

Optimasi Hyperparameter N-BEATS Menggunakan Optuna untuk Prediksi Harga Saham BBKA

DOI: <http://dx.doi.org/10.35889/jutisi.v15i1.3517>

Creative Commons License 4.0 (CC BY – NC)

Haeruddin^{1*}, Gautama Wijaya², Sherly³

Teknologi Informasi, Universitas Internasional Batam, Batam, Indonesia

*e-mail Corresponding Author: haeruddin@uib.ac.id

Abstract

Stock price prediction is crucial for supporting informed investment decisions due to the high volatility of stock prices. One of the key challenges in deep learning-based stock price prediction is determining the right hyperparameters. This research aimed to assess whether hyperparameter tuning with Optuna can enhance the N-BEATS model performance for predicting the stock price of PT Bank Central Asia Tbk. Historical stock price data were used and chronologically divided into training, validation, and testing sets. The efficacy of the models was measured using MAPE, RMSE, and R². The results showed that hyperparameter optimization using Optuna considerably enhanced the performance of N-BEATS, achieving a MAPE of 1.27%, which outperformed the standard N-BEATS model (1.44%) and the LSTM model (1.41%). This study proved that a systematic hyperparameter optimization approach can improve the performance of stock price forecasting models.

Keyword: N-BEATS; Optuna; Stock; Predict; BBKA

Abstrak

Prediksi harga saham menjadi aspek penting dalam mendukung penentuan keputusan investasi karena fluktuasi harga saham yang tinggi. Salah satu tantangan utama dalam pemodelan prediksi harga saham berbasis *deep learning* adalah penentuan *hyperparameter* yang tepat. Penelitian ini bertujuan untuk mengevaluasi efektivitas optimasi *hyperparameter* menggunakan Optuna dalam meningkatkan kinerja model N-BEATS untuk prediksi harga saham PT Bank Central Asia Tbk. Data historis harga saham digunakan dan dibagi secara kronologis menjadi data latih, validasi, dan uji. Evaluasi kinerja akhir dilakukan menggunakan metrik MAPE, RMSE, dan R². Hasil penelitian menunjukkan bahwa optimasi *hyperparameter* dengan Optuna mampu meningkatkan kinerja N-BEATS dengan nilai MAPE sebesar 1.27% dibandingkan dengan N-Beats standar (MAPE 1.44%) dan LSTM (MAPE 1.41%). Penelitian ini menunjukkan bahwa pendekatan optimasi *hyperparameter* yang sistematis efektif dalam meningkatkan kinerja model prediksi harga saham.

Kata kunci: N-BEATS; Optuna; Saham; Prediksi; BBKA

1. Pendahuluan

Partisipasi masyarakat di pasar modal terus meningkat dan berkontribusi pada pertumbuhan ekonomi serta ketahanan finansial jangka panjang. Namun, fluktuasi harga saham menghadirkan tantangan, terutama bagi investor pemula karena berisiko menimbulkan kerugian signifikan [1]. Fenomena tingginya minat masyarakat terhadap investasi terlihat jelas di Indonesia. Berdasarkan data Bursa Efek Indonesia, jumlah investor tercatat 14,87 juta *Single Investor Identification* (SID) pada akhir 2024, kemudian melonjak sebesar 36,6% sepanjang tahun 2025 hingga mencapai 20,32 juta investor pada akhir Desember 2025 [2][3]. Kemampuan untuk memprediksi pergerakan harga saham menjadi aspek penting bagi investor di tengah kondisi pasar yang volatil karena berperan dalam memaksimalkan keuntungan dan mengurangi risiko investasi [4]. Prediksi harga saham sendiri telah lama menjadi fokus utama dalam pemodelan keuangan karena berpengaruh besar terhadap strategi investasi, manajemen risiko, serta efisiensi pasar [5].

PT Bank Central Asia Tbk (BBCA) adalah salah satu perusahaan dengan kapitalisasi pasar terbesar di Indonesia, sehingga pergerakan harga sahamnya menjadi perhatian utama investor pasar modal. Kinerja fundamental BBCA yang menunjukkan pertumbuhan pendapatan secara konsisten memperkuat kepercayaan investor dan memengaruhi dinamika harga saham perusahaan [6]. Namun, saham memiliki karakteristik non linier dan fluktuatif serta dipengaruhi oleh berbagai faktor, sehingga pola pergerakan harganya sulit diekstraksi secara langsung [7]. Investor harus menentukan waktu membeli, menjual, atau mempertahankan saham, di mana keputusan yang salah dapat meningkatkan risiko kerugian. Oleh karena itu, analisis terhadap perubahan harga saham historis penting untuk memperkirakan pergerakan harga di masa depan [8].

Neural Basis Expansion Analysis for Time Series (N-BEATS) merupakan model *deep learning* untuk peramalan deret waktu univariat. Model ini memiliki arsitektur berbasis *backward* dan *forward residual links* serta lapisan *fully connected* yang dalam. Pengujian pada berbagai dataset *benchmark* menunjukkan bahwa N-BEATS menghasilkan akurasi peramalan yang lebih tinggi dibandingkan sejumlah metode pembandingan, serta memiliki proses pelatihan yang cepat [9]. Akiba et al. (2019) menyatakan pencarian *hyperparameter* adalah salah satu tahapan yang paling menantang dalam pengembangan proyek *machine learning*. Seiring dengan meningkatnya kompleksitas metode *deep learning*, kebutuhan akan teknik optimasi *hyperparameter* otomatis yang efisien menjadi semakin penting. Untuk menghadapi tantangan tersebut, Optuna dikembangkan sebagai kerangka kerja optimasi *hyperparameter* otomatis yang dibuat untuk mencari parameter secara efisien, termasuk melalui penghentian awal pada konfigurasi yang tidak menjanjikan [10].

Penerapan arsitektur N-BEATS untuk menganalisis deret waktu telah dilakukan pada berbagai skala pasar, mulai dari indeks global hingga saham sektoral. Hal ini ditunjukkan oleh Liu et al. (2023) yang menggunakan N-BEATS untuk memprediksi indeks S&P 500 berdasarkan data *time series* dari 500 saham konstituen dengan interval per menit. Hasil penelitian menunjukkan bahwa N-BEATS secara konsisten mengungguli tujuh model *deep learning* lainnya, termasuk CNN, RNN, LSTM, dan GRU. Berdasarkan metrik evaluasi, N-BEATS memperoleh MAPE sebesar 0.02%, RMSE sebesar 0.8242, serta nilai *correlation coefficient* (COR) yang sangat tinggi yaitu 0.9998 [11]. Asmat dan Maiyama (2025) menerapkan arsitektur N-BEATS untuk prediksi harga Bitcoin menggunakan data *time series* per jam selama 729 hari yang diperoleh dari Yahoo Finance. Hasil evaluasi menunjukkan bahwa N-BEATS memiliki kinerja terbaik, dengan nilai MAE sebesar 0.00240 dan R^2 mencapai 0.9998, mengungguli model LSTM (MAE 0.04753; R^2 0.9263) dan Linear Regression (MAE 0.008994; R^2 0.9645) [12]. Namun, konfigurasi *hyperparameter* dalam kedua penelitian tersebut ditentukan secara manual tanpa menggunakan metode optimasi *hyperparameter* otomatis.


Naik et al. (2024) menggunakan N-BEATS untuk prediksi harga saham S&P 500 dan membandingkan dengan CNN, LSTM, dan GRU berdasarkan data Google Finance periode 2018-2023. Evaluasi menggunakan MAPE, MAE, dan RMSE, serta uji Diebold–Mariano, menunjukkan bahwa N-BEATS menghasilkan kinerja terbaik dengan nilai MAPE sebesar 1.15%, mengungguli CNN (1.61%), LSTM (1.70%), dan GRU (1.66%) [13]. Penelitian tersebut menerapkan *random search* dengan pembagian data *train-test* tanpa menggunakan *validation set* terpisah. Zein et al. (2024) mengevaluasi kinerja N-BEATS dalam memprediksi harga saham BBCA menggunakan data historis periode 25 Maret 2013-21 Maret 2023. Hasil menunjukkan bahwa N-BEATS menghasilkan MAPE terendah bernilai 1.05%, lebih baik jika dibandingkan dengan LSTM (1.40%), RNN (1.67%), dan ARIMA (1.07%) [4]. *Tuning hyperparameter* dilakukan dengan menguji konfigurasi setiap skenario tanpa optimasi *hyperparameter* otomatis.

Riswanda et al. (2025) menunjukkan bahwa penerapan optimasi Optuna dapat meningkatkan kinerja N-BEATS secara signifikan. Pada kasus prediksi inflasi Jawa Timur menggunakan data bulanan periode 2005-2024, N-BEATS yang dioptimasi Optuna mencapai MAPE 8.97%, mengungguli N-BEATS tanpa optimasi (11.05%), LSTM (12.23%), dan ARIMA (16.95%) [14]. Hal ini menunjukkan bahwa optimasi *hyperparameter* menggunakan Optuna secara signifikan meningkatkan akurasi model dibandingkan N-BEATS dasar, serta mengurangi risiko *overfitting* atau *underfitting* akibat konfigurasi parameter yang tidak tepat. Penelitian tersebut berfokus pada lingkup ekonomi makro, sehingga membuka peluang untuk penerapan pada prediksi harga saham.

Berdasarkan celah penelitian tersebut, penelitian ini bertujuan untuk mengevaluasi efektivitas optimasi *hyperparameter* menggunakan Optuna dalam meningkatkan kinerja dan stabilitas prediksi model N-BEATS pada pasar modal, khususnya saham BBKA menggunakan data jangka panjang (2016-2025). Selain itu, efektivitas model yang diusulkan akan diuji dengan membandingkannya dengan model *deep learning* LSTM. Evaluasi kinerja akhir model dilakukan menggunakan metrik *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), dan *R-Squared* (R^2) pada data uji untuk memastikan ketepatan dan stabilitas hasil prediksi terhadap fluktuasi data harga saham. Kebaruan penelitian ini terletak pada penerapan optimasi *hyperparameter* otomatis pada model N-BEATS untuk prediksi harga saham BBKA, sementara penelitian sebelumnya secara umum masih melakukan penentuan *hyperparameter* secara manual atau eksplorasi konfigurasi terbatas per skenario.

2. Metodologi

Penelitian ini dilakukan dengan pendekatan kuantitatif dan penelitian dikategorikan sebagai riset komputasi yang berfokus pada evaluasi kinerja algoritma untuk memprediksi deret waktu dalam upaya peramalan harga saham. Pendekatan kuantitatif dipilih karena seluruh proses penelitian dilakukan berdasarkan pengolahan dan analisis data numerik historis harga saham [15]. Metodologi penelitian disusun secara sistematis, mencakup tahapan pengumpulan data, *preprocessing data*, pemodelan, optimasi *hyperparameter*, serta evaluasi dan perbandingan kinerja model.



Gambar 1. Metodologi Penelitian

2.1 Pengumpulan Data

Data yang digunakan diperoleh dari Yahoo Finance berupa data historis harga saham harian PT Bank Central Asia Tbk (BBKA) dengan rentang waktu 1 Januari 2016 hingga 31 Desember 2025. Data terdiri atas enam atribut, yaitu *open*, *high*, *low*, *close*, *adjusted close*, dan *volume*. Penelitian ini berfokus pada harga penutupan (*close price*) sebagai variabel target.

2.2 Preprocessing Data

Preprocessing data merupakan tahap yang penting untuk menjamin kualitas dan konsistensi dataset [16]. Sebelum data dimasukkan ke dalam model, terdapat serangkaian proses yang harus dilakukan dimulai dari pemeriksaan dan pembersihan dataset untuk memastikan tidak terdapat nilai yang hilang (*missing values*). Nilai yang hilang dapat menyebabkan noise dalam proses pelatihan dan pengujian model [17]. Data disusun berdasarkan urutan waktu dari tanggal paling lama ke terbaru agar pola temporal dapat dimanfaatkan dengan benar dalam proses pelatihan model. Dataset dibagi secara berurutan menjadi data *training* (70%), *validation* (10%), dan *testing* (20%). Data *training* digunakan untuk

melatih model, data *validation* dimanfaatkan dalam proses penyesuaian parameter, dan data *testing* untuk mengevaluasi kemampuan generalisasi model [18].

Normalisasi dilakukan dengan mengubah rentang nilai data menjadi seragam, yaitu antara 0 hingga 1, tanpa mengubah bentuk distribusi aslinya. Proses ini sangat penting untuk menjamin stabilitas (*robustness*) selama proses pelatihan model sekaligus menghilangkan risiko dominasi fitur tertentu yang dapat mengganggu keakuratan prediksi. Metode yang digunakan adalah Min-Max Scaling dengan rumus [13]:

$$X'_t = \frac{X_t - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Dalam rumus ini, X_{min} dan X_{max} melambangkan nilai terendah dan tertinggi dalam rangkaian data historis, sedangkan X_t adalah nilai aktual pada periode tertentu yang kemudian diubah menjadi nilai ternormalisasi X'_t . Metode *sliding window* digunakan untuk mengubah data deret waktu menjadi data *supervised learning*, dengan menggunakan nilai pada beberapa periode sebelumnya sebagai *input* dan nilai pada periode berikutnya sebagai target prediksi satu langkah ke depan [19].

2.3 Model Prediksi

2.2.1 N-Beats

N-BEATS (Neural Basis Expansion Analysis for Time Series) merupakan arsitektur *deep learning* untuk prediksi data *time series*, yang memandang masalah prediksi sebagai regresi multivariat non-linear. Model ini terdiri dari beberapa *stack* berisi blok yang memproses *input* melalui *fully connected layer* untuk menghasilkan *backcast* (rekonstruksi input) dan *forecast* (prediksi), sementara residual diteruskan ke blok berikutnya. Dengan mengumpulkan blok residual, N-BEATS dapat menangkap ketergantungan temporal kompleks dan menghasilkan prediksi akurat. Arsitektur *deep residual learning*-nya mengatasi *vanishing gradient*, sehingga memungkinkan penggunaan banyak lapisan tanpa mengurangi kemampuan generalisasi [20].

2.2.2 Optimasi dengan Optuna

Penelitian ini menerapkan Optuna untuk mengoptimasi hyperparameter karena mampu menjelajahi ruang pencarian yang kompleks dan berdimensi tinggi dengan efisien. Optuna menggunakan *Tree-Structured Parzen Estimator* (TPE) sebagai metode pengambilan sampel, yang lebih efektif dibandingkan Grid Search dan Random Search, karena fokus pada area *hyperparameter* yang menjanjikan. Dengan mempertimbangkan hasil evaluasi sebelumnya, TPE mempercepat konvergensi ke konfigurasi optimal dengan iterasi dan biaya komputasi yang lebih rendah [14].

Tabel 1. Rentang Hyperparameter Optuna untuk Model N-BEATS

Hyperparameter Optuna	
window	30 – 90
hidden_size	64 – 512
n_layers	1-4
n_stacks	1-4
n_blocks	1-4
dropout	0.0 – 0.3
learning_rate	1e-4 – 1e-2
batch_size	{32, 64, 128}

Optimasi dilakukan pada beberapa *hyperparameter* utama, seperti ukuran *window*, jumlah *neuron*, jumlah *layer*, jumlah *stack*, *dropout rate*, *learning rate*, dan *batch size*. Fungsi objektif optimasi adalah mengurangi nilai kesalahan pada data *validation*.

2.2.3 Baseline Model

Long Short-Term Memory (LSTM) merupakan varian Recurrent Neural Network (RNN) yang diperkenalkan oleh Hochreiter dan Schmidhuber pada 1997. LSTM memiliki kemampuan untuk menangani ketergantungan jangka panjang dalam data berurutan, seperti harga saham. LSTM dapat mengingat informasi historis dan memprediksi pola berdasarkan urutan waktu.

Strukturnya terdiri dari lapisan *input*, *tersembunyi*, dan *output*, dengan *memory cell* serta tiga gerbang (*input*, *output*, dan *forget*) yang memungkinkan model menyimpan atau melupakan informasi penting untuk blok berikutnya [19].

2.4 Evaluasi dan Perbandingan Model

Mean Squared Error (MSE) merupakan salah fungsi *loss* yang banyak digunakan dalam prediksi harga saham [21]. Dalam penelitian ini, MSE digunakan untuk mengontrol kinerja model selama proses pelatihan pada data latih dan data validasi, serta sebagai dasar untuk menerapkan mekanisme *early stopping*.

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

Metrik evaluasi digunakan sebagai indikator untuk menilai kinerja prediksi suatu model. Dalam model time-series, ini dilakukan dengan mengukur kesalahan yang dihasilkan oleh model. Metrik yang digunakan untuk mengevaluasi model mencakup *Mean Absolute Percentage Error* (MAPE), *Root Mean Squared Error* (RMSE), dan *R-Squared* (R^2). MAPE menilai rata-rata selisih absolut antara nilai prediksi dan nilai yang sebenarnya dalam bentuk persentase, sehingga memudahkan pemahaman tentang seberapa besar deviasi relatif yang terjadi [18].

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (3)$$

RMSE menghitung rata-rata selisih kuadrat antara nilai prediksi dan nilai aktual, lalu diakarkan. Karena sensitif terhadap *outlier*, RMSE efektif untuk mengevaluasi rata-rata kesalahan model dalam skala absolut [15].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

R-squared berfungsi untuk menilai seberapa dekat nilai hasil prediksi dengan nilai aktual, serta merefleksikan kemampuan model dalam menjelaskan variasi pada harga saham [22].

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

3. Hasil dan Pembahasan

Penelitian ini berfokus pada evaluasi kinerja N-BEATS yang dioptimasi menggunakan Optuna dalam melakukan prediksi harga penutupan saham BBKA dengan *horizon* satu langkah ke depan. Sebagai pembandingan, penelitian ini menggunakan model LSTM yang umum digunakan untuk prediksi deret waktu saham.

3.1 Hasil Pengumpulan Data

		Open	High	Low	Close	AdjClose	Volume
2016-01-04	00:00:00	2635.0	2685.0	2630.0	2645.0	2180.474365	77479500
2016-01-05	00:00:00	2640.0	2710.0	2640.0	2675.0	2205.205811	96609000
2016-01-06	00:00:00	2665.0	2700.0	2640.0	2640.0	2176.352295	105370000
2016-01-07	00:00:00	2620.0	2630.0	2600.0	2600.0	2143.377441	146746500
2016-01-08	00:00:00	2590.0	2620.0	2590.0	2600.0	2143.377441	125820000
...	...	...	...	...	...	...	...
2025-12-23	00:00:00	8100.0	8125.0	7975.0	8025.0	8025.0	85044100
2025-12-24	00:00:00	8025.0	8075.0	8000.0	8025.0	8025.0	71260500
2025-12-26	00:00:00	8025.0	8025.0	8025.0	8025.0	8025.0	0
2025-12-29	00:00:00	8025.0	8025.0	7950.0	8025.0	8025.0	78399400
2025-12-30	00:00:00	7950.0	8175.0	7950.0	8075.0	8075.0	101995600

Gambar 2. Data Historis Saham BBKA

Data historis saham BBKA dengan periode 1 Januari 2016 hingga 31 Desember 2025 diperoleh dari Yahoo Finance menggunakan *library yfinance* dengan ticker BBKA.JK.

3.2 Hasil Preprocessing Data

Tahap *preprocessing* bertujuan untuk menyiapkan data sehingga bisa diproses oleh model statistik maupun *deep learning* tanpa menimbulkan *bias* atau kebocoran informasi. Prosedur yang dilakukan dimulai dari pembersihan dan validasi struktur data. Data diurutkan

berdasarkan waktu (*ascending*) dan dilakukan pemeriksaan *missing value*. Atribut *close* dipilih sebagai variabel target.

Pembagian data (*time-based split*) dilakukan secara berurutan (tanpa *shuffle*) menjadi data latih 70% dengan 1726 data, data validasi 10% dengan 246 data, dan data uji 20% dengan 495 data karena optimasi Optuna dan *early stopping* memerlukan *validation set* agar pemilihan *hyperparameter* tidak terpengaruh oleh data uji. Strategi memastikan keadilan dalam evaluasi karena *test set* benar-benar merepresentasikan data masa depan yang tidak digunakan dalam pelatihan maupun *tuning*. Normalisasi dilakukan menggunakan MinMaxScaler (0–1), tetapi *fit scaler* hanya pada data latih, selanjutnya *scaler* yang sama digunakan untuk mentransformasi data validasi dan uji. Pendekatan ini mencegah kebocoran informasi karena statistik data masa depan tidak ikut mempengaruhi proses scaling. *Sliding window* digunakan untuk membentuk *supervised learning*.

3.3 Hasil Pemodelan

3.3.1 Penerapan N-Beats

Model N-BEATS standar diterapkan dengan jendela input sepanjang 60 hari untuk menjaga konsistensi dengan model LSTM yang dijadikan pembanding. Arsitektur N-BEATS menggunakan *hidden size* sebesar 256 dengan dua lapisan *fully-connected* pada setiap *block*. Model ini terdiri atas dua *stack* dengan masing-masing dua *block*, sehingga total terdapat empat *residual block* yang berfungsi untuk memahami pola temporal secara bertahap. Proses pelatihan dilakukan menggunakan *optimizer Adam* dengan *learning rate* sebesar 0.001 dan ukuran *batch* sebanyak 64. Jumlah *epoch* maksimum ditetapkan sebesar 120 dengan mekanisme *early stopping* dan *patience* sebesar 15 untuk memberikan ruang pelatihan yang lebih luas pada arsitektur N-BEATS yang lebih dalam.

3.3.2 Hasil Optimasi Hyperparameter N-BEATS dengan Optuna

Bagian ini menyajikan hasil optimasi hyperparameter model N-BEATS menggunakan Optuna serta membahas pengaruh optimasi tersebut terhadap kinerja prediksi harga saham. Untuk proses optimasi, Tree-structured Parzen Estimator (TPE) digunakan sebagai sampler dan bertujuan untuk mengurangi validasi Mean Squared Error (MSE). Hasil yang disajikan adalah konfigurasi hyperparameter terbaik yang diperoleh dari proses optimasi. Konfigurasi terbaik diperoleh setelah melakukan 50 percobaan.

Tabel 2. Konfigurasi Hyperparameter Terbaik

Hyperparameter Optuna	
window	40
hidden_size	256
n_layers	4
n_stacks	1
n_blocks	3
dropout	0.13
learning_rate	0.00091
batch_size	32

Nilai objektif terbaik yang dicapai adalah validation MSE = 0.000254. Model dengan konfigurasi ini kemudian dilatih kembali menggunakan data pelatihan dan validasi sebelum dievaluasi pada data pengujian.

3.3.3 Penerapan Model Baseline LSTM

Model Long Short-Term Memory (LSTM) diterapkan sebagai model pembanding dengan konfigurasi jendela *input* sepanjang 60 hari untuk menangkap pola pergerakan harga saham dalam jangka menengah. Arsitektur LSTM menggunakan satu lapisan tersembunyi dengan 64 unit, yang dipilih untuk memastikan keseimbangan antara kemampuan representasi model dan tingkat kompleksitas komputasi. Proses pelatihan dilakukan menggunakan *optimizer Adam* dengan *learning rate* sebesar 0.001 dan ukuran *batch* sebanyak 64. Untuk menghindari terjadinya

overfitting, diterapkan mekanisme *early stopping* dengan nilai *patience* sebesar 12 dan jumlah *epoch* maksimum sebanyak 80.

3.4 Evaluasi dan Perbandingan Kinerja Model

Evaluasi kinerja model selama proses pelatihan dilakukan untuk menilai bagaimana model mempelajari pola data dan mempertahankan kemampuan generalisasi sebelum diuji pada data uji. Proses pelatihan model dilakukan secara berulang menggunakan metrik MSE pada data latih dan data validasi. Nilai MSE pada data latih mencerminkan kemampuan model dalam memahami pola historis, sedangkan nilai MSE pada data validasi digunakan untuk mengevaluasi kemampuan generalisasi terhadap data yang tidak terlibat dalam proses pembaruan bobot model. Oleh karena itu, evaluasi pada data validasi berperan penting dalam mengidentifikasi potensi *overfitting* selama proses pelatihan. Berikut kinerja pelatihan model berdasarkan nilai MSE data latih dan data validasi pada *epoch* terbaik yang ditentukan oleh kinerja validasi.

Tabel 3. Kinerja Model pada Proses Pelatihan


Model	Train MSE	Val MSE
LSTM	0.000298	0.000360
N-BEATS Standar	0.000292	0.000340
N-BEATS + Optuna	0.000224	0.000254

Model LSTM menunjukkan penurunan *error* pada data latih yang konsisten dengan fluktuasi moderat pada data validasi, yang mengindikasikan bahwa proses relatif stabil. Pada model N-BEATS standar, penurunan *error* terjadi dengan cepat di tahap awal pelatihan, namun disertai fluktuasi nilai MSE pada data validasi yang lebih besar, menyebabkan mekanisme *early stopping* menghentikan proses pelatihan. Sementara itu, N-BEATS dengan optimasi Optuna memperoleh nilai MSE validasi terendah, yang menandakan bahwa konfigurasi *hyperparameter* hasil optimasi berkontribusi dalam menjaga kestabilan kinerja model selama pelatihan. Hasil evaluasi ini menunjukkan bahwa penggunaan data validasi berperan penting dalam mengontrol proses pembelajaran model sebelum dilakukan evaluasi akhir pada data uji. Evaluasi kinerja dilakukan terhadap data uji menggunakan metrik MAPE, RMSE, dan R^2 .

Tabel 4. Perbandingan Kinerja Model pada Data Uji


Model	MAPE(%)	RMSE	R^2
N-BEATS + Optuna	1.27	149.34	0.97
N-BEATS Standar	1.44	171.42	0.96
LSTM	1.41	169.84	0.96

Hasil evaluasi menunjukkan bahwa model N-BEATS yang dioptimasi menggunakan Optuna menunjukkan kinerja terbaik dibandingkan model lainnya. Model ini memiliki nilai RMSE dan MAPE yang lebih rendah serta nilai R -squared yang lebih tinggi dibandingkan LSTM dan N-BEATS standar. Model LSTM sebagai pembanding menunjukkan performa yang cukup baik dalam mengikuti pola umum harga saham, meskipun akurasi masih kurang jika dibandingkan dengan N-BEATS yang telah dioptimasi. Di sisi lain, N-BEATS standar tanpa optimasi *hyperparameter* belum mampu mengungguli LSTM.




Gambar 3. Perbandingan Harga Aktual dan Prediksi Model LSTM

Gambar 3 memperlihatkan perbandingan antara harga penutupan saham BBKA aktual dan hasil prediksi menggunakan model LSTM dengan *horizon* satu langkah ke depan. Model LSTM dapat mengikuti pola pergerakan harga saham dan menangkap tren jangka menengah dengan cukup baik. Namun, pada beberapa periode saat terjadi perubahan harga yang tajam, terlihat bahwa hasil prediksi LSTM tampak lebih halus dibandingkan data aktual. Hal ini menunjukkan bahwa meskipun LSTM mampu menangkap pola temporal secara umum, terdapat keterbatasan dalam merespons fluktuasi harga yang bersifat mendadak.



Gambar 4. Perbandingan Harga Aktual dan Prediksi Model N-BEATS Standar

Model N-BEATS standar mampu mengikuti tren umum dari pergerakan harga saham dan menunjukkan pola yang relatif serupa dengan model LSTM. Akan tetapi, pada saat terjadi volatilitas tinggi, prediksi model masih menunjukkan deviasi terhadap nilai aktual. Hasil ini mengindikasikan bahwa tanpa optimasi *hyperparameter*, kemampuan N-BEATS dalam menyesuaikan diri terhadap dinamika pasar yang kompleks belum optimal.



Gambar 5. Perbandingan Harga Aktual dan Prediksi Model N-BEATS + Optuna

Hasil prediksi N-BEATS yang telah dioptimasi dengan Optuna terlihat lebih stabil dalam mengikuti pergerakan harga aktual dibandingkan dengan model LSTM dan N-BEATS standar. Model ini lebih responsif terhadap perubahan harga yang membuat perbedaan antara nilai prediksi dan nilai aktual terlihat lebih kecil secara visual. Hal ini menunjukkan bahwa optimasi *hyperparameter* berpengaruh dalam meningkatkan kemampuan representasi dan generalisasi model N-BEATS.

3.5 Pembahasan

Pada tahap pelatihan, model LSTM, N-BEATS standar, dan N-BEATS dengan optimasi Optuna masing-masing menunjukkan kemampuan pembelajaran yang baik dengan selisih MSE antara data latih dan data validasi yang cukup kecil. Pelaporan nilai MSE dilakukan pada *epoch* dengan kinerja validasi terbaik untuk setiap model. LSTM menghasilkan MSE sebesar 0.000298 pada data latih dan 0.000360 pada data validasi. N-BEATS standar menghasilkan MSE data latih sebesar 0.000292, dengan MSE validasi sebesar 0.000340. Sementara itu, N-BEATS dengan optimasi Optuna menghasilkan nilai MSE data latih sebesar 0.000224 dan nilai MSE validasi terendah, yaitu 0.000254. Hasil penelitian menunjukkan bahwa penerapan optimasi *hyperparameter* menggunakan Optuna mampu meningkatkan kinerja model N-BEATS dalam prediksi harga saham BBKA. Selama proses pelatihan, evaluasi berbasis data validasi

menunjukkan bahwa konfigurasi *hyperparameter* hasil optimasi menghasilkan nilai error validasi yang lebih rendah dan stabil dibandingkan N-BEATS standar. Hal ini mengindikasikan bahwa proses optimasi berbasis validasi berperan penting dalam mengarahkan proses pembelajaran model dan mengurangi potensi *overfitting* sebelum evaluasi akhir dilakukan pada data uji.

Pada tahap pengujian, N-BEATS dengan optimasi Optuna memberikan kinerja terbaik berdasarkan metrik evaluasi yang digunakan dengan nilai MAPE mencapai 1.27%, RMSE sebesar 149.34, dan nilai R^2 sebesar 0.97. Model N-BEATS standar dan LSTM menunjukkan kinerja yang cukup sebanding, dengan MAPE masing-masing bernilai 1.44% dan 1.41%, RMSE 171.42 dan 169.84, dan nilai R^2 sebesar 0.96. Meskipun model LSTM dan N-BEATS standar memiliki kinerja yang kompetitif, penerapan optimasi *hyperparameter* pada N-BEATS menghasilkan peningkatan dalam akurasi dan kemampuan generalisasi yang lebih baik pada data uji. Hal ini menunjukkan bahwa peningkatan kinerja model tidak hanya bergantung pada arsitektur, tetapi juga pada penentuan *hyperparameter* yang sesuai.

Hasil penelitian ini sejalan dengan penelitian terdahulu yang mengungkapkan keunggulan N-BEATS dalam pemodelan deret waktu finansial [4], [11-13]. Namun, berbeda dari penelitian sebelumnya yang secara umum masih melakukan penentuan *hyperparameter* secara manual atau eksplorasi konfigurasi terbatas per skenario, penelitian ini menerapkan optimasi *hyperparameter* otomatis menggunakan Optuna sebagai pendekatan yang lebih sistematis dalam menentukan konfigurasi model.

Selain itu, hasil penelitian ini melengkapi penelitian [14] yang menunjukkan efektivitas Optuna dalam mengoptimasi N-BEATS pada prediksi inflasi Jatim. Penerapan Optuna pada data harga saham BBKA menunjukkan bahwa optimasi *hyperparameter* otomatis tetap efektif dalam meningkatkan kinerja model. Dengan demikian, penelitian ini memperluas penerapan optimasi *hyperparameter* N-BEATS dari lingkup ekonomi makro ke pasar modal. Secara keseluruhan, hasil penelitian ini menunjukkan bahwa keberhasilan model *deep learning* dalam prediksi harga saham tidak hanya dipengaruhi oleh pemilihan arsitektur, melainkan juga oleh strategi pendekatan yang digunakan dalam menetapkan *hyperparameter*.

4. Simpulan

Penelitian ini bertujuan untuk mengevaluasi efektivitas optimasi *hyperparameter* menggunakan Optuna dalam meningkatkan kinerja model Neural Basis Expansion Analysis for Time Series (N-BEATS) pada prediksi harga saham BBKA. Hasil menunjukkan bahwa model N-BEATS dengan konfigurasi standar belum mengungguli model LSTM. Namun, setelah optimasi *hyperparameter* dilakukan menggunakan Optuna, kinerja model N-BEATS mengalami peningkatan, ditunjukkan oleh nilai kesalahan prediksi yang lebih rendah serta tingkat kesesuaian yang lebih tinggi terhadap data aktual dibandingkan LSTM dan N-BEATS standar. Hal ini menegaskan bahwa pemilihan dan penyesuaian *hyperparameter* adalah faktor penting dalam meningkatkan kinerja model *deep learning* untuk memprediksi harga saham. Oleh karena itu, penggunaan Optuna terbukti efektif sebagai pendekatan optimasi *hyperparameter* untuk meningkatkan akurasi prediksi harga saham BBKA. Penelitian selanjutnya dapat melakukan pengembangan lebih lanjut melalui pemanfaatan fitur tambahan, *horizon* prediksi yang lebih panjang, dan penerapan metode optimasi lain untuk meningkatkan kinerja model.

Daftar Referensi

- [1] M. Hani'ah, M. Z. Abdullah, W. I. Sabilla, S. Akbar, and D. R. Shafara, "Google Trends and Technical Indicator based Machine Learning for Stock Market Prediction," *Matrik J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 22, no. 2, pp. 271–284, 2023, doi: <https://doi.org/10.30812/matrik.v22i2.2287>.
- [2] Bursa Efek Indonesia, "SID Baru Bertambah 2,5 Juta, Investor Pasar Modal Tembus 17 Juta," *Regional Development Information System (RDIS) - Bursa Efek Indonesia*, 2025. <https://rdis.idx.co.id/id/news/sid-baru-bertambah-2-5-juta-investor-pasar-modal-tembus-17-juta> (accessed Dec. 31, 2025).
- [3] Bursa Efek Indonesia, "Menutup Tahun Penuh Prestasi, Pasar Modal Indonesia Optimis Menyongsong Tahun 2026," *Siaran Pers PT Bursa Efek Indonesia (PR No: 113/BEI.SPR/12-2025)*, 2025. <https://www.idx.co.id/id/berita/siaran-pers/2531> (accessed Dec. 31, 2025).
- [4] M. H. Zein, N. Yudistira, and P. P. Adikara, "Indonesian Stock Price Prediction Using Neural Basis Expansion Analysis for Interpretable Time Series Method," *J. Inf. Commun. Technol.*,

- vol. 23, no. 3, pp. 361–392, 2024, [Online]. Available: <https://e-journal.uum.edu.my/index.php/jict/article/view/20874>
- [5] X. Fan, C. Tao, and J. Zhao, “Advanced stock price prediction with xLSTM-based models: Improving long-term forecasting,” in *2024 11th International Conference on Soft Computing & Machine Intelligence (ISCMI)*, 2024, pp. 117–123. [Online]. Available: <https://api.semanticscholar.org/CorpusID:275956611>
- [6] M. R. Almasah and W. A. E. Prabowo, “Implementasi Deep Neural Network untuk Prediksi Harga Saham PT Bank Central Asia Tbk,” *J. Ris. Komput.*, vol. 12, no. 2, pp. 129–139, 2025, doi: <https://doi.org/10.30865/jurikom.v12i2.8544>.
- [7] Z. Pangestika and B. P. Josaphat, “Predicting Stock Price Using Convolutional Neural Network and Long Short Term Memory (Case Study: Stock of BBCA),” *J. Indones. Math. Soc.*, vol. 31, no. 1, pp. 1–18, 2025, doi: <https://doi.org/10.22342/jims.v31i1.1512>.
- [8] F. T. Samuelly and Y. Nataliani, “Prediksi Pergerakan Harga Saham Bank Mandiri Menggunakan Metode Support Vector Regression dan Algoritma Grid Search,” *Jutisi J. Ilm. Tek. Inform. dan Sist. Inf.*, vol. 14, no. 3, pp. 1441–1451, 2025, doi: <http://dx.doi.org/10.35889/jutisi.v14i3.3206>.
- [9] B. N. Oreshkin, D. Carpov, N. Chapados, and Y. Bengio, “N-BEATS: Neural basis expansion analysis for interpretable time series forecasting,” *arXiv*, pp. 1–31, 2020, doi: <https://doi.org/10.48550/arXiv.1905.10437>.
- [10] T. Akiba, S. Sano, T. Yanase, T. Ohta, and M. Koyama, “Optuna: A Next-generation Hyperparameter Optimization Framework,” in *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, Anchorage*, 2019, pp. 2623–2631. doi: <https://doi.org/10.1145/3292500.3330701>.
- [11] Y. Liu, C. Zhong, Q. Ma, Y. Jiang, and C. Zhang, “The S & P 500 Index Prediction Based on N-BEATS,” in *Proceedings of the 2nd International Academic Conference on Blockchain, Information Technology and Smart Finance (ICBIS 2023)*, 2023, vol. 2, pp. 923–929. doi: [10.2991/978-94-6463-198-2](https://doi.org/10.2991/978-94-6463-198-2).
- [12] G. Asmat and K. M. Maiyama, “Bitcoin Price Prediction Using N-BEATS ML Technique,” *EA/ Endorsed Trans. Scalable Inf. Syst.*, vol. 12, no. 2, pp. 1–8, 2025, doi: <https://doi.org/10.4108/eetsis.9006>.
- [13] B. S. Naik et al., “Stock Price Forecasting using N-Beats Deep Learning Architecture,” *J. Sci. Res. Reports*, vol. 30, no. 9, pp. 483–494, 2024, doi: [10.9734/jsrr/2024/v30i92373](https://doi.org/10.9734/jsrr/2024/v30i92373).
- [14] M. N. Riswanda, W. Syaifullah, and J. Saputra, “Prediction of Inflation Rate in East Java Using the N-BEATS Model and Optuna Optimization Prediksi Laju Inflasi di Jawa Timur Menggunakan Model N-BEATS dan Optimasi Optuna,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 3, pp. 1049–1060, 2025, doi: <https://doi.org/10.57152/malcom.v5i3.2141>.
- [15] M. Rizki, A. E. Danneswara, Y. D. Aprilia, M. F. R. Al Fajri, Y. Hendrian, and S. L. Kinanti, “Prediksi Harga Saham Bank BRI dan Bank BCA dengan Menggunakan Model LSTM,” *J. Artif. Intell. Digit. Bus.*, vol. 4, no. 2, pp. 4554–4560, 2025, doi: <https://doi.org/10.31004/riggs.v4i2.1264>.
- [16] Haeruddin, E. Noersasongko, Purwanto, and Muljono, “A Multi-Model Framework for Rainfall Forecasting: Evaluating Performance Model Statistical, Machine Learning, and Deep Learning Methods,” in *2025 International Conference on Smart Computing, IoT and Machine Learning (SIML)*, 2025, pp. 1–6. doi: [10.1109/siml65326.2025.11080798](https://doi.org/10.1109/siml65326.2025.11080798).
- [17] T. Tan, H. Sama, G. Wijaya, and O. E. Aboagye, “Studi Perbandingan Deteksi Intrusi Jaringan Menggunakan Machine Learning: (Metode SVM dan ANN),” *J. Teknol. dan Inf.*, vol. 13, no. 2, pp. 152–164, 2023, doi: <https://doi.org/10.34010/jati.v13i2.10484>.
- [18] M. K. Najib and S. Nurdianti, “Pemodelan Deret Waktu Menggunakan Non-linear Autoregressive Neural Network: Studi Kasus Prediksi Harga Saham Mandiri,” *Jambura J. Math.*, vol. 7, no. 2, pp. 213–220, 2025, doi: <https://doi.org/10.37905/jjom.v7i2.33397>.
- [19] R. N. Silalahi and Muljono, “Perbandingan Kinerja Metode Linear Regression, LSTM dan GRU Untuk Prediksi Harga Penutupan Saham Coca-Cola,” *Komputika J. Sist. Komput.*, vol. 13, no. 2, pp. 201–211, 2024, doi: <https://doi.org/10.34010/komputika.v13i2.12265>.
- [20] N. J. Santoso and F. Firdausillah, “N-Beats Optimization With K-Fold Cross-Validation for Stock Market Price Prediction in Indonesia,” *Eduvest - J. Univers. Stud.*, vol. 5, no. 11, pp. 13520–13530, 2025, doi: <https://doi.org/10.59188/eduvest.v5i11.52367>.

- [21] H. Yin, "Enhancing Directional Accuracy in Stock Closing Price Value Prediction Using a Direction-Integrated MSE Loss Function," in *Proceedings of the 1st International Conference on Data Analysis and Machine Learning - Volume 1: DAML*, 2023, pp. 119–126. doi: 10.5220/0012810200003885.
- [22] M. Barua, T. Kumar, K. Raj, and A. M. Roy, "Comparative Analysis of Deep Learning Models for Stock Price Prediction in the Indian Market," *FinTech*, vol. 3, no. 4, pp. 551–568, 2024, doi: <https://doi.org/10.3390/fintech3040029>.