

Pengembangan Aplikasi Prediksi Harga Emas Berbasis Web Menggunakan Model Time Series

Fikrian Nur Abdullah ¹, Ridwana Septian Nurardian ², Amelliya ³,
Ari Setia Saputra ⁴, Atio Wahyudi Saputra ⁵, Waeisul Bismi ⁶

^{1,2,3,4,5,6}Universitas Bina Sarana Informatika, Jl. Kramat Raya No.98, Kota Jakarta Pusat, Daerah Khusus Ibukota Jakarta 10450,
Indonesia

Info Artikel

Riwayat Artikel:

Received 2025-06-30

Revised 2025-10-30

Accepted 2025-11-15

Corresponding Author:

Waeisul Bismi

Email: waeisul.wbn@bsi.ac.id



This is an open access
article under the [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/)
license.

Abstract – High gold price volatility due to global economic instability poses challenges in investment decision-making. This research aims to develop a web-based gold price prediction application using a time series model, focusing on the Gated Recurrent Unit (GRU) algorithm. This application is designed to present real-time, accurate, and easily accessible gold price predictions, thereby improving efficiency and transparency in investment decision-making. The development process starts from collecting and preprocessing daily gold price data for the period 2013-2023, then comparing four predictive models: LSTM, GRU, ARIMA, and XGBoost. Evaluation is performed using MAE, RMSE, and R^2 metrics. Results showed that GRU provided the best performance with an RMSE value of 17.76 and R^2 of 0.9410. The GRU model is integrated into a web application using the Flask framework, with an interactive HTML-based interface and Chart.js visualization. This application presents real-time gold price predictions and can be accessed by general users and investors. The results of this study show that the time series approach with GRU is effective in projecting gold prices, and can be a relevant tool in supporting data-based investment decisions.

Keywords: Gold price prediction; GRU; Machine learning; Time Series; Web Application.

Abstrak – Volatilitas harga emas yang tinggi akibat ketidakstabilan ekonomi global menimbulkan tantangan dalam pengambilan keputusan investasi. Penelitian ini bertujuan mengembangkan aplikasi prediksi harga emas berbasis web menggunakan model deret waktu, dengan fokus pada algoritma Gated Recurrent Unit (GRU). Aplikasi ini dirancang untuk menyajikan prediksi harga emas secara real-time, akurat, dan mudah diakses, sehingga meningkatkan efisiensi dan transparansi informasi untuk pengambilan keputusan investasi. Proses pengembangan dimulai dari pengumpulan dan prapemrosesan data harga emas harian periode 2013-2023, kemudian membandingkan empat model prediktif: LSTM, GRU, ARIMA, dan XGBoost. Evaluasi dilakukan menggunakan metrik MAE, RMSE, dan R^2 . Hasil menunjukkan bahwa GRU memberikan kinerja terbaik dengan nilai RMSE sebesar 17.76 dan R^2 sebesar 0.9410. Model GRU diintegrasikan ke dalam aplikasi web menggunakan framework Flask, dengan antarmuka interaktif berbasis HTML dan visualisasi Chart.js. Aplikasi ini menyajikan prediksi harga emas secara real-time dan dapat diakses oleh pengguna umum maupun investor. Hasil penelitian ini menunjukkan bahwa pendekatan time series dengan GRU efektif dalam memproyeksikan harga emas, serta dapat menjadi alat bantu yang relevan dalam mendukung keputusan investasi berbasis data.

Kata Kunci: Aplikasi Web, GRU, Prediksi Harga Emas, Pembelajaran Mesin, Time Series.

I. PENDAHULUAN

Ketidakpastian ekonomi global dalam beberapa tahun terakhir terus meningkat akibat berbagai faktor eksternal seperti konflik geopolitik, krisis energi, serta inflasi yang melonjak di sejumlah kawasan. Kondisi ini menyebabkan investor cenderung beralih pada instrumen yang dianggap lebih stabil dan aman. Emas, sebagai aset lindung nilai, menjadi pilihan utama karena kemampuannya dalam mempertahankan nilai di tengah guncangan ekonomi. Seperti diberitakan dalam [1], minat terhadap emas meningkat secara signifikan karena persepsi stabilitas tersebut. Di tingkat nasional, fluktuasi ekspor logam dasar mulia Indonesia sepanjang 2012 hingga 2023 menunjukkan ketergantungan yang tinggi terhadap pasar global [2], sehingga pergerakan harga emas dalam negeri menjadi tidak stabil dan sulit diprediksi.

Pergerakan harga emas yang sangat fluktuatif mendorong kebutuhan akan pendekatan prediktif yang lebih presisi. Penelitian oleh [3] menggunakan model *Long Short Term Memory (LSTM)* untuk memprediksi harga emas dunia dan mencatat tingkat kesalahan *MAPE* sebesar 2,70%. [4] menyatakan bahwa Model *Long Short Term Memory (LSTM)* telah terbukti efektif dalam memprediksi pergerakan harga saham, baik untuk saham syariah maupun non-syariah. Sementara itu, [5] membandingkan metode *ARIMA* dan *Fuzzy Time Series* dalam konteks harga emas di Indonesia dan menyimpulkan bahwa *Fuzzy* memberikan hasil lebih baik dalam menangani data yang fluktuatif. Di sisi lain, [6] mengembangkan sistem prediksi harga emas berbasis *Artificial Neural Network (ANN)* yang dinilai menjanjikan untuk prediksi jangka menengah. Penelitian oleh [7] turut

mengembangkan model *hybrid* antara *ARIMA* dan *RNN* yang berhasil meningkatkan akurasi. Hasil dari berbagai pendekatan ini belum menunjukkan konsistensi dalam performa, menandakan belum adanya metode dominan yang terbukti unggul dalam semua konteks.

Model *Gated Recurrent Unit (GRU)* mulai mendapatkan perhatian karena kemampuannya dalam mempelajari pola jangka panjang dengan struktur yang lebih sederhana dibanding *LSTM*. Penelitian oleh [8] menunjukkan bahwa *GRU* lebih efisien dalam pelatihan dan memberikan akurasi sedikit lebih tinggi daripada *LSTM*. Hal ini diperkuat oleh temuan [9], yang menunjukkan bahwa *GRU* mampu menghasilkan prediksi dengan nilai R^2 mencapai 0,97. Di tengah tingginya kebutuhan akan sistem informasi prediktif yang responsif, efisien, dan mudah diakses, *GRU* muncul sebagai solusi yang layak untuk diterapkan dalam sistem prediksi harga emas berbasis teknologi.

Dari berbagai pendekatan yang telah dikaji, metode *Gated Recurrent Unit (GRU)* menunjukkan performa paling optimal dalam meramalkan harga emas. Dibandingkan dengan *LSTM*, *GRU* memiliki struktur yang lebih sederhana dan efisiensi komputasi yang lebih tinggi, namun tetap mampu menghasilkan prediksi yang akurat. Karakteristik ini menjadikan *GRU* sebagai pilihan yang sangat sesuai untuk mengolah data deret waktu dengan volume besar dan fluktuasi tinggi seperti data harga emas. Keunggulan ini memberikan alasan kuat untuk mengimplementasikan *GRU* dalam sistem prediksi berbasis web yang bersifat interaktif dan informatif.

Data diambil dari [10] Dataset "*Gold Price (2013-2023).csv*" merupakan kompilasi data historis harga emas dari periode 2013 hingga 2023, yang esensial untuk analisis deret waktu guna mengungkap tren, pola musiman, dan hubungan antara harga emas dengan berbagai indikator ekonomi. Data ini umumnya mencakup informasi tanggal dan harga emas, serta dapat diperkaya dengan detail seperti harga pembukaan, tertinggi, terendah, penutupan, dan volume perdagangan, menjadikannya fundamental untuk studi ekonomi, permodelan keuangan, strategi investasi, dan analisis dinamika pasar dalam ranah publikasi ilmiah.



Time series merupakan data observasi yang tercatat secara berurutan dalam interval waktu tertentu. Untuk melakukan peramalan, penting mengidentifikasi pola data, yang umumnya terbagi menjadi empat jenis yaitu horizontal, musiman, siklis, dan tren [11]. Dengan adanya data berkala, pola pergerakan variabel dalam periode waktu tertentu dapat dianalisis, sehingga informasi ini menjadi dasar dalam pengambilan keputusan, peramalan kondisi di masa depan termasuk dalam sektor perdagangan dan ekonomi serta untuk keperluan perencanaan kegiatan di masa mendatang. *Long Short Term Memory (LSTM)* adalah salah satu varian khusus *Recurrent Neural Network (RNN)* yang diperkenalkan oleh Schmidhuber dan Hochreiter. *LSTM* dapat menanganai dependensi jangka panjang. *LSTM* bekerja menggunakan tiga gerbang yaitu *input*, *output*, dan *forget gates* [12]. Rangkaian modul jaringan syaraf berulang adalah karakteristik dari setiap jaringan syaraf berulang. Struktur *LSTM* sama, tetapi *LSTM* memiliki fitur tambahan, yaitu gerbang sel [13]. Model *ARIMA* merupakan salah satu metode dalam analisis deret waktu (*time series*) yang digunakan dengan asumsi bahwa data yang digunakan bersifat stasioner, yaitu memiliki rata-rata dan varian yang tetap sepanjang waktu [11]. *XGBoost* merupakan pengembangan dari algoritma *gradient boosting decision tree* yang dirancang untuk efisiensi dan kecepatan dalam membangun pohon keputusan berlapis (*boosted trees*). Metode ini umum digunakan dalam penyelesaian masalah regresi dan klasifikasi melalui pendekatan *Gradient Boosting Decision Tree (GBDT)*. *XGBoost* termasuk dalam kategori teknik *boosting*, yang menggabungkan sejumlah pohon keputusan di mana setiap pohon dibangun dengan memperhatikan hasil dari pohon sebelumnya. Dalam proses klasifikasi, algoritma ini akan melakukan penyesuaian bobot pada setiap iterasi, sehingga menghasilkan model pohon yang semakin kuat dan akurat [14]. *GRU (Gated Recurrent Unit)* adalah salah satu turunan dari arsitektur *LSTM* yang dikembangkan oleh Cho pada tahun 2014. Dibandingkan dengan *LSTM*, *GRU* memiliki struktur yang lebih sederhana namun tetap mempertahankan performa yang setara dalam memproses data sekuensial. Keunggulan *GRU* terletak pada kemampuannya mengatasi permasalahan *vanishing gradient* secara lebih efisien. Dengan hanya menggunakan dua gerbang (*gate*) dan tiga fungsi aktivasi, *GRU* mampu mempercepat proses komputasi, terutama dalam pengolahan data berskala besar, serta menunjukkan kinerja yang optimal pada dataset dengan jumlah data yang terbatas [15]. *Python* merupakan bahasa pemrograman tingkat tinggi yang banyak digunakan dalam dunia akademik dan industri karena struktur sintaksisnya yang sederhana serta kemampuannya dalam menangani berbagai kebutuhan analisis data. Menurut [16], *Python* memudahkan pengolahan dan visualisasi data melalui pustaka-pustaka seperti *NumPy*, *Pandas*, dan *Matplotlib*, sehingga sangat cocok diterapkan dalam pengembangan model *machine learning*. Bahasa ini juga dinilai adaptif untuk penelitian komputasi ilmiah karena mendukung berbagai paradigma pemrograman dan dapat dijalankan di berbagai platform. *Google Colaboratory* adalah platform berbasis *cloud* yang memungkinkan pengguna menjalankan kode *Python* secara daring tanpa instalasi lokal. Dengan dukungan pustaka bawaan serta akses *GPU* gratis, *Google Colaboratory* sangat mendukung pembelajaran dan eksperimen komputasi. Menurut [17], *Google Colaboratory* mempermudah pemula memahami *Python* karena tampilannya yang intuitif dan ramah pengguna. Sementara itu, [18] mencatat bahwa penerapan *Google Colaboratory* dalam pembelajaran di sekolah mampu meningkatkan pemahaman siswa terhadap logika pemrograman dan praktik analisis data secara langsung.

Penelitian ini bertujuan untuk merancang dan mengembangkan sebuah aplikasi web untuk prediksi harga emas dengan mengimplementasikan model yang paling optimal berdasarkan evaluasi terhadap empat algoritma *time series*, yaitu *ARIMA*, *LSTM*, *XGBoost*, dan *GRU*. Hasil analisis menunjukkan bahwa model *GRU* memiliki tingkat akurasi tertinggi dibandingkan model lainnya, sehingga dipilih untuk diintegrasikan ke dalam sistem aplikasi. Aplikasi ini tidak hanya menyajikan hasil prediksi secara visual dan interaktif, tetapi juga menampilkan data historis dan tren harga emas secara komprehensif. Dengan demikian, aplikasi ini diharapkan mampu menjadi alat bantu yang efektif dalam mendukung pengambilan keputusan investasi berbasis data, khususnya bagi pengguna yang membutuhkan akses informasi harga emas yang cepat, akurat, dan mudah dipahami.

Dengan kehadiran sistem ini, diharapkan masyarakat dan investor dapat mengambil keputusan yang lebih tepat terkait transaksi emas. Secara praktis, keunggulan utama sistem ini adalah kemampuannya menerjemahkan model prediksi *GRU* yang kompleks ke dalam antarmuka web yang interaktif dan *real-time*, sebuah implementasi yang masih jarang ditemukan pada penelitian sebelumnya yang cenderung berfokus murni pada akurasi model. Penggunaan *GRU* di dalam aplikasi berbasis web ini juga diharapkan dapat menjadi fondasi bagi pengembangan sistem prediksi komoditas lain yang rentan terhadap gejolak ekonomi global. Selain itu, penelitian ini juga diharapkan berkontribusi dalam memperkuat penerapan teknologi kecerdasan buatan di sektor ekonomi dan keuangan Indonesia, serta mendorong terciptanya inovasi digital yang adaptif terhadap kebutuhan pasar.

II. METODE

Penelitian ini mengadopsi pendekatan pengembangan perangkat lunak berbasis ilmu data, yang digambarkan secara visual dalam diagram alir (*flowchart*) penelitian seperti ditunjukkan pada Gambar 1.a.



Gambar 1. Tampilan diagram berupa (a) tahap alur penelitian dan (b) sistem arsitektur web

Gambar 1.b menjelaskan arsitektur sistem yang terbagi menjadi dua komponen utama: Pelatihan Model *Offline* dan Aplikasi Web *Online*.

1. Pelatihan Model *Offline* (Sisi Kiri): Ini adalah tahap riset yang dilakukan di *Google Colaboratory*. Peneliti mengambil data mentah (*CSV/Excel*), memprosesnya (*Pandas*, *Scikit-Learn*), dan melatih model *GRU* (*Keras/TensorFlow*). Output utamanya adalah file model terlatih (*gru_model.h5*) yang diekspor.

2. Aplikasi Web Online (Sisi Kanan): Ini adalah aplikasi *live* yang diakses pengguna. Peneliti membangun *Back-End* menggunakan *Python Flask*, yang saat berjalan akan memuat (*load*) file *gru_model.h5*. Pengguna berinteraksi melalui *Front-End (HTML/CSS/JS)*, mengirimkan *HTTP request* ke *Back-End*. *Back-End* kemudian menggunakan model untuk melakukan prediksi *real-time* dan mengirimkan hasilnya kembali ke pengguna.

A. Pengumpulan Data

Pengumpulan data merupakan fase fundamental dalam penelitian ini. Peneliti mengakuisisi data historis harga emas harian periode 2013-2023 dari *Kaggle* untuk pelatihan dan pengujian model. Data yang diunduh mencakup atribut Tanggal, Harga Penutupan, Harga Pembukaan, Harga Tertinggi, dan Harga Terendah. Peneliti mengeksklusi kolom Volume Perdagangan dan Persentase Perubahan Harga karena tidak relevan sebagai fitur maupun target dalam proses prediksi harga emas.

B. Preprocessing Data

Tahap prapemrosesan data sangat penting untuk memastikan kualitas dan format yang tepat bagi pelatihan model deret waktu. Proses ini dimulai dengan pembersihan data, yaitu menghilangkan kolom '*Vol.*' dan '*Change %*', memastikan tidak ada data yang hilang di kolom harga (*Price, Open, High, Low*), serta mengonversi '*Date*' ke format *datetime* dan mengurutkannya secara kronologis. Selanjutnya, peneliti menerapkan normalisasi data menggunakan *MinMaxScaler*, yang mengubah nilai fitur dan target ke rentang $[0, 1]$. Peneliti melakukan normalisasi ini terpisah untuk fitur dan target agar model dapat menggeneralisasi lebih baik. Kemudian, peneliti mengubah data ke format sekuensial yang sesuai untuk model deret waktu. Peneliti menggunakan data dari 60 hari sebelumnya (*lag window* = 60) untuk memprediksi harga di hari berikutnya. Pemilihan *window* 60 hari ini didasarkan pada asumsi bahwa pergerakan harga dalam dua bulan (sekitar 60 hari kalender) memiliki relevansi yang kuat untuk memprediksi tren jangka pendek. Nilai ini juga merupakan praktik umum dalam literatur prediksi finansial yang terbukti memberikan keseimbangan antara menangkap pola historis yang cukup dan menghindari *noise* berlebih. Terakhir, peneliti membagi dataset menjadi 80% data pelatihan dan 20% data pengujian secara kronologis. Rasio 80:20 ini dipilih karena merupakan standar umum (*common practice*) dalam pemodelan *machine learning* yang terbukti memberikan data yang cukup untuk pelatihan model (80%) sekaligus menyisakan porsi data yang representatif dan independen untuk pengujian (20%) tanpa menyebabkan *underfitting*. Pembagian dilakukan secara kronologis untuk menjaga dependensi temporal data, dengan 10% dari data pelatihan dijadikan set validasi internal untuk memantau kinerja model dan mencegah *overfitting*.

C. Pelatihan Model

Pada tahap ini, peneliti melatih dan mengevaluasi empat jenis model *time series* untuk memprediksi harga emas.

1) *Long Short Term Memory (LSTM)*: *LSTM* adalah jaringan saraf berulang yang menggunakan arsitektur dua lapisan memori (masing-masing 64 unit dengan *dropout* 0.2), lapisan *Dense* (32 unit, '*relu*'), dan lapisan *Dense* 1 unit untuk *output*. Peneliti mengoptimalkan model ini dengan '*adam*' dan *loss function* '*mse*', serta melatihnya selama 100 *epoch* dengan *batch size* 32 dan *EarlyStopping*.

2) *Gated Recurrent Unit (GRU)*: *GRU* memiliki arsitektur serupa *LSTM*, peneliti menggunakan dua lapisan *GRU* (masing-masing 64 unit), diikuti oleh *Dropout* (0.2), *Dense* (32 unit, '*relu*'), dan *Dense* (1 unit). Kompilasi dan pelatihan *GRU* juga menggunakan '*adam*' dan '*mse*' dengan parameter yang sama seperti *LSTM*.

3) *Autoregressive Integrated Moving Average (ARIMA)*: Peneliti menerapkan *ARIMA* pada data harga emas yang belum dinormalisasi. Peneliti menentukan parameter optimal (*p, d, q*) melalui *grid search* ($p \in [0, 5]$, $d \in [0, 1]$, $q \in [0, 2]$), dengan mengabaikan kombinasi yang gagal konvergen.

4) *XGBoost*: Peneliti melatih *XGBoost* menggunakan fitur *Open, High, Low*, serta nilai *lagged* dari 60 hari sebelumnya yang diratakan sebagai *input*. Konfigurasi model meliputi *objective='reg:squarederror'*, *n_estimators=200*, *max_depth=6*, *learning_rate=0.05*, *subsample=0.8*, *colsample_bytree=0.8*, *min_child_weight=1*, dan *random_state=42*.

D. Evaluasi Model

Peneliti melakukan evaluasi kinerja model pada data pengujian yang telah di-inverse transform untuk mengembalikan skala nilai prediksi ke skala aslinya. Metrik evaluasi yang diterapkan meliputi:

1) *Mean Absolute Error (MAE)*: *MAE* mengukur rata-rata selisih absolut antara nilai prediksi dan aktual. Metrik ini memberikan gambaran akurasi umum model dan memiliki sensitivitas yang lebih rendah terhadap outlier dibandingkan *RMSE*.

$$MAE = \frac{1}{n} \sum |y_i - \hat{y}_i|$$

2) *Root Mean Squared Error (RMSE)*: *RMSE* menghitung akar kuadrat dari rata-rata kuadrat selisih antara nilai prediksi dan aktual. Metrik ini lebih peka terhadap *outlier* atau kesalahan prediksi dengan magnitudo besar, menjadikannya relevan dalam konteks peramalan harga di pasar finansial.

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

3) *R-Squared (R^2)*: R^2 mengindikasikan proporsi varians dalam variabel dependen yang dapat dijelaskan oleh model. Nilai R^2 berkisar antara 0 hingga 1, di mana nilai 1 merepresentasikan model yang sangat baik dalam menjelaskan variansi data, sementara nilai 0 menunjukkan bahwa model tidak lebih baik daripada memprediksi rata-rata data. Penting untuk dicatat bahwa R^2 dapat bernilai negatif, mengindikasikan kinerja model yang lebih buruk dibandingkan dengan sekadar memprediksi rata-rata nilai aktual.

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}}$$

E. Penyimpanan Model

Peneliti menyimpan model terbaik, yaitu *GRU*, beserta objek *scaler* yang telah dilatih untuk mendukung implementasi dalam aplikasi web tanpa perlu pelatihan ulang. Peneliti menyimpan model *GRU* dalam format *.h5* yang mendukung penyimpanan arsitektur dan bobot secara utuh menggunakan *Keras*. Sementara itu, peneliti menyimpan objek *MinMaxScaler* untuk fitur (*scaler_X*) dan target (*scaler_Y*) menggunakan *joblib.dump*, yang efisien untuk menyimpan objek *Python* berbasis array *NumPy* dalam ukuran besar, sehingga mendukung pemrosesan data secara optimal pada tahap prediksi selanjutnya.

F. Integrasi ke Web

Peneliti mengimplementasikan tahap integrasi model ke dalam aplikasi web menggunakan *framework Flask*, yang dipilih karena sifatnya yang ringan, fleksibel, dan sangat kompatibel dengan ekosistem *Python*. Untuk keperluan *deployment* di lingkungan produksi, server berstandar *WSGI*, seperti *Gunicorn* atau *uWSGI*, menjamin performa dan stabilitas aplikasi.

G. Antarmuka Pengguna

Peneliti mengimplementasikan pengembangan antarmuka pengguna pada sisi klien menggunakan *HTML* untuk mendefinisikan struktur konten dan *CSS* untuk aspek stilistika visual. *JavaScript* menangani fungsionalitas interaktif, termasuk komunikasi asinkron dengan *backend*. Terakhir, peneliti mengintegrasikan *library Chart.js* guna menyajikan grafik tren historis dan hasil prediksi secara dinamis dan informatif.

III. HASIL DAN PEMBAHASAN

A. Hasil Pengumpulan Data

Data yang digunakan dalam penelitian ini diambil dari dataset “*Gold Price (2013–2023)*” dalam format *CSV*. Dataset ini memuat informasi harga emas harian mulai tahun 2013 hingga 2023 sebanyak 2584 baris dengan atribut seperti *Date*, *Price*, *Open*, *High*, *Low*, *Volume*, dan *Change (%)*.

Gambar 2. Menampilkan data harga emas harian yang mencakup sejumlah fitur seperti *Open*, *High*, *Low*, dan *Volume*. Dataset ini masih dalam tahap awal (mentah), sebagaimana ditunjukkan oleh keberadaan nilai yang hilang serta belum dilakukannya transformasi atau normalisasi data.

	Date	Price	Open	High	Low	Vol.	Change %
0	12/30/2022	1,826.20	1,821.80	1,832.40	1,819.80	107.50K	0.01%
1	12/29/2022	1,826.00	1,812.30	1,827.30	1,811.20	105.99K	0.56%
2	12/28/2022	1,815.80	1,822.40	1,822.80	1,804.20	118.08K	-0.40%
3	12/27/2022	1,823.10	1,808.20	1,841.90	1,808.00	159.62K	0.74%
4	12/26/2022	1,809.70	1,805.80	1,811.95	1,805.55	NaN	0.30%

Gambar 2. Cuplikan Dataset Menth


B. Hasil Preprocessing Data

Gambar 3. Menampilkan dataset yang telah melalui proses prapemrosesan awal, termasuk pengubahan kolom *Date* ke dalam format *datetime* serta penyeragaman tipe data numerik menjadi format *float*. Fitur-fitur yang dianggap tidak relevan telah disingkirkan, sehingga tersisa atribut utama seperti *Price*, *Open*, *High*, dan *Low*. Hasil pengecekan menunjukkan tidak terdapat nilai kosong maupun data yang duplikat. Dataset ini siap untuk digunakan dalam analisis lebih lanjut dan eksplorasi data visual (*EDA*).

	Date	Price	Open	High	Low
0	2013-01-02	1689.9	1675.8	1695.0	1672.1
1	2013-01-03	1675.6	1688.0	1689.3	1664.3
2	2013-01-04	1649.9	1664.4	1664.4	1630.0
3	2013-01-07	1647.2	1657.3	1663.8	1645.3
4	2013-01-08	1663.2	1651.5	1662.6	1648.8

Gambar 3. *Processed Data*

Gambar 4. menunjukkan matriks korelasi antar variabel numerik, yaitu *Price*, *Open*, *High*, dan *Low*. Seluruh pasangan variabel memiliki koefisien korelasi yang sangat tinggi, mendekati nilai 1.00, yang mencerminkan adanya hubungan linier yang kuat antar fitur tersebut. Fenomena ini dapat dimaklumi karena nilai harga pembukaan, tertinggi, terendah, dan penutupan dalam satu hari perdagangan umumnya mengikuti pola pergerakan yang serupa. Meskipun demikian, mengingat model *time series* berfokus pada pola temporal, proses normalisasi dan penyusunan data berdasarkan urutan waktu tetap diperlukan agar model dapat menangkap dinamika tren secara lebih efektif.



Gambar 4. Matriks Korelasi

Gambar 5. menampilkan tren harga emas dari tahun 2013 hingga 2023. Terlihat bahwa harga emas mengalami fluktuasi signifikan, dengan tren penurunan pada awal periode (2013-2015) dan mulai mengalami kenaikan sejak tahun 2019. Lonjakan harga paling tajam terjadi pada periode 2020 hingga awal 2021, diduga akibat kondisi ekonomi global saat pandemi *COVID-19*. Setelah mencapai puncaknya di atas *USD* 2000, harga emas kembali mengalami koreksi dan stabil di kisaran *USD* 1800-1900 hingga akhir 2022.



Gambar 5. Grafik Tren Harga Emas

Selanjutnya, data dipisahkan menjadi fitur (*Open, High, Low*) dan target (*Price*), lalu dilakukan normalisasi menggunakan *MinMaxScaler*. Data kemudian diubah ke dalam bentuk *sequence* sepanjang 60 data sebelumnya sebagai input untuk memprediksi harga emas pada hari ke-61. Pembagian data dilakukan menjadi data latih (80%) dan data uji (20%) tanpa melakukan pengacakan (*shuffle=False*) agar urutan waktu tetap terjaga.

C. Hasil Pelatihan Model

Model *GRU* dibangun menggunakan library *TensorFlow/Keras* dengan dua lapisan utama, dilengkapi dengan *Dropout* untuk mencegah *overfitting*, serta *EarlyStopping* untuk menghentikan pelatihan jika tidak terdapat peningkatan signifikan pada *validation loss*. Model dilatih menggunakan data yang telah diproses sebelumnya.


D. Hasil Evaluasi Model

Gambar 6 menyajikan hasil evaluasi model, di mana *GRU* menghasilkan nilai *Root Mean Squared Error (RMSE)* paling rendah sebesar 17.76, yang menunjukkan tingkat galat prediksi yang paling minimal di antara seluruh model yang dibandingkan. Selain itu, nilai koefisien determinasi (R^2) sebesar 0.9410 mendukung temuan ini, mengindikasikan bahwa model *GRU* mampu menjelaskan sekitar 94,10% variabilitas dalam data harga emas pada data uji.

Model Evaluation Results:		
LSTM	-> MAE: 14.80, RMSE: 19.31, R2: 0.9302	
GRU	-> MAE: 13.56, RMSE: 17.76, R2: 0.9410	
ARIMA	-> MAE: 142.10, RMSE: 157.58, R2: -3.6410	
XGB	-> MAE: 23.77, RMSE: 30.52, R2: 0.8256	

Gambar 6. Hasil Evaluasi Model

Gambar 7. menyajikan perbandingan antara hasil prediksi harga emas oleh model *GRU* dengan data aktual pada data uji. Berdasarkan visualisasi tersebut, terlihat bahwa model *GRU* mampu merekonstruksi pola pergerakan harga emas secara akurat, menunjukkan kesesuaian yang tinggi antara nilai prediktif dan nilai observasi.




Gambar 7. Grafik Prediksi Harga Emas Model *GRU*

E. Hasil Penyimpanan Model

Model *GRU*, yang menunjukkan performa terbaik, disimpan dalam format *HDF5 (.h5)* guna memungkinkan pemanfaatan kembali tanpa perlu dilakukan pelatihan ulang. Selain itu, objek *MinMaxScaler* untuk fitur dan target diserialisasi menggunakan *joblib* untuk memastikan konsistensi skala data selama proses *deployment* dan prediksi pada tahap implementasi di masa mendatang.

F. Hasil Integrasi ke Web

Tahap ini merupakan proses integrasi model *GRU* hasil pelatihan ke dalam aplikasi web berbasis *Flask* terlihat pada gambar 8. *Framework Flask* dipilih karena ringan, fleksibel, dan mudah dikombinasikan dengan library *Python* lain seperti *TensorFlow*, *NumPy*, dan *joblib*.




Gambar 8. Alur Proses Pembuatan Sistem

Proses sistem prediksi dimulai dengan akuisisi data *input* (*Price, Open, High, Low*) dari pengguna melalui antarmuka web, yang kemudian divalidasi untuk integritas numerik. Data yang valid dinormalisasi menggunakan *MinMaxScaler* yang telah tersimpan sebelum dimuatnya model *Gated Recurrent Unit (GRU)* berformat .h5. Untuk menghasilkan prediksi, input yang telah dinormalisasi digabungkan dengan 59 data historis terakhir guna membentuk sekuens deret waktu sebagai masukan bagi model *GRU*. Hasil prediksi kemudian ditampilkan pada halaman web, sementara setiap transaksi prediksi didokumentasikan dalam file riwayat dan seluruh aktivitas sistem dicatat dalam berkas *log* untuk tujuan penelusuran dan *debugging*.

G. Hasil Antarmuka Pengguna

Antarmuka pengguna aplikasi dirancang secara responsif untuk menyajikan fungsionalitas utama secara intuitif. Fitur sentral memungkinkan pengguna untuk memasukkan data harga (*open, high, dan low*) melalui formulir input untuk menghasilkan prediksi harga emas secara langsung. Selain itu, aplikasi menyediakan fitur pendukung untuk mengakses riwayat prediksi, di mana data historis disajikan dalam format tabular maupun dalam bentuk visualisasi grafik tren. Seluruh data riwayat ini diperbarui secara otomatis setelah setiap proses prediksi berhasil dilakukan.



(a)



Waktu	Open	High	Low	Prediksi Harga
2025-05-25 11:35:22	1500.0	1800.0	1300.0	1533.8409
2025-05-25 11:37:31	1500.0	1800.0	1300.0	1278.167
2025-05-25 11:50:38	1500.0	1800.0	1300.0	1553.3381
2025-05-25 13:03:32	1700.0	1800.0	1600.0	1691.6472
2025-06-02 17:03:24	1700.0	1800.0	1600.0	1691.6472
2025-06-11 19:50:21	1600.0	1500.0	1300.0	1428.6409
2025-06-11 20:07:08	1400.0	1500.0	1200.0	1318.295
2025-06-21 19:05:22	1200.0	1300.0	1100.0	1278.167

(b)



(c)

Gambar 9. Tampilan website berupa (a) halaman input, (b) halaman tabel riwayat prediksi dan (c) halaman grafik riwayat prediksi

H. Analisis Kritis dan Implikasi

Hasil penelitian secara definitif menunjukkan keunggulan model *Gated Recurrent Unit (GRU)* dengan perolehan nilai R^2 tertinggi sebesar 0.9410 dan *RMSE* terendah 17.76, menegaskan bahwa arsitektur *GRU* yang lebih sederhana dan efisien secara komputasi sangat efektif dalam memodelkan data deret waktu dengan volatilitas tinggi seperti harga emas. Performa optimal ini sejalan dengan studi terdahulu yang juga menemukan *GRU* lebih unggul dalam prediksi harga emas dibandingkan *LSTM*, dan meskipun sedikit di bawah nilai R^2 0.97 yang dicapai dalam studi lain, hasil ini memvalidasi keandalan model di sektor finansial. Secara praktis, kontribusi utama penelitian ini adalah keberhasilan integrasi model *GRU* yang kompleks ke dalam aplikasi web berbasis *Flask* yang interaktif dan *real-time*, menjadikannya alat bantu keputusan investasi yang mudah diakses dan mendukung *data-driven investment decision support system*. Meskipun demikian, penelitian ini memiliki keterbatasan karena model hanya memanfaatkan data harga historis (*Open, High, Low*) dan belum mempertimbangkan faktor eksternal yang krusial seperti konflik geopolitik atau kebijakan moneter, yang menjadi fokus rekomendasi untuk pengembangan model *hybrid* di riset lanjutan.

IV. SIMPULAN

Pengembangan aplikasi web prediksi harga emas dalam penelitian ini, yang mengandalkan model *Gated Recurrent Unit (GRU)*, sukses mencapai keunggulan performa (*RMSE* 17.76; R^2 0.9410) dibandingkan model komparator seperti *LSTM*, *ARIMA*, dan *XGBoost*, serta berkontribusi sebagai alat bantu keputusan investasi *real-time* yang aksesibel. Meskipun demikian, model ini memiliki keterbatasan krusial akibat dependensinya yang eksklusif pada data historis (*Open, High, Low*) dan cakupan data yang terbatas pada periode 2013-2023. Untuk itu, rekomendasi riset lanjutan difokuskan pada adopsi model *hybrid* yang memperhitungkan faktor eksternal (misalnya, sentimen pasar atau kebijakan moneter), eksplorasi arsitektur *transformer* untuk dependensi jangka panjang, dan pengembangan aplikasi *mobile* untuk jangkauan pengguna yang lebih luas.

UCAPAN TERIMA KASIH

Ucapan terima kasih yang besar kepada Universitas Bina Sarana Informatika yang sudah memberikan banyak pembelajaran selama masa studi. Dan untuk dosen pembimbing terimakasih atas dedikasi yang diberikan dalam melakukan publikasi karya ilmiah ini.

DAFTAR PUSTAKA

- [1] Dea Duta Aulia, "Ketidakpastian Ekonomi Global Tinggi, Investasi Emas Masih Seksi?" Accessed: Jun. 21, 2025. [Online]. Available: <https://finance.detik.com/berita-ekonomi-bisnis/d-7880453/ketidakpastian-ekonomi-global-tinggi-investasi-emas-masih-seksi>
- [2] Badan Pusat Statistik, "Ekspor Logam Dasar Mulia Menurut Negara Tujuan Utama, 2012-2023." Accessed: Jun. 21, 2025. [Online]. Available: <https://www.bps.go.id/id/statistics-table/1/MjAzNCMx/ekspor-logam-dasar-mulia-menurut-negara-tujuan-utama--2012-2023.html11:19:14>
- [3] T. G. Lasijan, R. Santoso, and A. R. Hakim, "Prediksi Harga Emas Dunia Menggunakan Metode Long-Short Term Memory," *Jurnal Gaussian*, vol. 12, no. 2, pp. 287–295, 2023, doi: 10.14710/j.gauss.12.2.287-295.
- [4] E. Nurmawati, R. Abaysa, and R. A. Putra, "Optimalisasi Portofolio Saham Syariah Berbasis Prediksi Menggunakan Long Short-Term Memory (LSTM)," *Jurnal Informatika: Jurnal pengembangan IT*, vol. 10, no. 2, pp. 464–475, 2025, doi: 10.30591/jpit.v10i2.8421.
- [5] A. F. Ashilla, "Peramalan Harga Emas Indonesia Menggunakan Metode ARIMA Dan Fuzzy Time Series Algoritma Model Chen," Institut Teknologi Sepuluh November, 2022. doi: 10.25077/jmu.8.2.45-52.2019.
- [6] 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, 2023, doi: 10.47709/digitech.v3i2.2877.
- [7] M. A. Gustiansyah *et al.*, "Aplikasi Model ARIMA dalam Peramalan Data Harga Emas Dunia Tahun 2010-2022," *Jurnal Statistika dan Aplikasinya*, vol. 7, no. 1, pp. 84–92, 2023, doi: 10.21009/jsa.07108.
- [8] A. P. Meriani and A. Rahmatulloh, "Perbandingan Gated Recurrent Unit (GRU) Dan Algoritma Long Short Term Memory (LSTM) Linear Refression Dalam Prediksi Harga Emas Menggunakan Model Time Series," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 1, 2024, doi: 10.23960/jitet.v12i1.3808.
- [9] C. Tanudy, T. Handhayani, and J. Hendryli, "Prediksi Harga Emas di Indonesia Menggunakan Gated Recurrent Unit," *Jurnal Fasilkom*, vol. 13, no. 3, pp. 480–488, 2023, doi: 10.37859/jf.v13i3.6185.
- [10] Manu Siddhartha, "Gold Price Dataset." [Online]. Available: <https://www.kaggle.com/datasets/sid321axn/gold-price-prediction-dataset>
- [11] F. N. Sorlury, C. E. Mongi, and N. Nainggolan, "Penggunaan Model Autoregressive Integrated Moving Average (ARIMA) Untuk Meramalkan Nilai Tukar Petani (NTP) di Provinsi Sulawesi Utara," *Jurnal Matematika dan Aplikasi*, vol. 11, no. 1, pp. 59–66, 2022, [Online]. Available: <https://ejournal.unsrat.ac.id/index.php/decartesian>
- [12] S. A. Tussifah, "Analisis Perbandingan Kinerja Model ARIMA, LSTM Dan GRU Pada Stock Price Forecasting," Universitas Islam Negeri Syarif Hidayatullah, 2022.
- [13] F. Fauzi, S. Aulia, A. R. Syaifullah, and T. W. Utami, "Peramalan Harga Emas Menggunakan Pendekatan Long-Short Term Memory (LSTM)," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, pp. 252–257, 2024.
- [14] M. D. Maulana, A. Id Hadiana, and F. R. Umbara, "Algoritma Xgboost Untuk Klasifikasi Kualitas Air Minum," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 5, pp. 3251–3256, 2024, doi: 10.36040/jati.v7i5.7308.
- [15] N. K. Agusmawati, F. Khoiriyah, and A. Tholib, "Prediksi Harga Emas Menggunakan Metode LSTM Dan GRU," *Jurnal*

- Informatika dan Teknik Elektro Terapan*, vol. 11, no. 1, pp. 32–36, 2023, doi: <https://doi.org/10.23960/jitet.v11i3.3250>.
- [16] M. R. S. Alfarizi, M. Z. Al-farish, M. Taufiqurrahman, G. Ardiansah, and M. Elgar, “Penggunaan Python Sebagai Bahasa Pemrograman untuk Machine Learning dan Deep Learning,” *Karya Ilmiah Mahasiswa Bertauhid (KARIMAH TAUHID)*, vol. 2, no. 1, pp. 1–6, 2023.
- [17] F. Wilyani, Q. N. Arif, and F. Aslimar, “Pengenalan Dasar Pemrograman Python Dengan Google Colaboratory,” *Jurnal Pengabdian Pada Masyarakat Indonesia (JPPMI)*, vol. 3, no. 1, pp. 08–14, 2024, doi: 10.55606/jppmi.v3i1.1087.
- [18] H. U. Anjani, V. Vitriani, and M. Hastuti, “Pemanfaatan Media Google Colaboratory Pada Mata Pelajaran Informatika di SMA Negeri 5 Pekanbaru,” *SOKO GURU: Jurnal Ilmu Pendidikan*, vol. 4, no. 1, pp. 101–108, 2024, doi: 10.55606/sokoguru.v4i1.3613.