



PREDIKSI HARGA EMAS INDONESIA MENGGUNAKAN MODEL CNN-LSTM

Rika Septiana, Adetya Rielisa Putri, Wardah Shifa Maharani, Gina Destia Gultom,
Eka Darmayanti Simanullang*, Ken Dhita Tania, Allsela Meiriza, Ahmad Rifai

Program Studi Sistem Informasi, Universitas Sriwijaya, Indonesia

Abstrak: Harga emas memiliki volatilitas tinggi yang menjadikannya menarik untuk dianalisis secara prediktif. Penelitian ini bertujuan untuk memprediksi harga emas Indonesia dengan kombinasi model *Convolutional Neural Network* dan *Long Short-Term Memory* (CNN-LSTM) berdasarkan data historis yang berjumlah 4.434 data dari PT Antam Tbk dari periode 2010 sampai 2025. Model ini dibangun menggunakan lapisan *Conv1D* (satu dimensi) untuk ekstraksi fitur dan dua lapisan *LSTM* untuk memahami pola waktu. Pengujian dilakukan dengan tiga variasi jumlah *epoch* pelatihan, yaitu 50, 100, dan 150, lalu hasilnya dievaluasi menggunakan metrik *Root Mean Square Error* (RMSE). Model terbaik ditemukan pada *epoch* 100 dengan nilai RMSE data pelatihan sebesar 5.811,51 dan data uji sebesar 13.236,10. Hasil ini menunjukkan bahwa model CNN-LSTM mampu mengenali pola harga emas lebih baik dibandingkan skenario lain. Dengan demikian, penelitian ini dapat dimanfaatkan untuk membantu para investor dalam mengambil keputusan investasi dan sebagai dasar pengembangan sistem prediksi harga komoditas lainnya.

Kata kunci: CNN-LSTM, Data historis, Epoch, Prediksi Harga Emas, Root Mean Square Error

I. PENDAHULUAN

Harga emas merupakan salah satu indikator penting dalam perekonomian global yang dipengaruhi oleh berbagai faktor seperti inflasi, nilai tukar mata uang, dan suku bunga. Hasil pengujian pengaruh variabel suku bunga, nilai tukar, dan harga emas terhadap inflasi pada jangka pendek dan panjang menunjukkan bahwa pengaruh ketiga variabel tersebut signifikan dan positif terhadap perubahan inflasi di Jawa Barat. Meskipun harga emas tidak menunjukkan pengaruh

signifikan terhadap inflasi dalam jangka pendek, suku bunga dan nilai tukar rupiah menunjukkan pengaruh positif yang signifikan terhadap inflasi (Purwanti, 2022). Memprediksi harga emas merupakan tantangan yang kompleks dan menarik bagi akademisi dan praktisi keuangan karena nilai emas sangat fluktuatif dan dipengaruhi oleh banyak faktor, termasuk suku bunga, nilai tukar, kebijakan moneter, serta permintaan dan penawaran di pasar global.

Berbagai metode telah digunakan untuk memprediksi harga emas. Salah satu metode yang terbukti efektif adalah model *convolutional neural network* (CNN), baik digunakan secara mandiri maupun setelah dioptimasi dengan *long short-term memory*

* ekadarmayanti402@gmail.com

Diterima: 27 April 2025

Direvisi: 30 Mei 2025

Disetujui: 26 Juni 2025

DOI: 10.23969/infomatek.v27i1.24417

(LSTM), yang mampu meningkatkan akurasi prediksi berdasarkan evaluasi metrik kesalahan seperti MAE, MSE, dan RMSE (Handayani et al., 2022) dan (Julianto et al., 2024). Salah satu pendekatan yang semakin populer adalah penggunaan model deep learning, terutama Convolutional Neural Network (CNN) dan Long Short-Term Memory (LSTM), yang mampu menangkap pola kompleks dalam data time-series (Sezer et al., 2020). CNN dapat mengekstrak fitur penting dari data emas, sementara LSTM dapat mengambil temporal dependensi dari data yang mengandung pola tren jangka panjang dan musiman.

Penelitian sebelumnya telah menunjukkan keunggulan kombinasi CNN-LSTM dalam prediksi harga emas. (Amini & Kalantari, 2024) mengembangkan model CNN-BiLSTM dengan optimasi parameter otomatis yang terbukti meningkatkan akurasi prediksi. Penelitian menunjukkan bahwa kombinasi algoritma Convolutional Neural Network (CNN) dan Long Short-Term Memory (LSTM) dapat meningkatkan efektivitas dalam menganalisis data historis dibandingkan dengan penggunaan model individual. Misalnya, penelitian oleh (Guridno et al., 2024) menunjukkan bahwa metode hibrida CNN-LSTM mampu meningkatkan akurasi dalam klasifikasi topik berita dan analisis sentimen dibandingkan dengan metode standar.. Sementara itu, penelitian (Boongasame et al., 2023) membandingkan efektivitas model *deep learning* dengan metode tradisional seperti ARIMA dan SMA, dan menemukan bahwa *deep learning* lebih unggul dalam menangkap tren harga emas. (Liang et al., 2022) mengusulkan model *hybrid* ICEEMDAN-LSTM-CNN-CBAM yang mampu meningkatkan akurasi prediksi dengan teknik ekstraksi fitur yang lebih dalam. Penelitian lain juga menunjukkan keunggulan kombinasi

CNN-LSTM dalam prediksi harga emas. (Alhamdani et al., 2021) menggunakan metode Long Short-Term Memory (LSTM) untuk memprediksi harga emas dan menemukan bahwa kombinasi parameter terbaik menghasilkan nilai MAPE terbaik sebesar 0,69794%.

Di Indonesia, penelitian (Santika et al., 2021) menemukan bahwa model CNN-LSTM lebih unggul dibandingkan metode statistik dalam menangkap pola harga emas. (Fitriyanto & Kusriani, 2025) menyempurnakan model CNN-BiLSTM dengan metode *Attention* dan *Bayesian Optimization* yang terbukti mampu meningkatkan akurasi prediksi. Selain itu, penelitian (Tholib et al., 2023) mengevaluasi pendekatan *Gated Recurrent Unit* (GRU) dan LSTM, dan menemukan bahwa LSTM lebih unggul dari GRU dalam menangkap pola harga emas dengan metrik *error* yang lebih rendah. (Asnawi et al., 2023) mengembangkan metode XGBoost dalam prediksi bencana banjir untuk menunjukkan seberapa baik model *machine learning* menangani data *time-series*.


Dalam aspek volatilitas harga emas, (Vidal & Kristjanpoller, 2020) menunjukkan bahwa kombinasi CNN-LSTM lebih akurat dibandingkan model GARCH dan LSTM tunggal dalam memprediksi volatilitas harga emas. (Yan & Elbushra, 2024) mengembangkan model TSMixer-LSTM-CNN yang menggabungkan pendekatan spasial dan temporal untuk meningkatkan akurasi prediksi. Lebih lanjut, studi (Qiu et al., 2024) memperkenalkan model dua tahap dengan ekstraksi fitur dan koreksi residu untuk meningkatkan prediksi harga emas. Selain itu, (Salim & Djunaidy, 2024) menerapkan CNN-LSTM berbasis representasi gambar data *time-series* untuk meningkatkan performa prediksi harga emas. (Billah & Das, 2021) memanfaatkan model CNN-BiGRU untuk

meningkatkan prediksi harga emas dengan evaluasi metrik yang lebih unggul dibandingkan dengan metode lain. Penelitian (Zhang & Lei, 2022) juga menunjukkan bahwa penggabungan deep reinforcement learning dengan model prediksi dapat meningkatkan akurasi dalam prediksi harga komoditas, termasuk harga emas. Selanjutnya, (Yao et al., 2024) mengembangkan model hybrid CNN-LSTM yang terbukti efektif dalam meningkatkan prediksi risiko, yang metodologinya juga dapat diterapkan pada prediksi harga emas.

Prediksi harga emas merupakan penelitian yang kompleks karena dipengaruhi oleh banyak faktor ekonomi dan keuangan, tetapi dapat memberikan wawasan kepada investor untuk menentukan strategi berinvestasi pada emas. Oleh karena itu, penelitian ini mengkaji masalah utama tentang bagaimana kombinasi CNN dan LSTM dapat digunakan secara efektif dalam prediksi harga emas. Selain itu, penelitian ini juga bertujuan untuk mengoptimalkan proses ekstraksi fitur menggunakan CNN dari data harga emas serta menunjukkan volatilitas jangka panjang dan pola trend dengan LSTM. Serta, melakukan analisis yang lebih mendalam tentang sejauh mana model ini dapat memberikan prediksi yang lebih akurat daripada metode sebelumnya dengan menggunakan data harga emas terbaru.

II. METODOLOGI

Proses penelitian terdiri dari beberapa proses yang akan digambarkan pada Gambar 1.



Gambar 1. Proses Penelitian (Handayani et al., 2022)

2.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini dikumpulkan melalui *Kaggle* dan terdiri dari harga emas PT Antam Tbk dalam satuan gram terhitung dari 4 Januari 2010 hingga 2 Januari 2025 (Abbas, 2025). Data terdiri sebanyak 4.546 data harga emas per harinya. Data dikumpulkan dalam format CSV dan terdiri dari beberapa variabel utama, yaitu “Date” sebagai waktu pengumpulan harga emas dan “Price” sebagai harga emas per gram yang dijual dalam rupiah. Selanjutnya, data ini difokuskan pada variabel harga emas per gram sebagai target prediksi.

Tabel 1. Harga Emas di Indonesia

No	Bulan	Harga
0	2010-01-04	408000
1	2010-01-05	410000
2	2010-01-06	410000
3	2010-01-07	412000
4	2010-01-08	410000
...	...	...
4430	2024-12-28	1526000
4431	2024-12-29	1526000
4432	2024-12-30	1528000
4433	2024-12-31	1515000
4434	2025-01-02	1524000

2.2. Pemrosesan Data

Sebelum model *deep learning* dilaksanakan, dilakukan beberapa proses *preprocessing* untuk memastikan kualitas data dan data siap diolah. Proses yang dilakukan yaitu:

a. Validasi Data

Menemukan dan menangani *missing values* dan *outlier* dalam data. Jika data yang hilang dalam jumlah kecil, maka akan dilakukan penghapusan nilai (Handayani et al., 2022).

b. Normalisasi Data

Untuk meningkatkan kinerja model CNN-LSTM, data harga emas dinormalisasi

menggunakan *Min-Max Scaling* dengan rentang $[0,1]$ (Handayani et al., 2022).

c. Pembagian Data

Untuk melakukan prediksi, data akan dibagi menjadi 2 bagian dengan rasio 80% sebagai data *training* dan 20% sebagai data *testing* (Handayani et al., 2022).

2.3. Implementasi Model

Model deep learning ini dikembangkan menggunakan *python*. CNN digunakan untuk ekstraksi fitur dari data harga emas, sementara LSTM menangkap pola temporal dalam data *time-series* (Handayani et al., 2022).

2.4. Pengujian Model

Dengan menggunakan data uji, model diuji untuk melihat seberapa baik prediksi dibandingkan dengan data asli. Hasil prediksi dievaluasi menggunakan *Root Mean Square Error* (RMSE) untuk mengukur tingkat kesalahan antara nilai aktual dan nilai prediksi (Handayani et al., 2022).

2.5. Evaluasi Hasil

Evaluasi hasil dilakukan dengan menghitung metrik RMSE untuk setiap *epoch*. Apabila nilai RMSE lebih kecil, itu berarti model memiliki performa yang lebih baik (Handayani et al., 2022).

III. HASIL DAN PEMBAHASAN


3.1 Arsitektur Model CNN-LSTM

Arsitektur Model CNN-LSTM yang digunakan dalam penelitian ini memiliki konfigurasi *1D Convolutional Layer* dengan 64 filter, kernel size = 2 untuk ekstraksi fitur dari data *time-series*. LSTM *Layers* ada 2 *layer* dengan 128 unit neuron untuk menangkap pola jangka panjang pada harga emas, *Optimizer* dengan *Adam*, *Learning Rate* = 0.001 untuk mempercepat konvergensi model.

Sebelum data digunakan dalam model, data harus melalui pra-pemrosesan terlebih dahulu

untuk menjamin kualitas input yang baik. Langkah pertama adalah melakukan normalisasi menggunakan metode *Min-Max Scaler* agar nilai data berada dalam rentang 0 hingga 1. Setelah itu, data diubah menjadi format sekuensial, yaitu rangkaian data berurutan yang sesuai untuk dimasukkan ke dalam model CNN-LSTM. Format ini menggunakan beberapa harga emas sebelumnya sebagai dasar untuk memprediksi harga di masa mendatang.

Data yang telah diproses kemudian dibagi menjadi dua bagian yaitu *training set* yang digunakan untuk proses pelatihan model, dan *test set* yang berfungsi untuk menguji kemampuan generalisasi model tersebut. Model di kompilasi dengan *loss function* berupa *mean_squared_error* dan *optimizer Adam*. Dalam proses pelatihannya, model diuji dengan berbagai jumlah *epoch*, yaitu 50, 100, dan 150, untuk mengetahui model yang lebih baik terhadap lamanya pelatihan.




Gambar 2. Flowchart CNN-LSTM untuk prediksi harga emas

3.2 Prediksi Harga Emas dengan CNN-LSTM dengan Jumlah *Epoch* yang Berbeda

Penelitian ini menggunakan model CNN-LSTM untuk memprediksi harga emas berdasarkan data historis dari tahun 2010 hingga 2024. Model diuji dengan jumlah *epoch* yang berbeda, yaitu 50, 100, dan 150, untuk mengevaluasi performa model dalam melakukan prediksi.

1) Prediksi dengan *Epoch* 50


Pada pengujian dengan *epoch* 50, model menunjukkan tren prediksi yang mendekati harga emas aktual, namun masih terdapat deviasi yang cukup besar pada beberapa titik waktu. Grafik menunjukkan bahwa model masih mengalami kesulitan dalam menangkap pola harga emas yang kompleks.



Gambar 3. Prediksi Harga Emas dengan CNN-LSTM menggunakan *Epoch* 50

2) Prediksi dengan *Epoch* 100


Peningkatan jumlah *epoch* menjadi 100, model mulai menunjukkan peningkatan akurasi. Prediksi *data training* dan *testing* lebih mendekati harga emas aktual dibandingkan dengan hasil pada *epoch* 50. Meskipun demikian, terdapat beberapa fluktuasi yang masih belum sepenuhnya dapat ditangkap oleh model.



Gambar 4. Prediksi Harga Emas dengan CNN-LSTM menggunakan *Epoch* 100

3) Prediksi dengan *Epoch* 150

Pada pengujian dengan *epoch* 150, model menunjukkan peningkatan yang lebih signifikan dalam memprediksi harga emas. Deviasi antara harga aktual dan hasil prediksi semakin kecil, menandakan bahwa model semakin mampu memahami pola tren harga emas dalam data historis.



Gambar 5. Prediksi Harga Emas dengan CNN-LSTM menggunakan *Epoch* 150

3.3 Evaluasi RMSE

Evaluasi RMSE dari ketiga *epoch* yang berbeda yaitu *epoch* 50, 100, dan 150. Pada *epoch* 50, nilai *tes* RMSE sangat tinggi, menandakan model belum cukup belajar dari data (*underfitting*). Pada *epoch* 100, model menunjukkan performa terbaik dengan RMSE terendah pada *data training* dan *testing*, sehingga model mampu mempelajari pola


data dengan baik. Pada *epoch* 150, terjadi peningkatan signifikan pada tes RMSE, menandakan model mengalami *overfitting*, di mana model terlalu menyesuaikan dengan *data training* dan gagal memprediksi data testing dengan baik. Jadi, berdasarkan hasil ini, model terbaik diperoleh pada *epoch* 100 karena memberikan keseimbangan optimal antara akurasi pada *data training* dan *testing*.

Tabel 2. Hasil RMSE pada *Data Training* dan *Testing*

Epoch	Train RMSE	Test RMSE
50	6991.0723	34258.9690
100	5811.5114	13236.1043
150	5974.8455	42606.3708

3.4 Analisis Grafik Train Loss dan Validation Loss

Grafik Train Loss dan Validation Loss untuk setiap epoch seperti Gambar 6.



Gambar 6. Grafik *Train Loss* dan *Validation Loss*

Hasil analisis menunjukkan bahwa **pada epoch 50**, baik *Train Loss* maupun *Validation Loss* masih tinggi, menunjukkan model belum optimal. **Pada epoch 100**, meskipun *Validation Loss* mulai sedikit meningkat (indikasi *overfitting* ringan), model ini tetap menghasilkan **RMSE terbaik**. **Pada epoch 150**, *Validation Loss* mengalami lonjakan signifikan, menegaskan bahwa model mengalami *overfitting*. Jadi, meskipun grafik *Train Loss* vs *Validation Loss* pada *epoch* 100

menunjukkan indikasi *overfitting*, performa model tetap optimal berdasarkan hasil RMSE.

Hasil eksperimen menunjukkan bahwa model CNN-LSTM dengan *epoch* 100 memberikan hasil terbaik dalam memprediksi harga emas Indonesia.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa model **CNN-LSTM** dengan epoch **100** memberikan hasil terbaik dalam memprediksi harga emas Indonesia, sedangkan pada epoch **50** terjadi *underfitting* dan pada epoch **150** terjadi *overfitting*. Keberhasilan model dipengaruhi oleh kombinasi arsitektur CNN untuk ekstraksi fitur dan LSTM untuk mengenali pola temporal pada data harga emas. Hasil ini mendukung temuan sebelumnya bahwa kombinasi CNN-LSTM efektif dalam memprediksi data *time series* yang kompleks. Untuk meningkatkan performa model, disarankan menerapkan *Early Stopping*, menambahkan *Dropout Layer*, serta melakukan penyesuaian parameter dan eksplorasi *time step* yang lebih panjang agar model lebih stabil dan akurat pada pola harga emas yang fluktuatif.

DAFTAR PUSTAKA

Abbas. (2025). *Dataset Harga Emas*.
Alhamdani, F. D. S., Marthasari, G. I., & Aditya, C. S. K. (2021). Prediksi Harga Emas Menggunakan Metode Time Series Long Short-Term Memory Neural Network. *REPOSITOR*, 3(4), 375–386. <https://eprints.umm.ac.id/id/eprint/5942>
Amini, A., & Kalantari, R. (2024). Gold price prediction by a CNN-Bi-LSTM model along with automatic parameter tuning. *PLoS ONE*, 19(3 March). <https://doi.org/10.1371/journal.pone.0298426>

- Asnawi, F., Bisono, H., Megantara, A., & Kusri. (2023). Aplikasi Prediksi Banjir Menggunakan Algoritma XGBoost Berbasis Website. *Journal of Economic, Management, Accounting and Technology*, 379–389. <http://dx.doi.org/10.32500/jematech.v7i2.7644>
- Billah, M. M., & Das, S. (2021). Analysis and Prediction of Gold Price using CNN and Bi-GRU based Neural Network Model. *24th International Conference on Computer and Information Technology, ICCIT 2021*. <https://doi.org/10.1109/ICCIT54785.2021.9689880>
- Boongasame, L., Viriyaphol, P., Tassanavipas, K., & Temdee, P. (2023). Gold-Price Forecasting Method Using Long Short-Term Memory and the Association Rule. *Journal of Mobile Multimedia*, 19(1), 165–186. <https://doi.org/10.13052/jmm1550-4646.1919>
- Fitriyanto, N., & Kusri. (2025). Optimasi Prediksi Harga Emas Menggunakan CNN-Bi-LSTM dengan Mekanisme Attention dan Bayesian Optimization. *Journal of Economic, Management, Accounting and Technology*, 8(1), 210–219. <https://doi.org/10.32500/jematech.v8i1.8668>
- Guridno, C., Azimah, A., & Ningsih, S. (2024). *Jurnal Sistem Informasi Bisnis (JUNSIBI) ANALISIS HYBRID METODE CNN DAN LSTM DALAM MEDIA BERITA ONLINE INDONESIA PENULIS 1*. 5(1), 86–101. <https://doi.org/10.55122/junsibi.v5i1.1202>
- Handayani, S., Taslim, & Toresa, D. (2022). Convolutional Neural Network Long Short Term Memory Untuk Prediksi Harga Emas Indonesia. *Indonesian Journal of Computer Science*. <https://doi.org/https://doi.org/10.33022/ijcs.v11i3.3074>
- Julianto, M. F., Iqbal, M., Hidayat, W. F., & Malau, Y. (2024). PERBANDINGAN PENERAPAN ALGORITMA DEEP LEARNING DALAM PREDIKSI HARGA EMAS. *INTI Nusa Mandiri*, 19(1), 71–76. <https://doi.org/10.33480/inti.v19i1.5559>
- Liang, Y., Lin, Y., & Lu, Q. (2022). Forecasting gold price using a novel hybrid model with ICEEMDAN and LSTM-CNN-CBAM. *Expert Systems with Applications*, 206, 117847. <https://doi.org/10.1016/J.ESWA.2022.117847>
- Purwanti, Y. (2022). *Analysis of the Influence of Gold Price, Rupiah Exchange Rate and Interest Rate on West Java Inflation Persistence Degrees*. 1(1), 43–52. <https://doi.org/10.21787/govstat.1.1.2022.43-52>
- Qiu, C., Zhang, Y., Qian, X., Wu, C., Lou, J., Chen, Y., Xi, Y., Zhang, W., & Gong, Z. (2024). A Two-stage Deep Fusion Integration Framework Based on Feature Fusion and Residual Correction for Gold Price Forecasting. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2024.3408837>
- Salim, M., & Djunaidy, A. (2024). Development of a CNN-LSTM Approach with Images as Time-Series Data Representation for Predicting Gold Prices. *Procedia Computer Science*, 234, 333–340. <https://doi.org/10.1016/j.procs.2024.03.007>
- Santika, I. W. K. G., Sa'adah, S., & Yunanto, P. E. (2021). Prediksi harga emas

- menggunakan Convolutional Neural Network-Long Short-Term Memory (CNN-LSTM). *Universitas Telkom, S1 Informatika*.
<https://repository.telkomuniversity.ac.id/pustaka/172951/prediksi-harga-emas-menggunakan-convolutional-neural-network-long-short-term-memory-cnn-lstm-.html>
- Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing Journal*, 90. <https://doi.org/10.1016/j.asoc.2020.106181>
- Tholib, A., Agusmawati, N. K., & Khoiriyah, F. (2023). PREDIKSI HARGA EMAS MENGGUNAKAN METODE LSTM DAN GRU. *Jurnal Informatika Dan Teknik Elektro Terapan*, 11(3). <https://doi.org/10.23960/jitet.v11i3.3250>
- Vidal, A., & Kristjanpoller, W. (2020). Gold volatility prediction using a CNN-LSTM approach. *Expert Systems with Applications*, 157. <https://doi.org/10.1016/j.eswa.2020.113481>
- Yan, W., & Elbushra, M. (2024). Forecasting Sudan Gold Prices with a Hybrid Deep Learning Approach. *2024 International Conference on Cloud and Network Computing (ICCNC)*, 71–78. <https://doi.org/10.1109/ICCNC63989.2024.00020>
- Yao, J., Wang, J., Wang, B., Liu, B., & Jiang, M. (2024). *A Hybrid CNN-LSTM Model for Enhancing Bond Default Risk Prediction*. <https://ashpress.org/index.php/jcts/article/view/79/56>
- Zhang, J., & Lei, Y. (2022). Deep Reinforcement Learning for Stock Prediction. *Scientific Programming*, 2022. <https://doi.org/10.1155/2022/5812546>