

COMPARATIVE ANALYSIS OF ARIMA-BMA AND LSTM-BMA MODELS FOR PREDICTING GLOBAL GOLD PRICES

ANALISIS KOMPARATIF MODEL ARIMA-BMA DAN LSTM-BMA PADA PREDIKSI HARGA EMAS DUNIA

Diaz Aria Wicaksana^{1‡}, Cut Ashifa Sawallida¹, Atha Nabilah Rosyadi¹, Nawwaf Ariq Rabbani¹, and Septian Rahardiantoro¹

¹Study Program of Statistics and Data Science, IPB University, Indonesia

[‡]corresponding author: diazaria@apps.ipb.ac.id

Copyright © 2026 Diaz Aria Wicaksana, Cut Ashifa Sawallida, Atha Nabilah Rosyadi, Nawwaf Ariq Rabbani, and Septian Rahardiantoro. This is an open-access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Abstract

Gold is a safe haven asset whose price movements tend to be volatile and nonlinear, making the prediction process challenging in financial time series analysis. This study aims to compare the performance of hybrid ARIMA-BMA and LSTM-BMA models in predicting world gold prices for the 2000–2025 period using 1,358 weekly observations of gold futures prices. Five ARIMA and five LSTM models were built as candidate models, then combined using a Bayesian Model Averaging (BMA) approach based on RMSE weighting to produce more stable and robust predictions. The evaluation results show that the ARIMA-BMA model has better performance than LSTM-BMA, with a test data MAPE value of 1.76%, RMSE of 62.19, MAE of 44.88, and R^2 of 99.24%, while LSTM-BMA produces a MAPE of 4.29%, RMSE of 204.98, MAE of 136.57, and R^2 of 91.80%. The prediction results for the next 12 weeks show that gold prices are expected to increase gradually after reaching a peak at the end of 2025, with the BMA approach proven to be able to stabilize predictions and reduce dependence on a single model.

Keywords: Autoregressive Integrated Moving Average, Gold Price Forecasting, Long Short-Term Memory, Time Series Forecasting, Bayesian Model Averaging

Abstrak

Emas merupakan salah satu aset lindung nilai yang pergerakan harganya cenderung fluktuatif dan nonlinear sehingga proses prediksi menjadi tantangan dalam analisis deret waktu finansial. Penelitian ini bertujuan membandingkan kinerja model hybrid ARIMA-BMA dan LSTM-

BMA dalam memprediksi harga emas dunia periode 2000–2025 menggunakan 1.358 observasi mingguan harga emas berjangka. Lima model ARIMA dan lima model LSTM dibangun sebagai model kandidat, kemudian masing-masing digabungkan menggunakan pendekatan Bayesian Model Averaging (BMA) berbasis pembobotan RMSE untuk menghasilkan prediksi yang lebih stabil dan robust. Hasil evaluasi menunjukkan bahwa model ARIMA-BMA memiliki performa yang lebih baik dibandingkan LSTM-BMA, dengan nilai MAPE data uji sebesar 1.76%, RMSE 62.19, MAE 44.88, dan R^2 sebesar 99.24%, sementara LSTM-BMA menghasilkan MAPE sebesar 4.29%, RMSE 204.98, MAE 136.57, dan R^2 sebesar 91.80%. Hasil prediksi untuk 12 minggu ke depan menunjukkan bahwa harga emas diperkirakan mengalami kenaikan secara bertahap setelah mencapai puncak pada akhir tahun 2025, dengan pendekatan BMA terbukti mampu menstabilkan prediksi dan mengurangi ketergantungan terhadap model tunggal.

Kata Kunci: Autoregressive Integrated Moving Average, Harga Emas, Long Short-Term Memory, Prediksi Deret Waktu, Bayesian Model Averaging

1. Pendahuluan

Emas merupakan salah satu instrumen investasi dan aset lindung nilai (*safe haven*) yang penting dalam sistem keuangan global. Ketidakpastian ekonomi, inflasi, dan kondisi geopolitik menyebabkan harga emas mengalami fluktuasi yang tinggi sehingga prediksi harga emas menjadi perhatian penting dalam analisis deret waktu finansial (Shaliha *et al.*, 2025). Karakteristik harga emas yang dinamis, volatil, dan nonlinear menjadikan analisis prediksi semakin kompleks.

Metode yang umum digunakan dalam prediksi deret waktu adalah Autoregressive Integrated Moving Average (ARIMA) dan Long Short-Term Memory (LSTM). ARIMA efektif dalam menangkap pola linear dan cukup akurat untuk peramalan jangka pendek, sedangkan LSTM mampu memodelkan pola nonlinear dan ketergantungan jangka panjang pada data (Madhika *et al.*, 2023; Sarvaiya & Ramchandani, 2022). Namun, penggunaan model tunggal masih memiliki keterbatasan karena hasil prediksi sangat dipengaruhi konfigurasi model yang digunakan.

Meskipun demikian, penggunaan satu model tunggal masih memiliki keterbatasan karena hasil prediksi sangat dipengaruhi oleh konfigurasi model dan proses pelatihan yang digunakan. Untuk mengatasi permasalahan tersebut, penelitian ini menggunakan pendekatan Bayesian Model Averaging (BMA) yang menggabungkan beberapa model berdasarkan performanya masing-masing guna meningkatkan stabilitas dan robustness prediksi (Aponso & Weerasinghe, 2026; Elmi *et al.*, 2025).

Berdasarkan hal tersebut, penelitian ini bertujuan membandingkan

performa model hybrid ARIMA-BMA dan LSTM-BMA dalam memprediksi harga emas dunia menggunakan data mingguan periode 2000–2025. Beberapa model ARIMA dan LSTM dibangun sebagai model kandidat, kemudian digabungkan menggunakan pendekatan *Bayesian Model Averaging* untuk menghasilkan prediksi yang lebih stabil dan *robust*. Selanjutnya, kinerja kedua pendekatan dibandingkan menggunakan metrik RMSE, MAE, MAPE, dan koefisien determinasi (R^2) guna menentukan model yang paling efektif dalam memprediksi harga emas dunia.

2. Metodologi

2.1 Bahan dan Data

Data pada penelitian ini adalah data sekunder berupa harga emas berjangka (COMEX Gold Futures) pada pasar komoditas internasional yang bersumber dari <https://www.investing.com/commodities/gold> dalam rentang 1 Januari 2000 hingga 31 Desember 2025. Data ini terdiri atas 1358 observasi mingguan. Peubah respon (Y) mencakup deret waktu harga emas berjangka dengan satuan USD per *troy ounce* dan peubah penjelas (X) berupa waktu.

2.2 Metode Penelitian

Metode analisis dalam penelitian ini terdiri dari empat tahap utama, yaitu praproses data, eksplorasi data, pemodelan *hybrid* ARIMA-BMA, pemodelan LSTM-BMA, serta evaluasi kinerja model. Seluruh tahapan simulasi dan pemodelan diimplementasikan menggunakan bahasa pemrograman Python dengan bantuan beberapa *library* utama, yaitu Pandas dan NumPy untuk pengolahan data, Statsmodels untuk estimasi parameter model ARIMA, TensorFlow/Keras untuk pembangunan arsitektur LSTM, Scikit-learn untuk *scaling* dan metrik evaluasi, serta Matplotlib untuk visualisasi data.

2.2.1. Praproses Data

2.2.1.1. Pengumpulan dan Integrasi Data

Tahap praproses data dimulai dengan pengumpulan data harga emas dunia yang kemudian diurutkan berdasarkan waktu pengamatan. Pada tahap ini, juga dilakukan pemeriksaan konsistensi format tanggal serta kesesuaian satuan data agar seluruh observasi memiliki struktur yang seragam.

2.2.1.2. Data Cleaning

Tahap *data cleaning* meliputi pemeriksaan *missing value*, deteksi pencilan, dan pengecekan konsistensi nilai harga emas dalam dataset. Apabila ditemukan nilai yang hilang, maka dilakukan

penanganan dengan metode interpolasi atau penghapusan observasi yang tidak lengkap agar tidak memengaruhi proses pelatihan model.

2.2.1.3. Transformasi Data

Data mentah yang telah dikumpulkan sebelumnya terlebih dahulu ditransformasi menjadi bentuk yang siap digunakan oleh model prediksi berbasis *deep learning* seperti LSTM (Zhang, 2023). Jika data memiliki rentang nilai yang cukup besar, maka dilakukan normalisasi dengan metode *Min-Max Scaling* mengubah skala data ke dalam rentang 0 hingga 1 sehingga proses pembelajaran pada model menjadi lebih stabil dan efisien.

2.2.1.4. Pembagian Data

Dataset dipartisi menjadi data latih, data validasi, dan data uji dengan proporsi masing-masing sebesar 70%, 15%, dan 15%. Data latih digunakan untuk membangun model, data validasi digunakan untuk mengevaluasi performa model serta menentukan bobot BMA, sedangkan data uji digunakan untuk mengevaluasi kemampuan prediksi model terhadap data baru.

2.2.2. Eksplorasi Data

Tahap ini bertujuan untuk memahami karakteristik awal data harga emas.

2.2.2.1. Statistik Deskriptif

Analisis deskriptif dilakukan untuk menghitung statistik yang bisa menggambarkan karakteristik data. Statistik yang dihitung meliputi nilai rata-rata, median, nilai minimum, nilai maksimum, standar deviasi, serta nilai *skewness* dan *kurtosis*

2.2.2.2. Visualisasi Data

Visualisasi data dilakukan dengan membuat grafik deret waktu untuk mengamati pola pergerakan harga emas dari waktu ke waktu. Melalui visualisasi ini, dapat diidentifikasi adanya tren jangka panjang maupun fluktuasi harga yang terjadi pada periode tertentu.

2.2.3. Pemodelan Hybrid ARIMA-BMA dan LSTM-BMA

2.2.3.1. Model *Autoregressive Integrated Moving Average* (ARIMA)

ARIMA adalah metode peramalan deret waktu berdasarkan hubungan linier antara nilai saat ini dan nilai masa lalu. Pemodelan ini

memanfaatkan pola historis untuk memprediksi nilai di masa mendatang dan efektif untuk peramalan jangka pendek, tetapi kurang optimal untuk jangka panjang karena hasil prediksi cenderung stabil atau tidak banyak berubah (Mukron *et al.*, 2021). ARIMA juga dikembangkan dengan proses *differencing* untuk mengatasi ketidakstasioneran pada data. Persamaan umum model ARIMA (p, d, q) dituliskan dalam persamaan berikut :


$$\phi(B)(1-B)^d y_t = \delta + \theta(B)\varepsilon_t \quad (1)$$

dengan y_t melambangkan nilai deret waktu pada periode ke- t , $\phi(B)$ merupakan operator *autoregressive* (AR), $(1-B)^d$ adalah operator *differencing*, $\theta(B)$ adalah operator *moving average* (MA), δ adalah konstanta model, dan ε_t adalah error acak (*white noise*).

Penelitian ini menggunakan lima model ARIMA sebagai model kandidat, yaitu ARIMA(1,1,1), ARIMA(2,1,1), ARIMA(1,1,2), ARIMA(2,1,2), dan ARIMA(3,1,1). Variasi model dibangun melalui parameter autoregressive (p) dan moving average (q), sedangkan differencing (d=1) digunakan untuk menjaga kestasioneran data. Evaluasi model dilakukan menggunakan walk-forward validation dengan pendekatan expanding window dan skema one-step ahead forecasting, di mana model diperbarui pada setiap iterasi menggunakan seluruh data historis yang tersedia (Montolalu *et al.*, 2024). Selanjutnya, seluruh model dikombinasikan menggunakan Bayesian Model Averaging berbasis pembobotan RMSE untuk menghasilkan prediksi yang lebih stabil dan robust.

2.2.3.2. Model Long-Short-Term Memory (LSTM)

LSTM merupakan pengembangan dari Recurrent Neural Network (RNN) yang dirancang untuk mengatasi permasalahan *vanishing gradient* pada data deret waktu. Arsitektur ini mampu mempertahankan informasi dari periode sebelumnya sehingga efektif dalam menangkap ketergantungan jangka panjang dan pola nonlinear pada data finansial. LSTM memiliki mekanisme *memory cell* yang mengatur aliran informasi masuk, disimpan, dan dikeluarkan selama proses pembelajaran (Goodfellow *et al.*, 2016).



Gambar 1: Ilustrasi arsitektur *Long Short-Term Memory* sel tunggal.
Sumber: diadaptasi dari Lang (2022).

Forget gate berfungsi untuk menentukan informasi mana dari *cell state* sebelumnya yang perlu dipertahankan atau dihapus. Mekanisme ini menggunakan fungsi aktivasi sigmoid untuk menghasilkan nilai antara 0 dan 1 yang merepresentasikan tingkat kepentingan informasi dari waktu sebelumnya.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (2)$$

Input gate berperan dalam menentukan informasi baru yang akan dimasukkan ke dalam *cell state*. Proses ini terdiri dari dua langkah, yaitu menentukan nilai yang akan diperbarui menggunakan fungsi sigmoid serta menghasilkan kandidat nilai baru menggunakan fungsi aktivasi *tanh*. Nilai kandidat tersebut kemudian digunakan untuk memperbarui *cell state*.

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (3)$$

$$\hat{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (4)$$

Output gate menentukan informasi yang akan dikeluarkan sebagai hidden state pada waktu ke-t. Proses ini dilakukan dengan menggunakan fungsi sigmoid untuk menentukan bagian *cell state* yang akan ditampilkan sebagai *output*. Selanjutnya perkalian dari *output gate* sigmoid akan menghasilkan nilai akhir *hidden state*.

$$\sigma_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \times \tanh(C_t) \quad (6)$$

Di mana x_t menyatakan vektor input pada waktu ke-t, h_{t-1} merupakan *hidden state* dari waktu sebelumnya, C_{t-1} adalah *cell state* dari waktu sebelumnya, C_t merupakan *cell state* yang telah diperbarui, dan h_t menyatakan *hidden state* pada waktu ke-t. Selanjutnya, W menunjukkan bobot (*weight*) pada jaringan, sedangkan b menyatakan bias pada model.

Penelitian ini menggunakan beberapa model LSTM dengan *window size* 52, *optimizer* Adam dengan *learning rate* adaptif, *batch size* 16, jumlah *epoch* 30, dan *random seed* 42 untuk menjaga reproduktibilitas. Arsitektur sel LSTM memanfaatkan fungsi aktivasi sigmoid pada setiap *gate* serta *hyperbolic tangent* (*tanh*) untuk pemrosesan *cell state* dan *hidden state*. Keragaman model dibangun melalui variasi jumlah neuron dan nilai *dropout rate* (0.1-0.3) yang disesuaikan secara proporsional dengan kompleksitas model sebagai teknik regularisasi untuk mengurangi risiko *overfitting* (Srivastava *et al.*, 2014).

2.2.3.3. Bayesian Model Averaging

Dalam proses pemodelan prediksi seringkali terdapat ketidakpastian dalam pemilihan model yang paling tepat. Untuk mengatasi permasalahan tersebut digunakan pendekatan BMA. Metode BMA

menggabungkan beberapa model prediksi dengan memberikan bobot berdasarkan probabilitas posterior dari masing-masing model. Dengan pendekatan ini prediksi akhir diperoleh dari rata-rata berbobot seluruh model kandidat sehingga ketidakpastian model dapat diperhitungkan secara sistematis. Secara umum, apabila terdapat M model kandidat yang dinyatakan sebagai $m_1, m_2, \dots, m_M$, maka distribusi posterior dari parameter atau besaran prediksi θ berdasarkan data Y dapat dirumuskan sebagai berikut:

$$p(\theta | y) = \prod_{m=1}^M p(m | y) \cdot p(\theta | y, m) \quad (7)$$

Pada persamaan tersebut, M menyatakan jumlah model kandidat, $p(m|y)$ adalah probabilitas posterior model ke- m , dan $p(\theta|y, m)$ adalah distribusi posterior parameter dengan syarat model ke- m . Persamaan ini menunjukkan bahwa inferensi tidak hanya didasarkan pada satu model, tetapi pada seluruh model yang digabungkan secara probabilistik.

Dalam penelitian ini, model kandidat dibentuk dari beberapa spesifikasi model prediksi yang berbeda. Masing-masing model menghasilkan prediksi harga emas yang dinyatakan sebagai y_m . Selanjutnya, prediksi akhir dengan BMA diperoleh melalui rata-rata berbobot sebagai berikut:

$$\widehat{y}_{BMA} = \sum_{m=1}^M W_m \cdot \widehat{y}_m \quad (8)$$

dengan W_m adalah bobot posterior model ke- m . Nilai bobot ini mencerminkan seberapa besar dukungan data terhadap model tersebut.

Dalam implementasinya, bobot posterior model dapat didekati menggunakan ukuran kesalahan prediksi. Mengacu pada jurnal rujukan, bobot model dapat dihitung berdasarkan nilai *Root Mean Squared Error* (RMSE) sebagai berikut:

$$W_m \propto \exp\left(-\frac{1}{2}RMSE_m\right) \quad (9)$$

Bobot model dihitung menggunakan pendekatan *exponential weighting* berdasarkan nilai RMSE pada data validasi, sehingga model dengan nilai RMSE lebih kecil akan memperoleh bobot lebih besar. Jika $RMSE_i$ menyatakan nilai RMSE model ke- i , maka bobot model dihitung menggunakan persamaan berikut:

$$w_i = \frac{e^{-RMSE_i}}{\sum_{j=1}^K e^{-RMSE_j}} \quad (10)$$

Dengan w_i menyatakan bobot model ke- i , menyatakan nilai RMSE model ke- i , dan K merupakan jumlah model kandidat. Agar bobot dapat dibandingkan antar model, seluruh bobot kemudian dinormalisasi sehingga $\sum W_m = 1$.

Pendekatan BMA memberikan bobot lebih besar pada model dengan tingkat kesalahan rendah tanpa mengabaikan model lainnya. Pada data harga emas yang fluktuatif, BMA tidak hanya meningkatkan akurasi, tetapi juga mengurangi risiko ketergantungan pada model tunggal sehingga menghasilkan prediksi yang lebih stabil dan *robust* (Hoeting *et al.*, 1999).

2.2.4. Evaluasi Model

Tahap ini bertujuan mengevaluasi performa model dalam memprediksi harga emas. Evaluasi dilakukan menggunakan beberapa metrik kesalahan prediksi, yaitu:

2.2.4.1. Mean Absolute Percentage Error

Mean Absolute Percentage Error (MAPE) digunakan untuk mengukur rata-rata persentase dari kesalahan absolut antara nilai yang diprediksi dan nilai yang sebenarnya. Semakin rendah nilai MAPE, semakin baik kemampuan model dalam melakukan prediksi.

2.2.4.2. Root Mean Squared Error

Root Mean Squared Error (RMSE) digunakan untuk menentukan rata-rata kesalahan kuadrat antara nilai yang diprediksi dan nilai yang sebenarnya. Nilai RMSE yang lebih kecil menunjukkan bahwa model memiliki kemampuan prediksi yang lebih baik.

2.2.4.3. Mean Absolute Error

Mean Absolute Error (MAE) digunakan untuk menghitung rata-rata dari nilai absolut selisih antara nilai yang diprediksi dan nilai yang sebenarnya. Jika nilai MAE semakin kecil, hal ini menunjukkan bahwa model memiliki kemampuan prediksi yang lebih baik.

2.2.4.4. Koefisien Determinasi (R^2)

Koefisien determinasi (R^2) menghitung kemampuan model untuk menjelaskan variasi data aktual, dengan nilai berkisar antara 0 hingga 1. Nilai yang mendekati 1 menunjukkan tingkat kecocokan model yang tinggi (*goodness of fit*), sedangkan nilai yang mendekati 0 menunjukkan kemampuan penjelasan yang rendah terhadap variabilitas data.

2.2.5. Prediksi Harga Emas

Setelah model *hybrid* ARIMA-BMA dan LSTM-BMA diperoleh dan dievaluasi performanya, dilakukan prediksi harga emas dunia untuk 12

periode mingguan ke depan menggunakan pendekatan *multi-step forecasting* model dengan performa paling baik.

3. Hasil dan Pembahasan

3.1 Praproses Data

Dataset harga emas dunia terdiri atas 1358 observasi mingguan dengan tujuh peubah, yaitu Tanggal, Close, Open, High, Low, Volume, dan Change, serta tidak ditemukan *missing value*. Format data kemudian disesuaikan dan data diurutkan berdasarkan waktu pengamatan.

Pada tahap praproses, model LSTM menggunakan fitur tambahan berupa *return*, *moving average* 12 minggu (*ma_12*), dan *volatility* yang dinormalisasi menggunakan *Min-Max Scaling*. Sementara itu, model ARIMA menggunakan data deret waktu *Close* serta penentuan manual untuk kandidat model. Pada model LSTM, data dibentuk menjadi input sekuensial dengan *window size* 52 minggu, sedangkan pada model ARIMA digunakan pendekatan *walk-forward validation*.

3.2 Eksplorasi Data

Eksplorasi data dilakukan dengan menghitung statistik deskriptif yang dirincikan pada Tabel 1.

Tabel 1: Statistik deskriptif data

Rata-rata	Median	Nilai Min	Nilai Maks	Standar Deviasi	Skewness	Kurtosis
1230.316	1238.8	258.4	4534.8	741.786	1.08	2.21

Berdasarkan hasil statistik deskriptif, dapat diketahui bahwa data memiliki rentang nilai yang cukup besar. Selain statistik deskriptif, eksplorasi juga dilakukan dengan visualisasi berupa plot deret waktu harga emas mingguan yang bertujuan untuk melihat pola pergerakan harga selama waktu pengamatan.



Gambar 2: Plot harga emas mingguan periode 2000-2025.

Berdasarkan Gambar 2, harga emas menunjukkan tren meningkat disertai fluktuasi yang semakin kuat pada akhir periode pengamatan. Pola ini mengindikasikan bahwa data bersifat dinamis dan tidak stasioner, sehingga diperlukan metode prediksi yang mampu menangkap pola temporal dan ketergantungan jangka panjang.

3.3 Model Hybrid ARIMA-BMA

Tabel 2: Konfigurasi model ARIMA dan proporsi bobot BMA

Model	Konfigurasi				Proporsi Bobot (<i>Weight</i>)
	Ordo (p, d, q)	AR (p)	Differencing (d)	MA (q)	
1	ARIMA (1, 1, 1)	1	1	1	0.2167
2	ARIMA (2, 1, 1)	2	1	1	0.1847
3	ARIMA (1, 1, 2)	1	1	2	0.2069
4	ARIMA (2, 1, 2)	2	1	2	0.1850
5	ARIMA (3, 1, 1)	3	1	1	0.2068

3.4 Model Hybrid LSTM-BMA

Tabel 3: Konfigurasi model LSTM dan proporsi bobot BMA

Model	Konfigurasi				Proporsi Bobot (<i>Weight</i>)
	<i>Random Seed</i>	Neuron Layer 1	Dropout Rate	Neuron Layer 2	
1	42	32	0.10	16	0.1985
2	42	64	0.10	32	0.2003
3	42	64	0.20	32	0.2004
4	42	96	0.20	48	0.2004
5	42	128	0.30	64	0.2003


3.5 Evaluasi Kinerja Model

Penilaian dilakukan melalui kombinasi analisis metrik kesalahan serta grafik perbandingan nilai aktual dan hasil prediksi. Hasil evaluasi secara kuantitatif pada Tabel 4 dan hasil evaluasi secara visualisasi disajikan pada Gambar 3.

Tabel 4: Metrik evaluasi kinerja model Hybrid ARIMA-BMA dan LSTM-BMA

Model	MAPE Train (%)	MAPE Test (%)	RMSE	MAE	R^2 (%)
ARIMA-BMA	1.90	1.76	62.19	44.88	99.24
LSTM-BMA	2.24	4.29	204.98	136.57	91.80


Berdasarkan Tabel 4, model *hybrid* ARIMA-BMA menunjukkan performa yang lebih baik dibandingkan LSTM-BMA berdasarkan nilai MAPE, RMSE, dan MAE yang lebih rendah.



Gambar 3: Plot perbandingan data aktual dan hasil pada prediksi model hybrid ARIMA-BMA (a) dan LSTM-BMA (b).

Secara visual maupun berdasarkan metrik evaluasi, model ARIMA-BMA menghasilkan prediksi yang lebih mendekati data aktual dibandingkan LSTM-BMA. Hal ini menunjukkan bahwa ARIMA masih lebih optimal digunakan pada dataset berukuran kecil hingga menengah karena mampu menangkap pola linear data deret waktu secara lebih stabil. Hal ini sejalan dengan penelitian Mahajan (2026) yang menjelaskan bahwa ARIMA lebih sesuai digunakan pada forecasting dengan historical data terbatas, sedangkan LSTM umumnya membutuhkan data dalam jumlah besar agar dapat mempelajari pola nonlinear secara optimal.

3.6 Prediksi Harga Emas



Gambar 4: Plot hasil prediksi model hybrid Arima-BMA

Berdasarkan plot pada Gambar 4, Setelah memuncak di akhir 2025, harga emas diproyeksikan mengalami fase koreksi berupa kenaikan bertahap selama 12 minggu. Penggunaan pendekatan *Bayesian Model Averaging* (BMA) berhasil menyeimbangkan lima model ARIMA, sehingga meminimalisir fluktuasi jangka pendek dan menghasilkan prediksi yang lebih stabil pada awal 2026.

4. Simpulan dan Saran

Penelitian ini menunjukkan bahwa model ARIMA-BMA memiliki performa lebih baik dibandingkan LSTM-BMA dalam memprediksi harga emas dunia

periode 2000–2025, ditunjukkan oleh nilai kesalahan prediksi yang lebih rendah dan nilai R^2 yang lebih tinggi. Meskipun demikian, model LSTM-BMA tetap mampu menangkap pola temporal dan nonlinear dengan cukup baik. Hasil prediksi menunjukkan bahwa harga emas cenderung meningkat secara bertahap dalam 12 minggu ke depan. Penelitian selanjutnya disarankan menambahkan variabel eksternal seperti inflasi, nilai tukar, suku bunga, dan indeks dolar AS, serta mengembangkan model deep learning lain seperti GRU, Transformer, atau Attention-based model untuk meningkatkan akurasi prediksi.

Daftar Pustaka

- Aponsu, L., & Weerasinghe, L. (2026). Hybrid LSTM Forecasting Framework with Bayesian Model Averaging for Robust Exchange Rate Prediction. *International Journal of Advanced Networking and Applications*, 17(4), 7055-7061.
- Elmi, S., & Yanti, R. (2025). Prediksi Emisi CO2 di Indonesia Menggunakan Pendekatan Hybrid ARIMA dan LSTM. *BETRIK*, 16(02), 95-108.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
- Hoeting, J. A., Madigan, D., Raftery, A. E., & Volinsky, C. T. (1999). Bayesian Model Averaging: A Tutorial. *Statistical Science*, 14(4), 382-401.
- Lang, N. (2022). Long Short-Term Memory Networks (LSTM)- Simply Explained!. Data Basecamp.
- Madhika, Y. R., Kusriani, & Hidayat, T. (2023). Gold price prediction using the ARIMA and LSTM models. *Sinkron: Jurnal dan Penelitian Teknik Informatika*, 7(3), 1255–1264. <https://doi.org/10.33395/sinkron.v8i3.12461>
- Mahajan, H. (2026). *Comparative Study of Arima, Lstm and Prophet Models for Time Series Forecasting: A Comprehensive Review*. In Review. <https://doi.org/10.21203/rs.3.rs-8615640/v1>
- Mukron, M. H., Susianti, I., Azzahra, F., Kumala, Y. N., Widiyana, F. R., & Al Haris, M. (2021). Peramalan indeks harga konsumen Indonesia menggunakan autoregressive integrated moving average. *Jurnal Statistika Industri dan Komputasi*, 6(1), 20–25
- Sarvaiya, D., & Ramchandani, D. (2022). Time Series Analysis and Forecasting of Gold Price using ARIMA and LSTM Model. *International Journal for Research in Applied Science and Engineering Technology*, 10(9), 168–173. <https://doi.org/10.22214/ijraset.2022.46555>
- Shaliha, S. K., Zahwarani, A., Ilma, A. F. N., & Rahajuni, D. (2025). Dinamika ketidakpastian pasar keuangan global terhadap stabilitas

harga emas sebagai safe haven asset. *Journal of Economics Research and Policy Studies*, 5(3), 845-857.

Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(1), 1929–1958.

Zhang, K., Huo, X., & Shao, K. (2023). Temperature time series prediction model based on time series decomposition and Bi-LSTM network. *Mathematics*, 11(9), 2060. <https://doi.org/10.3390/math11092060>.