

Optimasi Prediksi Harga Emas Menggunakan CNN-Bi-LSTM dengan Mekanisme Attention dan Bayesian Optimization

Nur Fitriyanto ¹⁾, Kusriani ²⁾

¹⁾ Program Studi PJJ Informatika Universitas AMIKOM Yogyakarta, Indonesia

²⁾ Program Studi PJJ Informatika Universitas AMIKOM Yogyakarta, Indonesia

¹⁾ nur.fitriyanto@students.amikom.ac.id

²⁾ kusriani@amikom.ac.id

Abstrak

Prediksi harga emas merupakan aspek penting dalam investasi global karena volatilitasnya yang dipengaruhi oleh faktor ekonomi dan politik. Penelitian ini mengembangkan model hybrid CNN-Bi-LSTM dengan mekanisme *Attention* untuk menangkap pola data signifikan dan *Bayesian Optimization* untuk pencarian *hyperparameter* yang lebih efisien. Dataset yang digunakan mencakup harga emas harian dari 29 Desember 1978 hingga 4 Juni 2021, yang terbagi menjadi data pelatihan (70%), validasi (20%), dan pengujian (10%). Model yang dioptimasi menunjukkan hasil evaluasi dengan RMSE sebesar 17,98, MAE sebesar 10,93, RMAE sebesar 3,31, dan R^2 sebesar 1,00. Visualisasi hasil menunjukkan konvergensi stabil tanpa *overfitting*, distribusi residual yang mendekati normal, serta prediksi yang konsisten dengan data aktual. Integrasi mekanisme *Attention* dan *Bayesian Optimization* terbukti meningkatkan performa model secara signifikan. Penelitian ini membuka peluang pengembangan lebih lanjut dengan memasukkan variabel makroekonomi tambahan, seperti harga minyak mentah atau indeks saham, untuk memperluas cakupan prediksi.

Kata kunci : CNN-Bi-LSTM, Attention, Bayesian Optimization, Prediksi Harga Emas, Time Series.

Abstract

Gold price prediction is a crucial aspect of global investment due to its volatility influenced by economic and political factors. This study develops a hybrid CNN-Bi-LSTM model with an Attention mechanism to capture significant data patterns and Bayesian Optimization for efficient hyperparameter tuning. The dataset consists of daily gold prices from December 29, 1978, to June 4, 2021, split into training (70%), validation (20%), and testing (10%) sets. The optimized model achieved evaluation results with RMSE of 17.98, MAE of 10.93, RMAE of 3.31, and R^2 of 1.00. Visualizations demonstrated stable convergence without overfitting, residual distributions close to normal, and predictions consistent with actual data. The integration of Attention and Bayesian Optimization significantly enhanced model performance. This research provides opportunities for further development by incorporating additional macroeconomic variables, such as crude oil prices or stock indices, to expand prediction scope.

Keywords: CNN-Bi-LSTM, Attention, Bayesian Optimization, Gold Price Prediction, Time Series.

1. PENDAHULUAN

Emas merupakan logam mulia yang telah dianggap sebagai salah satu aset investasi yang paling penting di dunia. Logam ini dianggap sebagai salah satu bentuk investasi yang aman, sehingga harga dari emas memiliki karakteristik yang unik, dapat terpengaruh oleh berbagai faktor ekonomi, politik, dan sosial global, termasuk juga inflasi, suku bunga, nilai tukar mata uang dan ketidakpastian geopolitik (World Gold Council, n.d.). Harga dari emas memiliki fluktuasi yang dinamis, sehingga prediksi harga emas menjadi salah satu topik yang penting dalam bidang keuangan dan ekonomi. Dengan kemampuan untuk memprediksi harga emas secara akurat, investor dapat mengoptimalkan keputusan investasi mereka, sementara lembaga keuangan dapat mengurangi risiko pasar.

Penelitian ini merupakan sebuah pengembangan dari penelitian sebelumnya tentang prediksi harga emas oleh (Amini & Kalantari, 2024), mereka memperkenalkan model CNN-Bi-LSTM dengan optimasi

hyperparameter tuning menggunakan *Grid Search*. Meskipun pendekatan mereka menunjukkan hasil yang signifikan, terdapat beberapa kelemahan, termasuk ketergantungan pada *Grid Search*, yang memerlukan waktu komputasi yang tinggi dan tidak selalu menemukan kombinasi *hyperparameter* yang optimal (Amini & Kalantari, 2024). Sebagai upaya mengatasi kekurangan tersebut, penelitian ini akan mengintegrasikan mekanisme *Attention* dan menggunakan *Bayesian Optimization* untuk meningkatkan efisiensi dan akurasi model.

Dalam penelitian ini akan mengusulkan model *hybrid Convolutional Neural Network (CNN)* yang berkemampuan untuk ekstraksi fitur lokal, *Bidirectional Long Short-Term Memory (Bi-LSTM)* untuk menangkap pola temporal, serta mekanisme *Attention* untuk memberikan fokus pada pola data yang lebih relevan. Diharapkan pada pendekatan ini dapat menangkap karakteristik kompleks dari data *time series* harga emas dengan lebih baik. *Bayesian Optimization* juga digunakan untuk menggantikan *Grid Search* yang memungkinkan pencarian *hyperparameter* lebih efisien dengan mengurangi waktu komputasi sambil tetap menjaga akurasi model.

Dataset yang digunakan dalam penelitian ini merupakan data harga emas harian dari 29 Desember 1978 hingga 4 Juni 2021, mencakup periode yang panjang untuk menangkap pola temporal yang luas dan memastikan generalisasi model yang lebih baik. Data diproses melalui normalisasi menggunakan *MinMaxScaler* dan dibagi menjadi tiga untuk pelatihan (70%), validasi (20%) dan pengujian (10%) untuk memastikan evaluasi model yang komprehensif.



Gambar 1. Visualisasi harga emas harian

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model *hybrid CNN-Bi-LSTM* dengan integrasi mekanisme *Attention* dan *Bayesian Optimization* dalam memprediksi harga emas harian. Secara spesifik, penelitian ini berfokus pada meningkatkan efisiensi pencarian *hyperparameter* melalui *Bayesian Optimization* untuk menggantikan *Grid Search*, Memanfaatkan mekanisme *Attention* untuk meningkatkan kemampuan model dalam menangkap pola signifikan pada data *time series* harga emas serta Membandingkan performa model yang diusulkan dengan model dari penelitian sebelumnya dalam hal akurasi prediksi harga emas.

2. KAJIAN PUSTAKA

Harga emas, sebagai aset investasi yang signifikan, telah menjadi fokus utama dalam banyak studi, terutama dengan munculnya model berbasis *LSTM*, *Bi-LSTM*, *GRU*, dan *CNN*, serta pendekatan *hybrid* lainnya. Penelitian-penelitian ini memberikan landasan yang kokoh untuk pengembangan model dalam studi ini.

Penelitian oleh (Amini & Kalantari, 2024) menggunakan model *CNN-Bi-LSTM* dengan optimasi *hyperparameter* berbasis *Grid Search*, menghasilkan RMSE sebesar 34.87. Namun, pendekatan ini memiliki kelemahan, yaitu efisiensi komputasi yang rendah dan keterbatasan dalam eksplorasi ruang parameter. Penelitian ini menjadi acuan utama untuk pengembangan lebih lanjut dengan pendekatan *Bayesian Optimization*.

(Gong, 2024) membandingkan *LSTM* dengan *Linear Regression*, menunjukkan bahwa *LSTM* lebih unggul dalam menangkap pola jangka panjang. Penelitian ini menjadi dasar untuk memilih arsitektur *LSTM* dalam pengembangan model prediksi yang lebih kompleks. Selanjutnya, (Sivasamy, 2024) mengevaluasi performa *GRU*, *LSTM*, *HMM*, dan *SARIMA*. *GRU* menunjukkan hasil terbaik dengan RMSE 16.32, namun penelitian ini menyoroti perlunya integrasi mekanisme tambahan, seperti *Attention*, untuk meningkatkan kemampuan model.

Studi oleh (Boongasame et al., 2023) menggabungkan *LSTM* dengan *Association Rule* untuk seleksi fitur, meningkatkan prediksi dengan mempertimbangkan variabel makroekonomi. Pendekatan ini menginspirasi pengembangan lebih lanjut dalam eksplorasi variabel tambahan untuk prediksi harga emas. Sementara itu, penelitian oleh (Huang et al., 2024) mengkombinasikan *ARIMA* dengan *LSTM* untuk menangkap pola linear dan non-linear, menekankan pentingnya *preprocessing data* yang optimal.

Selama pandemi COVID-19, penelitian oleh (Hansun & Suryadibrata, 2021) menunjukkan pentingnya model yang lebih kompleks seperti *CNN-Bi-LSTM* untuk menangkap pola fluktuasi harga emas yang dinamis. Penelitian ini mendorong penggunaan arsitektur yang lebih canggih dalam studi ini. Selain itu, (YURTSEVER, 2021) membandingkan performa *LSTM*, *Bi-LSTM*, dan *GRU*, dengan hasil yang menunjukkan keunggulan *LSTM*, memberikan validasi untuk penggunaan *Bi-LSTM* dalam penelitian ini.

Penelitian oleh (Primananda & Isa, 2021) mengadopsi *Grid Search* untuk *hyperparameter tuning*, yang menjadi pembanding penting dengan *Bayesian Optimization* yang diterapkan dalam penelitian ini. Studi oleh (Salim & Djunaidy, 2024) mengeksplorasi representasi data *time series* sebagai gambar menggunakan *CNN-LSTM*, memberikan wawasan untuk pengembangan representasi data tambahan.

Pengembangan *LSTM-P* oleh (Zhang et al., 2022) menunjukkan bahwa reduksi noise dapat meningkatkan akurasi prediksi secara signifikan. Hal ini menginspirasi pendekatan *preprocessing* yang lebih baik dalam studi ini. (Lei & Lin, 2022) menyoroti kekuatan *LSTM* dalam menangkap pola temporal, sementara (Mohtasham Khani et al., 2021) menunjukkan bahwa model *LSTM multivariate* dapat mempertimbangkan dampak faktor eksternal seperti pandemi COVID-19.


Secara keseluruhan, penelitian-penelitian ini menunjukkan bahwa kombinasi *CNN-Bi-LSTM*, mekanisme *Attention*, dan *Bayesian Optimization* adalah pendekatan yang menjanjikan untuk meningkatkan akurasi prediksi harga emas. Kajian ini memberikan kontribusi yang signifikan terhadap literatur dengan mengintegrasikan berbagai pendekatan terbaik untuk menciptakan model prediksi yang lebih efisien dan akurat.

3. METODOLOGI PENELITIAN


Dalam penelitian ini, dataset dinormalisasi menggunakan *MinMaxScaler* untuk memastikan bahwa semua fitur berada dalam rentang nilai yang sama dengan rumus:

$$x_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \dots\dots\dots (1)$$

Di mana x adalah nilai asli, x_{min} adalah nilai minimum dalam dataset, x_{max} adalah nilai maksimum dalam dataset dan x_{scaled} adalah nilai hasil normalisasi.



Gambar 2. Normalisasi data dengan MinMaxScaling



Gambar 3. Pembagian data Training, Validation dan Testing

Arsitektur model yang digunakan antara lain Konvolusi (*CNN Block*) sebagai operasi konvolusi pada layer *CNN* untuk ekstraksi fitur lokal, *LSTM Block* yang digunakan untuk menangkap pola temporal, *Attention Mechanism* digunakan untuk memberikan bobot lebih pada fitur yang penting dan *Bayesian*

Optimization yang digunakan untuk mencari kombinasi *hyperparameter* optimal. Rumus yang digunakan sebagai berikut:

CNN Block:

$$y[i] = \sum_{k=0}^{K-1} \omega[k] \cdot x[i+k] + b \quad \dots\dots\dots (2)$$

Di mana $x[i]$ adalah input, $\omega[k]$ adalah kernel/filter, K adalah ukuran kernel, b adalah bias dan $y[i]$ adalah output.

LSTM Block:

Input Gate:

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

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad \dots\dots\dots (4)$$

Di mana i_t adalah *input gate*, W_i adalah bobot *input gate*, $\tilde{C}_t$ adalah *candidate cell state*, dan W_C adalah bobot *candidate*.

Forget Gate:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad \dots\dots\dots (5)$$

Di mana f_t adalah *forget gate*, W_f adalah bobot untuk *forget gate*, h_{t-1} adalah *hidden state* sebelumnya, x_t adalah *input* saat ini, dan b_f adalah bias.

Memory Update:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad \dots\dots\dots (6)$$

Output Gate:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad \dots\dots\dots (7)$$

$$h_t = o_t \tanh(C_t) \quad \dots\dots\dots (8)$$

Di mana o_t adalah *output gate*, dan h_t adalah *hidden state* atau *output* LSTM pada waktu t .

Attention Mechanism:

$$e_{ij} = \tanh(h_i \cdot W_a \cdot h_j) \quad \dots\dots\dots (9)$$

Di mana e_{ij} adalah skor perhatian, h_i, h_j adalah representasi fitur dan W_a adalah bobot perhatian.

Probabilitas perhatian dihitung menggunakan fungsi *softmax*:

$$\alpha_{ij} = \frac{\exp(e_{ij})}{\sum_k \exp(e_{ik})} \dots\dots\dots (10)$$

Output perhatian adalah:

$$c_i = \sum_j \alpha_{ij} \cdot h_j \dots\dots\dots (11)$$

Bayesian Optimization:

$$\min_{x \in X} f(x) \dots\dots\dots (12)$$

Evaluasi model yang dilakukan menggunakan empat metrik evaluasi yaitu *Root Mean Squared Error (RMSE)* yang digunakan untuk mengukur rata – rata kuadrat dari kesalahan prediksi, *Mean Absolute Error (MAE)* digunakan untuk menghitung rata – rata absolut dari kesalahan prediksi, *Root Mean Absolute Error (RMAE)* memberikan interpretasi yang lebih baik terhadap rata – rata kesalahan absolut dan *R-squared (R²)* untuk mengukur proporsi variasi dalam data yang dapat dijelaskan oleh model prediksi. Rumus yang digunakan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \dots\dots\dots (13)$$

Di mana y_i adalah nilai actual, $\hat{y}_i$ adalah nilai prediksi dan n adalah jumlah data.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \dots\dots\dots (14)$$


$$RMAE = \sqrt{MAE} \dots\dots\dots (15)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \dots\dots\dots (16)$$

Di mana $\bar{y}$ adalah rata – rata nilai actual.


4. HASIL DAN PEMBAHASAN

Hasil penelitian menunjukkan bahwa model *hybrid CNN-Bi-LSTM* yang dilengkapi dengan mekanisme *Attention* dan dioptimasi menggunakan *Bayesian Optimization* menghasilkan kinerja prediktif yang sangat baik. Evaluasi model menghasilkan nilai RMSE sebesar 17.98, MAE sebesar 10.93, RMAE sebesar 3.31, dan R² sebesar 1.00. Hasil ini menunjukkan bahwa model yang dikembangkan lebih unggul dibandingkan penelitian sebelumnya oleh (Amini & Kalantari, 2024), yang menggunakan pendekatan *Grid Search* untuk *hyperparameter tuning*.




Gambar 4. Visualisasi loss selama pelatihan

Visualisasi Konvergensi *Loss*: Gambar 4 menunjukkan visualisasi *loss* selama pelatihan model. Grafik ini menunjukkan bahwa model mencapai konvergensi yang stabil dengan nilai *loss* validasi yang konsisten lebih rendah dari *loss* pelatihan, yang mengindikasikan tidak adanya *overfitting*.



Gambar 5. Hasil plot

Perbandingan Prediksi dan Aktual: Gambar 5 menggambarkan hasil prediksi model terhadap data aktual. Prediksi model sangat akurat, dengan distribusi titik prediksi yang hampir mengikuti data aktual pada skala waktu yang sama, mencerminkan kemampuan model dalam menangkap pola fluktuasi harga emas harian.



Gambar 6. Visualisasi error (residuals)

Distribusi Residuals: Gambar 6 menampilkan histogram distribusi residuals, yang menunjukkan distribusi simetris di sekitar nilai nol. Hal ini mencerminkan model memiliki kesalahan yang kecil dan merata tanpa bias sistematis.

Hasil penelitian ini memberikan kontribusi signifikan dalam pengembangan model prediksi harga emas berbasis *machine learning*. Penambahan mekanisme *Attention* memberikan kemampuan untuk memberikan fokus lebih pada pola-pola penting dalam data, sementara *Bayesian Optimization* meningkatkan efisiensi dan akurasi *hyperparameter tuning* dibandingkan *Grid Search*. Studi ini mendukung penelitian (Zhang et al., 2022), yang menunjukkan efektivitas *Attention* dalam menangkap pola signifikan pada data *time series*, dan mendukung temuan dari (Ding et al., 2023), yang menyoroti keunggulan *Bayesian Optimization* dalam mengurangi waktu komputasi sekaligus meningkatkan akurasi model.

Secara keseluruhan, penelitian ini tidak hanya menunjukkan keunggulan model yang dikembangkan tetapi juga memberikan panduan tentang penggunaan metode modern dalam *machine learning* untuk meningkatkan prediksi harga komoditas. Penelitian selanjutnya dapat memperluas pendekatan ini dengan menambahkan variabel eksternal seperti harga minyak mentah atau indeks saham untuk mengeksplorasi keterkaitan ekonomi global yang lebih luas.

5. PENUTUP

Penelitian ini telah berhasil mengembangkan model CNN-Bi-LSTM untuk prediksi harga emas harian dengan melakukan penambahan mekanisme *Attention* dan *Bayesian Optimization* sebagai parameter otomatisnya. Model yang diusulkan ini mampu mengatasi kekurangan pada penelitian sebelumnya dengan meningkatkan efisiensi *hyperparameter tuning* serta meningkatkan akurasi dari prediksinya. Hasil evaluasi

menunjukkan model ini mencapai performa terbaik dengan nilai RMSE sebesar 17.98, MAE sebesar 10.93, RMAE sebesar 3.31, dan R^2 sebesar 1.00.

Penerapan mekanisme *Attention* memungkinkan model untuk memberikan fokus pada pola data yang lebih relevan, sementara *tuning* otomatis menggunakan *Bayesian Optimization* memberikan pendekatan yang lebih efisien dalam menemukan kombinasi *hyperparameter* terbaik dibandingkan metode tradisional seperti *Grid Search*. Visualisasi hasil prediksi menunjukkan tingkat akurasi yang tinggi dan distribusi residual yang mendekati normal, mengindikasikan stabilitas model tanpa tanda-tanda *overfitting*.

Namun, penelitian ini memiliki beberapa keterbatasan. Pertama, model bergantung pada data historis harga emas, yang mungkin tidak sepenuhnya mencerminkan dinamika pasar global saat ini. Kedua, penelitian ini belum mempertimbangkan variabel ekonomi makro lainnya, seperti harga minyak mentah, indeks saham, atau tingkat inflasi, yang dapat memberikan konteks tambahan untuk prediksi harga emas. Untuk pengembangan selanjutnya, disarankan untuk mengintegrasikan data tambahan, seperti variabel makroekonomi, untuk memperkaya konteks prediksi, mengeksplorasi metode ensemble atau model *hybrid* lainnya untuk menangkap pola *non-linear* yang lebih kompleks serta menerapkan model pada dataset *real-time* untuk mengevaluasi performa dalam skenario pasar terkini.

Penelitian ini memberikan kontribusi signifikan pada literatur prediksi harga emas dengan menghadirkan pendekatan yang lebih akurat dan efisien, serta membuka peluang untuk inovasi lebih lanjut dalam analisis data *time series*. Dengan hasil yang dicapai, model ini diharapkan dapat memberikan manfaat praktis bagi investor dan lembaga keuangan dalam mengantisipasi fluktuasi harga emas di masa depan.

DAFTAR PUSTAKA

- Amini, A., & Kalantari, R. (2024). Gold price prediction by a CNN-Bi-LSTM model along with automatic parameter tuning. *PLoS ONE*, 19(3 March), 1–17. <https://doi.org/10.1371/journal.pone.0298426>
- 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>
- Ding, S., Ding, S., & Ding, T. (2023). Trading strategy prediction model based on quadratic programming and XGBoost. *Proceedings - 2023 Asia-Europe Conference on Electronics, Data Processing and Informatics, ACEDPI 2023*, 165–170. <https://doi.org/10.1109/ACEDPI58926.2023.00040>
- Gong, W. (2024). Research on gold price forecasting based on lstm and linear regression. *SHS Web of Conferences*, 181, 02005. <https://doi.org/10.1051/shsconf/202418102005>
- Hansun, S., & Suryadibrata, A. (2021). Gold price prediction in covid-19 era. *International Journal of Computational Intelligence in Control*, 13(2), 29–34.
- Huang, Y., Yang, M., & Wang, L. (2024). Gold Price Prediction Model Based on LSTM Neural Network and ARIMA. *Highlights in Science, Engineering and Technology*, 101, 904–913. <https://doi.org/10.54097/zpxfzc86>
- Lei, J., & Lin, Q. (2022). Analysis of gold and bitcoin price prediction based on LSTM model. *Academic Journal of Computing & Information Science*, 5(6), 95–100. <https://doi.org/10.25236/ajcis.2022.050614>
- Mohtasham Khani, M., Vahidnia, S., & Abbasi, A. (2021). A Deep Learning-Based Method for Forecasting Gold Price with Respect to Pandemics. *SN Computer Science*, 2(4), 1–12. <https://doi.org/10.1007/s42979-021-00724-3>
- Primananda, S. B., & Isa, S. M. (2021). Forecasting Gold Price in Rupiah using Multivariate Analysis with LSTM and GRU Neural Networks. *Advances in Science, Technology and Engineering Systems Journal*, 6(2), 245–253. <https://doi.org/10.25046/aj060227>
- 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>
- Sivasamy, R. (2024). Machine Learning-Based GRU, LSTM, HMM, and SARIMA Models for Gold Pricing. *Journal of Electrical Systems*, 20(10s), 215–227. https://www.proquest.com/scholarly-journals/machine-learning-based-gru-lstm-hmm-sarima-models/docview/3092061935/se-2?accountid=49910%0Ahttps://media.proquest.com/media/hms/PFT/1/VXdTZ?_a=ChgyMDI0MDkxNTA2MTIxNDQ3NzoxMzkxNjgSBTMzNDM4GgpPTkVfU0VBUkNIIg02Ni4
- World Gold Council. (n.d.). *Regional Diversity of Gold Demand*. <https://www.gold.org/about-gold>
- YURTSEVER, M. (2021). Gold Price Forecasting Using LSTM, Bi-LSTM and GRU. *European Journal of*

Science and Technology, 31(31), 341–347. <https://doi.org/10.31590/ejosat.959405>

Zhang, X., Zhang, L., Zhou, Q., & Jin, X. (2022). A Novel Bitcoin and Gold Prices Prediction Method Using an LSTM-P Neural Network Model. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/1643413>