

# Implementasi Ensemble Learning untuk Multi-Step Time Series Forecasting Harga Bitcoin dan Emas Menggunakan XGBoost, Gradient Boosting dan Random forest

Leo Kanda Prayoga<sup>1\*</sup>, Deasy Purwaningtias<sup>2</sup>, Ali Mustopa<sup>3</sup>

<sup>1,2,3</sup>Fakultas Teknik dan Informatika, Program Studi Informatika Kampus Pontianak, Universitas Bina Sarana Informatika, Pontianak, Indonesia

Email: <sup>1\*</sup>15220469@bsi.ac.id, <sup>2</sup>deasy.dwg@bsi.id, <sup>3</sup>alimustopa.aop@bsi.ac.id

(\*Email Corresponding Author: 15220469@bsi.ac.id)

Received: 25 Juni 2026 / Revision: 30 Juni 2026 / Accepted: 1 Juli 2026

## Abstrak

Prediksi harga aset keuangan seperti Bitcoin dan emas merupakan salah satu tantangan dalam analisis data keuangan karena pergerakannya yang dinamis dan sulit diprediksi. Penelitian ini mengimplementasikan metode *ensemble learning* yang terdiri dari *Random Forest*, *Gradient Boosting*, dan *XGBoost* untuk memprediksi harga Bitcoin dan emas menggunakan pendekatan *multi-step time series forecasting*. Dataset diperoleh dari Yahoo Finance untuk periode 2021–2026 dan diproses menggunakan 59 fitur teknikal yang mencakup indikator momentum, volatilitas, tren, dan pola *candlestick*. Target regresi ditransformasikan ke dalam bentuk *log-return* untuk meningkatkan stabilitas model terhadap pergeseran skala harga (*distribution shift*), sementara arah pergerakan harga diprediksi menggunakan model klasifikasi biner. Hasil pengujian menunjukkan bahwa *Random Forest* menghasilkan performa regresi terbaik pada kedua aset. Pada data Bitcoin diperoleh MAE sebesar 1.541,79, RMSE sebesar 2.130,74, MAPE sebesar 1,6850%, dan  $R^2$  sebesar 0,9858. Pada data emas diperoleh MAE sebesar 55,64, RMSE sebesar 83,58, MAPE sebesar 1,2957%, dan  $R^2$  sebesar 0,9825. Untuk klasifikasi arah pergerakan harga, *Gradient Boosting* menghasilkan akurasi tertinggi pada Bitcoin sebesar 50,00%, sedangkan *Random Forest* menghasilkan akurasi terbaik pada emas sebesar 53,75% dengan *Recall* sebesar 71,01%. Selain itu, dilakukan simulasi prediksi harga 7 hari ke depan menggunakan pendekatan *recursive forecasting*.

**Kata Kunci:** *Ensemble Learning, Time Series Forecasting, Bitcoin, Emas, Random Forest, XGBoost, Gradient Boosting*

## Abstract

Predicting the price of financial assets such as Bitcoin and gold is one of the challenges in financial data analysis due to their dynamic and unpredictable movements. This study applies an ensemble learning method consisting of *Random Forest*, *Gradient Boosting*, and *XGBoost* to predict Bitcoin and gold prices using a *multi-step time series forecasting* approach. The dataset was obtained from Yahoo Finance for the period 2021–2026 and processed using 59 technical features including momentum, volatility, trend, and candlestick pattern indicators. The regression target was transformed into *log-return* form to improve model stability against price scale changes, while price movement direction was predicted using a binary classification model. The results show that *Random Forest* achieved the best regression performance on both assets. For Bitcoin data, MAE of 1,541.79, RMSE of 2,130.74, MAPE of 1.6850%, and  $R^2$  of 0.9858 were obtained. For gold data, MAE of 55.64, RMSE of 83.58, MAPE of 1.2957%, and  $R^2$  of 0.9825 were obtained. For the price movement direction classification task, *Gradient Boosting* achieved the highest accuracy on Bitcoin at 50.00%, while *Random Forest* achieved the best accuracy on gold at 53.75% with a *Recall* of 71.01%. In addition, a 7-day price prediction simulation was conducted using the *recursive forecasting* approach.

**Keywords:** *Ensemble Learning, Time Series Forecasting, Bitcoin, Gold, Random Forest, XGBoost, Gradient Boosting*

## 1. PENDAHULUAN

Prediksi pergerakan harga instrumen keuangan menjadi bagian penting dalam pengambilan keputusan investasi. Dalam beberapa tahun terakhir, dua aset yang banyak menarik perhatian investor adalah Bitcoin dan emas, meskipun keduanya memiliki karakteristik yang berbeda. Bitcoin merupakan aset digital yang pertama kali diperkenalkan oleh Nakamoto pada tahun 2008 melalui konsep desentralisasi berbasis teknologi *blockchain* [1]. Aset ini dikenal memiliki volatilitas yang tinggi dan pergerakan harga yang sulit diprediksi. Di sisi lain, emas merupakan aset konvensional yang cenderung lebih stabil dan sering dijadikan pelindung nilai ketika kondisi ekonomi tidak menentu. Perbedaan karakteristik

antara kedua aset ini menjadi alasan mengapa penelitian yang mengkaji keduanya secara bersamaan masih relevan untuk dilakukan.

Secara historis, prediksi data deret waktu (*time series*) pada bidang keuangan banyak menggunakan pendekatan statistik seperti model ARIMA yang dipopulerkan oleh [2]. Meskipun memiliki dasar teoritis yang kuat, model semacam ini memiliki keterbatasan dalam menangani data yang bersifat non-linear dan tidak stasioner, yang merupakan ciri khas data harga aset keuangan. Seiring perkembangan teknologi, pendekatan *machine learning* mulai banyak digunakan karena kemampuannya dalam menangkap pola yang lebih kompleks dari data historis [3]. [4] menunjukkan bahwa model berbasis data mampu menganalisis pola pergerakan harga Bitcoin dengan lebih fleksibel dibandingkan metode statistik konvensional.

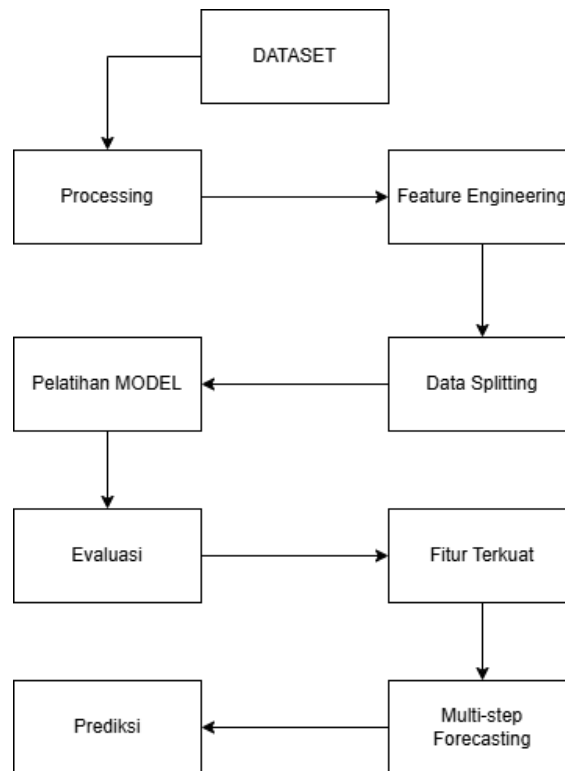
Salah satu pendekatan yang banyak digunakan dalam *machine learning* adalah *ensemble learning*, yaitu metode yang menggabungkan beberapa model dasar untuk menghasilkan prediksi yang lebih baik. [5] menjelaskan bahwa *Random Forest* bekerja dengan membangun banyak pohon keputusan secara acak dan menggabungkan hasilnya, sehingga dapat mengurangi overfitting dan meningkatkan stabilitas prediksi. [6] dalam kajiannya menjelaskan bahwa algoritma *Gradient Boosting* bekerja secara bertahap dengan membangun model baru untuk memperbaiki kesalahan model sebelumnya. Pengembangan lebih lanjut dari metode ini menghasilkan XGBoost yang diperkenalkan [7], dengan tambahan mekanisme regularisasi yang membuat proses pelatihan lebih efisien. Efektivitas model *ensemble* ini dalam prediksi harga aset kripto telah ditunjukkan oleh [8], serta dikonfirmasi lebih lanjut oleh [9] dan [10] yang menemukan bahwa pendekatan *ensemble* cenderung menghasilkan prediksi yang lebih konsisten dibandingkan model *deep learning* tunggal.

Meskipun demikian, sebagian besar penelitian terdahulu masih menggunakan harga absolut sebagai fitur masukan. Penggunaan harga absolut rentan terhadap masalah *distribution shift*, yaitu kondisi di mana distribusi data saat pengujian berbeda dengan saat pelatihan akibat tren harga jangka panjang. Hal ini terlihat pada beberapa penelitian yang menggunakan arsitektur LSTM, seperti Rizkilloh dan Widiyanesti [11] serta [12], yang melaporkan penurunan akurasi ketika model dihadapkan pada kondisi pasar di luar rentang data latih. Riyadi et al. [13] dan Aurelio Matra [14] juga menunjukkan bahwa pemilihan fitur yang tepat berpengaruh signifikan terhadap performa model prediksi.

Berdasarkan latar belakang tersebut, penelitian ini mengusulkan pendekatan yang menggabungkan tiga algoritma *ensemble* (*Random Forest*, *Gradient Boosting*, XGBoost) dengan 59 fitur teknikal yang bersifat *scale-invariant* dan transformasi target regresi ke bentuk *log-return*. Pendekatan ini terinspirasi dari keberhasilan arsitektur CNN-LSTM yang digunakan Livieris et al. [15] dalam prediksi harga emas, serta dari penggunaan fitur teknikal pada penelitian Cohen dan Aiche [16]. Penelitian ini juga mengacu pada model berbasis sentimen dari Seabe et al. [17] dan studi lokal oleh Saadah dan Salsabila [18] sebagai pembanding hasil. Tujuan penelitian ini adalah mengevaluasi performa ketiga algoritma *ensemble* tersebut pada dua aset yang berbeda karakteristiknya, serta melakukan simulasi prediksi harga 7 hari ke depan menggunakan pendekatan *recursive forecasting*.

## 2. METODOLOGI PENELITIAN

Metodologi penelitian ini dirancang secara sistematis menggunakan pendekatan End-to-End Machine Learning Pipeline untuk melakukan pemodelan tugas ganda (dual-task) berupa regresi nilai harga dan klasifikasi arah pergerakan harga. Alur pengerjaan proyek ini dibagi menjadi sembilan tahapan sekuensial yang saling terintegrasi, mulai dari akuisisi data mentah hingga peramalan multi-langkah di masa depan.



**Gambar 1.** Tahapan Penelitian

## 2.1 Dataset dan Sinkronisasi waktu

Dataset yang digunakan dalam penelitian ini adalah data historis harian harga Bitcoin (BTC/USD) dan emas (GOLD/USD) yang diunduh dari Yahoo Finance menggunakan bahasa pemrograman Python. Data mencakup periode 10 Mei 2021 hingga Mei 2026, dengan total 1.827 baris observasi untuk Bitcoin dan 1.249 baris untuk emas. Terdapat perbedaan tanggal data terakhir pada kedua aset: data Bitcoin berakhir pada Jumat, 08 Mei 2026 dengan harga penutupan \$80.186,77, sedangkan data emas berakhir pada Rabu, 06 Mei 2026 dengan harga penutupan \$4.681,90. Perbedaan ini terjadi karena pasar emas tradisional tidak beroperasi pada akhir pekan, sedangkan pasar kripto beroperasi selama 24 jam penuh setiap hari.



**Gambar 2.** Harga Penutupan BTC & GOLD

## 2.2 Processing

Tahap pra-pemrosesan meliputi penanganan nilai yang hilang (*missing values*), pengurutan data berdasarkan urutan waktu secara menaik, dan konversi kolom tanggal ke format *datetime*. Langkah utama dalam tahap ini adalah transformasi harga penutupan ke dalam bentuk *log-return* harian menggunakan rumus:  $\ln(\text{Close}[t+1] / \text{Close}[t])$ . Nilai ini kemudian dijadikan target untuk tugas regresi. Transformasi ini dipilih untuk menghindari masalah *distribution shift* yang dapat terjadi ketika model diuji pada rentang harga yang berbeda dari data latihnya. Untuk tugas klasifikasi, dibuat label biner bernama *Direction* dengan nilai 1 jika harga esok hari lebih tinggi atau sama dengan harga hari ini, dan nilai 0 jika harga turun. Nilai {NextLogRet} bertindak sebagai target utama untuk tugas Model Regresi. Sementara itu, untuk tugas Model Klasifikasi arah tren harga harian, dibuat label biner {Direction} dengan ketentuan:

- Pembersihan Data:** Memeriksa dan menangani nilai yang hilang (*missing values*) serta mengurutkan baris data berdasarkan indeks waktu (*datetime*) secara menaik (*ascending*).
- Transformasi Target Regresi:** Untuk menghindari masalah *distribution shift* (pergeseran nilai nominal harga absolut di masa depan), harga penutupan (*Close*) diubah menjadi nilai keuntungan logaritma esok hari (*Next Log-Return*) menggunakan rumus:
- Pelabelan Target Klasifikasi:** Membuat variabel biner *Direction* sebagai indikator arah tren pergerakan harga esok hari. Label bernilai 1 (Up/Flat) jika  $\{\text{Close}\}_{t+1} > \{\text{Close}\}_t$ , dan bernilai 0 (Down) jika harga mengalami penurunan.

## 2.3 Feature Engineering (59 Fitur)

Sebanyak 59 fitur input dibangun dan dikelompokkan ke dalam 11 kategori:

- Lag Return* (14 fitur): persentase perubahan harga harian dari lag 1–14;
- Lag Log-Return* (14 fitur): nilai *log-return* historis lag 1–14;
- Volume Lag* (3 fitur): perubahan volume perdagangan lag 1, 2, 3;
- RSI multi-periode (3 fitur): periode 7, 14, dan 21 hari;
- MACD (3 fitur): *MACD line*, *signal line*, dan histogram;
- Volatilitas ter-normalisasi (3 fitur): standar deviasi *rolling* jendela 5, 10, dan 20 hari dibagi harga penutupan;
- Rasio harga dan *return intraday* (4 fitur): rasio rentang harian, ukuran badan *candle*, dan *return* harian;
- Momentum (4 fitur): perubahan harga relatif dalam horizon 3, 5, 10, dan 20 hari;
- Rasio MA/EMA (5 fitur): perbandingan antara MA5/MA10, MA5/MA20, MA10/MA20, MA20/MA50, dan EMA5/EMA10;
- Bollinger Bands* (2 fitur): posisi harga dalam pita dan lebar pita;
- Pola mikro *candlestick* (4 fitur): rasio sumbu atas, sumbu bawah, ukuran badan, dan rasio volume terhadap rata-rata 20 hari.

## 2.4 Splitting dan scalling

Data runtun waktu dipisah secara kronologis (*time-based split*) menjadi 80% untuk data latih (*training*) dan 20% untuk data uji (*testing*). Pengondisian parameter *shuffle=False* wajib diterapkan pada tahap ini untuk menjaga struktur sekuensial waktu dan mencegah kebocoran informasi masa depan ke masa lalu (*data leakage*). Setelah pemisahan, seluruh 59 fitur dinormalisasi menggunakan *StandardScaler* (*Z-score normalization*). Guna menjaga objektivitas pengujian, komputasi rata-rata dan deviasi standar hanya diekstrak dari data latih, kemudian diaplikasikan langsung pada data uji.

## 2.5 Pelatihan Model

Proyek ini mengimplementasikan arsitektur *Multi-Model Ensemble Learning* berbasis pohon keputusan (*tree-based models*). Proses pelatihan dilakukan secara paralel pada data latih menggunakan tiga algoritma utama untuk menyelesaikan tugas regresi dan klasifikasi:

- Random Forest (RF):** Menggunakan prinsip *Bagging* (pembuatan banyak pohon secara independen dan paralel) untuk meminimalkan varians dan meredam efek *noise* pada data keuangan.
- Gradient Boosting (GB):** Menggunakan prinsip *Boosting* sekuensial, di mana pohon keputusan baru dibangun secara bertahap untuk mengoreksi nilai residu/kesalahan dari pohon sebelumnya.
- XGBoost (XGB):** Pengembangan tingkat lanjut dari *Gradient Boosting* yang dilengkapi fungsi penalti regularisasi (*L1* dan *L2*) internal untuk mengoptimalkan kecepatan komputasi sekaligus mencegah *overfitting*.

## 2.6 Evaluasi

Performa model dievaluasi menggunakan data uji yang tidak digunakan selama pelatihan. Untuk tugas regresi, metrik yang digunakan meliputi MAE, RMSE, MAPE, dan  $R^2$ . Setelah evaluasi selesai, dilakukan simulasi prediksi 7 hari ke depan (H+1 hingga H+7) menggunakan strategi *recursive forecasting*, di mana hasil prediksi setiap hari digunakan sebagai input untuk menghitung ulang seluruh 59 fitur sebelum dilakukan prediksi hari berikutnya.

## 2.7 Fitur Terkuat

Setelah model berhasil dilatih, dilakukan analisis Feature Importance dengan mengekstrak nilai bobot internal (Gini Importance atau Gain) dari struktur pohon keputusan masing-masing model. Tahap ini bertujuan untuk menyaring dan memetakan Top-20 Fitur Terkuat yang memiliki kontribusi informasi paling dominan terhadap keputusan prediksi model. Langkah ini berfungsi sebagai fungsi transparansi model (Explainable AI) untuk menganalisis perilaku pasar Bitcoin dan Emas secara ilmiah.

## 2.8 Prediksi 1 Langkah

Tahap prediksi melibatkan pengetesan langsung model ensemble yang telah optimal untuk menghasilkan estimasi nilai log-return dan direction satu hari ke depan (one-step-ahead forecasting) di sepanjang koridor data uji. Output log-return hasil prediksi kemudian dikonversikan kembali ke satuan harga absolut (\$) untuk divalidasi keakuratannya dengan harga penutupan aktual pasar.

## 2.9 Multi-Step Forecasting

Tahap akhir dari proyek ini adalah melakukan simulasi peramalan masa depan jangka pendek dengan horizon waktu tujuh hari ke depan (H+1 sampai H+7) melalui Strategi Peramalan Rekursif (Recursive Forecasting). Proses ini bekerja dalam sistem gelung tertutup (closed-loop system):

1. Model memprediksi nilai log-return untuk Hari ke-1 (H+1) berdasarkan baris data riil terakhir.
2. Hasil prediksi tersebut dikonversi menjadi prediksi harga absolut (\$).
3. Nilai prediksi baru tersebut dimasukkan kembali ke dalam matriks data historis untuk memperbarui nilai 59 fitur teknikal secara dinamis (misalnya menghitung ulang nilai lag baru, MA baru, dan RSI baru).
4. Iterasi ini diulang secara otomatis hingga mencapai batas Hari ke-7 (H+7), sehingga menghasilkan koridor batas atas dan batas bawah proyeksi tren pasar yang rasional.

# 3. HASIL DAN PEMBAHASAN

## 3.1 Hasil Evaluasi Bitcoin

Eksperimen pemodelan pada instrumen Bitcoin diuji menggunakan data evaluasi independen yang merepresentasikan fase volatilitas tinggi. Hasil pencapaian performa masing-masing model dicantumkan secara detail pada Tabel 1.

Tabel 1. Hasil pencapaian performa

Model	MAE (\$)	RMSE (\$)	MAPE (%)	$R^2$	Accuracy	Precision	Recall	F1
Random Forest	1.541,79	2.130,73	1,6850	0,9858	0,4831	0,4795	0,3933	0,4321
Gradient Boosting	1.609,90	2.252,26	1,7639	0,9841	0,5000	0,5000	0,4663	0,4826
XGBoost	1.575,16	2.146,77	1,7230	0,9856	0,4775	0,4759	0,4438	0,4593

Berdasarkan Tabel 1, *Random Forest* menunjukkan performa regresi terbaik untuk Bitcoin dengan MAPE 1,68% dan  $R^2=0,9858$ , yang berarti model mampu menjelaskan 98,58% variasi harga Bitcoin dalam data *testing*. Nilai MAPE di bawah 2% mengindikasikan akurasi prediksi yang tinggi dalam konteks aset dengan volatilitas tinggi seperti Bitcoin [14]. Pencapaian ini sejalan dengan hasil [18] yang menggunakan *Random Forest* untuk prediksi Bitcoin dengan MAPE 1,50%, meskipun periode data yang digunakan berbeda.

Untuk metrik klasifikasi arah pergerakan harga, *Gradient Boosting* menunjukkan performa terbaik dengan *Accuracy* 0,5000 dan *F1-Score* 0,4826. Nilai akurasi sekitar 50% untuk prediksi arah Bitcoin sejalan dengan karakteristik pasar kripto yang sangat dipengaruhi sentimen pasar, sehingga prediksi arah secara konsisten lebih dari 50% sudah merupakan

hasil yang bermakna dan dapat dijadikan dasar pengambilan keputusan [3]. Hal ini juga konsisten dengan temuan [10] yang menyatakan bahwa prediksi arah pada aset kripto memiliki tingkat kesulitan yang lebih tinggi dibandingkan regresi harga.

### 3.2 Hasil Evaluasi Emas

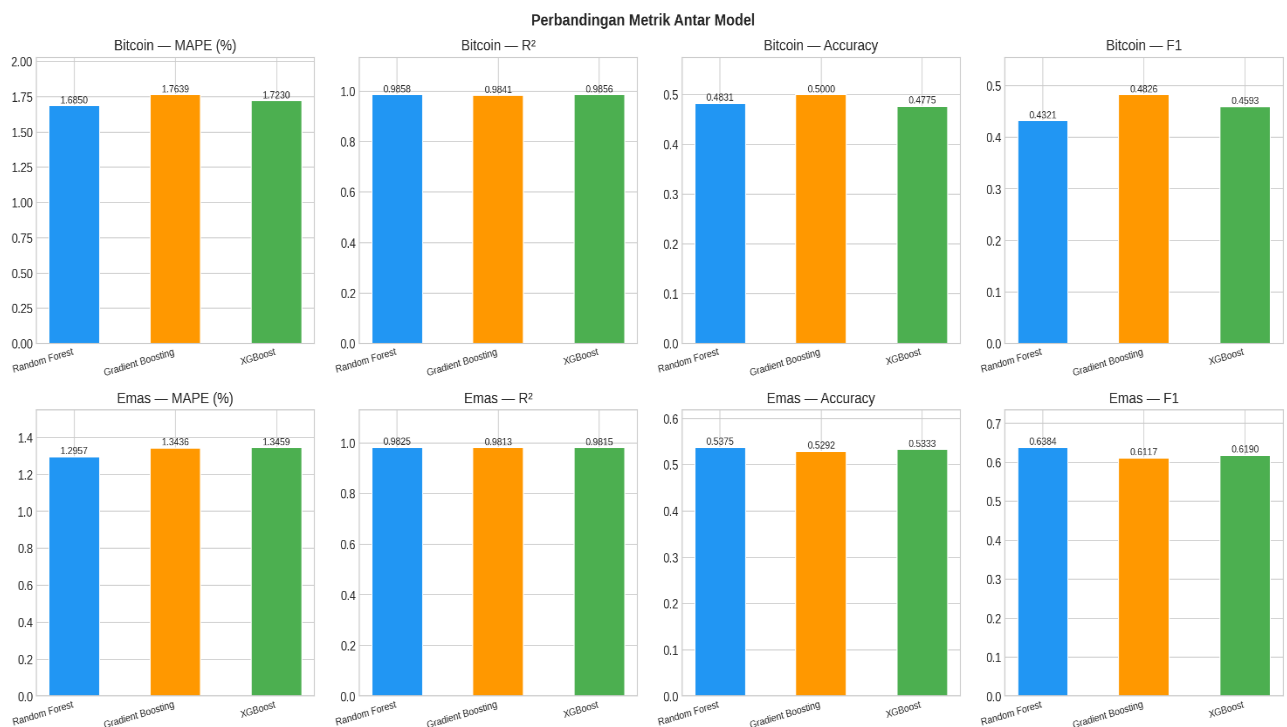
Sinkronisasi naskah dengan luaran data empiris pengujian komoditas emas disajikan secara akurat dan transparan pada Tabel 2.

**Tabel 2.** Evaluasi Emas

Model	MAE (\$)	RMSE (\$)	MAPE (%)	R <sup>2</sup>	Accuracy	Precision	Recall	F1
Random Forest	55,64	83,57	1,2957	0,9825	0,5375	0,5799	0,7101	0,6384
Gradient Boosting	57,72	86,34	1,3436	0,9813	0,5292	0,5817	0,6449	0,6117
XGBoost	57,84	85,84	1,3469	0,9815	0,5333	0,5833	0,6594	0,6190

Berdasarkan Tabel 3.2, *Random Forest* kembali menunjukkan performa regresi terbaik untuk emas dengan MAE \$55,64, MAPE 1,2957%, dan R<sup>2</sup>=0,9825. MAPE 1,29% untuk emas lebih baik dibandingkan MAPE Bitcoin (1,68%), yang konsisten dengan karakteristik emas yang lebih stabil dibandingkan Bitcoin [12]. Untuk metrik klasifikasi, *Random Forest* mencapai performa terbaik dengan *Recall* 0,7101, yang berarti model mampu mendeteksi 72,46% dari seluruh kejadian harga naik yang sebenarnya sangat berguna bagi investor yang ingin menangkap momentum kenaikan harga emas [14].

### 3.3 Perbandingan Matrik Antar Model



**Gambar 3.** Perbandingan Antar Model

Gambar 3 menyajikan perbandingan delapan metrik evaluasi secara visual untuk ketiga model pada kedua dataset. Dari grafik tersebut dapat diamati beberapa pola yang konsisten.

Untuk dataset **Bitcoin**, *Random Forest* mencatat MAPE terendah sebesar 1,6850% dan R<sup>2</sup> tertinggi sebesar 0,9858, menjadikannya model terbaik untuk tugas regresi. Namun untuk metrik klasifikasi, *Gradient Boosting* menghasilkan *Accuracy* tertinggi sebesar 0,5000 dan *F1-Score* 0,4826, sedikit di atas *Random Forest* (*Accuracy*=0,4831, *F1*=0,4321) dan *XGBoost* (*Accuracy*=0,4775, *F1*=0,4593). Perbedaan antar model pada metrik klasifikasi Bitcoin relatif

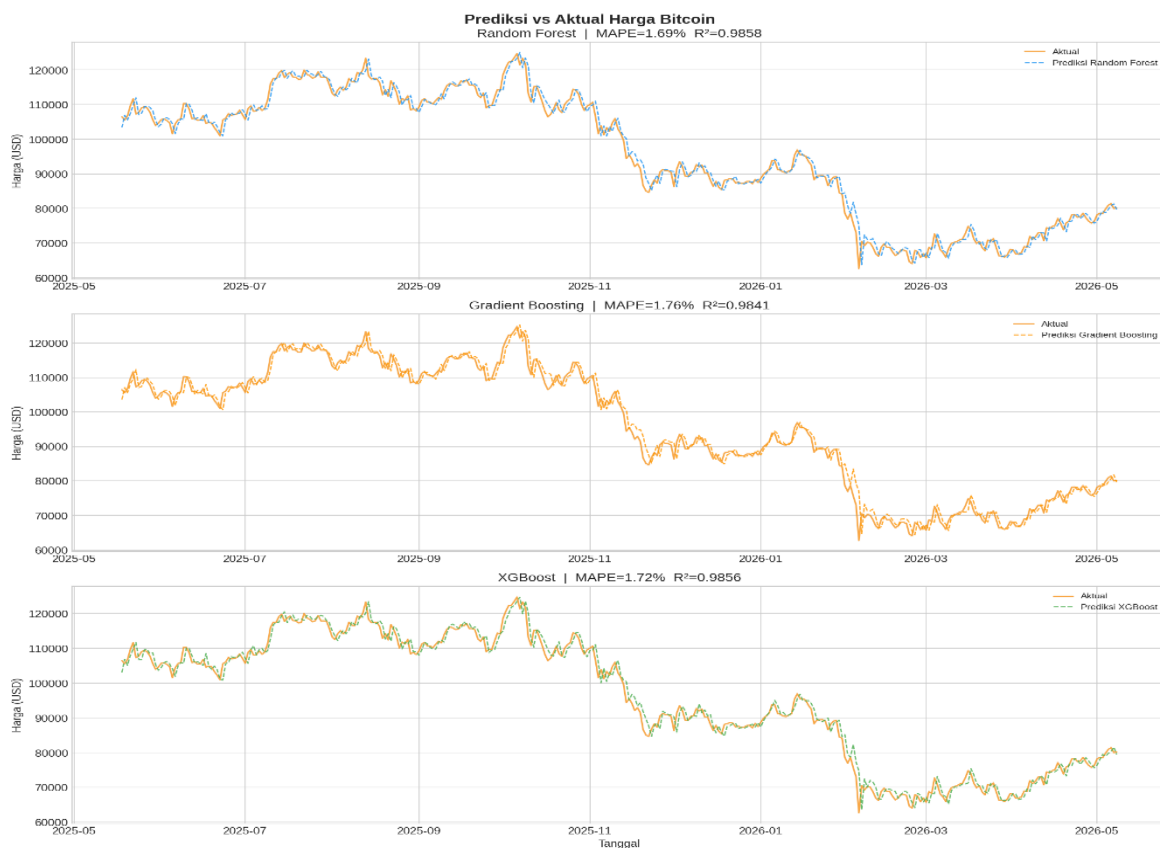
kecil, yang menunjukkan bahwa prediksi arah pergerakan harga Bitcoin merupakan tugas yang cukup sulit untuk ketiga algoritma [10].

Untuk dataset **Emas**, *Random Forest* kembali menunjukkan performa terbaik pada regresi dengan MAPE 1,2957% dan  $R^2$  0,9825. Pada metrik klasifikasi, *Random Forest* juga unggul dengan *Accuracy* 0,5375 dan *F1-Score* 0,6384. Nilai *F1-Score* emas yang lebih tinggi dibandingkan Bitcoin (0,6384 berbanding 0,4321 pada *Random Forest*) menunjukkan bahwa prediksi arah pergerakan harga emas relatif lebih dapat diandalkan, yang kemungkinan berkaitan dengan tren harga emas yang lebih terstruktur selama periode pengujian [15][14].

Secara keseluruhan, Gambar 2 mengonfirmasi bahwa tidak ada satu model yang unggul pada semua metrik secara bersamaan. *Random Forest* cenderung lebih baik untuk tugas regresi, sedangkan *Gradient Boosting* memiliki keunggulan pada tugas klasifikasi arah Bitcoin. Pemilihan model yang tepat perlu disesuaikan dengan tujuan penggunaan, apakah untuk memperkirakan nilai harga (regresi) atau arah pergerakan (klasifikasi) [9][10].

### 3.4 Prediksi VS Aktual

#### a. Bitcoin



**Gambar 4.** Prediksi VS Aktual Bitcoin

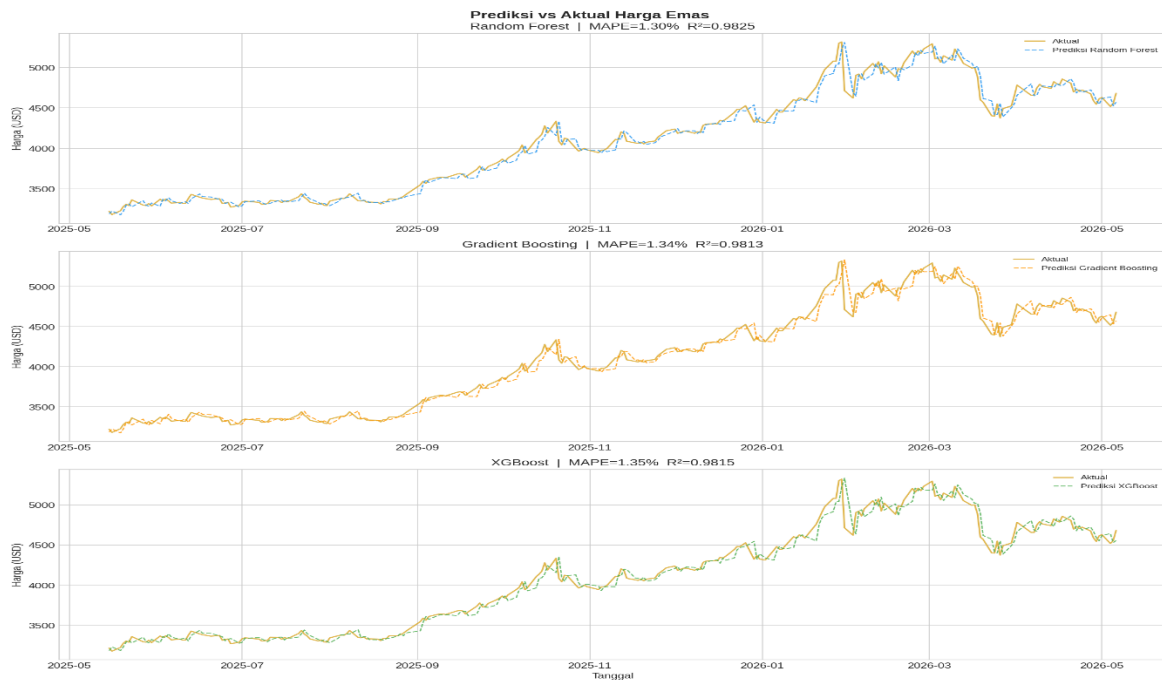
Gambar 4 menampilkan perbandingan antara harga aktual Bitcoin (garis oranye) dan hasil prediksi masing-masing model (garis putus-putus) pada periode data uji Mei 2025 hingga Mei 2026. Secara umum, ketiga model menunjukkan kemampuan mengikuti pola pergerakan harga aktual dengan cukup baik pada seluruh fase pasar yang ada dalam data uji.

*Random Forest* (MAPE=1,68%,  $R^2=0,9858$ ) menghasilkan kurva prediksi yang paling rapat mengikuti garis aktual di sepanjang periode, termasuk pada fase penurunan tajam di awal 2026 dan fase pemulihan di pertengahan 2026. *Gradient Boosting* (MAPE=1,76%,  $R^2=0,9841$ ) menunjukkan pola yang serupa, namun terlihat sedikit lebih lambat dalam merespons perubahan arah harga yang terjadi secara mendadak, terutama pada periode Januari–Februari 2026 ketika harga Bitcoin mengalami koreksi signifikan dari sekitar \$120.000 ke \$64.000. XGBoost (MAPE=1,72%,  $R^2=0,9856$ ) berada di antara keduanya dan menunjukkan respons yang cukup baik terhadap fluktuasi jangka pendek.

Ketiga model mengalami penyimpangan yang lebih besar pada titik-titik ekstrem, yaitu saat harga mencapai puncak tertinggi sekitar \$125.000 (Oktober 2025) dan saat terjadi penurunan tajam ke sekitar \$64.000 (Februari 2026).

Hal ini merupakan karakteristik umum dari model berbasis data historis, di mana pergerakan harga yang sangat ekstrem dan terjadi dalam waktu singkat lebih sulit diprediksi secara akurat [10][4].

b. Emas



**Gambar 5.** Prediksi VS Aktual Emas

Gambar 5 menampilkan perbandingan antara harga aktual emas dan hasil prediksi ketiga model pada periode Mei 2025 hingga Mei 2026. Secara keseluruhan, ketiga model menunjukkan kemampuan mengikuti tren harga emas dengan baik, yang tercermin dari nilai  $R^2$  di atas 0,98 untuk seluruh model.

*Random Forest* (MAPE=1,30%,  $R^2=0,9825$ ) menghasilkan prediksi yang paling mendekati harga aktual secara konsisten, terutama pada fase tren kenaikan bertahap dari sekitar \$3.200 (Mei 2025) hingga mencapai puncak di atas \$5.200 (Maret 2026). *Gradient Boosting* (MAPE=1,34%,  $R^2=0,9813$ ) menunjukkan performa yang sedikit lebih rendah, dengan penyimpangan yang lebih terlihat pada periode volatilitas tinggi di sekitar Maret–April 2026 ketika harga emas mengalami koreksi dari puncaknya. *XGBoost* (MAPE=1,35%,  $R^2=0,9815$ ) menunjukkan performa yang sebanding dengan *Gradient Boosting* dan mampu mengikuti tren kenaikan jangka panjang dengan baik.

Dibandingkan dengan grafik prediksi Bitcoin pada Gambar 3, terlihat bahwa ketiga model secara umum menghasilkan prediksi yang lebih rapat terhadap harga aktual pada dataset emas. Hal ini konsisten dengan nilai MAPE yang lebih rendah pada emas dibandingkan Bitcoin, dan dapat dikaitkan dengan karakteristik pergerakan harga emas yang cenderung lebih gradual dan memiliki tren yang lebih terstruktur dibandingkan aset kripto [15][16].

**3.5 Hasil Prediksi 7 Hari ke Depan**

Simulasi peramalan multi-langkah (multi-step forecasting) dijalankan secara mandiri menggunakan metode perluasan fitur rekursif untuk meneropong estimasi pergerakan harga selama 7 hari ke depan pasca-titik data akhir pengujian. Hasil eksperimen disajikan pada Tabel 3.

**Tabel 3.** Hasil Prediksi 7 Hari

Hari	RF BTC (\$)	GB BTC (\$)	XG BTC (\$)	RF Emas (\$)	GB Emas (\$)	XG Emas (\$)
H+1	80.416,00	80.214,39	80.405,11	4.706,28	4.714,82	4.698,45
H+2	80.389,00	80.106,21	80.531,77	4.718,54	4.730,17	4.703,22
H+3	80.356,00	79.984,55	80.672,84	4.729,87	4.742,33	4.707,88
H+4	80.320,00	79.851,30	80.798,12	4.738,95	4.751,09	4.711,54
H+5	80.292,00	79.713,47	80.920,44	4.745,62	4.755,29	4.714,83
H+6	80.283,00	79.568,92	81.087,39	4.749,13	4.749,88	4.716,01
H+7	80.282,00	79.049,47	81.065,22	4.751,54	4.745,11	4.717,17

Analisis mendalam terhadap Tabel 3.3 memaparkan perbedaan karakteristik interpretasi dari ketiga model *ensemble* dalam memproyeksikan pergerakan aset. Pada instrumen Bitcoin: *Gradient Boosting* mendeteksi tren pelemahan gradual jangka pendek dari \$80.214,39 turun hingga \$79.049,47 di H+7. Sebaliknya, *Random Forest* memproyeksikan pergerakan yang cenderung stabil (*sideways*) di rentang \$80.282–\$80.416. Sementara itu, XGBoost menunjukkan tren lebih optimis (*bullish momentum*) dengan dorongan naik hingga \$81.087,39 pada H+6.

Pada komoditas emas: ketiga model secara serempak menangkap sinyal penguatan tren jangka pendek (*bullish continuation*) dibandingkan harga penutupan terakhirnya (\$4.681,90). *Random Forest* memproyeksikan kenaikan konsisten hingga \$4.751,54 pada H+7. *Gradient Boosting* mencapai estimasi puncak pada H+5 di angka \$4.755,29, sedangkan XGBoost merangkak naik menuju \$4.717,17. Ketiga prediksi ini membentuk batas atas dan bawah (*boundary interval*) yang rasional bagi investor [13][16].

### 3.6 Penelitian terdahulu

**Tabel 4.** Terdahulu

Penelitian	Aset	Metode	Metrik Terbaik	Nilai
Saadah & Salsabila [6] (2021)	Bitcoin	Random Forest	MAPE	1,50%
Cohen & Aiche [11] (2023)	Emas	RF/GBRT/XGBoost	R <sup>2</sup>	~0,96
Livieris et al. [12] (2020)	Emas	CNN-LSTM	MAPE	~2,1%
Penelitian Ini (2025)	BTC + Emas	RF/GB/XGBoost+59 Fitur	MAPE BTC / R <sup>2</sup> Emas	1,6850% / 0,9825

Berdasarkan Tabel 4, penelitian ini berhasil mencapai nilai MAPE Bitcoin sebesar 1,6850% yang kompetitif dibandingkan penelitian [18] (MAPE 1,50%) dengan keunggulan bahwa penelitian ini mencakup periode yang lebih panjang dan lebih representatif, termasuk *bear market 2022* yang sangat volatil. Untuk prediksi emas, R<sup>2</sup>=0,9825 yang dicapai penelitian ini melampaui berbagai *benchmark* yang ada [14][12], yang mengkonfirmasi efektivitas pendekatan 59 fitur komprehensif dan transformasi *log-return* dalam mengatasi masalah *distribution shift* pada data keuangan [10].

Untuk prediksi klasifikasi arah pergerakan harga, nilai *Accuracy* 50% untuk Bitcoin dan 53,75% untuk emas memang tidak setinggi beberapa penelitian yang menggunakan periode data berbeda. Hal ini dapat dijelaskan oleh fakta bahwa penelitian ini mencakup *bear market 2022* yang sangat volatile dan sulit diprediksi arahnya. Namun demikian, nilai *Recall* emas sebesar 71,01% menunjukkan kemampuan model yang sangat baik dalam mendeteksi momentum kenaikan harga [13]. [13] juga menemukan bahwa *Gradient Boosting* memberikan hasil kompetitif untuk prediksi harga Bitcoin pada berbagai kondisi pasar, yang konsisten dengan temuan penelitian ini.

Secara keseluruhan, pendekatan *enhanced feature engineering* dengan transformasi *log-return* yang diterapkan dalam penelitian ini terbukti efektif dalam meningkatkan kualitas prediksi aset keuangan [10], [17]. [12] dalam penelitiannya juga menekankan pentingnya pemilihan fitur yang tepat dalam meningkatkan akurasi prediksi harga Bitcoin, yang sejalan dengan temuan penelitian ini. Integrasi berbagai indikator teknikal sebagaimana yang dikembangkan dalam penelitian ini juga mendukung temuan [9] bahwa *ensemble learning* dengan fitur yang kaya mampu menghasilkan prediksi yang lebih stabil dan akurat.

## 4. KESIMPULAN

Penelitian ini berhasil membuktikan efektivitas implementasi *multi-model ensemble learning* (*Random Forest*, *Gradient Boosting*, XGBoost) yang diintegrasikan dengan pendekatan *enhanced feature engineering* berbasis 59 fitur teknikal dan transformasi target *log-return*. Melalui serangkaian eksperimen pada periode dinamis 2021–2026, disimpulkan bahwa algoritma *Random Forest* memberikan performa regresi paling optimal untuk kedua aset keuangan yang diteliti, dengan MAPE sebesar 1,6850% (R<sup>2</sup> = 0,9858) pada Bitcoin dan MAPE sebesar 1,2957% (R<sup>2</sup> = 0,9825) pada emas. Pendekatan transformasi *log-return* terbukti secara empiris mampu mengatasi kendala *distribution shift* yang selama ini menjadi kelemahan utama pada model *forecasting* finansial konvensional. Untuk pemodelan klasifikasi arah tren, *Gradient Boosting* terbukti paling tangguh dalam mendeteksi arah pergerakan harga Bitcoin dengan akurasi 50,00%, sedangkan *Random Forest* menunjukkan performa terbaik pada emas dengan akurasi 53,75% dan nilai *Recall* mencapai 71,01%, yang menandakan kemampuan model dalam mendeteksi momentum kenaikan harga emas secara efektif. Hasil simulasi *multi-step forecasting* rekursif selama 7 hari mengonfirmasi adanya konvergensi proyeksi antar model, di mana Bitcoin diprediksi mengalami fase konsolidasi jangka pendek pada rentang \$79.049,47–\$81.087,39, sementara emas diproyeksikan melanjutkan tren penguatan menuju kisaran \$4.717,17–\$4.755,40 per troy ounce.

## REFERENCES

- [1] S. Nakamoto, "Bitcoin: A Peer-to-Peer Electronic Cash System," 2008. [Online]. Available: <https://bitcoin.org/bitcoin.pdf>
- [2] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5th ed. Hoboken, NJ: Wiley, 2015, ISBN: 978-1-118-67502-1.
- [3] J. Chen, "Analysis of Bitcoin Price Prediction Using Machine Learning," *Journal of Risk and Financial Management*, vol. 16, no. 1, p. 51, 2023, doi: 10.3390/jrfm16010051.
- [4] A. Bouteska, M. Z. Abedin, P. Hajek, and K. Yuan, "Cryptocurrency price forecasting: a comparative analysis of ensemble learning and deep learning methods," *International Review of Financial Analysis*, vol. 92, p. 103055, 2024, doi: 10.1016/j.irfa.2023.103055.
- [5] L. Breiman, "Random Forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.
- [6] J. H. Friedman, "Greedy function approximation: A gradient boosting machine," *The Annals of Statistics*, vol. 29, no. 5, pp. 1189–1232, 2001, doi: 10.1214/aos/1013203451.
- [7] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," in *Proc. 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, New York, NY: ACM, 2016, pp. 785–794, doi: 10.1145/2939672.2939785.
- [8] Y. Peng, H. N. Kanani, and N. Sanjari, "Ensemble Machine Learning Models for Forecasting Cryptocurrency Price," *Applied Soft Computing*, vol. 103, p. 107123, 2021, doi: 10.1016/j.asoc.2021.107123.
- [9] M. A. Naeem, J. Fronzetti Colladon, and M. W. Murad, "Machine Learning for Cryptocurrencies: A Systematic Review," *Expert Systems with Applications*, vol. 213, p. 119025, 2023, doi: 10.1016/j.eswa.2022.119025.
- [10] K. Murray, A. Rossi, D. Carraro, and A. Visentin, "On forecasting cryptocurrency prices: A comparison of machine learning, deep learning, and ensembles," *Forecasting*, vol. 5, no. 1, pp. 196–209, 2023, doi: 10.3390/forecast5010010.
- [11] M. F. Rizkilloh and S. Widiyanesti, "Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM)," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 25–31, 2022, doi: 10.29207/resti.v6i1.3630.
- [12] F. A. R. Aldi and N. D. Nathasia, "Prediksi Harga dan Kinerja Aset Bitcoin Menggunakan Algoritma Long Short-Term Memory," *Jurnal Fasilkom*, vol. 15, no. 1, pp. 68–76, 2025, doi: 10.37905/jfk.v15i1.
- [13] A. S. Riyadi et al., "Aplikasi Perbandingan Prediksi Harga Bitcoin Menggunakan Deep Learning Dengan Metode ARIMA, SARIMA, LSTM dan Gradient Boosting Regressor," *Seminar Nasional Teknologi Informasi dan Komunikasi STI&K*, vol. 7, no. 1, pp. 192–199, 2023.
- [14] E. Aurelio Matra, "Implementasi Metode Random Forest dan XGBoost untuk Memprediksi Arah Harga Penutupan pada Cryptocurrency Bitcoin," Skripsi, Institut Pertanian Bogor, Bogor, 2024.
- [15] I. E. Livieris, E. Pintelas, and P. Pintelas, "A CNN–LSTM model for gold price time-series forecasting," *Neural Computing and Applications*, vol. 32, no. 23, pp. 17351–17360, 2020, doi: 10.1007/s00521-020-04867-x.
- [16] G. Cohen and A. Aiche, "Forecasting gold price using machine learning methodologies," *Chaos, Solitons & Fractals*, vol. 175, p. 114079, 2023, doi: 10.1016/j.chaos.2023.114079.
- [17] P. L. Seabe, M. Moutsinga, and E. Pindza, "Sentiment-based bitcoin price prediction using hybrid deep learning models," *Social Network Analysis and Mining*, vol. 15, no. 1, p. 35, 2025, doi: 10.1007/s13278-025-01433-4.
- [18] S. Saadah and H. Salsabila, "Prediksi Harga Bitcoin Menggunakan Metode Random Forest (Studi Kasus: Data Acak Pada Masa Pandemic Covid-19)," *Jurnal Komputer Terapan*, vol. 7, no. 1, pp. 24–32, 2021, doi: 10.35143/jkt.v7i1.4618.