

Optimization of bilstm accuracy for gold price forecasting

Anggi Muammar Hanafi¹, Al-Khowarizmi²

^{1,2}Universitas Muhammadiyah Sumatera Utara, Indonesia

Email: anggimuammarhanafi@gmail.com; alkowarizmi@umsu.ac.id

ABSTRAK

Peramalan harga emas merupakan tantangan dalam sektor keuangan karena pergerakannya volatil dan nonlinier serta dipengaruhi oleh berbagai faktor ekonomi. Penelitian ini bertujuan mengimplementasikan dan mengoptimalkan model *Bidirectional Long Short-Term Memory* (BiLSTM) untuk meramalkan harga emas mingguan. Data yang digunakan berupa harga penutupan emas dunia secara mingguan periode 2020–2024 yang diperoleh dari Yahoo Finance. Tahapan pengolahan data meliputi normalisasi menggunakan *Min-Max Scaling*, pembentukan *sliding window*, serta pembagian data menjadi data latih dan data uji. Optimasi model dilakukan dengan menguji kombinasi *hyperparameter*, yaitu jumlah neuron, *epoch*, *batch size*, dan *dropout*. Evaluasi kinerja model menggunakan *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Hasil eksperimen menunjukkan bahwa konfigurasi *hyperparameter* terbaik menghasilkan RMSE sebesar 83,99 dan MAPE sebesar 2,41%. Hasil tersebut menunjukkan bahwa model BiLSTM mampu mengikuti pola pergerakan harga emas mingguan pada data yang digunakan dan dapat digunakan sebagai salah satu pendekatan dalam peramalan harga berbasis *deep learning*.

Kata Kunci: BiLSTM; harga emas; prediksi; time series forecasting; RMSE

ABSTRACT

Gold price forecasting is challenging in the financial sector due to its volatile and nonlinear movements, which are influenced by various economic factors. This study aims to implement and optimize a *Bidirectional Long Short-Term Memory* (BiLSTM) model for forecasting weekly gold prices. The data used consist of weekly world gold closing prices from 2020 to 2024 obtained from Yahoo Finance. The data preprocessing stages include normalization using *Min-Max Scaling*, sliding window construction, and data splitting into training and testing sets. Model optimization was performed by evaluating combinations of hyperparameters, including the number of neurons, epochs, batch size, and dropout. Model performance was evaluated using *Root Mean Squared Error* (RMSE) and *Mean Absolute Percentage Error* (MAPE). The experimental results show that the optimal hyperparameter configuration achieved an RMSE of 83.99 and a MAPE of 2.41%. These results indicate that the BiLSTM model is capable of capturing the weekly gold price movement patterns in the dataset and can be used as an approach for deep learning-based price forecasting.

Keywords: bilstm; gold price; prediction; time series forecasting; rmse

Corresponding Author:

Anggi Muammar Hanafi,
Universitas Muhammadiyah Sumatera Utara,
Jl. Kapten Mughtar Basri No.3, Glugur Darat II, Kec. Medan Tim., Kota
Medan, Sumatera Utara 20238, Indonesia
Email: anggimuammarhanafi@gmail.com



1. INTRODUCTION

Emas telah lama digunakan sebagai instrumen *safe haven* dan sarana diversifikasi investasi, terutama dalam menghadapi ketidakpastian ekonomi global. Karakteristik emas yang relatif mampu mempertahankan nilai aset menjadikannya salah satu instrumen yang menarik bagi investor (Asikin, 2025). Namun, harga emas bersifat fluktuatif, nonstasioner, dan sensitif terhadap berbagai dinamika makroekonomi serta kondisi geopolitik (Amri et al., 2024). Karakteristik tersebut menjadikan peramalan harga emas sebagai permasalahan *time series forecasting* yang kompleks karena pola pergerakannya dapat bersifat nonlinier dan dipengaruhi oleh berbagai faktor eksternal (Madhika et al., 2023).

Fluktuasi harga emas dapat menjadi tantangan dalam pengambilan keputusan investasi karena investor membutuhkan informasi mengenai kemungkinan pergerakan harga pada periode berikutnya. Metode peramalan konvensional, seperti *Autoregressive Integrated Moving Average* (ARIMA), memiliki keterbatasan dalam menangkap hubungan nonlinier yang kompleks pada data deret waktu. Oleh karena itu, pendekatan *deep learning*, khususnya *Long Short-Term Memory* (LSTM) dan pengembangannya berupa *Bidirectional Long Short-Term Memory* (BiLSTM), dapat digunakan sebagai alternatif dalam peramalan data deret waktu (Widiputra et al., 2021). BiLSTM memiliki kemampuan memproses informasi dari dua arah pada urutan data sehingga dapat memanfaatkan representasi temporal secara lebih komprehensif dalam proses pembelajaran (Widiputra et al., 2021). Penelitian Yurtsever (2021) menunjukkan bahwa arsitektur BiLSTM dapat diterapkan untuk peramalan harga emas dengan nilai RMSE sebesar 61,728 dan MAPE sebesar 3,48%.

Meskipun penelitian sebelumnya menunjukkan potensi BiLSTM dalam peramalan harga emas, masih terdapat peluang untuk mengkaji optimasi model menggunakan data dengan interval waktu mingguan. Penelitian ini berfokus pada penerapan dan optimasi model BiLSTM untuk meramalkan harga emas mingguan. Optimasi dilakukan dengan menguji beberapa *hyperparameter*, meliputi jumlah neuron, *batch size*, *dropout*, dan jumlah *epoch*, untuk memperoleh konfigurasi model dengan kinerja terbaik. Penggunaan data mingguan diharapkan dapat memberikan representasi pola pergerakan harga dalam periode yang lebih panjang dengan mengurangi fluktuasi jangka pendek yang terdapat pada data berfrekuensi lebih tinggi.

Berdasarkan fokus penelitian tersebut, penelitian ini bertujuan untuk membangun model BiLSTM dalam melakukan peramalan harga emas mingguan, mengoptimalkan *hyperparameter* model BiLSTM untuk memperoleh konfigurasi dengan kinerja terbaik, serta mengevaluasi kinerja model menggunakan metrik *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE).

2. RESEARCH METHOD

A. Data dan Sumber Data

Data yang digunakan dalam penelitian ini adalah harga penutupan mingguan emas periode Januari 2020 hingga Desember 2024 yang diperoleh dari *Yahoo Finance* melalui pustaka *Python yfinance*. Pemilihan frekuensi mingguan bertujuan untuk mengurangi volatilitas jangka pendek dan menyoroti tren jangka menengah-panjang.

B. Tahapan Penelitian

Tahapan penelitian ini terdiri atas beberapa proses utama, yaitu:

1) Pengumpulan Data

Data harga emas dikumpulkan dari *Yahoo Finance* menggunakan pustaka *yfinance* dengan simbol GC=F. Data yang digunakan berupa harga penutupan emas dengan interval mingguan sesuai periode penelitian.

2) Preprocessing Data

Tahap *preprocessing* meliputi pemeriksaan dan pembersihan data, normalisasi nilai menggunakan *MinMaxScaler*, serta pembentukan *sliding window* sepanjang 60 minggu. Setiap 60 data historis digunakan sebagai masukan untuk memprediksi harga emas pada periode berikutnya.

3) Pembangunan Model BiLSTM

Model dibangun menggunakan arsitektur *Bidirectional Long Short-Term Memory* (BiLSTM) yang terdiri atas lapisan input, satu lapisan BiLSTM, *dropout layer*, dan *dense output layer*. Model digunakan untuk mempelajari pola temporal dari data harga emas historis.

4) Optimasi Hyperparameter

Optimasi dilakukan dengan menguji beberapa kombinasi *hyperparameter*, meliputi jumlah neuron, *batch size*, *dropout rate*, dan jumlah *epoch*. Setiap konfigurasi diuji untuk memperoleh kombinasi parameter yang menghasilkan kinerja model terbaik berdasarkan nilai metrik evaluasi.

5) Evaluasi Model

Evaluasi dilakukan menggunakan data uji sebesar 20% dari keseluruhan data. Kinerja model diukur menggunakan metrik *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Nilai RMSE dan MAPE digunakan untuk menilai tingkat kesalahan hasil peramalan terhadap nilai aktual.

C. Evaluasi Kinerja

Evaluasi kinerja model dilakukan menggunakan dua metrik, yaitu:

1) Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) digunakan untuk mengukur besarnya akar rata-rata kuadrat selisih antara nilai hasil prediksi dan nilai aktual. Metrik ini menunjukkan tingkat kesalahan prediksi dengan memberikan penalti yang lebih besar terhadap kesalahan yang bernilai tinggi. Semakin kecil nilai RMSE, semakin kecil tingkat kesalahan prediksi yang dihasilkan oleh model.

2) Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) digunakan untuk mengukur rata-rata persentase kesalahan absolut antara nilai hasil prediksi dan nilai aktual. Metrik ini menunjukkan besarnya kesalahan prediksi dalam

bentuk persentase sehingga dapat memberikan gambaran mengenai tingkat kesalahan relatif terhadap nilai aktual. Semakin kecil nilai MAPE, semakin kecil persentase kesalahan prediksi yang dihasilkan oleh model.

3. RESULTS AND DISCUSSION


A. Analisis Hasil Pengujian

Pengujian model *Bidirectional Long Short-Term Memory* (BiLSTM) dilakukan menggunakan tiga konfigurasi *hyperparameter*, yaitu Awal, Rendah, dan Tinggi. Kinerja masing-masing konfigurasi dievaluasi menggunakan *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Hasil pengujian dari ketiga konfigurasi tersebut disajikan pada Tabel 1.

Table 1. Hasil Evaluasi Model BiLSTM

Konfigurasi	Units	Batch Size	Epoch	Dropout	RMSE	MAPE
Awal	32	8	100	0.2	108.05	3.03%
Rendah	16	4	50	0.1	99.46	3.24%
Tinggi (terbaik)	128	64	200	0.3	83.99	2.41%

Berdasarkan Tabel 1, konfigurasi Tinggi menghasilkan nilai RMSE terendah, yaitu 83,99, dibandingkan dengan konfigurasi Awal dan Rendah. Nilai tersebut menunjukkan penurunan RMSE sebesar 22% dibandingkan dengan konfigurasi *baseline*. Hasil ini menunjukkan bahwa konfigurasi dengan jumlah *units* dan *epochs* yang lebih tinggi menghasilkan tingkat kesalahan prediksi yang lebih rendah pada data harga emas mingguan yang digunakan dalam penelitian. Berdasarkan nilai RMSE sebagai salah satu dasar evaluasi kinerja model, konfigurasi Tinggi dipilih sebagai konfigurasi terbaik untuk digunakan pada tahap pengujian selanjutnya.



Gambar 1. Grafik Perbandingan Prediksi vs Aktual Harga Emas Mingguan

Visualisasi hasil prediksi model terbaik, yaitu Konfigurasi Tinggi, terhadap data aktual menunjukkan bahwa hasil prediksi secara umum mengikuti pola pergerakan harga emas mingguan, terutama pada periode dengan tren kenaikan. Pola tersebut menunjukkan bahwa model BiLSTM dapat mempelajari hubungan temporal dari data historis yang digunakan dalam proses pelatihan.

Meskipun demikian, terdapat beberapa perbedaan antara nilai prediksi dan nilai aktual, khususnya pada periode terjadinya perubahan harga yang relatif tajam. Beberapa puncak dan lembah pada data aktual belum dapat diikuti secara optimal oleh hasil prediksi. Kondisi tersebut dapat berkaitan dengan karakteristik data harga emas yang dipengaruhi oleh berbagai faktor eksternal yang tidak terdapat dalam variabel input penelitian, seperti perubahan kondisi ekonomi, kebijakan moneter, dan peristiwa geopolitik. Karena penelitian ini menggunakan data harga secara univariat, model hanya memanfaatkan informasi historis harga dalam melakukan peramalan.

Hasil tersebut sejalan dengan penelitian Dalimunthe et al. (2024) yang menerapkan metode berbasis LSTM dalam peramalan harga komoditas dan menunjukkan bahwa pengolahan data serta pemilihan metode pemodelan merupakan bagian penting dalam proses peramalan. Amini dan Kalantari (2024) juga menerapkan model hibrida CNN-BiLSTM dengan optimasi parameter untuk peramalan harga emas. Perbedaan arsitektur, variabel input, periode data, dan konfigurasi eksperimen menyebabkan hasil antarpelatihan tidak dapat dibandingkan secara langsung, tetapi penelitian tersebut dapat menjadi referensi dalam pengembangan model peramalan harga emas berbasis *deep learning*.

B. Implementasi Teknis Model Terbaik

Proses pembentukan model terbaik mencakup dua tahapan teknis utama, yaitu pra-pemrosesan data sekuensial dan perancangan arsitektur BiLSTM. Skrip Python yang digunakan mencakup proses pengambilan data, normalisasi menggunakan *MinMaxScaler*, serta pembentukan data sekuensial menggunakan metode *sliding window* dengan panjang 60 minggu. Tahapan tersebut menghasilkan data dalam bentuk urutan yang selanjutnya digunakan sebagai masukan bagi model *deep learning* dalam proses pelatihan dan peramalan.

```
import yfinance as yf
import numpy as np
from sklearn.preprocessing import MinMaxScaler

# Pengambilan Data, Normalisasi, dan Pembentukan Sliding Window
data = yf.download("GC=F", start="2020-01-01", end="2024-12-31", interval="1wk")
data = data[["Close"]].dropna()
scaler = MinMaxScaler()
scaled_data = scaler.fit_transform(data)

def create_dataset(dataset, window_size=60):
    X, y = [], []
    for i in range(window_size, len(dataset)):
        X.append(dataset[i - window_size:i, 0])
        y.append(dataset[i, 0])
    return np.array(X), np.array(y)

X, y = create_dataset(scaled_data, window_size=60)
# Reshape data untuk input BiLSTM: [sampel, timestep, fitur]
X = np.reshape(X, (X.shape[0], X.shape[1], 1))
train_size = int(len(X) * 0.8)
X_train, X_test = X[:train_size], X[train_size:]
y_train, y_test = y[:train_size], y[train_size:]
```

Setelah tahap pra-pemrosesan data, skrip kedua digunakan untuk mendefinisikan dan melatih arsitektur model terbaik yang menghasilkan nilai RMSE sebesar 83,99 dan MAPE sebesar 2,41%. Arsitektur tersebut terdiri atas satu lapisan *Bidirectional Long Short-Term Memory* (BiLSTM) dengan 128 *units* dan lapisan *dropout* sebesar 0,3. Penggunaan *dropout* bertujuan untuk mengurangi risiko *overfitting* selama proses pelatihan model. Model dilatih selama 200 *epochs* dengan *batch size* sebesar 64. Setelah proses prediksi selesai, hasil prediksi dikembalikan ke skala harga asli dalam satuan USD melalui proses *inverse transformation*. Selanjutnya, nilai prediksi dan nilai aktual pada skala asli digunakan untuk menghitung metrik evaluasi akhir, yaitu RMSE dan MAPE.

```
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Bidirectional, Dense, Dropout

# Konfigurasi Terbaik
UNITS = 128
BATCH_SIZE = 64
EPOCHS = 200
DROPOUT_RATE = 0.3
WINDOW_SIZE = X_train.shape[1]

# Pembangunan dan Pelatihan Model
model = Sequential()
model.add(Bidirectional(LSTM(units=UNITS, return_sequences=False),
                        input_shape=(WINDOW_SIZE, 1)))
model.add(Dropout(DROPOUT_RATE))
model.add(Dense(units=1))

model.compile(optimizer='adam', loss='mean_squared_error')
model.fit(X_train, y_train, epochs=EPOCHS, batch_size=BATCH_SIZE, verbose=0)

# Prediksi dan Evaluasi (Inverse Transform)
y_pred_scaled = model.predict(X_test)
```

```

y_test_original = scaler.inverse_transform(y_test.reshape(-1, 1))
y_pred_original = scaler.inverse_transform(y_pred_scaled)

def calculate_metrics(actual, predicted):
    rmse = np.sqrt(np.mean((actual - predicted)**2))
    mape = np.mean(np.abs((actual - predicted) / actual)) * 100
    return rmse, mape

```

Implementasi kode tersebut menjadi bagian penting dalam pembahasan karena menunjukkan keterkaitan antara konfigurasi model yang digunakan dan hasil pengujian pada Tabel 1. Arsitektur serta parameter *hyperparameter* yang telah ditentukan diimplementasikan dalam proses pelatihan model untuk menghasilkan konfigurasi dengan nilai RMSE sebesar 83,99 dan MAPE sebesar 2,41%.

4. CONCLUSION

BiLSTM merupakan pengembangan dari arsitektur LSTM yang termasuk dalam keluarga *Recurrent Neural Network* (RNN) dan dirancang untuk mengatasi keterbatasan dalam mempertahankan informasi pada urutan data yang panjang, termasuk permasalahan *vanishing gradient* (Sawitri, 2025). BiLSTM memproses informasi dalam dua arah, yaitu dari masa lalu ke masa depan (*forward direction*) dan dari masa depan ke masa lalu (*backward direction*), sehingga memungkinkan model memperoleh representasi temporal yang lebih komprehensif dari data deret waktu (Yudistira et al., 2023). Dalam penelitian ini, penerapan BiLSTM dengan optimasi *hyperparameter* menghasilkan konfigurasi terbaik dengan nilai RMSE sebesar 83,99 dan MAPE sebesar 2,41% pada peramalan harga emas mingguan. Hasil tersebut menunjukkan bahwa konfigurasi *hyperparameter* yang digunakan memberikan tingkat kesalahan prediksi yang lebih rendah dibandingkan konfigurasi lainnya pada data yang digunakan dalam penelitian. Model yang diperoleh dapat dikembangkan lebih lanjut untuk diintegrasikan ke dalam sistem peramalan berbasis web atau aplikasi sebagai sarana penyajian informasi hasil prediksi. Namun, hasil penelitian ini masih memiliki keterbatasan karena model hanya menggunakan data harga penutupan (*Close*) mingguan sebagai variabel input, sehingga belum mempertimbangkan faktor eksternal yang dapat memengaruhi pergerakan harga emas. Oleh karena itu, penelitian selanjutnya dapat mempertimbangkan penggunaan variabel tambahan, seperti harga pembukaan (*Open*), volume perdagangan, indikator teknikal, data makroekonomi, atau sentimen pasar. Selain itu, optimasi *hyperparameter* dapat dikembangkan menggunakan metode pencarian yang lebih sistematis, seperti *Random Search* atau *Bayesian Optimization*, untuk mengeksplorasi ruang parameter secara lebih luas dan memperoleh konfigurasi model yang sesuai dengan karakteristik data.

REFERENSI

- Amini, A., & Kalantari, R. (2024). Gold price prediction by a CNN-Bi-LSTM model along with automatic parameter tuning. *PLOS ONE*, 19(3), e0298426. <https://doi.org/10.1371/journal.pone.0298426>
- Amri, I. F., Astuti, S. A., Sulistiya, I., Suherdi, A., & Al Haris, M. (2024). Peramalan harga emas Antam menggunakan metode generalized autoregressive conditional heteroskedasticity (GARCH). *UJMC (Unisda Journal of Mathematics and Computer Science)*, 10(1), 26–35. <https://doi.org/10.52166/ujmc.v10i1.4679>
- Asikin, M. Z. (2025). Peran emas sebagai lindung nilai terhadap ketidakpastian pasar keuangan global. *Hawalah: Kajian Ilmu Ekonomi Syariah*, 3(3), 123–133. <https://doi.org/10.57096/hawalah.v3i3.54>
- Dalimuthe, R. A., Adek, R. T., & Agusniar, C. (2024). Prediksi harga emas menggunakan algoritma long short-term memory (LSTM). *Prosiding Seminar Nasional Teknologi dan Teknik Informatika (SENASTIKA)*, 1(1).
- Kushariyadi, K., Apriyanto, H., Herdiana, Y., Asy'ari, F. H., Judijanto, L., Pasrun, Y. P., & Mardikawati, B. (2024). *Artificial intelligence: Dinamika perkembangan AI beserta penerapannya*. PT Sonpedia Publishing Indonesia.
- Madhika, Y. R., Kusriani, K., & Hidayat, T. (2023). Gold price prediction using the ARIMA and LSTM models. *Sinkron: Jurnal dan Penelitian Teknik Informatika*, 8(3), 1255–1264. <https://doi.org/10.33395/sinkron.v8i3.12461>
- Nurulhuda, E. S., & Kosasih, K. (2019). Pengaruh inflasi, kurs dolar AS, dan suku bunga (BI) terhadap penentuan harga emas. *Kinerja*, 2(2), 71–94. <https://doi.org/10.34005/kinerja.v2i02.797>
- Sawitri, D. (2025). Peran deep learning dan big data dalam mendeteksi masalah keuangan. *Djtechno: Jurnal Teknologi Informasi*, 6(1), 193–207. <https://doi.org/10.46576/djtechno.v6i1.6037>
- Widiputra, H., Mailangkay, A., & Gautama, E. (2021). Prediksi indeks BEI dengan ensemble convolutional neural network dan long short-term memory. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(3), 456–465. <https://doi.org/10.29207/resti.v5i3.3111>
- Yahoo Finance. (2024). *Gold futures (GC=F) historical data*. Retrieved January 5, 2025, from <https://finance.yahoo.com/quote/GC=F/history>
- Yurtsever, M. (2021). Gold price forecasting using LSTM, Bi-LSTM and GRU. *Avrupa Bilim ve Teknoloji Dergisi*, (31), 341–347. <https://doi.org/10.31590/ejosat.959405>