

Implementasi Algoritma XGBoost dengan Walk Forward Validation untuk Prediksi Harga Emas Antam

Mochammad Hisyam*, Zahratul Fitri, Hafizh Al Kautsar Aidilof

Fakultas Teknik, Program Studi Teknik Informatika, Universitas Malikussaleh, Lhokseumawe, Indonesia

Email: ^{1,*}mochammad.200170249@mhs.unimal.ac.id, ²zahratulfitri@unimal.ac.id, ³hafizh@unimal.ac.id

Email Penulis Korespondensi: mohammad.200170249@mhs.unimal.ac.id

Submitted 01-06-2025; Accepted 10-07-2025; Published 14-08-2025

Abstrak

Prediksi harga emas yang akurat sangat penting dalam mendukung pengambilan keputusan finansial dan investasi. Penelitian ini membangun dan mengoptimalkan model prediksi harga emas harian menggunakan algoritma Extreme Gradient Boosting (XGBoost) berdasarkan data historis harga dan indikator teknikal. Model dikembangkan untuk memprediksi dua jenis harga, yaitu harga "Close" dan "Buyback" dalam satuan IDR/gram. Pengoptimalan dilakukan melalui metode Bayesian Optimization untuk memperoleh kombinasi hyperparameter terbaik. Evaluasi model dilakukan menggunakan pendekatan Walk Forward Validation (WV) dengan sliding window 14 hari, serta dua metrik evaluasi utama, yaitu Root Mean Square Error (RMSE) dan Mean Absolute Percentage Error (MAPE). Hasil penelitian menunjukkan bahwa model mampu memberikan performa prediksi yang sangat baik dengan rata-rata RMSE sebesar 15.431,92 dan MAPE sebesar 1,03% untuk harga Close, serta RMSE sebesar 15.382,64 dan MAPE sebesar 1,15% untuk harga Buyback. Visualisasi prediksi menunjukkan bahwa model secara konsisten mengikuti pola harga aktual. Analisis feature importance mengungkap bahwa indikator teknikal seperti RSI, EMA, dan MACD memiliki kontribusi signifikan terhadap model. Keberhasilan penelitian ini menunjukkan bahwa XGBoost yang dioptimalkan dapat menjadi pendekatan andal dalam memprediksi harga emas, serta membuka peluang untuk pengembangan model prediksi yang lebih kompleks pada studi lanjutan.

Kata Kunci: Prediksi Harga Emas; XGBoost; Bayesian Optimization; Walk Forward Validation; Indikator teknikal

Abstract

Accurate gold price prediction is crucial in supporting financial and investment decision-making. This study aims to develop and optimize a daily gold price prediction model using the Extreme Gradient Boosting (XGBoost) algorithm based on historical price data and technical indicators. The model was constructed to predict two types of prices, namely "Close" and "Buyback" prices in IDR/gram. Optimization was carried out using Bayesian Optimization to obtain the best hyperparameter combinations. The model was evaluated using a Walk Forward Validation (WV) approach with a 14-day sliding window and two main evaluation metrics: Root Mean Square Error (RMSE) and Mean Absolute Percentage Error (MAPE). The results show that the model provides excellent predictive performance, with an average RMSE of 15,431.92 and MAPE of 1.03% for Close price, and RMSE of 15,382.64 and MAPE of 1.15% for Buyback price. The prediction visualizations indicate that the model consistently follows the actual price trend. Feature importance analysis reveals that technical indicators such as RSI, EMA, and MACD significantly contribute to the model. The success of this study demonstrates that an optimized XGBoost model can serve as a reliable approach for gold price forecasting and opens opportunities for developing more advanced predictive models in future research.

Keywords: Gold Price Prediction; XGBoost; Bayesian Optimization; Walk Forward Validation; Technical indicators

1. PENDAHULUAN

Emas merupakan komoditas logam mulia bernilai tinggi yang tidak hanya digunakan dalam industri perhiasan, tetapi juga berperan penting sebagai instrumen keuangan yang berfungsi sebagai penyimpan nilai dan pelindung terhadap risiko inflasi maupun ketidakstabilan ekonomi global [1]. Popularitas emas sebagai instrumen investasi juga terus meningkat seiring dengan kecenderungan harga jual dan beli yang mengalami kenaikan dari waktu ke waktu. Namun demikian, pergerakan harga emas tidak sepenuhnya stabil, karena tetap dapat mengalami fluktuasi yang menimbulkan risiko tersendiri bagi para investor [2].

Fluktuasi harga emas dipengaruhi oleh berbagai faktor, baik makroekonomi seperti suku bunga dan nilai tukar, maupun faktor teknikal yang tercermin dari pola pergerakan harga masa lalu [3]. Emas, khususnya jenis emas batangan produksi PT Aneka Tambang Tbk (Antam) kerap dijadikan acuan utama oleh investor dan masyarakat Indonesia karena merepresentasikan harga jual beli logam mulia secara fisik di pasar domestik [4]. Ketidaktepatan dalam membeli emas tanpa didukung perhitungan yang cermat dapat menimbulkan potensi kerugian, baik bagi masyarakat umum maupun investor. Oleh karena itu, sebelum melakukan pembelian, penting bagi investor untuk memahami apakah harga emas saat ini tergolong ideal, mengingat kemungkinan harga dapat mengalami penurunan dalam waktu dekat. Oleh karena itu, diperlukan model prediksi yang mampu memperkirakan harga emas di masa mendatang guna memberikan acuan dalam pengambilan keputusan investasi [5].

Permasalahan utama dalam prediksi harga emas adalah tingginya volatilitas dan kompleksitas pola pergerakannya yang tidak linier. Pendekatan konvensional seperti regresi linear atau metode statistik tradisional sering kali tidak mampu menangkap dinamika ini secara efektif, terutama ketika berhadapan dengan data non-stasioner dan berfluktuasi tinggi [6]. Oleh karena itu, diperlukan pendekatan yang mampu mengolah data historis serta fitur teknikal secara simultan untuk menghasilkan prediksi yang lebih akurat. Salah satu metode pembelajaran mesin yang terbukti efektif dalam menangani regresi non-linier adalah Extreme Gradient Boosting (XGBoost), yang tidak hanya menggabungkan prinsip boosting dengan efisiensi komputasi dan regularisasi untuk mencegah overfitting, tetapi juga memiliki kemampuan dalam mengelola dataset berukuran besar dengan banyak fitur secara efisien [7].


Sejumlah penelitian sebelumnya telah memanfaatkan algoritma pembelajaran mesin untuk memprediksi harga komoditas. Salah satu studi yang relevan dalam konteks prediksi harga aset keuangan yang menerapkan metode XGBoost untuk memprediksi harga saham Bank BCA selama periode 2017 hingga 2020. Penelitian ini memanfaatkan indikator teknikal seperti SMA, EMA, MACD, dan RSI sebagai fitur masukan untuk model XGBoost. Hasil evaluasi menunjukkan bahwa EMA menjadi indikator paling berpengaruh terhadap hasil prediksi, dengan tingkat akurasi cukup baik (MAPE sebesar 4,01%) [8]. Penelitian lain menerapkan penggunaan algoritma XGBoost untuk meramalkan harga perak dengan pendekatan tuning hyperparameter grid search sebagai metode optimasi terhadap 4 hyperparameter utama. Evaluasi model dilakukan menggunakan 5-fold cross-validation. Model terbaik menghasilkan nilai RMSE sebesar 1.6998 dan MAPE sebesar 5,98% [9]. Ada juga penelitian lain yang membahas efektivitas penggunaan model machine learning sederhana seperti linear regression dan model lanjutan seperti XGBoost dalam memprediksi harga spot emas harian. Penelitian ini melakukan pencarian kombinasi hyperparameter terbaik menggunakan grid search. Evaluasi hasil menunjukkan bahwa model linear regression memberikan nilai $R^2 = 1.0$ dan MSE mendekati nol, yang menandakan overfitting. Sementara itu, model XGBoost memberikan performa sangat baik dengan $R^2 = 0.999$ dan MSE sebesar 0.2188 [10]. Penelitian lainnya juga menggunakan pendekatan Long Short-Term Memory (LSTM) untuk memodelkan harga emas harian internasional yang bersifat non-stasioner. Penelitian ini menerapkan skema walk-forward validation untuk memilih kombinasi hyperparameter terbaik, dengan hasil akhir model terbaik diperoleh menggunakan optimizer Adam, learning rate 0.01, dan 100 epoch. Model ini menghasilkan nilai MAPE sebesar 0,4867%, yang dikategorikan sebagai akurasi tinggi. Akan tetapi, Penelitian ini masih terbatas pada data univariat, tanpa mempertimbangkan variabel atau indikator lain untuk mengatasi permasalahan heteroskedastisitas [11]. Penelitian lainnya mengusulkan penggunaan model ensemble regresi untuk memperkirakan harga emas dalam satuan dolar Amerika per troy ons dengan menggunakan periode data sekitar 1 tahun. Tujuh model regresi mulai dari linear hingga ensemble seperti voting dan stacking regressor diujikan dengan dataset yang dilengkapi indikator teknikal (SMA, RSI, Bollinger Band, dan indeks DXY). Eksperimen menunjukkan bahwa stacking regressor memberikan hasil terbaik, dengan nilai MAPE sebesar 2,2036 [12].

Sejumlah studi sebelumnya menunjukkan pemanfaatan algoritma pembelajaran mesin XGBoost dalam prediksi harga aset keuangan dan komoditas. Namun, terdapat beberapa celah penelitian yang masih belum banyak dijelajahi. Sebagian besar penelitian berfokus pada aset berdenominasi dolar AS, seperti harga saham dan emas internasional, sehingga konteks lokal seperti pasar emas Indonesia dalam satuan IDR/gram masih belum banyak dieksplorasi. Dari sisi optimasi, sebagian studi masih mengandalkan metode grid search yang bersifat ekshausif dan kurang efisien dibanding pendekatan adaptif seperti Bayesian Optimization. Validasi model juga umumnya menggunakan pemisahan data konvensional (80:20) atau k-fold cross-validation statis, yang tidak mempertimbangkan aspek temporal dalam data deret waktu. Hal ini berpotensi menghasilkan estimasi performa yang tidak mencerminkan kondisi prediksi aktual. Berdasarkan identifikasi tersebut, penelitian ini mengusulkan pengembangan model XGBoost untuk prediksi harga jual dan beli kembali emas dari antam berbasis IDR/gram dengan menggabungkan indikator teknikal yang relevan, tuning hyperparameter menggunakan Bayesian Optimization, serta validasi menggunakan skema walk forward validation yang lebih sesuai dengan karakteristik data time series untuk meningkatkan akurasi prediksi harga emas dalam konteks pasar domestik.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilakukan melalui serangkaian tahapan terstruktur yang bertujuan untuk membangun model prediksi harga emas berbasis algoritma XGBoost. Gambar 1 berikut menyajikan diagram alur tahapan penelitian secara umum.



Gambar 1. Tahapan Penelitian

Penelitian ini diawali dengan pengumpulan data historis harga emas harian dalam satuan IDR/gram dari situs Pusat Data Kontan yang mengacu pada harga emas dari antam dan mencakup harga close dan buyback dari februari 2010 hingga maret 2025. Selanjutnya dilakukan proses eksplorasi dan pembersihan data untuk menangani duplikasi, missing

value, serta konsistensi format. Tahap berikutnya adalah rekayasa fitur dengan menambahkan indikator teknikal seperti MA, EMA, RSI, MACD, dan Signal Line untuk memperkuat representasi pola harga. Model XGBoost kemudian dibangun sebagai model dasar menggunakan parameter default. Untuk meningkatkan performa, dilakukan optimasi hyperparameter menggunakan Bayesian Optimization. Tahapan akhir melibatkan validasi dan evaluasi model dengan skema walk forward validation (WV) menggunakan sliding window sepanjang 14 hari untuk mencerminkan prediksi secara berurutan waktu. Evaluasi kinerja model dilakukan menggunakan metrik RMSE dan MAPE untuk menilai akurasi dan kestabilan prediksi.

2.2 Pengumpulan Data

situs pusatdata.kontan.co.id adalah sebuah platform digital yang dikelola oleh Kontan, bagian dari grup Kompas Gramedia yang bergerak di bidang penyediaan informasi ekonomi dan bisnis. Situs ini menyediakan berbagai jenis data historis ekonomi dan keuangan, termasuk harga logam mulia seperti emas dan perak. Data harga emas yang tersedia pada platform ini merujuk pada harga resmi dari PT Aneka Tambang Tbk (Antam), yang merupakan produsen utama logam mulia di Indonesia [13]. Dataset harga emas yang digunakan dalam penelitian ini mencakup dua jenis harga, yaitu harga Close (jual) dan Buyback (beli kembali) oleh antam yang direkam secara harian dari 10 Februari 2010 hingga 9 Maret 2025. Total terdapat 4.210 baris data yang mencerminkan pergerakan harga selama sekitar 15 tahun.

2.3 Eksplorasi dan Pembersihan Data

Salah satu pendekatan yang umum digunakan pada data deret waktu untuk mengatasi keberadaan nilai kosong (*missing values*) adalah menggunakan metode forward fill untuk mempertahankan kontinuitas temporal, dan interpolasi linear untuk mengisi nilai hilang secara halus berdasarkan nilai disekitarnya [14]. Dalam penelitian ini, eksplorasi awal dilakukan untuk memahami karakteristik statistik dan pola distribusi harga emas dalam dataset. Untuk menjaga integritas data pada penelitian ini, penanganan nilai hilang (*missing value*) dilakukan dengan metode *forward fill*. Sedangkan untuk nilai-nilai harga yang lebih rendah dari ambang batas kewajaran dianggap sebagai outlier dan digantikan dengan NaN, yang selanjutnya diimputasi menggunakan interpolasi linear agar tetap mempertahankan kontinuitas tren. Proses ini menghasilkan data yang bersih, bebas dari anomali ekstrem, dan siap digunakan dalam tahap rekayasa fitur dan pembangunan model prediksi. Dalam penelitian ini juga tidak dilakukan proses normalisasi maupun standarisasi terhadap fitur numerik. Hal ini didasarkan pada karakteristik algoritma XGBoost yang bersifat *tree-based* dan tidak bergantung pada skala data. Algoritma ini mempartisi data berdasarkan nilai ambang (*threshold*), sehingga perbedaan skala antar fitur tidak mempengaruhi proses pelatihan maupun hasil prediksi [15].

2.4 Rekayasa Fitur (Feature Engineering)

Indikator teknikal merupakan alat bantu analisis kuantitatif yang dirancang untuk menginterpretasikan pergerakan harga melalui pendekatan matematis terhadap data historis, seperti harga penutupan, volume, dan volatilitas. Dalam konteks pasar keuangan, indikator ini digunakan untuk mengidentifikasi tren, kekuatan momentum, titik jenuh beli/jual, dan potensi pembalikan arah [16]. Dalam penelitian ini, fitur-fitur yang dibangun mengacu pada indikator teknikal yang umum digunakan dalam analisis pasar, khususnya dalam konteks pergerakan harga emas. Beberapa fitur teknikal yang diturunkan meliputi rata-rata bergerak (Moving Average/MA) untuk periode 5, 15, dan 30 hari, serta Exponential Moving Average (EMA) 9 hari. Selain itu, indikator Relative Strength Index (RSI), Moving Average Convergence Divergence (MACD), dan signal line juga dihitung untuk menangkap momentum dan arah tren harga. Fitur lain yang dibentuk adalah daily return, yang merepresentasikan persentase perubahan harga harian dan membantu model mengenali pola volatilitas. Seluruh fitur direkayasa berdasarkan dua target berbeda, yaitu harga *Close* dan harga *Buyback*, sehingga terdapat dua set fitur yang disesuaikan untuk masing-masing target prediksi. Setiap fitur dihitung secara berurutan berdasarkan nilai historis, tanpa kebocoran informasi dari data masa depan.

2.5 Hyperparameter Tuning

Hyperparameter merupakan parameter eksternal dalam algoritma pembelajaran mesin yang ditetapkan sebelum proses pelatihan dimulai dan tidak diperbarui selama pelatihan berlangsung. Pengaturan hyperparameter yang berbeda dapat menghasilkan kinerja model yang sangat bervariasi, sehingga pemilihan kombinasi parameter yang optimal menjadi tahap penting dalam pengembangan model. Proses ini dikenal sebagai *hyperparameter tuning*, yang bertujuan untuk mengidentifikasi konfigurasi parameter terbaik guna meningkatkan performa model secara keseluruhan [17]. Proses hyperparameter tuning dilakukan dengan menggunakan bayesian optimization, yaitu suatu pendekatan optimasi berbasis probabilitas yang efektif dan efisien untuk menemukan kombinasi parameter optimal dalam ruang pencarian yang luas. Berbeda dengan metode pencarian seperti grid search atau random search yang bersifat eksploratif namun tidak adaptif, bayesian optimization membangun model surrogate (misalnya Gaussian Process) untuk memodelkan fungsi objektif, dan secara iteratif mengevaluasi titik pencarian baru berdasarkan fungsi akuisisi yang mempertimbangkan eksploitasi dan eksplorasi. Keunggulan pendekatan ini terletak pada kemampuannya untuk mengurangi jumlah evaluasi fungsi yang mahal secara komputasi serta memberikan solusi optimal dalam ruang parameter berdimensi tinggi [18]. Beberapa hyperparameter utama pada XGBoost meliputi *n_estimators*, *learning_rate*, *max_depth*, *subsample*, dan *colsample_bytree*, masing-masing berpengaruh terhadap kompleksitas model, kecepatan konvergensi, serta risiko overfitting atau underfitting. Pada penelitian ini, tuning hyperparameter dilakukan untuk memperoleh kombinasi

parameter terbaik yang dapat meminimalkan nilai kesalahan prediksi berdasarkan metrik evaluasi Root Mean Square Error (RMSE) dan Mean Absolute Percentage Error (MAPE). Tabel 1 berikut menyajikan ruang pencarian (search space) dari hyperparameter yang digunakan dalam tuning model XGBoost pada penelitian ini:

Tabel 1. Ruang Pencarian Hyperparameter

Parameter	Rentang Nilai
<i>n_estimators</i>	100-1000
<i>learning_rate</i>	0.01-0.3
<i>max_depth</i>	3-15
<i>subsample</i>	0.5-1
<i>colsample_bytree</i>	0.3-1
<i>gamma</i>	0-5
<i>lambda</i>	0-10
<i>alpha</i>	0-10

2.6 Pengembangan Model XGBoost

XGBoost merupakan algoritma machine learning berbasis pohon keputusan yang dikembangkan secara khusus untuk mengatasi masalah overfitting dan meningkatkan efisiensi komputasi dalam proses pembelajaran. Algoritma ini bekerja dengan pendekatan boosting, yaitu membangun model prediktif secara iteratif dengan menambahkan pohon-pohon baru untuk memperbaiki kesalahan dari prediksi sebelumnya. Setiap pohon baru dibentuk berdasarkan fungsi objektif yang menggabungkan fungsi loss dan regularisasi, sehingga mampu menjaga keseimbangan antara bias dan varians [15]. Pemilihan XGBoost dalam penelitian ini didasarkan pada kemampuannya dalam menangkap hubungan nonlinier antara fitur prediktor dengan target harga emas. Selain itu, XGBoost telah terbukti unggul dalam berbagai kompetisi dan studi empiris karena kestabilan, akurasi, dan kecepatan pelatihannya yang superior dibandingkan algoritma model lain seperti regresi linier, neural networks, dan random forest [19]. Model XGBoost dalam penelitian ini dikembangkan langsung dengan konfigurasi parameter hasil optimasi untuk memastikan performa prediktif yang lebih baik sejak awal pengujian. Model ini kemudian dievaluasi menggunakan dua metrik utama, yaitu Root Mean Squared Error (RMSE) dan Mean Absolute Percentage Error (MAPE), guna mengukur tingkat kedekatan hasil prediksi dengan data aktual secara kuantitatif. Berikut adalah rumus fungsi objektif dari XGBoost:

$$Obj(\theta) = \sum_{i=1}^n L(y_i, \hat{y}_i) + \sum_k \Omega(f_k) \quad (1)$$

Keterangan :

$L(y_i, \hat{y}_i)$: Fungsi loss yang mengukur kesalahan prediksi

$\Omega(f_k)$: Fungsi regularisasi yang mengontrol kompleksitas model agar tidak overfitting

2.7 Skema Validasi

Pada permasalahan deret waktu seperti prediksi harga emas, validasi model tidak dapat dilakukan secara acak karena adanya ketergantungan kronologis antar data. Penggunaan data masa depan dalam pelatihan dapat menyebabkan kebocoran informasi (*data leakage*). Oleh karena itu, penelitian ini menggunakan teknik *walk-forward validation* yang mempertahankan urutan waktu. *Walk-forward validation* membagi data pelatihan dan pengujian secara berurutan. Model dilatih pada subset awal, kemudian diuji pada periode selanjutnya. Selanjutnya, jendela data pelatihan digeser secara bertahap (*sliding window*) dan proses ini diulang. Teknik ini memungkinkan model untuk dievaluasi secara realistik dalam skenario dunia nyata, di mana hanya data historis yang tersedia saat membuat prediksi [11].



Gambar 2. Ilustrasi Walk-Forward Validation dengan Sliding Window

Berbeda dari pembagian data statis seperti *train-test split* atau *k-fold cross-validation*, metode ini menghindari penggunaan data masa depan, sehingga menghasilkan evaluasi yang lebih adil dan relevan. Pendekatan *sliding window* juga menguji kemampuan model dalam beradaptasi terhadap perubahan tren dan pola musiman dalam data harga emas. Proses *walk-forward validation* dimulai dengan membagi 80% data awal sebagai data pelatihan pertama (*initial training*

window), kemudian dilakukan pengujian pada jendela waktu tertentu selama 14 hari (*test window*). Setelah setiap iterasi, jendela pelatihan digeser ke depan sebesar 14 hari secara bertahap tanpa memperluas ukuran jendela pelatihan. Implementasi validasi ini menghasilkan sejumlah iterasi yang menguji kemampuan model dalam beradaptasi terhadap perubahan dinamika data secara berkelanjutan. Pada setiap iterasi, data pengujian ditandai dengan indeks bertingkat, misalnya *test_1*, *test_2*, dan seterusnya. Pendekatan ini tidak hanya mempertahankan urutan waktu tetapi juga memberikan gambaran evaluasi performa model secara konsisten sepanjang periode dataset.

2.8 Evaluasi Model XGBoost

Pada tahap ini, Model regresi yang dibangun dalam penelitian ini dievaluasi menggunakan dua metrik evaluasi yang umum digunakan dalam analisis deret waktu, yaitu Root Mean Squared Error (RMSE) dan Mean Absolute Percentage Error (MAPE) [20], [21]. RMSE memberikan ukuran absolut dari kesalahan prediksi model, dihitung dalam satuan yang sama dengan variabel target, dan digunakan untuk mengukur seberapa jauh hasil prediksi menyimpang dari data aktual. Sementara itu, MAPE mengukur rata-rata kesalahan absolut dalam bentuk persentase terhadap nilai aktual. Metrik ini sangat berguna dalam konteks di mana interpretasi dalam bentuk persentase lebih informatif daripada unit absolut. Nilai MAPE di bawah 5% dianggap sangat baik, MAPE antara 10%–25% tergolong rendah namun masih dapat diterima, sedangkan nilai di atas 25% menunjukkan akurasi sangat rendah dan model dianggap tidak layak digunakan [21]. Dalam penelitian ini, nilai RMSE dan MAPE dihitung pada setiap iterasi validasi menggunakan skema *walk-forward* dengan pendekatan *sliding window*, sehingga diperoleh rata-rata performa model yang mencerminkan kemampuan generalisasi terhadap data masa depan.

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

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (3)$$

Keterangan :

n : Jumlah data
 y_i : Nilai aktual ke- i
 $\hat{y}_i$: Nilai prediksi ke- i

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil dari proses pengujian model prediksi harga emas menggunakan algoritma XGBoost yang telah dioptimasi. Proses dilakukan terhadap dua target prediksi, yaitu harga *Close* dan *Buyback* berdasarkan data historis harga emas harian. Pembahasan difokuskan pada evaluasi performa model, analisis kontribusi fitur teknis, serta pengaruh tuning hyperparameter terhadap akurasi prediksi. Seluruh eksperimen dilakukan dengan pendekatan *Walk Forward Validation* untuk memastikan ketahanan model dalam skenario data berurutan waktu (*time series*).


3.1 Eksplorasi dan Pembersihan Data

Dataset yang digunakan dalam penelitian ini terdiri dari data historis harga emas harian dalam satuan IDR/gram, yang mencakup dua jenis harga, yaitu harga *Close* dan harga *Buyback* dengan rentang waktu 10 Februari 2010 hingga 9 Maret 2025 dengan total sebanyak 4210 entri data harian. Berdasarkan observasi awal, ditemukan bahwa pada awal periode data (khususnya pada 2010), kolom *buyback* memiliki sejumlah nilai kosong (NaN) akibat belum dicatatkan secara konsisten. Untuk menangani hal ini, nilai kosong pada kolom *buyback* diisi sementara dengan harga *close* sebagai estimasi awal, lalu dilakukan metode *forward-fill* yaitu mengisi dengan nilai sebelumnya yang tersedia. Berikut cuplikan lima data teratas dan terbawah setelah proses pembersihan dilakukan :

Tabel 2. Sampel Dataset

<i>Date</i>	<i>Close (IDR)</i>	<i>Buyback (IDR)</i>
2010-02-10	342.000	342.000
2010-02-11	341.000	341.000
2010-02-12	343.000	343.000
2010-02-15	342.000	342.000
2010-02-16	343.000	343.000
...	...	...
2025-03-05	1.709.000	1.558.000
2025-03-06	1.706.000	1.555.000
2025-03-07	1.690.000	1.539.000
2025-03-08	1.690.000	1.539.000
2025-03-09	1.690.000	1.539.000

Selain nilai hilang, dilakukan juga deteksi dan penanganan *outliers* atau anomali ekstrem yang muncul akibat kesalahan input, yang disaring berdasarkan ambang batas harga minimum yang wajar sebesar Rp300.000. Nilai yang berada di bawah ambang ini dikonversi menjadi *NaN* dan diimputasi kembali menggunakan interpolasi linier untuk menjaga konsistensi data. Berikut visualisasi pergerakan harga emas close dan buyback setelah dilakukan pembersihan data:



Gambar 2. Grafik Pergerakan Harga Close dan Buyback Emas

Gambar 2 diatas menunjukkan tren pergerakan harga emas (close) dan harga buyback dari tahun 2010 hingga awal 2025. Harga emas secara umum menunjukkan pola tren naik jangka panjang, dengan fluktuasi yang semakin signifikan seiring waktu, terutama setelah tahun 2020. Hal ini dapat dikaitkan dengan berbagai dinamika ekonomi global, seperti pandemi COVID-19 dan ketidakpastian ekonomi internasional yang mendorong permintaan terhadap aset safe haven seperti emas. Terlihat bahwa harga close (garis kuning) secara konsisten lebih tinggi dibandingkan harga buyback (garis biru). Selisih ini merupakan margin yang wajar sebagai bagian dari biaya operasional dan keuntungan penjual [22]. Dengan telah dilakukannya pembersihan nilai kosong dan koreksi terhadap anomali input, grafik ini mencerminkan representasi data yang lebih akurat dan layak digunakan sebagai dasar pengembangan model prediksi.

3.2 Hasil Hyperparameter Tuning

Proses tuning hyperparameter dilakukan untuk memperoleh kombinasi nilai parameter yang optimal dalam membangun model XGBoost untuk prediksi harga emas. Tuning ini bertujuan untuk meningkatkan akurasi model dengan mengurangi nilai kesalahan yang dihasilkan selama proses prediksi, serta mencegah terjadinya overfitting maupun underfitting. Pada penelitian ini, proses tuning dilakukan menggunakan pendekatan *Bayesian Optimization*, yang dikenal efisien dalam mencari kombinasi parameter terbaik pada ruang pencarian yang besar dan kompleks. Optimasi dilakukan secara terpisah untuk dua target prediksi, yaitu harga Close dan harga Buyback, dengan meminimalkan nilai kesalahan kuadrat akar (Root Mean Squared Error/RMSE) sebagai fungsi objektif. Selama proses tuning, model dievaluasi menggunakan skema Walk Forward Validation dengan pendekatan sliding window sepanjang 14 hari dan proporsi data pelatihan sebesar 80% dari total data. Jumlah iterasi yang digunakan sebanyak 25 iterasi dengan 5 titik eksplorasi awal (init points). Hasil dari proses *Bayesian Optimization* terhadap kedua target disajikan pada Tabel 3 berikut:

Tabel 3. Nilai Hyperparameter Optimal

Parameter	Harga <i>Close</i>	Harga <i>Buyback</i>
<i>n_estimators</i>	408	800
<i>learning_rate</i>	0.266	0.050
<i>max_depth</i>	3	4
<i>subsample</i>	0.649	0.753
<i>colsample_bytree</i>	0.967	0.862
<i>gamma</i>	2.817	1.164
<i>lambda</i>	0.361	2.427
<i>alpha</i>	1.282	6.454

Tabel 3 menunjukkan hasil tuning hyperparameter menggunakan Bayesian Optimization untuk prediksi harga Close dan Buyback. Model harga Buyback membutuhkan jumlah pohon lebih banyak, yaitu 800, serta tingkat regularisasi lebih tinggi dengan lambda sebesar 2,427 dan alpha sebesar 6,454, menandakan perlunya pengendalian kompleksitas yang ketat. Sebaliknya, model harga Close menunjukkan hasil optimal pada 408 pohon dengan learning rate lebih tinggi, yakni 0,266, memungkinkan adaptasi lebih cepat terhadap perubahan harga. Kedalaman pohon pada kedua model cenderung dangkal, masing-masing 3 dan 4, guna mencegah overfitting. Nilai subsample dan colsample_bytree yang tinggi menunjukkan hampir seluruh data dan fitur digunakan saat pelatihan. Sementara itu, parameter gamma menunjukkan bahwa model Close memerlukan batas pemangkasan lebih besar dibanding Buyback. Kombinasi parameter optimal ini akan digunakan dalam pelatihan model sebelum dievaluasi performanya.

3.3 Evaluasi Performa Model dengan Skema *Walk Forward Validation*

Setelah kombinasi hyperparameter optimal diperoleh, selanjutnya dilakukan pengujian model dengan menerapkan skema *walk forward validation* dengan pendekatan *sliding window* yang menghasilkan total 59 *fold* data uji, di mana setiap *fold* mencakup 14 hari data pengamatan yang menguji kemampuan model dalam membuat prediksi pada data yang belum pernah dilihat sebelumnya secara berurutan dari waktu ke waktu. Evaluasi dilakukan pada setiap *fold* menggunakan dua metrik utama, yaitu RMSE dan MAPE untuk menilai tingkat kesalahan prediksi terhadap data aktual harga emas. Mengingat banyaknya jumlah *fold* yang dihasilkan, penyajian hasil evaluasi dalam artikel ini difokuskan pada lima *fold* awal dan lima *fold* terakhir sebagai representasi kinerja model di awal dan akhir periode pengujian. Selain itu, disertakan pula nilai rata-rata RMSE dan MAPE dari seluruh *fold* untuk menggambarkan performa agregat model secara keseluruhan. Hasil evaluasi performa model disajikan pada tabel 4 berikut :

Tabel 4. Evaluasi Performa Model Harga *Close* dan *Buyback*

<i>Fold</i>	Tanggal Awal Uji	Tanggal Akhir Uji	RMSE (<i>Close</i>)	MAPE (<i>Close</i>)	RMSE (<i>Buyback</i>)	MAPE (<i>Buyback</i>)
1	2022-11-12	2022-11-25	4341.01	0.38%	4963.01	0.45%
2	2022-11-26	2022-12-09	5850.38	0.48%	5891.10	0.52%
3	2022-12-10	2022-12-23	6553.85	0.52%	6811.94	0.66%
4	2022-12-24	2022-01-06	2711.59	0.21%	4144.79	0.35%
5	2023-01-07	2022-01-20	2303.49	0.19%	6149.97	0.53%
...	...	...	...	...	...	...
55	2024-12-19	2025-01-01	3541.38	0.18%	5108.72	0.32%
56	2025-01-02	2025-01-15	19178.89	1.10%	11714.90	0.69%
57	2025-01-16	2025-01-29	35073.01	1.94%	38304.51	2.46%
58	2025-01-30	2025-02-12	47405.85	2.58%	53198.21	3.17%
59	2025-02-13	2025-02-26	44080.41	2.42%	43401.00	2.59%
Rata-rata	-	-	15.431,92	1,03%	15.382,64	1,15%

Berdasarkan hasil evaluasi performa model pada Tabel 4, dapat disimpulkan bahwa model XGBoost mampu memberikan prediksi harga emas yang akurat. Pada periode awal pengujian, model mencatat nilai error yang rendah, seperti pada *fold* pertama dengan RMSE sebesar 4.341,01 dan MAPE 0,38% untuk harga *Close*, serta RMSE 4.963,01 dan MAPE 0,45% untuk harga *Buyback*. Di akhir periode, error meningkat, misalnya pada *fold* ke-59, RMSE mencapai 44.080,41 (*Close*) dan 43.401,00 (*Buyback*), dengan MAPE masing-masing 2,42% dan 2,59%. Peningkatan error ini bukan disebabkan oleh penurunan kinerja model, melainkan karena kenaikan harga emas yang signifikan pada periode tersebut. Mengingat RMSE mengukur kesalahan dalam satuan nilai absolut (IDR), kenaikan harga aktual turut memengaruhi besarnya nilai error. Secara keseluruhan, model menunjukkan performa prediksi yang konsisten dengan rata-rata MAPE 1,03% (*Close*) dan 1,15% (*Buyback*), yang mencerminkan tingkat kesalahan relatif yang rendah. Ini membuktikan bahwa model yang menggunakan konfigurasi hyperparameter dengan *Bayesian Optimization* mampu menangani dinamika pasar emas secara efektif.

3.3 Analisis Hasil Prediksi dan Visualisasi Model pada Data Uji


Untuk memberikan gambaran yang lebih konkret terkait akurasi hasil prediksi model XGBoost dengan fitur teknikal dan konfigurasi hyperparameter optimal, dilakukan perbandingan antara nilai harga aktual dengan nilai prediksi pada awal dan akhir periode pengujian. Perbandingan ini disajikan dalam bentuk tabel yang mencakup tanggal pengujian, nilai harga aktual dan nilai hasil prediksi model dalam satuan IDR/gram yang dapat dilihat pada tabel 5 di bawah ini.

Tabel 5. Nilai Hasil Prediksi Model Harga *Close* dan *Buyback*

Tanggal	Harga Aktual (<i>Close</i>)	Harga Prediksi (<i>Close</i>)	Harga Aktual (<i>Buyback</i>)	Harga Prediksi (<i>Buyback</i>)
2022-11-12	972.000,0	968.175,87	874.000	865.589,68
2022-11-13	972.000,0	977.145,68	874.000	871.217,81
2022-11-14	970.000,0	973.231,18	872.000	872.541,62
2022-11-15	973.000,0	980.469,06	875.000	879.101,12
2022-11-16	981.000,0	986.265,87	884.000	884.452,75
2022-11-17	981.000,0	984.200,25	886.000	885.561,25
2022-11-18	980.000,0	983.938,31	886.000	889.339,75
2022-11-19	978.000,0	977.398,56	884.000	891.032,68
...	...	...	...	...
2025-02-19	1.691.000,0	1.647.839,00	1.541.000	1.497.621,00
2025-02-20	1.708.000,0	1.656.097,25	1.558.000	1.507.343,87
2025-02-21	1.707.000,0	1.654.570,75	1.557.000	1.507.387,12
2025-02-22	1.704.000,0	1.653.863,37	1.554.000	1.504.752,00


2025-02-23	1.704.000,0	1.654.078,00	1.554.000	1.499.954,87
2025-02-24	1.705.000,0	1.654.237,50	1.555.000	1.499.935,62
2025-02-25	1.707.000,0	1.647.863,12	1.557.000	1.496.354,87
2025-02-26	1.694.000,0	1.625.834,12	1.544.000	1.479.495,75

Hasil pada tabel 5 menunjukkan bahwa prediksi model XGBoost untuk harga Close dan Buyback menunjukkan performa yang baik dan akurat sepanjang periode pengujian. Hal ini tercermin dari prediksi yang mengikuti nilai pergerakan harga aktual secara konsisten. Selisih yang relatif kecil pada nilai harga aktual dan hasil prediksi menunjukkan keakuratan model yang juga diperkuat oleh evaluasi numerik sebelumnya (tabel 4), di mana nilai rata-rata RMSE dan MAPE yang tergolong rendah, menunjukkan tingkat kesalahan prediksi yang rendah. Untuk memberikan gambaran yang lebih jelas terhadap kemampuan model dalam mengikuti pergerakan harga aktual, dilakukan visualisasi dalam bentuk grafik antara harga aktual dan harga prediksi. Gambar 3 berikut menampilkan grafik visualisasi guna menunjukkan sejauh mana prediksi model XGBoost mendekati nilai aktual harga *Close* selama periode pengujian.



Gambar 3. Grafik Perbandingan Nilai Aktual dan Prediksi Harga *Close*

Gambar 3 menampilkan perbandingan antara harga *Close* aktual (garis merah) dan hasil prediksi model XGBoost (garis biru) selama periode pengujian. Kedua garis bergerak secara berdekatan dan mengikuti pola yang sama, dengan deviasi yang relatif kecil di sebagian besar waktu pengujian. Pada pertengahan tahun 2024, terlihat adanya penyimpangan di mana prediksi tampak tertinggal dari lonjakan harga aktual. Meskipun demikian, visualisasi ini mengonfirmasi bahwa model mampu merepresentasikan tren harga emas dengan akurat, serta mendukung hasil evaluasi numerik sebelumnya yakni nilai RMSE dan MAPE rendah yang mencerminkan performa prediksi yang akurat dan generalisasi yang baik pada data uji. Untuk memberikan gambaran performa model dalam memprediksi harga *Buyback* emas, Gambar 4 berikut menyajikan perbandingan antara nilai aktual dan hasil prediksi selama periode pengujian.




Gambar 4. Grafik Perbandingan Nilai Aktual dan Prediksi Harga *Buyback*

Gambar 4 memperlihatkan perbandingan antara harga *Buyback* aktual dan hasil prediksi model XGBoost selama periode pengujian. Secara umum, garis prediksi mengikuti pola harga aktual dengan konsistensi yang tinggi, mencerminkan akurasi model yang baik. Meskipun terdapat deviasi kecil pada pertengahan tahun 2024, model tetap mampu mempertahankan kecocokan arah tren secara keseluruhan. Pola grafik pada Gambar 4 juga menunjukkan kemiripan yang kuat dengan Gambar 3, baik dari segi pergerakan maupun kedekatan prediksi terhadap nilai aktual. Konsistensi ini menegaskan kemampuan generalisasi model dalam memetakan dinamika harga *Close* dan *Buyback* yang secara ekonomi saling berkaitan.


3.5 Analisis Residual

Analisis residual ditujukan untuk memahami pola kesalahan prediksi model secara lebih mendalam, khususnya dalam mengidentifikasi apakah terdapat bias sistematis serta sejauh mana model mampu mengikuti dinamika harga emas yang sebenarnya. Gambar 5 berikut menampilkan residual pada model harga *Close* emas yang tersebar di sekitar nol.



Gambar 5. Sebaran Residual Model Prediksi Harga *Close*

Pada Gambar 5, sebagian besar residual tampak tersebar secara acak di sekitar angka nol, mengindikasikan bahwa model tidak menunjukkan kecenderungan bias sistematis, baik *overestimation* maupun *underestimation*. Namun demikian, terlihat adanya peningkatan nilai residual pada periode sekitar April 2024 dan awal 2025. Kenaikan residual ini terutama terjadi bersamaan dengan periode ketika harga emas mengalami lonjakan harga secara signifikan. Perubahan harga yang bersifat agresif dan dalam waktu dekat tersebut tampaknya tidak sepenuhnya dapat ditangkap oleh model, yang pada akhirnya menghasilkan deviasi yang lebih besar antara nilai aktual dan nilai hasil prediksi. Untuk melihat konsistensi pola ini, Gambar 6 berikut menampilkan residual prediksi pada model prediksi harga *Buyback* emas.




Gambar 6. Sebaran Residual Model Prediksi Harga *Buyback*

Gambar 6 menunjukkan pola residual dari hasil prediksi harga *Buyback* emas yang dihasilkan oleh model XGBoost. Secara umum, residual tersebar cukup merata di sekitar nol, menandakan bahwa prediksi model cenderung tidak menyimpang terlalu jauh dari nilai aktual dalam sebagian besar periode pengujian. Pola yang terbentuk relatif serupa dengan grafik residual harga *Close*, di mana lonjakan residual juga terlihat pada periode yang sama, yaitu sekitar April 2024 dan awal 2025, saat harga mengalami kenaikan drastis. Pola ini semakin memperkuat temuan bahwa model XGBoost cenderung kesulitan menangkap perubahan ekstrem yang tidak tercermin dalam pola historis, sehingga performa model sedikit menurun pada periode harga yang sangat dinamis. Kondisi ini menunjukkan keterbatasan dari XGBoost, yakni ketidakmampuannya mengekstrapolasi nilai di luar rentang data latih. Karena berbasis pohon keputusan, XGBoost hanya mampu memprediksi dalam kisaran pola historis yang telah dipelajari [23]. Ketika harga emas naik signifikan dan agresif pada waktu dekat melebihi nilai tertinggi sebelumnya, model tidak dapat mengikutinya secara akurat. Hal ini menyebabkan prediksi tertinggal dari harga aktual, menghasilkan residual besar serta peningkatan nilai RMSE dan MAPE pada akhir periode pengujian.

3.6 Feature Importance

Untuk memahami kontribusi masing-masing fitur dalam proses prediksi, dilakukan analisis *feature importance* berdasarkan nilai *F-Score* dari model XGBoost. Analisis ini bertujuan untuk mengidentifikasi fitur mana yang paling sering digunakan dalam membentuk pohon keputusan, sehingga dapat diketahui mana yang paling berpengaruh terhadap hasil prediksi model. Grafik *feature importance* yang memberikan visualisasi kontribusi masing-masing indikator teknikal dalam rekayasa fitur dapat dilihat pada Gambar 7, yang mengurutkan fitur berdasarkan tingkat kepentingannya dalam model prediksi harga *Close* dan *Buyback*.



Gambar 7. Feature importance Model Prediksi Harga *Close* dan *Buyback*

Gambar 7 memperlihatkan bahwa fitur MA_5 merupakan fitur yang paling sering digunakan dalam model prediksi baik untuk harga *Close* maupun *Buyback*, diikuti oleh indikator momentum lainnya seperti RSI, MACD, dan *signal_line*. Secara keseluruhan, hasil ini menunjukkan bahwa model lebih responsif terhadap pergerakan harga jangka pendek dan indikator teknikal berbasis momentum. Hasil *feature importance* juga menunjukkan keterkaitan yang erat dengan pendekatan sliding window yang digunakan dalam skema *walk-forward validation*. Hal ini mengindikasikan bahwa model XGBoost secara eksplisit mengandalkan informasi paling mutakhir dalam data historis untuk melakukan prediksi. Dengan demikian, penerapan sliding window berdurasi 14 hari memperkuat kecenderungan model dalam menangkap dinamika harga emas harian.

4. KESIMPULAN

Penelitian ini berhasil membangun model prediksi harga emas harian menggunakan algoritma Extreme Gradient Boosting (XGBoost) dengan memanfaatkan data historis harga logam mulia serta berbagai indikator teknikal sebagai fitur input. Model yang dikembangkan mampu memprediksi harga dengan cukup akurat, sebagaimana tercermin dari nilai evaluasi rata-rata RMSE sebesar 15.431,92 dan MAPE sebesar 1,03% untuk harga *close*, serta RMSE 15.382,64 dan MAPE 1,15% untuk harga *buyback*, yang telah dilakukan optimasi hyperparameter menggunakan Bayesian Optimization. Hasil ini menunjukkan bahwa model XGBoost yang dibangun mampu menangkap pola dan tren historis harga emas dengan baik, khususnya dalam konteks data uji yang relatif stabil. Meski demikian, terdapat deviasi prediksi yang ditandai dengan besaran deviasi prediksi terhadap harga aktual, seiring dengan kenaikan tajam harga emas aktual, yang turut mengindikasikan keterbatasan model dalam mengekstrapolasi pola harga di luar rentang data latih. Selain itu, fitur input yang digunakan dalam penelitian ini terbatas pada variabel teknikal yang berbasis harga historis, sehingga belum mampu sepenuhnya merepresentasikan faktor-faktor eksternal yang memengaruhi harga emas, seperti nilai tukar, suku bunga global, atau kondisi geopolitik. Oleh karena itu, disarankan agar penelitian selanjutnya mengintegrasikan variabel eksternal sebagai fitur tambahan dan mengeksplorasi pendekatan *hybrid model* seperti gabungan XGBoost dengan *Long Short-Term Memory (LSTM)* atau model *stacking ensemble* lainnya, yang secara teoritis mampu menggabungkan kekuatan model statistik dan pembelajaran dalam menangkap pola nonlinier dan jangka panjang dalam data harga komoditas.

REFERENCES

- [1] A. Tholib, N. K. Agusmawati, and F. Khoiriyah, "PREDIKSI HARGA EMAS MENGGUNAKAN METODE LSTM DAN GRU," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, Aug. 2023, doi: 10.23960/jitet.v11i3.3250.
- [2] R. A. Nadir and R. N. Sukmana, "Sistem Prediksi Harga Emas Berdasarkan Data Time Series Menggunakan Metode Artificial Neural Network (ANN)," *Digital Transformation Technology*, vol. 3, no. 2, pp. 426–437, Sep. 2023, doi: 10.47709/digitech.v3i2.2877.
- [3] R. F. Sholeh, B. A. Dermawan, and I. Maulana, "PERAMALAN HARGA EMAS DI INDONESIA MENGGUNAKAN ALGORITMA DOUBLE EXPONENTIAL SMOOTHING DAMPED TREND FORECASTING GOLD PRICE IN INDONESIA USING DOUBLE EXPONENTIAL SMOOTHING DAMPED TREND ALGORITHM," *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 4, no. 2, p. 2021.
- [4] S. Sholiha and W. U. Dewi, "Sciencestatistics Journal of Statistics, Probability, and Its Application Penggunaan ARIMA Box-Jenskin dalam Meramalkan Harga Emas Antam Tahun 2025-2027 di Indonesia," vol. 2, no. 2, pp. 59–69, 2024, [Online]. Available: <https://scholar.ummetro.ac.id/index.php/sciencestatistics/index>
- [5] A. Mulya Hadi, W. Witanti, J. Informatika, and U. Jenderal Achmad Yani, "Agustus 2024 486 PREDIKSI PERGERAKAN HARGA EMAS MENGGUNAKAN METODE GENETIC SUPPORT VECTOR REGRESSION," *Jurnal Informatika Teknologi dan Sains*.

- [6] P. Dipti and P. Trupti, "GOLD PRICE PREDICTION USING MACHINE LEARNING," *www.irjmets.com @International Research Journal of Modernization in Engineering*, [Online]. Available: www.irjmets.com
- [7] G. Cohen and A. Aiche, "Forecasting gold price using machine learning methodologies," *Chaos Solitons Fractals*, vol. 175, p. 114079, Oct. 2023, doi: 10.1016/J.CHAOS.2023.114079.
- [8] B. Jange, "Prediksi Harga Saham Bank BCA Menggunakan XGBoost," *ARBITRASE: Journal of Economics and Accounting*, vol. 3, no. 2, pp. 231–237, Nov. 2022, doi: 10.47065/arbitrase.v3i2.495.
- [9] D. N. Gono, H. Napitupulu, and Firdaniza, "Silver Price Forecasting Using Extreme Gradient Boosting (XGBoost) Method," *Mathematics*, vol. 11, no. 18, Sep. 2023, doi: 10.3390/math11183813.
- [10] B. Jiao and I. A. Fulton, "Gold Prediction Based on XGBoost and OLS," 2024.
- [11] M. R. Nurhambali, Y. Angraini, and A. Fitrianto, "Implementation of Long Short-Term Memory for Gold Prices Forecasting," *Malaysian Journal of Mathematical Sciences*, vol. 18, no. 2, pp. 399–422, 2024, doi: 10.47836/mjms.18.2.11.
- [12] Z. H. Kilimci, "Ensemble Regression-Based Gold Price (XAU/USD) Prediction," APA, 2022.
- [13] "Harga Emas Hari Ini." Accessed: May 29, 2025. [Online]. Available: https://pusatdata.kontan.co.id/market/logam_mulia
- [14] G. Huang, "Missing data filling method based on linear interpolation and lightgbm," in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Feb. 2021. doi: 10.1088/1742-6596/1754/1/012187.
- [15] "Data Preparation for XGBoost | XGBoosting." Accessed: May 29, 2025. [Online]. Available: <https://xgboosting.com/data-preparation-for-xgboost>
- [16] M. Anjas Aprihartha, M. Husniyati, and T. Nur Alam, "IMPLEMENTASI METODE RANDOM FOREST DALAM MEMREDIKSI SINYAL PERGERAKAN SAHAM," vol. 14, no. 1, pp. 43–49, doi: 10.24843/MTK.2025.v14.i01.p477.
- [17] M. Rizky Mubarak, R. Herteno, I. Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lambung Mangkurat Jalan Ahmad Yani Km, and K. Selatan, "HYPER-PARAMETER TUNING PADA XGBOOST UNTUK PREDIKSI KEBERLANGSUNGAN HIDUP PASIEN GAGAL JANTUNG."
- [18] A. Stuke, P. Rinke, and M. Todorovic, "Efficient hyperparameter tuning for kernel ridge regression with Bayesian optimization," *Mach Learn Sci Technol*, vol. 2, no. 3, Sep. 2021, doi: 10.1088/2632-2153/abee59.
- [19] S. Ben Jabeur, S. Mefteh-Wali, and J. L. Viviani, "Forecasting gold price with the XGBoost algorithm and SHAP interaction values," *Ann Oper Res*, vol. 334, no. 1–3, pp. 679–699, Mar. 2024, doi: 10.1007/s10479-021-04187-w.
- [20] H. Supriyanto, "A COMPARISON OF SUPERVISED LEARNING METHODS FOR FORECASTING TIME SERIES IN OUTSIDE PATIENT VISITS," vol. 10, no. 2, 2022.
- [21] Y. Syukriyah and A. Purnama, "Knowbase: International Journal of Knowledge in Database Modelling Time Series Data for Stock Prices Prediction Using Bidirectional Long Short-Term Memory Keywords RNN BiLSTM Time Series Data Stock Prices Correspondence," *International Journal of Knowledge in Database*, vol. 04, no. 02, pp. 115–129, doi: 10.30983/knowbase.v4i2.8759.
- [22] B. Pengelola and K. Haji, *Investasi Emas BPKH*. [Online]. Available: www.bpkh.go.id
- [23] "Interpretable Machine Learning." Accessed: May 29, 2025. [Online]. Available: <https://christophm.github.io/interpretable-ml-book/>