


Optimisasi Hyperparameter BiLSTM Menggunakan Bayesian Optimization untuk Prediksi Harga Saham

Fandi Presly Simamora, Ronsen Purba, dan Muhammad Fermi Pasha




Volume 7, Issue 1, Pages 8–13, February 2025

Diterima 26 Agustus 2024, Direvisi 9 Desember 2024, Ditetujui 16 Desember 2024, Diterbitkan 1 Februari 2025

To Cite this Article : F. P. Simamora, R. Purba, dan M. F. Pasha, "Optimisasi Hyperparameter BiLSTM Menggunakan Bayesian Optimization untuk Prediksi Harga Saham", *Jambura J. Math*, vol. 7, no. 1, pp. 8–13, 2025, <https://doi.org/10.37905/jjom.v7i1.27166>

© 2025 by author(s)

JOURNAL INFO • JAMBURA JOURNAL OF MATHEMATICS



	Homepage	:	http://ejurnal.ung.ac.id/index.php/jjom/index
	Journal Abbreviation	:	Jambura J. Math.
	Frequency	:	Biannual (February and August)
	Publication Language	:	English (preferable), Indonesia
	DOI	:	https://doi.org/10.37905/jjom
	Online ISSN	:	2656-1344
	Editor-in-Chief	:	Hasan S. Panigoro
	Publisher	:	Department of Mathematics, Universitas Negeri Gorontalo
	Country	:	Indonesia
	OAI Address	:	http://ejurnal.ung.ac.id/index.php/jjom/oai
	Google Scholar ID	:	iWLjgaUAAAAJ
	Email	:	info.jjom@ung.ac.id

JAMBURA JOURNAL • FIND OUR OTHER JOURNALS




Jambura Journal of Biomathematics



Jambura Journal of Mathematics Education



Jambura Journal of Probability and Statistics



EULER : Jurnal Ilmiah Matematika, Sains, dan Teknologi

Optimisasi *Hyperparameter* BiLSTM Menggunakan *Bayesian Optimization* untuk Prediksi Harga Saham

Fandi Presly Simamora^{1,*} , Ronsen Purba¹ , dan Muhammad Fermi Pasha¹ 

¹Program Studi Magister Teknologi Informasi, Universitas Mikroskil, Medan, Indonesia

ARTICLE HISTORY

Diterima 26 Agustus 2024
Direvisi 9 Desember 2024
Disetujui 16 Desember 2024
Diterbitkan 1 Februari 2025

KATA KUNCI

BiLSTM
Bayesian Optimization
Optimisasi *Hyperparameter*
Prediksi Harga Saham

KEYWORDS

BiLSTM
Bayesian Optimization
Hyperparameter Tuning
Stock Price Prediction

ABSTRAK. Akurasi model *deep learning* dalam memprediksi data pasar saham yang dinamis dan *non-linear* sangat bergantung pada pemilihan *hyperparameter* yang optimal. Namun, pemilihan *hyperparameter* yang optimal membutuhkan biaya fungsi objektif model yang cukup besar karena harus mencoba semua kemungkinan kombinasi dari konfigurasi *hyperparameter*. Tujuan dari penelitian ini adalah menemukan konfigurasi *hyperparameter* model BiLSTM yang optimal menggunakan *Bayesian Optimization*. Penelitian dilakukan menggunakan tiga saham blue chip dari sektor yang berbeda yaitu BBCA, BYAN, dan TLKM dengan dua skenario jumlah iterasi pencarian. Hasil pengujian menunjukkan bahwa *Bayesian Optimization* mampu menemukan konfigurasi *hyperparameter* model BiLSTM yang optimal dengan nilai MAPE terbaik pada masing-masing data saham yaitu BBCA 1,2092%, BYAN 2,0609%, dan TLKM 1,2027%. Dibandingkan dengan penelitian mengenai *Grid Search-BiLSTM* sebelumnya, penggunaan *Bayesian Optimization-BiLSTM* dapat menghasilkan nilai MAPE yang lebih rendah.

ABSTRACT. The accuracy of *deep learning* models in predicting dynamic and *non-linear* stock market data highly depends on selecting optimal *hyperparameters*. However, finding optimal *hyperparameters* can be costly in terms of the model's objective function, as it requires testing all possible combinations of *hyperparameter* configurations. This research aims to find the optimal *hyperparameter* configuration for the BiLSTM model using *Bayesian Optimization*. The study was conducted using three blue-chip stocks from different sectors, namely BBCA, BYAN, and TLKM, with two scenarios of search iterations. The test results show that *Bayesian Optimization* was able to find the optimal *hyperparameter* configuration for the BiLSTM model, with the best MAPE values for each stock: BBCA 1.2092%, BYAN 2.0609%, and TLKM 1.2027%. Compared to previous research on *Grid Search-BiLSTM*, the use of *Bayesian Optimization-BiLSTM* resulted in lower MAPE values.



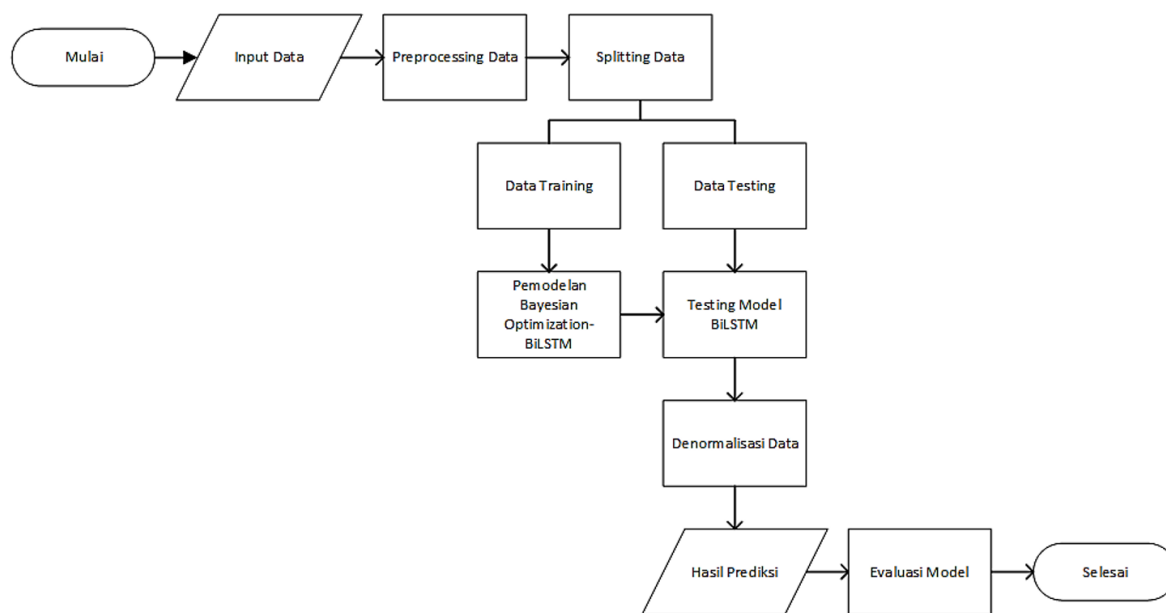
This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International License. Editorial of JJoM: Department of Mathematics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B. J. Habibie, Bone Bolango 96554, Indonesia.

1. Pendahuluan

Prediksi harga saham merupakan sebuah tantangan bagi para peneliti dan pelaku pasar saham karena data pasar saham yang dinamis dan *non-linear* membuatnya sulit untuk diidentifikasi [1, 2]. Secara umum, metode *deep learning* terbukti lebih efektif dalam mengatasi masalah ini karena kemampuannya dalam memahami pola pada data deret waktu harga saham dibandingkan metode statistik dan metode *machine learning*. Meskipun demikian, akurasi model *deep learning* sangat bergantung pada pemilihan *hyperparameter* yang digunakan [3]. Penggunaan model *deep learning* yang sama untuk menyelesaikan suatu masalah mungkin memberikan akurasi yang berbeda-beda tergantung pada konfigurasi *hyperparameter* yang digunakan. Namun, pemilihan *hyperparameter* yang optimal akan membutuhkan biaya fungsi objektif model yang cukup besar karena harus mencoba semua kemungkinan kombinasi dari *hyperparameter* yang ada. Oleh karena itu, penting untuk menerapkan optimisasi pada pemilihan *hyperparameter* model untuk mendapatkan *hyperparameter* yang optimal serta mengurangi biaya fungsi objektif [4].

Salah satu model *deep learning* yang sering kali digunakan dalam prediksi data deret waktu adalah *Long Short Term Memory* (LSTM). Model ini terbukti mampu menangani sejumlah permasalahan klasifikasi maupun regresi yang berkaitan dengan prediksi deret waktu pada berbagai domain permasalahan. Beberapa *hyperparameter* yang dapat dikonfigurasi pada model ini mencakup jumlah neuron, *epoch*, *learning rate*, *batch size* dan *time step* [5, 6]. Dalam mendukung proses pemilihan *hyperparameter* optimal pada model LSTM, Ulina dkk [7] menerapkan *Improved Firefly Algorithm* pada model CEEMDAN-LSTM untuk memprediksi harga *forex* yang hasilnya menunjukkan bahwa penerapan optimisasi ini menghasilkan nilai RMSE, MAE, dan MAPE yang lebih rendah jika dibandingkan dengan model yang tidak menerapkannya. Penelitian lain mengenai pemilihan *hyperparameter* LSTM dilakukan oleh Ulum dan Girsang [8] dengan membandingkan beberapa algoritma optimisasi yaitu *LSTM-Genetic Algorithm*, *LSTM-Particle Swarm Optimization*, dan *LSTM-Symbiotic Organism Search* yang hasilnya *LSTM-Symbiotic Organism Search* menjadi model terbaik berdasarkan nilai RMSE. Pada tahun berikutnya, Gülmez [9] membandingkan tiga variasi optimisasi model LSTM, ANN, *LSTM-Genetic*

*Penulis Korespondensi.



Gambar 1. Diagram alur penelitian

Algorithm, dan LSTM-Artificial Rabbits Optimization Algorithm yang hasilnya mayoritas hasil prediksi terbaik terhadap saham-saham pada indeks DJIA diperoleh menggunakan LSTM-Artificial Rabbits Optimization Algorithm. Pada tahun yang sama terdapat penerapan praktis model LSTM yang dilakukan oleh Singh dan Markande [10] dalam menganalisis pasar saham yang menghasilkan kesimpulan bahwa salah satu tantangan penggunaan model ini terdapat pada konfigurasi *hyperparameter* yang dipergunakan. Berdasarkan penelitian-penelitian sebelumnya dapat disimpulkan bahwa kinerja LSTM sangat dipengaruhi oleh konfigurasi *hyperparameter* yang digunakan dimana penggunaan algoritma optimisasi dapat membantu menemukan konfigurasi model yang optimal. Namun LSTM memiliki keterbatasan dalam memahami konteks yang lebih luas karena hanya berfokus pada pola data secara *forward* sehingga mengurangi kemampuan untuk menangkap hubungan timbal-balik atau sebab-akibat antar data [11].

Untuk mengatasi batasan LSTM sebelumnya terdapat varian LSTM yaitu *Bidirectional Long Short Term Memory* (BiLSTM) yang memiliki sebuah layer tambahan sehingga mampu memproses data secara *forward* dan *backward* [12]. Hal ini membuat model BiLSTM dapat memahami konteks data dengan lebih efektif karena layer *backward* menyediakan informasi mengenai *end of the sequence* yang berguna untuk memprediksi data berikutnya. Dalam membandingkan kinerja model LSTM dan model BiLSTM, terdapat penelitian Yang dan Wang [2] serta penelitian Sunny dkk [3] yang menggunakan konfigurasi *hyperparameter* yang sama pada kedua model dimana hasilnya model BiLSTM memberikan prediksi dengan akurasi yang lebih baik. Dalam mendukung proses pemilihan *hyperparameter* pada model BiLSTM terdapat penelitian Puteri dkk [13] yang menambahkan algoritma *Grid Search* yang hasilnya penggunaan algoritma ini memberikan nilai MAPE yang lebih rendah dibandingkan model yang tidak menggunakannya. Algoritma ini bekerja dengan cara membagi rentang *hyperparameter* ke dalam *grid* dan mencoba kombinasi *grid* untuk menemukan hasil yang optimal. Namun algoritma ini berpotensi mengalami masalah dimensi karena jumlah evaluasi *hyperparameter* yang meningkat secara eksponensial sesuai dengan konfigurasi *hyperpara-*

meter yang dilakukan [14]. Selain itu algoritma ini juga mengabaikan informasi dari ruang pencarian *hyperparameter* sebelumnya yang berpotensi mengakibatkan penentuan *hyperparameter* yang kurang optimal [15]. Untuk mengatasi masalah ini, terdapat algoritma lain yaitu *Bayesian Optimization* yang dapat digunakan. Algoritma ini terdiri dari dua unsur utama yaitu *surrogate model* untuk memperkirakan fungsi objektif saat ini dan *acquisition function* untuk menentukan sampel mana yang akan dievaluasi selanjutnya [16]. Penelitian Wu dkk [15] menerapkan algoritma ini pada beberapa model *machine learning*, menunjukkan kemampuannya dalam membantu konfigurasi *hyperparameter* model tersebut dengan akurasi yang lebih baik. Penelitian Samaniego dkk [17] mengenai pemilihan rute *monitoring* kendaraan air otomatis juga menunjukkan bahwa pemilihan konfigurasi *hyperparameter* menggunakan algoritma ini memberikan kombinasi terbaik jika dibandingkan dengan *Genetic Algorithm* dan *Lawnmower Algorithm*. Meskipun demikian algoritma ini perlu diuji pada model-model yang lebih kompleks seperti model *deep learning*.

Dengan mempertimbangkan cara kerja *Bayesian Optimization* yang melakukan pencarian berdasarkan evaluasi fungsi objektif serta kerjanya yang unggul dibandingkan beberapa algoritma optimisasi lainnya, maka penelitian ini menerapkan algoritma tersebut sebagai pengganti algoritma *Grid Search* pada penelitian optimisasi BiLSTM oleh Puteri dkk [13] sekaligus melihat kerjanya bila diterapkan pada model *deep learning*. Selain itu penelitian ini juga menambahkan dua data saham dari sektor yang berbeda untuk melihat kemampuan optimisasi pada data dengan karakteristik saham yang berbeda-beda. Dengan demikian penelitian ini bertujuan mengombinasikan *Bayesian Optimization* dan BiLSTM untuk mendapatkan *hyperparameter* yang optimal sehingga meningkatkan akurasi prediksi harga saham.

2. Metode

2.1. Alur Penelitian

Penelitian ini dilaksanakan mengikuti tahapan diagram alur penelitian pada Gambar 1.

Tahapan penelitian berdasarkan Gambar 1, secara garis besar dimulai dengan membaca dataset masing-masing saham yaitu BBKA, BYAN dan TLKM, preprocessing data, splitting data menjadi dua bagian yaitu training dan testing, memodelkan Bayesian Optimization-BiLSTM untuk mendapatkan hyperparameter BiLSTM yang optimal, melakukan testing, denormalisasi data, dan diakhiri dengan evaluasi model.

2.2. Data Penelitian

Data yang digunakan pada penelitian ini merupakan data historis harga saham blue chip dari 3 sektor saham yang berbeda-beda yaitu Bank Central Asia (BBKA.JK), Bayan Resources (BYAN.JK), dan Telekomunikasi Indonesia (TLKM.JK). Data diambil dari situs Yahoo Finance dengan periode waktu yakni dari 3 Januari 2011-30 Desember 2022 dengan data yang digunakan berupa data harga tutup harian saham (close). Adapun total masing-masing data saham yang digunakan dalam penelitian ini yaitu sebanyak 2980 data.

2.3. Preprocessing Data

Preprocessing data yang dilakukan terdiri dari data cleaning dan normalisasi data. Data cleaning dilakukan untuk menangani data yang hilang dengan mengisi nilai berdasarkan nilai rata-rata data tersebut. Selanjutnya data yang telah sesuai kemudian akan dinormalisasi agar setiap data memiliki skala yang sama menggunakan min-max normalization. Normalisasi data menggunakan pers. (1),

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}}, \tag{1}$$

dengan

- x_{norm} : nilai normalisasi,
- x : nilai aktual,
- x_{min} : nilai minimum dari keseluruhan data, dan
- x_{max} : nilai maksimum dari keseluruhan data.

2.4. Splitting Data

Data yang telah melewati tahap preprocessing kemudian dibagi menjadi dua bagian yaitu 90% untuk data training dan 10% sisanya untuk data testing. Kedua bagian data yang telah dibagi kemudian disegmentasi untuk menentukan berapa banyak data masukan untuk memprediksi langkah waktu berikutnya. Pada penelitian ini segmentasi dilakukan dengan panjang data sebanyak 30 berdasarkan penelitian Puteri dkk [13] sebelumnya.

3. Pemodelan Bayesian Optimization dan BiLSTM

Berdasarkan penelitian Puteri dkk [13], penelitian ini menggunakan satu hidden layer dan optimizer adam. Selain itu, penelitian ini juga akan mengoptimisasi hyperparameter model BiLSTM seperti yang terdapat pada Tabel 1.

Tabel 1. Deskripsi hyperparameter model BiLSTM

Hyperparameter	Nilai Ruang Pencarian
Batch	4 s.d. 128
Dropout Rate	0,1 s.d. 0,3
Epoch	50 s.d. 250
Hidden Neuron	5 s.d. 25

Selain hyperparameter model BiLSTM, penelitian ini juga

menggunakan konfigurasi hyperparameter model Bayesian Optimization seperti yang terdapat pada Tabel 2.

Tabel 2. Deskripsi hyperparameter model Bayesian Optimization

Hyperparameter	Nilai Hyperparameter
Init Points	5
N Iter	25, 50

Setiap iterasi pencarian akan dievaluasi menggunakan metrik Mean Square Error untuk menentukan konfigurasi hyperparameter yang optimal dari seluruh iterasi pencarian. Pada akhirnya model BiLSTM akhir akan dibangun menggunakan konfigurasi hyperparameter ini.

3.1. Denormalisasi Data

Proses denormalisasi merupakan proses mengembalikan data yang telah dinormalisasi ke skala awal untuk kemudian dibandingkan antara data hasil prediksi dengan data aktual. Denormalisasi data menggunakan pers. (2),

$$x = x' (x_{max} - x_{min}) + x_{min}, \tag{2}$$

dengan

- x : nilai aktual,
- x' : nilai normalisasi,
- x_{max} : nilai maksimum dari keseluruhan data, dan
- x_{min} : nilai minimum dari keseluruhan data.

3.2. Evaluasi Model

Salah satu metrik yang dapat digunakan untuk mengukur ketepatan suatu model dalam melakukan prediksi adalah Mean Absolute Percentage Error (MAPE). Metrik ini mengukur rata-rata dari persentase perbedaan absolut antara nilai sebenarnya dan nilai yang diprediksi model. MAPE dihitung menggunakan pers. (3),

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\%, \tag{3}$$

dengan

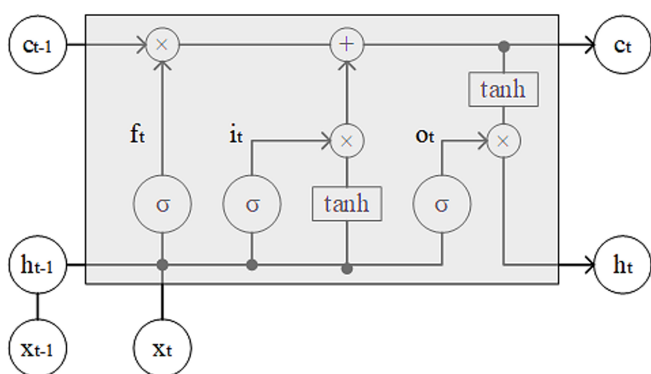
- n : banyak data,
- y_i : nilai aktual, dan
- \hat{y}_i : nilai prediksi.

Semakin kecil nilai MAPE maka kinerja model semakin baik.

3.3. Long Short Term Memory (LSTM)

Long Short Term Memory (LSTM) merupakan sebuah pengembangan dari model Recurrent Neural Network yang diusulkan oleh Hochreiter dan Schmidhuber [18] dengan menambahkan penggunaan sel memori dan mekanisme gate control. Mekanisme gate control pada model ini terdiri dari forget gate, input gate, cell state, dan output gate. Penggunaan sel memori dan mekanisme gate control pada LSTM membuat model LSTM dapat mempertahankan informasi dalam jangka panjang serta mengurangi masalah vanishing gradient dan exploding gradient dengan lebih efektif [2]. Model LSTM dapat dilihat pada Gambar 2.


Dari Gambar 2, x merupakan vektor input, h merupakan vektor output, f , i dan o mewakili nilai aktivasi dari forget gate, input gate, dan output gate, C mewakili cell state dimana subscript t mewakili waktu, σ mewakili fungsi aktivasi sigmoid, dan \tanh mewakili fungsi aktivasi tangen [2].



Gambar 2. Arsitektur LSTM

3.4. Bidirectional Long-Short Term Memory (BiLSTM)

Bidirectional Long-Short Term Memory (BiLSTM) merupakan sebuah pengembangan lanjutan dari RNN dan LSTM yang mengatasi masalah ketergantungan jangka panjang dalam model-model sebelumnya. BiLSTM menggabungkan dua arah LSTM untuk mengekstraksi informasi dari data secara maju dan mundur secara bersamaan sehingga memudahkan pengumpulan data yang mungkin tidak terpakai. Model ini menggunakan data yang sudah melewati tahap preprocessing sebagai masukan, melewati lapisan jaringan saraf LSTM forward layer dan backward layer, kemudian menuju ke full connection layer dan memberikan hasil prediksi [19]. Model BiLSTM dapat dilihat pada Gambar 3.



Gambar 3. Arsitektur BiLSTM

3.5. Bayesian Optimization

Bayesian Optimization merupakan sebuah metode yang efisien untuk melakukan optimisasi global terhadap sebuah fungsi yang hasilnya tidak diketahui secara pasti. Metode ini terdiri dari dua unsur utama yaitu surrogate model untuk memperkirakan fungsi objektif saat ini dan acquisition function untuk menentukan sampel mana yang akan dievaluasi selanjutnya [20]. Proses pencarian akan dilakukan hingga jumlah iterasi tercapai dimana pada awalnya pencarian akan dilakukan dengan mengambil sejumlah titik acak dari konfigurasi hyperparameter. Surrogate model akan dibangun berdasarkan evaluasi awal ini dan akan terus diperbarui dengan menambahkan informasi hasil evaluasi pada setiap iterasi.

4. Hasil dan Pembahasan

4.1. Data Penelitian

Data penelitian yang digunakan terdiri dari data saham Bank Central Asia (BBCA.JK), Bayan Resources (BYAN.JK), dan Telekomunikasi Indonesia (TLKM.JK) dengan mengambil atribut close

sekaligus sebagai harga penutupan yang akan diprediksi. Contoh sampel data menggunakan saham BBCA dapat dilihat pada Tabel 3.

Tabel 3. Data close saham BBCA

Date	Data Aktual
2011-01-03	1290
2011-01-04	1300
2011-01-05	1320
⋮	⋮
2022-12-28	8650
2022-12-29	8575
2022-12-30	8550

4.2. Preprocessing Data

Data penelitian yang berupa data close saham sebelumnya dinormalisasi menggunakan min-max normalization untuk mengubah data menjadi rentang 0 sampai 1. Normalisasi data perlu dilakukan untuk memastikan data memiliki skala yang sama sebelum diproses lebih lanjut. Contoh hasil normalisasi menggunakan data saham BBCA dapat dilihat pada Tabel 4.

Tabel 4. Hasil normalisasi data saham BBCA

Date	Data Aktual	Data Normalisasi
2011-01-03	1290	0,025547
2011-01-04	1300	0,026764
2011-01-05	1320	0,029197
⋮	⋮	⋮
2022-12-28	8650	0,920925
2022-12-29	8575	0,911800
2022-12-30	8550	0,908759

4.3. Splitting Data

Data yang telah melewati tahap preprocessing kemudian dibagi menjadi data training dan data testing dengan perbandingan masing-masing sebesar 90% dan 10%. Pembagian data dilakukan secara berurut dan dilanjutkan dengan segmentasi data dengan panjang 30 data.

4.4. Pemodelan Bayesian Optimization dan BiLSTM

Data yang telah dibagi menjadi data training dan data testing kemudian digunakan dalam proses pencarian hyperparameter yang optimal menggunakan algoritma Bayesian Optimization. Deskripsi ruang pencarian hyperparameter yang digunakan pada penelitian ini dapat dilihat pada Tabel 1. Selain hyperparameter model BiLSTM, penelitian ini juga menggunakan dua konfigurasi hyperparameter model Bayesian Optimization yang dapat dilihat pada Tabel 2. Model Bayesian Optimization-BiLSTM akan dibangun menggunakan kedua konfigurasi ini. Pada model yang telah dibangun akan dilakukan iterasi untuk mencoba kombinasi hyperparameter baru berdasarkan hasil evaluasi dari sebelumnya hingga iterasi maksimum tercapai.

Berdasarkan optimisasi hyperparameter yang dilakukan menggunakan ketiga data saham BBCA, BYAN, dan TLKM, maka diperoleh konfigurasi hyperparameter yang optimal pada masing-masing data saham seperti pada Tabel 5.

Tabel 5. Konfigurasi hyperparameter optimal melalui model Bayesian Optimization

Saham	Hyperparameter Bayesian Optimization		Hyperparameter BiLSTM				MSE
	Init Points	N Iter	Batch	Dropout Rate	Epoch	Hidden Neuron	
BBCA	5	25	104	0,1	231	13	0,000236
		50	78	0,2924	190	24	0,000239
25		127	0,1234	180	19	0,000458	
50		78	0,1101	129	11	0,000573	
25		25	0,2062	151	24	0,000365	
TLKM		50	9	0,2168	125	22	0,000381

Berdasarkan Tabel 5, dapat dilihat bahwa jumlah iterasi yang lebih banyak tidak selalu menghasilkan nilai MSE yang lebih rendah berdasarkan konfigurasi hyperparameter yang diperoleh. Hal ini kemungkinan disebabkan oleh inisiasi ruang pencarian awal yang terbatas yaitu sebanyak 5 *init points* serta sifat *stochastik* dari algoritma Bayesian Optimization. Selain itu pada Tabel 5 juga terlihat bahwa selisih nilai MSE pada skenario masing-masing data saham tidak terlalu jauh. Hal ini dapat menjadi pertimbangan untuk mengurangi jumlah iterasi pencarian sehingga meminimalisir biaya fungsi objektif model.

Setelah konfigurasi hyperparameter yang optimal diperoleh pada masing-masing skenario data saham, maka model BiLSTM akhir akan dibangun berdasarkan konfigurasi ini. Model akhir ini kemudian digunakan untuk melakukan prediksi terhadap data *testing* yang sebelumnya sudah disiapkan pada tahapan *splitting data*. Contoh hasil prediksi terhadap data *testing* menggunakan data saham BBKA disajikan pada Tabel 6.

Tabel 6. Data prediksi saham BBKA

Date	Data Prediksi	
	BBKA (5, 25)	BBKA (5, 50)
2021-12-01	0,746440	0,743903
2021-12-02	0,746126	0,742806
2021-12-03	0,766772	0,759477
⋮	⋮	⋮
2022-12-28	0,901259	0,894324
2022-12-29	0,906469	0,900829
2022-12-30	0,898948	0,896453

4.5. Denormalisasi Data

Pada tahap ini, dilakukan denormalisasi data terhadap harga aktual dan hasil prediksi harga saham sebelumnya untuk mengembalikannya ke skala awal. Proses denormalisasi dilakukan dengan cara melakukan *inverse transform* pada data yang dinormalisasi menggunakan fungsi *MinMaxScaler*. Contoh data harga aktual, hasil prediksi, dan selisih antara keduanya menggunakan saham BBKA dapat dilihat pada Tabel 7.

4.6. Evaluasi Model

Model BiLSTM yang telah dibangun kemudian dievaluasi dengan mengukur nilai MAPE masing-masing model. Berdasarkan pengujian yang dilakukan maka diperoleh nilai MAPE masing-masing model data saham seperti pada Tabel 8.

Berdasarkan Tabel 8, dapat dilihat bahwa secara umum Bayesian Optimization mampu membantu pemilihan hyperparameter yang optimal pada model BiLSTM dengan nilai MAPE yang cukup

Tabel 7. Hasil denormalisasi data saham BBKA

Date	Data Aktual	Data Prediksi		Selisih	
		BBKA (5,25)	BBKA (5,50)	BBKA (5,25)	BBKA (5,50)
2021-12-01	7300	7215	7194	84	105
2021-12-02	7500	7213	7185	286	314
2021-12-03	7375	7382	7322	-7	52
⋮	⋮	⋮	⋮	⋮	⋮
2022-12-28	8650	8488	8431	161	218
2022-12-29	8575	8531	8484	43	90
2022-12-30	8550	8469	8448	80	101

Tabel 8. Nilai MAPE masing-masing model Bayesian Optimization-BiLSTM

Saham	N Iter	MAPE
BBKA	25	1,5661%
	50	1,2092%
BYAN	25	2,7639%
	50	8,5697%
TLKM	25	1,2336%
	50	1,2027%

rendah. Adapun MAPE terendah yang diperoleh pada masing-masing data saham yaitu BBKA 1,2092% pada *n iter* 50, BYAN 2,7639% pada *n iter* 25, dan TLKM 1,2027% pada *n iter* 50. Dari hasil ini dapat disimpulkan bahwa generalisasi untuk masing-masing konfigurasi hyperparameter terbaik berdasarkan nilai MAPE dapat dilakukan dengan baik untuk ketiga data *testing*. Selain itu hal ini menggambarkan bahwa model Bayesian Optimization-BiLSTM mampu melakukan prediksi harga *close* ketiga data saham dengan akurat.

Dari Tabel 7 dan Tabel 8, dapat disimpulkan bahwa meskipun jumlah iterasi yang semakin banyak mengakibatkan nilai MSE semakin tinggi, untuk nilai MAPE berlaku sebaliknya dimana semakin banyak jumlah iterasi yang dilakukan maka nilai MAPE cenderung semakin rendah. Hal ini terlihat berlaku pada kedua saham BBKA dan TLKM sedangkan untuk data saham BYAN terlihat tren yang berbeda dimana peningkatan iterasi tidak menghasilkan peningkatan nilai MAPE. Perbedaan hasil dari ketiga sektor saham ini mencerminkan volatilitas masing-masing sektor saham dimana BBKA dari sektor keuangan dan TLKM dari sektor infrastruktur lebih stabil dibandingkan BYAN dari sektor energi. Dengan demikian beberapa sektor saham mungkin memerlukan pendekatan khusus karena pergerakan harga sahamnya yang dipengaruhi oleh faktor-faktor lain.

Selain membandingkan skenario masing-masing saham, pe-

nelitian ini juga membandingkan nilai matriks evaluasi model terbaik dengan model penelitian terdahulu yang dapat dilihat pada Tabel 9.

Tabel 9. Perbandingan hasil model penelitian dengan model terdahulu

Saham	Model	MAPE
TLKM	<i>Grid Search-BiLSTM</i>	10,83%
	<i>Bayesian Optimization-BiLSTM</i>	1,2027%

Dari Tabel 9 dapat dilihat bahwa dengan menggunakan dataset yang sama, model *Bayesian Optimization-BiLSTM* memiliki nilai MAPE yang lebih rendah dibandingkan model *Grid Search-BiLSTM*. Dengan demikian dapat disimpulkan bahwa model *Bayesian Optimization-BiLSTM* memiliki akurasi yang lebih tinggi dalam memprediksi harga saham.

5. Kesimpulan

Berdasarkan hasil penelitian yang dilakukan maka diperoleh hasil bahwa *Bayesian Optimization* dapat membantu mengoptimisasi pemilihan *hyperparameter* model BiLSTM dengan konfigurasi *hyperparameter* yang optimal pada masing-masing data saham meliputi *batch* 78, *dropout rate* 0,2924, *epoch* 190, dan jumlah *neuron* 24 pada data saham BBCA, *batch* 127, *dropout rate* 0,1234, *epoch* 180, dan jumlah *neuron* 19 pada data saham BYAN, serta *batch* 9, *dropout rate* 0,2168, *epoch* 125, dan jumlah *neuron* 22 pada data saham TLKM. Selain itu dibandingkan dengan penelitian menggunakan model *Grid Search-BiLSTM* sebelumnya, model *Bayesian Optimization-BiLSTM* terbukti mampu memberikan hasil prediksi yang lebih akurat berdasarkan nilai MAPE.

Kontribusi Penulis. Fandi Presly Simamora: Konseptualisasi, metodologi, perangkat lunak, analisis formal, investigasi, sumber daya, kurasi data, penulisan–persiapan draf asli, visualisasi, administrasi proyek. Ronson Purba: Konseptualisasi, metodologi, validasi, analisis formal, investigasi, kurasi data, supervisi. Muhammad Fermi Pasha: Konseptualisasi, metodologi, validasi, analisis formal, investigasi, kurasi data, supervisi. Semua penulis telah membaca dan menyetujui versi manuskrip yang diterbitkan.

Ucapan Terima Kasih. Para penulis menyampaikan terima kasih kepada editor dan reviewer atas pembacaan yang cermat, kritik yang mendalam, dan rekomendasi yang praktis untuk meningkatkan kualitas tulisan ini.

Pembiayaan. Penelitian ini tidak menerima pembiayaan eksternal.

Konflik Kepentingan. Para penulis menyatakan tidak ada konflik kepentingan yang terkait dengan artikel ini.

Ketersediaan Data. Data yang digunakan untuk mendukung temuan dalam penelitian dapat diakses di <http://www.finance.yahoo.com>.

Referensi

- [1] S. Srivinay, B. C. Manujakshi, M. G. Kabadi, and N. Naik, "A Hybrid Stock Price Prediction Model Based on PRE and Deep Neural Network," *Data (Basel)*, vol. 7, no. 5, pp. 1–11, 2022, doi: [10.3390/data7050051](https://doi.org/10.3390/data7050051).
- [2] M. Yang and J. Wang, "Adaptability of Financial Time Series Prediction Based on BiLSTM," in *Procedia Computer Science*, Elsevier B.V., 2022, pp. 18–25, doi: [10.1016/j.procs.2022.01.003](https://doi.org/10.1016/j.procs.2022.01.003).
- [3] Md. A. I. Sunny, M. M. S. Maswood, and A. G. Alharbi, "Deep Learning-Based Stock Price Prediction Using LSTM and Bi-Directional LSTM Model," in *2020 2nd Novel Intelligent and Leading Emerging Sciences Conference (NILES)*, Institute of Electrical and Electronics Engineers Inc., 2020, pp. 87–92, doi: [10.1109/NILESS0944.2020.9257950](https://doi.org/10.1109/NILESS0944.2020.9257950).
- [4] N. B. Korade and Mohd. Zuber, "Stock Price Forecasting using Convolutional Neural Networks and Optimization Techniques," *International Journal of Advanced Computer Science and Applications*, vol. 13, no. 11, pp. 378–385, 2022, doi: [10.14569/IJACSA.2022.0131142](https://doi.org/10.14569/IJACSA.2022.0131142).
- [5] H. Song and H. Choi, "Forecasting Stock Market Indices Using The Recurrent Neural Network Based Hybrid Models: CNN-LSTM, GRU-CNN, and Ensemble Models," *Applied Sciences*, vol. 13, no. 7, pp. 1–26, 2023, doi: [10.3390/app13074644](https://doi.org/10.3390/app13074644).
- [6] H. N. Bhandari, B. Rimal, N. R. Pokhrel, R. Rimal, K. R. Dahal, and R. K. C. Khatri, "Predicting Stock Market Index Using LSTM," *Machine Learning with Applications*, vol. 9, pp. 1–15, 2022, doi: [10.1016/j.mlwa.2022.100320](https://doi.org/10.1016/j.mlwa.2022.100320).
- [7] M. Ulina, R. Purba, and A. Halim, "Foreign Exchange Prediction using CEEMDAN and Improved FA-LSTM," in *2020 Fifth International Conference on Informatics and Computing (ICIC)*, IEEE, 2020, pp. 1–6, doi: [10.1109/ICIC50835.2020.9288615](https://doi.org/10.1109/ICIC50835.2020.9288615).
- [8] D. S. N. Ulum and A. S. Girsang, "Hyperparameter Optimization of Long-Short Term Memory using Symbiotic Organism Search for Stock Prediction," *International Journal of Innovative Research and Scientific Studies*, vol. 5, no. 2, pp. 121–133, 2022, doi: [10.53894/ijirss.v5i2.415](https://doi.org/10.53894/ijirss.v5i2.415).
- [9] B. Gülmez, "Stock Price Prediction with Optimized Deep LSTM Network with Artificial Rabbits Optimization Algorithm," *Expert Syst Appl*, vol. 227, pp. 1–16, 2023, doi: [10.1016/j.eswa.2023.120346](https://doi.org/10.1016/j.eswa.2023.120346).
- [10] A. Singh and L. Markande, "Stock Market Forecasting Using LSTM Neural Network," *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, vol. 9, no. 3, pp. 544–554, 2023, doi: [10.32628/cseit23903138](https://doi.org/10.32628/cseit23903138).
- [11] K. Chen, R. Purba, and A. Halim, "Stock Price Prediction Using XCEEMDAN-Bidirectional LSTM-Spline," *Indonesian Journal of Artificial Intelligence and Data Mining*, vol. 5, no. 1, pp. 1–12, 2022, doi: [10.24014/ijaidm.v5i1.14424](https://doi.org/10.24014/ijaidm.v5i1.14424).
- [12] C. Han and X. Fu, "Challenge and Opportunity: Deep Learning-Based Stock Price Prediction by Using Bi-Directional LSTM Model," *Frontiers in Business, Economics and Management*, vol. 8, no. 2, pp. 51–54, 2023, doi: [10.54097/fbem.v8i2.6616](https://doi.org/10.54097/fbem.v8i2.6616).
- [13] 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 Journal of Mathematics*, vol. 6, no. 1, pp. 39–45, 2024, doi: [10.37905/jjom.v6i1.23297](https://doi.org/10.37905/jjom.v6i1.23297).
- [14] F. Hutter, L. Kotthoff, and J. Vanschoren, "Hyperparameter Optimization," in *Automated Machine Learning*, Springer Cham, 2019, ch. Chapter 1, pp. 3–33. [Online]. Available: <http://www.springer.com/series/15602>.
- [15] J. Wu, X. Y. Chen, H. Zhang, L. D. Xiong, H. Lei, and S. H. Deng, "Hyperparameter Optimization for Machine Learning Models Based on Bayesian Optimization," *Journal of Electronic Science and Technology*, vol. 17, no. 1, pp. 26–40, 2019, doi: [10.11989/JEST.1674-862X.80904120](https://doi.org/10.11989/JEST.1674-862X.80904120).
- [16] P. I. Frazier, "A Tutorial on Bayesian Optimization," pp. 1–22, 2018, doi: [10.48550/arXiv.1807.02811](https://doi.org/10.48550/arXiv.1807.02811).
- [17] F. P. Samaniego, D. G. Reina, S. L. T. Marin, M. Arzamendia, and D. O. Gregor, "A Bayesian Optimization Approach for Water Resources Monitoring Through an Autonomous Surface Vehicle: The Ypacarai Lake Case Study," *IEEE Access*, vol. 9, pp. 9163–9179, 2021, doi: [10.1109/ACCESS.2021.3050934](https://doi.org/10.1109/ACCESS.2021.3050934).
- [18] S. Hochreiter and J. Schmidhuber, "Long Short Term Memory," *Neural Comput*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [19] M. Jia, J. Huang, L. Pang, and Q. Zhao, "Analysis and Research on Stock Price of LSTM and Bidirectional LSTM Neural Network," in *Proceedings of the 3rd International Conference on Computer Engineering, Information Science & Application Technology (ICCIA 2019)*, Atlantis Press, 2019, pp. 467–473, doi: [10.2991/iccia-19.2019.72](https://doi.org/10.2991/iccia-19.2019.72).
- [20] T. Liwei, F. Li, S. Yu, and G. Yuankai, "Forecast of LSTM-XGBoost in Stock Price Based on Bayesian Optimization," *Intelligent Automation and Soft Computing*, vol. 29, no. 3, pp. 855–868, 2021, doi: [10.32604/iasc.2021.016805](https://doi.org/10.32604/iasc.2021.016805).