

Prediksi Harga Penutupan Harian Ethereum Terhadap Rupiah Menggunakan *Random Forest* dan Indikator Teknikal

Dimas Danni Arganata^{a,1,*}, Mohammad Zainudin^{b,2}

^{a,b} Program Studi Teknik Informatika, Institut Teknologi dan Bisnis Asia Malang, Jl. Soekarno Hatta Jl. Rembeksari No.1 A, Mojolangu, Kec. Lowokwaru, 65113, Indonesia

¹ dimasarganata01@gmail.com*, ² mzein@asia.ac.id

* corresponding author

ARTICLE INFO

ABSTRACT

Keywords

Ethereum
Cryptocurrency Forecasting
Random Forest Regression
Technical Indicator
Machine Learning

This research aims to develop a predictive model for estimating the daily closing price of Ethereum (ETH) against the Indonesian Rupiah (IDR) using the Random Forest Regression algorithm. Ethereum is one of the most widely traded cryptocurrencies and is known for its high volatility, which makes accurate price prediction essential for supporting data-driven investment decisions. Historical price data were collected from the CoinGecko API for a period of 365 days, followed by preprocessing, feature engineering, and the computation of several technical indicators including Exponential Moving Average (EMA-14), Relative Strength Index (RSI-14), Daily Return, Bollinger Bands Upper, Average True Range (ATR-14), and Close Lag-1. The research starting from data selection and preprocessing to modeling, evaluation and visualization. Random Forest Regression was chosen due to its robustness in handling nonlinear relationships and noisy time-series data. The dataset was split using a 90:10 time-based hold-out method, and model performance was evaluated using four regression metrics: MAE, RMSE, MAPE, and R-squared. The best configuration of the model achieved a MAPE of 2.88%, indicating a high level of predictive accuracy. Feature importance analysis shows that Daily Return and ATR-14 contributed most significantly to the prediction. The findings demonstrate that Random Forest Regression can effectively capture the nonlinear patterns in cryptocurrency price movements, providing an accurate and reliable model for short-term forecasting. This model may serve as a valuable reference for investors, financial analysts, and developers of automated trading systems.

1. Pendahuluan

Aset kripto merupakan sebuah bentuk aset digital yang dirancang untuk bekerja sebagai alat tukar menggunakan kriptografi yang kuat untuk mengamankan transaksi keuangan, mengontrol penciptaan unit tambahan, dan memverifikasi transfer aset. Salah satu aset kripto yang populer dan memiliki kapitalisasi pasar terbesar kedua setelah Bitcoin adalah Ethereum [1].

Ethereum telah digunakan dalam berbagai aplikasi terdesentralisasi dan kontrak pintar (smart contract) yang berjalan di atas teknologi *blockchain*. Seiring dengan meningkatnya adopsi dan ketertarikan terhadap aset kripto, prediksi harga Ethereum menjadi semakin penting dalam pengambilan keputusan investasi. Namun, pergerakan harga Ethereum yang sangat fluktuatif membuat prediksi harga menjadi tantangan tersendiri [2], [3].

Berbagai penelitian telah dilakukan untuk mengatasi tantangan ini dengan pendekatan berbasis machine learning. Liu et al. [2] mengulas bahwa metode data mining banyak digunakan dalam pasar keuangan, termasuk pasar aset digital. Akyildirim et al. [1] menunjukkan bahwa machine learning dapat memberikan

prediksi yang lebih akurat dibandingkan metode tradisional. Beberapa algoritma populer yang sering digunakan adalah *Random Forest*, *Support Vector Machine (SVM)*, *Long Short-Term Memory (LSTM)* dan *Artificial Neural Network (ANN)* [4], [5].

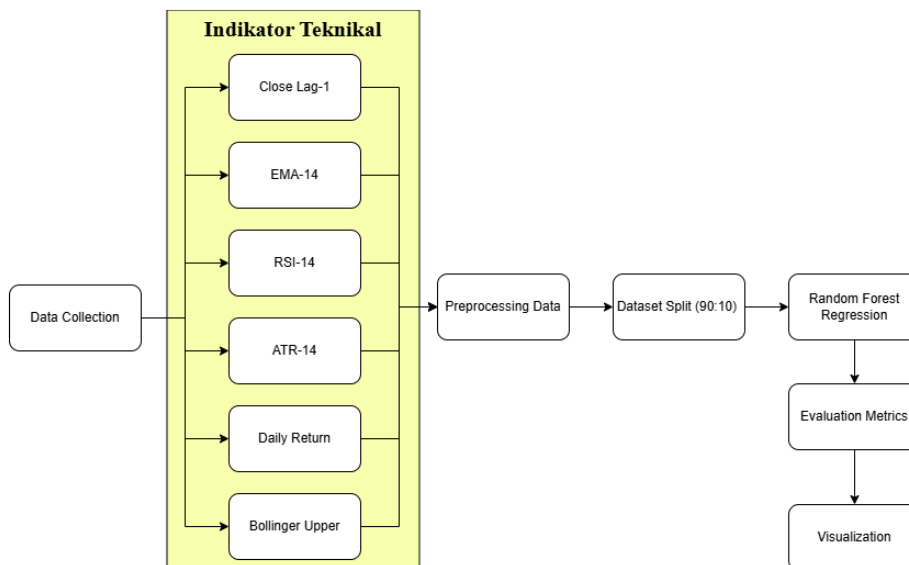
Selain algoritma prediksi, penggunaan indikator teknikal seperti *Moving Average*, *Relative Strength Index (RSI)*, dan *Moving Average Convergence Divergence (MACD)* juga banyak digunakan dalam analisis harga aset kripto. Indikator teknikal ini digunakan untuk mengidentifikasi tren dan pola dalam data historis harga [3].

2. Metodologi Penelitian

Penelitian ini bertujuan membangun model prediksi harga penutupan harian Ethereum terhadap Rupiah dengan algoritma *Random Forest Regression*, Tahapan penelitian ini melibatkan pemanfaatan metode penambangan data (*data mining*) untuk analisis dan prediksi di pasar keuangan yang mencakup seleksi data, pra-pemrosesan, transformasi fitur, pemodelan, dan evaluasi [2]

Proses dimulai dengan pengumpulan data historis Ethereum dari CoinGecko API. Data kemudian diolah menjadi sejumlah indikator teknikal seperti EMA, RSI, ATR, dan Bollinger Bands. Indikator tersebut dipilih karena terbukti efektif dalam mendukung akurasi model prediksi, sebagaimana dijelaskan dalam penelitian oleh Fozap [3].

Setelah melalui tahapan pra-pemrosesan, data dibagi menjadi data latih dan data uji dengan rasio 90:10. Model Random Forest dilatih menggunakan parameter optimal dan dievaluasi dengan metrik MAE, RMSE, MAPE, dan R². Diagram alur keseluruhan metode ditampilkan pada Gambar 1 dan tiap tahap akan dijelaskan dalam subbagian berikut.



Gambar 1. Diagram Flowchart

2.1. Data Collection

Tahap awal dalam penelitian ini adalah pengumpulan data historis harga Ethereum terhadap Rupiah. Data diperoleh melalui CoinGecko API, yang merupakan salah satu penyedia data kripto global terkemuka dan telah banyak digunakan dalam penelitian terkait prediksi harga aset digital. API ini menyediakan data dalam

format OHLC (Open, High, Low, Close), volume, serta tanggal (Date) dengan resolusi harian, sehingga sangat sesuai untuk membangun model prediktif berbasis time series.

Dataset dikumpulkan selama periode 365 hari terakhir, mencerminkan fluktuasi harga jangka menengah yang relevan untuk prediksi harian. Struktur data yang digunakan mencakup atribut-atribut *date*, *open*, *high*, *low*, *close*, dan *volume*

Informasi ini akan menjadi dasar dalam pembentukan fitur teknikal yang dijelaskan pada subbab berikut. Struktur dan deskripsi lengkap atribut dapat dilihat pada Tabel 1.

Tabel 1. Daftar Atribut, Tipe, dan Deskripsi

Attribut	Tipe	Deskripsi
<i>Date</i>	<i>Datetime</i>	Tanggal Transaksi
<i>Close</i>	<i>Float</i>	Harga Penutup t
<i>High</i>	<i>Float</i>	Harga Tertinggi t
<i>Low</i>	<i>Float</i>	Harga Terendah t
<i>Volume</i>	<i>Float</i>	Total Volume t

2.2. Pembuatan Fitur (Indikator Teknikal)

Tahap feature engineering dilakukan untuk menghasilkan variabel-variabel baru yang mampu merepresentasikan pola historis pergerakan harga Ethereum terhadap Rupiah. Penggunaan indikator teknikal dalam konteks pasar keuangan dan kripto terbukti efektif dalam mengungkap hubungan non-linear serta memperkuat performa model prediktif berbasis pembelajaran mesin, [1][6]. Seluruh indikator dihitung berdasarkan harga penutupan (*close price*), karena komponen ini paling stabil dan relevan untuk analisis jangka pendek.

Indikator pertama yang digunakan adalah Close Lag-1, yaitu nilai harga penutupan pada periode sebelumnya. Fitur ini merepresentasikan temporal dependence dalam data time series, di mana harga saat ini sangat dipengaruhi oleh harga sebelumnya [6]. Rumus perhitungan Close Lag-1 adalah:

$$CloseLag^1 = Close_t^{(-1)} \tag{1}$$

Selanjutnya dihitung indikator *Exponential Moving Average* (EMA-14). EMA merupakan indikator tren yang memberikan bobot lebih besar pada data terbaru, sehingga lebih responsif terhadap perubahan harga jangka pendek dibandingkan SMA Menurut Nurfalah et al. [7], EMA efektif dalam mendeteksi arah tren jangka pendek pada aset kripto seperti Bitcoin, dengan tingkat akurasi sinyal sebesar 53,33% dalam periode analisis 2017–2023. Hal ini menunjukkan bahwa EMA layak digunakan sebagai indikator teknikal untuk mendukung pengambilan keputusan dalam prediksi harga aset digital. Rumus perhitungan EMA adalah:

$$EMA_t = \alpha \cdot Close_t + (1 - \alpha) \cdot EMA_t^{(-1)} \tag{2}$$

$$\alpha = \frac{2}{n + 1} \tag{3}$$

Indikator berikutnya adalah *Relative Strength Index* (RSI-14), yaitu indikator momentum yang mengukur kekuatan tren berdasarkan perbandingan rata-rata kenaikan dan penurunan dalam periode waktu tertentu. RSI banyak digunakan untuk mengidentifikasi kondisi *overbought* dan *oversold*, serta memiliki nilai prediktif terhadap pembalikan tren jangka pendek. Menurut Agudelo-Aguirre et al. [8], RSI mampu memberikan sinyal beli dan jual yang cukup akurat ketika digunakan dalam strategi berbasis kecerdasan buatan, menjadikannya salah satu indikator teknikal yang efektif untuk pengambilan keputusan investasi. Rumus RSI dirumuskan sebagai:

$$RS = \frac{\text{Average Gain}}{\text{Average Loss}} \quad (4)$$

$$RSI = 100 - \frac{100}{1 + RS} \quad (5)$$

Untuk mengukur volatilitas harga, digunakan indikator *Average True Range* (ATR-14). ATR merupakan rata-rata bergerak dari nilai True Range, yang dihitung berdasarkan rentang antara harga tertinggi, harga terendah, dan harga penutupan sebelumnya. Indikator ini dirancang untuk menangkap besarnya fluktuasi harga harian dan sangat berguna dalam menganalisis aset dengan volatilitas tinggi seperti kripto. Penelitian sebelumnya menggunakan ATR sebagai salah satu indikator volatilitas dalam membantu proses prediksi tren harga menggunakan pendekatan machine learning [9]. Rumus perhitungan ATR adalah:

$$ATR_n = \frac{1}{n} \sum_{i=1}^n TR_i \quad (6)$$

$$TR_i = \max(|High - Low|, |High - Close^{(prev)}|, |Low - Close^{(prev)}|) \quad (7)$$

Selain itu, dihitung pula indikator *Daily Return*, yaitu persentase perubahan harga harian berdasarkan selisih harga penutupan antar periode. Akyildirim et al. [1] menyatakan bahwa return harian merupakan salah satu variabel penting dalam prediksi pasar kripto, karena mampu merepresentasikan pergerakan harga yang terjadi akibat fluktuasi pasar dalam waktu singkat. Oleh karena itu, fitur ini digunakan untuk memperkuat representasi pola harga dalam model prediksi. Rumusnya adalah:

$$Return_t = \frac{(Close_t - Close_{t-1})}{Close_{t-1}} \quad (8)$$

Indikator teknikal terakhir yang digunakan adalah *Bollinger Upper Band*, yaitu batas atas zona volatilitas berdasarkan simpangan baku dari harga penutupan terhadap rata-rata bergerak. Bollinger Bands secara luas digunakan untuk mengukur tekanan volatilitas dan mendeteksi kondisi pasar ekstrem. Menurut Vaidya [10], pelebaran pita *Bollinger* mencerminkan meningkatnya volatilitas pasar, sementara kontraksi pita menunjukkan kondisi pasar yang stabil. *Upper Band* juga dapat digunakan sebagai sinyal *overbought*, yaitu ketika harga menembus batas atas, yang sering kali diikuti oleh koreksi harga atau pembalikan arah pasar. Rumus *Bollinger Upper* adalah:

$$Upper_t = MA_t + k \cdot \sigma_t \quad (9)$$

Seluruh indikator teknikal tersebut disusun ke dalam satu matriks fitur (*feature matrix*) yang digunakan sebagai input bagi model *Random Forest Regression*. Pemilihan indikator dilakukan berdasarkan relevansi masing-masing dalam menangkap dinamika pasar kripto, termasuk aspek tren, momentum, volatilitas, serta perubahan harga harian. Penggabungan berbagai jenis indikator ini bertujuan untuk memberikan representasi komprehensif terhadap perilaku harga Ethereum, sehingga model memiliki landasan yang kuat dalam mempelajari pola historis dan membuat prediksi yang lebih akurat. *Feature matrix* ini menjadi fondasi utama dalam proses pelatihan model pada tahap selanjutnya.

2.3. Preprocessing Data

Pra-pemrosesan data merupakan langkah penting untuk memastikan kualitas dan integritas dataset sebelum digunakan dalam pelatihan model prediksi. Dalam konteks pasar aset digital yang sangat volatil, data seringkali mengandung *missing values* dan nilai ekstrem yang dapat mengganggu performa model. Seperti disampaikan oleh Liu et al. [2], kualitas data masukan memiliki pengaruh langsung terhadap kinerja model prediksi dalam domain keuangan, khususnya pada dataset dengan dinamika tinggi seperti kripto.

Dalam penelitian ini, pra-pemrosesan dilakukan melalui dua tahap utama. Tahap pertama adalah penanganan nilai hilang yang muncul sebagai akibat dari perhitungan indikator teknikal seperti EMA, RSI, dan ATR. Indikator-indikator tersebut memerlukan periode historis untuk menghasilkan nilai yang valid, sehingga baris awal dataset mengandung nilai kosong. Oleh karena itu, baris-baris tersebut dihapus, mengikuti pendekatan yang umum digunakan dalam studi prediksi deret waktu finansial seperti yang diterapkan oleh Akyildirim et al. [1].

Tahap kedua adalah pengurutan data secara kronologis (*ascending order*) berdasarkan kolom tanggal. Ini dilakukan untuk menjaga kontinuitas waktu karena model prediktif berbasis *time series*, seperti Random Forest Regression, sangat bergantung pada urutan data. Data di pasar keuangan sebagian besar diklasifikasikan sebagai data deret waktu yang bersifat dinamis, sangat bising (*highly noisy*), non-linear, dan kompleks [2]. Oleh karena itu, memastikan bahwa model *machine learning* dilatih dan diuji secara sekuensial adalah penting untuk mengukur kemampuan generalisasi model pada data masa depan yang tidak terlihat.

Melalui kedua tahap tersebut, diperoleh dataset yang bersih, bebas dari nilai hilang, dan terstruktur secara temporal, yang kemudian siap digunakan dalam proses pembagian data dan pembangunan model prediksi.

2.4. Pembagian Dataset (90% Train, 10% Test)

Setelah tahap pra-pemrosesan selesai, dataset dibagi menjadi dua bagian menggunakan pendekatan *time-series split*, yaitu metode pembagian data yang mempertahankan urutan kronologis. Pendekatan ini penting dalam data deret waktu seperti harga aset kripto, karena menjaga kontinuitas temporal diperlukan untuk mencegah *data leakage*. Hal ini krusial mengingat data di pasar keuangan sebagian besar diklasifikasikan sebagai data deret waktu yang dinamis, kompleks, dan sangat bising, sehingga model prediksi harus mampu menggeneralisasi dengan baik pada data masa depan yang tidak terlihat [2].

Dalam penelitian ini, digunakan rasio 90:10, dengan 90% data digunakan sebagai data latih (*training set*) dan 10% sebagai data uji (*testing set*). Rasio ini dipilih untuk memberikan model ruang belajar yang luas terhadap tren historis harga, sekaligus menyisakan data terbaru untuk mengevaluasi kemampuan generalisasi model. Pemilihan rasio ini juga sejalan dengan hasil studi oleh Muraina [11], yang menunjukkan bahwa pembagian data dengan rasio 90:10 menghasilkan kinerja model terbaik dalam beberapa algoritma pembelajaran mesin.

2.5. Random Forest Regression

Metode *Random Forest Regression* digunakan sebagai model utama dalam penelitian ini karena kemampuannya dalam menangani hubungan non-linear pada data deret waktu finansial serta kestabilannya terhadap *noise* dan *outlier*. *Random Forest* merupakan algoritma *ensemble learning* berbasis teknik *bagging*, di mana model membangun banyak pohon keputusan (*decision tree*) dan menghasilkan prediksi akhir melalui proses agregasi.

Menurut Salman et al. [12], algoritma ini bekerja dengan membentuk setiap pohon menggunakan sampel acak dari data (*bootstrap sampling*), serta melakukan pemilihan fitur secara acak pada setiap node pemisahan. Proses ini menciptakan keragaman antar pohon yang membantu mengurangi risiko *overfitting*, sekaligus meningkatkan akurasi dan stabilitas model. Prediksi akhir diperoleh dengan menghitung rata-rata dari seluruh

output pohon, menjadikan model ini andal untuk prediksi berbasis deret waktu. proses prediksi akhir dari *Random Forest Regression* dinyatakan dengan:

$$\hat{y} = \frac{1}{n} \sum_{i=1}^n h_i(x) \quad (10)$$

Dalam konteks pasar finansial, Random Forest telah banyak digunakan dalam kerangka kerja data mining untuk menangani kompleksitas data numerik dan menangkap pola-pola tersembunyi dalam variabel teknikal, Saadah dan Salsabila [13] membuktikan bahwa *Random Forest Regression* berhasil memprediksi harga Bitcoin secara akurat dengan nilai MAPE sebesar 1.50% dan akurasi 98.50%, menjadikannya sangat cocok untuk pasar finansial.

Pada penelitian ini, model *Random Forest* dilatih dengan parameter sebagai berikut:

- *n_estimators* = 500
- *max_depth* = 15
- *min_samples_split* = 4
- *max_features* = None
- *dan random_state* = 42

Parameter ini dipilih secara manual untuk mencapai performa optimal berdasarkan uji coba. Model ini menggunakan seluruh fitur teknikal yang telah dibangun, termasuk EMA, RSI, ATR, *Daily Return*, dan *Bollinger Bands*, untuk memprediksi nilai harga penutupan Ethereum pada periode berikutnya. Kombinasi indikator tren, momentum, dan volatilitas diharapkan membantu model dalam menangkap karakteristik pasar kripto secara lebih menyeluruh.

2.6. Evaluation Metrics

Evaluasi model dilakukan menggunakan empat metrik regresi yang umum digunakan dalam penelitian prediksi harga finansial. Metrik ini dipilih untuk memberikan gambaran yang komprehensif mengenai tingkat kesalahan prediksi dan kemampuan model dalam menjelaskan variabilitas data. Empat metrik tersebut adalah *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *R-Squared* (R^2). Penggunaan lebih dari satu metrik evaluasi penting untuk memastikan bahwa kinerja model tidak hanya baik pada satu jenis kesalahan, tetapi konsisten pada berbagai perspektif evaluasi [14].

MAE bersifat linear dan tidak memperbesar kesalahan besar, sehingga memberikan penilaian yang stabil terhadap error. Rumus MAE dituliskan sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (11)$$

Sementara itu, RMSE digunakan untuk mengukur kesalahan berbasis kuadrat, sehingga kesalahan besar memiliki dampak lebih besar pada hasil evaluasi. RMSE sering digunakan dalam model prediksi harga karena sensitif terhadap *outlier*:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

MAPE mengukur kesalahan dalam bentuk persentase, sehingga memberikan interpretasi yang lebih mudah dipahami dalam konteks prediksi harga. Nilai MAPE yang semakin kecil menunjukkan bahwa model semakin akurat secara proporsional terhadap nilai aktual:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (13)$$

Terakhir, *R-Squared* (R^2) digunakan untuk mengukur seberapa besar variansi data yang dapat dijelaskan oleh model. Nilai R^2 mendekati 1 menandakan model mampu menjelaskan variabilitas data dengan baik, sementara nilai mendekati 0 menunjukkan kemampuan model yang rendah dalam menangkap pola data:

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (14)$$

Melalui penggunaan keempat metrik tersebut, penelitian ini dapat menilai performa model *Random Forest Regression* dari berbagai sudut pandang, sehingga hasil evaluasi bersifat lebih menyeluruh dan akurat.

2.7. Visualization

Tahap visualisasi dilakukan untuk memberikan gambaran lebih jelas mengenai performa model dalam memprediksi harga penutupan harian Ethereum terhadap Rupiah. Visualisasi diperlukan karena hasil evaluasi numerik seperti MAE, RMSE, MAPE, dan R^2 belum sepenuhnya menggambarkan bagaimana model mengikuti pola harga aktual. Melalui visualisasi, peneliti dapat melihat kesesuaian tren antara nilai aktual dan nilai prediksi secara langsung, sehingga mempermudah identifikasi adanya deviasi signifikan atau lonjakan harga.

Visualisasi utama yang digunakan adalah grafik perbandingan antara harga aktual dan harga prediksi. Grafik ini menunjukkan sejauh mana model mampu mengikuti arah tren harga. Selain itu, ditampilkan pula grafik feature importance, untuk mengetahui kontribusi masing-masing fitur dalam proses prediksi. Visualisasi juga berperan penting dalam mendukung pengambilan keputusan, karena mampu menyajikan informasi secara intuitif dan interaktif, sehingga meningkatkan kepercayaan dan keputusan yang terinformasi [15]

3. Hasil dan Pembahasan

Pada bab ini disajikan hasil pengolahan data dan analisis performa model *Random Forest Regression* dalam memprediksi harga penutupan harian Ethereum terhadap Rupiah (ETH/IDR). Analisis dilakukan berdasarkan metrik evaluasi, visualisasi prediksi, serta kontribusi masing-masing fitur teknikal terhadap model. Seluruh hasil yang ditampilkan merupakan keluaran dari proses pelatihan dan pengujian yang telah dijelaskan pada bab sebelumnya, dengan menggunakan pembagian dataset 90% sebagai data latih dan 10% sebagai data uji. Pembahasan dalam bab ini berfokus pada interpretasi hasil yang diperoleh, termasuk tingkat akurasi model, kesesuaian pola antara harga aktual dan harga prediksi, serta faktor-faktor yang mempengaruhi kinerja model. Analisis ini bertujuan untuk memberikan pemahaman yang lebih mendalam mengenai kemampuan model dalam menangkap pola pergerakan harga aset kripto yang bersifat dinamis dan volatil.

Selain itu, hasil penelitian juga dibandingkan dengan temuan studi terdahulu untuk memberikan konteks dan memperkuat validitas interpretasi.

3.1 Hasil Evaluasi Model

Evaluasi performa model dilakukan untuk mengukur kemampuan *Random Forest Regression* dalam memprediksi harga penutupan harian Ethereum terhadap Rupiah. Model diuji menggunakan testing set sebesar 10% dari total dataset dengan pendekatan *time-series split*. Hasil evaluasi ditampilkan pada Tabel 2.

Tabel 2. Hasil Evaluasi


Metrik	Nilai
MAE Return%	2,7986%
RMSE return%	3,6829%
Rsquare Return%	0,0670
MAE Harga	Rp. 1,953,273
RMSE Harga	Rp. 2,554,591
Mape harga	2,88%

Berdasarkan tabel tersebut, nilai MAPE sebesar 2.88% menunjukkan bahwa model memiliki tingkat kesalahan relatif yang rendah. Dalam konteks prediksi harga aset digital, nilai MAPE di bawah 5% dianggap cukup baik karena volatilitas harga kripto yang tinggi.

Meskipun nilai *R-Squared* relatif kecil, kondisi ini merupakan karakteristik umum pada prediksi jangka pendek aset kripto yang bersifat non-linear dan sangat fluktuatif, sehingga variansi data sulit dijelaskan secara menyeluruh oleh model regresi. Dengan demikian, nilai R^2 yang rendah tidak dapat secara langsung diinterpretasikan sebagai kegagalan model, selama metrik kesalahan seperti MAPE dan MAE menunjukkan akurasi yang baik.

3.2 Analisis Grafik Prediksi dan Harga Aktual

Hasil prediksi model dibandingkan dengan harga aktual ditampilkan pada Gambar 2. Grafik tersebut menunjukkan bahwa model mampu mengikuti pola pergerakan harga secara umum, terutama pada fase kenaikan dan penurunan tren yang terjadi pada awal dan pertengahan periode pengujian. Pergerakan garis prediksi yang berada dekat dengan garis aktual mengindikasikan bahwa model berhasil menangkap arah tren (*trend direction*) dengan baik.



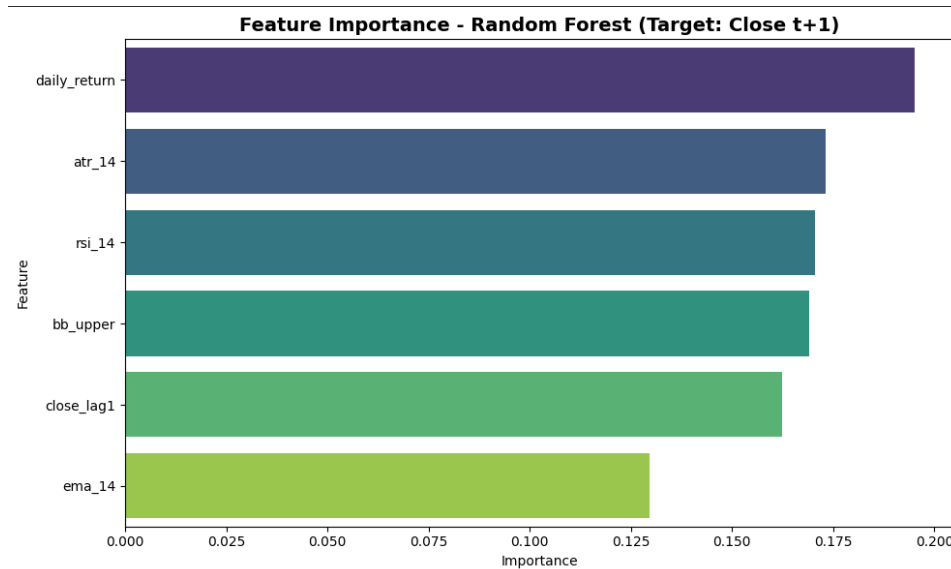
Gambar 2. Harga Aktual vs Prediksi

Pada beberapa titik tertentu, terutama ketika terjadi perubahan harga yang tajam, terdapat deviasi yang lebih besar antara nilai aktual dan nilai prediksi. Hal ini wajar terjadi pada aset kripto karena volatilitas yang tinggi menyebabkan fluktuasi harga yang sulit diprediksi secara akurat oleh model berbasis *machine learning*

Kendati demikian, secara keseluruhan, model tetap konsisten dalam merepresentasikan dinamika harga harian.

3.2 Analisis *Feature Importance*

Analisis *feature importance* dilakukan untuk mengidentifikasi kontribusi setiap fitur teknikal terhadap prediksi model. Hasilnya ditampilkan pada Gambar 3 dan Tabel 3.



Gambar 3. Grafik *Feature Importance*

Tabel 3. Tabel *Feature Importance*

Feature	Importance
Dialy Return%	0,195196
ATR-14	0,173190
RSI-14	0,170440
BB-Upper	0,169057
Close Lag1	0,162449
EMA-14	0,129668

Fitur daily return menjadi indikator paling berpengaruh, menunjukkan bahwa perubahan harga harian memiliki relevansi besar terhadap prediksi harga hari berikutnya. Indikator volatilitas seperti ATR-14, serta indikator momentum seperti RSI-14, juga memberikan kontribusi signifikan. Sementara itu, fitur close_lag1 menunjukkan pentingnya ketergantungan temporal dalam data harga, sedangkan EMA-14 tercatat memiliki kontribusi paling kecil. Hal ini menunjukkan bahwa tren jangka menengah kurang relevan untuk prediksi harga harian.

4. Kesimpulan

Penelitian ini bertujuan untuk memprediksi harga penutupan harian Ethereum terhadap Rupiah (ETH/IDR) menggunakan algoritma *Random Forest Regression* berbasis indikator teknikal. Berdasarkan hasil pengujian, model berhasil mencapai tingkat kesalahan relatif yang rendah dengan nilai MAPE sebesar 2.88%, yang menunjukkan bahwa hasil prediksi cukup dekat dengan nilai aktual. Meskipun nilai R-Squared pada data uji relatif kecil, hal ini merupakan karakteristik umum pada prediksi jangka pendek aset kripto yang memiliki volatilitas tinggi dan pola harga non-linear.

Hasil visualisasi menunjukkan bahwa model mampu mengikuti pola umum pergerakan harga, terutama pada fase kenaikan dan penurunan tren. Beberapa deviasi yang terjadi pada periode perubahan harga ekstrem merupakan sesuatu yang wajar, mengingat harga aset kripto sangat dipengaruhi oleh dinamika pasar dan sentimen yang sulit diprediksi secara stabil. Analisis *feature importance* juga menunjukkan bahwa indikator teknikal seperti daily return, ATR-14, dan RSI-14 memiliki kontribusi paling besar dalam mempengaruhi prediksi model, sementara EMA-14 memiliki peran yang lebih kecil.

Hal ini menandakan bahwa volatilitas dan momentum pasar memiliki pengaruh dominan terhadap perubahan harga jangka pendek. Secara keseluruhan, penelitian ini menunjukkan bahwa *Random Forest Regression* merupakan metode yang cukup efektif untuk memprediksi harga harian ETH/IDR menggunakan fitur-fitur teknikal. Hasil penelitian ini juga sejalan dengan temuan studi terdahulu yang mengonfirmasi efektivitas model ensemble dalam menangani data finansial yang dinamis dan non-linear. Dengan akurasi yang diperoleh, model ini dapat menjadi acuan awal untuk pengembangan sistem prediksi aset kripto berbasis pembelajaran mesin, terutama pada konteks peramalan jangka pendek.

Daftar Pustaka

- [1] E. Akyildirim, A. Goncu, and A. Sensoy, "Prediction of cryptocurrency returns using machine learning," *Ann Oper Res*, vol. 297, no. 1–2, pp. 3–36, Feb. 2021, doi: 10.1007/s10479-020-03575-y.
- [2] H. Liu, S. Huang, P. Wang, and Z. Li, "A review of data mining methods in financial markets," *Data Science in Finance and Economics*, vol. 1, no. 4, pp. 362–392, 2021, doi: 10.3934/DSFE.2021020.
- [3] F. M. P. Fozap, "Hybrid Machine Learning Models for Long-Term Stock Market Forecasting: Integrating Technical Indicators," *Journal of Risk and Financial Management*, vol. 18, no. 4, Apr. 2025, doi: 10.3390/jrfm18040201.
- [4] A. Gatera, M. Kuradusenge, G. Bajpai, C. Mikeka, and S. Shrivastava, "Comparison of random forest and support vector machine regression models for forecasting road accidents," *Sci Afr*, vol. 21, Sep. 2023, doi: 10.1016/j.sciaf.2023.e01739.
- [5] R. Fegiyanto, A. Hermawan, and F. Ardiani, "Prediksi Harga Crypto dengan Algoritma Jaringan Saraf Tiruan," 2024. [Online]. Available: <https://journal.stmiki.ac.id>
- [6] A. Rastogi, A. Qais, A. Saxena, and D. Sinha, "Stock Market Prediction with Lasso Regression using Technical Analysis and Time Lag," in *2021 6th International Conference for Convergence in Technology, I2CT 2021*, Institute of Electrical and Electronics Engineers Inc., Apr. 2021. doi: 10.1109/I2CT51068.2021.9417935.
- [7] Rizwan Nurfalaha, Habi Baturohmah, and Rieska Rahayu Ayuningsih, "ANALISIS TINGKAT AKURASI SIGNAL INDIKATOR EXPONENTIAL MOVING AVERAGE PADA BITCOIN (PERIODE 2017 – 2023)," *Jurnal Informatika Teknologi dan Sains (Jinteks)*, vol. 5, no. 3, pp. 446–453, Aug. 2023, doi: 10.51401/jinteks.v5i3.2969.



- [8] A. Agudelo-Aguirre, N. Duque-Méndez, and A. Galvis-Flórez, “Artificial Intelligence in Stock Market Investment Through the RSI Indicator,” *Computers*, vol. 14, no. 11, p. 487, Nov. 2025, doi: 10.3390/computers14110487.
- [9] Y. Lin, S. Liu, H. Yang, and H. Wu, “Stock Trend Prediction Using Candlestick Charting and Ensemble Machine Learning Techniques with a Novelty Feature Engineering Scheme,” *IEEE Access*, vol. 9, pp. 101433–101446, 2021, doi: 10.1109/ACCESS.2021.3096825.
- [10] R. Vaidya, “Nepse in bollinger bands,” 2021, *American Institute of Mathematical Sciences*. doi: 10.3934/NAR.2021023.
- [11] I. O. Muraina, “IDEAL DATASET SPLITTING RATIOS IN MACHINE LEARNING ALGORITHMS: GENERAL CONCERNS FOR DATA SCIENTISTS AND DATA ANALYSTS,” *7th INTERNATIONAL MARDIN ARTUKLU SCIENTIFIC RESEARCHES CONFERENCE*, Feb. 2022, Accessed: Dec. 02, 2025. [Online]. Available: www.artuklukongresi.org
- [12] H. A. Salman, A. Kalakech, and A. Steiti, “Random Forest Algorithm Overview,” *Babylonian Journal of Machine Learning*, vol. 2024, pp. 69–79, Jun. 2024, doi: 10.58496/bjml/2024/007.
- [13] S. Saadah and H. Salsabila, “Jurnal Politeknik Caltex Riau Prediksi Harga Bitcoin Menggunakan Metode Random Forest (Studi Kasus: Data Acak Pada Awal Masa Pandemic Covid-19),” 2021. [Online]. Available: <https://jurnal.pcr.ac.id/index.php/jkt/>
- [14] D. Chicco, M. J. Warrens, and G. Jurman, “The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation,” *PeerJ Comput Sci*, vol. 7, pp. 1–24, 2021, doi: 10.7717/PEERJ-CS.623.
- [15] E. Oral, R. Chawla, M. Wijkstra, N. Mahyar, and E. Dimara, “From Information to Choice: A Critical Inquiry Into Visualization Tools for Decision Making,” *IEEE Trans Vis Comput Graph*, pp. 1–11, Aug. 2023, doi: 10.1109/TVCG.2023.3326593.