



Optimasi Hiperparameter *XGBoost Regression* untuk Prediksi Harga Saham BBNI Berbasis Transaksi Historis

Muhammad Irfan

Program Studi Informatika, Universitas Sebelas April, Indonesia

*Penulis Korespondensi: 220660121160@student.unsap.ac.id

Abstract. Stock investment in the banking sector, such as PT Bank Negara Indonesia (Persero) Tbk (BBNI), carries high risks due to dynamic market volatility, necessitating accurate prediction methods to support investment decision-making. This study aims to optimize the performance of the *XGBoost Regression* algorithm in predicting BBNI stock prices based on historical transaction data from the last five years. The methodology applied includes data preprocessing for price format validation, feature engineering using technical indicators (SMA, EMA, MACD, RSI), and hyperparameter optimization using the Grid Search Cross-Validation technique. The experimental results demonstrate that hyperparameter optimization effectively refines the model's predictive stability. While maintaining a highly precise Mean Absolute Percentage Error (MAPE) of 2.00%, the Grid Search technique successfully reduced the nominal error (RMSE) and improved the model's goodness-of-fit (*R-Squared*). These findings confirm that the optimized model offers superior generalization capabilities in capturing price volatility compared to the baseline model. Consequently, this optimized predictive model provides a robust analytical tool for investors and financial analysts to mitigate risks and formulate effective trading strategies in the highly fluctuating banking stock market.

Keywords: BBNI; Grid Search; Hyperparameter Optimization; Stock Prediction; *XGBoost*.

Abstrak. Investasi saham di sektor perbankan seperti PT Bank Negara Indonesia (Persero) Tbk (BBNI) memiliki risiko tinggi akibat volatilitas pasar yang dinamis, sehingga memerlukan metode prediksi yang akurat untuk membantu pengambilan keputusan investasi. Penelitian ini bertujuan untuk mengoptimalkan kinerja algoritma *XGBoost Regression* dalam memprediksi harga saham BBNI berdasarkan data historis transaksi selama lima tahun terakhir. Metodologi yang diterapkan meliputi prapemrosesan data untuk validasi format harga, rekayasa fitur menggunakan indikator teknikal (SMA, EMA, MACD, RSI), serta optimasi *hyperparameter* menggunakan teknik *Grid Search Cross-Validation*. Hasil pengujian menunjukkan bahwa penerapan optimasi *hyperparameter* mampu menyempurnakan stabilitas prediksi model. Meskipun akurasi relatif (MAPE) bertahan pada angka presisi 2,00%, teknik *Grid Search* berhasil mereduksi tingkat kesalahan nominal (*Root Mean Squared Error*) dan meningkatkan kecocokan model (*R-Squared*). Selain itu, analisis *feature importance* mengungkapkan bahwa indikator tren jangka pendek, khususnya *Simple Moving Average 5 hari* (SMA_5), menjadi faktor paling dominan yang memengaruhi pergerakan harga. Hal ini membuktikan bahwa model teroptimasi memiliki kemampuan generalisasi yang lebih baik dalam menangkap volatilitas harga dibandingkan model *baseline*.

Kata kunci: BBNI; Grid Search; Optimasi Hyperparameter; Prediksi Saham; *XGBoost*.

1. LATAR BELAKANG

Pasar modal memegang peranan vital dalam perekonomian Indonesia sebagai sarana investasi dan sumber pendanaan perusahaan (Lubis et al., 2024). PT Bank Negara Indonesia (Persero) Tbk atau BBNI merupakan salah satu saham sektor perbankan yang konsisten masuk dalam indeks LQ45 karena memiliki kapitalisasi pasar yang besar serta tingkat likuiditas yang tinggi. Sektor perbankan dikenal memiliki sensitivitas tinggi terhadap kebijakan makroekonomi dan sentimen global, yang sering kali memicu volatilitas harga saham yang ekstrem (Jumiati et al., 2024). Meskipun menjanjikan imbal hasil yang menarik, investasi saham memiliki risiko tinggi akibat fluktuasi harga yang dinamis dan dipengaruhi oleh banyak faktor eksternal (Samsudin et al., 2023). Konsep Hipotesis Pasar Efisien (EMH) beranggapan

bahwa seluruh informasi yang tersedia sudah terserap ke dalam harga pasar saat ini, kondisi ini menyebabkan prediksi harga di masa mendatang menjadi sulit dilakukan secara akurat (Liani et al., 2024). Namun, dalam praktiknya, data deret waktu (*time series*) saham sering kali menunjukkan pola berulang (tren) yang dapat dieksploitasi menggunakan analisis teknikal untuk meminimalkan risiko investasi (Li, 2023).

Tantangan utama dalam analisis teknikal konvensional adalah subjektivitas dalam pembacaan grafik dan ketidakmampuan manusia dalam memproses data historis bervolume besar secara cepat (Lommers et al., 2021). Oleh karena itu, pendekatan berbasis *Machine Learning* menjadi solusi yang semakin dominan untuk menangani data non-linear yang kompleks di pasar keuangan (Vasellini, 2023). Analisis *time series* konvensional seperti ARIMA sering kali terkendala oleh asumsi linearitas data (Putri & Kusuma, 2025; Waciko et al., 2025), sehingga pendekatan non-linear seperti *XGBoost* lebih disukai. Berbagai metode komputasi telah diterapkan dalam penelitian sebelumnya, mulai dari *Long Short-Term Memory* (LSTM) Pipin et al. (2023), *Support Vector Regression* (SVR) Riziq & Dzikrillah, (2025), hingga algoritma Facebook Prophet (Wiejaya & Fenriana, 2024). Meskipun metode berbasis *Deep Learning* seperti LSTM populer untuk data sekuensial, penelitian terbaru menunjukkan bahwa untuk data tabular terstruktur (seperti data historis saham OHLC), algoritma berbasis pohon keputusan (*Tree-Based Models*) sering kali memberikan kinerja yang lebih unggul dengan biaya komputasi yang jauh lebih rendah (Shwartz-Ziv & Armon, 2022). Di antara berbagai algoritma yang tersedia, *Extreme Gradient Boosting* (*XGBoost*) telah terbukti memberikan performa superior dibandingkan metode lain seperti SVR atau *Artificial Neural Networks* (ANN) dalam menangani data tabular terstruktur (Bentéjac et al., 2021). Keunggulan utama *XGBoost* terletak pada skalabilitas, kecepatan komputasi, dan mekanisme regularisasi yang efektif untuk mencegah *overfitting* (Chen & Guestrin, 2016). Selain itu, kemampuan *XGBoost* dalam menangani *missing values* secara otomatis menjadikannya lebih *robust* dibandingkan model jaringan saraf yang memerlukan pra-pemrosesan data yang sangat ketat (Wang et al., 2023).

Meskipun *XGBoost* dikenal andal, kinerjanya sangat bergantung pada konfigurasi *hyperparameter* (parameter hiper) yang digunakan (Zlobin & Bazylevych, 2025). Banyak penelitian sebelumnya menerapkan *XGBoost* dengan pengaturan parameter *default*, yang sering kali tidak menghasilkan akurasi optimal karena setiap karakteristik saham memiliki perilaku data yang unik (Yang, 2021). Penggunaan parameter yang tidak sesuai dapat menyebabkan model mengalami *underfitting* (gagal menangkap pola) atau *overfitting* (terlalu menghafal data latih), sehingga validasi model pada data baru menjadi buruk (Ilemobayo et al.,

2024). Penelitian yang dilakukan oleh Shaji (2025) dan Subasi (2024) menunjukkan bahwa penyetelan parameter hiper (*hyperparameter tuning*) menggunakan metode pencarian sistematis seperti *Grid Search* dapat meningkatkan akurasi prediksi secara signifikan dan menurunkan tingkat kesalahan (*error rate*). Selain optimasi algoritma, kualitas fitur input juga memegang peranan kunci. Integrasi indikator teknikal seperti *Moving Average* (MA) dan *Relative Strength Index* (RSI) sebagai fitur input terbukti mampu memperkaya informasi yang dipelajari oleh model (Ku et al., 2025). Pendekatan *hybrid* yang menggabungkan indikator teknikal dengan algoritma *Machine Learning* diketahui mampu menangkap sinyal momentum pasar yang sering kali terlewatkan jika hanya menggunakan data harga mentah semata (Kamara et al., 2022).

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengoptimalkan algoritma *XGBoost Regression* guna memprediksi harga penutupan saham BBNI. Kontribusi kebaruan (*novelty*) dalam studi ini difokuskan pada implementasi metode optimasi *Grid Search Cross-Validation* yang bertujuan menemukan konfigurasi *hyperparameter* paling optimal secara otomatis pada data historis transaksi lima tahun terakhir, serta analisis *feature importance* untuk mengidentifikasi indikator teknikal yang paling dominan dalam memengaruhi pergerakan harga BBNI. Hasil penelitian ini diharapkan dapat memberikan kontribusi empiris mengenai efektivitas optimasi parameter dalam meningkatkan presisi model prediksi saham di sektor perbankan Indonesia.

2. KAJIAN TEORITIS

Prediksi Harga Saham dan Analisis Teknikal

Analisis data deret waktu (*time series*) di pasar keuangan bertujuan untuk mengidentifikasi pola historis yang dapat digunakan untuk memperkirakan pergerakan harga di masa depan (Li, 2023). Dalam memprediksi harga saham, penggunaan data mentah (*Open, High, Low, Close*) sering kali tidak cukup untuk menangkap momentum pasar. Oleh karena itu, penerapan indikator analisis teknikal seperti *Simple Moving Average* (SMA), *Exponential Moving Average* (EMA), *Moving Average Convergence Divergence* (MACD), dan *Relative Strength Index* (RSI) sangat diperlukan. Pendekatan hibrida yang menggabungkan fitur indikator teknikal ini ke dalam model prediktif terbukti secara empiris mampu meningkatkan kepekaan algoritma terhadap tren dan titik balik harga (Kamara et al., 2022). Indikator-indikator ini bertindak sebagai ekstraksi fitur (*feature engineering*) yang memperkaya informasi bagi algoritma *machine learning* (Ku et al., 2025).

Extreme Gradient Boosting (XGBoost)

XGBoost merupakan varian pengembangan dari algoritma pohon keputusan (*decision tree*) yang menggunakan prinsip *gradient boosting* untuk meningkatkan akurasi secara iteratif (Chen & Guestrin, 2016). Berbeda dengan metode konvensional, *XGBoost* dirancang secara khusus untuk mengoptimalkan efisiensi komputasi, fleksibilitas, dan penanganan data yang hilang (*missing values*) secara otomatis (Wang et al., 2023). Dalam konteks pemodelan data finansial yang terstruktur atau tabular, metode berbasis pohon seperti *XGBoost* secara konsisten menunjukkan performa yang mengungguli metode statistik klasik maupun algoritma *deep learning* yang lebih kompleks namun boros komputasi (Bentéjac et al., 2021; Shwartz-Ziv & Armon, 2022). Pengembangan model prediksi komputasi ini umumnya diimplementasikan dalam lingkungan pemrograman Python, dengan memanfaatkan integrasi pustaka analisis data numerik dan *machine learning* yang andal (Géron, 2019; McKinney, 2022).


Optimasi Hyperparameter dan Penelitian Terdahulu

Kapasitas algoritma *XGBoost* dalam mempelajari data sangat ditentukan oleh pengaturan *hyperparameter*, seperti *learning rate*, kedalaman pohon (*max depth*), dan jumlah estimator. Karena tidak ada satu konfigurasi universal yang cocok untuk semua jenis data saham, optimasi parameter secara sistematis menjadi krusial (Zlobin & Bazylevych, 2025). *Grid Search Cross-Validation* merupakan teknik pencarian hiperparameter yang mengevaluasi seluruh kombinasi parameter yang telah ditentukan secara berulang untuk menemukan model dengan tingkat kesalahan terkecil dan kemampuan generalisasi tertinggi (Ilemobayo et al., 2024; Subasi, 2024).

Beberapa penelitian terdahulu telah mengaplikasikan algoritma pembelajaran mesin untuk peramalan harga aset keuangan, seperti penggunaan *Long Short-Term Memory* (LSTM) Pipin et al. (2023), *Support Vector Regression* (SVR) Riziq & Dzikrillah, (2025), hingga algoritma *time series Prophet* (Wiejaya & Fenriana, 2024). Namun, penelitian terbaru yang dilakukan oleh Waciko et al (2025) dan Shaji (2025) menegaskan bahwa ketika *XGBoost* dipadukan dengan optimasi *hyperparameter* yang tepat seperti *Grid Search*, model tersebut mampu mereduksi *error rate* secara drastis dibandingkan saat menggunakan parameter *default*. Tinjauan pustaka ini memberikan landasan yang kuat bahwa penerapan *XGBoost* yang dioptimalkan dengan *Grid Search* merupakan metode yang sangat relevan dan tangguh untuk menyelesaikan masalah prediksi volatilitas harga pada saham BBNI.

3. METODE PENELITIAN

Penelitian ini mengadopsi pendekatan kuantitatif dengan desain eksperimental komputasi untuk mengembangkan model prediksi harga penutupan saham PT Bank Negara Indonesia (Persero) Tbk (BBNI). Metodologi yang diusulkan mengintegrasikan algoritma *Machine Learning* non-linear, yaitu *Extreme Gradient Boosting (XGBoost)*, yang dioptimalkan kinerjanya menggunakan teknik pencarian parameter otomatis *Grid Search Cross-Validation*. Implementasi model dilakukan menggunakan bahasa pemrograman Python dengan memanfaatkan pustaka Pandas untuk manipulasi data McKinney (2022) dan *Scikit-Learn* untuk pemodelan *machine learning* (Géron, 2019). Seluruh tahapan penelitian disusun secara terstruktur guna memastikan validitas dan reliabilitas hasil prediksi, mencakup proses akuisisi data historis, prapemrosesan data, rekayasa fitur berbasis indikator teknikal, hingga evaluasi kinerja model. Rincian alur kerja sistematis tersebut divisualisasikan pada diagram alir (*flowchart*) di Gambar 1.



Gambar 1. Diagram Alir Metodologi Penelitian.

Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data sekunder berupa data deret waktu (*time series*) historis dari saham PT Bank Negara Indonesia (Persero) Tbk (kode: BBNI), yang tergolong dalam saham *blue chip* dengan likuiditas tinggi di sektor perbankan Indonesia. Dataset diperoleh melalui portal penyedia data finansial global, Investing.com, yang menyediakan akses terbuka terhadap rekam jejak transaksi pasar modal. Rentang waktu pengambilan data ditetapkan selama lima tahun penuh, terhitung sejak 1 Januari 2020 hingga 1 Desember 2025. Pemilihan periode ini ditujukan untuk menangkap berbagai dinamika kondisi pasar yang signifikan, termasuk fase volatilitas tinggi akibat pandemi global serta fase pemulihan ekonomi pasca-pandemi, sehingga model dapat mempelajari pola tren jangka panjang maupun fluktuasi jangka pendek secara komprehensif. Dataset terdiri dari total 1.428 observasi harian yang mencakup lima variabel fitur standar dalam analisis teknikal, yaitu harga

Pembukaan (*Open*), harga Tertinggi (*High*), harga Terendah (*Low*), harga Penutupan (*Close*), dan Volume perdagangan (Li, 2023).

Prapemrosesan Data

Tahap prapemrosesan memegang peranan vital dalam siklus pengembangan model *Machine Learning*, mengingat kualitas data masukan berkorelasi langsung dengan kinerja prediksi yang dihasilkan (*Garbage In, Garbage Out*). Proses ini bertujuan untuk membersihkan *noise*, menyamakan format, dan mempersiapkan struktur data agar kompatibel dengan algoritma *XGBoost*. Langkah pertama difokuskan pada standarisasi format data volume transaksi. Data mentah yang diperoleh memiliki format *string* dengan sufiks karakter "M" (merepresentasikan Juta), yang tidak dapat diproses secara langsung oleh operasi matematis. Oleh karena itu, dilakukan transformasi data dengan mengonversi sufiks tersebut menjadi nilai numerik penuh (tipe data *float*) untuk memastikan kalkulasi fitur berjalan akurat.

Selanjutnya, dilakukan validasi ketat terhadap integritas skala harga. Pada data mentah, terdeteksi adanya anomali di mana harga saham terbaca dalam satuan desimal (misalnya 4,30) akibat perbedaan interpretasi format pemisah ribuan (*thousands separator*) pada sistem penyedia data. Koreksi dilakukan dengan menormalisasi nilai tersebut kembali ke satuan mata uang Rupiah (IDR) yang valid (misalnya Rp 4.300), sehingga rentang harga mencerminkan nilai pasar yang sesungguhnya dan dapat dibandingkan secara logis. Penanganan data yang hilang (*missing values*) juga menjadi perhatian utama, khususnya pada hari libur bursa. Penelitian ini menerapkan metode imputasi *Forward Fill*, yaitu mengisi nilai kosong dengan nilai pada hari perdagangan sebelumnya. Pendekatan ini dipilih karena karakteristik data deret waktu yang memiliki dependensi temporal, di mana asumsi terbaik untuk nilai saat ini adalah kondisi terakhir yang diketahui, guna menjaga kontinuitas tren tanpa memperkenalkan bias masa depan (Li, 2023).

Tahap akhir dari prapemrosesan adalah pembagian dataset (*data splitting*). Berbeda dengan data konvensional yang dapat diacak, data *time series* harus mempertahankan urutan kronologisnya. Oleh karena itu, skema pembagian dilakukan secara sekuensial (*non-shuffled*), dengan proporsi 80% data awal dialokasikan sebagai data latih (*training set*) untuk pembelajaran pola model, dan 20% data terakhir dialokasikan sebagai data uji (*testing set*). Pemilihan rasio 80:20 ini ditetapkan karena merupakan standar empiris yang sangat optimal untuk dataset berukuran menengah (sekitar 1.400 observasi). Proporsi ini memberikan sampel historis yang cukup luas bagi algoritma untuk mengenali siklus pasar jangka panjang, sekaligus menyisakan data pengujian yang representatif (sekitar 286 hari perdagangan bursa) untuk memvalidasi performa model. Pemisahan ini bertujuan untuk mensimulasikan skenario

prediksi masa depan yang realistis dan mengevaluasi kemampuan generalisasi model pada data yang belum pernah dipelajari sebelumnya (*unseen data*) (Li, 2023).

Rekayasa Fitur

Rekayasa fitur merupakan tahapan kritis untuk mentransformasi data harga mentah (OHLC) menjadi sinyal informatif yang dapat memetakan struktur pasar yang kompleks. Untuk meningkatkan sensitivitas model terhadap pola tren jangka pendek maupun jangka menengah, penelitian ini mengintegrasikan indikator teknikal sebagai variabel prediktor tambahan (Chen & Guestrin, 2016).

Pertama, diterapkan indikator *Simple Moving Average* (SMA) yang berfungsi sebagai filter *noise* untuk mengidentifikasi arah tren dominan. Penelitian ini menggunakan pendekatan *multi-timeframe* dengan variasi periode sebesar 5, 15, dan 30 hari. Pemilihan periode 5 hari merepresentasikan satu siklus perdagangan mingguan (*weekly trading cycle*), sedangkan periode 15 dan 30 hari merepresentasikan tren jangka menengah bulanan. Formulasi SMA didefinisikan pada Persamaan (1).

$$SMA_n = \frac{1}{n} \sum_{i=1}^n P_i \dots\dots\dots(i)$$

Dimana P_i adalah harga penutupan pada hari ke- i dan n adalah periode waktu observasi. Selanjutnya, untuk menangkap dinamika momentum pasar yang sering kali mendahului perubahan harga, digunakan indikator *Relative Strength Index* (RSI). RSI adalah osilator yang mengukur kecepatan dan perubahan pergerakan harga guna mendeteksi kondisi jenuh beli (*overbought*) atau jenuh jual (*oversold*). Fitur ini krusial bagi *XGBoost* untuk mengenali potensi titik balik (*reversal points*) ketika harga sudah bergerak terlalu ekstrem. Nilai RSI dihitung berdasarkan rasio rata-rata keuntungan (*average gain*) terhadap rata-rata kerugian (*average loss*) dalam periode 14 hari, sebagaimana ditunjukkan pada Persamaan (2).

$$RSI = 100 - \left(\frac{100}{1 + RS} \right) \dots\dots\dots(ii)$$

Di mana RS (*Relative Strength*) adalah rasio rata-rata kenaikan harga terhadap rata-rata penurunan harga. Terakhir, indikator *Moving Average Convergence Divergence* (MACD) digunakan untuk menganalisis hubungan antara dua *Exponential Moving Average* (EMA). Nilai MACD diperoleh dari selisih antara EMA periode 12 hari dan EMA periode 26 hari, seperti terlihat pada Persamaan (3).

$$MACD = EMA_{12}(P) - EMA_{26}(P) \dots\dots\dots(iii)$$

Pemilihan Model dan Optimasi

Pemilihan algoritma pemodelan didasarkan pada karakteristik data saham yang non-linear dan memiliki tingkat kebisingan (*noise*) tinggi. Oleh karena itu, penelitian ini menggunakan algoritma *Extreme Gradient Boosting (XGBoost)*, sebuah metode *ensemble learning* berbasis pohon keputusan (*decision tree*) yang dikembangkan untuk efisiensi komputasi dan performa prediksi yang superior. Berbeda dengan *Gradient Boosting* konvensional, *XGBoost* mengintegrasikan mekanisme regularisasi L1 dan L2 dalam fungsi objektifnya untuk mengontrol kompleksitas model, sehingga sangat efektif dalam mencegah terjadinya *overfitting* pada data latih yang terbatas. Selain itu, algoritma ini menggunakan pendekatan *second-order Taylor expansion* untuk mengaproksimasi fungsi kerugian (*loss function*), yang memungkinkan konvergensi yang lebih cepat dan akurat (Putri & Kusuma, 2025; Riziq & Dzikrillah, 2025).

Mengingat kinerja *XGBoost* sangat sensitif terhadap konfigurasi *hyperparameter*, pengaturan parameter secara manual sering kali bersifat subjektif dan tidak menjamin hasil optimal. Untuk mengatasi tantangan tersebut, penelitian ini menerapkan strategi optimasi otomatis menggunakan metode *Grid Search Cross-Validation*. Teknik ini bekerja dengan cara mengeksplorasi seluruh ruang kemungkinan kombinasi parameter yang telah didefinisikan secara sistematis (*exhaustive search*) untuk menemukan konfigurasi global yang menghasilkan tingkat kesalahan terendah. Untuk memastikan model dievaluasi secara objektif, pencarian ini dipadukan dengan mekanisme validasi silang 5-lipatan khusus data deret waktu (*Time Series 5-Fold Cross-Validation*). Mekanisme ini memvalidasi model secara iteratif pada rentang waktu yang terus bergeser maju, sehingga memastikan bahwa model yang dihasilkan memiliki stabilitas yang baik (*robust*) dan terhindar dari bias partisi data (Bentéjac et al., 2021).

Ruang pencarian parameter yang diuji dirancang secara spesifik berdasarkan keseimbangan antara beban komputasi dan kompleksitas data saham. Parameter utama yang dioptimasi meliputi: (1) *n_estimators* dengan variasi nilai 100, 200, 300, dan 400; (2) *learning_rate* dengan nilai 0,001, 0,01, dan 0,05; (3) *max_depth* pada rentang angka 8, 10, 12, dan 15; serta (4) parameter gamma dengan nilai 0,001, 0,01, dan 0,02. Pemilihan rentang *hyperparameter* ini didasari oleh karakteristik data pasar keuangan yang sangat dipenuhi oleh derau (*noise*). Kombinasi nilai *max_depth* yang moderat hingga tinggi memungkinkan model untuk mendeteksi interaksi indikator teknikal yang kompleks, sementara penggunaan rentang *learning_rate* yang kecil (pembelajaran konservatif) dan parameter gamma (pemangkasan otomatis) berfungsi secara krusial sebagai jaring pengaman untuk mencegah fenomena

overfitting. Dengan pembatasan ruang pencarian ini, waktu komputasi *Grid Search* tetap efisien namun tetap mampu menemukan konfigurasi yang unggul dalam hal generalisasi data.

Evaluasi Kinerja

Kinerja model dievaluasi menggunakan metrik utama *Mean Absolute Percentage Error* (MAPE) untuk mengukur rata-rata persentase kesalahan prediksi relatif terhadap nilai aktual (Li, 2023). MAPE dipilih karena interpretasinya yang mudah dipahami dalam konteks finansial untuk melihat seberapa besar penyimpangan prediksi dalam persen. Rumus MAPE ditunjukkan pada Persamaan (4).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100 \% \dots \dots \dots (iv)$$

Di mana A_t adalah harga aktual pada waktu t , F_t adalah harga hasil prediksi pada waktu t , dan n adalah jumlah data uji. Selain MAPE, penelitian ini juga menggunakan *Root Mean Squared Error* (RMSE) untuk mengukur besaran kesalahan dalam satuan Rupiah, serta *R-Squared* (R^2) untuk mengetahui seberapa baik variabel independen menjelaskan variabilitas variabel dependen. Rumus RMSE dan R^2 berturut-turut ditunjukkan pada Persamaan (5) dan (6).

$$MSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2} \dots \dots \dots (v)$$

$$R^2 = 1 - \frac{\sum_{t=1}^n (A_t - F_t)^2}{\sum_{t=1}^n (A_t - \bar{A})^2} \dots \dots \dots (vi)$$

Di mana $\bar{A}$ adalah rata-rata dari harga aktual.

4. HASIL DAN PEMBAHASAN

Bagian ini menyajikan analisis komprehensif terhadap hasil eksperimen komputasi yang dirancang untuk memvalidasi efektivitas model *Extreme Gradient Boosting* (XGBoost) dalam memprediksi harga saham BBNI. Struktur pembahasan disusun secara sistematis, dimulai dengan analisis statistik deskriptif dan visualisasi karakteristik data historis untuk memahami pola tren, volatilitas, serta dampak penerapan indikator teknikal seperti *Simple Moving Average* (SMA) dan *Exponential Moving Average* (EMA) terhadap sinyal pergerakan harga. Pemahaman mendalam terhadap perilaku data ini menjadi landasan penting sebelum melangkah ke tahap pemodelan.

Selanjutnya, dipaparkan proses eksperimental dalam penentuan konfigurasi model terbaik melalui mekanisme *Grid Search Cross-Validation*. Pada bagian ini, analisis difokuskan pada dampak penyetelan *hyperparameter* terhadap penurunan tingkat kesalahan prediksi, serta perbandingan kinerja antara model dengan parameter *default* (*baseline*) dan model yang telah

dioptimasi. Selain aspek akurasi, pembahasan juga mencakup interpretabilitas model melalui analisis *Feature Importance*, yang bertujuan untuk mengungkap indikator teknikal mana yang memiliki kontribusi paling dominan dalam memengaruhi keputusan algoritma. Evaluasi akhir dilakukan secara kuantitatif menggunakan metrik standar industri seperti *Mean Absolute Percentage Error* (MAPE), *Root Mean Squared Error* (RMSE), dan koefisien determinasi (R^2) untuk memverifikasi keandalan model dalam menghadapi data uji yang merepresentasikan kondisi pasar nyata.

Analisis Pola Data dan Indikator Teknikal

Sebelum melangkah ke tahap pemodelan prediktif, analisis eksploratif dilakukan secara menyeluruh terhadap data historis saham BBNI untuk memahami karakteristik distribusi dan perilaku pergerakan harga. Langkah awal melibatkan perhitungan statistik deskriptif guna memetakan rentang volatilitas data. Ringkasan statistik data latih dan data uji disajikan pada Tabel 1.

Tabel 1. Statistik Deskriptif Data Saham BBNI (2020–2025).


Atribut Statistik	Data Latih (Train)	Data Uji (Test)
Jumlah Data (<i>Count</i>)	1.142 hari	286 hari
Harga Rata-rata (<i>Mean</i>)	Rp 5.132	Rp 4.980
Standar Deviasi (<i>Std</i>)	Rp 1.033	Rp 450
Harga Minimum (<i>Min</i>)	Rp 3.160	Rp 4.020
Harga Maksimum (<i>Max</i>)	Rp 8.500	Rp 5.800

Berdasarkan Tabel 1, terlihat bahwa data memiliki variabilitas yang cukup tinggi, ditandai dengan selisih yang signifikan antara harga minimum (Rp 3.160) dan harga maksimum (Rp 8.500). Standar deviasi sebesar Rp 1.033 pada data latih mengindikasikan adanya fluktuasi harga yang lebar, yang menjadi tantangan tersendiri bagi algoritma *machine learning* dalam meminimalkan *error*.

Analisis visual melalui dekomposisi *time series* memperlihatkan bahwa saham BBNI memiliki tren kenaikan (*uptrend*) jangka panjang yang kuat, namun disertai dengan siklus fluktuasi musiman. Volatilitas ekstrem terdeteksi pada periode awal tahun 2020, yang bertepatan dengan guncangan pasar akibat pandemi global, di mana harga mengalami koreksi tajam sebelum akhirnya mengalami pemulihan (*rebound*) bertahap. Fenomena ini menegaskan bahwa data saham bersifat non-stasioner dan memiliki *noise* yang tinggi.

Untuk mengatasi masalah *noise* tersebut, penerapan indikator teknikal menjadi krusial. Visualisasi pada Gambar 4.1 menunjukkan bahwa indikator *Simple Moving Average* (SMA) dan *Exponential Moving Average* (EMA) efektif dalam memperhalus pergerakan harga harian, sehingga pola tren dasar lebih mudah diidentifikasi oleh model. Terlihat perbedaan

karakteristik yang jelas: indikator SMA periode pendek (5 hari) sangat responsif dan menempel ketat pada harga aktual, berfungsi menangkap sinyal perubahan tren jangka pendek. Sebaliknya, SMA periode panjang (30 hari) memberikan gambaran tren makro yang lebih stabil dan lambat bereaksi terhadap fluktuasi harian, berfungsi sebagai filter untuk menghindari sinyal palsu (*false signals*). Kombinasi kedua perspektif waktu ini memberikan fitur yang kaya bagi algoritma *XGBoost* untuk mempelajari pola harga secara komprehensif.



Gambar 2. Pergerakan Harga Saham BBNI dengan Indikator Teknikal.

Hasil Optimasi Hyperparameter

Tahap optimasi model merupakan langkah krusial untuk memastikan algoritma *XGBoost* dapat beradaptasi secara presisi dengan karakteristik volatilitas data saham BBNI. Proses pelatihan dilakukan menggunakan pendekatan *Grid Search Cross-Validation* dengan skema validasi silang 5-lipatan (*5-fold CV*). Secara total, algoritma mengevaluasi 256 kombinasi *hyperparameter* yang berbeda dalam ruang pencarian yang telah ditentukan guna meminimalkan fungsi kerugian (*loss function*) secara iteratif.

Berdasarkan hasil eksperimen komputasi, ditemukan bahwa model mencapai kinerja paling optimal dengan konfigurasi parameter yang cenderung kompleks. Terpilihnya jumlah *n_estimators* sebanyak 400 dan kedalaman pohon (*max_depth*) sebesar 10 mengindikasikan bahwa pola pergerakan harga saham BBNI memiliki struktur non-linear yang rumit, sehingga memerlukan model dengan kapasitas pembelajaran (*learning capacity*) yang tinggi untuk menangkap detail fluktuasi harga. Meskipun demikian, risiko terjadinya *overfitting* akibat kompleksitas model tersebut berhasil dimitigasi melalui penggunaan tingkat pembelajaran (*learning_rate*) yang rendah, yaitu 0,05, serta penambahan parameter regularisasi gamma sebesar 0,02. Kombinasi ini memaksa model untuk belajar secara bertahap dan konservatif, menghasilkan prediksi yang tidak hanya akurat pada data latih tetapi juga generalis pada data uji. Rincian konfigurasi parameter terbaik hasil optimasi dirangkum dalam Tabel 4.2.

Tabel 2. Konfigurasi Parameter Terbaik Hasil *Grid Search*.


Parameter	Nilai Terbaik	Fungsi Utama
n_estimators	400	Menentukan jumlah pohon keputusan (<i>decision trees</i>) yang dibangun dalam model.
learning_rate	0,05	Mengontrol besarnya pembaruan bobot pada setiap iterasi sehingga memengaruhi kecepatan proses pembelajaran model.
max_depth	10	Menentukan kedalaman maksimum setiap pohon untuk menangkap pola yang lebih kompleks tanpa membuat model terlalu rumit.
gamma	0,02	Parameter regularisasi yang mengontrol pembentukan percabangan baru pada pohon untuk membantu mencegah <i>overfitting</i> .

Analisis Fitur Dominan

Selain akurasi prediksi, salah satu keunggulan fundamental dari algoritma *XGBoost* adalah kapabilitasnya dalam memberikan interpretabilitas model (*model interpretability*) melalui pemeringkatan skor kepentingan fitur (*Feature Importance*). Skor ini dihitung berdasarkan rata-rata peningkatan (*gain*) yang diberikan oleh setiap fitur terhadap penurunan fungsi *error* di seluruh pohon keputusan yang dibangun.

Berdasarkan analisis visual pada Gambar 4.2, terungkap temuan empiris yang signifikan bahwa indikator tren jangka pendek, yakni SMA_5 (Rata-rata Pergerakan 5 Hari), mendominasi arsitektur keputusan model dengan bobot kepentingan mencapai 0,9356 (93,56%). Dominasi mutlak ini mengindikasikan bahwa struktur volatilitas harga saham BBNI memiliki autokorelasi yang sangat kuat dengan riwayat harga dalam satu minggu perdagangan terakhir (5 hari bursa). Secara psikologis pasar, hal ini mencerminkan perilaku investor yang cenderung *trend-following*, di mana keputusan transaksi sangat dipengaruhi oleh momentum harga yang baru saja terjadi.

Sebaliknya, indikator osilator seperti *Relative Strength Index* (RSI) dan indikator momentum *Moving Average Convergence Divergence* (MACD) hanya memberikan kontribusi minor sebagai fitur pelengkap (*complementary features*). Meskipun skor kepentingannya rendah, kehadiran fitur-fitur ini tetap krusial sebagai penyeimbang untuk mendeteksi anomali pasar, seperti kondisi jenuh beli (*overbought*) atau jenuh jual (*oversold*), yang sering kali luput dari deteksi rata-rata bergerak sederhana. Temuan ini mengonfirmasi hipotesis bahwa saham BBNI memiliki karakteristik *short-term trending* yang kuat, sehingga variabel *lag* harga jangka pendek menjadi prediktor yang jauh lebih reliabel dibandingkan indikator teknikal yang lebih kompleks.



Gambar 3. Tingkat Kepentingan Fitur dalam Model Prediksi.

Evaluasi Kinerja Model

Tahap akhir dari eksperimen ini adalah evaluasi kinerja model pada data uji (*testing set*) yang merepresentasikan kondisi pasar masa depan yang belum pernah dipelajari oleh model. Berdasarkan hasil pengujian kuantitatif, model *XGBoost* yang telah dioptimasi menunjukkan performa yang sangat impresif dengan mencatatkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 2,00%. Mengacu pada standar klasifikasi kemampuan peramalan, nilai MAPE di bawah 10% dikategorikan sebagai peramalan yang sangat akurat (*highly accurate forecasting*). Hal ini mengindikasikan bahwa model memiliki tingkat presisi yang tinggi dan risiko deviasi yang minim dalam memprediksi harga penutupan saham BBNI.

Untuk memvalidasi efektivitas metode optimasi yang diusulkan, kinerja model *XGBoost Optimized* dibandingkan dengan model *Baseline* (*XGBoost* dengan parameter *default*). Perbandingan hasil evaluasi kedua model dirangkum dalam Tabel 4.3.

Tabel 3. Perbandingan Kinerja Model Baseline vs Optimized.


Metrik Evaluasi	Model (Default)	Baseline	Model Optimized (Grid Search)	Peningkatan Kinerja
MAPE	2,00%	2,00%	2,00%	0,00%
RMSE	115,22	115,22	114,01	+1,21 poin
MAE	88,63	88,63	88,29	+0,34 poin
R-Squared (R^2)	0,9228	0,9228	0,9245	+0,0017

Berdasarkan Tabel 3, terlihat fenomena menarik di mana nilai MAPE pada model *Baseline* dan *Optimized* menunjukkan hasil identik sebesar 2,00%. Hal ini mengindikasikan bahwa model dasar *XGBoost* sebenarnya sudah sangat kompatibel dengan pola data saham BBNI. Namun, efektivitas optimasi *Grid Search* terlihat secara spesifik pada penurunan nilai *error* nominal. RMSE berhasil diturunkan dari 115,22 menjadi 114,01, dan MAE turun dari 88,63 menjadi 88,29. Meskipun penurunan ini terlihat marjinal, peningkatan nilai R^2 menjadi

0,9245 menegaskan bahwa model yang dioptimasi memiliki kemampuan generalisasi yang sedikit lebih baik dalam menjelaskan varian data. Dalam konteks perdagangan frekuensi tinggi atau volume besar, selisih akurasi Rp 1,21 (RMSE) per lembar saham dapat terakumulasi menjadi nilai yang signifikan, sehingga model *Optimized* tetap lebih direkomendasikan.

Validitas model semakin diperkuat melalui analisis visual pada Gambar 4. Grafik perbandingan menunjukkan bahwa garis prediksi (merah putus-putus) mampu mengikuti garis harga aktual (biru) dengan sangat presisi (himpit), tidak hanya pada periode tren naik (*uptrend*), tetapi juga sangat responsif pada periode penurunan harga tajam (*downtrend*). Model tidak menunjukkan gejala *lagging* yang signifikan, yang sering menjadi kelemahan metode *time series* konvensional. Distribusi *error* yang terpusat di angka nol juga mengindikasikan bahwa model bersifat *unbiased*, artinya tidak memiliki kecenderungan sistematis untuk memprediksi harga terlalu tinggi (*overestimation*) atau terlalu rendah (*underestimation*).

Lebih lanjut, keunggulan komparatif dari pendekatan yang diusulkan ini menjadi sangat jelas ketika dihadapkan pada tantangan pemodelan data finansial tabular. Meskipun berbagai literatur sering merekomendasikan algoritma *Deep Learning* seperti LSTM atau *Support Vector Regression* (SVR) untuk peramalan deret waktu, metode-metode tersebut umumnya menuntut beban komputasi yang sangat masif dan proses normalisasi data yang rumit. Pemilihan algoritma *XGBoost* dalam penelitian ini secara empiris terbukti lebih efisien untuk data tabular terstruktur seperti OHLC saham. Hal ini dibuktikan melalui hasil eksperimen di mana model *Baseline* (*XGBoost* tanpa optimasi) saja sudah mampu menyentuh tingkat presisi (MAPE) 2,00%. Penerapan *Grid Search* kemudian bertindak sebagai penyempurna krusial yang menekan angka kesalahan absolut (RMSE) ke titik minimum. Dengan demikian, model *XGBoost* yang telah dioptimasi ini tidak hanya unggul dari segi kecepatan dan efisiensi komputasi dibandingkan model jaringan saraf tiruan, tetapi juga menawarkan stabilitas prediksi dan kemampuan generalisasi yang lebih tangguh dalam memetakan fluktuasi pasar perbankan.



Gambar 4. Perbandingan Harga Aktual vs Prediksi Model *XGBoost Optimized*.

5. KESIMPULAN DAN SARAN

Penelitian ini menyimpulkan bahwa optimasi algoritma *Extreme Gradient Boosting* (*XGBoost*) menggunakan *Grid Search Cross-Validation* secara efektif meningkatkan stabilitas dan presisi prediksi harga saham BBNI. Model teroptimasi mencapai nilai *Mean Absolute Percentage Error* (MAPE) 2,00%, koefisien determinasi (R^2) 0,9245, serta berhasil menurunkan kesalahan nominal (*Root Mean Squared Error*) menjadi Rp 114,01. Selain itu, temuan empiris menunjukkan dominasi indikator teknikal jangka pendek, di mana *Simple Moving Average 5 hari* (SMA_5) memberikan kontribusi terbesar (93,56%). Hal ini menegaskan bahwa perilaku harga saham BBNI memiliki autokorelasi yang kuat dengan tren perdagangan mingguan.

Secara praktis, temuan ini memberikan implikasi yang berharga bagi para investor dan analis keuangan. Tingginya akurasi model dalam menangkap volatilitas dan tren jangka pendek menjadikan sistem ini sangat relevan untuk diaplikasikan dalam strategi perdagangan algoritmik (*algorithmic trading*). Dengan memanfaatkan model ini, investor dapat mengotomatisasi identifikasi momentum titik masuk (*entry*) dan titik keluar (*exit*) yang potensial, sekaligus meminimalkan bias emosional manusia yang sering kali muncul saat menghadapi fluktuasi pasar perbankan yang dinamis.

Meskipun menunjukkan performa teknikal yang *robust*, implikasi praktis model ini terbatas pada ketiadaan variabel kualitatif, sehingga rentan terhadap guncangan eksternal pasar (*market shocks*) seperti rilis data makroekonomi dadakan, perubahan suku bunga, atau sentimen geopolitik global. Oleh karena itu, model prediktif ini direkomendasikan sebagai alat pendukung keputusan yang harus disandingkan dengan analisis fundamental. Sebagai tindak lanjut, penelitian mendatang disarankan untuk mengintegrasikan analisis sentimen dari berita keuangan atau media sosial ke dalam variabel prediktor, serta membandingkan kinerjanya

dengan metode *Deep Learning* seperti LSTM atau GRU untuk menguji konsistensi model pada berbagai siklus ekonomi.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Program Studi Informatika, Universitas Sebelas April yang telah memberikan dukungan lingkungan akademis dalam penyelesaian penelitian ini. Penghargaan juga disampaikan kepada penyedia data Investing.com yang telah menyediakan akses data historis pasar modal secara terbuka, sehingga memungkinkan terlaksananya eksperimen komputasi ini.

DAFTAR REFERENSI

- Bentéjac, C., Csörgő, A., & Martínez-Muñoz, G. (2021). A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, 54, 1937–1967. <https://doi.org/10.1007/s10462-020-09896-5>
- Chen, T., & Guestrin, C. (2016). *XGBoost : A Scalable Tree Boosting System*. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems* (2nd ed.). O'Reilly Media.
- Ilemobayo, J. A., Durodola, O., Alade, O., Awotunde, O. J., Olanrewaju, A. T., Falana, O., Ogungbire, A., Osinuga, A., Ogunbiyi, D., Ifeanyi, A., Odezuligbo, I. E., & Edu, O. E. (2024). Hyperparameter Tuning in Machine Learning: A Comprehensive Review. *Journal of Engineering Research and Reports*, 26(6), 388–395. <https://doi.org/10.9734/jerr/2024/v26i61188>
- Jumiati, Pimpi, L., Muhtar, N., Abapihi, B., Aswani, & Ningtyas, R. A. (2024). Analisis Volatilitas Saham Sektor Perbankan Menggunakan Metode Garch (Studi Kasus: Bank BUMN Pada Saham LQ45 yang terdaftar di BEI). *Jurnal Matematika, Komputasi, & Statistika*, 4(2). <https://doi.org/10.33772/jmks.v4i2.98>
- Kamara, A. F., Chen, E., & Pan, Z. (2022). An ensemble of a boosted hybrid of deep learning models and technical analysis for forecasting stock prices. *Information Sciences*, 594, 1–19. <https://doi.org/10.1016/j.ins.2022.02.015>
- Ku, C. S., Charan, S. D. R., Soong, H.-C., Lim, J. T., Ooi, J. O., & Hong, Z.-W. (2025). A Systematic Review of Stock Market Forecasting Utilizing Machine Learning and Deep Learning. *2025 IEEE 16th Control and System Graduate Research Colloquium (ICSGRC)*, 1–6. <https://doi.org/10.1109/ICSGRC65918.2025.11159810>
- Li, T. (2023). Application Analysis of Financial Time Series in Stock Market. *Advances in Economics, Management and Political Sciences*, 13, 264–270. <https://doi.org/10.54254/2754-1169/13/20230744>

- Liani, T., br. Simbolon, L. R., Anwar, H. R., & br. Naibaho, E. A. I. (2024). Analisis Efisiensi Pasar Modal di Indonesia. *Bisma: Business and Management Journal*, 2(1), 1–13. <https://doi.org/10.59966/bisma.v2i1.680>
- Lommers, K., Harzli, O. El, & Kim, J. (2021). Confronting Machine Learning With Financial Research. *ArXiv Preprint ArXiv:2103.00366*. <https://doi.org/10.48550/arXiv.2103.00366>
- Lubis, P. K. D., Manalu, C. L. N., Lubis, A. A., Tambunan, L. M., & Saputra, F. (2024). The Role of the Capital Market in Increasing Economic Growth in Indonesia. *Marcopolo: Indonesian Journal of Interdisciplinary Research in Science and Technology*, 2(5), 248–254. <https://doi.org/10.55927/marcopolo.v2i5.9322>
- McKinney, W. (2022). *Python for Data Analysis: Data Wrangling with Pandas, NumPy, and Jupyter* (3rd ed.). O'Reilly Media.
- p Shaji, S., R, R., Varghese, J., Sathyan, L., & J, D. (2025). Optimizing Hyperparameters: Techniques for Improving Machine Learning Models. *International Research Journal on Advanced Engineering and Management*, 2(12), 2786–2790. <https://doi.org/10.47392/IRJAEM.2024.0561>
- Pipin, S. J., Purba, R., & Kurniawan, H. (2023). Prediksi Saham Menggunakan Recurrent Neural Network (RNN-LSTM) dengan Optimasi Adaptive Moment Estimation. *Journal of Computer System and Informatics (JoSYC)*, 4(4), 806–815. <https://doi.org/10.47065/josyc.v4i4.4014>
- Putri, I. G. A. P. D., & Kusuma, N. P. N. (2025). Cash Flow Forecasting for Companies Listed on the Indonesia Stock Exchange Using the ARIMA Model. *Jurnal Ilmiah Sistem Informasi Dan Teknik Informatika (JISTI)*, 8(2). <https://doi.org/10.57093/jisti.v8i2.341>
- Riziq, I. F., & Dzikrillah, A. R. (2025). Impelementasi Algoritma LSTM Dan SVR Untuk Prediksi Harga Bitcoin Menggunakan Data Yahoo Finance. *METIK JURNAL*, 9(2). <https://doi.org/10.47002/90ypad22>
- Samsudin, A., Hidayat, R., Ramadhani, C. N., Safitri, S. N., Yulianti, V. R., Ferdiansyah, T., & Royhan, M. F. (2023). Analisis Price Earning Ratio (PER) dalam Pengambilan Keputusan Investasi Saham Perbankan: Studi Kasus pada Perusahaan Sektor Perbankan yang Terdaftar di Bursa Efek Indonesia Tahun 2022. *El-Mujtama: Jurnal Pengabdian Masyarakat*, 3(2), 488–498. <https://doi.org/10.47467/elmujtama.v3i2.2805>
- Shwartz-Ziv, R., & Armon, A. (2022). Tabular data: Deep learning is not all you need. *Information Fusion*, 81, 84–90. <https://doi.org/10.1016/j.inffus.2021.11.011>
- Subasi, N. (2024). Comprehensive Analysis of Grid and Randomized Search on Dataset Performance. *European Journal of Engineering and Applied Sciences*, 7(2), 77–83. <https://doi.org/10.55581/ejeas.1581494>
- Vasellini, R. (2023). ML Application to the Financial Market. In F. Cecconi (Ed.), *AI in the Financial Markets: New Algorithms and Solutions* (pp. 85–94). Springer. https://doi.org/10.1007/978-3-031-26518-1_7
- Waciko, K. J., Susanti, L. A., Muayyad, & Fakhrurozi, R. N. (2025). Forecasting Tourist Arrivals in Bali: A Grid Search-Tuned Comparative Study of Random Forest, *XGBoost*, and a Hybrid RF-*XGBoost* Model. *INFERENSI*, 8(3), 251. <https://doi.org/10.12962/j27213862.v8i3.23334>
- Wang, T., Li, Q., Yang, J., Xie, T., Wu, P., & Liang, J. (2023). Transformer Fault Diagnosis

Method Based on Incomplete Data and TPE-*XGBoost* . *Applied Sciences*, 13(13), 7539. <https://doi.org/10.3390/app13137539>

Wiejaya, A., & Fenriana, I. (2024). Prediksi Harga Saham Top 10 NASDAQ dengan Time Series Prophet. *Jurnal Bit-Tech*, 7(2). <https://doi.org/10.32877/bt.v7i2.1736>

Yang, Y. (2021). Market Forecast using *XGBoost* and Hyperparameters Optimized by TPE. *2021 IEEE International Conference on Artificial Intelligence and Industrial Design (AIID)*, 336–339. <https://doi.org/10.1109/AIID51893.2021.9456538>

Zlobin, M., & Bazylevych, V. (2025). Bayesian Optimization for Tuning Hyperparametr of Machine Learning Models: A Performance Analysis in *XGBoost* . *Computer Systems and Information Technologies*, 1(1), 1–16. <https://doi.org/10.31891/csit-2025-1-16>