

EVALUASI KOMPARATIF *MACHINE LEARNING* DAN *DEEP LEARNING* UNTUK PREDIKSI HARGA EMAS MENGGUNAKAN DATA HISTORIS DAN INDIKATOR MAKROEKONOMI

Sahril Saputra^{*1}, Thamrinsyah¹, Noni Rahmawati¹, Suroto¹, Tomi Kurniawan¹, Resky Surya Dharma¹

¹Program Studi Sistem Informasi, Institut Teknologi dan Sains Nahdlatul Ulama, Jambi, Indonesia
Penulis korespondensi: Sahril Saputra (sahrilsaputra@itsnugbi.ac.id)

Prediksi harga emas merupakan permasalahan penting dalam analisis pasar keuangan karena harga emas dipengaruhi oleh dinamika historis harga serta berbagai kondisi ekonomi dan pasar keuangan. Penelitian ini mengevaluasi secara komparatif kinerja Random Forest, Extreme Gradient Boosting, Long Short-Term Memory, dan Gated Recurrent Unit dalam memprediksi harga emas satu langkah ke depan menggunakan dua skenario masukan, yaitu data historis harga emas dan kombinasi data historis dengan indikator makroekonomi. Data penelitian mencakup periode 2016–2025 dan dievaluasi menggunakan Mean Absolute Error, Root Mean Square Error, Mean Absolute Percentage Error, dan koefisien determinasi. Hasil pengujian menunjukkan bahwa baseline Naïve menghasilkan kesalahan prediksi terendah dengan MAE 25,9345, RMSE 37,3274, dan MAPE 0,8684%. Penambahan indikator makroekonomi belum meningkatkan kinerja model. Perbedaan distribusi harga yang besar antara data pelatihan dan pengujian turut memengaruhi kinerja model, khususnya model berbasis pohon keputusan.

Kata Kunci – *Deep Learning, Harga Emas, Indikator Makroekonomi, Machine Learning, Prediksi.*

I. PENDAHULUAN

Emas merupakan salah satu aset yang memiliki peranan penting dalam pasar keuangan karena digunakan sebagai instrumen investasi sekaligus aset lindung nilai ketika terjadi ketidakpastian ekonomi dan gejolak pasar[1]. Pergerakan harga emas tidak hanya dipengaruhi oleh pola historis harga, tetapi juga berkaitan dengan kondisi pasar keuangan dan perkembangan ekonomi makro, seperti nilai tukar dolar Amerika Serikat, tingkat suku bunga, imbal hasil obligasi, inflasi, harga minyak, dan indeks pasar saham[2]. Kompleksitas hubungan tersebut menyebabkan pergerakan harga emas memiliki karakteristik yang dinamis dan nonlinear sehingga prediksi harga emas menjadi salah satu permasalahan yang menarik dalam penelitian *time series* dan analisis

pasar keuangan[3]. Penelitian terdahulu menunjukkan bahwa sejumlah indikator pasar keuangan, termasuk indeks saham, volatilitas, komoditas, dan imbal hasil obligasi, memiliki informasi yang dapat dimanfaatkan untuk melakukan prediksi harga emas [4].

Perkembangan metode *Machine Learning* memberikan alternatif dalam mengatasi hubungan nonlinear pada data harga emas. Metode seperti *Random Forest* dan *Extreme Gradient Boosting* (XGBoost) mampu memanfaatkan sejumlah variabel prediktor untuk membentuk hubungan nonlinear antara data masukan dan harga yang diprediksi[5]. Penelitian Cohen dan Aiche menunjukkan bahwa penggunaan indikator pasar keuangan dan komoditas yang dikombinasikan dengan karakteristik historis dapat memberikan informasi yang relevan dalam prediksi harga emas. Penelitian tersebut juga menunjukkan bahwa model berbasis *Gradient Boosted Regression Trees* dan XGBoost dapat digunakan untuk melakukan prediksi harga emas dengan memanfaatkan berbagai indikator eksternal [4].

Selain *Machine Learning*, perkembangan *Deep Learning* memberikan pendekatan yang berbeda melalui kemampuan model dalam mempelajari pola temporal dari data berurutan[6]. *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) merupakan arsitektur yang banyak digunakan dalam permasalahan prediksi *time series* karena dirancang untuk menangkap ketergantungan informasi antarperiode[7]. Penelitian pada harga emas menunjukkan bahwa berbagai arsitektur *Deep Learning*, termasuk LSTM dan GRU, dapat digunakan untuk menangkap pola nonlinear dan temporal pada pergerakan harga emas. Studi yang menggunakan beberapa model *Deep Learning* pada harga emas Indonesia juga menunjukkan bahwa performa model dapat berbeda berdasarkan arsitektur dan karakteristik horizon prediksi yang digunakan [8].

Pemanfaatan indikator makroekonomi sebagai variabel tambahan juga menjadi salah satu perkembangan dalam penelitian prediksi harga emas[9]. Beberapa penelitian menggunakan indikator seperti *Consumer Price Index* (CPI), *U.S. Dollar Index* (DXY), *U.S. Treasury yield*, suku bunga, harga minyak, dan indeks S&P 500 untuk

memberikan informasi tambahan di luar harga historis emas[10]. Penelitian terbaru bahkan secara khusus menganalisis hubungan antara indikator ekonomi dan harga emas serta menunjukkan bahwa penggunaan beberapa indikator ekonomi sebagai fitur dapat memberikan informasi tambahan dalam proses prediksi [11]. Penelitian lain yang menggunakan data bulanan harga emas dan indikator seperti CPI, DXY, US10Y, WTI, dan S&P 500 juga menunjukkan semakin berkembangnya pendekatan multivariat dalam prediksi harga emas [12].

Meskipun demikian, penggunaan variabel makroekonomi dan model yang semakin kompleks tidak secara otomatis menghasilkan peningkatan kinerja prediksi. Hasil penelitian dapat dipengaruhi oleh periode pengamatan, frekuensi data, pemilihan variabel, horizon prediksi, metode *preprocessing*, serta karakteristik perubahan harga pada periode pengujian[13]. Studi sebelumnya juga memperlihatkan bahwa performa model *Machine Learning* dan *Deep Learning* dapat berbeda bergantung pada panjang urutan masukan dan karakteristik data yang digunakan [14]. Oleh karena itu, perbandingan model perlu dilakukan pada konfigurasi data dan skenario masukan yang terkontrol agar pengaruh penggunaan data historis dan indikator eksternal dapat diamati secara lebih jelas.

Permasalahan tersebut menjadi semakin relevan ketika harga emas mengalami perubahan level yang besar dalam periode tertentu. Model prediksi yang dilatih pada suatu distribusi harga belum tentu mampu mengikuti perubahan level harga yang berada jauh di luar rentang data pelatihan[15]. Kondisi tersebut dapat menyebabkan perbedaan kinerja yang besar antarmodel, khususnya antara model yang memiliki kemampuan *extrapolation* terbatas dan pendekatan *baseline* sederhana yang menggunakan harga periode sebelumnya sebagai prediksi. Oleh sebab itu, evaluasi model prediksi harga emas tidak cukup hanya dilakukan berdasarkan nilai metrik kesalahan, tetapi juga perlu mempertimbangkan karakteristik distribusi data antara periode pelatihan dan pengujian[16].

Penelitian terdahulu juga menunjukkan adanya kecenderungan penggunaan model yang semakin kompleks, seperti model hibrida LSTM-XGBoost, SARIMA-LSTM-Random Forest, maupun arsitektur *Deep Learning* yang lebih kompleks[17]. Penelitian terbaru mengenai model hibrida LSTM-XGBoost, misalnya, menggunakan indikator CPI, DXY, US10Y, WTI, dan S&P 500 untuk melakukan prediksi harga emas multivariat [12]. Sementara itu, penelitian lain menggunakan kombinasi SARIMA, LSTM, dan *Random Forest* dengan indikator makroekonomi untuk meningkatkan kemampuan prediksi harga emas [14]. Perkembangan tersebut menunjukkan bahwa penelitian prediksi emas telah bergerak dari penggunaan harga historis secara sederhana menuju pemanfaatan kombinasi

informasi historis, indikator ekonomi, dan arsitektur model yang semakin kompleks.

Berdasarkan perkembangan tersebut, masih diperlukan evaluasi yang membandingkan model *Machine Learning* dan *Deep Learning* dalam kondisi eksperimen yang sama, terutama untuk melihat apakah penambahan indikator makroekonomi memberikan kontribusi yang konsisten terhadap prediksi harga emas. Penelitian ini tidak berfokus pada pengembangan arsitektur hibrida baru, tetapi pada **evaluasi komparatif yang terkontrol** terhadap beberapa pendekatan dengan tingkat kompleksitas yang berbeda. Pendekatan tersebut memungkinkan perbandingan antara model berbasis pohon, model *Deep Learning*, dan *baseline* sederhana dalam menggunakan informasi historis maupun kombinasi informasi historis dan makroekonomi.


Berdasarkan permasalahan tersebut, penelitian ini bertujuan mengevaluasi kinerja *Random Forest*, XGBoost, LSTM, dan GRU dalam memprediksi harga emas satu langkah ke depan (*1-step ahead*). Evaluasi dilakukan melalui dua skenario masukan, yaitu skenario **Historical**, yang menggunakan karakteristik historis harga emas, dan skenario **Historical + Macro**, yang menggabungkan karakteristik historis dengan indikator makroekonomi dan pasar keuangan. *Naïve Forecast* digunakan sebagai *baseline* untuk memberikan pembandingan terhadap model *Machine Learning* dan *Deep Learning*. Kinerja masing-masing model dievaluasi menggunakan *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi (R^2).

Kontribusi penelitian ini terletak pada penyajian evaluasi empiris yang membandingkan model *Machine Learning* dan *Deep Learning* melalui dua skenario informasi secara konsisten pada data harga emas harian. Selain membandingkan nilai kesalahan prediksi, penelitian ini juga menganalisis perubahan kinerja setelah penambahan indikator makroekonomi serta mempertimbangkan perubahan distribusi harga antara data pelatihan dan data pengujian. Dengan demikian, penelitian ini diharapkan dapat memberikan gambaran yang lebih objektif mengenai kinerja model prediksi harga emas pada kondisi data yang mengalami perubahan level harga, sekaligus menunjukkan bahwa peningkatan kompleksitas model perlu dievaluasi berdasarkan karakteristik data dan bukan semata-mata berdasarkan penggunaan algoritma yang lebih kompleks.

II. METODE PENELITIAN

A. Alur Penelitian

Penelitian ini dilakukan melalui beberapa tahapan yang meliputi pengumpulan data, *data preprocessing*, pembentukan fitur, pembentukan target prediksi, pembagian data *training* dan *testing*, pembangunan model, pengujian, serta evaluasi kinerja model. Alur penelitian ditunjukkan pada Gambar 1.



Gambar 1. Alur penelitian prediksi harga emas

B. Data Penelitian

Data harga emas diperoleh dari Yahoo Finance dengan kode $GC=F$, sedangkan indikator makroekonomi dan pasar keuangan diperoleh dari Federal Reserve Economic Data (FRED). Periode pengumpulan data ditetapkan dari 2016 hingga 2025. Setelah proses penggabungan, pembentukan fitur, dan *preprocessing*, diperoleh 2.301 observasi dengan periode 20 September 2016 sampai 14 November 2025.

Data dibagi berdasarkan urutan waktu menjadi data pelatihan sebanyak 1.840 observasi dan data pengujian sebanyak 461 observasi. Data pelatihan mencakup periode 20 September 2016 sampai 18 Januari 2024, sedangkan data pengujian mencakup 19 Januari 2024 sampai 14 November 2025.

C. Variabel dan Feature Engineering

Penelitian menggunakan dua kelompok fitur. Kelompok pertama terdiri atas 15 fitur historis harga emas, yaitu *open*, *high*, *low*, *close*, *gold return*, *gold lag* 1, 3, 7, 14, dan 30 periode, *moving average* 7, 14, dan 30 periode, serta volatilitas 7 dan 30 periode.

Kelompok kedua terdiri atas 12 indikator makroekonomi dan pasar keuangan, yaitu DXY, perubahan DXY, US10Y, perubahan US10Y, FEDFUNDS, perubahan FEDFUNDS, CPI, perubahan CPI, WTI, *return* WTI, SP500, dan *return* SP500.

Berdasarkan kelompok fitur tersebut, eksperimen dibagi menjadi dua skenario seperti ditunjukkan pada Tabel 1.

Tabel 1. Skenario Eksperimen

Skenario	Fitur	Jumlah
<i>Historical</i>	Fitur historis harga emas	15
<i>Historical + Macro</i>	Fitur historis + indikator makroekonomi	27

Target prediksi dibentuk menggunakan harga penutupan satu periode berikutnya:

$$Y_t = \text{Close}_{t+1} \quad (1)$$

Dengan demikian, model menggunakan informasi pada

periode t untuk memprediksi harga penutupan pada periode $t + 1$

D. Pemodelan

Empat model digunakan dalam eksperimen, yaitu *Random Forest*, *XGBoost*, *LSTM*, dan *GRU*. *Random Forest* dan *XGBoost* digunakan untuk memodelkan hubungan nonlinear antarfitur, sedangkan *LSTM* dan *GRU* digunakan untuk menangkap pola temporal pada data deret waktu.

Untuk *LSTM* dan *GRU*, data dibentuk menjadi *sequence* sepanjang 30 periode. Data dinormalisasi menggunakan *MinMaxScaler* yang hanya *fit* pada data pelatihan. Proses pelatihan dilakukan secara berurutan tanpa pengacakan data dan menggunakan *early stopping*. Sementara itu, *Naïve Forecast* digunakan sebagai *baseline* dengan prediksi harga periode berikutnya berdasarkan harga periode saat ini.

E. Evaluasi

Kinerja model dievaluasi menggunakan MAE, RMSE, MAPE, dan R^2 . MAE, RMSE, dan MAPE digunakan untuk mengukur besarnya kesalahan prediksi, sedangkan R^2 digunakan untuk melihat kemampuan model dalam menjelaskan variasi nilai aktual. Rumus evaluasi yang digunakan adalah:

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

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4)$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (5)$$


Model dengan nilai MAE, RMSE, dan MAPE yang lebih rendah menunjukkan kesalahan prediksi yang lebih kecil, sedangkan nilai R^2 yang lebih tinggi menunjukkan kemampuan penjelasan variasi data yang lebih besar.

III. HASIL DAN PEMBAHASAN

A. Pergerakan Harga Emas

Dataset akhir terdiri dari 2.301 observasi dan 31

variabel dengan periode 20 September 2016 sampai 14 November 2025. Data menunjukkan adanya perubahan tingkat harga emas yang cukup besar, terutama pada periode akhir pengamatan.




Gambar 2. Pergerakan Harga Emas Periode 2016–2025

Gambar 2 menunjukkan bahwa harga emas mengalami fluktuasi sepanjang periode penelitian dan meningkat cukup tajam pada periode 2024–2025. Kondisi tersebut menjadi salah satu karakteristik penting dalam proses pengujian model.

B. Korelasi Harga Emas dan Indikator Makroekonomi

Analisis korelasi dilakukan untuk melihat hubungan awal antara harga emas dengan indikator makroekonomi yang digunakan.




Gambar 3. Matriks Korelasi Harga Emas dan Indikator Makroekonomi

Hasil korelasi menunjukkan adanya hubungan yang berbeda antarvariabel. Beberapa indikator juga memiliki korelasi yang cukup tinggi satu sama lain, sehingga penambahan indikator makroekonomi perlu diuji melalui perbandingan kinerja model.

C. Pembagian Data Training dan Testing

Data dibagi secara kronologis dengan proporsi 80:20. Sebanyak 1.840 observasi digunakan untuk *training* dan 461 observasi untuk *testing*. Periode *training* berlangsung dari 20 September 2016 sampai 18 Januari 2024, sedangkan *testing* berlangsung dari 19 Januari 2024 sampai 14 November 2025.



Gambar 4. Pembagian Data *Training* dan *Testing*

Perbedaan tingkat harga terlihat cukup jelas antara kedua periode. Harga maksimum pada *training* sebesar 2.093,10, sedangkan pada *testing* mencapai 4.359,40. Kondisi ini menunjukkan adanya *distribution shift* yang dapat memengaruhi kinerja model.

D.Hasil Pengujian Model


Hasil pengujian model *1-step ahead* ditampilkan pada Tabel 2.

Tabel 2. Hasil Pengujian Model Prediksi Harga Emas

Model	Skenario	MAE	RMSE	MAPE (%)	R ²
Naïve	Historis	25,9345	37,3274	0,8684	0,9956
Random Forest	Historis	816,7420	992,1576	25,7536	-2,0751
XGBoost	Historis	839,9977	1.013,7435	26,5616	-2,2104
LSTM	Historis	516,7529	654,7013	15,8553	-0,4705

Model	Skenario	MAE	RMSE	MAPE (%)	R ²
GRU	Historis	562,1112	713,4214	17,2329	-0,7461
Random Forest	Historis+ Makro	816,8579	992,7433	25,7518	-2,0787
XGBoost	Historis+ Makro	841,4009	1.014,2395	26,6185	-2,2135
LSTM	Historis+ Makro	1.084,4102	1.207,0566	35,0381	-3,9985
GRU	Historis+ Makro	896,0083	1.007,3415	28,8378	-2,4813


Hasil menunjukkan bahwa *Naïve Forecast* menghasilkan error paling rendah dengan MAE 25,9345 dan MAPE 0,8684%. Pada skenario historis, *LSTM* memiliki MAE lebih rendah dibandingkan *GRU*, *Random Forest*, dan *XGBoost*.



Gambar 5. Perbandingan RMSE Model

Visualisasi RMSE memperlihatkan perbedaan kinerja antar model secara lebih jelas. *Naïve Forecast* memiliki nilai RMSE paling rendah dibandingkan model lainnya.

E. Perbandingan Prediksi Aktual



Gambar 6. Perbandingan Harga Aktual dan Prediksi Model


Hasil prediksi menunjukkan bahwa *Naïve Forecast* lebih mampu mengikuti perubahan tingkat harga pada periode *testing*. Sebaliknya, prediksi *Random Forest* dan *XGBoost* cenderung berada pada rentang sekitar 2.000, sementara harga aktual meningkat hingga 4.359,40.

Perbedaan tersebut berkaitan dengan perubahan distribusi harga antara data *training* dan *testing*, sehingga model berbasis pohon mengalami kesulitan mengikuti tingkat harga baru.

F. Pengaruh Indikator Makroekonomi

Penambahan indikator makroekonomi belum meningkatkan kinerja model. MAE *Random Forest* berubah dari 816,7420 menjadi 816,8579, sedangkan *XGBoost* berubah dari 839,9977 menjadi 841,4009.

Perubahan lebih besar terjadi pada *LSTM* dan *GRU*. MAE *LSTM* meningkat dari 516,7529 menjadi 1.084,4102, sedangkan *GRU* meningkat dari 562,1112 menjadi 896,0083.



Gambar 7. Perbandingan Kinerja Model Berdasarkan Skenario

Hasil tersebut menunjukkan bahwa pada konfigurasi penelitian ini, penambahan indikator makroekonomi belum memberikan peningkatan prediksi harga emas untuk horizon *1-step ahead*.

G. Pembahasan

Secara keseluruhan, hasil penelitian menunjukkan bahwa *Naïve Forecast* menghasilkan kinerja terbaik pada eksperimen ini. Model *deep learning* pada skenario historis menghasilkan *error* lebih rendah dibandingkan

Random Forest dan *XGBoost*, tetapi masih berada di atas *Naïve Forecast*. Seluruh model regresi selain *Naïve Forecast* menghasilkan nilai (R^2) negatif, bahkan mencapai -3,9985 pada model *LSTM* dengan indikator makroekonomi. Nilai tersebut menunjukkan bahwa prediksi model secara matematis lebih buruk dibandingkan prediktor konstan yang menggunakan rata-rata nilai aktual pada data pengujian sebagai acuan. Perbedaan tingkat harga antara data *training* dan *testing*, dengan harga maksimum masing-masing sebesar 2.093,10

dan 4.359,40, mengindikasikan adanya *distribution shift* yang berpotensi menyebabkan model kesulitan memprediksi harga di luar rentang yang dipelajari. Selain itu, penggunaan *MinMaxScaler* yang di-fit pada data *training* dapat menghasilkan nilai transformasi di atas 1 pada data *testing* yang melampaui rentang pelatihan. Kondisi ini berpotensi memengaruhi kinerja *deep learning* dan respons fungsi aktivasi, meskipun pengaruh saturasi perlu diverifikasi lebih lanjut. Penambahan indikator makroekonomi juga belum meningkatkan kinerja model dan justru meningkatkan *error* pada seluruh model yang diuji. Temuan ini berlaku pada periode data, fitur, horizon prediksi, dan konfigurasi eksperimen yang digunakan, sehingga tidak dapat digeneralisasi bahwa *Naïve Forecast* selalu lebih baik daripada model *machine learning* dan *deep learning*.

IV. KESIMPULAN DAN SARAN

Hasil penelitian menunjukkan bahwa *Naïve Forecast* menghasilkan kinerja terbaik dalam prediksi harga emas 1-step ahead dengan MAE 25,9345, RMSE 37,3274, dan MAPE 0,8684%, sedangkan seluruh model regresi lainnya menghasilkan nilai R^2 negatif. Hasil tersebut menunjukkan bahwa model belum mampu mengatasi perubahan distribusi harga antara data pelatihan dan pengujian, sementara penambahan indikator makroekonomi belum meningkatkan kinerja prediksi. Penelitian selanjutnya disarankan menerapkan online learning atau incremental learning untuk memperbarui model menggunakan data terbaru, serta mengembangkan arsitektur model adaptif agar lebih mampu menyesuaikan diri terhadap perubahan pola dan tingkat harga emas. Selain itu, pemeriksaan nilai hasil normalisasi pada data pengujian diperlukan untuk mengevaluasi kemungkinan pengaruh nilai di luar rentang pelatihan terhadap kinerja model *deep learning*.

DAFTAR PUSTAKA

- [1] R. Mardiya, T. Amani, and E. D. Vidiyastutik, "Pengaruh Pendapatan, Pengetahuan Investasi, dan Literasi Keuangan Nasabah Terhadap Minat Investasi Tabungan Emas Pada PT. Pegadaian Cabang Probolinggo," *eCo-Fin*, vol. 7, no. 2, 2025, doi: 10.32877/ef.v7i2.2306.
- [2] R. W. Abdillah and S. Dwiasnati, "Penerapan Gradient Boosting Regression dalam Prediksi Pergerakan Harga Emas Berdasarkan Pendekatan Moving Average of VWAP," *InComTech: Jurnal Telekomunikasi dan Komputer*, vol. 15, no. 1, 2025, doi: 10.22441/incomtech.v15i1.28304.
- [3] E. N. Sofiyanti, S. Ulinuha, R. Okiyanto, M. Al Haris, and R. Wasono, "Peramalan Harga Emas Menggunakan Metode Fuzzy Time Series Chen dalam Investasi untuk Meminimalisir Risiko," *Journal of Mathematics, Computations and Statistics*, vol. 7, no. 1, 2024, doi: 10.35580/jmathcos.v7i1.1955.
- [4] G. Cohen and A. Aiche, "Forecasting gold price using machine learning methodologies," *Chaos Solitons Fractals*, vol. 175, 2023, doi: 10.1016/j.chaos.2023.114079.
- [5] A. R. Putri, N. A. Santoso, and B. A. Santoso, "Implementasi Algoritma Regresi Linier dan ARIMA untuk Prediksi Harga Emas," *RIGGS: Journal of Artificial Intelligence and Digital Business*, vol. 4, no. 3, 2025, doi: 10.31004/riggs.v4i3.2757.
- [6] A. Tholib, N. K. Agusmawati, and F. Khoiriyah, "PREDIKSI HARGA EMAS MENGGUNAKAN METODE LSTM DAN GRU," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, 2023, doi: 10.23960/jitet.v11i3.3250.
- [7] 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.
- [8] A. P. J. Putra, B. M. Williamsyah, A. Rizal, F. Dewanta, A. L. Prasasti, and S. Ziani, "Comparative Deep Learning Models for Indonesian Gold Price Forecasting," *Advance Sustainable Science, Engineering and Technology*, vol. 8, no. 3, 2026, doi: 10.26877/asset.v8i3.2608.
- [9] I. Ikhsani, . M., A. R. Dikananda, and . M., "PREDIKSI HARGA EMAS MENGGUNAKAN ALGORITMA SEASONAL AUTO REGRESSIVE INTEGRATED MOVING AVERAGE," *Jurnal Informasi dan Komputer*, vol. 13, no. 01, 2025, doi: 10.35959/jik.v13i01.639.
- [10] M. Jami'ul Umam, A. Jazuli, and T. Khotimah, "PREDIKSI HARGA SAHAM ANEKA TAMBANG PERSERO TBK (ANTM) MENGGUNAKAN METODE MACHINE LEARNING," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 6, 2025, doi: 10.36040/jati.v9i6.15570.
- [11] G. Bao, Y. Niu, B. Cui, and W. Ji, "Revealing the correlation between economic indicators and gold prices for forecasting: Medium term forecast framework with data patch," *Expert Syst. Appl.*, vol. 298, 2026, doi: 10.1016/j.eswa.2025.129594.
- [12] A. J. B. Nainggolan, Y. A. Hutajulu, K. Kevin, and M. N. K. Nababan, "Hybrid LSTM-XGBoost Model with Residual Error Correction for Multivariate Gold Price Forecasting Using Macroeconomic Indicators," *Research in Education, Technology, and Multiculture*, vol. 5, no. 1, 2026, doi: 10.61436/rietm/v5i1.pp60-74.
- [13] P. Simamora, S. A. Pasaribu, and Vera Wijaya, "Peningkatan dan Optimalisasi Prediksi Harga Emas Menggunakan Metode Combine Machine Learning Random Forest dan Gradient Boosting," *Jurnal Mahkota Informatika*, vol. 1, no. 1, 2025, doi: 10.59929/mahtik.v1i1.37.
- [14] P. Foroutan and S. Lahmiri, "Deep learning systems for forecasting the prices of crude oil and precious metals," *Financial Innovation*, vol. 10, no. 1, 2024, doi: 10.1186/s40854-024-00637-z.
- [15] Mohammad Sufa Ammar Habibi, Arindra Harris Abdillah, Mohammad Idhom, and Trimono Trimono, "PERBANDINGAN KINERJA GRU DAN SVR UNTUK PREDIKSI EMAS DI INDONESIA," *Informatika: Jurnal Teknik Informatika dan Multimedia*, vol. 5, no. 1, 2025, doi: 10.51903/informatika.v5i1.1105.
- [16] Edi Ismanto, Ahmad Gunawan Dalimunthe, Muhammad Iqbal, and Fauza Addinunnisa, "Analisis Perbandingan Model Machine Learning dan Deep Learning untuk Peramalan Harga Saham," *Jurnal Ilmu Komputer dan Teknik Informatika*, vol. 2, no. 1, 2026, doi: 10.64803/juikti.v2i1.114.
- [17] R. Martin, F. Faisal, I. N. Aditya, A. J. Wahidin, B. Rahmatullah, and I. Kurniawati, "Analisis Prediksi Harga Emas Menggunakan Regresi Linear dan K-Nearest Neighbors," *RIGGS: Journal of Artificial Intelligence and Digital Business*, vol. 4, no. 4, 2025, doi: 10.31004/riggs.v4i4.3606.