

Optimasi Hyperparameter Bidirectional LSTM Menggunakan Particle Swarm Optimization untuk Estimasi Harga Saham PTBA

Hyperparameter Optimization of Bidirectional LSTM Using Particle Swarm Optimization for PTBA Stock Price Estimation

Pramudya Reksha Kumala¹, Anggraini Puspita Sari^{*2}, Afina Lina Nurlailli³

Universitas Pembangunan Nasional Veteran, Jawa Timur

*E-mail : 22081010186@student.upnjatim.ac.id¹, anggraini.puspita.if@upnjatim.ac.id^{*2},
afina.lina.if@upnjatim.ac.id³*

**Corresponding author*

Received 5 June 2026; Revised 14 July 2026; Accepted 19 July 2026

Abstrak - Estimasi harga saham merupakan permasalahan yang kompleks akibat pergerakan harga yang bersifat volatil dan non-linear. Penelitian ini mengimplementasikan model *Bidirectional Long Short-Term Memory* (BiLSTM) yang dioptimasi menggunakan *Particle Swarm Optimization* (PSO) untuk melakukan estimasi harga saham PTBA. Data yang digunakan merupakan data historis harian saham PTBA sebanyak 1.199 data dari rentang 5 Mei 2021 hingga 5 Mei 2026 yang diperoleh dari *investing.com*. PSO digunakan untuk menentukan kombinasi *hyperparameter* optimal pada model BiLSTM yang meliputi *learning rate*, *hidden units* pada dua lapisan, dan *dropout rate*, dengan menggunakan 20 partikel dan 30 iterasi. Hasil optimasi PSO menghasilkan kombinasi *hyperparameter* optimal yaitu *learning rate* sebesar 0,00402, *hidden units* lapisan pertama sebesar 92, *hidden units* lapisan kedua sebesar 48, dan *dropout rate* sebesar 0,14600. Model PSO-BiLSTM yang dilatih menggunakan kombinasi tersebut menghasilkan nilai MAE sebesar 31,7024, RMSE sebesar 50,7833, dan MAPE sebesar 1,1745% pada data uji. Hasil komparasi dengan model Baseline BiLSTM menunjukkan peningkatan akurasi sebesar 33,43% pada MAE, 23,19% pada RMSE, dan 33,96% pada MAPE, membuktikan bahwa optimasi *hyperparameter* menggunakan PSO mampu meningkatkan kemampuan estimasi model BiLSTM secara signifikan.

Kata Kunci - BiLSTM, PSO, Optimasi *Hyperparameter*, Estimasi Harga Saham, PTBA

Abstract - Stock price estimation is a complex problem due to the volatile and non-linear nature of price movements. This study implements a *Bidirectional Long Short-Term Memory* (BiLSTM) model optimized using *Particle Swarm Optimization* (PSO) for PTBA stock price estimation. The dataset consists of 1,199 daily historical stock price observations of PTBA from May 5, 2021, to May 5, 2026, obtained from *investing.com*. PSO was employed to determine the optimal combination of *hyperparameters* for the BiLSTM model, including the *learning rate*, *hidden units* in two layers, and *dropout rate*, using 20 particles and 30 iterations. The optimization process yielded an optimal *hyperparameter* combination consisting of a *learning rate* of 0.00402, 92 *hidden units* in the first layer, 48 *hidden units* in the second layer, and a *dropout rate* of 0.14600. The PSO-BiLSTM model trained with these *hyperparameters* achieved an MAE of 31.7024, an RMSE of 50.7833, and a MAPE of 1.1745% on the test dataset. A comparison with the Baseline BiLSTM model demonstrated reductions of 33.43% in MAE, 23.19% in RMSE, and 33.96% in MAPE, indicating that *hyperparameter* optimization using PSO significantly improves the estimation performance of the BiLSTM model.

Keywords - BiLSTM, PSO, *Hyperparameter* Optimization, Stock Price Estimation, PTBA

1. PENDAHULUAN

Saham merupakan bukti kepemilikan suatu individu maupun kelompok terhadap suatu perusahaan terbuka [1]. Instrument investasi saham menjadi salah satu instrument yang diminati oleh para investor di pasar modal hingga saat ini karena menawarkan potensi imbal hasil yang cukup tinggi dibandingkan dengan beberapa investasi lain seperti emas, deposito, hingga obligasi [2]. Namun, instrumen investasi saham memiliki resiko yang selaras dengan tawaran imbal hasilnya. Investasi saham memiliki resiko yang cukup tinggi atau pergerakan harga yang volatil [3]. Maka dari itu estimasi harga saham memiliki peranan penting dalam memberikan petunjuk bagi investor saham dalam mengambil keputusan investasi mereka.

Salah satu emiten saham yang cukup diminati oleh para investor saham yaitu PTBA. PTBA merupakan perusahaan yang bergerak di bidang energi batubara yang memiliki fundamental yang cukup kuat dan telah menjadi saham *blue chip* [4]. PTBA juga termasuk dalam emiten yang tergabung pada dua indeks yang berperan penting pada pergerakan IHSG, antara lain yaitu LQ45 dan IDX30 yang menggambarkan bahwa emiten ini memiliki volume transaksi yang tinggi dengan kapitalisasi yang besar disertai fundamental yang sangat kuat. Namun, harga saham PTBA memiliki volatilitas yang tinggi dikarenakan salah satu faktornya yaitu sektor yang dijalankan perusahaan ini bergerak dibidang yang dipengaruhi oleh harga batu bara dunia.

Beberapa upaya telah dilakukan dalam penelitian-penelitian yang telah ada dalam membangun sebuah model estimasi harga saham. Beberapa penelitian tersebut antara lain Latifa dan Lidya [5] melakukan penelitian dengan menggunakan ARIMA-GARCH dalam pemodelan estimasi harga saham pada emiten BBKA dan BBRI. Hasil dari penelitian ini menunjukkan bahwa model berhasil mendapatkan nilai MAPE yang tergolong baik dengan angka 3,46% pada emiten BBKA dan 4,09% pada emiten BBRI, namun model masih menggunakan metode konvensional dan masih terbatas dalam menangkap pola non-linear [5]. Lalu penelitian yang dilakukan oleh Khairul [6] dengan melakukan estimasi pada harga saham Bank Mandiri dengan menggunakan pendekatan yang lebih baru berbasis *deep learning* dengan menggunakan model *Long Short-Term Memory*. Penelitian ini berhasil dalam pembuatan model estimasi harga saham dengan mendapatkan akurasi MAPE yang tergolong tinggi dengan angka 2.75% [6]. Namun, model *Long Short-Term Memory* masih memproses data hanya dari satu arah maju, peningkatan ini diberikan pada model terbaru yaitu *Bidirectional Long Short-Term Memory* dengan kemampuan yang dapat melakukan proses data dari dua arah sekaligus maju dan mundur [7]. Peningkatan model ini memberikan nilai akurasi yang lebih baik dibandingkan dengan model LSTM konvensional. Salah satu penelitian yang dilakukan pada model ini dalam konteks estimasi harga saham dilakukan oleh Dian [8] dengan melakukan komparasi antara model LSTM konvensional dengan BiLSTM untuk mendapatkan hasil estimasi harga saham terendah pada perusahaan PT Aneka Tambang Tbk, PT Unilever Indonesia Tbk. dan PT Indofood Sukses Makmur Tbk. Berdasarkan penelitian yang dilakukan, model BiLSTM berhasil mengungguli LSTM konvensional pada ketiga saham dengan nilai MAPE sebesar 2,59%, 1,77%, dan 1,05% [8]. Berdasarkan hasil tersebut didapatkan Kesimpulan bahwa metode BiLSTM memiliki peningkatan dibandingkan dengan pendahulunya yaitu LSTM konvensional dalam memodelkan estimasi harga saham.

Namun, pendekatan *deep learning* sangat dipengaruhi oleh pemilihan *hyperparameter* yang tepat. Beberapa penelitian yang dilakukan sebelumnya memiliki kekurangan pada penentuan *hyperparameter*, penentuan ini masih dilakukan secara manual, penentuan yang masih manual tersebut membuat potensi dari model dalam mengestimasi harga saham menjadi kurang maksimal. Maka diperlukan sebuah teknik optimasi pada penentuan *hyperparameter* untuk mendapatkan nilai optimal agar model dapat mengeluarkan potensi maksimal dalam pemodelan estimasi harga saham. Penelitian yang dilakukan oleh Burhan [9] menunjukkan bahwa model yang dilakukan optimasi pada nilai *hyperparameter* mendapatkan angka yang lebih baik dibandingkan dengan model yang tidak dioptimasi. Hasil yang didapatkan pada penelitian ini menunjukkan angka MAPE 3,52% yang lebih baik dibandingkan dengan hasil model LSTM tanpa optimasi PSO dengan angka MAPE sebesar 9,91% [9]. Meskipun PSO telah terbukti dalam

optimasinya pada model LSTM, perlu dilakukan percobaan lebih lanjut pada model BiLSTM dengan tujuan untuk pemodelan estimasi harga saham pada emiten PTBA.

Penelitian ini menerapkan model BiLSTM yang dioptimasi menggunakan PSO guna melakukan estimasi harga saham PTBA berbasis data historis harian. Penerapan PSO difokuskan pada pencarian nilai hyperparameter terbaik untuk model BiLSTM, yang mencakup *learning rate*, jumlah *hidden units*, serta *dropout rate*, agar model menghasilkan estimasi yang lebih unggul dibandingkan penentuan hyperparameter secara konvensional. Untuk mengukur kualitas estimasi secara menyeluruh, evaluasi dilakukan menggunakan tiga metrik yaitu MAE, RMSE, dan MAPE. Melalui pendekatan ini, penelitian diharapkan mampu memperkaya wawasan dalam bidang deep learning dan optimasi metaheuristik, khususnya pada domain keuangan, sekaligus menjadi acuan bagi pengembangan penelitian serupa di masa mendatang.

2. METODE PENELITIAN

Penelitian ini dilakukan melalui beberapa tahapan yang dilakukan secara berurutan. tahapan dari penelitian ini terbagi menjadi 4 tahapan antara lain yaitu: pengumpulan data, pra-pemrosesan data, perancangan dan pelatihan model PSO-BiLSTM, evaluasi model. Untuk penggambaran lebih jelas tahapan pada metode penelitian ditunjukkan pada Gambar 1.



Gambar 1. Alur Tahapan Penelitian

2.1. Pengumpulan Data

Data historis harian PTBA yang digunakan diambil secara langsung pada portal investasi *investing.com*, platform tersebut mencakup berbagai data tentang investasi dimulai dari harga saham harian emiten yang tersebar pada tiap negara. Data yang terdapat pada data harian suatu saham tersebut terdiri dari beberapa variabel antara lain yaitu *Open*, *High*, *Low*, *Close*, *Volume*, dan *Change %* yang merupakan representasi harga saham PTBA. Pada penelitian ini, data yang digunakan untuk membangun pemodelan estimasi harga saham dibatasi pada rentang waktu 5 tahun dengan data yang diambil merupakan data harian saham PTBA, data yang diambil dimulai dari 5 Mei 2021 hingga 5 Mei 2026 dengan total data sebanyak 1199 data. Penelitian ini menargetkan estimasi harga saham pada nilai *Close* atau Price sebagai penutupan harga saham karena dinilai sebagai representasi nilai asli sebuah saham pada hari tersebut. Untuk mendapatkan gambaran data yang didapatkan dari website *investing.com* ditunjukkan pada Tabel 1.

Tabel 1. Data Harga Saham

Date	Price	Open	High	Low	Vol.	Change
5/5/2021	2,290	2,300	2,300	2,270	9.69M	-0.43%
5/6/2021	2,290	2,300	2,330	2,290	13.02M	0.00%
5/7/2021	2,280	2,300	2,320	2,280	11.63M	-0.44%
...	...	...	...	...	...	...
4/30/2026	2,870	2,920	2,930	2,850	14.06M	-1.37%
5/4/2026	2,950	2,900	2,950	2,890	17.45M	2.79%
5/5/2026	2,950	2,960	2,970	2,910	11.85M	0.00%

2.2. Pra-pemrosesan Data

Sebelum masuk ke pemodelan, data historis PTBA dari *investing.com* melalui serangkaian pra-pemrosesan. Karakter non-numerik seperti satuan 'M' pada kolom *Volume* dihapus agar seluruh fitur terekam dalam format numerik murni yang kompatibel dengan arsitektur BiLSTM. Setelah pembersihan, dataset sebanyak 1.199 observasi dipartisi menjadi tiga subset dengan proporsi 80:10:10 masing-masing 959 baris untuk pelatihan, 119 untuk validasi, dan 121 untuk pengujian dengan mempertahankan kronologi temporal tanpa pengacakan..

1. Pembersihan Data

Tahap awal pra-pemrosesan difokuskan pada pembersihan data mentah. Nilai pada kolom *Volume* yang masih mengandung suffix “M” (*million*) dikonversi ke bentuk desimal agar tidak terbaca sebagai string oleh *layer input*. Langkah ini diperlukan karena BiLSTM hanya menerima tensor numerik, keberadaan karakter alfabetik dapat mengakibatkan *type error* atau mengaburkan pola *volume* perdagangan yang sebenarnya.

2. Pembagian Rasio Data

Setelah data melalui proses pembersihan, dataset selanjutnya dipartisi menjadi tiga subset terpisah. Proporsi yang digunakan adalah 80% untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian. Dengan jumlah total 1.199 data, maka diperoleh 959 sampel pelatihan, 119 sampel validasi, dan 121 sampel pengujian. Seluruh proses pembagian ini dilakukan secara berurutan sesuai kronologi waktu guna menjaga keutuhan pola temporal dalam data *time series*, tanpa melakukan randomisasi pada urutan data.

3. Normalisasi Data

Normalisasi Data merupakan tahapan untuk menyamakan rentang pada besaran data, data yang memiliki rentang terlalu jauh mengakibatkan model cenderung bias terhadap angka yang lebih besar, dalam penelitian ini dilakukan normalisasi data dengan menggunakan *Min-Max Scaling* dengan tujuan untuk menyamakan rentang angka pada data ke dalam skala 0 hingga 1 [10]. Normalisasi diperlukan dalam proses pra-pemrosesan dengan alasan model *deep learning* memiliki sensitifitas yang sangat tinggi terhadap perbedaan skala antar fitur dan dapat memperlambat konvergensi selama proses pelatihan. Persamaan untuk normalisasi *MinMax-Scaling* ditunjukkan pada persamaan (1).

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Di mana x' adalah Hasil normalisasi, x adalah Angka fitur, x_{min} adalah Angka fitur terkecil, x_{max} adalah Angka fitur terbesar.

4. Pembuatan Sekuensial


Pembentukan data sekuensial merupakan salah satu tahapan penting dalam pra-pemrosesan setelah data dinormalisasi. Pada tahap ini, data deret waktu yang semula berbentuk deretan observasi biasa diubah menjadi data berurutan agar dapat dipelajari oleh model BiLSTM berdasarkan jendela waktu tertentu [11]. Dalam penelitian ini, ukuran jendela waktu atau *window size* ditetapkan sebesar 15. Artinya, model menggunakan data selama 15 hari sebelumnya sebagai *input* untuk mendapatkan estimasi harga pada hari berikutnya, yaitu hari ke-16.

2.3. Arsitektur Model BiLSTM

BiLSTM merupakan model *deep learning* untuk menangani data *time series*, berbeda dengan pendahulunya LSTM yang hanya memiliki mekanisme untuk membaca data sekuensial satu arah saja, BiLSTM memiliki peningkatan mekanisme dari pendahulunya yaitu dapat membaca data sekuensial dua arah secara berdampingan atau paralel yaitu data maju dan mundur [7]. Kemampuan pemrosesan dua arah ini memungkinkan model untuk menangkap ketergantungan model untuk menangkap ketergantungan temporal yang lebih lengkap dibandingkan dengan LSTM konvensional yang hanya dapat memproses data satu arah maju saja.

LSTM sendiri merupakan varian dari RNN yang dirancang untuk mengatasi kekurangan model dalam mengatasi *vanishing gradient* pada RNN standar dengan melalui mekanisme

gerbang [12]. Mekanisme ini terdiri dari tiga gerbang yaitu, *forget gate*, *input gate*, dan *output gate*, yang secara bersamaan mengatur aliran informasi di dalam sel memori. Gambar arsitektur LSTM ditunjukkan pada Gambar 2 dengan Persamaan LSTM ditunjukkan pada persamaan (2) hingga (7).



Gambar 2. Arsitektur LSTM

Forget gate bertugas untuk menentukan informasi mana dari sel memori sebelumnya yang perlu dibuang atau dipertahankan

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \quad (2)$$

Input gate bertugas untuk menentukan seberapa besar informasi baru akan disimpan, sedangkan g_t merupakan kandidat nilai baru yang akan ditambahkan ke sel memori

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \quad (3)$$

$$g_t = \tanh(W_g \times [h_{t-1}, x_t] + b_g) \quad (4)$$

Nilai sel memori c_t diperbarui melalui penggabungan hasil *forget gate* dengan memori sebelumnya dan hasil input *gate* pada kandidat nilai baru g_t .

$$c_t = f_t \times c_{t-1} + i_t \times g_t \quad (5)$$


Output gate menentukan bagian dari sel memori yang akan diteruskan sebagai *hidden state* h_t ke lapisan berikutnya.

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t \times \tanh(c_t) \quad (7)$$

Di mana σ adalah fungsi sigmoid, $\tanh$ adalah fungsi *hyperbolic tangent*, W adalah matriks bobot, dan b adalah bias pada masing-masing gerbang.

Pada arsitektur BiLSTM, dua lapisan LSTM dijalankan secara berdampingan atau paralel, satu memproses urutan data dari awal ke akhir dan satu dari akhir ke awal. *Hidden state* dari kedua arah kemudian dilakukan penggabungan (*concatenate*) untuk menghasilkan representasi akhir dengan perhitungan BiLSTM ditunjukkan pada persamaan (8) hingga (10) dan arsitektur BiLSTM ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur BiLSTM

$$\vec{h}_t = LSTM(x_t, h_{t-1}) \quad (8)$$

$$\overleftarrow{h}_t = LSTM(x_t, h_{t+1}) \quad (9)$$

$$y_t = [\vec{h}_t, \overleftarrow{h}_t] \quad (10)$$

Di mana $\vec{h}_t$ adalah *hidden state LSTM forward*, $\overleftarrow{h}_t$ Adalah *hidden state LSTM backward*, dan y_t Adalah output gabungan keduanya yang menjadi input lapisan selanjutnya.

2.4. Particle Swarm Optimization (PSO)

Pada penelitian ini, teknik pencarian solusi optimal dilakukan dengan memanfaatkan PSO yang dikembangkan Kennedy dan Eberhart (1995). Berbeda dengan metode optimasi konvensional yang mengandalkan gradien, PSO mengadopsi perilaku sosial kawanan burung dalam eksplorasi ruang pencarian. Masing-masing individu dalam kawanan (partikel) menyimpan posisi terbaik yang pernah dicapai secara lokal (pbest) maupun secara global (gbest). Kedua informasi tersebut kemudian digunakan untuk memperbarui posisi dan kecepatan setiap partikel pada iterasi berikutnya [13].

Pergerakan partikel dikendalikan oleh pembaruan kecepatan dan posisi pada setiap iterasi. Pembaruan kecepatan partikel ditunjukkan pada persamaan (11).

$$v_i^{t+1} = w \times v_i^t + c_1 r_1 (Pbest_i - x_i^t) + c_2 r_2 (Gbest - x_i^t) \quad (11)$$

Setelah kecepatan diperbarui, posisi partikel kemudian diperbarui ditunjukkan pada persamaan (12)

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (12)$$

Di mana v_i^{t+1} adalah vektor kecepatan partikel i pada iterasi berikutnya, w adalah bobot inersia yang mengontrol kecepatan sebelumnya terhadap kecepatan saat ini, v_i^t adalah vector kecepatan partikel i pada iterasi saat ini, c_1 adalah koefisien akselerasi kognitif untuk mengontrol besar partikel bergerak menuju posisi terbaik lokal, c_2 adalah koefisien akselerasi sosial untuk mengontrol besar partikel bergerak menuju posisi terbaik global kawanan, r_1, r_2 adalah bilangan acak dengan rentang 0 hingga 1 untuk menghindarkan partikel pada jebakan optimum lokal, $Pbest_i$ adalah posisi terbaik yang pernah dicapai oleh partikel i , x_i^t adalah posisi koordinat partikel i pada iterasi saat ini, $Gbest_i$ adalah posisi terbaik yang ditemukan oleh seluruh kawanan partikel dalam ruang pencarian.

2.5. Optimasi Hyperparameter BiLSTM dengan PSO

Optimasi *Particle Swarm Optimization* digunakan dalam pencarian kombinasi nilai *hyperparameter* optimal pada model BiLSTM. *Hyperparameter* yang dioptimasi dalam penelitian ini terdiri dari empat variabel yaitu *learning rate*, *hidden units* lapisan pertama, *hidden units* lapisan kedua, dan *dropout rate*. Setiap variabel *hyperparameter* dicari dalam rentang yang telah ditetapkan sebagaimana ditunjukkan pada Tabel 2.

Tabel 2. Ruang Pencarian *Hyperparameter*

Hyperparameter	Rentang Nilai	Tipe
Learning Rate	[0,0001 - 0,01]	Kontinu
Hidden Units Layer 1	[32 - 256]	Diskrit
Hidden Units Layer 2	[32 - 256]	Diskrit
Dropout Rate	[0,1 – 0,5]	Kontinu

Proses optimasi dijalankan dengan jumlah partikel sebesar 20 dan maksimal iterasi sebesar 30. Setiap partikel merepresentasikan satu kandidat kombinasi *hyperparameter* yang bergerak dalam ruang pencarian empat dimensi. PSO pada penelitian ini menggunakan *inertia weight* adaptif yang nilainya berkurang secara linier dari $w_{max} = 0,90$ menuju $w_{min} = 0,4$ seiring iterasi bertambah, dengan tujuan untuk menyeimbangkan antara eksplorasi global pada awal iterasi dan eksploitasi lokal pada akhir iterasi [14]. Perhitungan *inertia weight* adaptif ditunjukkan pada persamaan (13).

$$w = w_{max} - \frac{w_{max} - w_{min}}{iter_{max}} \times iter \quad (13)$$

Di mana w merupakan bobot inersia, w_{max} adalah bobot inersia maksimal, w_{min} adalah bobot inersia minimal, $iter$ adalah iterasi, dan $iter_{max}$ adalah jumlah iterasi maksimal yang telah ditetapkan.

2.6. Evaluasi Model

Pengujian terhadap arsitektur PSO-BiLSTM dilakukan dengan tujuan mengukur akurasi prediksi sekaligus kesalahan estimasi pada data pengujian. Tiga parameter kuantitatif diterapkan sebagai instrumen evaluasi, yakni Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), serta Mean Absolute Percentage Error (MAPE). Alasan pemilihan ketiga metrik tersebut adalah kemampuannya untuk memberikan dimensi penilaian yang berbeda namun saling melengkapi ketika menganalisis deviasi antara nilai hasil prediksi dengan nilai observasi harga saham PTBA.

1. MAE

MAE merupakan metrik evaluasi yang mengukur rata-rata selisih antara nilai estimasi dengan nilai harga aktual. Tujuan dari penggunaan metrik ini yaitu untuk mengetahui seberapa besar rata-rata kesalahan estimasi model secara keseluruhan tanpa memperhatikan arah kesalahannya. Persamaan MAE ditunjukkan pada persamaan (14) [15].

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (14)$$

Di mana Y_i merupakan nilai aktual data ke i , $\hat{Y}_i$ merupakan nilai estimasi pada data ke i , n merupakan jumlah banyak data, dan $|Y_i - \hat{Y}_i|$ merupakan nilai absolut dari operasi pengurangan nilai absolut dengan hasil estimasi.

2. RMSE

RMSE merupakan nilai metrik evaluasi yang mengukur akar kuadrat dari rata-rata kuadrat selisih antara nilai estimasi dengan nilai aktual. Berbeda dengan MAE, RMSE memberikan hukuman yang lebih besar pada kesalahan yang nilainya jauh dari nilai aktual karena adanya operasi kuadrat, sehingga metrik ini lebih sensitif pada kesalahan estimasi yang lebih besar. Persamaan RMSE ditunjukkan pada persamaan (15) [15].

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (15)$$

Di mana Y_i merupakan nilai aktual data ke i , $\hat{Y}_i$ merupakan nilai estimasi pada data ke i , n merupakan jumlah banyak data, dan $(Y_i - \hat{Y}_i)^2$ merupakan nilai kuadrat dari hasil pengurangan data aktual dengan nilai hasil estimasi.

3. MAPE

MAPE merupakan metrik evaluasi yang mengukur rata-rata presentasi kesalahan antara nilai estimasi dengan nilai aktual. Tujuan dari penggunaan metrik ini yaitu untuk memberikan gambaran kesalahan model dalam bentuk presentase sehingga lebih mudah untuk diinterpretasikan. Persamaan MAPE ditunjukkan pada persamaan (16) [15].

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (16)$$

Di mana A_t merupakan nilai aktual data ke t , F_t merupakan nilai estimasi pada data ke t , n merupakan jumlah banyak data, dan $\left| \frac{A_t - F_t}{A_t} \right|$ merupakan nilai absolut dari persentase kesalahan estimasi pada nilai aktual.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Pra-pemrosesan Data

Data yang digunakan dalam menunjang penelitian ini merupakan harga saham PTBA sebanyak 1.199 data yang dikumpulkan dari rentang 5 Mei 2021 hingga 5 Mei 2026. Target estimasi pada pemodelan ini fokus pada variabel *Close* atau *Price* yang dinilai dapat merepresentasikan harga asli saham pada penutupan bursa. Pada tahap awal, data dibersihkan dari karakter yang tidak diperlukan untuk model, seperti menghapus huruf “M” dan konversi ke nilai desimal pada kolom *Volume*. Setelah dilakukan pembersihan, data dibagi menjadi tiga bagian dengan rasio sebesar 80:10:10, hasil dari pembagian ini menghasilkan 959 data latih, 119 data validasi, dan 121 data uji. Pembagian dilakukan secara berurutan tanpa melakukan pengacakan dengan tujuan untuk mempertahankan pola temporal pada data. Visualisasi pembagian ditunjukkan pada Tabel 3.

Tabel 3. Pembagian Rasio Data

No	Set	Rasio	Jumlah Data	Rentang Index
1	Train	80%	959	0 - 958
2	Validasi	10%	119	959 - 1077
3	Test	10%	121	1078 - 1198

Selanjutnya, seluruh data dinormalisasi menggunakan *Min-Max Scaling* menjadi seragam dengan rentang 0 hingga 1 untuk mencegah model bias pada fitur yang memiliki angka besar dan mempercepat konvergensi model. Tahap terakhir, pada pra-pemrosesan yaitu membentuk data menjadi sekuensial dengan ukuran *window size* sebesar 15 hari, yang berarti model akan menggunakan data 15 hari kebelakang untuk *input* untuk melakukan estimasi pada harga saham pada hari ke-16. Visualisasi normalisasi dan pembuatan sekuensial ditunjukkan pada Tabel 4 dan Tabel 5.

Tabel 4. Normalisasi Data

Index	Price	Open	High	Low	Vol.	Change %
0	0.110266	0.116279	0.103846	0.108055	0.018998	0.607293
1	0.110266	0.116279	0.115385	0.115914	0.028837	0.625314
2	0.106464	0.116279	0.111538	0.111984	0.024730	0.606873
3	0.106464	0.112403	0.103846	0.100196	0.044733	0.625314
4	0.106464	0.108527	0.115385	0.104126	0.062520	0.62531

Berdasarkan Tabel 4, data yang awalnya memiliki rentang berbeda dirubah menjadi rentang yang seragam, perubahan ini membuat setiap fitur memiliki rentang diantara 0 hingga 1. Data yang telah dilakukan normalisasi kemudian akan dibentuk menjadi bentuk sekuensial.


Tabel 5. Hasil Pembentukan Sekuensial

No	Dataset	Jumlah Sampel	Timestep	Jumlah Fitur
1	X_train	944, 15, 6	15	6
2	X_val	119, 15, 6	15	6
3	X_Test	121, 15, 6	15	6

Berdasarkan Tabel 5, proses pembentukan sekuensial dengan *windows size* 15, didapati bahwa data latih menjadi 944 sampel, sedangkan untuk data validasi dan data test masing-masingnya memiliki 119 dan 121 sampel. Setiap sampel memiliki dimensi yang sama dengan 15 *timestep* dan juga 6 jumlah fitur yang digunakan.

3.2. Proses dan Hasil Optimasi PSO

Proses optimasi PSO dilakukan untuk memperoleh kombinasi hyperparameter yang paling optimal pada model BiLSTM. Pencarian dilakukan pada empat dimensi ruang hyperparameter dengan rentang yang telah ditentukan, yaitu learning rate sebesar 0,0001 hingga 0,01, jumlah hidden units pada lapis pertama sebesar 32 hingga 256, jumlah hidden units pada lapis kedua sebesar 32 hingga 256, serta dropout rate sebesar 0,1 hingga 0,5. Algoritma PSO dijalankan menggunakan 20 partikel dengan jumlah iterasi maksimum sebanyak 30. Untuk menyeimbangkan proses pencarian global pada awal iterasi dan eksploitasi lokal pada akhir iterasi, digunakan bobot inersia adaptif yang nilainya menurun secara bertahap dari 0,90 hingga 0,40. Visualisasi grafik konvergensi PSO ditunjukkan pada Gambar 4.



Gambar 4. Kurva Konvergensi PSO


Berdasarkan grafik konvergensi PSO pada Gambar 4, nilai RMSE terbaik turun tajam pada iterasi awal. Nilai tersebut turun dari 0,02681 pada iterasi pertama menjadi 0,02250 pada iterasi kedua. Setelah itu nilai RMSE cenderung stabil sampai iterasi ke-14. Kemudian, nilai kembali turun pada iterasi ke-15 menjadi 0,02105. Nilai RMSE stabil lagi sampai iterasi ke-22, lalu turun pada iterasi ke-23 menjadi 0,02093. Penurunan terakhir terjadi pada iterasi ke-29 dimana RMSE yang didapat mencapai angka 0,02050, dan nilai itu bertahan sampai iterasi terakhir ke-30. Pola penurunan ini menunjukkan bahwa PSO dapat memperbaiki solusi secara perlahan dan bertahap dengan melalui beberapa fase hingga mencapai kondisi konvergen di akhir iterasi. Hasil akhir kombinasi *hyperparameter* yang didapat oleh PSO ditampilkan pada Tabel 6.

Tabel 6. Hasil Pencarian *Hyperparameter* PSO

Hyperparameter	Nilai Optimal	Tipe
Learning Rate	0,00402	Kontinu
Hidden Units Layer 1	92	Diskrit
Hidden Units Layer 2	48	Diskrit
Dropout Rate	0,14600	Kontinu

3.3. Pelatihan Model PSO-BiLSTM

Proses pelatihan model PSO-BiLSTM dilakukan dengan menggunakan kombinasi *hyperparameter* optimal yang telah diperoleh pada saat optimasi PSO, yaitu *learning rate* sebesar 0,00402, *hidden units* pada lapisan pertama sebesar 92, *hidden layer* pada lapisan kedua sebesar 48, dan *dropout rate* sebesar 0,14600. Model dilatih dengan menggunakan 959 data latih dan divalidasi dengan menggunakan 119 data validasi dengan menggunakan *window size* 15. Proses pelatihan dilakukan dengan menggunakan optimasi Adam, *loss function* MSE, dan *batch size* sebesar 64 selama 100 epoch. Grafik *loss* pada saat pelatihan ditunjukkan pada Gambar 5.



Gambar 5. Kurva Loss Pelatihan Model

Perkembangan dari proses pelatihan dapat dilihat pada grafik *training loss* dan *validation loss* yang ditunjukkan pada Gambar 5. Pada epoch pertama, nilai *training loss* sangat tinggi mencapai angka 0,0971, namun kemudian mengalami penurunan yang sangat tajam hingga menyentuh angka 0,0046 pada epoch ke-5. Penurunan kemudian berlanjut secara konsisten hingga sekitar epoch ke-30, di mana nilai dari *training loss* mulai stabil pada rentang 0,0015 sampai 0,0018. Nilai *validation loss* sejak awal pelatihan sudah berada di posisi jauh lebih rendah dibandingkan dari *training loss*, yaitu di angka 0,0027 pada epoch pertama dan terus menurun hingga mencapai nilai terbaiknya pada angka 0,000379 pada epoch ke-98. Kondisi tersebut wajar karena *dropout* hanya aktif pada saat pelatihan sehingga angka pada *training loss* lebih tinggi dibandingkan dengan *validation loss*. Secara keseluruhan, pola konvergensi yang didapatkan tidak mengindikasikan adanya *overfitting* yang signifikan.

3.4. Hasil Evaluasi Model PSO BiLSTM

Untuk mengetahui seberapa baik model dalam memprediksi harga saham PTBA, dilakukan evaluasi pada model PSO-BiLSTM pada tiga metrik evaluasi MAE, RMSE, MAPE untuk mengetahui angka dari tiga metrik evaluasi tersebut. Evaluasi dilakukan dengan menguji model pada data yang belum pernah dilihat sebelumnya yaitu data uji sebesar 121 data yang

merupakan 10% dari keseluruhan dataset. Hasil evaluasi model PSO-BiLSTM pada ketiga metrik tersebut ditunjukkan pada Tabel 7.

Tabel 7. Hasil Evaluasi Model PSO-BiLSTM

Metrik Evaluasi	Nilai
MAE	31,7024
RMSE	50,7833
MAPE %	1,1745%

Berdasarkan pengujian pada Tabel 7, model PSO-BiLSTM memperoleh nilai MAE 31,7024, RMSE 50,7833, dan MAPE 1,1745%. Dari nilai MAE tersebut dapat dipahami bahwa rata-rata perbedaan antara harga saham aktual PTBA dengan estimasi model berkisar 31,70. Adapun RMSE sebesar 50,783 menandakan bahwa model memiliki tingkat error estimasi yang relatif kecil, walaupun pada beberapa prediksi masih terdapat penyimpangan, karena RMSE memberikan penalti lebih tinggi pada kesalahan besar.

Nilai MAPE 1,1745% mengungkapkan bahwa persentase rata-rata kesalahan prediksi terhadap harga riil hanya sekitar 1,17%, yang membuktikan bahwa model PSO-BiLSTM memiliki akurasi tinggi dalam estimasi harga saham PTBA pada data testing. Dengan demikian, dapat disimpulkan bahwa model PSO-BiLSTM memiliki performa yang sangat baik dalam estimasi harga saham PTBA.

3.5. Komparasi Model

Komparasi model dilakukan untuk melihat seberapa baik optimasi PSO berpengaruh pada hasil evaluasi model BiLSTM. Komparasi dilakukan dengan membandingkan model *baseline* BiLSTM tanpa optimasi dengan model PSO-BiLSTM untuk mengukur seberapa besar kontribusi PSO dalam meningkatkan performa estimasi harga saham PTBA. Pada model *Baseline* BiLSTM, hyperparameter ditentukan secara manual tanpa melalui proses optimasi, sedangkan pada model PSO-BiLSTM, hyperparameter ditentukan melalui proses pencarian optimal menggunakan algoritma PSO. Hasil perbandingan ketiga metrik evaluasi antara kedua model ditunjukkan pada Tabel 8.

Tabel 8. Komparasi Hasil Evaluasi Model


Metrik Evaluasi	<i>Baseline</i> BiLSTM	PSO-BiLSTM	Peningkatan
MAE	47,6226	31,7024	33,43%
RMSE	66,1128	50,7833	23,19%
MAPE %	1,7785%	1,1745%	33,96%

Berdasarkan hasil komparasi pada Tabel 8, model PSO-BiLSTM berhasil mengungguli *Baseline* BiLSTM pada seluruh metrik evaluasi. Nilai MAE mengalami penurunan dari angka 47,6226 menjadi 31,7024, angka ini menunjukkan peningkatan sebesar 33,43%. Nilai RMSE juga mengalami penurunan dari angka 66,1128 menjadi 50,7833 dengan peningkatan sebesar 23,19%. Peningkatan yang paling signifikan didapatkan pada metrik MAPE, di mana nilai turun dari angka 1,7785% menjadi 1,1745% atau meningkat sebesar 33,96%. Hasil ini menunjukkan bahwa penggunaan optimasi PSO dalam menentukan kombinasi *hyperparameter* optimal memberikan dampak yang sangat signifikan dalam peningkatan kemampuan model BiLSTM dalam melakukan estimasi harga saham PTBA dibandingkan dengan penentuan *hyperparameter* secara manual.

3.6. Visualisasi Hasil Estimasi Harga Saham

Visualisasi hasil estimasi dilakukan untuk memberikan gambaran seberapa baik model PSO-BiLSTM dalam mengikuti pergerakan harga saham aktual PTBA dibandingkan dengan

model *baseline* BiLSTM. Perbandingan secara visual ini digunakan untuk memperjelas hasil evaluasi nilai metrik evaluasi yang dipaparkan sebelumnya, yaitu melalui metrik MAE, RMSE, dan MAPE. Grafik perbandingan estimasi ditunjukkan pada Gambar 6.



Gambar 6. Grafik Estimasi dan Perbandingan Model

Berdasarkan Gambar 6, secara keseluruhan, kedua model secara umum mampu merepresentasikan pola perubahan harga saham PTBA selama periode pengujian. Namun terdapat perbedaan pada kedekatan dengan data aktual yang sangat signifikan. Model *baseline* ditunjukkan dengan garis merah putus-putus terlihat konsisten memprediksi di bawah nilai aktual hampir sepanjang periode pengujian, di periode Januari hingga Februari 2026 *baseline* gagal mengikuti kenaikan harga aktual dan tertinggal cukup jauh dari nilai aktual. Model PSO-BiLSTM ditunjukkan dengan garis biru sebaliknya menghasilkan angka estimasi yang digambarkan pada grafik yang rapat mengikuti pergerakan garis hitam yang merupakan nilai aktual.

Pada periode sekitar bulan Maret 2026, terjadi lonjakan harga aktual yang sangat tajam hingga menyentuh angka Rp3.200. Model *baseline* hanya mampu mengikuti sebagian kecil lonjakan dengan deviasi yang sangat besar, sementara model PSO-BiLSTM berhasil mengikuti lonjakan dengan jauh lebih baik dibandingkan dengan *baseline* meskipun belum sepenuhnya mencapai nilai puncak aktual. Memasuki periode Mei 2026, *baseline* masih tertinggal di bawah harga aktual secara konsisten, sedangkan model PSO-BiLSTM berhasil mengikuti pergerakan harga akurat dengan sangat akurat. Grafik menunjukkan jelas model jauh lebih andal dalam mengikuti pergerakan harga aktual dibandingkan *Baseline BiLSTM*.

4. KESIMPULAN

Setelah melalui berbagai tahapan yang telah dilaksanakan, hasil penelitian ini menunjukkan bahwa optimasi *hyperparameter* menggunakan PSO terbukti mampu meningkatkan performa model BiLSTM dalam melakukan estimasi harga saham PTBA. PSO berhasil menemukan kombinasi *hyperparameter* optimal dalam ruang pencarian empat dimensi menggunakan 20 partikel dan 30 iterasi, dengan hasil *learning rate* sebesar 0,00402, *hidden units* lapisan pertama sebesar 92, *hidden units* lapisan kedua sebesar 48, dan *dropout rate* sebesar 0,14600. Model PSO-BiLSTM yang dilatih menggunakan kombinasi tersebut menghasilkan nilai MAE sebesar 31,7024, RMSE sebesar 50,7833, dan MAPE sebesar 1,1745% pada data uji. Hasil komparasi dengan model *Baseline* BiLSTM menunjukkan peningkatan akurasi pada metrik MAE sebesar 33,43%, RMSE sebesar 23,19%, dan MAPE sebesar 33,96%, yang membuktikan bahwa penentuan *hyperparameter* secara otomatis menggunakan PSO memberikan hasil yang jauh lebih baik dibandingkan penentuan secara manual. Untuk penelitian selanjutnya, disarankan untuk mencoba metode optimasi lain seperti *Genetic Algorithm* atau *Bayesian Optimization* yang dapat menjelajahi ruang pencarian *hyperparameter* yang lebih luas, serta mencoba penerapan pada emiten saham lain untuk menguji generalisasi model.

REFERENSI

- [1] J. S. Putra, R. D. Ramadhani, and A. Burhanuddin, “Prediksi Harga Saham Bank Bri Menggunakan Algoritma Linear Regresion Sebagai Strategi Jual Beli Saham,” *J. Dinda Data Sci. Inf. Technol. Data Anal.*, vol. 2, no. 1, pp. 1–10, Feb. 2022, doi: 10.20895/dinda.v2i1.273.
- [2] V. R. Danestiara, E. Setiana, I. Akbar, and T. Hidayah, “Algoritma Gated Recurrent Unit untuk Prediksi Harga Indeks Penutupan Saham LQ45,” *J. Account. Inf. Syst.*, vol. 7, no. 1, pp. 1–8, Mar. 2024, doi: 10.32627/aims.v7i1.814.
- [3] P. Triya, N. Suarna, and N. Dienwati Nuris, “PENERAPAN MACHINE LEARNING DALAM MELAKUKAN PREDIKSI HARGA SAHAM PT. BANK MANDIRI (PERSERO) TBK DENGAN ALGORITMA LINEAR REGRESSION,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 1207–1214, Mar. 2024, doi: 10.36040/jati.v8i1.8958.
- [4] Silvia Febriani Lestari, Ahmad Idris, and Dadang Afrianto, “Pengaruh Keputusan Investasi, Keputusan Pendanaan dan Kebijakan Dividen Terhadap Nilai Perusahaan,” *Kaji. Ekon. dan Akunt. Terap.*, vol. 2, no. 3, pp. 01–11, Aug. 2025, doi: 10.61132/keat.v2i3.1441.
- [5] L. Ananda Talalu and L. Irsadyah Irwan, “PERBANDINGAN PREDIKSI HARGA SAHAM MENGGUNAKAN MODEL ARIMA-GARCH,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 10, no. 1, pp. 757–762, Jan. 2026, doi: 10.36040/jati.v10i1.16824.
- [6] K. I. Mahmud, R. Kurniawan, H. Oktafia, and L. Wijaya, “Prediksi Harga Saham Bank Mandiri Berdasarkan Data Bmri Historical Stock Price,” *J. Media Infotama*, vol. 22, no. 1, pp. 215–221, 2026, doi: 10.37676/jmi.v22i1.10983.
- [7] A. Puspita Sari, E. A. Hakim, D. Arman Prasetya, R. Arifuddin, and P. Dani, “SISTEM PREDIKSI KECEPATAN DAN ARAH ANGIN MENGGUNAKAN BIDIRECTIONAL LONG SHORT-TERM MEMORY,” *Semin. Keinsinyuran Progr. Stud. Progr. Profesi Ins.*, vol. 1, no. 1, pp. 6–16, Jun. 2021, doi: 10.22219/skpsppi.v1i0.4196.
- [8] D. I. Puteri, “Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah,” *Euler J. Ilm. Mat. Sains dan Teknol.*, vol. 11, no. 1, pp. 35–43, May 2023, doi: 10.34312/euler.v11i1.19791.
- [9] D. Burhan, I. K. Hasan, and L. O. Nashar, “Analisis Peramalan Harga Saham PT Unilever Indonesia Menggunakan Pemodelan LSTM dengan Optimasi PSO,” *J. Ris. Mhs. Mat.*, vol. 5, no. 3, pp. 228–235, Feb. 2026, doi: 10.18860/jrmm.v5i3.40090.
- [10] I. Winarni and N. Pratiwi, “Prediksi Harga Saham Menggunakan Metode Long-Short Term Memory Studi Kasus: Saham Intel Corporation,” *Decod. J. Pendidik. Teknol. Inf.*, vol. 5, no. 2, pp. 380–390, Jul. 2025, doi: 10.51454/decode.v5i2.1192.
- [11] D. I. Puteri, G. Darmawan, and B. N. Ruchjana, “Prediksi Harga Saham Syariah menggunakan Bidirectional Long Short Term Memory (BiLSTM) dan Algoritma Grid Search,” *Jambura J. Math.*, vol. 6, no. 1, pp. 39–45, 2024, doi: 10.37905/jjom.v6i1.23297.
- [12] M. Ławryńczuk and K. Zarzycki, “LSTM and GRU type recurrent neural networks in model predictive control: A Review,” *Neurocomputing*, vol. 632, no. January, p. 129712, Jun. 2025, doi: 10.1016/j.neucom.2025.129712.
- [13] A. M. Rizki and A. L. Nurlaili, “Algoritme Particle Swarm Optimization (PSO) untuk Optimasi Perencanaan Produksi Agregat Multi-Site pada Industri Tekstil Rumahan,” *J. Comput. Electron. Telecommun.*, vol. 1, no. 2, pp. 1–9, 2021, doi: 10.52435/complete.v1i2.73.
- [14] F. Yang, J. Chen, and Y. Liu, “Improved and optimized recurrent neural network based on PSO and its application in stock price prediction,” *Soft Comput.*, vol. 27, no. 6, pp. 3461–3476, Mar. 2023, doi: 10.1007/s00500-021-06113-5.
- [15] A. Zameer, F. Jaffar, F. Shahid, M. Muneeb, R. Khan, and R. Nasir, “Short-term solar

energy forecasting: Integrated computational intelligence of LSTMs and GRU,” *PLoS One*, vol. 18, no. 10, p. e0285410, Oct. 2023, doi: 10.1371/journal.pone.0285410.