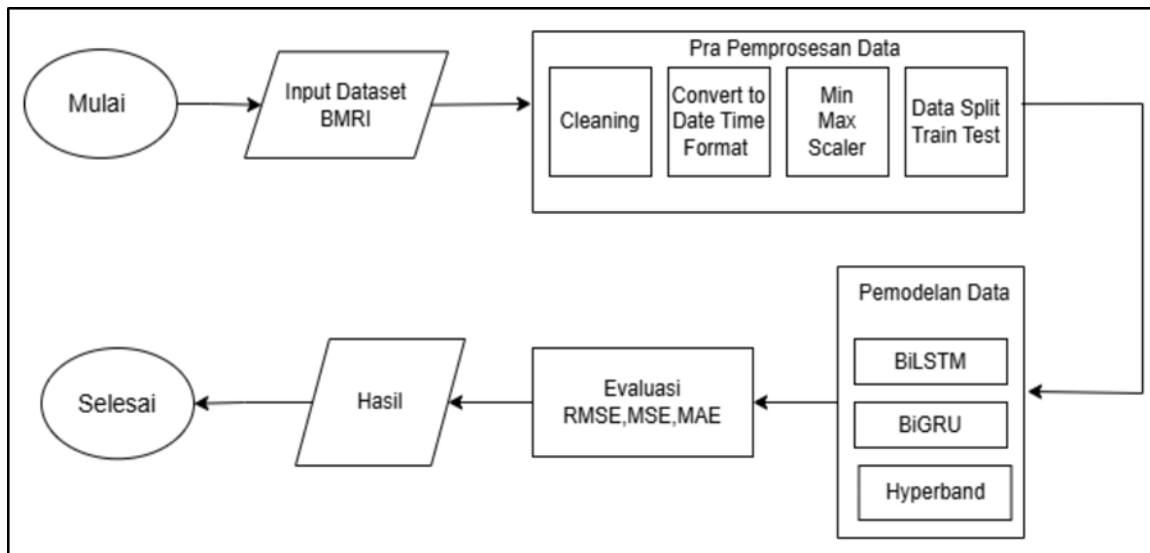
Objek studi dalam penelitian ini adalah saham PT Bank Mandiri (Persero) Tbk (BMRI). Pemilihan saham ini didasarkan pada posisinya sebagai salah satu saham *blue chip* dengan kapitalisasi pasar terbesar di Indonesia dan keanggotaannya dalam indeks LQ45. Pergerakan harga saham BMRI sangat dipengaruhi oleh sentimen pasar global dan kondisi makroekonomi domestik, menjadikannya dataset yang sangat representatif dan menantang untuk menguji ketangguhan model prediksi *Deep Learning*. Melalui penelitian ini, diharapkan dapat dihasilkan sebuah model prediksi yang tidak hanya memiliki tingkat akurasi tinggi, tetapi juga stabil dan andal untuk digunakan sebagai alat bantu pengambilan keputusan investasi di pasar modal Indonesia.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Rancangan tahapan penelitian ini didesain dengan pendekatan sistematis guna memastikan bahwa setiap langkah berkontribusi secara efektif terhadap pencapaian akurasi prediksi harga saham BMRI yang optimal. Alur kerja dimulai dari akuisisi data historis jangka panjang, yang kemudian diproses melalui serangkaian teknik pra-pemrosesan data yang ketat termasuk pembersihan *noise*, konversi format waktu, normalisasi skala fitur, hingga pembagian dataset untuk menjamin validitas *input* model. Tahap inti melibatkan konstruksi arsitektur *Deep Learning* hibrida yang mengintegrasikan lapisan Bi-LSTM dan Bi-GRU, di mana kinerjanya dimaksimalkan melalui skema optimasi *hyperparameter* otomatis berbasis algoritma *Hyperband* untuk mencapai konvergensi terbaik. Rangkaian proses ini

ditutup dengan evaluasi komprehensif menggunakan metrik statistik standar (RMSE, MSE, MAE) untuk mengukur deviasi prediksi terhadap data aktual. Secara visual, keseluruhan kerangka kerja metodologi ini diilustrasikan secara rinci pada Gambar 1 berikut.



**Gambar 1.** Alur Penelitian

Penelitian dimulai dengan pengambilan data historis harga saham Bank Mandiri (BMRI) selama kurun waktu 10 tahun (2014–2024), Data diperoleh dari dataset publik di Kaggle (Dataset Saham Bank Indonesia 2014 - 2024). Data kemudian melalui tahap pra-pemrosesan yang mencakup pembersihan data (*cleaning*), konversi format tanggal (*date-time formatting*), normalisasi fitur menggunakan *Min–Max Scaler*, serta pembagian dataset dengan proporsi 80% untuk data latih (*training set*) dan 20% untuk data uji (*testing set*). Selanjutnya, penelitian memasuki tahapan pemodelan dengan membangun arsitektur Hybrid Bidirectional Long Short-Term Memory (BiLSTM) dan Bidirectional Gated Recurrent Unit (BiGRU) sebagai inti model. Untuk memperoleh konfigurasi paling optimal, dilakukan proses hyperparameter tuning menggunakan algoritma *Hyperband* secara otomatis. Penelitian ditutup dengan evaluasi kinerja prediksi menggunakan tiga metrik utama, yaitu Root Mean Squared Error (RMSE), Mean Squared Error (MSE), dan Mean Absolute Error (MAE) sebagai indikator tingkat akurasi model

## 2.2 Pengumpulan dan Prapemrosesan Data

Penelitian ini menggunakan data sekunder berupa riwayat harga saham PT Bank Mandiri (BMRI) yang diambil dari repositori publik Kaggle (cmglonly) dengan rentang periode 2014–2024 [10]. Dataset memuat informasi perdagangan harian seperti *Date*, *Open*, *High*, *Low*, *Close*, *Adjusted Close*, dan *Volume*, di mana nilai *Close Price* dipilih sebagai variabel utama karena dianggap paling representatif dalam mencerminkan penilaian pasar pada akhir sesi perdagangan [11]. Sebelum digunakan dalam pemodelan, tahap pra-pemrosesan data dilakukan untuk meningkatkan kualitas dan mengurangi bias prediksi [12], meliputi pembersihan data, konversi format tanggal, normalisasi, serta pembagian data untuk keperluan pelatihan dan pengujian model. Proses ini meliputi langkah – langkah berikut ini :

- Data Cleaning*: Tahap ini dilakukan untuk mengatasi *missing values* serta menghilangkan data yang dianggap mengganggu (*noise*). Record yang tidak lengkap diperbaiki atau dihapus agar kualitas dan keandalan dataset tetap terjaga sebelum masuk ke proses pelatihan *Deep Learning* [13].
- Konversi Format Datetime: Kolom *Date* diubah ke tipe *datetime* dan dijadikan indeks utama. Langkah ini penting dalam pengolahan data *time series* karena memastikan urutan data mengikuti waktu sebenarnya sehingga analisis dapat dilakukan secara kronologis [14].
- Normalisasi (*Min–Max Scaler*): Nilai harga saham dinormalisasi ke rentang [0 - 1] agar skala data lebih seragam. Normalisasi ini mendukung proses pelatihan model berbasis *Gradient Descent* seperti LSTM dan GRU karena mempercepat proses konvergensi serta mencegah fitur dengan nilai besar mendominasi model [15].
- Data Splitting*: Dataset kemudian dibagi menjadi dua bagian, yaitu 80% data latih dan 20% data uji. Pembagian persentase ini banyak direkomendasikan dalam penelitian sebelumnya karena mampu menjaga keseimbangan antara pemahaman pola oleh model dan kemampuan generalisasi terhadap data baru [16].

## 2.3 Pemodelan Data

Pemodelan data pada penelitian ini menerapkan pendekatan *Deep Learning* dengan arsitektur hibrida. Model dibangun berdasarkan dua pengembangan RNN modern, yakni Bi-LSTM dan Bi-GRU, yang ditingkatkan performanya melalui optimasi otomatis.

- Bidirectional Long Short-Term Memory (Bi-LSTM) *Long Short-Term Memory* (LSTM) dirancang untuk mengatasi masalah *vanishing gradient* pada RNN tradisional dengan menggunakan mekanisme *cell state*. Dalam konteks



prediksi saham yang memiliki volatilitas tinggi, arsitektur *Bidirectional* (Bi-LSTM) diterapkan untuk meningkatkan kemampuan model. Berbeda dengan LSTM standar yang hanya memproses informasi dari masa lalu ke masa depan, Bi-LSTM memproses data input dari dua arah secara simultan (*forward* dan *backward*). Pendekatan ini memungkinkan model untuk menangkap konteks dependensi jangka panjang yang lebih tuah dan pola fluktuasi harga yang kompleks, yang terbukti meningkatkan akurasi pada data finansial [9]. Proses matematis pada unit LSTM diatur oleh beberapa gerbang (*gate*). Persamaan untuk *Forget Gate* ( $f_t$ ), *Input Gate* ( $i_t$ ), dan *Output Gate* ( $o_t$ ) adalah sebagai berikut :

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

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

Fungsi aktivasi *tanh* digunakan dalam persamaan *cell state* karena rentang nilainya (-1 hingga 1) membantu memusatkan data (*zero-centered*), yang terbukti mempercepat proses pembelajaran pada arsitektur LSTM dibandingkan fungsi *sigmoid*. Dalam rangkaian persamaan matematis di atas, simbol  $\sigma$  merepresentasikan fungsi aktivasi *sigmoid* yang bertugas mengatur aliran informasi melalui gerbang dengan keluaran bernilai antara 0 hingga 1. Setiap gerbang dikendalikan oleh parameter yang dapat dilatih, yaitu bobot matriks ( $W_f, W_i, W_c, W_o$ ) dan vektor bias ( $b_f, b_i, b_c, b_o$ ) yang masing-masing berasosiasi dengan gerbang *forget*, *input*, *candidate*, dan *output*. Proses komputasi melibatkan dua input utama, yakni *hidden state* dari langkah waktu sebelumnya ( $h_{t-1}$ ) dan data input pada langkah waktu saat ini ( $x_t$ ). Interaksi seluruh variabel ini pada akhirnya menghasilkan *cell state* yang telah diperbarui ( $C_t$ ), yang berfungsi sebagai memori jangka panjang jaringan untuk langkah waktu berikutnya.

- b. Bidirectional Gated Recurrent Unit (Bi-GRU) *Gated Recurrent Unit* (GRU) merupakan penyederhanaan dari arsitektur LSTM yang menggabungkan *forget gate* dan *input gate* menjadi satu mekanisme *update gate*. Struktur ini membuat GRU lebih efisien secara komputasi namun tetap mampu menangkap dependensi jangka panjang. Varian *Bidirectional* (Bi-GRU) diketahui mampu memberikan konvergensi pelatihan yang lebih cepat dibandingkan LSTM tanpa mengorbankan akurasi, menjadikannya komponen ideal untuk menstabilkan prediksi dalam model hibrida [11]. Secara matematis, pembaruan informasi pada unit GRU diformulasikan sebagai berikut:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (7)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (8)$$

$$\tilde{h}_t = \tanh(W \cdot [r_t * h_{t-1}, x_t] + b_h) \quad (9)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (10)$$

Mekanisme pembaruan informasi pada persamaan di atas dikendalikan oleh dua gerbang utama. Variabel  $z_t$  merepresentasikan *update gate* yang menentukan seberapa banyak informasi masa lalu yang perlu dipertahankan, sedangkan  $r_t$  adalah *reset gate* yang mengatur seberapa banyak informasi masa lalu yang harus diabaikan. Interaksi kedua gerbang ini memengaruhi perhitungan kandidat *hidden state* baru ( $\tilde{h}_t$ ) yang kemudian dikombinasikan untuk menghasilkan *hidden state* final ( $h_t$ ). Seluruh operasi ini melibatkan parameter bobot matriks ( $W$ ) dan vektor bias ( $b$ ) yang nilainya diperbarui secara adaptif selama proses pelatihan model.

- c. Optimasi Hyperparameter (Hyperband) Untuk mendapatkan performa terbaik, model hibrida ini dioptimasi menggunakan algoritma *Hyperband*. *Hyperband* merupakan pendekatan berbasis *bandit algorithm* yang merumuskan pencarian konfigurasi sebagai masalah alokasi sumber daya adaptif. Berbeda dengan *Grid Search* yang menguji seluruh kombinasi hingga selesai, *Hyperband* secara dinamis membagi sumber daya (*epoch*) hanya pada konfigurasi model yang potensial menggunakan strategi *Successive Halving*. Penerapan algoritma ini pada model *Deep Learning* terbukti mampu menemukan kombinasi *hyperparameter* optimal jauh lebih efisien dibandingkan metode konvensional [12].

Dalam implementasi optimasi ini, *Optimizer* tipe Adam dipilih karena kemampuannya beradaptasi dengan *learning rate* yang dinamis, yang memberikan konvergensi lebih stabil pada data saham yang penuh *noise* [14]. Selain itu, untuk mencegah *overfitting*, diterapkan mekanisme Dropout sebesar 0.2. Bahwa *Dropout* sangat krusial dalam pemodelan data finansial untuk meningkatkan kemampuan generalisasi model terhadap data baru [16].

## 2.4 Evaluasi Model

Evaluasi kinerja model dilakukan untuk menilai ketepatan prediksi terhadap data aktual. Pada penelitian ini, tiga metrik utama digunakan sebagai standar evaluasi dalam analisis deret waktu [17]:



- a. *Mean Squared Error (MSE)* menghitung rata-rata kuadrat kesalahan antara nilai prediksi dan nilai aktual. Metrik ini efektif untuk optimasi namun sensitif terhadap *outlier* [18].

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (11)$$

- b. *Root Mean Squared Error (RMSE)* merupakan akar kuadrat dari MSE. Metrik ini memiliki satuan yang sama dengan data asli (Rupiah), sehingga memudahkan interpretasi besaran kesalahan harga saham [18].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

- c. *Mean Absolute Error (MAE)* mengukur rata-rata selisih absolut yang dianggap lebih alami dan tidak bias karena memperlakukan semua kesalahan secara setara. Penggunaan metrik ini sangat disarankan dalam evaluasi model prediksi finansial, khususnya pada studi saham perbankan, untuk mengetahui besaran kesalahan rata-rata secara riil [19].

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (13)$$

Dalam ketiga persamaan evaluasi kinerja tersebut, variabel  $n$  merepresentasikan jumlah total sampel pada data uji yang digunakan dalam eksperimen. Notasi  $y_i$  mengacu pada nilai aktual harga saham BMRI yang tercatat, sedangkan  $\hat{y}_i$  adalah nilai prediksi yang dihasilkan oleh model. Perbedaan antara kedua nilai inilah yang dihitung baik melalui pengkuadratan maupun nilai absolut untuk mengukur deviasi dan menentukan tingkat akurasi model secara kuantitatif.

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Pengumpulan Data

Penelitian ini menggunakan data sekunder dari Kaggle, yaitu dataset “Dataset Saham Bank Indonesia 2014–2024” yang memuat data historis saham BMRI. Dataset ini dipilih karena bersifat publik, terdokumentasi dengan baik, dan memiliki cakupan waktu panjang. Data terdiri dari 7 dengan total lebih dari 2.474 data poin periode 2014–2024. Variabel Close digunakan sebagai target karena paling representatif menggambarkan nilai saham pada akhir perdagangan. Jumlah data yang besar mendukung pelatihan model deret waktu pada arsitektur Hybrid Bidirectional LSTM–GRU. Contoh sebagian data disajikan pada Tabel 1.

**Tabel 1.** Dataset Saham Bank Mandiri (BMRI)

NO	TANGGAL	OPEN	HIGH	LOW	CLOSE	ADJ. CLOSE	VOLUME
1	8/12/2014	2687,50	2693,75	2618,75	2637,50	1760,50	69,020,800
2	9/12/2014	2631,25	2662,50	2625,00	2631,25	1756,38	43,210,000
3	10/12/2014	2650,00	2700,00	2637,50	2693,75	1798,10	67,644,800
4	11/12/2014	2643,75	2718,75	2643,75	2681,25	1789,75	65,913,200
...	...	...	...	...	...	...	...
2470	26/11/2024	6600,00	6600,00	6325,00	6400,00	6400,00	107,194,300
2471	28/11/2024	6350,00	6525,00	6350,00	6450,00	6450,00	81.883.200
2472	29/11/2024	6325,00	6375,00	6125,00	6150,00	6150,00	157.628.700
2473	02/12/2024	6175,00	6250,00	5975,00	6000,00	6000,00	114.555.300
2474	03/12/2024	6100,00	6275,00	6100,00	6275,00	6275,00	99.509.800

Tabel 1 menyajikan sampel representatif dari dataset historis saham Bank Mandiri (BMRI) yang digunakan dalam penelitian ini. Data tersebut mencakup periode perdagangan dari tahun 2014 hingga 2024 dengan total 2.474 rekaman data harian. Sebagaimana terlihat pada tabel, setiap entri memuat atribut fitur perdagangan yang lengkap, meliputi tanggal transaksi (Tanggal), harga pembukaan (Open), harga tertinggi (High), harga terendah (Low), harga penutupan (Close), harga penutupan yang disesuaikan (Adj. Close), serta volume perdagangan (Volume). Variabel harga penutupan (Close) dalam tabel ini selanjutnya dipilih sebagai fitur target utama dalam proses pelatihan model karena merefleksikan valuasi konsensus pasar pada akhir sesi perdagangan.

#### 3.2 Prapemrosesan Data

Setelah data historis saham BMRI diperoleh dengan total 2.474 poin data, tahap pemrosesan data dilakukan melalui serangkaian langkah untuk menyiapkan *dataset* agar kompatibel dengan arsitektur *Deep Learning*.

- a. *Normalisasi Data*

Proses normalisasi diterapkan pada data harga saham menggunakan metode Min–Max Scaler. Nilai data diseragamkan ke dalam rentang 0.0 - 1.0. Normalisasi ini sangat krusial karena mendukung proses pelatihan model berbasis *Gradient Descent* seperti LSTM dan GRU, yang bertujuan untuk mempercepat proses konvergensi serta mencegah fitur dengan nilai besar mendominasi model.



#### b. Pembentukan Jendela Waktu (*Windowing*) dan *Reshaping*

Data yang telah dinormalisasi kemudian diubah menjadi pasangan sampel pelatihan dan target melalui mekanisme pembentukan jendela waktu (*windowing*). Dalam penelitian ini, ditetapkan time step (jendela waktu) sepanjang 60 hari. Melalui proses ini, total sampel yang valid adalah  $2.474 - 60 - 1 = 2.413$  sampel. Setiap sampel merepresentasikan 60 hari harga historis untuk memprediksi harga pada hari ke-61. Selanjutnya, data input diubah bentuknya (*reshaped*) menjadi format tiga dimensi [*samples, time steps, features*] agar sesuai dengan input arsitektur Bidirectional LSTM-GRU.

#### c. Pembagian Data (Data Splitting)

Total 2.413 sampel yang telah dibentuk kemudian dibagi dengan proporsi 80% untuk data latih (*training*) dan 20% untuk data uji (*testing*). Hasil pembagian data tersebut adalah 1.930 sampel data latih dan 483 sampel data uji. Secara dimensi, data input untuk pelatihan adalah (1930, 60, 1) dan data uji adalah (483, 60, 1). Pembagian ini bertujuan menjaga keseimbangan antara kemampuan model untuk memahami pola dan kemampuan generalisasi terhadap data baru yang belum pernah dilihat.

### 3.3 Implementasi dan Arsitektur Model

Setelah data historis harga saham PT Bank Mandiri (BMRI) melalui seluruh tahapan pra-pemrosesan (*normalisasi, windowing, dan pembagian data*), langkah selanjutnya adalah implementasi model *Deep Learning*. Tahap ini berfokus pada pembangunan arsitektur *Hybrid Bidirectional Long Short-Term Memory (BiLSTM)* dan *Bidirectional Gated Recurrent Unit (BiGRU)* yang merupakan inti dari penelitian ini. Pengembangan arsitektur ini didasari oleh kebutuhan untuk memodelkan deret waktu finansial yang kompleks dan non-linear, dengan memanfaatkan keunggulan Bi-LSTM dalam menangkap ketergantungan jangka panjang dan efisiensi komputasi dari Bi-GRU. Untuk memastikan model beroperasi pada performa terbaik, arsitektur yang dibangun wajib melalui proses optimasi *hyperparameter* menggunakan algoritma Hyperband.

#### 3.3.1 Arsitektur Model Bi-LSTM

Setelah data melalui tahap pra-pemrosesan, implementasi model dimulai dengan membangun arsitektur *Long Short-Term Memory (LSTM)* yang dikembangkan menjadi versi *bidirectional (Bi-LSTM)*. Pemilihan LSTM didasarkan pada kemampuannya yang superior dalam menangkap pola deret waktu jangka panjang melalui mekanisme *memory cell* dan gerbang kontrol informasi yang stabil, mengatasi kelemahan *vanishing gradient* pada *Recurrent Neural Network (RNN)* tradisional. Penggunaan arsitektur *bidirectional* memungkinkan jaringan untuk memproses data input dari dua arah secara simultan (*forward dan backward*). Secara konseptual, pendekatan ini memperkaya kemampuan model dalam mengenali pola fluktuasi harga saham karena dapat menganalisis konteks dari urutan data sebelumnya maupun data yang akan datang, sehingga menghasilkan representasi fitur yang lebih komprehensif. Model Bi-LSTM ini berfungsi sebagai basis arsitektur untuk memvalidasi efektivitas pendekatan *bidirectional* dalam prediksi deret waktu finansial.

#### 3.3.2 Arsitektur Model Bi-GRU

Langkah selanjutnya adalah mengembangkan model *Gated Recurrent Unit (GRU)* menjadi versi *bidirectional (Bi-GRU)*. GRU dipilih karena arsitekturnya yang lebih sederhana dan lebih efisien dibandingkan LSTM, menggunakan dua gerbang utama (*reset dan update gate*). Kesederhanaan ini bertujuan untuk mencapai efisiensi komputasi yang lebih tinggi, menghasilkan proses pelatihan yang lebih cepat dengan potensi risiko *overfitting* yang lebih rendah, khususnya dalam skenario di mana dataset tidak terlalu besar. Transformasi menjadi Bi-GRU tetap mempertahankan kemampuan membaca pola dua arah dengan kompleksitas perhitungan yang minimal. Model Bi-GRU digunakan untuk membandingkan trade-off antara kecepatan dan kemampuan penangkapan pola kompleks dibandingkan dengan Bi-LSTM, sebelum dilakukan penggabungan.

#### 3.3.3 Pengembangan Model Hybrid Bi-LSTM–Bi-GRU

Tahap ini merupakan inti dari penelitian, yaitu menggabungkan dua arsitektur sebelumnya menjadi model Hybrid Bi-LSTM–Bi-GRU. Model hibrida ini dirancang secara sekuensial: lapisan Bi-LSTM ditempatkan di bagian awal tumpukan untuk memprioritaskan ekstraksi pola temporal jangka panjang yang kompleks, kemudian dilanjutkan dengan lapisan Bi-GRU yang bertugas menyederhanakan representasi jangka pendek, meningkatkan stabilitas sinyal, dan mereduksi *noise* sebelum *output* disalurkan ke lapisan *Dense*. Kombinasi sinergis ini diharapkan mampu menghasilkan representasi data yang lebih kaya dan stabil dibandingkan model tunggal Bi-LSTM atau Bi-GRU. Namun, struktur hibrida yang kompleks memiliki potensi *overfitting* yang lebih tinggi. Oleh karena itu, performa optimal model ini sangat bergantung pada optimasi *hyperparameter*, di mana konfigurasi unit *neuron, dropout, optimizer, dan fungsi aktivasi* harus diatur secara cermat.

#### 3.3.4 Optimasi Hyperparameter Menggunakan Hyperband

Hyperband dipilih sebagai algoritma optimasi hyperparameter karena kecepatannya yang mampu menguji puluhan hingga ratusan kombinasi parameter secara efisien. Berbeda dengan *grid search* yang mencoba seluruh kombinasi tanpa strategi pengurangan, Hyperband menggunakan pendekatan *successive halving* untuk mengeliminasi konfigurasi yang kurang menjanjikan sejak awal. Dalam eksperimen ini, Hyperband melakukan tuning terhadap beberapa hyperparameter penting



yaitu jumlah unit Bi-LSTM (32–128), jumlah unit Bi-GRU (32–128), Dropout (0.1–0.5), Optimizer (Adam atau RMSprop), Fungsi aktivasi (*tanh* atau *relu*)

Hyperband menjalankan banyak kombinasi pada *epoch* kecil, kemudian melanjutkan hanya konfigurasi terbaik untuk *epoch* lebih besar. Dari seluruh percobaan, Hyperband menghasilkan satu set hyperparameter terbaik yang kemudian digunakan untuk membangun dan melatih ulang model. Konfigurasi terbaik yang dihasilkan oleh algoritma Hyperband disajikan dalam Tabel 2:

**Tabel 2.** Hasil Hyperparameter Terbaik

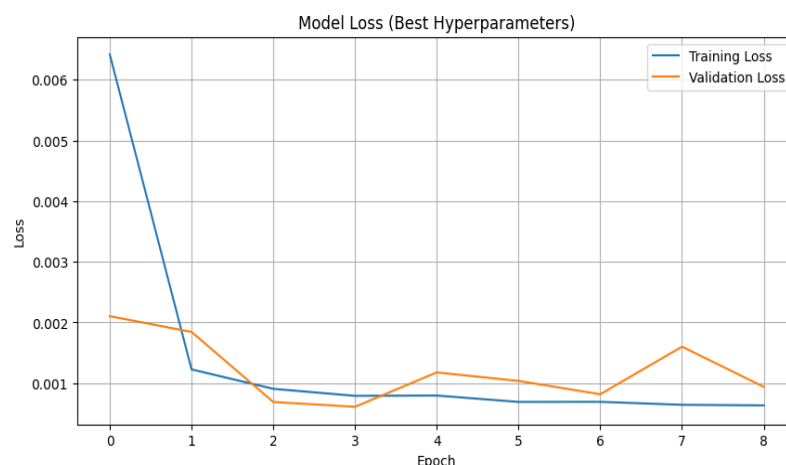
Parameter	Konfigurasi Terbaik
Units LSTM	128
Units GRU	32
Dropout	0.2
Optimizer	Adam
Activation	Tanh

Hasil *tuning* Hyperband yang disajikan pada Tabel 2 menunjukkan bahwa konfigurasi optimal berada pada lapisan Bi-LSTM dengan 128 unit dan lapisan Bi-GRU dengan 32 unit. Komposisi ini menegaskan pentingnya lapisan Bi-LSTM yang memiliki kapasitas memori lebih besar untuk menangkap *long-term dependencies*, yang kemudian direduksi dan distabilkan oleh lapisan Bi-GRU yang lebih ringkas. Penggunaan *Dropout* moderat sebesar 0.2 berfungsi efektif dalam mencegah *overfitting* tanpa menghambat proses pembelajaran. Pemilihan *Optimizer* Adam dan fungsi aktivasi *tanh* juga memberikan kontribusi besar terhadap performa. *Optimizer* Adam mampu menjaga stabilitas *gradien*, sementara fungsi aktivasi *tanh* seringkali lebih disukai dalam model RNN karena rentangnya yang terpusat di sekitar nol membantu mengatasi masalah *gradient vanishing* atau kesulitan konvergensi.

Secara keseluruhan, hasil *tuning* ini membuktikan bahwa proses optimasi *hyperparameter* sangat penting dalam model *deep learning* berbasis deret waktu, karena konfigurasi yang spesifik dan teroptimasi menghasilkan perbedaan signifikan dalam performa prediksi.

### 3.3.5 Pemodelan Menggunakan Hyperparameter Terbaik

Setelah konfigurasi *hyperparameter* optimal berhasil diidentifikasi melalui algoritma Hyperband (sepaimana disajikan pada Tabel 2), model *hybrid* Bi-LSTM–Bi-GRU kemudian dibangun ulang sepenuhnya menggunakan kombinasi parameter terbaik tersebut. Model ini dilatih ulang hingga maksimal 100 *epoch* dengan implementasi mekanisme *early stopping* untuk mencegah *overfitting*. Pelatihan ulang model dengan *hyperparameter* optimal menunjukkan hasil yang signifikan pada stabilitas proses pembelajaran. Penurunan *loss* yang dicapai model menunjukkan konvergensi yang lebih cepat dan stabil, baik pada *training loss* maupun *validation loss*. Proses *loss* model disajikan pada Gambar 2.



**Gambar 2.** Grafik *Training Loss* dan *Validation Loss* Model dengan Hyperparameter Optimal

Grafik *training loss* pada Gambar 2 memperlihatkan tren penurunan yang cepat dan stabil sejak *epoch* awal. *Validation loss* juga menunjukkan penurunan yang harmonis dengan *training loss*, yang mengindikasikan bahwa model tidak hanya menghafal data latih, tetapi juga mampu melakukan generalisasi yang efektif pada data validasi. Meskipun terdapat sedikit fluktuasi pada *validation loss* setelah *epoch* ke-3, tren keseluruhan tetap stabil dan mendekati *training loss* hingga titik penghentian.

Model yang dihasilkan dari tahap ini memiliki komposisi parameter yang paling seimbang untuk mempelajari pola fluktuasi harga saham: lapisan Bi-LSTM secara efektif menangkap pola jangka panjang, Bi-GRU berperan menstabilkan pola jangka pendek, *dropout* (0.2) mencegah *overfitting*, dan *optimizer* Adam mempercepat konvergensi tanpa *gradient explosion*. Tahap pemodelan ulang ini menjadi bukti empiris bahwa optimasi *hyperparameter* yang tepat dapat meningkatkan efisiensi dan stabilitas performa model secara signifikan dibandingkan performa *baseline* awal.



### 3.4 Evaluasi Model

Evaluasi kinerja model merupakan tahap krusial untuk menilai seberapa baik model *Hybrid Bi-LSTM–Bi-GRU* yang telah dioptimasi mampu merepresentasikan dan memprediksi fluktuasi harga saham Bank Mandiri (BMRI). Evaluasi kinerja dilakukan menggunakan tiga metrik utama yang umum digunakan dalam prediksi deret waktu (*time series forecasting*), yaitu Root Mean Squared Error (RMSE), Mean Squared Error (MSE), dan Mean Absolute Error (MAE). Model dianggap memiliki performa yang baik apabila ketiga nilai metrik kesalahan tersebut bernilai kecil.

#### 3.4.1 Hasil Evaluasi Kuantitatif

Hasil evaluasi kuantitatif dilakukan pada data uji (*testing set*) untuk menilai kemampuan generalisasi model terhadap data baru. Hasil perhitungan metrik kesalahan, baik dalam skala normalisasi (0–1) maupun skala asli (Rupiah), disajikan pada Tabel 3.

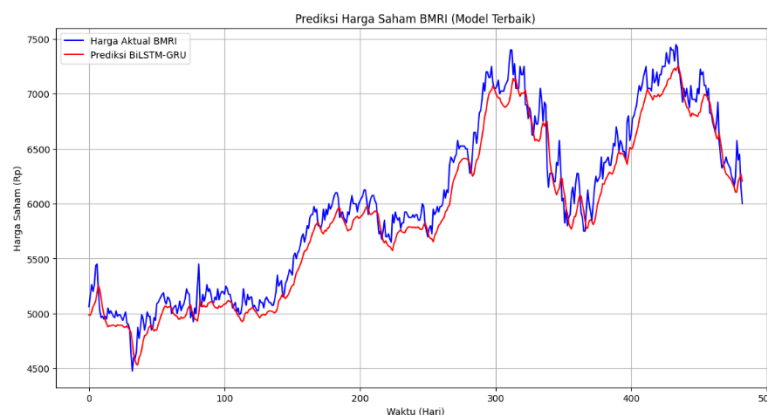
**Tabel 3.** Hasil Evaluasi Kuantitatif Akhir Model

Metric	Scale 0-1	Rupiah (Asli)
MAE	0.02549767	142.53
MSE	0.00094030	29382.58
RMSE	0.03066432	171.41

Tabel 3 menunjukkan bahwa model yang telah dioptimasi dengan *hyperparameter* terbaik mampu mencapai nilai kesalahan yang sangat rendah. Nilai RMSE sebesar 171.41 Rupiah menunjukkan bahwa rata-rata penyimpangan prediksi model dari harga aktual berada pada skala yang kecil dan mudah diinterpretasikan dalam satuan mata uang asli. Sementara itu, nilai MAE sebesar 142.53 Rupiah menunjukkan rata-rata besar kesalahan prediksi tanpa dipengaruhi oleh kuadrat kesalahan, menandakan stabilitas prediksi model terhadap fluktuasi tajam pada data. Nilai MSE sebesar 0.00094030 dalam skala 0–1 mengindikasikan bahwa proses pelatihan telah efektif dalam meminimalkan kesalahan kuadrat. Kombinasi nilai ketiga metrik yang rendah ini secara keseluruhan membuktikan kemampuan prediksi yang baik dari model *Hybrid Bi-LSTM–Bi-GRU*.

#### 3.4.2 Hasil Evaluasi Visual

Untuk memvalidasi kesimpulan dari metrik kuantitatif, performa prediksi divisualisasikan melalui perbandingan antara Harga Aktual saham BMRI dengan Hasil Prediksi model pada data uji (*testing set*). Grafik perbandingan tersebut disajikan pada Gambar 3.



**Gambar 3.** Prediksi Harga Saham BMRI (Model Terbaik) vs. Harga Aktual

Gambar 3 menunjukkan bahwa garis prediksi model (*Prediksi BiLSTM-GRU*, warna merah) mampu mengikuti tren pergerakan Harga Aktual BMRI (warna biru) dengan sangat erat. Model berhasil menangkap tren kenaikan dan penurunan harga saham secara akurat selama periode pengujian. Meskipun terdapat sedikit penyimpangan pada titik volatilitas ekstrem (misalnya, di sekitar Hari ke-50 dan Hari ke-300), kurva prediksi secara umum mempertahankan tingkat kedekatan yang tinggi dengan data aktual, sesuai dengan nilai RMSE yang rendah. Keberhasilan ini secara visual memperkuat temuan kuantitatif, mengindikasikan bahwa arsitektur *Hybrid Bi-LSTM–Bi-GRU*, setelah melalui optimasi Hyperband, memiliki kemampuan generalisasi yang efektif dan andal untuk memodelkan dinamika pasar saham yang non-linear.

### 3.5 Pembahasan

Pembahasan hasil penelitian ini difokuskan pada interpretasi kinerja model *Hybrid Bi-LSTM–Bi-GRU* yang telah dioptimasi menggunakan algoritma Hyperband, serta validasi efektivitas arsitektur gabungan dalam memprediksi harga saham BMRI. Hasil yang diperoleh menunjukkan bahwa seluruh tahapan metodologi, mulai dari pra-pemrosesan data hingga optimasi *hyperparameter*, berkontribusi signifikan terhadap akurasi model. Efektivitas pemodelan dimulai dari



penetapan arsitektur hibrida. Pemilihan Bi-LSTM sebagai lapisan awal berfungsi efektif untuk menangkap ketergantungan deret waktu jangka panjang yang kompleks, sementara lapisan Bi-GRU memberikan efisiensi komputasi dan berperan menstabilkan sinyal jangka pendek. Konfigurasi optimal yang ditemukan oleh Hyperband (Bi-LSTM: 128 unit; Bi-GRU: 32 unit; Dropout: 0.2; Optimizer: Adam; Activation: tanh) mendukung sinergi ini, di mana Bi-LSTM dialokasikan unit yang lebih besar untuk fungsi memori, dan Bi-GRU yang lebih kecil untuk efisiensi. Hal ini menunjukkan bahwa arsitektur hibrida memang memerlukan *hyperparameter* yang tidak simetris antara kedua unit untuk mencapai kinerja terbaik. Konvergensi proses pelatihan model yang dilatih ulang dengan parameter optimal menunjukkan stabilitas yang tinggi, dibuktikan dengan grafik *loss* yang harmonis antara *Training Loss* dan *Validation Loss* (Gambar 2). Stabilitas ini mengindikasikan bahwa penggunaan *dropout* moderat dan *optimizer* Adam efektif mencegah *overfitting* dan *gradient explosion*, sehingga model mampu melakukan generalisasi secara efektif pada data yang belum pernah dilihat. Pada evaluasi akhir, model berhasil mencapai performa kuantitatif yang sangat baik pada data uji. Nilai RMSE sebesar 171.41 Rupiah dan MAE sebesar 142.53 Rupiah membuktikan bahwa rata-rata kesalahan prediksi berada dalam batas deviasi yang kecil dan sangat dapat diterima dalam konteks fluktuasi harga saham harian. Nilai RMSE yang sedikit lebih tinggi daripada MAE menunjukkan adanya beberapa *outlier* atau volatilitas ekstrem yang ditekankan oleh metrik kuadrat, namun secara keseluruhan, akurasi model tetap tinggi. Secara visual, hasil ini dikonfirmasi oleh Grafik Prediksi (Gambar 3) yang menunjukkan bahwa garis prediksi model (*Hybrid* Bi-LSTM–Bi-GRU) mengikuti kurva harga aktual saham BMRI dengan tingkat kedekatan yang superior, bahkan pada periode volatilitas tinggi. Hasil penelitian ini sejalan dengan penelitian terdahulu yang menunjukkan bahwa sistem gabungan (hibrida) seringkali memiliki performa lebih tinggi dibandingkan model tunggal [20]. Dengan memanfaatkan kekuatan Bi-LSTM untuk konteks panjang dan efisiensi Bi-GRU untuk konteks pendek, model berhasil mengatasi sifat non-linear dan volatilitas tinggi pada data harga saham, menegaskan bahwa optimasi *hyperparameter* menggunakan Hyperband adalah kunci untuk memaksimalkan performa prediksi dalam pemodelan deret waktu *deep learning*.

#### 4. KESIMPULAN

Penelitian ini bertujuan untuk mengoptimalkan kinerja model *Deep Learning* Hybrid Bidirectional LSTM–GRU dalam memprediksi harga saham PT Bank Mandiri (BMRI) dengan menerapkan optimasi *hyperparameter* menggunakan algoritma Hyperband. Berdasarkan analisis metodologi dan hasil pengujian yang telah dilakukan, dapat ditarik beberapa kesimpulan utama. Pertama, efektivitas arsitektur hibrida dan *bidirectional* terbukti mampu mengatasi sifat non-linear dan volatilitas tinggi pada data deret waktu finansial. Kombinasi lapisan Bi-LSTM dan Bi-GRU memanfaatkan keunggulan Bi-LSTM dalam manajemen memori jangka panjang dan efisiensi Bi-GRU dalam stabilitas komputasi. Kedua, algoritma Hyperband berhasil menemukan konfigurasi *hyperparameter* paling optimal, yaitu 128 unit Bi-LSTM, 32 unit Bi-GRU, *Dropout* 0.2, *Optimizer* Adam, dan fungsi *Activation* tanh. Konfigurasi yang tidak simetris ini (128 vs 32 unit) menegaskan bahwa alokasi sumber daya pada lapisan yang berbeda sangat krusial untuk memaksimalkan sinergi model *hybrid*. Penerapan *early stopping* pada model yang dioptimasi ini juga berhasil mencapai konvergensi yang stabil dengan *Validation Loss* yang harmonis dengan *Training Loss* (Gambar 2), menunjukkan kemampuan generalisasi yang tinggi. Ketiga, kinerja prediksi model dinilai sangat akurat. Evaluasi pada data uji menghasilkan nilai kesalahan yang rendah dengan Mean Absolute Error (MAE): 142.53 Rupiah, Root Mean Squared Error (RMSE): 171.41 Rupiah, dan Mean Squared Error (MSE): 29382.58. Nilai RMSE 171.41 Rupiah menunjukkan bahwa rata-rata penyimpangan prediksi model dari harga aktual berada pada skala yang kecil dan dapat diterima dalam konteks perdagangan saham harian. Hasil visual dari grafik prediksi (Gambar 3) semakin memperkuat temuan ini, menunjukkan bahwa model mampu mengikuti pergerakan tren harga saham BMRI secara akurat. Dengan demikian, model *Hybrid* Bi-LSTM–Bi-GRU yang dioptimasi dengan Hyperband terbukti efektif dan andal untuk digunakan sebagai alat bantu prediksi harga saham.

#### REFERENCES

- [1] P. K. Dewi Lubis, H. H. Br Silalahi, A. Fitria Sinaga, P. Nidia Sapma, and V. Sitio, "Pasar Modal Dan Pengaruhnya Terhadap Perekonomian Di Indonesia," *JAKA (Jurnal Akuntansi, Keuangan, dan Audit.*, vol. 5, no. 1, pp. 196–214, 2024, doi: 10.56696/jaka.v5i1.10755.
- [2] A. Farhadi, A. Zamanifar, A. Alipour, A. Taheri, and M. Asadolahi, "A Hybrid LSTM-GRU Model for Stock Price Prediction," *IEEE Access*, vol. 13, no. May, pp. 117594–117618, 2025, doi: 10.1109/ACCESS.2025.3586558.
- [3] I. Sukartaatmadja, S. Khim, and M. N. Lestari, "Faktor-faktor Yang Mempengaruhi Harga Saham Perusahaan," *J. Ilm. Manaj. Kesatuan*, vol. 11, no. 1, pp. 21–40, 2023, doi: 10.37641/jimkes.v11i1.1627.
- [4] D. Satria, "Predicting Banking Stock Prices Using Rnn, Lstm, and Gru Approach," *Appl. Comput. Sci.*, vol. 19, no. 1, pp. 82–94, 2023, doi: 10.35784/acs-2023-06.
- [5] B. Y. Dwiandiyanta, R. Hartanto, and R. Ferdiana, "Optimization of Stock Predictions on Indonesia Stock Exchange: A New Hybrid Deep Learning Method," *Eng. Technol. Appl. Sci. Res.*, vol. 15, no. 1, pp. 19370–19379, 2025, doi: 10.48084/etasr.9363.
- [6] G. Prasad, S. K. Sahoo, and H. Kaur, "A Comparative Study on Conventional Methods and Machine Learning Approaches on Stock Market Prediction," *SSRN Electron. J.*, 2024, doi: 10.2139/ssrn.4824929.
- [7] W. Hastomo, A. S. B. Karno, N. Kalbuana, E. Nisfiani, and L. ETP, "Optimasi Deep Learning untuk Prediksi Saham di Masa Pandemi Covid-19," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 7, no. 2, pp. 133–140, 2021, doi: 10.26418/jp.v7i2.47411.
- [8] K. Liu, J. Cheng, and J. Yi, "Copper price forecasted by hybrid neural network with Bayesian Optimization and wavelet transform," *Resour. Policy*, vol. 75, no. December 2021, p. 102520, 2022, doi: 10.1016/j.resourpol.2021.102520.



- [9] M. Majid, J. Altaie, M. H. Tuama, R. O. Dirchal, and W. M. Mashloosh, "An Enhanced LSTM-Based Model for Stock Price Forecasting Using Feature Engineering and Advanced Hyperparameter Optimization," *Int. J. Hum. Comput. Stud.*, vol. 7, no. December, pp. 156–161, 2025, doi: 10.31149/ijhcs.v7i3.5555.
- [10] Handhika Yanuar Pratama, "Dataset Saham Bank Indonesia 2014 - 2024," kaggle. [Online]. Available: <https://www.kaggle.com/datasets/cmglonly/dataset-saham-bank-indonesia-2014-2024>
- [11] Y. Zhang and G. M. Tumibay, "Stock Price Prediction Based on the Bi-GRU-Attention Model," *J. Comput. Commun.*, vol. 12, pp. 72–85, 2024, doi: 10.4236/jcc.2024.124007.
- [12] Y. Song and M. Chiangpradit, "Hyperband-Optimized CNN-BiLSTM with Attention Mechanism for Corporate Financial Distress Prediction," *Appl. Sci.*, vol. 5, pp. 1–27, 2025, doi: 10.3390/app15115934.
- [13] F. H. Sezgin, Ö. Algorabi, G. Sart, and M. Güler, "Hyperparameter-Optimized RNN , LSTM , and GRU Models for Airline Stock Price Prediction : A Comparative Study on THYAO and PGSUS," *Symmetry (Basel)*, vol. 17, no. 11, pp. 1–19, 2025, doi: 10.3390/sym17111905.
- [14] A. Ritonga, A. Ma, and I. Suwamo, "Stock Price Forecasting with Multivariate Time Series Long Short-Term Memory : A Deep Learning Approach," *J. Robot. Control*, vol. 5, no. 5, pp. 1322–1335, 2024, doi: 10.18196/jrc.v5i5.22460.
- [15] I. Winarni and N. Pratiwi, "Prediksi Harga Saham Menggunakan Metode Long Short Term Memory Studi Kasus : Saham Intel Corporation," *J. Pendidik. Teknol. Inf.*, vol. 5, no. 2, pp. 380–390, 2025, doi: 10.51454/decode.v5i2.1192.
- [16] O. Harris and M. Andrews, "Effects and Results of Dropout Layer in Reducing Overfitting with Convolutional Neural Networks (CNN)," *World Journal of Advanced Engineering Technology and Sciences*, vol. 13, no. 2, pp. 836–853, 2024, doi: 10.30574/wjaets.2024.13.2.0584.
- [17] E. Sayed, M. El Kenawy, A. Ali, and A. Nima, "Predicting Potato Crop Yield with Machine Learning and Deep Learning for Sustainable Agriculture", *Potato Research* vol. 68, no. 1, pp. 759-792, 2025. doi: 10.1007/s11540-024-09753-w.
- [18] T. O. Hodson, "Root-mean-square error ( RMSE ) or mean absolute error ( MAE ) : when to use them or not," *Geosci. Model Dev.*, vol. 7, no. 2, pp. 5481–5487, 2022, doi: 10.5194/gmd-15-5481-2022.
- [19] D. Setiawan, T. W. E. Suryawijaya , M. I. Anugrah, J. Pearl, and A. N. Chasanah, "Optimizing Banking Stock Price Prediction: Deep Learning Based Approach," *Int. J. Accounting, Manag. Econ. Res.*, vol. 2, no. 1, pp. 111–125, 2024, doi: 10.56696/ijamer.v2i1.30.
- [20] M. Saberironaghi, J. Ren, and A. Saberironaghi, "Stock Market Prediction Using Machine Learning and Deep Learning Techniques : A Review," *AppliedMath*, vol. 5, no. 76, 2025, doi: 10.3390/appliedmath5030076.