



# Perbandingan Kinerja Algoritma Random Forest dan Xgboost Dalam Memprediksi Harga Bitcoin Menggunakan Indikator Teknikal

## Performance Comparison of Random Forest and XGBoost Algorithms in Predicting Bitcoin Prices Using Technical Indicators

Ahmad Siddiq Fadhillah\*, Rahmat Budiarsa

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Esa Unggul, Jakarta, Indonesia

Email: <sup>1</sup>\*siddiqfadhillah123@student.esaunggul.ac.id, <sup>2</sup>rahmat.budiarsa@esaunggul.ac.id

Email Penulis Korespondensi: siddiqfadhillah123@student.esaunggul.ac.id

Received: 03/08/2026, Revised: 08/10/2026, Accepted: 16/10/2026, Published: 16/10/2026

**Abstrak**—Kegagalan kerangka teori ekonomi tradisional dan model peramalan linear konvensional dalam memetakan struktur data non-linear akibat volatilitas ekstrem aset kripto telah menciptakan kesenjangan teoretis pada studi prediksi harga Bitcoin. Mengingat pendekatan *ensemble learning* terbukti unggul dalam menangani data finansial berdimensi tinggi namun masih menyisakan perdebatan akademis terkait algoritma mana yang paling adaptif, Kajian ini bertujuan untuk membandingkan kinerja arsitektur *Random Forest Regressor* dan *XGBoost Regressor*. Pemilihan kedua algoritma ini secara spesifik dilandasi oleh urgensi untuk menguji manakah di antara dua paradigma komputasi yang kontras yakni pendekatan *bagging* yang berfokus mereduksi varians (*Random Forest*) melawan pendekatan *boosting* yang berfokus mengoreksi galat secara iteratif (*XGBoost*) yang paling tangguh dalam merespons volatilitas harga Bitcoin. Pendekatan kuantitatif digunakan dengan memanfaatkan deret waktu historis harian Bitcoin periode 1 Januari 2024 hingga 19 Oktober 2025, di mana *Simple Moving Average* (SMA) dan *Relative Strength Index* (RSI) bertindak sebagai fitur prediktor utama, kemudian kedua model dievaluasi secara komprehensif melalui pengukuran tingkat kesalahan absolut dan persentase. Hasil eksperimen membuktikan bahwa *XGBoost Regressor* tampil jauh lebih superior dengan menekan margin kesalahan hingga mencapai akurasi maksimal (MAE: 2327,81; RMSE: 2978,93; MAPE: 1,99%; R2: 0,4571), mengalahkan *Random Forest* yang tampak kewalahan merespons gejolak fluktuasi secara akurat (MAE: 2891,19; RMSE: 3619,53; MAPE: 2,53%; R2: 0,1984). Selain itu, temuan riset membongkar fakta bahwa kedua mesin algoritma tersebut nyaris mengabaikan indikator momentum dan secara mutlak mendasarkan keputusan prediksinya pada pergerakan tren rata-rata jangka pendek. Kesimpulannya, *XGBoost* terbukti secara empiris sebagai algoritma yang jauh lebih tangguh dan presisi dibandingkan *Random Forest* untuk memetakan dinamika harga Bitcoin yang sarat akan anomali. Kontribusi utama dari penelitian ini terletak pada pembuktian empiris terkait efektivitas paradigma *boosting* atas *bagging* pada aset kripto bergejolak tinggi, serta implementasi langsung arsitektur prediksi pemenang menjadi perangkat lunak *dashboard* interaktif berbasis Streamlit untuk memfasilitasi pengambilan keputusan investasi secara praktis di dunia nyata.

**Kata Kunci:** Bitcoin; Indikator Teknikal; Machine Learning; Prediksi Harga; Random Forest; XGBoost

**Abstract**—The extreme volatility of crypto assets makes Bitcoin price movements notoriously difficult to predict using conventional linear forecasting approaches. This study aims to compare the performance of two machine learning algorithms Random Forest Regressor and XGBoost Regressor in projecting Bitcoin's closing price. A quantitative approach was employed using two years of historical time-series data, with the Simple Moving Average (SMA) and Relative Strength Index (RSI) serving as primary predictor features; both models were then comprehensively evaluated using absolute and percentage error metrics. Experimental results demonstrate that the XGBoost Regressor significantly outperformed the other model, achieving superior accuracy by minimizing error margins (MAE: 2327.81; RMSE: 2978.93; MAPE: 1.99%; R2: 0.4571), whereas the Random Forest model struggled to accurately capture volatile fluctuations (MAE: 2891.19; RMSE: 3619.53; MAPE: 2.53%; R2: 0.1984). Furthermore, the findings reveal that both algorithms largely disregarded momentum indicators, basing their predictions almost entirely on short-term average trend movements. In conclusion, XGBoost is empirically proven to be a far more robust and precise algorithm than Random Forest for modeling the anomaly-prone price dynamics of Bitcoin. The primary contribution of this research lies in providing empirical evidence regarding the effectiveness of the boosting paradigm over bagging for highly volatile crypto assets, as well as the direct implementation of the winning prediction architecture into an interactive Streamlit based dashboard to facilitate practical, real world investment decision making.

**Keywords:** Bitcoin; Technical Indicators; Machine Learning; Price Prediction; Random Forest; XGBoost

## 1. PENDAHULUAN

Meskipun pada mulanya dirancang murni sebagai sistem kas elektronik *peer-to-peer* [1], perkembangan pesat teknologi finansial kini telah memosisikan Bitcoin sebagai instrumen investasi alternatif utama yang mendisrupsi lanskap keuangan global [2]. Namun, berbeda dengan mata uang fiat, ketiadaan otoritas terpusat membuat mekanisme pembentukan harga Bitcoin terlepas dari fundamental ekonomi makro tradisional maupun kebijakan moneter bank sentral [2]. Akibatnya, dinamika harga aset ini murni digerakkan oleh perilaku spekulatif pasar, sentimen penawaran-permintaan, dan faktor keamanan teknologi, yang pada akhirnya memicu tingkat volatilitas sangat ekstrem [2], [3]. Karakteristik fluktuasi harga yang kompleks dan tidak menentu inilah yang memunculkan urgensi akademis untuk memperbarui kerangka analitik prediktif, mengingat pendekatan peramalan ekonomi klasik seringkali gagal memetakan anomali tersebut secara akurat.

Meski menjanjikan prospek pengembalian yang tinggi, pergerakan harga Bitcoin identik dengan volatilitas yang ekstrem. Dinamika harga ini sangat kompleks karena pembentukannya tidak bergantung pada variabel makroekonomi atau kebijakan moneter tradisional. Harga murni digerakkan oleh tarik-menarik antara penawaran dan permintaan,



perilaku spekulatif pasar, hingga isu keamanan siber yang dapat memicu fluktuasi tajam secara tiba-tiba [2], [4]. Akibatnya, kerangka kerja ekonomi klasik seperti Paritas Daya Beli (PPP) maupun peramalan konvensional berbasis data linear, seperti *Exponential Smoothing*, seringkali gagal memetakan tren harga secara akurat [5]. Mengingat rentetan data pasar kripto memiliki struktur yang sangat non-linear dan fluktuatif, pendekatan analitik konvensional harus digantikan dengan arsitektur *machine learning* berbasis *ensemble*, seperti *Random Forest* dan *XGBoost*. Metode ini tidak hanya secara empiris terbukti jauh lebih adaptif dalam mengurai kompleksitas data finansial berdimensi tinggi dibandingkan model linear tunggal [6], [7], tetapi juga sangat andal dalam mengekstraksi pola data yang dinamis secara otomatis tanpa memerlukan instruksi pemrograman yang eksplisit [8].

Di antara berbagai algoritma komputasi, pendekatan *ensemble learning* menonjol karena kemampuannya dalam mengurai kompleksitas data finansial berdimensi tinggi [7], sekaligus secara efektif meminimalisasi bias prediksi [9]. Dua algoritma terkemuka dalam kategori ini, yakni *Random Forest Regressor* (berbasis *bagging*) dan *Extreme Gradient Boosting* *XGBoost* (berbasis *boosting*), memiliki mekanisme optimasi yang secara fundamental berbeda [10], [11]. Berbagai studi terdahulu telah mengonfirmasi ketangguhan kedua model ini, namun sekaligus memunculkan perdebatan teoretis terkait algoritma mana yang paling optimal. Riset Anwas et al. [10] membuktikan bahwa *XGBoost* mampu menghasilkan margin kesalahan terendah dan sangat tajam dalam menangkap anomali harga, sementara studi lain seperti Kurniawan et al. [12] dan Samsudin et al. [13] justru menilai *Random Forest* lebih superior berkat kemampuannya menjaga stabilitas dan meredam gangguan (*noise*) pada data historis. Kesenjangan literatur (perbedaan kesimpulan) dari riset-riset terdahulu inilah yang mendasari urgensi penelitian ini, yaitu untuk melakukan evaluasi komparatif definitif guna memecahkan ketidakpastian mengenai arsitektur mana yang secara empiris paling tangguh saat dihadapkan pada volatilitas ekstrem harga Bitcoin.

Namun, performa optimal dari algoritma prediksi tidak hanya bergantung pada arsitektur model, tetapi juga pada kualitas ekstraksi fitur (indikator) yang dimasukkan. Dalam analisis pergerakan aset kripto, *Relative Strength Index* (RSI) merupakan instrumen krusial untuk mengukur momentum dan mendeteksi kondisi pasar yang jenuh beli (*overbought*) maupun jenuh jual (*oversold*) [5], yang secara empiris terbukti esensial untuk memperkuat keandalan sinyal prediksi komputasi [14]. Apabila dikalibrasi bersama *Simple Moving Average* (SMA) periode 7 hari yang merepresentasikan arah tren jangka pendek [12], kombinasi fitur ini memberikan konteks struktural yang kaya bagi model untuk mempelajari dinamika harga.

Berpijak pada gap literatur dan tantangan volatilitas tersebut, penelitian ini bertujuan untuk menyajikan analisis komparatif yang komprehensif antara *Random Forest* dan *XGBoost* dalam memprediksi harga Bitcoin. Mengatasi keterbatasan studi-studi terdahulu yang umumnya hanya berfokus pada satu algoritma dominan dan sebatas melakukan evaluasi numerik statis, kebaruan (*novelty*) dari riset ini terletak pada dua aspek utama penyelesaian masalah. Pertama, evaluasi performa algoritma secara spesifik disandarkan pada optimalisasi sinergi input indikator teknikal (SMA dan RSI), menggunakan metrik validasi yang ketat (MAE, RMSE, MAPE, dan  $R^2$ ). Kedua, luaran dari riset ini tidak berhenti pada rumusan di atas kertas. Model dengan performa terbaik diimplementasikan secara langsung ke dalam sebuah purwarupa aplikasi web interaktif berbasis *Streamlit*, sebuah pendekatan pengembangan yang diakui sangat efektif untuk mengoperasionalkan model *machine learning* ke dalam sistem *dashboard* analitik finansial yang fungsional secara seketika [15].


Pendekatan komprehensif ini tidak hanya memberikan kontribusi teoretis dalam ranah *machine learning* dan prediksi deret waktu finansial, tetapi juga menyumbangkan alat bantu visual (*decision support system*) yang praktis bagi investor maupun analis dalam mengarungi ketidakpastian pasar *cryptocurrency*.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Penelitian ini menerapkan pendekatan kuantitatif melalui serangkaian tahapan yang komprehensif untuk menjembatani kesenjangan literatur terkait prediksi harga mata uang kripto. Tahapan diawali dengan pengumpulan 658 data deret waktu historis harian Bitcoin (BTC-USD) selama periode 1 Januari 2024 hingga 19 Oktober 2025 Yahoo Finance, yang mencakup atribut *Date*, *Open*, *High*, *Low*, *Close*, dan *Volume* sebagai landasan pemodelan yang objektif. Selanjutnya, dilakukan rekayasa fitur dengan mengintegrasikan indikator *Simple Moving Average* (SMA) 7 hari untuk melacak tren jangka pendek dan *Relative Strength Index* (RSI) 14 hari sebagai osilator momentum guna mengidentifikasi kondisi *overbought* atau *oversold* [5], yang secara krusial terbukti memperkuat keandalan sinyal prediksi komputasi [14]. Memasuki tahap pemodelan, penelitian ini secara ketat membandingkan dua algoritma *ensemble learning* terkemuka *Random Forest Regressor* dan *XGBoost Regressor* untuk mengevaluasi bagaimana kombinasi indikator teknis tersebut secara langsung meningkatkan arsitektur pembelajaran non-linear model dalam mengestimasi pergerakan harga hari berikutnya [7].

Kinerja prediksi dari algoritma tersebut kemudian dievaluasi secara multidimensi menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan Koefisien Determinasi ( $R^2$ ) untuk mengukur akurasi presisi serta ketahanan struktural model secara menyeluruh dalam kondisi volatilitas ekstrem [11].



**Gambar 1.** Bagan Flowchart Penelitian

Gambar 1 mengilustrasikan alur penelitian, mulai dari akuisisi data hingga implementasi sistem akhir. Tahap awal berfokus pada identifikasi masalah terkait volatilitas Bitcoin. Setelah pengumpulan data, dataset menjalani prapemrosesan dan rekayasa fitur sebelum dibagi menjadi subset data latih dan data uji. Akhirnya, proses penelitian menyimpulkan dengan pelatihan model regresi, evaluasi performa menggunakan metrik standar, dan penerapan arsitektur prediktif ke dalam aplikasi berbasis web.

## 2.1 Teknik Pengumpulan Data

Dataset utama diperoleh dari repositori publik Yahoo Finance, yang mencakup 658 catatan harian Bitcoin (BTC-USD) selama periode dua tahun. Keseluruhan data historis tersebut bersifat terbuka dan dapat dibuka langsung melalui tautan <https://finance.yahoo.com/quote/BTC-USD/history>. Dataset ini terdiri dari enam atribut kontinu: Date, Open, High, Low, Close, dan Volume. Atribut-atribut ini sangat penting karena merepresentasikan dinamika pasar harian secara komprehensif, mulai dari posisi pembukaan hingga volume transaksi yang mengindikasikan likuiditas pasar.

## 2.2 Tahapan Pra-Pemrosesan dan Rekayasa Fitur

Selama fase prapemrosesan, representasi harga yang stabil diformulasikan dengan menghitung *Median Price* dari harga *High*, *Low*, dan *Open*.

$$AveragePrice = \frac{High + Low + Close}{3} \quad (1)$$

Nilai ini menjadi input dasar bagi dua indikator teknikal vital: *Relative Strength Index* (RSI) 14-hari untuk mengukur momentum, dan *Simple Moving Average* (SMA) 7-hari untuk melacak tren jangka pendek.

$$RSI = 100 - \frac{100}{1 + RS} \quad (2)$$

$$SMA_n = \frac{P_1 + P_2 + \dots + P_n}{n} \quad (3)$$

Data yang kosong akibat kalkulasi *rolling* dieliminasi, menghasilkan 644 baris dataset yang bersih. Normalisasi data dilakukan menggunakan *MinMaxScaler* agar seluruh fitur berada pada skala 0 hingga 1 [6].

$$P_{t-normalize} = \frac{P_t - \min(P_t)}{\max(P_t) - \min(P_t)} \quad (4)$$

Dataset kemudian dipartisi secara kronologis menjadi 85% [16] untuk data latih (547 catatan) dan 15% untuk data uji (97 catatan) guna menjaga kontinuitas deret waktu.



### 2.3 Pembangunan dan Evaluasi Model

Penelitian ini menggunakan dua algoritma *ensemble learning*: *Random Forest Regressor* dan *XGBoost Regressor*. *Random Forest* bekerja dengan konsep *bagging* untuk membangun pohon keputusan paralel guna mengurangi varians [7].

$$\hat{f}(x) = \frac{1}{N} \sum_{i=1}^N f_i(x) \quad (5)$$

Pengurangan varians untuk pemisahan node dalam model ini bergantung pada Mean Squared Error (MSE).

Sebaliknya, XGBoost menggunakan pendekatan penguatan gradien ekstrem, membangun pohon secara berurutan di mana setiap pohon baru mengoreksi kesalahan residual dari pendahulunya menggunakan ekspansi Taylor orde kedua [17].

$$Obj = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (6)$$

Untuk mencapai akurasi prediksi yang optimal, kedua algoritma menjalani proses penalaan Hyperparameter yang ketat di perlukan dalam penggunaan metode RandomizedSearchCV [18].

Tabel 1 menyajikan ruang pencarian Hyperparameter spesifik yang dikonfigurasi baik algoritma XGBoost maupun Random Forest pada Tabel 2 selama tahap tuning ini.

**Tabel 1.** Konfigurasi ruang Hyperparameter XGBoost Regressor

| Parameter        | Value Ranges                                |
|------------------|---------------------------------------------|
| n_estimators     | 100, 300, 500, 1000, 1500, 2000, 2500, 3000 |
| learning_rate    | 0.001, 0.01, 0.03, 0.05, 0.1, 0.2, 0.3      |
| max_depth        | 3, 4, 5, 6, 7, 8, 10, 12                    |
| min_child_weight | 1, 2, 3, 5, 7                               |
| subsample        | 0.5, 0.6, 0.7, 0.8, 0.9, 1.0                |

Penjabaran masing-masing parameter pada Tabel 1 di atas sangat menentukan struktur pohon pada model *XGBoost*. Parameter *n\_estimators* difungsikan untuk menentukan jumlah total pohon keputusan (*decision trees*) yang dibangun secara sekuensial guna mengoreksi kesalahan residual secara bertahap [17]. Untuk mencegah terjadinya *overfitting*, model mengandalkan *learning\_rate* untuk mengatur kecepatan adaptasi serta langkah pembaharuan bobot pada setiap iterasinya [11], [17]. Kompleksitas model turut dikontrol oleh *max\_depth* yang membatasi tingkat kedalaman maksimal dari setiap cabang, didukung oleh *min\_child\_weight* untuk menetapkan beban minimal sampel data yang harus ada pada simpul daun akhir. Terakhir, parameter *subsample* berperan dalam menentukan proporsi acak dari sampel data latih yang diekstrak pada saat model membangun setiap pohon.

**Tabel 2.** Konfigurasi ruang Hyperparameter Random Forest Regressor

| Parameter         | Value Ranges                                |
|-------------------|---------------------------------------------|
| n_estimators      | 100, 300, 500, 1000, 1500, 2000, 2500, 3000 |
| max_depth         | None, 10, 20, 30, 40, 50, 100               |
| min_samples_split | 2, 5, 10, 15, 20                            |
| min_samples_leaf  | 1, 2, 4, 6, 8, 10                           |

Sedangkan untuk pembentukan arsitektur *ensemble* pada *Random Forest* (Tabel 2), model menggunakan parameter *n\_estimators* guna menetapkan jumlah keseluruhan pohon keputusan majemuk yang dilatih secara paralel untuk mereduksi varians [7]. Tingkat kerumitan pohon diatur oleh parameter *max\_depth* yang membatasi kedalamannya agar model tidak menghafal fluktuasi acak secara kaku [13]. Dalam hal distribusi data pada simpul, *min\_samples\_split* digunakan untuk menentukan seberapa banyak jumlah minimum sampel yang diperlukan saat memecah sebuah *node*, yang secara langsung diimbangi oleh *min\_samples\_leaf* untuk memastikan bahwa jumlah minimal sampel pada simpul daun (*leaf*) selalu terpenuhi sebelum pembagian struktur pohon dihentikan [7].

Teknik optimasi ini secara sistematis mengeksplorasi berbagai kombinasi parameter melalui 20 iterasi untuk mengidentifikasi arsitektur yang paling adaptif terhadap data yang fluktuatif [18]. Proses pencarian menggunakan mekanisme validasi silang *TimeSeriesSplit* dengan 5 fold untuk mencegah kebocoran data secara ketat. Pada akhirnya, kombinasi parameter terbaik dipilih berdasarkan kemampuannya menghasilkan Mean Absolute Percentage Error (MAPE) terendah selama tahap validasi silang.

Untuk menguji dan memvalidasi algoritma secara objektif, prediksi model dievaluasi terhadap harga penutupan Bitcoin aktual dari dataset pengujian (15% data). Evaluasi kinerja dilakukan secara menyeluruh menggunakan empat metrik statistik: Mean Absolute Error (MAE), Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), dan Koefisien Determinasi ( $R^2$ ). Metrik-metrik ini sesuai sepenuhnya dengan rumus yang tercantum dalam kerangka kerja tesis:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$



$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (10)$$

Sebagai langkah akhir, arsitektur algoritma yang menunjukkan performa paling tangguh berdasarkan hasil evaluasi diintegrasikan ke dalam antarmuka web interaktif dengan memanfaatkan *framework* Streamlit [15]. Implementasi sistem ini memfasilitasi peramalan pasar secara *real-time* serta menyediakan dasbor komprehensif yang memungkinkan pengguna untuk mengunggah dataset historis dan melakukan analisis hasil prediksi secara instan.

### 3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan temuan empiris dari fase pemodelan prediktif yang disusun secara sistematis untuk menjawab tujuan penelitian. Pembahasan diawali dengan rincian pra-pemrosesan data historis dan integrasi indikator teknikal *Simple Moving Average* (SMA) serta *Relative Strength Index* (RSI). Selanjutnya, diuraikan tahapan optimasi *hyperparameter* untuk menyempurnakan arsitektur *XGBoost* dan *Random Forest Regressor*. Inti analisis berfokus pada evaluasi komparatif kinerja algoritma berdasarkan metrik kesalahan, dilanjutkan dengan analisis tingkat kepentingan fitur (*feature importance*) untuk membedah bobot indikator tren dan momentum pada masing-masing model. Pembahasan ditutup dengan penetapan model prediksi terbaik, eksekusi proyeksi harga untuk hari berikutnya, serta demonstrasi implementasinya menjadi alat peramalan yang praktis.

#### 3.1 Persiapan Dataset, Prapemrosesan, dan Analisis Eksploratif

Analisis empiris ini menggunakan dataset historis harian Bitcoin (BTC-USD) dari Yahoo Finance yang mencakup periode perdagangan dua tahun. Dataset awal terdiri dari 658 observasi dengan atribut *Date*, *Close*, *High*, *Low*, *Open*, dan *Volume*, serta terkonfirmasi terbebas dari duplikasi dan nilai kosong (*missing values*). Untuk menghindari bias pada fluktuasi harga penutupan, direkayasa fitur Harga Median (rata-rata dari harga *High*, *Low*, dan *Open*) sebagai garis dasar yang lebih stabil. Nilai ini kemudian digunakan untuk membentuk fitur prediktor teknikal, yaitu *Relative Strength Index* (RSI) 14 hari untuk mengukur momentum pasar dan *Simple Moving Average* (SMA) 7 hari untuk memetakan tren jangka pendek. Akibat penggunaan perhitungan *rolling window* pada indikator tersebut, baris data awal yang bernilai *null* dihapus secara sistematis, sehingga menyisakan 644 observasi final yang siap digunakan untuk pemodelan komputasi. Untuk mencegah bias struktural yang parah dan dengan ketat menghindari kebocoran data (*data leakage*) selama fase pelatihan model, dataset kronologis dipartisi secara manual dengan mempertahankan urutan deret waktu menjadi 85% subset pelatihan (547 rekam) dan 15% subset pengujian (97 rekam) [16]. Setelah proses partisi, transformasi *MinMaxScaler* dieksekusi [6]. Guna menjamin tidak adanya kebocoran informasi dari data masa depan, fungsi kalibrasi batas skala (*fit\_transform*) diaplikasikan secara eksklusif hanya pada subset pelatihan untuk mempelajari nilai minimum dan maksimum historis. Parameter batas skala yang telah terkunci tersebut kemudian digunakan secara kaku untuk mentransformasi (*transform*) subset pengujian. Prosedur ini secara efektif menormalisasi semua fitur input kontinu ke dalam skala standar 0 hingga 1 guna memastikan stabilitas komputasi, tanpa membiarkan model mengintip distribusi data pengujian.

#### 3.2 Optimasi Hyperparameter dan Analisis Peringkat Algoritma

Sebelum memfinalisasi model, kinerja *XGBoost* dan *Random Forest Regressor* dioptimalkan melalui tahapan *hyperparameter tuning* menggunakan teknik *RandomizedSearchCV*. Proses ini mengeksplorasi kombinasi parameter secara acak yang dievaluasi melalui mekanisme validasi silang *TimeSeriesSplit* 5 lipatan. Tujuan utama dari optimasi ini adalah menemukan konfigurasi struktural spesifik yang mampu meminimalkan nilai *Mean Absolute Percentage Error* (MAPE).

**Tabel 3.** Peringkat Hyperparameter dan Konfigurasi untuk XGBoost Regressor

| No | Jumlah Pohon | Tingkat Pembelajaran | Kedalaman Maksimal | Nilai MAPE (%) |
|----|--------------|----------------------|--------------------|----------------|
| 1  | 3000         | 0.05                 | 3                  | 7.124212       |
| 2  | 2000         | 0.01                 | 10                 | 7.180155       |
| 3  | 500          | 0.3                  | 3                  | 7.200335       |
| 4  | 3000         | 0.01                 | 3                  | 7.365340       |
| 5  | 500          | 0.03                 | 12                 | 7.374020       |
| 6  | 1500         | 0.01                 | 3                  | 7.414275       |
| 7  | 2500         | 0.1                  | 5                  | 7.422282       |
| 8  | 300          | 0.3                  | 7                  | 7.429387       |
| 9  | 1000         | 0.03                 | 6                  | 7.486192       |
| 10 | 300          | 0.01                 | 7                  | 7.537824       |

Hasil optimasi XGBoost, yang dirinci secara ekstensif pada Tabel 3, menunjukkan bahwa arsitektur prediktif yang paling tangguh (Peringkat 1) mencapai MAPE validasi silang terendah yang mungkin yaitu 7,124%. Kinerja puncak ini dicapai dengan memanfaatkan volume masif sebanyak 3000 *estimator*, tingkat pembelajaran menengah sebesar 0,05, dan kedalaman pohon maksimal yang dibatasi sangat ketat sebesar 3. Alasan analitis untuk konfigurasi optimal spesifik ini tertanam dalam pada sifat mekanisme *gradient boosting* dan volatilitas kripto yang ekstrem. Pohon yang sengaja dibuat dangkal (kedalaman maksimal 3) secara ketat mencegah algoritma melakukan *overfitting*; ini menghentikan model dari menghafal kebisingan pasar (*market noise*) acak yang tidak menentu. Meskipun penggunaan 3000 pohon sekuensial umumnya berisiko tinggi memicu *overfitting*, model ini tetap stabil berkat intervensi tingkat pembelajaran (*learning rate*) sebesar 0,05 dan mekanisme regularisasi internal yang mengendalikan pembaharuan bobot secara konservatif pada setiap iterasinya [17]. Lebih lanjut, untuk mengatasi beban waktu komputasi yang berat akibat volume iterasi yang masif tersebut, algoritma ini dikonfigurasi menggunakan pendekatan histogram (*tree method = hist*), yang secara signifikan mempercepat proses pemisahan simpul tanpa mengorbankan akurasi prediksi. Sebaliknya, konfigurasi peringkat terendah (Peringkat 10) memanfaatkan pohon yang jauh lebih dalam (kedalaman 7) tetapi *estimator* yang jauh lebih sedikit (300) di samping tingkat pembelajaran yang sangat lambat (0,01). Pengaturan ini melumpuhkan kapasitas algoritma untuk mengoreksi secara iteratif kesalahan prediktifnya, dan mengelembungkan tingkat kesalahan menjadi 7,537%.

**Tabel 4.** Peringkat Hyperparameter dan Konfigurasi untuk Random Forest Regressor


| No | Jumlah Pohon | Kedalaman Maksimal | Sampel Minimum Pemisahan | Nilai MAPE (%) |
|----|--------------|--------------------|--------------------------|----------------|
| 1  | 300          | None               | 5                        | 6.032          |
| 2  | 500          | 20                 | 5                        | 6.045          |
| 3  | 1500         | None               | 10                       | 6.191          |
| 4  | 2000         | None               | 2                        | 6.517          |
| 5  | 1500         | 10                 | 2                        | 6.599          |
| 6  | 500          | 40                 | 5                        | 6.846          |
| 7  | 2500         | 100                | 10                       | 6.899          |
| 8  | 300          | None               | 15                       | 7.174          |
| 9  | 1500         | 50                 | 5                        | 7.275          |
| 10 | 500          | 20                 | 2                        | 7.637          |

Untuk *Random Forest Regressor*, konfigurasi paling optimal (Peringkat 1) menghasilkan MAPE 6,032% dengan menggunakan 300 *estimator*, kedalaman maksimum tak terbatas (*None*), dan minimal sampel pemisahan sebesar 5. Tanpa batasan kedalaman, model leluasa mempelajari pola data yang kompleks secara mendalam. Sementara itu, batas pemisahan 5 sampel efektif mencegah *overfitting* dengan menahan model agar tidak menangkap anomali (kebisingan) yang tidak relevan. Sebaliknya, konfigurasi dengan performa terendah (Peringkat 10) menghasilkan MAPE 7,637% akibat membatasi kedalaman pada 20 namun membiarkan pemisahan hanya pada 2 sampel. Kombinasi ini membuat model menjadi kaku sekaligus sangat rentan terhadap kebisingan acak, yang pada akhirnya merusak akurasi prediksi.


### 3.3 Tingkat Kesalahan Indikator dan Sensitivitas Algoritma

Aspek penting dari penelitian ini adalah evaluasi sistematis tentang bagaimana indikator teknikal yang dipilih *Relative Strength Index* (RSI) dan *Simple Moving Average* (MA7) secara spesifik memengaruhi tingkat kesalahan prediktif di kedua algoritma. Analisis sensitivitas ini diukur secara kuantitatif menggunakan *Root Mean Square Error* (RMSE) untuk mengukur deviasi nominal dari harga penutupan aktual dan memberikan penalti pada proyeksi *outlier* yang besar.

Berdasarkan visualisasi pada Gambar 2, terlihat evaluasi tingkat kesalahan prediksi (*Root Mean Square Error*/RMSE) untuk algoritma *XGBoost Regressor*. Penggunaan indikator *Relative Strength Index* (RSI) secara eksklusif menghasilkan deviasi kesalahan yang sangat masif, yakni mencapai 37.821,11. Namun, ketika model mengintegrasikan sinergi antara indikator momentum (RSI) dan arah tren (MA7), nilai RMSE mengalami penurunan drastis hingga menyentuh titik terendah absolut pada angka 2.978,93. Hal ini secara empiris membuktikan bahwa arsitektur *gradient boosting* pada XGBoost sangat bergantung pada keragaman dimensi data untuk memetakan volatilitas harga kripto secara presisi [7].



**Gambar 2.** Tingkat Kesalahan RMSE dari XGBoost Regressor Berdasarkan Skenario Input Indikator Teknikal



**Gambar 3.** Tingkat Kesalahan RMSE dari Random Forest Regressor Berdasarkan Skenario Input Indikator Teknikal

Sebaliknya, Gambar 3 mengilustrasikan perilaku yang sangat berbeda pada arsitektur *Random Forest Regressor*. Algoritma berbasis *ensemble bagging* ini justru mencapai tingkat kesalahan paling minimum (RMSE 4.066,00) ketika hanya diumpankan dengan indikator MA7 secara mandiri. Penambahan indikator RSI ke dalam sistem komputasi *Random Forest* nyatanya tidak membawa perbaikan, melainkan memperburuk kinerja model dengan menggelembungkan angka kesalahan menjadi 4.204,24. Fenomena ini mengindikasikan bahwa sifat RSI yang berosilasi tinggi bertindak sebagai gangguan (*noise*) yang mendistraksi mekanisme perataan matematis *Random Forest* dalam melacak tren jangka pendek primer [12].

**Tabel 5.** Kinerja RMSE Berdasarkan Integrasi Indikator Teknikal

| Input Feature Scenario | XGBoost   | Random Forest |
|------------------------|-----------|---------------|
| RSI                    | 37,821.11 | 38,461.74     |
| MA7                    | 4,113.25  | 4,066.00      |
| RSI & MA7              | 2,978.93  | 4,204.24      |


Sebagai rujukan komprehensif, Tabel 5 merangkum matriks evaluasi RMSE tersebut, yang secara definitif menyimpulkan bahwa *XGBoost* membutuhkan fusi indikator gabungan untuk mencapai performa puncak, sementara *Random Forest* lebih stabil pada fitur tren berdimensi tunggal.

Hasil pengujian menunjukkan kontras perilaku algoritmik yang jelas. Pada *XGBoost Regressor*, penggunaan indikator RSI secara mandiri menghasilkan tingkat kesalahan yang tidak dapat diterima (RMSE 37.821,11), membuktikan bahwa momentum saja tidak cukup untuk memetakan harga kripto. Namun, saat RSI dikombinasikan dengan indikator tren MA7, tingkat kesalahan *XGBoost* turun drastis ke titik terendah (RMSE 2.978,93). Hal ini mengonfirmasi bahwa *XGBoost* membutuhkan sinergi antara dimensi momentum dan tren untuk mencapai presisi maksimal. Sebaliknya, *Random Forest* justru mencapai kinerja paling optimal (RMSE 4.066,00) saat hanya mengandalkan indikator MA7 secara mandiri. Penambahan RSI pada model ini malah memperburuk kinerja, menaikkan tingkat kesalahan menjadi 4.204,24. Penurunan akurasi ini terjadi karena sifat RSI yang berosilasi tinggi bertindak sebagai *noise* (kebisingan) yang mengganggu mekanisme perataan matematis *Random Forest* dalam melacak tren jangka pendek.


### 3.4 Koefisien Determinasi ( $R^2$ )

Untuk lebih memvalidasi temuan dari analisis RMSE, metrik *R-Squared* ( $R^2$ ) digunakan untuk mengukur kapasitas proporsional dari indikator teknikal dalam menjelaskan varians dan arah tren dari pergerakan pasar aktual.

Berdasarkan visualisasi pada Gambar 4, terlihat distribusi kinerja  $R^2$  untuk model *XGBoost Regressor*. Penggunaan indikator RSI atau MA7 secara terpisah menghasilkan nilai  $R^2$  negatif yang sangat ekstrem, yakni -86,5199 dan -0,0352. Namun, melalui kombinasi sinergis antara RSI dan MA7, *XGBoost* berhasil bangkit dan meraih skor  $R^2$  positif sebesar 0,4571. Hal ini membuktikan bahwa integrasi kedua indikator mutlak diperlukan agar arsitektur *gradient boosting* dapat menyaring sinyal pasar yang saling kontradiktif secara akurat.



**Gambar 4.** Kinerja R-Squared dari XGBoost Regressor Di Berbagai Skenario Indikator



**Gambar 5.** Kinerja R-Squared dari Random Forest Regressor Di Berbagai Skenario Indikator

Sebaliknya, Gambar 5 mengilustrasikan tantangan komputasi yang jauh lebih luas pada *Random Forest Regressor*. Secara keseluruhan, seluruh skenario pengujian pada model ini menghasilkan skor  $R^2$  negatif. Walaupun demikian, pemanfaatan indikator tren MA7 secara mandiri memberikan hasil yang paling optimal karena posisinya paling mendekati angka nol (-0,0115). Masuknya indikator RSI ke dalam sistem ini terbukti semakin menjatuhkan skor menjadi -0,0815, yang secara definitif mengonfirmasi bahwa data momentum yang beresilasi tinggi bertindak sebagai faktor pendestabilisasi bagi mekanisme pemungutan suara internal (*ensemble bagging*) model tersebut.

**Tabel 6.** Kinerja R-Squared Berdasarkan Integrasi Indikator Teknikal


| Input Feature Scenario | XGBoost $R^2$ | Random Forest $R^2$ |
|------------------------|---------------|---------------------|
| RSI                    | -86.5199      | -89.5099            |
| MA7                    | -0.0352       | -0.0115             |
| RSI & MA7              | 0.4571        | -0.0815             |

Sebagai rujukan komprehensif, Tabel 6 merekapitulasi matriks perbandingan nilai  $R^2$  dari kedua algoritma. Terkait dominasi varians negatif pada hasil pengujian tersebut, secara teoretis dalam evaluasi *machine learning*, nilai  $R^2$  dapat jatuh ke rentang negatif (di bawah nol) apabila tingkat deviasi prediksi model lebih besar daripada varians data aktual.

Hal ini mengindikasikan bahwa performa algoritma pada subset pengujian tersebut lebih buruk dibandingkan dengan hanya menggunakan nilai rata-rata (*mean baseline*) dari data historis [19]. Dalam konteks prediksi harga Bitcoin yang sarat akan anomali, fenomena ini wajar terjadi karena algoritma yang hanya dibekali fitur berdimensi tunggal sangat rentan terhadap *noise* volatilitas ekstrem, sehingga memicu proyeksi yang menyimpang jauh dari garis ekuilibrium tren pasar.

### 3.5 Kepentingan Fitur dan Distribusi Bobot

Untuk menginterpretasikan secara mendalam mekanisme pengambilan keputusan internal algoritma dan memahami alasan berbedanya tingkat kesalahan, dilakukan analisis Kepentingan Fitur (*Feature Importance*) dengan sangat cermat.



**Gambar 6.** Distribusi Bobot Kepentingan Fitur dari Model XGBoost dan Random Forest

Ekstraksi visual dari tingkat kepentingan fitur mengungkapkan ketidakseimbangan struktural yang parah tentang cara algoritma *machine learning* memprioritaskan indikator teknikal yang diberikan. Kedua model *ensemble* ini menunjukkan ketergantungan komputasi yang nyaris mutlak pada *Simple Moving Average* 7 hari (MA7) dalam menyusun prediksi akhir mereka. Secara rinci, XGBoost mengalokasikan bobot keputusan yang sangat besar senilai 91,00% pada indikator tren ini, sedangkan *Random Forest* mengalokasikan bobot yang lebih tinggi lagi yaitu 98,24%. Hasilnya, *Relative Strength Index* 14 hari (RSI14) sebagian besar diabaikan oleh kedua algoritma, hanya diberi bobot 9,00% di XGBoost dan persentase tidak signifikan sebesar 1,76% di *Random Forest*. Analisis ini mengindikasikan bahwa perataan

tren harga rata-rata jangka pendek secara historis memiliki relevansi matematis yang secara signifikan jauh lebih tinggi untuk *decision trees ensemble* dibandingkan dengan metrik momentum berbasis osilator saat ditugaskan memetakan volatilitas harga kripto yang ekstrem.


### 3.6 Matriks Evaluasi Kinerja Komprehensif

Kinerja prediktif akhir dari kedua model yang telah terlatih dan teroptimasi penuh dievaluasi secara kuantitatif terhadap dataset pengujian yang tidak terlihat sebelumnya di empat metrik statistik komprehensif.

**Tabel 7.** Kinerja Matriks Evaluasi

| Algorithm               | Mean Absolute Error (MAE) | Root Mean Square Error (RMSE) | Mean Absolute Percentage Error (MAPE) | R-Squared (R <sup>2</sup> ) |
|-------------------------|---------------------------|-------------------------------|---------------------------------------|-----------------------------|
| XGBoost Regressor       | 2327.81                   | 2978.93                       | 1.99%                                 | 0.4571                      |
| Random Forest Regressor | 2891.19                   | 3619.53                       | 2.53%                                 | 0.1984                      |

Hasil evaluasi metrik secara empiris membuktikan keunggulan mutlak *XGBoost Regressor* dalam peramalan ini. *XGBoost* mencatatkan deviasi nominal yang lebih rendah dengan nilai MAE 2327,81 dan RMSE 2978,93, yang menunjukkan stabilitas tinggi dalam meredam *outlier* ekstrem. Pada aset keuangan yang sangat volatil, *XGBoost* mampu meraih MAPE sebesar 1,99% (jauh di bawah batas toleransi industri 10%), membuktikan tingginya presisi prediksi proporsional terlepas dari skala harga. Keunggulan ini semakin diperkuat oleh skor R<sup>2</sup> sebesar 0,4571 yang terbukti jauh lebih tangguh dalam menjelaskan varians pergerakan harga aktual dibandingkan *Random Forest* yang hanya mencapai 0,1984.



**Gambar 7.** Perbandingan Visual Harga Bitcoin Aktual vs Prediksi pada Data Pengujian

Visualisasi grafis dari fase pengujian Gambar 7 memvalidasi secara visual atas temuan-temuan dari data statistiknya. Lintasan harga aktual ini memperlihatkan pergerakan ayunan yang tidak menentu dan parah. Lintasan prediksi dari *XGBoost* memberikan respons dinamis, serta mampu merefleksikan tren kenaikan maupun penurunan akut dengan responsivitas tinggi. Sangat kontras dari itu, lintasan model *Random Forest* menampilkan tingkat penghalusan perhitungan secara matematis secara berlebihan, dan ini memperlihatkan sifat kekakuan serta ketidakmampuan yang terang untuk menembus rentang puncak dan titik dasar harga paling ekstrem, yang memvalidasi perolehan atas penalti RMSE yang dimilikinya lebih tinggi.

### 3.7 Peramalan Prediktif Hari Berikutnya (H+1)

Sebagai uji empiris penutup, arsitektur-arsitektur terlatih secara intensif ini dimanfaatkan untuk secara praktis memproyeksikan harga penutupan Bitcoin di periode berturut-turut selanjutnya (H+1). Mekanisme proyeksi mengekstraksi titik data kronologis terbaru dari susunan dataset ini, yang menorehkan harga pada titik penutupan aktual terkini di nilai 108.666,71 USD. Masukan mentah ini diskalakan secara mulus dan dilewatkan pada arsitektur final dari masing-masing model.

**Tabel 8.** Proyeksi Harga Bitcoin Hari Berikutnya (H+1)

| Algoritma               | Current Actual Close | Predicted Close (H+1) | Projected Market Movement | MAPE (%) |
|-------------------------|----------------------|-----------------------|---------------------------|----------|
| XGBoost Regressor       | 108666.7109          | 105,375.51            | Down (-3.03%)             | 1.997480 |
| Random Forest Regressor | 108666.7109          | 113,892.53            | Up (+4.81%)               | 2.525532 |

Kedua model menghasilkan proyeksi arah pergerakan harga yang saling bertolak belakang untuk hari berikutnya. *Random Forest* memprediksi tren *bullish* dengan kenaikan +4,81% menuju level 113.892,53 USD. Sebaliknya, *XGBoost* meramalkan koreksi *bearish* sebesar -3,03% yang menekan harga turun ke posisi 105.375,51 USD. Keputusan akhir didasarkan pada perbandingan tingkat akurasi metrik evaluasi. Karena *XGBoost Regressor* terbukti jauh lebih andal dengan margin kesalahan (MAPE) hanya 1,99% dibandingkan *Random Forest* (2,53%), proyeksi dari *XGBoost* ditetapkan



sebagai keluaran dengan probabilitas kebenaran tertinggi. Kesimpulannya, harga penutupan Bitcoin pada periode berikutnya diproyeksikan akan mengalami penurunan ke level 105.375,51 USD.

### 3.8 Pembahasan Komprehensif dan Komparasi Riset Terdahulu

Hasil empiris ini secara definitif membuktikan supremasi *XGBoost Regressor* atas *Random Forest Regressor* dalam memproyeksikan volatilitas Bitcoin. *XGBoost* sukses menekan margin kesalahan secara optimal (MAE 2327,81; RMSE 2978,93; MAPE 1,99%;  $R^2$  0,4571), secara mutlak mengungguli *Random Forest* (MAE 2891,19; RMSE 3619,53; MAPE 2,53%;  $R^2$  0,1984). Temuan ini merevisi studi Ahmed *et al.* [20] yang sebelumnya mengunggulkan *Random Forest* pada data mentah, sekaligus memvalidasi pernyataan Zhu *et al.* [7] bahwa algoritma *ensemble* sangat sensitif terhadap seleksi fitur teknis. Keunggulan *XGBoost* bersumber dari kemampuannya mengoreksi *residual error* secara iteratif, memungkinkannya menyintesis indikator tren (MA7) dan momentum (RSI) secara proporsional (dominasi MA7 terkendali di 91,00%). Ini sejalan dengan Anwas *et al.* [10] mengenai ketangguhan *XGBoost* pada data non linear Bitcoin. Sebaliknya, kinerja *Random Forest* justru terdegradasi oleh penambahan RSI. Menurut Kurniawan *et al.* [12], osilasi ekstrem RSI bertindak sebagai *noise* yang mengacaukan mekanisme *internal voting* model, sehingga memaksa *Random Forest* bergantung absolut pada MA7 (dominasi 98,24%) demi menjaga stabilitas. Kesimpulannya, pendekatan *boosting* terbukti jauh lebih presisi, adaptif, dan andal dibandingkan *bagging* dalam peramalan kripto bervolatilitas tinggi.

## 4. KESIMPULAN

Penelitian ini berhasil mengonstruksi arsitektur *machine learning* adaptif untuk memprediksi volatilitas non linear harga Bitcoin melalui integrasi indikator tren (SMA 7 hari) dan momentum (RSI 14 hari). Hasil evaluasi membuktikan supremasi *XGBoost Regressor* (dioptimasi melalui *RandomizedSearchCV*) yang sukses menekan margin kesalahan ke titik minimal dengan perolehan MAE 2327,81; RMSE 2978,93; MAPE 1,99%; dan  $R^2$  0,4571. Sebaliknya, asimilasi indikator RSI pada *Random Forest Regressor* justru mendistorsi kalkulasi matematis dan menurunkan akurasi model (MAPE 2,53%;  $R^2$  0,1984). Analisis fitur lebih lanjut menyingkap bahwa tren pergerakan jangka pendek (SMA) secara absolut mendominasi landasan keputusan prediksi pada kedua model *ensemble* tersebut. Penelitian ini memberikan kontribusi secara akademis melalui pembuktian empiris keunggulan paradigma *boosting* dibandingkan *bagging* dalam memetakan data kripto yang bergejolak, serta kontribusi praktis berupa implementasi arsitektur *XGBoost* terbaik ke dalam purwarupa aplikasi web interaktif berbasis Streamlit untuk memfasilitasi keputusan investasi pengguna. Untuk pengembangan riset selanjutnya, keandalan model dapat ditingkatkan melalui penambahan indikator teknis komplementer seperti *Bollinger Bands* dan *MACD*, serta diintegrasikan dengan analisis sentimen fundamental seperti *Fear and Greed Index* maupun ekstraksi berita *real-time* guna meredam efek keterlambatan prediksi (*lagging*) saat terjadi guncangan pasar yang tak terduga.

## 5. PERNYATAAN PENULIS

### 5.1 Kontribusi Penulis

Konseptualisasi: A. S. F., dan R. B.;

Metodologi: A. S. F., dan R. B.;

Perangkat Lunak: A. S. F.;

Validasi: A. S. F., dan R. B.;

Analisis Formal: A. S. F.;

Investigasi: A. S. F.;

Sumber Daya: A. S. F.;

Kurasi Data: A. S. F.;

Penulisan Draf Awal: A. S. F.;

Penulisan, Peninjauan, dan Penyuntingan: A. S. F., dan R. B.;

Visualisasi: A. S. F.;

Seluruh penulis telah membaca dan menyetujui versi manuskrip yang telah diterbitkan. Seluruh penulis telah membaca dan menyetujui versi manuskrip yang telah diterbitkan.

### 5.2 Ketersediaan Data

Data historis Bitcoin yang disajikan dalam penelitian ini diperoleh melalui metode *crawling data* dari portal publik Yahoo Finance. Dataset mentah hasil ekstraksi maupun data yang telah melalui pra-pemrosesan tersedia berdasarkan permintaan kepada penulis korespondensi.

### 5.3 Pendanaan

Penelitian ini tidak menerima pendanaan eksternal dari pihak publik, komersial, maupun lembaga nirlaba mana pun. Seluruh kegiatan penelitian didanai secara mandiri oleh penulis.

### 5.4 Pernyataan Dewan Peninjau Institusional





Tidak Berlaku (Not applicable).

### 5.5 Pernyataan Persetujuan Berdasarkan Informasi

Tidak Berlaku (Not applicable).

### 5.6 Pernyataan Konflik Kepentingan

Para penulis menyatakan bahwa mereka tidak memiliki kepentingan keuangan yang bersaing atau hubungan pribadi yang diketahui yang dapat dianggap memengaruhi pekerjaan yang dilaporkan dalam artikel ini.

### 5.7 Penggunaan AI Generatif dan Teknologi Berbantuan AI dalam Proses Penulisan

Para penulis menggunakan AI Generatif murni sebagai asisten penyuntingan untuk meningkatkan kejelasan tata bahasa dan kelancaran narasi akademik dalam artikel ini. Para penulis telah meninjau, mengonfirmasi, dan menyunting konten yang dihasilkan dengan bantuan AI serta bertanggung jawab penuh atas keaslian dan akurasi versi akhir publikasi.

## REFERENCES

- [1] N. Köse, Y. E. Gür, and E. Ünal, "Deep Learning and Machine Learning Insights Into the Global Economic Drivers of the Bitcoin Price," *J. Forecast.*, vol. 44, no. 5, pp. 1666–1698, Aug. 2025, doi: 10.1002/for.3258.
- [2] S. Hossain, M. Bairagi, J. Aktar, U. Honey, and S. A. Mithy, "The Evolution of Bitcoin: A Historical Analysis and Future Prospects," *iRASD Journal of Economics*, vol. 5, no. 2, pp. 241–252, Jun. 2023, doi: 10.52131/joe.2023.0502.0124.
- [3] M. N. M. Bhutta *et al.*, "A Survey on Blockchain Technology: Evolution, Architecture and Security," *IEEE Access*, vol. 9, no. 1, pp. 61048–61073, 2021, doi: 10.1109/ACCESS.2021.3072849.
- [4] S. Abdallah-Ou-Moussa, M. Wynn, and O. Kharbouch, "Blockchain, Cryptocurrencies, and Decentralized Finance: A Case Study of Financial Inclusion in Morocco," *International Journal of Financial Studies*, vol. 13, no. 3, pp. 1–25, Sep. 2025, doi: 10.3390/ijfs13030124.
- [5] H. Sebastião and P. Godinho, "Forecasting and Trading Cryptocurrencies With Machine Learning Under Changing Market Conditions," *Financial Innovation*, vol. 7, no. 1, Dec. 2021, doi: 10.1186/s40854-020-00217-x.
- [6] E. Fitri, "Analisis Perbandingan Metode Regresi Linier, Random Forest Regression dan Gradient Boosted Trees Regression Method untuk Prediksi Harga Rumah," *Journal of Applied Computer Science and Technology (JACOST)*, vol. 4, no. 1, pp. 2723–1453, 2023, doi: 10.52158/jacost.491.
- [7] Y. Zhu *et al.*, "Price Prediction of Bitcoin Based on Adaptive Feature Selection and Model Optimization," *Mathematics*, vol. 11, no. 6, Mar. 2023, doi: 10.3390/math11061335.
- [8] M. Nowak and M. Pawłowska-Nowak, "Dynamic Pricing Method in the E-Commerce Industry Using Machine Learning," *Applied Sciences (Switzerland)*, vol. 14, no. 24, pp. 1–15, Dec. 2024, doi: 10.3390/app142411668.
- [9] A. R. Al Musyaffa, Y. Pristyanto, and N. Mauliza, "Comparison of Ensemble Methods for Decision Tree Models in Classifying E. Coli Bacteria," *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, vol. 10, no. 3, pp. 514–522, Feb. 2025, doi: 10.33480/jitk.v10i3.5972.
- [10] I. M. Anwas, F. Fahrianto, I. M. Shofi, and Ajif Yunizar Pratama, "Performance Comparison of LSTM, XGBoost, and Residual-Correction Hybrid LSTM–XGBoost Models for Bitcoin Price Forecasting," *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 25, no. 2, pp. 251–262, Mar. 2026, doi: 10.30812/matrik.v25i2.5983.
- [11] J. Chen, "Analysis of Bitcoin Price Prediction Using Machine Learning," *Journal of Risk and Financial Management*, vol. 16, no. 1, Jan. 2023, doi: 10.3390/jrfm16010051.
- [12] T. A. D. Kurniawan, A. Setiawan, and F. Tita, "Perbandingan Kinerja Metode Support Vector Regression dan Metode Regresi Linier Berganda dalam Memprediksi BMI pada Dataset ASTHMA," *Jurnal Sains dan Edukasi Sains*, vol. 8, no. 2, pp. 133–142, Aug. 2025, doi: 10.24246/juses.v8i2p133-142.
- [13] S. Samsudin, M. D. Irawan, M. I. P. Nasution, and R. A. Putri, "Bitcoin Price Forecasting Using Random Forest and On-Chain Data," *Applied Information System and Management (AISM)*, vol. 8, no. 2, pp. 355–364, Oct. 2025, doi: 10.15408/aism.v8i2.46690.
- [14] M. D. Stasiak, Z. Staszak, and M. Stawarz, "Forecasting Crude Oil Prices Using the Binary RSI (bRSI) Indicator," *Energies (Basel)*, vol. 18, no. 12, Jun. 2025, doi: 10.3390/en18123034.
- [15] S. Adeyemi, M. Z. Iqbal, and M. G. M. Talukder, "Machine Learning-Based Diabetes Risk Prediction via DiaHealth Dataset with Explainable AI and Streamlit Deployment," *Future Internet*, vol. 18, no. 6, pp. 1–18, Jun. 2026, doi: 10.3390/fi18060331.
- [16] A. Akusta and M. N. Salur, "The Effect of Cryptocurrency Ecosystem and Global Indicators on Bitcoin Price," *Sosyoekonomi*, vol. 33, no. 63, pp. 115–142, Jan. 2025, doi: 10.17233/sosyoekonomi.2025.01.06.
- [17] D. Wu, H. Cai, and T. Li, "Food Safety Risk Prediction and Regulatory Policy Enlightenment Based on Machine Learning," *Systems*, vol. 13, no. 8, Aug. 2025, doi: 10.3390/systems13080715.
- [18] N. Alamsyah, B. Budiman, T. P. Yoga, and R. Y. R. Alamsyah, "XGBoost Hyperparameter Optimization Using RandomizedSearchCV for Accurate Forest Fire Drought Condition Prediction," *Jurnal Pilar Nusa Mandiri*, vol. 20, no. 2, pp. 103–110, Sep. 2024, doi: 10.33480/pilar.v20i2.5569.
- [19] I. Naskinova, M. Kolev, M. Milev, and P. Mitev, "Signal-Derived Feature Analysis for Cuffless Blood Pressure Estimation: Comparing Machine Learning and Deep Learning on ICU Physiological Waveforms," *AI (Switzerland)*, vol. 7, no. 3, Mar. 2026, doi: 10.3390/ai7030098.
- [20] M. Ahmed, S. A. Suha, F. H. Mahi, and F. U. Ahmed, "Evaluating the Performance of Bitcoin Price Forecasting Using Machine Learning Techniques on Historical Data," *IAPGOS*, vol. 14, no. 2, pp. 101–108, 2024, doi: 10.35784/iapgos.5657.

