



## Peramalan Harga Emas Berbasis Time Series Menggunakan Arsitektur LSTM Deep Learning

Diva Arifal Adha<sup>1</sup>, Adam Ramadhan<sup>2</sup>, Habil Maulana<sup>3</sup>, Patlan Putra Humala Harahap<sup>4</sup>, Edi Ismanto<sup>5</sup>

Email: <sup>1</sup>230401007@student.umri.ac.id, <sup>2</sup>230401015@student.umri.ac.id, <sup>3</sup>230401004@student.umri.ac.id, <sup>4</sup>230401043@student.umri.ac.id, <sup>5</sup>edi.ismanto@umri.ac.id

<sup>1,2,3,4,5</sup>Teknik Informatika, Fakultas Ilmu dan Komputer, Universitas Muhammadiyah Riau

Diterima: 07 Agustus 2015 | Direvisi: - | Disetujui: 31 Agustus 2025

©2025 Program Studi Teknik Informatika Fakultas Ilmu Komputer,  
Universitas Muhammadiyah Riau, Indonesia

### Abstrak

Harga emas merupakan salah satu komoditas yang sangat berpengaruh dalam perekonomian global. Fluktuasi harga emas yang tinggi menjadi tantangan tersendiri bagi investor, analis keuangan, dan pengambil kebijakan dalam menentukan strategi dan keputusan yang tepat. Oleh karena itu, diperlukan metode prediksi yang akurat untuk memperkirakan pergerakan harga emas di masa depan. Penelitian ini bertujuan untuk melakukan peramalan harga emas menggunakan pendekatan *deep learning* dengan algoritma *Long Short-Term Memory* (LSTM). Model LSTM memiliki kemampuan dalam mempelajari ketergantungan jangka panjang pada data deret waktu (*time series*), sehingga cocok untuk memodelkan data historis emas yang kompleks dan dinamis. Data yang digunakan dalam penelitian ini berupa data historis harga emas harian yang diperoleh dari sumber terpercaya. Proses *pre-processing* dilakukan untuk membersihkan dan menormalisasi data sebelum digunakan dalam pelatihan model. Selain itu, penelitian ini juga membandingkan kinerja model LSTM dengan model *Multilayer Variate* untuk membuat prediksi lebih dari satu fitur. Evaluasi dilakukan menggunakan metrik *Mean Squared Error* (MSE) dan *Root Mean Squared Error* (RMSE). Hasil penelitian menunjukkan bahwa model LSTM memberikan hasil prediksi yang lebih akurat dibandingkan MLP, dengan nilai kesalahan yang lebih rendah dan stabilitas model yang lebih baik. Dengan demikian, pendekatan *deep learning* khususnya LSTM dapat digunakan sebagai alternatif yang efektif dalam peramalan harga emas dan mendukung pengambilan keputusan dalam bidang keuangan.

**Kata kunci:** Harga emas, Deep learning, Peramalan, LSTM, Time series

## Gold Price Forecasting Based on Time Series Using the LSTM Deep Learning Architecture

### Abstract

Gold is one of the most influential commodities in the global economy. Its high price volatility poses a significant challenge for investors, financial analysts, and policymakers in formulating effective strategies and making accurate decisions. Therefore, an accurate prediction method is needed to forecast future gold price movements. This study aims to forecast gold prices using a deep learning approach with the Long Short-Term Memory (LSTM) algorithm. The LSTM model is capable of learning long-term dependencies in time-series data, making it highly suitable for modeling complex and dynamic financial data. The data used in this study consists of daily historical gold prices obtained from reliable sources. A preprocessing phase was carried out to clean and normalize the data before training the model. Furthermore, this study compares the performance of the LSTM model with the Multilayer Perceptron (MLP) model to examine differences in prediction accuracy. Evaluation metrics such as Mean Squared Error (MSE) and Root Mean Squared Error (RMSE) were used to assess model performance. The results show that the LSTM model provides more accurate predictions compared to MLP, with lower error values and better model stability. In conclusion, the deep learning approach, particularly the LSTM model, can serve as an effective alternative for gold price forecasting and support data-driven decision-making in the financial sector.

**Keywords:** Gold Price, Deep learning, Forecasting, LSTM, Time series

## 1. PENDAHULUAN

Emas merupakan salah satu logam mulia yang sejak lama digunakan sebagai alat tukar dan investasi karena nilainya yang relatif stabil serta kecenderungan mengalami peningkatan dari waktu ke waktu [1]. Stabilitas nilai emas menjadikannya aset yang banyak diminati masyarakat untuk menghadapi ketidakpastian ekonomi, termasuk inflasi, krisis global, dan fluktuasi nilai tukar [2]. Dalam praktiknya, harga emas tidak selalu bergerak secara linier dan dapat mengalami fluktuasi tajam yang dipengaruhi oleh faktor internal maupun eksternal, seperti suku bunga, inflasi, nilai tukar mata uang, harga minyak mentah, hingga indeks pasar saham [3][4]. Meningkatnya ketertarikan masyarakat terhadap investasi digital pasca pandemi COVID-19 juga turut mendorong lonjakan transaksi emas sebagai bentuk lindung nilai (*hedging*) dari penurunan daya beli [5].

Namun, tingginya volatilitas harga emas menimbulkan tantangan tersendiri bagi investor, sehingga dibutuhkan sistem yang mampu memprediksi harga emas secara akurat untuk mendukung pengambilan keputusan investasi [6]. Prediksi harga emas selama ini telah dilakukan menggunakan berbagai pendekatan matematis dan statistik. Salah satu metode konvensional yang masih banyak digunakan adalah *Autoregressive Integrated Moving Average* (ARIMA) karena kemampuannya dalam mengakomodasi pola data deret waktu [2]. Namun, penelitian menunjukkan bahwa akurasi ARIMA cenderung menurun ketika diaplikasikan pada data fluktuatif dalam jangka panjang.

Hal ini mendorong peneliti untuk mengembangkan pendekatan yang lebih adaptif, salah satunya dengan memanfaatkan *machine learning*, khususnya *deep learning*. LSTM (*Long Short-Term Memory*) adalah jenis jaringan syaraf tiruan yang merupakan pengembangan dari *Recurrent Neural Network* (RNN) dan dirancang untuk mengatasi permasalahan *vanishing gradient* pada data deret waktu [7]. Dengan struktur memori jangka panjang yang kompleks, LSTM mampu menangkap pola jangka pendek maupun panjang pada data *time-series* seperti harga emas. Dalam penelitian sebelumnya, LSTM menunjukkan performa unggul dibandingkan ARIMA maupun regresi linier, khususnya pada data dengan pola tidak linear dan bersifat fluktuatif [8].


Berbagai penelitian telah membuktikan efektivitas LSTM dalam melakukan peramalan harga emas. Madhika et al. (2023) menunjukkan bahwa LSTM menghasilkan nilai *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE) yang lebih kecil dibandingkan ARIMA dalam memprediksi harga emas global, dengan RMSE sebesar 8.124 dan MAPE 0.023. Guo (2024) dalam studinya mencatat akurasi LSTM mencapai 96.9% pada prediksi harga emas berdasarkan data tahun 2013–2023, yang memberikan dampak signifikan terhadap efisiensi pasar emas global. Penelitian lain juga menunjukkan bahwa meskipun *Gated Recurrent Unit* (GRU) memiliki akurasi yang cukup tinggi, namun nilai error LSTM secara umum lebih rendah berdasarkan evaluasi MAE, RMSE, dan MAPE [9][10].

Kelebihan LSTM dalam menangani data deret waktu menjadikannya pilihan utama dalam penelitian ini. Akan tetapi, studi perbandingan juga menunjukkan bahwa efektivitas model LSTM sangat tergantung pada konfigurasi parameter dan *pre-processing* data yang digunakan. Untuk itu, penting dilakukan eksperimen ulang yang komprehensif terhadap data harga emas terkini, khususnya pada konteks Indonesia, agar dapat memberikan referensi prediksi yang lebih relevan secara lokal. Selain pendekatan *deep learning*, pendekatan matematis seperti interpolasi polinomial Newton dan Lagrange juga telah digunakan untuk memprediksi fluktuasi harga emas. Meskipun lebih sederhana, pendekatan ini memiliki keterbatasan akurasi pada data berskala besar dan sangat fluktuatif.

Oleh karena itu, integrasi pendekatan berbasis *data mining* dan *deep learning* semakin menjadi fokus penelitian modern dalam upaya meminimalkan risiko investasi dan meningkatkan ketepatan estimasi harga emas. Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model prediksi harga emas berbasis algoritma *Long Short-Term Memory* (LSTM) menggunakan data historis harga emas dengan *pre-processing* dan konfigurasi parameter yang optimal. Diharapkan hasil dari penelitian ini dapat memberikan kontribusi nyata dalam membantu investor individu maupun institusional dalam mengambil keputusan investasi emas secara lebih cermat dan akurat.

## 2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen berbasis pemodelan prediktif menggunakan algoritma *Long Short-Term Memory* (LSTM). Tujuan utama dari penelitian ini adalah untuk membangun model prediksi harga emas harian berdasarkan data historis menggunakan jaringan saraf tiruan berbasis waktu. Pendekatan LSTM dipilih karena kemampuannya yang unggul dalam menangkap pola temporal dan ketergantungan jangka panjang pada data deret waktu, yang tidak dapat ditangani secara efektif oleh algoritma regresi tradisional.



Gambar 1. Alur Penelitian

### 2.1 Pengumpulan dan Pemrosesan Data

Data yang digunakan dalam penelitian ini merupakan data historis harga emas harian yang diperoleh dari sumber terbuka dalam format CSV dengan nama file Gold\_Price.csv. Dataset ini memuat informasi harga emas dengan atribut utama seperti Date, Open, High, Low, dan Price dan dengan jumlah isi sebanyak 2577 Record Data. Rentang tanggal historis pada data diketahui dari awal tahun 2013 hingga akhir tahun 2022. Setelah itu data kemudian dimuat menggunakan library *pandas* dalam *Python* dan diubah tipe datanya, khususnya kolom Date, ke dalam format *datetime* agar dapat diurutkan secara kronologis dan digunakan dalam pembuatan deret waktu. Setelah data dimuat, dilakukan pemeriksaan terhadap keberadaan nilai kosong (*missing values*) dan duplikasi data. Nilai kosong yang ditemukan pada baris tertentu dihapus karena proporsinya sangat kecil dan tidak signifikan terhadap keseluruhan data. Data juga dibersihkan dari karakter non-numerik pada nilai harga seperti tanda dolar (\$) agar dapat dikonversi ke tipe numerik (*float*).

	Date	Price	Open	High	Low
0	2022-12-30	1826.2	1821.8	1832.4	1819.8
1	2022-12-29	1826.0	1812.3	1827.3	1811.2
2	2022-12-28	1815.8	1822.4	1822.8	1804.2
3	2022-12-27	1823.1	1808.2	1841.9	1808.0
4	2022-12-23	1804.2	1801.0	1812.2	1798.9
...	...	...	...	...	...
2573	2013-01-08	1663.2	1651.5	1662.6	1648.8
2574	2013-01-07	1647.2	1657.3	1663.8	1645.3
2575	2013-01-04	1649.9	1664.4	1664.4	1630.0
2576	2013-01-03	1675.6	1688.0	1689.3	1664.3
2577	2013-01-02	1689.9	1675.8	1695.0	1672.1

Gambar 2. Dataset Historis Harga Emas

### 2.2 Eksplorasi dan Analisis Data


Eksplorasi data dilakukan untuk memahami distribusi serta hubungan antar fitur dalam dataset. Salah satu metode utama yang digunakan adalah visualisasi *heatmap* korelasi *Pearson*. Visualisasi ini menggambarkan seberapa kuat hubungan antar fitur seperti Open, High, Low, dan Price. Hasil analisis menunjukkan korelasi yang sangat tinggi (nilai > 0.99) antar fitur tersebut, sehingga seluruhnya dipertahankan sebagai variabel input dalam model. Visualisasi *heatmap* dibuat menggunakan library *seaborn*.

### 2.3 Pelatihan Model Arsitektur LSTM

*Long Short-Term Memory* (LSTM) adalah salah satu arsitektur jaringan saraf tiruan yang dikembangkan dari *Recurrent Neural Network* (RNN), yang dirancang khusus untuk menangani permasalahan data berurutan atau *time series*. LSTM pertama kali

diperkenalkan untuk mengatasi kelemahan utama RNN, yaitu masalah *vanishing gradient*, yang terjadi saat jaringan dilatih pada data dengan ketergantungan jangka panjang. RNN secara umum bekerja dengan mengandalkan konteks historis melalui pemrosesan berulang, tetapi sering gagal mempertahankan informasi penting dalam jangka waktu yang lama karena gradien yang menghilang selama proses *backpropagation* [11].

Untuk mengatasi masalah tersebut, LSTM memperkenalkan struktur khusus yang disebut sebagai *memory cell*, yang memiliki kemampuan untuk menyimpan informasi dalam periode waktu panjang. Arsitektur LSTM terdiri dari tiga komponen utama: *input gate*, *forget gate*, dan *output gate*. *Forget gate* berfungsi menentukan informasi apa yang akan dibuang dari memori berdasarkan kombinasi input saat ini dan status sebelumnya. Sementara itu, *input gate* mengontrol informasi baru yang akan disimpan dalam *cell state*, dan *output gate* menentukan bagian dari *cell state* yang akan dihasilkan sebagai output jaringan pada waktu tertentu [12]. Secara matematis, fungsi kerja LSTM dijelaskan melalui serangkaian persamaan aktivasi, yang masing-masing merepresentasikan proses internal dari setiap *gate*. Yang dirumuskan sebagai berikut:



Gambar 3. Arsitektur LSTM

Formula LSTM:

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

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_t, x_t] + b_C) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

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

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

Keunggulan utama LSTM terletak pada struktur internalnya yang kompleks, yang terdiri dari tiga komponen utama yang disebut sebagai gerbang (*gate*). Gerbang-gerbang ini terdiri dari *forget gate*, *input gate*, dan *output gate*, yang masing-masing memiliki fungsi mengatur aliran informasi di dalam jaringan. *Forget gate* menentukan informasi lama mana yang perlu dilupakan, input gate mengatur informasi baru apa yang akan disimpan, sedangkan output gate memilih informasi mana yang akan diteruskan ke tahap berikutnya. Dengan mekanisme ini, LSTM dapat belajar dari informasi masa lalu, mempertahankannya selama periode yang relevan, dan menggunakannya untuk membuat prediksi yang lebih akurat [13].

Dalam penerapannya, LSTM terbukti unggul dalam memodelkan data time series seperti prediksi harga komoditas, estimasi umur transformator, dan peramalan kebutuhan stok farmasi. Penelitian yang membandingkan LSTM dengan metode lain seperti *Multilayer Perceptron* (MLP), ARIMA, atau metode statistik konvensional secara konsisten menunjukkan bahwa LSTM menghasilkan akurasi yang lebih tinggi dalam banyak kasus, terutama karena kemampuannya mengelola dependensi temporal dalam data historis secara efektif [14][15]. Dengan kemampuannya ini, LSTM menjadi salah satu fondasi penting dalam pengembangan sistem prediktif berbasis deep learning saat ini.

Model prediksi dirancang menggunakan *library Keras* dari *TensorFlow*. Model menggunakan arsitektur *Sequential* dengan satu lapisan LSTM sebanyak 64 unit, diikuti oleh *Dropout* sebesar 0.2 untuk mencegah *overfitting*, dan satu *Dense layer* sebagai

output layer untuk prediksi harga emas. Optimizer yang digunakan adalah Adam dengan fungsi kehilangan mean squared error (MSE). Konfigurasi pelatihan dilakukan selama 50 epoch dengan batch size sebesar 32, seperti ditunjukkan pada sintaks berikut:

## 2.4 Evaluasi Model

Evaluasi kinerja model dilakukan dengan menggunakan metrik evaluasi yang bertujuan untuk mengukur tingkat akurasi hasil prediksi. Dalam konteks pemodelan deret waktu (time-series), proses evaluasi dilakukan dengan menghitung tingkat kesalahan (error) antara nilai prediksi dan nilai aktual. Beberapa metrik yang umum digunakan dalam evaluasi model deret waktu antara lain adalah Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE), yang juga diadopsi dalam penelitian ini.

Mean Absolute Error (MAE) menghitung rata-rata kesalahan absolut tanpa mempertimbangkan arah kesalahan, karena setiap selisih antara nilai prediksi dan aktual diubah menjadi nilai absolut. Oleh karena itu, MAE dianggap sebagai metrik yang intuitif dalam merepresentasikan besarnya kesalahan rata-rata dari keseluruhan data yang diamati.

Mean Squared Error (MSE) merupakan salah satu metrik evaluasi yang paling umum digunakan dalam analisis regresi, termasuk dalam pemodelan deret waktu. MSE menghitung rata-rata dari kuadrat selisih antara nilai prediksi dan nilai aktual, sehingga memberikan bobot kesalahan yang lebih besar terhadap deviasi yang signifikan. Dengan demikian, MSE tidak hanya mencerminkan akurasi rata-rata prediksi, tetapi juga sensitivitas terhadap kesalahan besar (outliers). Nilai MSE yang rendah mengindikasikan bahwa model memiliki tingkat kesalahan prediksi yang minimal secara konsisten. Oleh karena itu, semakin kecil nilai MSE, maka semakin baik kemampuan model dalam merepresentasikan pola data yang sebenarnya.

Root Mean Square Error (RMSE) merepresentasikan besarnya rata-rata kesalahan prediksi yang dihitung dalam satuan yang sama dengan data aslinya. RMSE memberikan penalti yang lebih besar terhadap kesalahan yang signifikan karena kesalahan kuadrat yang diperhitungkan dalam perhitungannya. Semakin kecil nilai RMSE mendekati nol menunjukkan bahwa prediksi model semakin mendekati nilai aktual, sehingga akurasi model dapat dikatakan tinggi.

$R^2$  score, atau koefisien determinasi, merupakan metrik evaluasi yang digunakan untuk mengukur seberapa besar proporsi variansi dari data aktual yang dapat dijelaskan oleh model prediksi. Nilai  $R^2$  berkisar antara 0 hingga 1, di mana semakin mendekati 1 menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam merepresentasikan pola data dan menghasilkan prediksi yang akurat.

## 3. HASIL DAN PEMBAHASAN

### 3.1 Hasil Evaluasi Training & Testing Model LSTM

Evaluasi performa model LSTM dalam melakukan prediksi harga emas dilakukan menggunakan beberapa metrik statistik yang umum digunakan dalam analisis regresi, yaitu Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan Koefisien Determinasi ( $R^2$  Score). Berdasarkan hasil pengujian seperti pada tabel 1 dibawah, model menunjukkan nilai MAE sebesar 10.822, yang berarti rata-rata kesalahan absolut antara nilai aktual dan nilai prediksi hanya sekitar 10.82 USD. Hal ini menunjukkan bahwa model mampu menghasilkan prediksi yang cukup dekat dengan nilai sebenarnya. Nilai MSE sebesar 209.3128 mengindikasikan bahwa kesalahan kuadrat rata-rata dari prediksi juga tergolong rendah, sedangkan nilai RMSE sebesar 14.4676 menunjukkan bahwa simpangan rata-rata prediksi dari nilai aktual berada di kisaran  $\pm 14.47$  USD, yang masih tergolong akurat dalam konteks prediksi harga komoditas dengan volatilitas tinggi seperti emas.

Lebih lanjut, nilai  $R^2$  sebesar 0.9605 menunjukkan bahwa model LSTM mampu menjelaskan sekitar 96,05% variabilitas dalam data harga emas. Ini mencerminkan tingkat kecocokan (goodness of fit) yang sangat tinggi antara hasil prediksi dan data aktual, menandakan bahwa model telah berhasil mempelajari pola historis dengan sangat baik dan memiliki kemampuan generalisasi yang kuat terhadap data baru. Dengan kombinasi nilai error yang rendah dan nilai  $R^2$  yang tinggi, dapat disimpulkan bahwa model LSTM yang dibangun dalam penelitian ini sangat efektif untuk tugas forecasting harga emas.

Tabel 1. Nilai Matrix Evaluasi Model LSTM

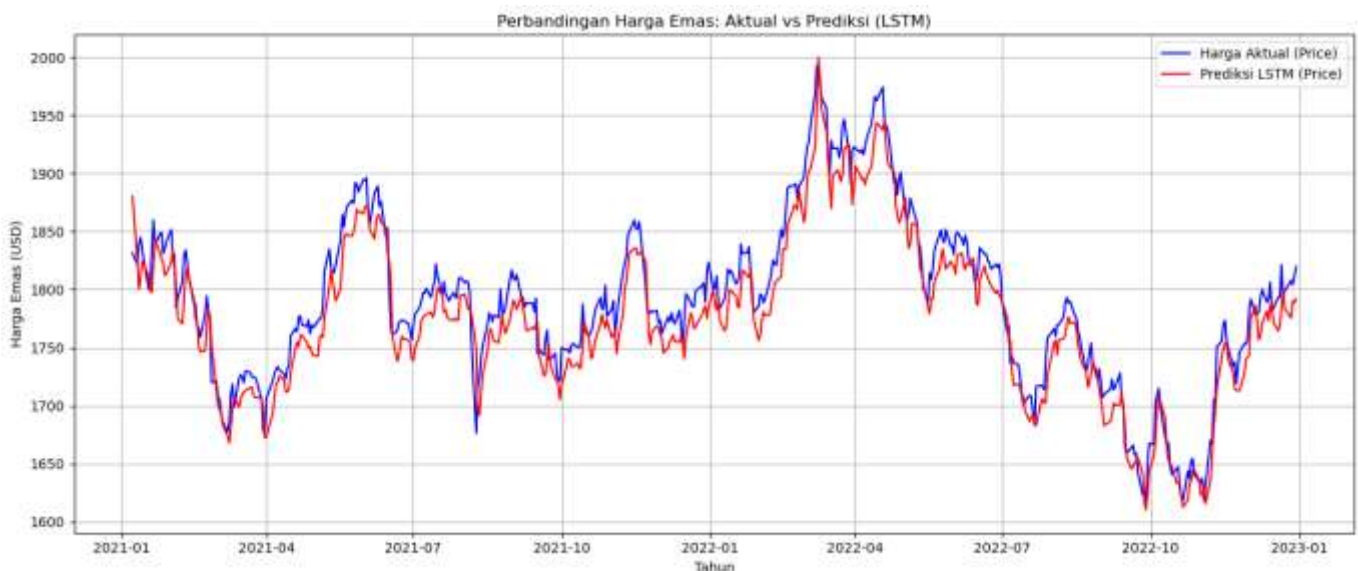
Matrix evaluasi	Nilai
MAE	10.822
MSE	209.3128
RMSE	14.4676

R <sup>2</sup> Score	0.9605
----------------------	--------

### 3.2 Hasil Prediksi Model LSTM

Pada gambar 4 di-bawah menunjukkan grafik antara harga emas aktual dan hasil prediksi model. Grafik berwarna biru merepresentasikan prediksi individual terhadap harga aktual, sedangkan grafik warna merah menunjukkan hasil prediksi yang telah dihasilkan oleh algoritma LSTM yang telah di-training. Evaluasi performa model LSTM dilakukan dengan membandingkan harga emas aktual dengan hasil prediksi model dalam rentang waktu dari awal tahun 2021 hingga akhir 2022. Berdasarkan grafik, terlihat bahwa prediksi model (ditunjukkan oleh garis merah) secara umum mengikuti tren dari data harga emas aktual (ditunjukkan oleh garis biru) dengan cukup baik.

Model mampu menangkap fluktuasi harga secara musiman maupun tren jangka panjang, termasuk saat terjadi kenaikan dan penurunan tajam. Meskipun terdapat sedikit deviasi atau perbedaan nilai prediksi pada beberapa titik, terutama saat terjadi perubahan harga yang ekstrem, secara keseluruhan hasil prediksi tetap berada dalam batas yang wajar dan cenderung tidak menyimpang jauh dari data sebenarnya. Kesesuaian pola ini menunjukkan bahwa model LSTM berhasil mengenali dan merepresentasikan pola historis harga emas secara efektif, sehingga memiliki potensi yang kuat untuk digunakan dalam tugas forecasting harga emas di masa mendatang.




Gambar 4. Data aktual vs Prediksi

### 3.3 Evaluasi Loss Model Selama Pelatihan

Pada Gambar 5 menampilkan grafik *loss* antara data pelatihan (*training loss*) dan data validasi (*validation loss*) selama 50 *epoch*. Grafik ini bertujuan untuk mengevaluasi stabilitas dan kemampuan generalisasi model terhadap data baru. Evaluasi kinerja model dilakukan dengan memantau nilai *loss* selama proses pelatihan, baik pada data pelatihan (*train loss*) maupun data validasi (*validation loss*).

Berdasarkan grafik *Training vs Validation Loss*, terlihat bahwa nilai *loss* pada data pelatihan mengalami penurunan secara konsisten seiring bertambahnya jumlah *epoch*, yang menandakan bahwa model berhasil mempelajari pola data secara efektif. Meskipun *validation loss* menunjukkan fluktuasi di beberapa *epoch*, secara umum juga mengalami penurunan dan cenderung stabil mendekati nol pada akhir pelatihan.

Hal ini menunjukkan bahwa model tidak mengalami *overfitting* secara signifikan dan memiliki kemampuan generalisasi yang cukup baik terhadap data yang belum pernah dilihat sebelumnya. Nilai *loss* yang rendah dan konvergen ini mengindikasikan bahwa arsitektur LSTM yang digunakan mampu menangkap pola temporal dalam data historis harga emas secara optimal untuk tujuan prediksi. Evaluasi *loss* ini merupakan indikator penting dalam validasi model *deep learning* karena menggambarkan kinerja selama pelatihan dan potensi performa pada data yang tidak terlihat sebelumnya.



Gambar 5. Grafik Perbandingan Training Loss dan Validation Loss

#### 4. KESIMPULAN

Berdasarkan hasil penelitian secara keseluruhan, hasil penelitian menunjukkan bahwa penggunaan model LSTM multivariat sangat efektif untuk menangkap pola dinamis dari pergerakan harga emas. Dengan memperhatikan fitur-fitur historis yang berkorelasi tinggi, model mampu belajar dengan baik tanpa mengalami *overfitting*. Akurasi model yang tinggi didukung oleh nilai  $R^2$  yang hampir sempurna dan error absolut yang rendah. Namun demikian, terdapat beberapa tantangan dalam penerapan model ini, seperti sensitivitas terhadap parameter hiper dan ketergantungan pada kontinuitas data harian. Selain itu, model ini tidak mempertimbangkan faktor eksternal seperti krisis global, geopolitik, atau intervensi pasar, yang juga dapat memengaruhi harga emas secara signifikan.

#### DAFTAR PUSTAKA

- [1] A. Aulia, B. Aprianti, Y. Supriyanto, and C. Rozikin, "Prediksi Harga Emas dengan Menggunakan Algoritma Support Vector Regression (Svr) dan Linear Regression," *J. Ilm. Wahana Pendidik.*, vol. 8, no. 5, pp. 84–88, 2022, doi: 10.5281/zenodo.6408864.
- [2] H. R. Sri, S. Wahyuningsih, and M. Siringoringo, "Peramalan Harga Emas Indonesia Menggunakan Model ARIMA (0,1,1)-GARCH (1,0)," *J. Ekspansional*, vol. 15, no. 1, pp. 1–10, 2024.
- [3] Y. R. M. Ferdinandus, K. Kusriani, 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.
- [4] A. E. S. H. Maharani, D. A. Azka, and D. Darlena, "Gold Price Fluctuation Forecasting Based on Newton and Lagrange Polynomial Interpolation," *J. Varian*, vol. 7, no. 1, pp. 87–98, 2023, doi: 10.30812/varian.v7i1.3230.
- [5] M. F. Julianto, M. Iqbal, W. F. Hidayat, and Y. Malau, "Perbandingan Penerapan Algoritma Deep Learning Dalam Prediksi Harga Emas," *INTI Nusa Mandiri*, vol. 19, no. 1, pp. 71–76, 2024, doi: 10.33480/inti.v19i1.5559.
- [6] F. Fauzi, S. Aulia, A. R. Syaifullah, and T. W. Utami, "Peramalan Harga Emas Menggunakan Pendekatan Long-Short Term Memory (LSTM)," *J. Edukasi dan Penelit. Inform.*, vol. 10, no. 2, p. 252, 2024, doi: 10.26418/jp.v10i2.78332.
- [7] Y. Guo, "Research on the application of gold price prediction based on LSTM model," *Inf. Syst. Econ.*, vol. 5, no. 4, pp. 112–118, 2024, doi: 10.23977/infse.2024.050414.
- [8] A. Rosyd, A. Irma Purnamasari, and I. Ali, "Penerapan Metode Long Short Term Memory (Lstm) Dalam Memprediksi Harga Saham Pt Bank Central Asia," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 501–506, 2024, doi: 10.36040/jati.v8i1.8440.
- [9] 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," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 1, 2024, doi: 10.23960/jitet.v12i1.3808.
- [10] A. Tholib, N. K. Agusmawati, and F. Khoiriyah, "Prediksi Harga Emas Menggunakan Metode Lstm Dan Gru," *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 3, pp. 620–627, 2023, doi: 10.23960/jitet.v11i3.3250.
- [11] S. Sen, D. Sugiarto, and A. Rochman, "Komparasi Metode Multilayer Perceptron (MLP) dan Long Short Term Memory (LSTM) dalam Peramalan Harga Beras," *Ultim. J. Tek. Inform.*, vol. 12, no. 1, pp. 35–41, 2020, doi: 10.31937/ti.v12i1.1572.
- [12] D. R. Alghifari, M. Edi, and L. Firmansyah, "Implementasi Bidirectional LSTM untuk Analisis Sentimen Terhadap Layanan Grab Indonesia," *J. Manaj. Inform.*, vol. 12, no. 2, pp. 89–99, 2022, doi: 10.34010/jamika.v12i2.7764.
- [13] F. Yanti, B. Nurina Sari, and S. Defiyanti, "Implementasi Algoritma Lstm Pada Peramalan Stok Obat," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 4, pp. 6082–6089, 2024, doi: 10.36040/jati.v8i4.10068.
- [14] A. Novian and U. T. Kartini, "Peramalan Loss Of Life Tranformator Berdasarkan Loading dan Temperature Menggunakan LSTM di Gardu Induk

- 150KV Buduran,” *J. Tek. Elektro*, vol. 12, no. 1, pp. 81–86, 2023, doi: 10.26740/jte.v12n1.p81-86.
- [15] S. I. N. Suwandi, Raras Tyasnurita, and Hanifan Muhayat, “Peramalan Emisi Karbon Menggunakan Metode SARIMA dan LSTM,” *J. Comput. Sci. Informatics Eng.*, vol. 6, no. 1, pp. 73–80, 2022, doi: 10.29303/jcosine.v6i1.436.