

Expert Advisor Untuk Prediksi Jual Atau Beli XAU/USD Menggunakan Metode GRU

Uwais fatih Ramadhan¹, Syofiya Syidada²

^{1,2} Fakultas Teknik Informatika
Universitas Wijaya Kusuma Surabaya
Email: ¹ ufr061@mhs.uwks.ac.id, ² shofiya@uwks.ac.id

Abstrak

Prediksi harga aset keuangan seperti XAU/USD (Emas) memiliki tantangan tinggi karena sifat datanya yang volatil dan non-linear. Penelitian ini bertujuan untuk mengembangkan model prediksi harga XAU/USD pada timeframe M15 menggunakan arsitektur Deep Learning Gated Recurrent Unit (GRU). Berbeda dengan model univariat konvensional, penelitian ini mengintegrasikan tujuh fitur multivariate yang terdiri dari harga OHLC serta tiga indikator teknikal (EMA 50, RSI 14, dan ATR 14). Model dibangun menggunakan arsitektur Sequential dua lapis dengan teknik regularisasi dropout dan L2 untuk mencegah overfitting. Hasil pengujian menunjukkan performa model yang sangat kuat dengan nilai R-Squared sebesar 0.9583 dan Mean Absolute Error (MAE) sebesar 92.72 USD. Selain akurasi harga, model menunjukkan kemampuan prediksi arah tren (directional accuracy) dengan nilai F1-Score sebesar 54.49%. Implementasi sistem dilakukan melalui deployment menggunakan FastAPI, yang memungkinkan model diintegrasikan ke dalam sistem perdagangan otomatis secara real-time. Hasil penelitian menyimpulkan bahwa kombinasi fitur teknikal dan arsitektur GRU mampu memberikan estimasi harga yang presisi serta keunggulan statistik dalam pengambilan keputusan perdagangan.

Kata kunci: Deep Learning, Gated Recurrent Unit, Prediksi Harga, Time-Series, XAU/USD.

Abstract

Predicting financial asset prices such as XAU/USD (Gold) presents significant challenges due to their volatile and non-linear nature. This study aims to develop a XAU/USD price prediction model on the M15 timeframe using the Gated Recurrent Unit (GRU) Deep Learning architecture. Unlike conventional univariate models, this research integrates seven multivariate features consisting of OHLC prices and three technical indicators (EMA 50, RSI 14, and ATR 14). The model is constructed using a two-layer Sequential architecture with dropout and L2 regularization techniques to prevent overfitting. Experimental results demonstrate high model performance with an R-Squared value of 0.9583 and a Mean Absolute Error (MAE) of 92.72 USD. Beyond price accuracy, the model exhibits directional accuracy with an F1-Score of 54.49%. System implementation is achieved through deployment using FastAPI, enabling the model to be integrated into real-time automated trading systems. The study concludes that the combination of technical features and GRU architecture provides precise price estimation and a statistical edge for trading decision-making.

Keywords: Deep Learning, Gated Recurrent Unit, Prediksi Harga, Time-Series, XAU/USD.

I. PENDAHULUAN

Pasar keuangan global saat ini menempatkan komoditas emas (XAU/USD) sebagai salah satu instrumen perdagangan yang paling strategis. Emas tidak hanya berfungsi sebagai aset investasi, tetapi juga sebagai instrumen *safe haven* yang mampu melindungi nilai aset di tengah ketidakpastian ekonomi dan geopolitik global [1]. Di Indonesia, perdagangan emas berjangka juga menunjukkan tren peningkatan sebagai instrumen diversifikasi portofolio yang stabil. Tingginya volume perdagangan pada instrumen ini menawarkan peluang keuntungan yang signifikan, namun fluktuasi harganya tetap menjadi tantangan besar [2].


Karakteristik pergerakan harga XAU/USD sangat kompleks, bersifat non-linear, dan memiliki tingkat volatilitas yang ekstrim. Perubahan harga yang sangat cepat sering kali menyebabkan metode analisis teknikal konvensional gagal dalam memberikan sinyal yang presisi. Penggunaan indikator teknikal tradisional seringkali bersifat lagging atau tertunda, sehingga diperlukan pendekatan komputasi cerdas yang lebih adaptif untuk menangkap pola pergerakan harga secara real-time [3].

Perkembangan teknologi *Deep Learning* telah membawa perubahan besar dalam analisis data runtun waktu (*time-series*). Arsitektur *Recurrent Neural Network* (RNN) dan variannya seperti *Long Short-Term Memory* (LSTM) telah menjadi standar dalam memprediksi data keuangan karena kemampuannya menangkap dependensi jangka Panjang [4]. Meski demikian, implementasi model yang terlalu kompleks seringkali terkendala oleh waktu pelatihan model yang lama dan kebutuhan sumber daya komputasi yang tinggi.

Sebagai alternatif yang lebih efisien, metode *Gated Recurrent Unit* (GRU) hadir dengan arsitektur yang lebih ringkas namun tetap memiliki performa yang kompetitif. Penelitian di Indonesia juga mulai mengeksplorasi efisiensi GRU untuk data keuangan karena kemampuannya meminimalkan risiko overfitting dengan struktur pintu logika yang lebih sederhana dibanding LSTM [5]. Hal inilah yang mendasari penelitian ini untuk mengembangkan sebuah *Expert Advisor* berbasis metode GRU guna menghasilkan prediksi sinyal jual atau beli pada XAU/USD yang lebih responsif dan efisien.

II. METODE PENELITIAN

Metode penelitian mengikuti enam tahapan CRISP-DM yang ditunjukkan pada Gambar 3.1. Berikut penjelasan singkat tiap tahapan, disesuaikan dengan proyek prediksi XAU/USD M15 menggunakan.



Gambar 1. Metode CRISP-DM

Pada gambar 1 ini kerangka kerja CRISP-DM (*Cross-Industry Standard Process for Data Mining*) sebagai metodologi sistematis untuk pengembangan model prediksi. Metodologi ini dipilih karena sifatnya yang siklikal dan terstruktur, yang memungkinkan adanya iterasi antara setiap tahapan guna memastikan akurasi model tetap selaras dengan tujuan fungsional dari *Expert Advisor* yang dibangun.

2.1 Business Understanding

Tahap awal penelitian difokuskan pada pemahaman mendalam terhadap domain perdagangan instrumen keuangan XAU/USD. Masalah utama yang diidentifikasi adalah tingginya risiko kerugian yang disebabkan oleh keputusan perdagangan yang bersifat emosional dan subjektif di tengah volatilitas pasar yang ekstrim. Emas dikenal memiliki fluktuasi harga yang dipengaruhi oleh banyak faktor eksternal, sehingga diperlukan sebuah sistem cerdas yang mampu melakukan analisis teknikal secara objektif tanpa terpengaruh oleh faktor psikologis manusia.

2.2 Data Understanding

Fase ini melibatkan proses pengumpulan dan eksplorasi awal terhadap dataset historis XAU/USD yang diambil dari terminal perdagangan. Data yang dikumpulkan mencakup variabel harga *Open*, *High*, *Low*, *Close* (OHLC) dan volume transaksi dalam rentang waktu yang telah ditentukan. Peneliti melakukan pemeriksaan kualitas data secara menyeluruh untuk mendeteksi keberadaan nilai yang hilang (*missing values*) atau adanya anomali harga yang mungkin timbul akibat kesalahan teknis pada sistem penyedia data atau adanya *gap* harga saat pembukaan pasar.

2.3 Data Preparation

Data Preparation merupakan tahap yang paling intensif karena data mentah harus ditransformasi ke dalam format yang dapat dicerna oleh algoritma *Deep Learning*. Langkah pertama adalah melakukan normalisasi data menggunakan teknik *Min-Max Scaling* untuk mengubah rentang nilai harga ke dalam skala 0 hingga 1. Proses ini sangat krusial dalam pelatihan model berbasis RNN atau GRU karena fungsi aktivasi seperti tanh atau sigmoid bekerja lebih optimal pada rentang nilai tersebut, sekaligus mencegah terjadinya masalah *gradient explosion* selama proses pelatihan.

Langkah kedua adalah pembentukan *sliding window*, di mana data diatur ke dalam urutan waktu (*sequences*) tertentu untuk memberikan konteks temporal bagi model. Sebagai contoh, model akan diberikan 60 bar harga terakhir sebagai input untuk memprediksi harga pada bar berikutnya, sehingga model belajar mengenai korelasi waktu antar candle. Terakhir, dataset dibagi secara kronologis menjadi tiga bagian utama, yaitu data latih (*training*) untuk pembentukan pola dasar, data validasi untuk optimasi parameter, dan data uji (*testing*) untuk validasi akhir performa model secara independen.

Normalisasi Data

$$z = \frac{x_i - X_{min}}{X_{max} - X_{min}} \quad [1]$$

Keterangan:

Z = Nilai hasil normalisasi
Xi = Nilai asli
Xmin = Hasil rata – rata dari seluruh nilai dalam data
Xmax = Hasil simpangan baku dari seluruh nilai dalam data

2.4 Modeling

Pada tahap pemodelan, dirancang arsitektur *Gated Recurrent Unit* (GRU) yang dikenal lebih efisien dibandingkan arsitektur RNN lainnya. GRU dipilih karena keunggulannya dalam menangani masalah *vanishing gradient*, namun memiliki struktur yang lebih ringkas dibandingkan LSTM karena hanya menggunakan dua pintu logika utama. Arsitektur model yang dirancang terdiri dari layer input, beberapa layer GRU tersembunyi untuk ekstraksi fitur temporal, layer dropout untuk mengurangi risiko *overfitting*, serta layer output dengan fungsi aktivasi linear guna menghasilkan nilai prediksi harga yang kontinu.


Proses pelatihan melibatkan optimasi pada *Update Gate* dan *Reset Gate* yang terdapat dalam sel GRU. *Update Gate* berfungsi menentukan seberapa banyak informasi dari langkah waktu sebelumnya yang harus tetap dipertahankan, sementara *Reset Gate* bertugas menentukan seberapa banyak informasi masa lalu yang harus diabaikan untuk mempelajari pola baru. Pelatihan ini dilakukan menggunakan *optimizer Adam* dan fungsi kerugian *Mean Squared Error* (MSE) yang dihitung secara iteratif melalui sejumlah epoch hingga model mencapai titik konvergensi dengan tingkat galat terkecil.

Para meter Model.

Parameter	Input
Unit GRU	[32]
Lookback	[15,20]
Timestamp	[15,20]
Batch Size	[16,32]
Epoch	[50,100]
Optimizer	[adam]

Gambar 2. Parameter Model

Pada Gambar 2 menentukan model parameter yang akan digunakan dalam *deep learning Gate Recurrent Unit* (GRU) yang bertujuan untuk memberikan kinerja terbaik, seperti akurasi yang lebih tinggi dan aspek lainnya yang terdapat pada terhadap evaluasi modal:



Gambar 3. Model Arsitektur *Gated Recurrent Unit* (GRU)

Pada Gambar 3. model GRU memiliki struktur yang lebih sederhana yang hanya memiliki *update gate* dan *reset gate*. Meskipun memiliki lebih sedikit gerbang dan struktur yang lebih sederhana, model GRU memberikan akurasi prediksi yang sebanding dengan model *deep learning* lainnya[8]. *Reset gate*

memiliki fungsi untuk memilih dari informasi yang harus diatur ulang atau dihapus sedangkan *update gate* memiliki fungsi untuk memilih informasi yang harus dipertahankan. Setelah itu, menghitung *hidden state* yang berfungsi untuk menyimpan informasi yang relevan sebelumnya dengan menggunakan *update gate*.

2.5 Evaluasi

Setelah model berhasil dilatih, performanya dievaluasi menggunakan data uji yang sebelumnya tidak pernah dilihat oleh model selama proses pelatihan. Semakin rendah nilai metrik tersebut, maka semakin tinggi tingkat presisi model dalam mengikuti dinamika pergerakan harga XAU/USD. peneliti menguji ketepatan model dalam menghasilkan sinyal beli saat tren diprediksi naik dan sinyal jual saat tren diprediksi turun melalui simulasi visual. Visualisasi perbandingan antara harga aktual dan harga prediksi sangat penting untuk memvalidasi apakah model mampu menangkap volatilitas dan momen pembalikan tren (reversal),

1. Accuracy

Accuracy adalah ukuran yang menunjukkan seberapa baik model klasifikasi dapat memprediksi kelas yang tepat dari data yang diberikan

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad [2]$$

2. Precision

Precision adalah rasio dari jumlah label yang diidentifikasi dengan benar terhadap total jumlah label yang diidentifikasi

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad [3]$$

3. F1-Score

F1-Score adalah perhitungan kombinasi dari nilai *precision* dan nilai *recall* yang kemudian hasilnya disebut sebagai nilai pengukuran

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad [4]$$

4. Recall

Recall adalah metrik yang menunjukkan seberapa banyak data yang diklasifikasi dengan benar dalam suatu kategori dibandingkan dengan total jumlah data yang sebenarnya masuk ke dalam kategori tersebut

$$Recall = \frac{TP}{TP+FN} \quad [5]$$

5. Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) yaitu metode alternatif untuk mengevaluasi teknik peramalan yang digunakan untuk mengukur tingkat akurasi hasil perkiraan suatu model.

$$\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad [6]$$

6. Mean Square Error (MSE)

Merupakan perhitungan yang digunakan untuk menghitung rata-rata kesalahan berpangkat [16].

$$Z = \sum \frac{(Aktual - forecast)}{n - 1} \quad [7]$$

7. Mean Absolute Error (MAE)

Mean Absolute Error merupakan salah satu metode yang digunakan untuk mengukur tingkat keakuratan model peramalan dengan menunjukkan rata – rata kesalahan (*error*) absolut antara hasil peramalan/prediksi dengan nilai riil.

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \quad [8]$$

2.6 Deployment

Tahap akhir adalah deployment, di mana model yang telah divalidasi dikonversi menjadi sebuah sistem pendukung keputusan yang fungsional bagi para trader. Implementasi ini mencakup penyusunan logika operasional yang mampu menerima aliran data harga terbaru secara berkelanjutan dan secara otomatis mengeluarkan output berupa rekomendasi tindakan perdagangan. Meskipun fokus utama penelitian seminar ini adalah pada analisis performa, tahap ini menjamin bahwa hasil riset memiliki nilai aplikatif dan teknis yang tinggi untuk digunakan pada platform perdagangan riil di masa depan.

Pada fase ini, dilakukan juga dokumentasi menyeluruh mengenai spesifikasi sistem, parameter model terbaik, serta limitasi yang ditemukan selama penelitian. Dokumentasi ini berfungsi sebagai panduan bagi pengembangan lebih lanjut, misalnya integrasi dengan manajemen risiko atau penambahan fitur indikator tambahan. Hal ini bertujuan agar hasil penelitian memberikan kontribusi nyata bagi literatur teknologi finansial, khususnya dalam pengembangan sistem perdagangan otomatis yang lebih efisien dan responsif terhadap dinamika pasar global yang kompleks.

III. HASIL DAN PEMBAHASAN

3.1 Business Understanding

Tujuan utama dari fase ini adalah merumuskan kriteria keberhasilan model dari sudut pandang fungsionalitas *Expert Advisor*. Model diharapkan tidak hanya memberikan nilai matematis yang presisi, tetapi juga harus mampu memberikan sinyal beli (*buy*) atau jual (*sell*) yang memiliki relevansi terhadap pergerakan tren pasar yang sebenarnya. Hal ini menjadi landasan untuk menentukan strategi pemodelan dan batasan masalah yang akan dikembangkan pada tahapan selanjutnya, guna menjamin bahwa hasil penelitian memiliki nilai aplikatif di dunia trading.

3.2 Data Understanding

Tabel 1. Dataset Xau/Usd

time	open	high	low	close
2023-01-02 18:00:00	1,826,837	1,829,958	1,825,967	1,826,217
2023-01-02 18:15:00	1,826,197	1,828,997	1,823,287	1,827,847
2023-01-02 18:30:00	1,827,807	1,828,347	1,826,965	1,827,735
2023-01-02 18:45:00	1,827,715	1,829,305	1,827,618	1,829,295

Pada tabel 1 menampilkan dataset mentah dari XAU/USD pada *timeframe* 15 menit Dataset ini mencakup periode 1 Januari 2023 pukul 18:00:00 hingga 17 Oktober 2025 pukul 16:58:00 dengan total 283.143 candle. Kolom yang tersedia adalah time, open, high, low, close, dan volume.

3.3 Data Preparation

	time	open	high	low	close
0	2023-01-02 21:15:00	1829.498	1830.665	1828.215	1830.435
1	2023-01-02 21:30:00	1830.435	1838.385	1830.395	1838.088
2	2023-01-02 21:45:00	1838.095	1839.865	1837.117	1838.245
3	2023-01-02 22:00:00	1838.225	1841.275	1838.225	1840.875
4	2023-01-02 22:15:00	1840.895	1843.055	1839.838	1841.475
69433	2026-04-09 02:00:00	4727.295	4728.963	4721.271	4722.867
69434	2026-04-09 02:15:00	4723.194	4727.885	4722.501	4725.673
69435	2026-04-09 02:30:00	4725.592	4732.817	4725.279	4732.300
69436	2026-04-09 02:45:00	4732.240	4733.073	4717.642	4719.288
69437	2026-04-09 03:00:00	4719.226	4720.399	4715.799	4718.320

Gambar 4. Dataset XAUUSD

langkah awal setelah kita memutuskan untuk memprediksi harga XAU/USD timeframe 15 menit. Data yang digunakan diambil dari HistData.com karena situs ini menyediakan data forex secara gratis dan sudah terbukti akurat oleh banyak trader serta peneliti di seluruh dunia.

	open	high	low	close	ema_50	rsi	atr
69446	4727.295	4728.963	4721.271	4722.867	4733.419508	54.322340	12.921357
69447	4723.194	4727.885	4722.501	4725.673	4733.115724	53.363843	12.697143
69448	4725.592	4732.817	4725.279	4732.300	4733.083734	60.456560	12.350143
69449	4732.240	4733.073	4717.642	4719.288	4732.542725	53.744320	12.740714
69450	4719.226	4720.399	4715.799	4718.320	4731.984971	52.043581	12.452429

Gambar 5. Menambahkan Fitur

Penggunaan fitur Open, High, dan Low bertujuan untuk memberikan detail struktur pergerakan harga dan volatilitas di setiap interval, melengkapi fitur harga Close. Indikator EMA 50 ditambahkan untuk mendeteksi arah tren, RSI 14 untuk mengukur momentum jenuh pasar demi menghindari kesalahan prediksi saat pembalikan arah, serta ATR 14 untuk merepresentasikan tingkat risiko volatilitas. Integrasi ketujuh fitur multivariate ini memungkinkan model GRU menangkap korelasi data yang lebih mendalam, sehingga mampu meningkatkan akurasi prediksi dengan nilai R-Squared mencapai 0.9583.

	open	high	low	close	ema_50	rsi	atr
0	0.005752	0.005831	0.006260	0.005997	0.004411	0.672269	0.028561
1	0.006000	0.007869	0.006838	0.008023	0.004522	0.798974	0.031824
2	0.008028	0.008260	0.008619	0.008065	0.004632	0.782812	0.029407
3	0.008062	0.008633	0.008913	0.008761	0.004764	0.814452	0.030768
4	0.008769	0.009103	0.009341	0.008919	0.004898	0.805492	0.032016

Gambar 6. Normalisasi

menunjukkan proses normalisasi menggunakan *MinMaxScaler*. memperlihatkan nilai fitur sebelum normalisasi yang skalanya sangat berbeda (misalnya harga Close ribuan, sedangkan RSI hanya 0–100). Setelah normalisasi, grafik kanan menampilkan semua fitur berada pada rentang 0 sampai 1.

	Parameter	Konfigurasi
0	Window Size (Lookback)	60 Periode (15 Jam)
1	Fitur per Step	7 Fitur (OHLC + Indikator)
2	Target Prediksi	Harga Close t+1
3	Total Sequences	69378

Gambar 7. Window Size

Window size sebesar 60 berarti model menggunakan data histori 15 jam ke belakang (60 candle M15) sebagai basis informasi untuk memprediksi harga pada 15 menit berikutnya. Teknik ini memungkinkan model GRU mempelajari pola pergerakan harga, tren, dan volatilitas jangka pendek secara berurutan (time-series), sehingga model memiliki "memori" terhadap fluktuasi pasar sebelum mengambil keputusan prediksi.

0	Data Training (80%)	55502	(55502, 60, 7)
1	Data Testing (20%)	13876	(13876, 60, 7)
2	Total Data	69378	(69378, 60, 7)

Gambar 8. Pembagian Data *Training & Test*

Pembagian data menjadi Training (80%) dan Testing (20%) dilakukan untuk menjamin validitas model. Data Training digunakan agar model dapat mempelajari hubungan antara fitur dan target harga, sedangkan data Testing berfungsi sebagai data "asing" untuk menguji kemampuan generalisasi model pada kondisi pasar yang belum pernah dilihat sebelumnya. Pemisahan ini memastikan bahwa nilai akurasi R-Squared 0.9583 yang diperoleh murni hasil kemampuan prediksi model, bukan sekadar menghafal data (overfitting).

3.4 Modeling

	Layer Type	Configuration
0	Input Layer	60 samples x 7 features
1	GRU Layer 1	64 Units (L2 Reg)
2	Dropout 1	Rate: 0.3
3	GRU Layer 2	32 Units (L2 Reg)
4	Dropout 2	Rate: 0.3
5	Dense Layer 1	16 Units (ReLU)
6	Output Layer	1 Unit (Linear)

Gambar 9. Model *Sequential GRU*

Model *Sequential* yang digunakan dalam penelitian ini merupakan arsitektur jaringan saraf tiruan di mana setiap layer disusun secara linier dan berurutan. Alur datanya dimulai dari Input Layer yang menerima 7 fitur dengan panjang data histori (window) 60 periode. Data kemudian diproses oleh dua lapis GRU; lapis pertama (64 units) berfungsi mengekstraksi tren utama, dan lapis kedua (32 units) mendalami fluktuasi harga yang lebih detail. Penggunaan Dropout 0.3 di antara lapisan bertujuan untuk menjaga agar model tidak "menghafal" data (overfitting), sementara lapisan Dense di akhir berfungsi sebagai pengolah akhir untuk menghasilkan satu angka prediksi harga penutupan (*Close price*).

3.5 Evaluasi

	Metrik Evaluasi	Nilai (Value)	Keterangan
0	Mean Absolute Error (MAE)	92.72 USD	Rata-rata kesalahan absolut harga
1	Mean Squared Error (MSE)	15901.21 USD ²	Penalti untuk error besar (Kuadrat)
2	Root Mean Squared Error (RMSE)	126.10 USD	Standar deviasi dari error prediksi
3	R-Squared (R2 Score)	0.9583 (95.83%)	Tingkat akurasi prediksi tren

Gambar 10. Hasil Evaluasi RMSE, MSE, & MAE

Hasil evaluasi regresi menunjukkan tingkat akurasi yang sangat tinggi dengan nilai *R-Squared* sebesar 0.9583, yang berarti model mampu menjelaskan 95,83% variansi pergerakan harga emas. Nilai MAE sebesar 92.72 USD mengindikasikan bahwa rata-rata selisih antara harga prediksi dan aktual berada pada rentang yang wajar mengingat volatilitas tinggi pada XAU/USD. Sementara itu, nilai RMSE sebesar 126.10 USD dan MSE sebesar 15901.21 USD² menunjukkan bahwa model memiliki ketahanan yang baik terhadap outlier dan mampu meminimalkan kesalahan prediksi yang ekstrem, sehingga hasil estimasi harga tetap stabil dan konsisten mengikuti arah pergerakan pasar yang sebenarnya.

	Metrik Klasifikasi	Nilai (Value)
0	Accuracy	0.5079 (50.79%)
1	Precision	0.5252 (52.52%)
2	Recall	0.5661 (56.61%)
3	F1-Score	0.5449 (54.49%)

Gambar 11. Hasil Akurasi

Selain prediksi harga nominal, pengujian terhadap arah tren harga memberikan hasil yang sangat memuaskan dengan *Accuracy* sebesar 50.79% dan F1-Score sebesar 54.49%. Nilai *Precision* sebesar 52.52% membuktikan bahwa model memiliki keunggulan statistik dalam menentukan sinyal beli (buy) atau jual (sell) dibandingkan dengan probabilitas acak. Hasil ini menegaskan bahwa integrasi fitur multivariate (OHLC dan indikator teknikal) berhasil memberikan model GRU kemampuan klasifikasi yang tajam, sehingga tidak hanya akurat dalam memprediksi angka harga, tetapi juga dapat diandalkan sebagai basis pengambilan keputusan dalam strategi perdagangan otomatis.

3.6 Deployment

Tahap deployment merupakan fase implementasi model yang telah melalui proses pelatihan dan evaluasi ke dalam lingkungan produksi agar dapat memberikan layanan prediksi secara real-time. Pada penelitian ini, arsitektur deployment dirancang menggunakan framework FastAPI untuk membangun sebuah Application Programming Interface (API) yang bersifat asinkronus dan ringan. Model GRU yang telah disimpan dalam format .h5 dimuat ke dalam server API untuk melayani permintaan (request) prediksi dari aplikasi klien. Alur kerja deployment dimulai dengan pengiriman data histori sebanyak 60 periode melalui protokol HTTP POST, yang kemudian diproses oleh server untuk melakukan inferensi harga. Hasil prediksi tersebut kemudian dikirimkan kembali dalam format JSON setelah melalui tahap denormalisasi. Skema ini dirancang agar model memiliki interoperabilitas tinggi, sehingga dapat diintegrasikan dengan berbagai platform perdagangan otomatis seperti MetaTrader 5 atau bot notifikasi telegram.

IV. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa implementasi model Gated Recurrent Unit (GRU) dengan arsitektur Sequential dua lapis terbukti sangat efektif dalam memprediksi harga XAU/USD pada timeframe M15. Integrasi tujuh fitur multivariate yang menggabungkan data OHLC dengan indikator teknikal seperti EMA 50, RSI 14, dan ATR 14 memberikan kontribusi signifikan terhadap kemampuan model dalam memahami dinamika pasar, yang dibuktikan dengan pencapaian nilai R-Squared sebesar 0.9583. Secara teknis, penggunaan dropout 0.3 dan regulasi L2 berhasil meminimalisir overfitting, sehingga model tetap stabil dengan nilai MAE sebesar 92.72 USD dan RMSE sebesar 126.10 USD. Selain akurasi harga nominal, model juga menunjukkan keunggulan statistik dalam memprediksi arah tren pasar dengan nilai F1-Score sebesar 54.49% dan Akurasi 50.79%, yang mengindikasikan adanya statistical edge untuk keperluan strategi perdagangan. Terakhir, keberhasilan tahap deployment menggunakan framework FastAPI memastikan bahwa model ini tidak hanya unggul secara eksperimental, tetapi juga siap diintegrasikan ke dalam sistem produksi atau bot perdagangan otomatis secara real-time.

REFERENSI

- [1] A. F. Yuliana and R. Robiyanto, "PERAN EMAS SEBAGAI SAFE HAVEN BAGI SAHAM PERTAMBANGAN DI INDONESIA PADA PERIODE PANDEMI COVID-19," *Jurnal Ilmiah Bisnis dan Ekonomi Asia*, vol. 15, no. 1, pp. 1–11, Feb. 2021, doi: 10.32815/jibeka.v15i1.217.
- [2] D. Rakhmawati and M. Nurhalim, "Prediksi harga emas berjangka di masa pandemi covid-19 menggunakan model tren deterministik," *AKUNTABEL: Jurnal Ekonomi dan Keuangan*, vol. 18, no. 1, pp. 146–152, Mar. 2021, doi: 10.30872/JAKT.V18I1.9145.
- [3] A. Muliani Harahap and S. Fitrie, "IMPLEMENTASI GATED RECURRENT UNIT (GRU) UNTUK PREDIKSI HARGA SAHAM BANK KONVENSIONAL DI INDONESIA," *JISTech (Journal of Islamic Science and Technology) JISTech*, vol. 6, no. 2, pp. 42–49, 2021, Accessed: May 07, 2026. [Online]. Available: <http://jurnal.uinsu.ac.id/index.php/jistech>
- [4] R. S. Sinambela, M. Ula, and A. F. Ulva, "Prediksi Harga Emas Menggunakan Algoritma Regresi Linear Berganda Dan Support Vector Machine (SVM)," *Jurnal Sistem dan Teknologi Informasi (JustIN)*, vol. 12, no. 2, p. 253, Apr. 2024, doi: 10.26418/JUSTIN.V12I2.73386.
- [5] R. Dey and F. M. Salemt, "Gate-variants of Gated Recurrent Unit (GRU) neural networks," *Midwest Symposium on Circuits and Systems*, vol. 2017-August, pp. 1597–1600, Sep. 2017, doi: 10.1109/MWSCAS.2017.8053243.