



Optimasi Hyperparameter Bi-Directional Long Short Term Memory Menggunakan Particle Swarm Optimization Untuk Prediksi Saham BBRI

Made Arya Adi Yoga¹, Andreas Perdana²

madea8116@gmail.com¹, andreas.perdana@dharmawacana.ac.id²

^{1,2} Universitas Dharma Wacana, Metro, Indonesia

*Korespondensi: ✉ madea8116@gmail.com

Abstrak

The capital market, particularly banking stocks such as PT Bank Rakyat Indonesia (Persero) Tbk. (BBRI), exhibits volatile and non-linear price movements that are difficult to predict with conventional methods. This study aims to improve BBRI stock price prediction by integrating Bi-Directional Long Short Term Memory (Bi-LSTM) and Particle Swarm Optimization (PSO). Historical daily data for BBRI.JK from November 11, 2003, to December 29, 2023, were collected using yfinance and transformed into a multivariate dataset consisting of 14 features, including Close, Volume, returns, moving averages, volatility, RSI, MACD, and price-range variables. After feature engineering and missing-value removal, 4,940 records were used. The data were split chronologically into training, validation, and testing sets, normalized with Min-Max Scaler fitted only on the training data, and arranged into 45-step sequences. PSO optimized hidden size, number of layers, learning rate, dropout rate, batch size, and sequence length based on validation performance. The best configuration was hidden size 256, one layer, learning rate 0.001856, dropout 0.00, batch size 32, and sequence length 45. The final PSO-Bi-LSTM model achieved RMSE 105.47, MAE 84.59, and MAPE 2.21%, outperforming LSTM and Bi-LSTM baselines. Walk-forward validation produced an average MAPE of 2.55%. These results show that PSO-based hyperparameter optimization improves Bi-LSTM performance for BBRI stock prediction, although the model should support rather than replace investment decision-making.

Status Artikel:

Diterima: 14-05-2026

Direvisi: 18-05-2026

Diterima: 02-06-2026

Kata Kunci:

BBRI.

Bi-LSTM.

Deep Learning.

hyperparameter.

PSO.



© 2026 Made Arya Adi Yoga, Andreas Perdana

This work is licensed under a

[Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/).

PENDAHULUAN

Investasi pasar modal berperan penting dalam aktivitas ekonomi karena menyediakan ruang alokasi dana bagi investor dan sumber pembiayaan bagi perusahaan. Dalam konteks Indonesia, saham sektor perbankan sering menjadi perhatian karena memiliki kapitalisasi dan likuiditas yang besar. PT Bank Rakyat Indonesia (Persero) Tbk. (BBRI) merupakan salah satu saham perbankan yang banyak diamati investor. Namun, harga saham BBRI tetap bergerak

secara fluktuatif karena dipengaruhi oleh kondisi makroekonomi, sentimen pasar, kebijakan keuangan, dan dinamika perdagangan harian. Sifat data yang non-linear dan berubah menurut waktu membuat prediksi harga saham tidak cukup jika hanya mengandalkan pendekatan statistik konvensional. Pada tahap awal, penelitian prediksi pasar banyak membandingkan metode statistik, machine learning, dan deep learning untuk melihat kemampuan masing-masing model dalam membaca pola keuangan

(Jiang, 2021; Li & Bastos, 2020). Kajian berikutnya menunjukkan bahwa deep learning semakin dominan karena mampu menangkap hubungan non-linear dan ketergantungan temporal pada data pasar saham (Jiang, 2021; Li & Bastos, 2020). Dalam perkembangan terbaru, penelitian juga mulai menekankan pentingnya rancangan model, pemilihan fitur, dan evaluasi yang lebih hati-hati agar hasil prediksi tidak hanya rendah secara error, tetapi juga relevan secara praktis (Mintarya et al., 2023; Phuoc et al., 2024; Sonkavde et al., 2023).

Literatur terbaru menunjukkan bahwa model deep learning banyak digunakan untuk memodelkan data keuangan karena mampu mengenali pola deret waktu yang kompleks. LSTM menjadi salah satu model yang dominan karena mampu menyimpan informasi jangka panjang dan mengurangi masalah vanishing gradient (Bintang & Suhirman, 2025). Dalam konteks prediksi saham, LSTM telah digunakan untuk menangkap pola temporal dan terbukti mampu memberikan hasil kompetitif dibandingkan pendekatan konvensional (Fischer & Krauss, 2018; Nelson et al., 2017). Pengembangan selanjutnya menunjukkan bahwa kombinasi LSTM dengan proses ekstraksi fitur atau model pembelajaran lain dapat meningkatkan kemampuan model dalam membaca pola pasar yang kompleks (Bao et al., 2017; Chong et al., 2017). Dalam arsitektur dua arah, Bi-LSTM digunakan untuk menangkap representasi sekuens dari arah forward dan backward dalam jendela historis, sehingga informasi temporal dapat dipelajari secara lebih kaya. Beberapa studi pada data saham menunjukkan bahwa Bi-LSTM dan variasinya mampu menghasilkan prediksi yang baik ketika konfigurasi model dirancang secara tepat (Amzad Chy et al., 2024; Puteri, 2023; Swarnalata Rath et al., 2024). Dalam konteks Indonesia, penelitian mengenai LSTM, Bi-LSTM, dan model hibrida juga mulai berkembang pada saham emiten tertentu dan skema prediksi rekursif (Darja et al., 2025; Kwanda et al., 2024; Pramudya et al., 2025; Wei & Wang, 2025). Selain itu, model hibrida yang menggabungkan mekanisme pembelajaran temporal dan representasi fitur yang lebih kompleks juga dilaporkan mampu memperkuat performa prediksi (Bintang & Suhirman, 2025).

Meskipun demikian, kajian terdahulu juga menegaskan bahwa performa deep learning dalam prediksi saham tidak hanya ditentukan oleh pemilihan arsitektur. Akurasi model sangat dipengaruhi oleh proses pra-pemrosesan, teknik pembagian data, panjang sekuens, pemilihan fitur, dan strategi validasi (Hewamalage et al., 2021; Lim & Zohren, 2021). Selain faktor desain data, konfigurasi hyperparameter seperti hidden size, jumlah layer, dropout rate, learning rate, batch size, dan epoch juga menentukan stabilitas hasil pelatihan (Akşehir & Kılıç, 2024; Sezer et al., 2020). Beberapa studi lain menunjukkan bahwa dekomposisi frekuensi dan model hibrida dapat membantu model menangkap pola volatil, tetapi tetap membutuhkan rancangan eksperimen yang tepat agar hasilnya stabil dan tidak bergantung pada satu skenario pengujian (Niu et al., 2020; Rezaei et al., 2021). Dengan demikian, penggunaan arsitektur yang lebih kompleks belum tentu menghasilkan prediksi yang lebih baik apabila konfigurasi model tidak dioptimasi secara sistematis.

Dalam kelompok penelitian lain, optimasi hyperparameter mulai digunakan untuk meningkatkan stabilitas dan akurasi model prediksi saham. Particle Swarm Optimization (PSO) relevan digunakan karena dapat mengeksplorasi ruang pencarian parameter secara populatif, sederhana, dan relatif efisien dibandingkan pencarian manual atau grid search (Burhan et al., 2026). Pada data keuangan, PSO dapat membantu model menemukan kombinasi parameter yang lebih sesuai ketika data memiliki pola bising dan volatil (Henrique et al., 2019; Makridakis et al., 2018). Dalam studi prediksi saham Indonesia, integrasi LSTM dan PSO juga menunjukkan bahwa optimasi dapat memperbaiki kualitas prediksi dibandingkan penggunaan konfigurasi manual (Burhan et al., 2026). Selain PSO, pendekatan optimasi dan hibridisasi juga digunakan pada model CNN-LSTM, Bi-LSTM, dan deret waktu lain untuk meningkatkan kestabilan prediksi (Saini & Nagpal, 2024; Vidal & Kristjanpoller, 2020). Variasi representasi data, seperti konversi deret waktu menjadi citra, menunjukkan bahwa pola pasar dapat dipelajari melalui bentuk fitur visual (Sezer & Ozbayoglu, 2018). Sementara itu, pemanfaatan fitur limit order book menunjukkan bahwa informasi mikrostruktur pasar dapat memperkaya prediksi, meskipun noise pasar tetap menjadi tantangan utama (Afrianto et al., 2022; Tsantekidis et al., 2020). Namun, sebagian studi masih berfokus pada LSTM standar, indeks pasar global, saham non-perbankan, atau belum menempatkan Bi-LSTM dan PSO secara eksplisit dalam kerangka evaluasi perbandingan yang terstruktur (Asnawiyah & Eka Putra, 2025).

Berdasarkan pemetaan tersebut, celah penelitian ini terletak pada masih terbatasnya kajian yang secara khusus mengoptimasi hyperparameter Bi-LSTM menggunakan PSO untuk prediksi harga saham BBRI sebagai saham perbankan Indonesia (Ramadhanti et al., 2025). Kebaruan penelitian ini tidak hanya berada pada penggunaan PSO dan Bi-LSTM, tetapi pada penerapan kombinasi keduanya untuk data BBRI dengan tahapan yang terukur: feature engineering multivariat, pembagian data secara kronologis, normalisasi yang menghindari data leakage, pembentukan sekuens 45 langkah waktu berdasarkan hasil optimasi, optimasi parameter melalui PSO, dan perbandingan langsung dengan LSTM serta Bi-LSTM tanpa optimasi.

Penelitian ini bertujuan untuk menganalisis bagaimana PSO digunakan dalam mengoptimasi hyperparameter Bi-LSTM dan mengukur sejauh mana integrasi PSO-Bi-LSTM dapat meningkatkan akurasi prediksi harga saham BBRI dibandingkan model LSTM dan Bi-LSTM. Kontribusi penelitian ini adalah menyediakan bukti empiris bahwa optimasi hyperparameter dapat menjadi faktor penentu dalam peningkatan performa model prediksi saham, terutama ketika model diterapkan pada data saham perbankan Indonesia yang fluktuatif.

METHODS

1. Data Penelitian

Penelitian ini menggunakan data historis harga saham harian PT Bank Rakyat Indonesia (Persero) Tbk. dengan kode ticker BBRI.JK yang diunduh melalui pustaka yfinance. Periode data yang digunakan adalah 11 November 2003 sampai 31 Desember 2023, dengan hari perdagangan terakhir yang tersedia pada 29 Desember 2023. Variabel target yang diprediksi adalah harga penutupan (closing price), sedangkan variabel masukan menggunakan fitur

multivariat yang terdiri atas Close, Volume, Return, LogReturn, MA_5, MA_20, MA_60, STD_20, Volatility_20, RSI_14, MACD, MACD_Signal, HL_Range, dan OC_Range.

2. Pra-pemrosesan Data

Tahap pra-pemrosesan dilakukan untuk memastikan data siap digunakan dalam pemodelan deret waktu. Data harga saham terlebih dahulu dibersihkan dari nilai kosong dan diurutkan secara kronologis. Selanjutnya, dilakukan feature engineering untuk membentuk fitur teknikal seperti return, log return, moving average, volatilitas, RSI, MACD, serta rentang harga harian. Setelah proses feature engineering dan penghapusan nilai kosong, jumlah data yang digunakan menjadi 4.940 baris.

Normalisasi dilakukan menggunakan Min-Max Scaler dengan rentang nilai [0,1] sebagaimana dirumuskan berikut:

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}}$$

Untuk menghindari data leakage, parameter normalisasi dihitung hanya pada data latih, lalu digunakan untuk mentransformasikan data validasi dan data uji. Data kemudian dibentuk menjadi sekuens historis, dan panjang sekuens ikut dioptimasi melalui PSO. Berdasarkan hasil optimasi, panjang sekuens terbaik adalah 45 langkah waktu, sehingga model menggunakan 45 data historis sebelumnya untuk memprediksi harga pada waktu berikutnya.

3. Arsitektur Model

Penelitian ini menggunakan tiga model, yaitu LSTM, Bi-LSTM, dan PSO-Bi-LSTM. Model LSTM digunakan sebagai model pembanding dasar, model Bi-LSTM digunakan untuk menangkap representasi sekuens dua arah, sedangkan model PSO-Bi-LSTM merupakan model utama yang diusulkan, yaitu Bi-LSTM dengan hyperparameter yang dioptimasi menggunakan PSO. Seluruh model menggunakan masukan multivariat dengan 14 fitur.

Pada model baseline, konfigurasi awal yang digunakan adalah hidden size = 64, number of layers = 1, dropout = 0,1, learning rate = 0,001, batch size = 64, dan sequence length = 45 agar perbandingan dengan model hasil PSO tetap adil. Untuk model Bi-LSTM, keluaran dari lapisan dua arah digabungkan dan diteruskan ke lapisan fully connected untuk menghasilkan prediksi akhir.

Secara umum, representasi Bi-LSTM dituliskan sebagai berikut:

$$\begin{aligned}h_t^f &= \text{LSTM}_{\text{forward}}(x_t, h_{t-1}^f) \\h_t^b &= \text{LSTM}_{\text{backward}}(x_t, h_{t+1}^b) \\h_t &= [h_t^f; h_t^b] \\y_t &= Wh_t + b\end{aligned}$$

Dalam penelitian ini, pemrosesan dua arah dilakukan pada sekuens historis sepanjang 45 langkah waktu yang merupakan hasil optimasi PSO. Model tidak menggunakan data aktual

setelah titik prediksi, tetapi memanfaatkan representasi dua arah di dalam jendela historis yang sama.

4. Optimasi hyperparameter dengan Particle Swarm Optimization

Untuk meningkatkan performa model Bi-LSTM, penelitian ini menerapkan (PSO) untuk mencari kombinasi hyperparameter terbaik. Hyperparameter yang dioptimasi meliputi hidden size pada rentang 32-256, number of layers pada rentang 1-2, learning rate pada rentang 0,0001-0,003, dropout rate pada rentang 0-0,30, batch size pada pilihan 16, 32, dan 64, serta sequence length pada pilihan 30, 45, 60, dan 90.

PSO dijalankan menggunakan 20 partikel dan 30 iterasi. Setiap partikel merepresentasikan satu kandidat kombinasi hyperparameter. Kinerja setiap partikel dievaluasi menggunakan performa pada data validasi. Pada tahap optimasi, setiap kandidat model dilatih maksimum 40 epoch dengan early stopping patience sebesar 8 untuk mempercepat proses pencarian parameter terbaik.

Persamaan pembaruan kecepatan dan posisi partikel adalah sebagai berikut:

$$v_{id}^{t+1} = wv_{id}^t + c_1r_1(pbest_{id} - x_{id}^t) + c_2r_2(gbest_{id} - x_{id}^t)$$
$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1}$$

Nilai bobot inersia (w) dibuat menurun secara linier selama iterasi optimasi dari 0,9 menjadi 0,4. Parameter percepatan individu dan sosial masing-masing ditetapkan sebesar 1,5. Berdasarkan proses optimasi, kombinasi hyperparameter terbaik adalah hidden size = 256, number of layers = 1, learning rate = 0,001856, dropout rate = 0,00, batch size = 32, dan sequence length = 45.

5. Proses Pelatihan Model

Seluruh model dilatih menggunakan optimizer Adam dan loss function Mean Squared Error (MSE). Adam dipilih karena umum digunakan pada pelatihan jaringan saraf berbasis gradien dan mampu menyesuaikan laju pembelajaran secara adaptif (Diash et al., 2025; Simamora et al., 2025). Proses pelatihan dilakukan dengan framework TensorFlow/Keras, menggunakan early stopping dan ReduceLROnPlateau untuk menjaga stabilitas pelatihan.

Untuk model pembanding LSTM dan Bi-LSTM, proses pelatihan dilakukan dengan learning rate = 0,001, batch size = 64, maksimum epoch = 150, dan early stopping patience = 15.

Sementara itu, model akhir PSO-Bi-LSTM dilatih menggunakan hyperparameter terbaik hasil optimasi PSO, yaitu hidden size 256, satu layer, learning rate 0,001856, dropout 0,00, batch size 32, dan sequence length 45. Pelatihan model akhir menggunakan maksimum epoch = 150 dan early stopping patience = 15. Model terbaik disimpan berdasarkan nilai validation loss terendah, kemudian digunakan pada tahap evaluasi akhir terhadap data uji.

6. Evaluasi Model

Kinerja model dievaluasi menggunakan tiga metrik, yaitu Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Ketiga metrik tersebut digunakan agar evaluasi error lebih komprehensif.

Rumus evaluasi yang digunakan adalah:

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

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

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

Tabel 1. Interpretasi Nilai MAPE


Skala MAPE	Interpretasi
< 10%	Sangat Baik
10–20%	Baik
20–50%	Layak
> 50%	Buruk

Setelah prediksi dilakukan pada data uji, hasil prediksi dikembalikan ke skala harga asli melalui proses denormalization. Selanjutnya, nilai RMSE, MAE, dan MAPE dihitung untuk masing-masing model, yaitu LSTM, Bi-LSTM, dan PSO-Bi-LSTM. Selain evaluasi pada data uji, penelitian ini juga menambahkan walk-forward validation untuk melihat konsistensi performa model pada beberapa jendela waktu.

7. Tahapan Penelitian

Tahapan penelitian dilakukan secara berurutan sebagai berikut:

1. Mengunduh data historis saham BBRI dari Yahoo Finance menggunakan `yfinance`.
2. Melakukan pembersihan data dan membentuk fitur teknikal multivariat.
3. Membagi data menjadi data latih, validasi, dan uji secara kronologis.
4. Melakukan normalisasi dengan Min-Max Scaler.
5. Membentuk data sekuens dan mengoptimasi panjang sekuens melalui PSO.
6. Melatih model baseline LSTM dan Bi-LSTM.
7. Mengoptimasi hyperparameter Bi-LSTM menggunakan PSO.
8. Melatih model akhir PSO-Bi-LSTM dengan parameter terbaik hasil optimasi.
9. Melakukan prediksi pada data uji dan mengembalikan hasil ke skala harga asli.
10. Membandingkan kinerja model LSTM, Bi-LSTM, dan PSO-Bi-LSTM menggunakan RMSE, MAE, dan MAPE.

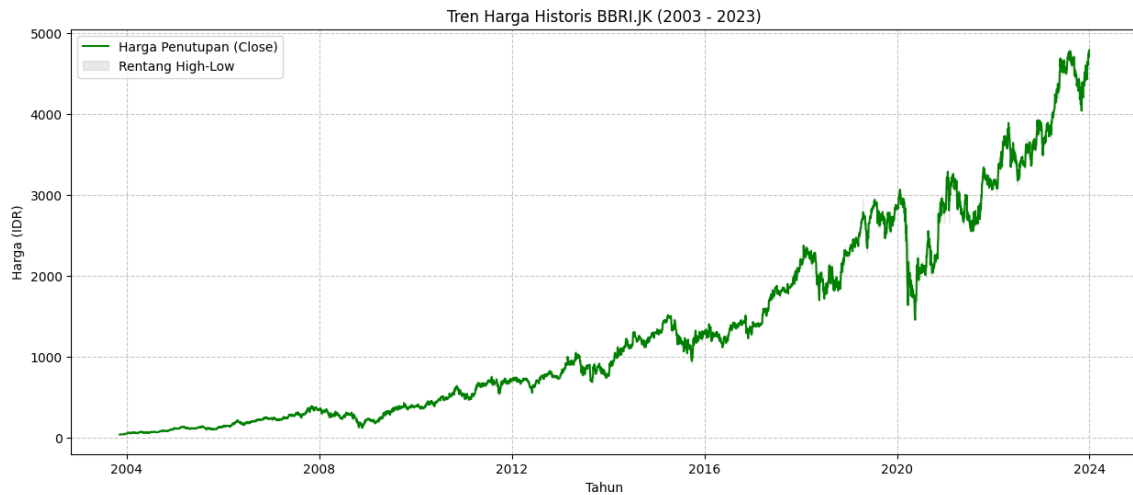


Gambar 1. Tahap penelitian

RESULTS AND DISCUSSION

1. Pengumpulan Data

Data penelitian ini menggunakan harga saham harian PT Bank Rakyat Indonesia (Persero) Tbk. (BBRI) yang diperoleh melalui Yahoo Finance. Dataset awal mencakup total 4.999 baris data dari periode 11 November 2003 hingga 29 Desember 2023. Setelah proses feature engineering dan penghapusan nilai kosong akibat perhitungan indikator teknikal, jumlah data yang digunakan dalam pemodelan menjadi 4.940 baris.



Gambar 2. Tren Harga Penutupan Historis Saham BBRI (2003-2023)

Berdasarkan Gambar 2, terlihat volatilitas yang tinggi dengan tren pertumbuhan jangka panjang pada harga saham BBRI. Hasil pembacaan data pada kode program menunjukkan nilai Close awal berada pada rentang minimum 36,2104 dan maksimum 4.499,5674. Rentang data yang lebar ini menuntut proses normalisasi agar model Bi-LSTM dapat belajar secara stabil.

2. Preprocessing Data

Pada tahap preprocessing, seluruh fitur numerik dinormalisasi menggunakan Min-Max Scaler agar perbedaan skala antarfitur tidak mendominasi pembaruan bobot jaringan saraf. Scaler hanya di-fit pada data latih, kemudian digunakan untuk mentransformasikan data validasi dan data uji. Dataset hasil feature engineering sebanyak 4.940 baris kemudian dibagi secara kronologis menjadi tiga bagian:

1. Data Latih (Training Data) sebesar 80% (3.952 baris), digunakan untuk melatih bobot dan bias model.
2. Data Validasi (Validation Data) sebesar 10% (494 baris), digunakan sebagai acuan PSO dalam mencari hyperparameter optimal dan sebagai pemicu early stopping.
3. Data Uji (Testing Data) sebesar 10% (494 baris), digunakan untuk evaluasi akhir pada data yang belum digunakan selama pelatihan model.

Pembagian data dilakukan tanpa shuffling agar ketergantungan temporal tetap terjaga. Periode data latih adalah 2 Februari 2004 sampai 6 Desember 2019, periode validasi adalah 9 Desember 2019 sampai 17 Desember 2021, dan periode pengujian adalah 20 Desember 2021 sampai 29 Desember 2023. Ringkasan preprocessing disajikan pada Tabel 2.

Tabel 2. Ringkasan Data dan Preprocessing

Komponen	Nilai	Periode	Keterangan
Data awal	4.999	2003-11-11 s.d. 2023-12-29	Unduhan BBRI.JK
Data siap model	4.940	2004-02-02 s.d. 2023-12-29	14 fitur teknikal

Komponen	Nilai	Periode	Keterangan
Latih	3.952	2004-02-02 s.d. 2019-12-06	80% kronologis
Validasi	494	2019-12-09 s.d. 2021-12-17	10% kronologis
Uji	494	2021-12-20 s.d. 2023-12-29	10% kronologis
Scaler / Sequence	Min-Max / 45	Fit pada data latih	Target Close

3. Hasil optimasi hyperparameter dengan PSO

Tahap krusial dalam penelitian ini adalah mencari hyperparameter optimal menggunakan Particle Swarm Optimization (PSO). Optimasi dilakukan sebanyak 30 iterasi dengan 20 partikel. Setiap partikel mengeksplorasi nilai hidden size, number of layers, learning rate, dropout rate, batch size, dan sequence length.

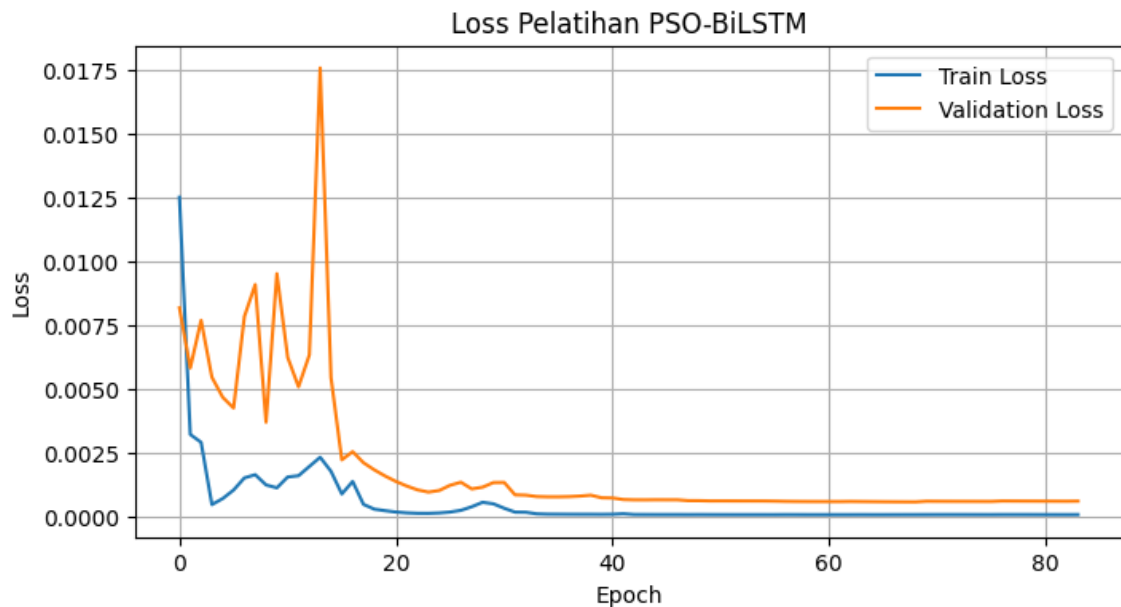
Kombinasi parameter terbaik yang ditemukan oleh PSO disajikan pada Tabel 3. Pada proses optimasi, nilai fitness terbaik mencapai 61,1636 dengan RMSE validasi 66,3052, MAE 49,1664, dan MAPE 2,0850%.

Tabel 3. Parameter Optimal Hasil Optimasi PSO

Parameter	Nilai Optimal
Hidden Size	256
Number of Layers	1
Learning Rate	0,001856
Dropout Rate	0,00
Batch Size	32
Sequence Length	45

4. Proses Pelatihan Model

Model Bi-LSTM dengan arsitektur optimal kemudian dilatih menggunakan maksimum 150 epoch. Untuk menjaga efisiensi dan mencegah overfitting, diterapkan early stopping dengan patience 15 dan penurunan learning rate otomatis. Pelatihan model akhir PSO-Bi-LSTM menggunakan sequence length terbaik sebesar 45, dengan bentuk data $X_{train}=(3907, 45, 14)$, $X_{val}=(494, 45, 14)$, dan $X_{test}=(494, 45, 14)$. Pelatihan akhir berjalan sampai epoch ke-84.



Gambar 3. Grafik Loss Pelatihan dan Validasi

Kurva loss pada Gambar 3 menunjukkan bahwa loss pelatihan menurun tajam pada awal epoch dan kemudian relatif stabil, sedangkan validation loss mengalami fluktuasi pada awal pelatihan sebelum menurun dan lebih stabil pada epoch berikutnya. Pola ini menunjukkan bahwa model mampu mempelajari pola time series saham BBRI tanpa indikasi overfitting yang ekstrem.

5. Evaluasi dan Perbandingan Kinerja Model

Setelah proses pelatihan selesai, seluruh model diuji dengan menggunakan data uji yang belum pernah dilihat selama proses pelatihan. Evaluasi dilakukan menggunakan tiga metrik, yaitu Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Tiga metrik ini digunakan agar dapat memberikan penjelasan yang lebih lengkap mengenai tingkat kesalahan yang dilakukan oleh setiap model.

Untuk memperoleh gambaran yang lebih objektif mengenai efektivitas pendekatan yang diusulkan, penelitian ini membandingkan performa tiga model, yaitu LSTM, Bi-LSTM, dan PSO-Bi-LSTM. Model LSTM digunakan sebagai baseline, Bi-LSTM digunakan untuk melihat pengaruh arsitektur dua arah, sedangkan PSO-Bi-LSTM digunakan untuk menilai dampak optimasi hyperparameter terhadap performa prediksi.

Tabel 4. Perbandingan Kinerja Model

Model	RMSE	MAE	MAPE (%)
LSTM	128,08	101,00	2,62%
Bi-LSTM	117,16	94,30	2,48%
PSO-Bi-LSTM	105,47	84,59	2,21%

Berdasarkan Tabel 4, model PSO-Bi-LSTM menghasilkan performa paling baik dengan RMSE 105,47, MAE 84,59, dan MAPE 2,21%. Nilai error ini lebih rendah dibandingkan

LSTM yang memperoleh RMSE 128,08, MAE 101,00, dan MAPE 2,62%, serta Bi-LSTM tanpa optimasi yang memperoleh RMSE 117,16, MAE 94,30, dan MAPE 2,48%. Berdasarkan interpretasi MAPE, seluruh model berada pada kategori sangat baik karena nilainya di bawah 10%, tetapi PSO-Bi-LSTM memiliki tingkat kesalahan paling kecil.

Secara kuantitatif, PSO-Bi-LSTM menurunkan RMSE sekitar 17,66%, MAE sekitar 16,24%, dan MAPE sekitar 15,62% dibandingkan LSTM. Dibandingkan Bi-LSTM tanpa optimasi, PSO-Bi-LSTM menurunkan RMSE sekitar 9,98%, MAE sekitar 10,29%, dan MAPE sekitar 10,80%. Hasil ini menunjukkan bahwa optimasi hyperparameter tetap memberikan kontribusi penting walaupun model pembanding sudah menggunakan arsitektur dua arah.


Tabel 5. Hasil Walk-forward Validation Model PSO-Bi-LSTM

Fold	RMSE	MAE	MAPE (%)
1	37,56	28,55	1,86%
2	95,19	79,43	3,55%
3	94,59	77,27	3,13%
4	80,17	62,76	1,67%
Mean ± Std	76,88 ± 27,11	62,01 ± 23,50	2,55 ± 0,93%

Hasil walk-forward validation pada Tabel 5 menunjukkan bahwa performa PSO-Bi-LSTM relatif konsisten pada beberapa periode pengujian. Rata-rata MAPE sebesar 2,55% masih berada pada kategori sangat baik, sehingga model tidak hanya baik pada satu pembagian data uji, tetapi juga cukup stabil pada skenario evaluasi bertahap.

6. Perbandingan Visual Harga Aktual vs Prediksi

Untuk memberikan gambaran yang lebih jelas mengenai performa model utama, hasil prediksi PSO-Bi-LSTM dibandingkan secara visual dengan harga aktual saham BBRI pada data uji. Visualisasi ini digunakan untuk melihat sejauh mana model mampu mengikuti pola pergerakan harga saham yang sebenarnya.



Gambar 4. Perbandingan Harga Aktual dan Hasil Prediksi Model PSO-Bi-LSTM

Berdasarkan Gambar 4, kurva prediksi yang dihasilkan oleh model PSO-Bi-LSTM terlihat mampu mengikuti pola pergerakan harga aktual dengan cukup baik. Kedekatan antara garis prediksi dan garis aktual menunjukkan bahwa model dapat menangkap tren umum serta sebagian fluktuasi harga saham pada periode data uji 2021-2023.

Meskipun demikian, pada beberapa titik masih terdapat selisih antara nilai prediksi dan nilai aktual, terutama ketika terjadi perubahan harga yang cepat. Hal ini menunjukkan bahwa model belum sepenuhnya mampu menangkap seluruh dinamika pasar yang sangat fluktuatif. Namun secara umum, hasil visual ini mendukung temuan kuantitatif pada Tabel 4 bahwa model PSO-Bi-LSTM memiliki performa prediksi yang baik dengan tingkat kesalahan relatif rendah.

7. Pembahasan

Hasil penelitian menunjukkan bahwa PSO-Bi-LSTM mampu menjawab tujuan penelitian, yaitu mengoptimasi hyperparameter Bi-LSTM dan meningkatkan akurasi prediksi harga saham BBRI. Parameter terbaik yang diperoleh PSO adalah hidden size 256, number of layers 1, learning rate 0,001856, dropout rate 0,00, batch size 32, dan sequence length 45. Kombinasi ini menghasilkan performa pengujian terbaik dengan RMSE 105,47, MAE 84,59, dan MAPE 2,21%.

Jika dibandingkan dengan LSTM dan Bi-LSTM tanpa optimasi, PSO-Bi-LSTM menghasilkan penurunan error yang konsisten. Dibandingkan LSTM, PSO-Bi-LSTM menurunkan RMSE sekitar 17,66%, MAE sekitar 16,24%, dan MAPE sekitar 15,62%. Dibandingkan Bi-LSTM tanpa optimasi, PSO-Bi-LSTM menurunkan RMSE sekitar 9,98%, MAE sekitar 10,29%, dan MAPE sekitar 10,80%. Temuan ini konsisten dengan studi dan Burhan et al. (2026) yang menunjukkan bahwa optimasi berbasis PSO dapat memperbaiki performa model deret waktu keuangan.

Temuan penelitian ini juga menunjukkan bahwa Bi-LSTM tanpa optimasi sudah memberikan hasil lebih baik daripada LSTM pada skenario fix, tetapi peningkatan tersebut masih dapat diperkuat melalui PSO. Hal ini dapat dijelaskan karena Bi-LSTM memiliki kompleksitas parameter yang lebih tinggi sehingga sensitif terhadap learning rate, dropout, batch size, jumlah hidden units, dan panjang sekuens. Dengan pencarian parameter yang

sistematis, model dapat menemukan konfigurasi yang lebih sesuai dengan karakteristik data saham BBRI.

Secara teoretis, hasil ini mendukung pandangan bahwa keberhasilan deep learning dalam prediksi keuangan bergantung pada kesesuaian antara karakteristik data, arsitektur model, fitur masukan, dan strategi pelatihan. Penggunaan fitur teknikal multivariat membantu model memperoleh informasi yang lebih kaya, sedangkan PSO membantu menentukan kombinasi parameter yang lebih stabil.

Dari sisi praktis, model PSO-Bi-LSTM dapat digunakan sebagai alat bantu analisis prediktif untuk membaca kecenderungan harga saham BBRI berdasarkan data historis. Meskipun demikian, nilai MAPE yang rendah tidak dapat langsung dimaknai sebagai jaminan keuntungan investasi. Harga saham tetap dipengaruhi oleh faktor eksternal seperti volume transaksi, suku bunga, inflasi, kebijakan pemerintah, laporan keuangan, dan sentimen pasar. Oleh sebab itu, model ini lebih tepat diposisikan sebagai pendukung keputusan, bukan sebagai dasar tunggal dalam pengambilan keputusan investasi.

Keterbatasan penelitian ini terletak pada cakupan fitur yang masih berfokus pada data harga historis dan indikator teknikal. Walaupun penelitian ini sudah menggunakan fitur multivariat, model belum memasukkan variabel fundamental, makroekonomi, mikrostruktur pasar, dan sentimen pasar. Penelitian selanjutnya perlu menguji tambahan volume perdagangan yang lebih detail, indikator teknikal lain, variabel makroekonomi, data sentimen, serta skema evaluasi walk-forward yang lebih luas agar ketahanan model pada data pasar yang berubah dapat diuji secara lebih kuat.

SIMPULAN

Penelitian ini membuktikan bahwa integrasi Particle Swarm Optimization (PSO) dengan Bi-Directional Long Short Term Memory (Bi-LSTM) dapat meningkatkan kinerja prediksi harga saham BBRI. PSO berhasil memperoleh kombinasi hyperparameter terbaik berupa hidden size 256, number of layers 1, learning rate 0,001856, dropout rate 0,00, batch size 32, dan sequence length 45. Dengan konfigurasi tersebut, model PSO-Bi-LSTM menghasilkan RMSE 105,47, MAE 84,59, dan MAPE 2,21%. Nilai ini lebih rendah dibandingkan LSTM dan Bi-LSTM tanpa optimasi, sehingga menunjukkan bahwa proses optimasi berperan penting dalam memperbaiki akurasi model.

Temuan utama penelitian ini adalah bahwa arsitektur Bi-LSTM dapat memberikan hasil yang lebih baik daripada LSTM, tetapi performanya masih bergantung pada kesesuaian hyperparameter. Bi-LSTM tanpa PSO memperoleh RMSE 117,16, MAE 94,30, dan MAPE 2,48%, sedangkan Bi-LSTM yang dioptimasi menggunakan PSO menghasilkan performa terbaik dengan RMSE 105,47, MAE 84,59, dan MAPE 2,21%. Dengan demikian, kontribusi penelitian ini terletak pada bukti empiris bahwa optimasi hyperparameter perlu ditempatkan sebagai bagian penting dalam pengembangan model deep learning untuk prediksi saham, khususnya pada saham perbankan Indonesia seperti BBRI.

Secara praktis, model PSO-Bi-LSTM dapat membantu investor atau analis sebagai alat bantu prediksi berbasis data historis dan indikator teknikal. Namun, model ini belum dapat dijadikan dasar tunggal dalam pengambilan keputusan investasi karena harga saham tetap dipengaruhi oleh faktor eksternal seperti kondisi makroekonomi, laporan keuangan, kebijakan pemerintah, dan sentimen pasar. Penelitian selanjutnya disarankan menambahkan variabel

fundamental, variabel makroekonomi, data sentimen, serta membandingkan PSO dengan metode optimasi lain untuk memperoleh evaluasi yang lebih komprehensif dan robust.

REFERENSI

- Afrianto, N., Fudholi, D. H., & Rani, S. (2022). Prediksi Harga Saham Menggunakan BiLSTM dengan Faktor Sentimen Publik. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 6(1), 41–46. <https://doi.org/10.29207/resti.v6i1.3676>
- Akşehir, Z. D., & Kılıç, E. (2024). Analyzing the critical steps in deep learning-based stock forecasting: A literature review. *PeerJ Computer Science*, 10, e2312. <https://doi.org/10.7717/peerj-cs.2312>
- Amzad Chy, Md. K., Muhammad Masum, A. K., Alam, M. S., Azad, Md. A. K., Hassan, Md. M., & Bhuiyan, T. (2024). Deep Learning-Based Stock Price Prediction: A Comprehensive Approach Using Bi-LSTM. *2024 4th International Conference on Ubiquitous Computing and Intelligent Information Systems (ICUIS)*, 805–810. <https://doi.org/10.1109/ICUIS64676.2024.10866126>
- Asnawiyah, & Eka Putra, R. (2025). Perbandingan Algoritma LSTM dan BiLSTM Untuk Analisis Sentimen Multi-Class Media Sosial Twitter. *Journal of Informatics and Computer Science (JINACS)*, 6(03), 778–786. <https://doi.org/10.26740/jinacs.v6n03.p778-786>
- Bao, W., Yue, J., & Rao, Y. (2017). A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PLOS ONE*, 12(7), e0180944. <https://doi.org/10.1371/journal.pone.0180944>
- Bintang, A. M., & Suhirman, S. (2025). Penerapan Long Short-Term Memory dalam Prediksi Harga Mingguan Bitcoin Berbasis Data Historis. *Jurnal Pustaka AI (Pusat Akses Kajian Teknologi Artificial Intelligence)*, 5(3), 688–694. <https://doi.org/10.55382/jurnalpustakaai.v5i3.1582>
- Burhan, D., Hasan, I. K., & Nashar, L. O. (2026). Analisis Peramalan Harga Saham PT Unilever Indonesia Menggunakan Pemodelan LSTM dengan Optimasi PSO. *Jurnal Riset Mahasiswa Matematika*, 5(3), 228–235. <https://doi.org/10.18860/jrmm.v5i3.40090>
- Chong, E., Han, C., & Park, F. C. (2017). Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. *Expert Systems with Applications*, 83, 187–205. <https://doi.org/10.1016/j.eswa.2017.04.030>
- Darja, R., Irwan, & Muh. Irwan. (2025). MEMPREDIKSIKAN HARGA SAHAM BANK RAKYAT INDONESIA (PERSERO) TBK MENGGUNAKAN METODE BIDIRECTIONAL LONG SHORT TERM MEMORY (BI-LSTM). *Jurnal INSTEK (Informatika Sains Dan Teknologi)*, 10(2), 472–483. <https://doi.org/10.24252/instek.v10i2.57438>
- Diash, H. D., Nathania, V., Idhom, M., & Trimono, T. (2025). Application of CNN-BiLSTM Algorithm for Ethereum Price Prediction. *Journal of Applied Informatics and Computing*, 9(4), 1709–1714. <https://doi.org/10.30871/jaic.v9i4.9757>
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>
- Henrique, B. M., Sobreiro, V. A., & Kimura, H. (2019). Literature review: Machine learning techniques applied to financial market prediction. *Expert Systems with Applications*, 124, 226–251. <https://doi.org/10.1016/j.eswa.2019.01.012>

- Hewamalage, H., Bergmeir, C., & Bandara, K. (2021). Recurrent Neural Networks for Time Series Forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1), 388–427. <https://doi.org/10.1016/j.ijforecast.2020.06.008>
- Jiang, W. (2021). Applications of deep learning in stock market prediction: Recent progress. *Expert Systems with Applications*, 184, 115537. <https://doi.org/10.1016/j.eswa.2021.115537>
- Kwanda, K., Herwindiati, D. E., & Lauro, M. D. (2024). Perbandingan LSTM dan Bidirectional LSTM pada Sistem Prediksi Harga Saham Berbasis Website. *Ranah Research : Journal of Multidisciplinary Research and Development*, 7(1), 26–35. <https://doi.org/10.38035/rrij.v7i1.1255>
- Li, A. W., & Bastos, G. S. (2020). Stock Market Forecasting Using Deep Learning and Technical Analysis: A Systematic Review. *IEEE Access*, 8, 185232–185242. <https://doi.org/10.1109/ACCESS.2020.3030226>
- Lim, B., & Zohren, S. (2021). Time-series forecasting with deep learning: A survey. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379(2194), 20200209. <https://doi.org/10.1098/rsta.2020.0209>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLOS ONE*, 13(3), e0194889. <https://doi.org/10.1371/journal.pone.0194889>
- Mintarya, L. N., Halim, J. N. M., Angie, C., Achmad, S., & Kurniawan, A. (2023). Machine learning approaches in stock market prediction: A systematic literature review. *Procedia Computer Science*, 216, 96–102. <https://doi.org/10.1016/j.procs.2022.12.115>
- Nelson, D. M. Q., Pereira, A. C. M., & De Oliveira, R. A. (2017). Stock market's price movement prediction with LSTM neural networks. *2017 International Joint Conference on Neural Networks (IJCNN)*, 1419–1426. <https://doi.org/10.1109/IJCNN.2017.7966019>
- Niu, H., Xu, K., & Wang, W. (2020). A hybrid stock price index forecasting model based on variational mode decomposition and LSTM network. *Applied Intelligence*, 50(12), 4296–4309. <https://doi.org/10.1007/s10489-020-01814-0>
- Phuoc, T., Anh, P. T. K., Tam, P. H., & Nguyen, C. V. (2024). Applying machine learning algorithms to predict the stock price trend in the stock market – The case of Vietnam. *Humanities and Social Sciences Communications*, 11(1), 393. <https://doi.org/10.1057/s41599-024-02807-x>
- Pramudya, E., Retnoningsih, D., & Ruswanti, D. (2025). *Implementasi Metode LSTM untuk Prediksi Harga Saham PT Indofood CBP Sukses Makmur Tbk*. 3.
- Puteri, D. I. (2023). Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah. *Euler : Jurnal Ilmiah Matematika, Sains Dan Teknologi*, 11(1), 35–43. <https://doi.org/10.34312/euler.v11i1.19791>
- Ramadhanti, A. R., Putri, S. R., Trimono, & Mohammad Idhom. (2025). Implementasi Model BiLSTM-Attention untuk Prediksi Nilai IHSG Berdasarkan Data Historis OHLCV. *Jurnal Ilmiah Media Sisfo*, 19(2), 98–108. <https://doi.org/10.33998/mediasisfo.2025.19.2.2392>
- Rezaei, H., Faaljou, H., & Mansourfar, G. (2021). Stock price prediction using deep learning and frequency decomposition. *Expert Systems with Applications*, 169, 114332. <https://doi.org/10.1016/j.eswa.2020.114332>
- Saini, P., & Nagpal, B. (2024). PSO-CNN-Bi-LSTM: A Hybrid Optimization-Enabled Deep Learning Model for Smart Farming. *Environmental Modeling & Assessment*, 29(3), 517–534. <https://doi.org/10.1007/s10666-023-09920-2>

- Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing*, 90, 106181. <https://doi.org/10.1016/j.asoc.2020.106181>
- Sezer, O. B., & Ozbayoglu, A. M. (2018). Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach. *Applied Soft Computing*, 70, 525–538. <https://doi.org/10.1016/j.asoc.2018.04.024>
- Simamora, F. P., Purba, R., & Pasha, M. F. (2025). Optimisasi Hyperparameter BiLSTM Menggunakan Bayesian Optimization untuk Prediksi Harga Saham. *Jambura Journal of Mathematics*, 7(1), 8–13. <https://doi.org/10.37905/jjom.v7i1.27166>
- Sonkavde, G., Dharrao, D. S., Bongale, A. M., Deokate, S. T., Doreswamy, D., & Bhat, S. K. (2023). Forecasting Stock Market Prices Using Machine Learning and Deep Learning Models: A Systematic Review, Performance Analysis and Discussion of Implications. *International Journal of Financial Studies*, 11(3), 94. <https://doi.org/10.3390/ijfs11030094>
- Swarnalata Rath, Das, N. R., & Pattanayak, B. K. (2024). Stacked BI-LSTM and E-Optimized CNN-A Hybrid Deep Learning Model for Stock Price Prediction. *Optical Memory and Neural Networks*, 33(2), 102–120. <https://doi.org/10.3103/S1060992X24700024>
- Tsantekidis, A., Passalis, N., Tefas, A., Kannianen, J., Gabbouj, M., & Iosifidis, A. (2020). Using Deep Learning for price prediction by exploiting stationary limit order book features. *Applied Soft Computing*, 93, 106401. <https://doi.org/10.1016/j.asoc.2020.106401>
- Vidal, A., & Kristjanpoller, W. (2020). Gold volatility prediction using a CNN-LSTM approach. *Expert Systems with Applications*, 157, 113481. <https://doi.org/10.1016/j.eswa.2020.113481>
- Wei, E., & Wang, Z. (2025). Stock price prediction using CEEMD-CNN-BiLSTM-AM: A hybrid deep learning approach. *Proceedings of the 2025 5th International Conference on Applied Mathematics, Modelling and Intelligent Computing*, 287–295. <https://doi.org/10.1145/3745533.3745581>