

Komparasi LSTM dan GRU untuk Prediksi Harga Emas Berdasarkan Inflasi, Nilai Tukar, Suku Bunga

Comparison of LSTM and GRU for Gold Price Prediction Based on Inflation, Exchange Rate, Interest Rate

*¹Moh. Wahyu Abrory, ²Rizka Hadiwiyan, ³Nambi Sembilu

^{1,2,3}Program Studi Sistem Informasi, Fakultas Ilmu Komputer, UPN "Veteran" Jawa Timur

E-mail: ¹*22082010075@student.upnjatim.ac.id, ²rizkahadiwiyan.si@upnjatim.ac.id,

³nambi.si@upnjatim.ac.id

Abstrak

Emas merupakan aset strategis yang banyak dimanfaatkan sebagai instrumen lindung nilai di Indonesia, dengan harga yang dipengaruhi oleh faktor makroekonomi domestik seperti inflasi, suku bunga acuan Bank Indonesia, dan nilai tukar USD/IDR. Model statistik klasik seperti ARIMA memiliki keterbatasan dalam menangkap pola non-linear dan ketergantungan jangka panjang pada data deret waktu finansial. Penelitian ini membandingkan performa dua algoritma deep learning, yaitu Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU), dalam memprediksi harga emas harian ANTAM LM berdasarkan variabel makroekonomi tersebut. Data yang digunakan mencakup periode Januari 2015 hingga September 2025, bersumber dari PT Antam, Bank Indonesia, dan Investing.com. Proses penelitian meliputi pengumpulan data, preprocessing, eksplorasi data, split dataset, pemodelan dengan hyperparameter tuning, serta evaluasi menggunakan metrik RMSE dan MAPE. Data dibagi ke tiga skenario split yaitu 70:30, 80:20, dan 90:10. Hasil evaluasi menunjukkan bahwa GRU memberikan performa terbaik pada skema split 90:10 dengan RMSE sebesar Rp35.417,91 dan MAPE sebesar 1,47%, lebih unggul dibandingkan LSTM terbaik dengan RMSE sebesar Rp96.808,45 dan MAPE sebesar 4,58%. Model GRU diimplementasikan ke dalam aplikasi web berbasis Flask dan React sebagai alat bantu pengambilan keputusan investasi emas.

Kata kunci: Prediksi Harga Emas, LSTM, GRU, Deep Learning, Makroekonomi

Abstract

Gold is a strategic asset widely used as a hedging instrument in Indonesia, with its price influenced by domestic macroeconomic factors including inflation, Bank Indonesia's benchmark interest rate, and the USD/IDR exchange rate. Classical statistical models such as ARIMA have limitations in capturing non-linear patterns and long-term dependencies in financial time series data. This study compares the performance of two deep learning algorithms, Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU), in predicting the daily price of ANTAM LM gold based on the aforementioned macroeconomic variables. Data covering the period from January 2015 to September 2025 were obtained from PT Antam, Bank Indonesia, and Investing.com. The research process included data collection, preprocessing, exploratory data analysis, dataset splitting under three schemes (70:30, 80:20, and 90:10), model training with hyperparameter tuning, and evaluation using RMSE and MAPE metrics. Results demonstrated that GRU achieved the best performance under the 90:10 split scheme with an RMSE of IDR 35,417.91 and a MAPE of 1.47%, outperforming the best LSTM model which recorded an RMSE of IDR 96,808.45 and a MAPE of 4.58%. The best-performing GRU model was deployed into a Flask and React-based web application serving as a tool for investment decision-making.

Keywords: Gold Price Prediction, LSTM, GRU, Deep Learning, Macroeconomics

1. PENDAHULUAN

Emas merupakan salah satu komoditas logam mulia yang banyak digunakan sebagai instrumen investasi, penyimpan nilai, dan aset lindung nilai. Dalam catatan sejarah, emas telah digunakan sebagai alat tukar yang sah, yang nilainya diakui dan dapat diperjualbelikan di berbagai kondisi pasar, menjadikannya aset yang likuid dan universal [1]. Di Indonesia, salah satu produk emas yang paling dikenal adalah emas batangan Logam Mulia ANTAM LM yang diproduksi oleh PT Aneka Tambang Tbk (ANTAM), dengan kadar kemurnian 99,99 persen atau 24 karat dan telah tersertifikasi resmi oleh *London Bullion Market Association* (LBMA) [2].

Harga emas di pasar domestik tidak hanya bergerak mengikuti fluktuasi harga global, tetapi juga dipengaruhi oleh faktor-faktor internal seperti tingkat inflasi nasional, suku bunga acuan Bank Indonesia, serta pergerakan kurs USD terhadap IDR [3]. Sepanjang paruh pertama tahun 2025, harga emas batangan ANTAM mengalami lonjakan signifikan dari Rp1.515.000 per gram pada Januari menjadi Rp1.896.000 per gram pada Juli, meningkat sekitar 25,1% [4]. Kondisi ini mendorong kebutuhan akan sistem prediksi harga emas yang akurat guna mendukung pengambilan keputusan investasi.


Model statistik klasik seperti *ARIMA* telah banyak digunakan untuk memprediksi harga emas, namun performanya menjadi kurang optimal ketika diterapkan pada kondisi pasar yang kompleks dengan tren tidak stabil, hubungan temporal antar variabel, dan tingkat volatilitas tinggi. Penelitian yang membandingkan *ARIMA* dengan *Support Vector Machine (SVM)* menemukan bahwa *MAPE SVM* sebesar 2,5 jauh lebih rendah dibandingkan *MAPE ARIMA* yang mencapai 2897,59, menyoroti kelemahan utama *ARIMA* dalam mengenali pola jangka panjang [5].

Tren penelitian terbaru menunjukkan bahwa pendekatan *deep learning* lebih unggul dibandingkan model klasik dalam memprediksi harga komoditas. Studi yang mengevaluasi berbagai model *machine learning* dan *deep learning* pada prediksi harga logam menemukan bahwa *Stacked LSTM* menghasilkan *MAPE* 0,74% dan *GRU* sebesar 0,79%, secara konsisten melampaui *SVM*, *XGBoost*, dan *ARIMA* [6]. Penelitian lain membuktikan bahwa *LSTM* menghasilkan *RMSE* 8,124 dan *MAPE* 0,023 pada prediksi harga emas global, jauh lebih baik dari *ARIMA* dengan *RMSE* 43,599 dan *MAPE* 0,185 [7].

Berdasarkan kajian literatur, belum ditemukan studi yang secara langsung membandingkan *LSTM* dan *GRU* untuk prediksi harga emas ANTAM LM dengan variabel inflasi, suku bunga BI, dan kurs *USD/IDR* dalam konteks Indonesia. Penelitian ini mengisi kesenjangan tersebut dengan membandingkan efektivitas kedua algoritma menggunakan tiga indikator makroekonomi domestik yang dipilih berdasarkan bukti empiris bahwa ketiga faktor tersebut memiliki dampak paling signifikan dan langsung terhadap dinamika harga emas di pasar Indonesia [8]. Hasil akhir penelitian ini berupa sistem web interaktif berbasis *Flask* dan *React* yang memungkinkan pengguna memilih durasi prediksi secara fleksibel sebagai alat bantu investasi.

2. METODOLOGI PENELITIAN

Penelitian ini mengikuti alur sistematis mulai dari studi literatur, analisis kebutuhan, pengumpulan data, *preprocessing*, eksplorasi data (*EDA*), pembagian data, pemodelan, evaluasi model, hingga implementasi sistem berbasis web.



Gambar 1. Alur Penelitian

Gambar 1 menunjukkan alur penelitian yang digunakan secara keseluruhan. Proses dimulai dari studi literatur untuk membangun landasan teori, dilanjutkan dengan analisis kebutuhan data dan perangkat, pengumpulan data dari sumber resmi, *preprocessing* untuk menyeragamkan struktur data, EDA untuk memahami karakteristik data, pembagian data ke skenario *split*, pemodelan *LSTM* dan *GRU* dengan *hyperparameter tuning*, evaluasi menggunakan *RMSE* dan *MAPE*, hingga implementasi model terbaik ke dalam aplikasi web.

2.1. Data dan Variabel Penelitian

Data yang digunakan mencakup empat variabel utama dalam periode Januari 2015 hingga September 2025, menghasilkan 3.926 observasi. Harga emas harian ANTAM LM diperoleh dari *endpoint API* situs Logam Mulia (*logammulia.com*). Data kurs *USD/IDR* harian diperoleh dari Investing.com. Data inflasi dan suku bunga acuan BI diperoleh dari situs resmi Bank Indonesia dalam frekuensi bulanan.

Variabel harga emas berperan sebagai variabel dependen, sedangkan inflasi, suku bunga, dan kurs *USD/IDR* merupakan variabel independen. Penelitian ini tidak memasukkan variabel ketidakpastian global seperti indeks EPU atau GPR karena fokus ditujukan pada determinan makroekonomi domestik yang lebih konsisten dan relevan terhadap konteks pasar Indonesia [9].

2.2. Data Preprocessing

Tahap *preprocessing* mencakup konversi format tanggal, penyeragaman granularitas waktu, penanganan *missing value*, konversi tipe data numerik, dan *feature engineering*. Data inflasi dan suku bunga yang tersedia secara bulanan dikonversi ke frekuensi harian menggunakan metode *forward fill*. *Missing value* ditangani dengan *forward fill* dan *backward fill* untuk menjaga kesinambungan data *time series*.

Feature engineering menghasilkan 19 fitur yang digunakan secara konsisten pada proses *training* dan inferensi. Fitur tersebut mencakup: (1) variabel makroekonomi dasar (*usd_idr*, *inflation*, *interest_rate*); (2) *lag features* (*gold_price_lag_1*, *gold_price_lag_7*, *gold_price_lag_14*, *usd_idr_lag_1*, *usd_idr_lag_7*); (3) *moving average* (*gold_price_ma_7*, *gold_price_ma_14*, *gold_price_ma_30*, *usd_idr_ma_7*); (4) fitur volatilitas (*gold_price_std_7*, *gold_price_std_14*, *usd_idr_std_7*); dan (5) fitur momentum (*gold_price_pct_1*, *gold_price_pct_7*, *usd_idr_pct_1*, *usd_idr_pct_7*).

2.3. Arsitektur Model LSTM dan GRU

Long Short-Term Memory (LSTM) merupakan varian *RNN* yang dikembangkan oleh Hochreiter dan Schmidhuber untuk mengatasi masalah *vanishing gradient* [10]. *LSTM* memiliki tiga gerbang utama yaitu *forget gate*, *input gate*, dan *output gate* dengan mekanisme *cell state* untuk menyimpan informasi jangka panjang. Persamaan matematis *LSTM* adalah sebagai berikut:

$$\begin{aligned}f_t &= \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\\tilde{C}_t &= \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \\C_t &= f_t * C_{t-1} + i_t * \tilde{C}_t \\o_t &= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\h_t &= o_t * \tanh(C_t)\end{aligned}$$

Gated Recurrent Unit (GRU) merupakan varian *RNN* yang lebih sederhana dengan dua gerbang utama, yaitu *update gate* dan *reset gate*, tanpa *output gate* terpisah [11] [12]. Struktur ini membuat *GRU* lebih ringan secara komputasi namun tetap mampu mempelajari ketergantungan temporal. Persamaan *GRU* adalah:

$$\begin{aligned}z_t &= \sigma(W_z \cdot [h_{t-1}, x_t]) \\r_t &= \sigma(W_r \cdot [h_{t-1}, x_t]) \\\tilde{h}_t &= \tanh(W \cdot [r_t * h_{t-1}, x_t]) \\h_t &= (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t\end{aligned}$$

Kedua model dibangun dengan dua *layer recurrent* masing-masing 128 unit (sebelum *tuning*), diikuti *dropout*, *dense layer* 32 unit dengan *aktivasi ReLU*, dan *output layer 1 neuron*. *Input shape* adalah (60, 19) yang merepresentasikan 60 *timestep lookback* dan 19 fitur.

2.4. Data Splitting dan Normalisasi

Dataset dibagi ke tiga skenario *split* secara kronologis: 70:30, 80:20, dan 90:10. Pembagian dilakukan secara berurutan berdasarkan waktu untuk mencegah data *leakage*. Normalisasi menggunakan *MinMaxScaler* diterapkan terpisah untuk fitur (*scaler_X*) dan target (*scaler_y*), dengan parameter dihitung hanya dari data training kemudian diterapkan ke data pengujian. Data yang telah dinormalisasi diubah menjadi *sequence* dengan *lookback window* 60 hari.

2.5. Hyperparameter Tuning

Hyperparameter tuning dilakukan menggunakan *grid search* dengan ruang pencarian yang identik untuk *LSTM* dan *GRU* agar perbandingan berlaku adil. Parameter yang diuji meliputi jumlah *unit per layer* (64, 128, 256), *dropout rate* (0,0; 0,05; 0,1), dan *learning rate* (0,0001; 0,0005; 0,001). Kombinasi ketiga parameter menghasilkan 27 konfigurasi per model. Validasi dilakukan menggunakan *TimeSeriesSplit* dengan tiga *fold*. *Early stopping* diterapkan untuk mencegah *overfitting*.

2.6. Metrik Evaluasi

Evaluasi model menggunakan dua metrik yang saling melengkapi. *Root Mean Square Error (RMSE)* mengukur rata-rata besarnya kesalahan prediksi dalam satuan rupiah:

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

Mean Absolute Percentage Error (MAPE) mengukur tingkat kesalahan dalam bentuk persentase yang lebih mudah dibandingkan antar konteks:

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

2.7. Implementasi Sistem Web

Model terbaik diintegrasikan ke dalam aplikasi web dengan arsitektur terpisah antara *backend Flask* dan *frontend React*. Backend berperan sebagai server inferensi yang memuat model *GRU*, *scaler*, dan *metadata*, serta menyediakan *API endpoint* untuk *upload dataset*, prediksi asinkron, *monitoring job*, dan ekspor hasil. *Frontend* menyediakan antarmuka halaman *Dashboard*, halaman Prediksi, dan halaman Data Historis. Prediksi *multi-hari* dilakukan menggunakan pendekatan *recursive forecasting* dengan mekanisme *damping*, *clipping*, dan *calibration* untuk menjaga stabilitas hasil.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Pengumpulan Data

Pengumpulan data menghasilkan 3.926 observasi harian untuk periode Januari 2015 hingga September 2025. Data harga emas diperoleh melalui *endpoint API* yang digunakan oleh grafik interaktif pada situs resmi Logam Mulia, diakses melalui fitur *inspect network* pada browser sehingga data diperoleh langsung dalam bentuk respons JSON dengan struktur *array* `[[timestamp, harga]]`. *Timestamp* dalam milidetik dikonversi ke format *datetime* harian, kemudian data diurutkan secara kronologis dan disimpan dalam format *CSV*. Data kurs *USD/IDR* harian diperoleh dari Investing.com, sedangkan data inflasi dan suku bunga acuan BI diperoleh dari situs resmi Bank Indonesia dalam interval bulanan. Setiap variabel awalnya tersimpan dalam *file* terpisah sesuai sumbernya masing-masing.

The image displays four separate Excel spreadsheets side-by-side, representing the raw datasets collected. The first spreadsheet, titled 'gold_prices', shows a list of dates from 2015 to 2025 with corresponding gold prices. The second, 'BI-7Day-RR', shows the 7-day reverse repo rate from the Bank of Indonesia. The third, 'Data Inflasi', shows monthly inflation data from August 2025 back to October 2024. The fourth, 'Data Historis USD_IDR', shows the historical exchange rate of the US Dollar against the Indonesian Rupiah from August 2025 back to March 2023.

Gambar 2. Raw Dataset

Gambar 2 menampilkan kondisi awal *dataset* sebelum proses integrasi. Terlihat bahwa setiap variabel memiliki format dan frekuensi waktu yang berbeda, dengan data harga emas dan kurs tersedia secara harian sementara inflasi dan suku bunga hanya tersedia secara bulanan. Kondisi ini menjadi dasar utama perlunya tahap *preprocessing* untuk menyeragamkan struktur data sebelum digunakan dalam pemodelan.

3.2. Hasil *Preprocessing*

Setelah seluruh *file* dikumpulkan, proses *preprocessing* dilakukan untuk menyeragamkan granularitas waktu dan membentuk *dataset* final yang konsisten. Data inflasi dan suku bunga yang semula tersedia dalam format bulanan dikonversi menjadi format harian menggunakan metode *forward fill*. Data kurs *USD/IDR* yang telah tersedia dalam frekuensi harian langsung disejajarkan berdasarkan tanggal observasi. Setelah penggabungan, *dataset* final terdiri dari 3.926 baris tanpa *missing value*.

	1	2	3	4	5
1	date	gold_price	usd_idr	inflation	interest_rate
2	1/1/2015	549000	12385	0.0696	0.0775
3	1/2/2015	545000	12542.5	0.0696	0.0775
4	1/3/2015	545000	12542.5	0.0696	0.0775
5	1/4/2015	545000	12542.5	0.0696	0.0775
6	1/5/2015	545000	12627.5	0.0696	0.0775
7	1/6/2015	550000	12657.5	0.0696	0.0775
8	1/7/2015	557000	12738.5	0.0696	0.0775
9	1/8/2015	558000	12680	0.0696	0.0775
10	1/9/2015	557000	12651.5	0.0696	0.0775
11	1/10/2015	557000	12651.5	0.0696	0.0775
12	1/11/2015	557000	12651.5	0.0696	0.0775
13	1/12/2015	563000	12597.5	0.0696	0.0775
14	1/13/2015	561000	12597.5	0.0696	0.0775
15	1/14/2015	563000	12613	0.0696	0.0775
16	1/15/2015	561000	12560	0.0696	0.0775
17	1/16/2015	573000	12587.5	0.0696	0.0775
18	1/17/2015	581000	12587.5	0.0696	0.0775
19	1/18/2015	581000	12587.5	0.0696	0.0775
20	1/19/2015	580000	12618.5	0.0696	0.0775
21	1/20/2015	580000	12584	0.0696	0.0775
22	1/21/2015	584000	12480	0.0696	0.0775

3927 rows x 5 columns 2:1 (8 chars)

Gambar 3. Preview Dataset Setelah Preprocessing

Gambar 3 menampilkan struktur *dataset* setelah proses integrasi dan *preprocessing*. Dataset memuat lima kolom utama yaitu *date*, *gold_price*, *usd_idr*, *inflation*, dan *interest_rate* dengan tipe data masing-masing sebagaimana ditunjukkan pada Tabel 2.

Tabel2. Tipe Data Penelitian	
Variabel	Tipe Data
<i>date</i>	<i>date</i>
<i>gold_price</i>	<i>float64</i>
<i>usd_idr</i>	<i>float64</i>
<i>inflation</i>	<i>float64</i>
<i>interest_rate</i>	<i>float64</i>

Seluruh variabel numerik telah tersimpan dalam tipe *float64* sehingga dapat langsung digunakan dalam proses analisis maupun pemodelan. *Feature engineering* kemudian diterapkan untuk membentuk 19 fitur turunan yang mencakup *lag features*, *moving average*, fitur volatilitas, dan fitur momentum sebagaimana dijelaskan pada subbab 2.2.


3.3. Exploratory Data Analysis

Descriptive Statistics:				
	gold_price	usd_idr	inflation	interest_rate
count	3926.0000	3926.0000	3926.0000	3926.0000
mean	913638.3087	14462.7913	0.0325	0.0523
std	351875.8041	1003.3605	0.0151	0.0118
min	545000.0000	12385.0000	-0.0009	0.0350
25%	629000.0000	13623.1250	0.0218	0.0425
50%	916000.0000	14325.0000	0.0313	0.0525
75%	1030000.0000	15185.0000	0.0372	0.0600
max	2234000.0000	16870.0000	0.0726	0.0775

Gambar 4. Descriptive Analytic


Analisis deskriptif pada Gambar 4, menunjukkan bahwa variabel harga emas memiliki nilai rata-rata Rp913.638 dengan median Rp916.000. Kedekatan *mean* dan *median* menunjukkan distribusi relatif seimbang meskipun standar deviasi sebesar Rp351.875 mengindikasikan variasi harga yang cukup tinggi sepanjang periode pengamatan. Nilai minimum tercatat Rp545.000 dan nilai maksimum mencapai Rp2.234.000. Variabel kurs USD/IDR memiliki rata-rata Rp14.462 dengan standar deviasi Rp1.003, mencerminkan dinamika pasar valuta asing yang moderat selama periode observasi.

Dekomposisi STL pada data bulanan memisahkan komponen tren, musiman, dan *residual*. Komponen tren menunjukkan arah naik yang konsisten dari awal hingga akhir periode dengan akselerasi yang semakin curam menjelang 2024 hingga 2025, mengindikasikan bahwa dinamika utama harga emas lebih banyak dipengaruhi oleh faktor struktural dan makroekonomi dibanding fluktuasi jangka pendek. Komponen musiman berfluktuasi di sekitar nol dengan rentang kecil hanya beberapa persen terhadap rata-rata bulanan, menandakan tidak adanya pola musiman yang dominan. Komponen *residual* menunjukkan beberapa lonjakan ekstrem terutama sekitar tahun 2020 yang mengindikasikan *shock* eksternal akibat pandemi COVID-19.




Gambar 5. Dekomposisi Harga Emas

Gambar 5 menampilkan hasil dekomposisi STL yang memisahkan data harga emas menjadi komponen *observed*, tren, musiman, dan *residual*. Komponen tren memperlihatkan kenaikan bertahap sejak 2015 yang semakin curam menjelang 2024-2025. Komponen musiman bergerak di sekitar nol dengan amplitudo kecil, sedangkan komponen *residual* memperlihatkan lonjakan signifikan pada periode 2020 yang mencerminkan dampak kondisi pasar global yang tidak terprediksi.



Gambar 6. Analisis ACF dan PACF

Analisis *ACF* pada Gambar 6, memperlihatkan pola penurunan lambat (*slow decay*) yang mengindikasikan data bersifat non-stasioner dengan dependensi jangka panjang, sementara *PACF* hanya signifikan pada *lag* pertama kemudian menurun tajam. Kondisi ini mengonfirmasi bahwa harga emas pada waktu sekarang dipengaruhi oleh harga pada periode sebelumnya dalam jangka panjang, sekaligus memperkuat alasan penggunaan model berbasis *RNN* yang mampu menangkap pola ketergantungan temporal dibandingkan model statistik klasik seperti *ARIMA*.



Gambar 7. Heatmap Correlation Matrix

Gambar 7 menampilkan matriks korelasi antar seluruh variabel penelitian. *USD/IDR* menunjukkan korelasi tertinggi terhadap harga emas sebesar 0,872, jauh lebih tinggi dibandingkan inflasi dan suku bunga. Secara ekonomi, dominansi *USD/IDR* sebagai prediktor dapat dijelaskan karena harga emas domestik merupakan hasil interaksi langsung antara harga emas internasional yang dinyatakan dalam dolar AS dan nilai tukar rupiah. Ketika rupiah melemah terhadap dolar AS, harga emas dalam rupiah cenderung meningkat meskipun harga emas global tidak mengalami kenaikan yang sebanding. Temuan ini menjadi justifikasi kuat bahwa variabel *USD/IDR* merupakan fitur paling informatif dalam model prediksi harga emas Indonesia.

3.4. Hasil Hyperparameter Tuning

Tabel 1. Spesifikasi peralatan

#	Model	Split	Units	Dropout	Learning Rate
1	<i>LSTM</i>	70:30	256	0.005	0.0005
2	<i>LSTM</i>	80:20	256	0.00	0.0005
3	<i>LSTM</i>	90:10	256	0.00	0.0010
4	<i>GRU</i>	70:30	256	0.05	0.0010
5	<i>GRU</i>	80:20	256	0.10	0.0010
6	<i>GRU</i>	90:10	256	0.00	0.0010

Seluruh konfigurasi optimal menggunakan 256 *units*, mengindikasikan kapasitas representasi yang lebih besar menjadi faktor penting untuk data harga emas yang kompleks. *LSTM* cenderung optimal dengan *dropout* rendah dan *learning rate* konservatif, sementara *GRU* konsisten optimal dengan *learning rate* 0,001 yang menunjukkan kemampuan konvergensi lebih cepat.

LSTM cenderung optimal dengan *dropout* rendah hingga nol dan *learning rate* yang lebih konservatif (0,0005), menunjukkan kebutuhan proses *training* yang lebih stabil akibat struktur *gate* yang lebih kompleks. Sebaliknya, *GRU* konsisten optimal dengan *learning rate* lebih tinggi yaitu 0,001, menunjukkan kemampuan konvergensi yang lebih cepat dan toleransi lebih baik terhadap pembaruan bobot yang agresif. *Dropout rate* pada *GRU* bervariasi antar skenario (0,05; 0,10; 0,00), mengindikasikan sensitivitas yang lebih adaptif terhadap distribusi data pada setiap skenario *split*.

3.5. Hasil Training dan Evaluasi Model

Proses *training* dilakukan secara terpisah untuk setiap kombinasi model dan skenario *split* menggunakan *hyperparameter* terbaik masing-masing. Hasil evaluasi lengkap pada seluruh enam kombinasi ditampilkan pada Tabel 4.


Tabel 4. Full Evaluation Results

<i>Model</i>	<i>Split</i>	<i>Units</i>	<i>Dropout</i>	<i>Learning Rate</i>	<i>RMSE (IDR)</i>	<i>MAPE</i>
<i>LSTM</i>	70:30	256	0.005	0.0005	115.598,96	4,46%
<i>LSTM</i>	80:20	256	0.00	0.0005	112.260,88	4,74%
<i>LSTM</i>	90:10	256	0.00	0.0010	96.808,45	4,58%
<i>GRU</i>	70:30	256	0.05	0.0010	70.450,40	2,77%
<i>GRU</i>	80:20	256	0.10	0.0010	81.062,64	3,48%
<i>GRU</i>	90:10	256	0.00	0.0010	35.417,91	1,47%

3.6. Analisis Keunggulan GRU terhadap LSTM


Keunggulan *GRU* dapat dijelaskan dari beberapa perspektif. Secara arsitektur, *GRU* menggunakan dua *gate* dibandingkan tiga *gate* *LSTM* sehingga jumlah parameter *trainable GRU* sebesar 160.449 lebih sedikit dari *LSTM* yang memiliki 211.521 parameter. Dengan 3.447 sampel *training* pada skenario 90:10, rasio data terhadap parameter pada *GRU* lebih baik, mendukung generalisasi yang lebih stabil pada data uji.

Dari sisi proses *training*, *GRU* mencapai *early stopping* lebih cepat pada seluruh skenario. Pada *split* 90:10, *GRU* berhenti pada *epoch* 19 dengan bobot optimal dari *epoch* 9, sementara *LSTM* baru berhenti pada *epoch* 39 dengan bobot optimal dari *epoch* 29. Konvergensi yang lebih cepat pada *GRU* mengindikasikan efisiensi pembelajaran yang lebih tinggi pada karakteristik data ini.



Gambar 8. Line Chart Actual vs Prediction GRU dan LSTM (Split 90:10)

Gambar 8 menampilkan perbandingan langsung antara harga emas aktual dan hasil prediksi *LSTM* serta *GRU* pada skenario *split* 90:10 dalam bentuk *time series*. Garis prediksi *GRU* mengikuti pola pergerakan aktual dengan lebih dekat dan konsisten, terutama saat terjadi tren kenaikan dan fluktuasi jangka pendek. Sebaliknya, prediksi *LSTM* cenderung berada di bawah nilai aktual dengan deviasi yang lebih besar, khususnya pada bagian akhir data ketika harga mengalami kenaikan tajam. *GRU* menunjukkan kemampuan merespons perubahan tren dengan lebih adaptif, sementara *LSTM* tampak lebih lambat dalam menyesuaikan arah pergerakan.



Gambar 9. Scatter Plot Actual vs Predicted - GRU dan LSTM (Split 90:10)

Gambar 9 membandingkan *scatter plot* antara nilai aktual dan prediksi untuk *LSTM* dan *GRU* pada konfigurasi terbaik masing-masing. Pada *scatter plot* *LSTM*, titik-titik data menunjukkan penyebaran yang cukup lebar terutama pada rentang harga tinggi, dengan kecenderungan *underpredict* yang terlihat dari posisi titik yang berada di bawah garis diagonal ideal. Pada *scatter plot* *GRU*, titik-titik data tampak lebih rapat dan konsisten mengikuti garis diagonal, menandakan prediksi yang memiliki deviasi lebih kecil dan distribusi *error* yang lebih seragam di berbagai rentang nilai. Temuan ini secara visual mengonfirmasi superioritas *GRU* dalam menghasilkan estimasi yang mendekati kondisi ideal.

Temuan ini sejalan dengan studi Primananda dan Isa [13] yang menemukan *GRU* lebih akurat untuk rentang data kurang dari tiga tahun pada prediksi harga emas

dalam Rupiah, serta studi Varshini et al. [6] yang menunjukkan *GRU* mencapai *MAPE* 0,79% sebanding dengan *Stacked LSTM* 0,74% pada data harga logam. Perbedaan nilai *MAPE* pada penelitian ini yang lebih tinggi dibandingkan studi tersebut dapat dijelaskan oleh kompleksitas tambahan karena target prediksi berupa harga emas dalam Rupiah yang dipengaruhi sekaligus oleh harga emas internasional dan fluktuasi nilai tukar USD/IDR, sehingga variabilitas data lebih tinggi dibandingkan prediksi harga emas dalam USD.

3.5. Implementasi Sistem Web

Model *GRU* pada skenario *split* 90:10 dipilih sebagai model final dan dikemas dalam tiga artefak *deployment* sebagaimana ditunjukkan pada Tabel 5.

Tabel 5. Artefak *Deployment* Model *GRU*


Artefak	Fungsi
<i>GRU_90-10.keras</i>	Menyimpan arsitektur dan bobot model <i>GRU</i>
<i>scalers_90-10.joblib</i>	Menyimpan <i>scaler_X</i> dan <i>scaler_y</i> untuk transformasi fitur dan target
<i>meta_90-10.joblib</i>	Menyimpan <i>metadata</i> seperti fitur, target, <i>lookback</i> , dan rentang nilai target

Ketiga artefak saling terkait karena model membutuhkan struktur *input*, skala data, dan urutan fitur yang sama seperti pada tahap *training*. *Backend Flask* memuat ketiga artefak ini melalui *service GoldPredictor* yang bertugas sebagai penghubung antara *API Flask* dan model *GRU*.

Tabel 6. *Endpoint* Utama *Backend*


<i>Endpoint</i>	<i>Method</i>	Fungsi
<i>/api/upload</i>	<i>POST</i>	Mengunggah dan memproses <i>dataset</i> CSV
<i>/api/sample-data</i>	<i>GET</i>	Memuat <i>sample</i> data bawaan sistem
<i>/api/predict</i>	<i>POST</i>	Membuat <i>job</i> prediksi asinkron
<i>/api/job/<job_id>/status</i>	<i>GET</i>	Memantau status dan hasil prediksi
<i>/api/export</i>	<i>GET</i>	Mengekspor hasil prediksi ke <i>file</i> CSV
<i>/api/dashboard</i>	<i>GET</i>	Mengambil data ringkasan <i>dashboard</i>
<i>/api/historical</i>	<i>GET</i>	Mengambil data historis untuk visualisasi

Prediksi multi-hari dilakukan secara *recursive*. *Model* memprediksi satu hari ke depan, hasil prediksi tersebut ditambahkan ke *working data*, kemudian fitur dihitung ulang untuk membentuk *input* prediksi berikutnya. Karena variabel makroekonomi masa depan belum tersedia, *backend* membentuk proyeksi eksogen berdasarkan nilai historis terakhir menggunakan tren linier yang diredam (*damping*) dan dibatasi (*clipping*) agar tidak bergerak terlalu jauh dari rentang *data training*.



Gambar 10. Tampilan Halaman Prediksi Aplikasi Web

Gambar 10 menampilkan antarmuka halaman Prediksi sebagai pusat implementasi model *GRU* pada aplikasi. Pengguna dapat mengunggah *dataset CSV* atau menggunakan *sample data* bawaan, memilih horizon prediksi melalui slider jumlah hari, menjalankan proses *forecast* secara asinkron, dan melihat hasilnya dalam bentuk grafik perbandingan antara data aktual dan prediksi model. Halaman ini juga menyajikan ringkasan metrik berupa estimasi *MAPE runtime*, *confidence score*, dan opsi ekspor hasil prediksi ke *file CSV*.



Gambar 11. Tampilan Halaman Dashboard

Gambar 11 menampilkan halaman *Dashboard* yang berfungsi sebagai ringkasan utama kondisi harga emas. Halaman ini menyajikan kartu statistik berupa harga terkini, harga terendah, harga tertinggi, volatilitas, sentimen pasar, dan estimasi prediksi besok dalam satu tampilan yang informatif. Dengan susunan komponen tersebut, *Dashboard* berperan sebagai titik awal sebelum pengguna berpindah ke fitur prediksi atau peninjauan data historis, sehingga memperkuat fungsi aplikasi sebagai sistem informasi sekaligus sistem prediksi harga emas yang dapat dimanfaatkan sebagai alat bantu pengambilan keputusan investasi.

KESIMPULAN

Penelitian ini membandingkan performa *LSTM* dan *GRU* dalam memprediksi harga emas harian ANTAM LM berbasis variabel makroekonomi (inflasi, suku bunga BI, dan kurs USD/IDR) pada periode Januari 2015 hingga September 2025. Berdasarkan evaluasi pada enam kombinasi model dan skenario *split*, dapat disimpulkan:

Pertama, model *GRU* secara konsisten mengungguli *LSTM* di seluruh skenario *split data*. *GRU* dengan konfigurasi *split* 90:10, 256 *units*, tanpa *dropout*, dan *learning rate* 0,001 mencapai *RMSE* terbaik sebesar Rp35.417,91 dan *MAPE* 1,47%, jauh lebih baik dari *LSTM* terbaik yang menghasilkan *RMSE* Rp96.808,45 dan *MAPE* 4,58% pada skenario yang sama. Keunggulan *GRU* dikaitkan dengan struktur *gate* yang lebih sederhana, jumlah parameter lebih sedikit, dan kemampuan konvergensi yang lebih efisien pada ukuran *dataset* yang digunakan.

Kedua, pendekatan multivariat berbasis variabel makroekonomi domestik terbukti efektif, dengan *USD/IDR* sebagai prediktor dominan (korelasi 0,872). Penggunaan 19 fitur hasil *feature engineering* yang mencakup variabel eksogen, *lag*, *moving average*, volatilitas, dan momentum memberikan konteks temporal yang memadai bagi model dalam menangkap dinamika harga emas Indonesia.

Ketiga, model *GRU* terbaik berhasil diimplementasikan ke dalam aplikasi web fungsional berbasis *Flask* dan *React* dengan 2 halaman utama dan mekanisme prediksi asinkron yang dapat dimanfaatkan sebagai alat bantu pengambilan keputusan investasi emas oleh investor ritel di Indonesia.

Untuk penelitian selanjutnya, disarankan untuk mengeksplorasi arsitektur yang lebih kompleks seperti *Temporal Fusion Transformer*, *Bidirectional LSTM*, atau model hibrida *CNN-GRU*, serta pendekatan *Direct Multi-Step (MIMO)* untuk mengurangi akumulasi *error* pada horizon prediksi panjang. Penambahan variabel seperti harga emas internasional (*spot LBMA*), *indeks DXY*, harga minyak mentah, dan indikator teknikal juga berpotensi meningkatkan akurasi model.

DAFTAR PUSTAKA

- [1] G. Duffee, D. Krueger, L. Kogan, D. Andrei, and B. McDonald, "Gold's Value as an Investment," 2023. [Online]. Available: <http://finance.wharton.upenn.edu/~jermann/>.
- [2] Logam Mulia, "Logam Mulia | Gold, Silver and Precious Metal Trading Company." Accessed: Oct. 19, 2025. [Online]. Available: <https://www.logammulia.com/id>
- [3] S. Aprizal and M. N. Harahap, "Determinants of Gold Prices in Indonesia Period of 2018-2022," *Jurnal Ilmu Manajemen dan Ekonomika*, vol. 17, no. 2, pp. 185–202, Jun. 2025, doi: 10.35384/JIME.V17I2.770.
- [4] I. C. Rahmansyah, R. Chaidir, and L. Nugraha, "Gold Price, Inflation, and Dollar Exchange Rate: The Case of Gold Investment in Indonesia," *The Indonesian Capital Market Review*, vol. 13, no. 1, doi: 10.21002/icmr.v13i1.13238.
- [5] D. Makala and Z. Li, "Prediction of gold price with ARIMA and SVM," in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Feb. 2021. doi: 10.1088/1742-6596/1767/1/012022.
- [6] A. Varshini, P. Kayal, and M. Maiti, "How good are different machine and deep learning models in forecasting the future price of metals? Full sample versus sub-sample," *Resources Policy*, vol. 92, p. 105040, May 2024, doi: 10.1016/J.RESOURPOL.2024.105040.
- [7] Y. R. M. Ferdinandus, K. Kusri, and T. Hidayat, "Gold Price Prediction Using the ARIMA and LSTM Models," *Sinkron*, vol. 8, no. 3, pp. 1255–1264, 2023, doi: 10.33395/sinkron.v8i3.12461.
- [8] R. B. Barsky, C. Epstein, A. Lafont-Mueller, and Y. Yoo, "What drives gold prices?," *Chicago Fed Letter*, 2021, doi: 10.21033/CFL-2021-464.
- [9] S. R. Baker, N. Bloom, and S. J. Davis, "Measuring Economic Policy Uncertainty," *Q. J. Econ.*, vol. 131, no. 4, pp. 1593–1636, Nov. 2016, doi: 10.1093/QJE/QJW024.

-
- [10] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/NECO.1997.9.8.1735.
 - [11] J. Chung, C. Gulcehre, and K. Cho, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling," *arXiv preprint arXiv*, 2014.
 - [12] A. Sherstinsky, "Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network," *Physica D*, vol. 404, Mar. 2020, doi: 10.1016/J.PHYSD.2019.132306.
 - [13] S. B. Primananda and S. M. Isa, "Forecasting Gold Price in Rupiah using Multivariate Analysis with LSTM and GRU Neural Networks," *Advances in Science, Technology and Engineering Systems Journal*, vol. 6, no. 2, pp. 245–253, 2021, doi: 10.25046/aj060227.