

Prediksi Harga Emas Menggunakan Algoritma Long-Short Term Memory dengan Optimasi Adaptive Momen Estimation

Muh. Hadrianto¹, Anugrah Nur Isnaeni Rahman², Aulia Syahrani Haris³,
Ahmad Juzril⁴, Novia Rahmadani⁵

^{1,2,3,4,5}Departemen Statistika, Universitas Hasanuddin, Indonesia

Article Info

Article history:

Received Dec 08, 2024

Revised Sept 13, 2025

Accepted Sept 15, 2025

Keywords:

Adaptive Momen Estimation

Long-Short Term Memory

Prediksi Harga Emas

Time Series

ABSTRACT

Accurate gold price prediction is a crucial aspect of investment decision-making. This study implements a Long Short-Term Memory (LSTM) model, optimized with Adaptive Moment Estimation (Adam), to forecast daily gold prices based on historical data from the 2000-2024 period. The experimental results demonstrate the superior performance of the LSTM-Adam model, which achieved high accuracy with a Mean Absolute Percentage Error (MAPE) of 0.96% and a Mean Squared Error (MSE) of 320,854,198. This model proved to outperform benchmark models such as GRU, ARIMA, and Random Forest by exhibiting the lowest error rates. Furthermore, projections for the next year indicate a consistent upward trend in prices. These findings confirm that the LSTM-Adam architecture is a reliable and robust approach for gold price forecasting, offering a practical contribution to investment strategies and opening opportunities for further applications in modeling other commodity prices.

Corresponding Author:

Muh. Hadrianto,
Departemen Statistika,
Universitas Hasanuddin,
Jl. Politeknik, Tamalanrea, Tamalanrea Indah, Makassar.
Email: muhhadriantoarsyad@gmail.com

1. PENDAHULUAN

Kebutuhan hidup manusia terus meningkat, sementara inflasi yang berkelanjutan menyebabkan harga barang dan jasa naik, yang pada gilirannya dapat menyebabkan penurunan pendapatan riil masyarakat. Kondisi ini menimbulkan kekhawatiran tentang kemampuan mereka dalam membiayai kebutuhan hidup saat ini dan di masa depan. Untuk menghadapi hal tersebut, banyak orang memilih untuk mengalihkan tabungan mereka ke dalam bentuk investasi, karena nilai mata uang yang tergerus inflasi berpotensi merugikan. Investasi menawarkan berbagai alternatif, seperti properti, tanah, saham, modal usaha, dan logam mulia seperti emas. Sebagian besar masyarakat beranggapan bahwa harga emas selalu meningkat terhadap nilai tukar rupiah, meskipun kenyataannya, harga emas juga mengalami fluktuasi harian yang signifikan, yang menjadikannya sebagai investasi berbasis data *time series*. Oleh karena itu, penting bagi investor untuk dapat memprediksi harga emas di masa depan menggunakan metode ilmiah yang dapat meminimalkan risiko investasi.

Peramalan harga emas menjadi topik yang menarik dan banyak diteliti, mengingat volatilitas harga yang cukup tinggi. Berbagai metode prediksi harga emas, mulai dari yang sederhana hingga yang kompleks, terus dikembangkan untuk mencapai akurasi yang lebih tinggi dalam peramalan. Metode-metode ini mempertimbangkan sifat non-linearitas dari data harga emas itu sendiri [1]. Dalam peramalan harga, metode konvensional seperti regresi linear dan ARIMA (*Autoregressive Integrated Moving Average*) sering digunakan, mengingat kemudahan dalam mengaplikasikan model pada data historis. Namun, metode-metode ini memiliki keterbatasan dalam menangkap pola yang lebih kompleks dan hubungan non-linear dalam data harga emas, yang dapat mengarah pada ketidakakuratan prediksi dalam menghadapi perubahan dinamis pasar.

Metode *machine learning*, seperti *Support Vector Machine* (SVM) dan *Random Forest*, semakin banyak digunakan dalam peramalan harga karena kemampuannya untuk menangkap pola yang lebih kompleks dan hubungan non-linear dalam data. Keunggulan ini membuat metode *machine learning* lebih unggul


dibandingkan dengan pendekatan statistik klasik seperti regresi linear dan ARIMA, terutama ketika data yang dihadapi memiliki struktur yang rumit. Namun, penerapan *machine learning* pada data *time series* masih menghadapi tantangan, terutama dalam menangani pola non-linearitas tinggi dan dependensi temporal.

Kemunculan *Deep Learning*, khususnya *Recurrent Neural Network* (RNN), menawarkan solusi dalam memahami hubungan temporal pada data *time series*. Namun, RNN menghadapi kendala dalam mengolah urutan panjang karena masalah *vanishing gradient*, yang menghambat kemampuan jaringan untuk belajar pola jangka panjang. *Long Short-Term Memory* (LSTM) kemudian dikembangkan untuk mengatasi kendala tersebut dengan mekanisme memori jangka panjang melalui *input gate*, *forget gate*, dan *output gate* yang memungkinkan model menangkap pola jangka panjang dalam data [2]. Untuk mengoptimalkan bobot setiap layer dan menghasilkan prediksi yang akurat, LSTM dapat menggunakan optimasi *adaptive momen estimation* (Adam). Dibandingkan dengan *Stochastic Gradient Descent* (SGD), Optimasi Adam menunjukkan kecepatan konvergensi yang lebih tinggi. Adam merupakan modifikasi dari *Gradient Descent* yang lebih efisien dalam komputasi dan cocok untuk optimasi dengan parameter besar, sehingga menghasilkan prediksi yang lebih akurat pada *output layer* [3].

Selain itu, penelitian yang dilakukan oleh Cahyani *et al.* dalam memprediksi harga bahan pokok nasional, seperti beras, daging ayam, dan minyak goreng, menggunakan berbagai metode optimasi untuk menguji skenario prediksi. Metode yang digunakan meliputi *Adaptive Gradient* (ADAGRAD), *Adaptive Moment Estimation* (Adam), dan *Root Mean Square Propagation* (RMSProp). Hasil uji coba menunjukkan bahwa metode Adam memberikan hasil terbaik dalam menghasilkan prediksi yang akurat pada sebagian besar komoditas yang diuji. Berdasarkan hasil penelitian tersebut, metode optimasi Adam terbukti mampu meningkatkan performa prediksi secara signifikan [4]. Temuan tersebut sejalan dengan penelitian yang menegaskan bahwa LSTM menjadi salah satu model *deep learning* paling unggul dalam peramalan data *time series* di berbagai domain, termasuk keuangan dan energi, berkat kemampuannya menangkap hubungan temporal yang kompleks [5]. Namun, penerapan kombinasi LSTM dengan optimasi Adam pada peramalan harga emas masih jarang dilakukan, padahal emas memiliki karakteristik volatilitas yang tinggi dan berdampak langsung terhadap keputusan investasi masyarakat. Oleh karena itu, penelitian ini berupaya mengisi celah tersebut dengan menerapkan metode LSTM yang dioptimasi menggunakan Adam untuk memprediksi harga emas. Pendekatan ini diharapkan dapat menghasilkan model prediksi yang lebih akurat dibandingkan metode konvensional, sehingga mampu memberikan kontribusi nyata dalam pengelolaan risiko investasi masyarakat.

2. METODE

Tahapan penelitian yang dilakukan terdiri dari beberapa langkah, antara lain: pengumpulan data, eksplorasi data, *pre-processing*, pelatihan model LSTM, evaluasi model, denormalisasi, prediksi harga emas dan interpretasi serta kesimpulan. Proses ini digambarkan secara rinci pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1. Pengumpulan Data

Pengumpulan data harga dalam penelitian ini meliputi pengambilan data secara sekunder diperoleh dari situs web resmi *World Gold Council* (WGC), yang dapat diakses melalui <https://www.gold.org/goldhub/data/gold-prices>. *World Gold Council* (WGC) adalah organisasi internasional yang mewakili industri emas global, khususnya perusahaan-perusahaan pertambangan emas terkemuka.

Data yang digunakan dalam penelitian ini adalah data harga emas harian pada periode Januari 2000 hingga November 2024, yang terdiri dari 9087 baris data. Data tersebut mencatat harga emas dalam satuan *troy ounce*, dengan 1 *troy ounce* setara dengan 31,1035 gram. Satuan *troy ounce* adalah standar internasional yang digunakan dalam perdagangan logam mulia, termasuk emas, perak, dan platinum di pasar global.

2.2. Pre-Processing Data

Tahapan *pre-processing* data dilakukan untuk mempersiapkan data mentah menjadi data yang siap digunakan dalam pembangunan model LSTM [6]. *Pre-processing* data sangat penting dalam penelitian ini karena metode LSTM membutuhkan data *time series* yang telah diformat dan disesuaikan agar dapat menghasilkan prediksi yang akurat. Langkah-langkah *pre-processing* data dalam penelitian ini meliputi:

2.2.1. Data Cleaning

Dalam analisis *time series*, interval waktu yang konsisten sangat penting untuk menghasilkan model yang akurat. Penanganan dilakukan dengan membuat rentang tanggal lengkap (2000–2024) berfrekuensi harian dan mengidentifikasi tanggal yang hilang. Metode *forward fill* diterapkan untuk mengisi harga emas yang hilang menggunakan nilai sebelumnya, untuk mengatasi lompatan tanggal akibat pencatatan awal yang hanya mencatat dihari jam kerja. Hal ini dilakukan agar data memiliki kontinuitas temporal dengan rentang waktu seragam yang diperlukan untuk analisis *time series* tanpa mengubah pola harga historis.

2.2.2. Normalisasi

Normalisasi data adalah langkah penting dalam *preprocessing* yang bertujuan untuk mengubah skala data agar berada dalam rentang tertentu. Normalisasi ini dilakukan untuk mempercepat pelatihan model, meningkatkan stabilitas komputasi, dan memastikan kontribusi setiap fitur proporsional. Data harga emas dinormalisasi ke dalam rentang [0, 1] dengan metode *min-max scaler* yang dirumuskan sebagai berikut [7]:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

2.2.3. Pembagian Data Training dan Testing


Pada penelitian ini, data harga emas dari tahun 2000 hingga 2024 dibagi menjadi dua bagian, yaitu 80% untuk data pelatihan dan 20% untuk data pengujian. Pembagian dilakukan berdasarkan urutan waktu untuk menjaga keutuhan informasi *time series*. Dari total data yang tersedia, data *training* terdiri atas 7.268 baris, sedangkan data *testing* sebanyak 1.818 baris.

2.2.4. Penentuan Time Step

Data *time series* diubah menjadi bentuk *sequence* dengan menggunakan parameter *time step*. *Time step* merupakan jumlah periode sebelumnya yang digunakan untuk memprediksi nilai pada periode berikutnya [8]. Dalam penelitian ini, nilai *time step* ditentukan berdasarkan analisis pola harga emas, yang bertujuan untuk menangkap hubungan temporal yang relevan dari data historis. Pada tahap ini, dipilih *time step* sebesar 30 hari, berdasarkan analisis pola data harga emas, di mana fluktuasi harga cenderung lebih jelas dalam rentang waktu bulanan. Dengan menggunakan *time step* ini, model akan memanfaatkan 30 hari terakhir untuk memprediksi harga emas pada hari berikutnya.

2.3. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) disebutkan untuk pertama kali pada tahun 1997 yang dijelaskan oleh Hochreiter dan Schmidhuber [9]. LSTM juga dikenal sebagai jaringan saraf dengan arsitektur yang fleksibel, sehingga strukturnya dapat disesuaikan sesuai dengan kebutuhan aplikasi tertentu. LSTM merupakan salah satu jenis dari *Recurrent Neural Network* yang dirancang untuk mengenali pola jangka panjang pada data *time series* [10]. Struktur detail dari satu unit sel LSTM ditampilkan pada Gambar 2.



Gambar 2. Sel LSTM

Gambar 2 menunjukkan satu sel LSTM yang terdiri dari tiga komponen utama, yaitu *Forget Gate*, *Input Gate*, dan *Output Gate*. *Forget Gate* berfungsi untuk mengatur informasi dari input sebelumnya (C_{t-1}) yang perlu diabaikan. Nilai pada *forget gate* berada dalam rentang 0 hingga 1. Ketika nilainya mendekati 0, sel LSTM akan melupakan informasi dari langkah sebelumnya. *Input Gate* merupakan komponen yang berisi informasi baru yang akan dimasukkan dari input saat ini (X_t) dan *output gate* sebelumnya (h_{t-1}). Nilai *input gate* juga berupa nilai antara 0 dan 1 [11]. *Output Gate* berperan dalam menghasilkan nilai keluaran dari sel LSTM berdasarkan kondisi status sel saat ini (C_t) dan nilai dari output gate (h_t). Berdasarkan penelitian Hochreiter & Schmidhuber (1997), persamaan yang digunakan dalam metode LSTM dijelaskan melalui persamaan (2) hingga (6) [12]:

$$\text{Input Gate} : i_t = \sigma(W_i[h_{t-1}, X_t] + b_i) \quad (2)$$

$$\text{Forget Gate} : f_t = \sigma(W_f[h_{t-1}, X_t] + b_f) \quad (3)$$

$$\text{Output Gate} : o_t = \sigma(W_o[h_{t-1}, X_t] + b_o) \quad (4)$$

$$\text{Intermediate Cell State} : \tilde{C} = \tanh(W_c[h_{t-1}, X_t] + b_c) \quad (5)$$

$$\text{Cell state (next memory input)} : C_t = (i_t \times \tilde{C}) + (f_t \times C_{t-1}) \quad (6)$$

dengan,


W = bobot (weight) dari matriks.

h = hidden state pada time step sebelumnya

x = input time step

b = bias dari vector.

Akurasi prediksi diperoleh dari data yang telah melalui proses pelatihan, di mana salah satu faktor kunci keberhasilannya adalah jumlah lapisan tersembunyi [13]. Atribut yang digunakan dalam penelitian ini mencakup tanggal pencatatan harga emas harian dan nilai harga emas per troy ounce. Arsitektur LSTM yang digunakan untuk memprediksi harga emas disajikan pada Gambar 3.



Gambar 3. Arsitektur LTSM Prediksi Harga Emas

2.4. Adaptive Momen Estimation (Adam)

Optimasi Adam adalah sebuah metode optimisasi berbasis stokastik untuk pembaruan bobot jaringan secara iteratif berdasarkan data pelatihan, yang merupakan pendekatan orde pertama dari fungsi objektif stokastik [14]. Tujuan utama dari optimasi Adam adalah untuk menghitung *adaptive learning rate* untuk setiap parameter. *Learning rate* ini mengontrol seberapa besar perubahan yang dilakukan pada bobot jaringan. Berikut ini merupakan persamaan untuk optimasi Adam [15]:

$$\text{Menghitung gradien } g_t \text{ pada waktu } t : g_t = \nabla_{\theta} f_t(\theta_{t-1}) \quad (7)$$

$$\text{Memperbarui bias momen vektor pertama : } m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (8)$$

$$\text{Memperbarui bias momen vektor kedua : } v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (9)$$

$$\text{menghitung bias momen vektor pertama : } \hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (10)$$

$$\text{Menghitung bias momen vektor kedua : } \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (11)$$

$$\begin{array}{l} \text{Memperbarui parameter dengan} \\ \text{menggunakan learning rate} \end{array} : \theta_{t+1} = \theta_t - \frac{n}{\sqrt{\hat{v}_t + \varepsilon}} \hat{m}_t \quad (12)$$

2.5. Pelatihan Model LSTM

Pelatihan model LSTM dilakukan dengan menggunakan data yang telah dilakukan pada tahap *preprocessing* sebelumnya, meliputi data yang telah dinormalisasi dan dipisahkan ke dalam data pelatihan. Tahapan pelatihan meliputi:

2.5.1. Input Data

Tahap input data merupakan langkah awal dalam pelatihan model LSTM. Pada tahap ini, data telah dipisahkan menjadi dua bagian, yaitu data training dan data testing. Selanjutnya, data latih dipersiapkan dalam format tiga dimensi (*samples, timesteps, features*) yang sesuai dengan kebutuhan model LSTM. Data yang awalnya berbentuk dua dimensi (*rows, features*), di mana setiap baris mewakili waktu (*timestamp*) dan setiap kolom adalah fitur, perlu diubah menjadi format tiga dimensi untuk mencerminkan urutan waktu yang diperlukan oleh model LSTM. Proses transformasi ini dilakukan menggunakan fungsi *reshaping* dari library Python seperti NumPy atau Pandas.

2.5.2. Arsitektur Model

Arsitektur model LSTM yang digunakan dalam penelitian ini dirancang untuk menangani data *time series* dengan mempertimbangkan pola temporal. Model ini terdiri dari beberapa lapisan utama, yaitu lapisan LSTM, lapisan *dropout*, dan lapisan *dense (fully connected)*. Lapisan LSTM berfungsi untuk menangkap pola temporal dalam data dengan memanfaatkan mekanisme memori jangka pendek dan jangka panjang. Selanjutnya, lapisan *dropout* diterapkan untuk mengurangi risiko *overfitting* dengan secara acak menonaktifkan sejumlah unit selama pelatihan. Lapisan *dense* digunakan untuk menghasilkan prediksi akhir, yang dalam kasus ini adalah harga emas pada waktu tertentu. Arsitektur yang digunakan dalam penelitian ini dirancang dengan parameter pada Tabel 1 berikut:

Tabel 1. Arsitektur Model LSTM

Parameter	Konfigurasi
Jumlah Neuron pada LSTM	10, 20, 30, 40, 50
Dropout Rate	0.2
Aktivasi pada Lapisan Dense	Linear
Optimizer	Adam
Loss Function	Mean Squared Error (MSE)

2.5.3. Parameter Pelatihan Model

Parameter pelatihan model LSTM yang digunakan dalam penelitian ini dirancang untuk memastikan proses pelatihan berlangsung secara efisien dan menghasilkan model dengan performa yang optimal. Proses

pelatihan dilakukan dengan beberapa pengaturan utama, yaitu jumlah *epoch*, *batch size*, *learning rate*, dan *validation split*.

Jumlah *epoch* ditetapkan untuk mengontrol jumlah iterasi pelatihan penuh pada data, memastikan model cukup belajar tanpa *overfitting*. *Batch size* digunakan untuk menentukan jumlah data yang diproses dalam satu kali pembaruan bobot. Selain itu, *learning rate* pada *optimizer Adam* diatur untuk mengontrol kecepatan pembaruan parameter model, sehingga proses konvergensi ke solusi optimal dapat berjalan stabil. *Validation split* diterapkan dengan memisahkan sebagian data latih sebagai data validasi selama pelatihan. Parameter pelatihan yang digunakan dalam penelitian ini dapat dilihat pada Tabel 2 berikut:

Tabel 2. Parameter Pelatihan Model

Parameter	Nilai
<i>Epoch</i>	100, 200, 300
<i>Batch size</i>	32
<i>Learning rate</i>	0.001
<i>Validation split</i>	0.2

2.5.4. Parameter Model Terbaik

Tahap pemilihan parameter model terbaik dilakukan dengan menguji variasi jumlah *neuron* pada lapisan LSTM dan jumlah *epoch* untuk menentukan konfigurasi model yang optimal. Pemilihan model terbaik didasarkan pada performa model yang diukur menggunakan metrik *Mean Squared Error* (MSE). Hasilnya dapat dilihat pada Tabel 3 berikut:

Tabel 3. Parameter Model

Learning Rate	Jumlah Neuron	Epoch	MSE
0.001	10	100	2118003.8659
		200	1756500.8582
		300	2101142.3162
	20	100	1494411.5773
		200	827768.5783
		300	1218961.9320
	30	100	1135227.4090
		200	584990.5952
		300	957091.6193
	40	100	567707.4524
		200	538876.7668
		300	491477.8940
	50	100	320854.1981
		200	1109645.7958
		300	358732.7479

2.6. Denormalisasi

Setelah memperoleh hasil dari proses prediksi, langkah berikutnya adalah melakukan denormalisasi sebelum menghitung akurasi prediksi. Denormalisasi dilakukan untuk mengembalikan data hasil prediksi ke nilai aslinya, karena data prediksi masih berada dalam bentuk rentang interval yang diperoleh dari proses normalisasi. Persamaan denormalisasi dapat dilihat sebagai berikut [6]:

$$d = d'(max - min) + min \quad (13)$$

dengan,

d = Nilai hasil denormalisasi

d' = Nilai data normalisasi

max = Nilai maksimum dari data aktual

min = Nilai minimum dari data aktual.

2.7. Evaluasi Model

Evaluasi kinerja model dalam penelitian ini menggunakan *Mean Square Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE). MSE mengukur kesalahan prediksi yang signifikan karena kesalahan-kesalahan tersebut dikuadratkan. Metode ini cenderung memberikan penilaian yang lebih baik untuk kesalahan kecil, namun terkadang menghasilkan perbedaan yang besar. Sementara itu MAPE dihitung menggunakan kesalahan mutlak dalam setiap periode dibagi dengan nilai-nilai yang diamati untuk periode tersebut. Semakin kecil nilai MAPE maka semakin baik kinerja peramalan [16]. Persamaan untuk menghitung nilai MSE dan MAPE adalah sebagai berikut:

$$MSE = \frac{\sum_{i=1}^n e_i^2}{n} = \frac{\sum_{i=1}^n (X_i - F_i)^2}{n} \quad (14)$$

$$MAPE = \frac{\sum_{i=1}^n \frac{|e_i|}{X_i} \times 100\%}{n} = \frac{\sum_{i=1}^n \frac{|X_i - F_i|}{X_i} \times 100\%}{n} \quad (15)$$

dengan,

X_i = Data aktual pada periode ke i

F_i = Nilai peramalan pada periode ke i

e_i = Kesalahan peramalan pada periode i

n = Jumlah data.

Adapun kriteria skala MAPE adalah sebagai berikut:

Tabel 4. Kriteria Skala MAPE	
Skala MAPE	Kriteria
< 10%	Sangat Baik
10 – 20 %	Baik
20 – 50 %	Cukup
> 50 %	Buruk

3. HASIL DAN PEMBAHASAN

Tahapan ini akan menjelaskan proses yang dilakukan untuk prediksi harga emas menggunakan metode LSTM.

3.1. Deskripsi Data


Deskripsi data dilakukan untuk memberikan gambaran awal mengenai karakteristik data yang digunakan serta pola perubahan harga emas dari waktu ke waktu. Statistik deskriptif mencakup perhitungan rata-rata, median, nilai minimum, maksimum, dan standar deviasi harga emas harian untuk memahami sebaran data dan fluktuasi harga. Hasilnya pada Tabel 5 berikut:

Tabel 5. Statistik Deskriptif	
Statistik	IDR (Per Troy Ounce)
Rata-rata	13,939,326.68
Median	14,683,424.10
Minimum	1,985,982.50
Maksimum	43,614,112.50
Standar Deviasi	9,280,451.84

Tabel 5 menunjukkan bahwa harga emas memiliki nilai rata-rata sebesar 13,939,326.68 IDR dengan nilai minimum 1,985,982.50 IDR dan maksimum 43,614,112.50 IDR. Standar deviasi sebesar 9,280,451.84 IDR menunjukkan adanya fluktuasi yang cukup tinggi dalam harga emas selama periode tersebut. Selain itu, nilai median yang sebesar 14,683,424.10 IDR menunjukkan bahwa distribusi data cenderung simetris dan tidak terlalu jauh dari nilai rata-rata.

3.2. Tren Pola Harga Emas

Setelah analisis deskriptif dilakukan, langkah selanjutnya adalah menganalisis tren harga emas menggunakan grafik *time series* untuk menunjukkan pergerakan dan fluktuasi harga harian. Hasilnya dapat dilihat pada Gambar 4 berikut:




Gambar 4. Tren Pola Harga Emas

Gambar 4 menunjukkan tren harga emas yang meningkat signifikan dari 2000 hingga 2024, dengan kenaikan stabil jangka panjang dan lonjakan signifikan pada 2010-2012 dan setelah 2019.

3.3. Evaluasi Model

Pada penelitian ini, metrik evaluasi yang digunakan adalah *Mean Absolute Percentage Error* (MAPE). MAPE dipilih karena mampu mengukur tingkat kesalahan prediksi dalam bentuk persentase, sehingga memudahkan interpretasi performa model. Hasil evaluasi menunjukkan bahwa nilai MAPE yang diperoleh adalah 0.96%.

Merujuk pada Tabel Kriteria Skala MAPE, nilai sebesar 0.96% masuk dalam kategori Sangat Baik karena berada di bawah 10%. Hal ini menunjukkan bahwa model yang digunakan memiliki kemampuan prediksi yang sangat baik dan dapat diandalkan untuk menangkap pola temporal dalam data. Berikut merupakan hasil prediksi dengan nilai aktual dapat dilihat pada gambar 5



Gambar 5. Aktual Vs Prediksi Harga Emas

3.4. Perbandingan Kinerja dengan Model Lain

Penilaian kinerja model dilakukan dengan membandingkan beberapa model lain yang umum digunakan dalam peramalan deret waktu, yaitu GRU, ARIMA, dan Random Forest (RF). Seluruh model dibangun dan dievaluasi menggunakan skema pembagian data yang sama (80% data latih dan 20% data uji). Evaluasi dilakukan dengan menggunakan MSE dan MAPE hasil perbandingan ditunjukkan pada Tabel 6.


Tabel 6. Perbandingan LSTM dengan model lain

Model	MSE	MAPE (%)
LSTM	320,854,198	0.96
GRU	346,622,820	1.38
ARIMA (0,1,1)	490,179,939	5.40
Random Forest	906,943,035	23.19

Hasil pada Tabel 6 menunjukkan bahwa LSTM (Adam) memberikan MSE terkecil dan MAPE terendah, sehingga menjadi model dengan akurasi terbaik pada pengujian. GRU menempati posisi berikutnya, sedangkan ARIMA (0,1,1) dan RF menunjukkan kesalahan yang lebih tinggi. Secara metodologis, keunggulan LSTM dapat dikaitkan dengan kemampuannya menangkap dependensi temporal jangka panjang dan pola nonlinier pada data deret waktu, sementara optimisasi Adam membantu proses konvergensi bobot yang lebih stabil. Sebaliknya, ARIMA yang berasumsi linearitas serta RF yang mengandalkan konstruksi fitur lag statis kurang efektif dalam merepresentasikan dinamika jangka panjang yang kompleks pada harga emas. Temuan ini menguatkan pemilihan LSTM-Adam sebagai model utama dalam studi ini.

3.5. Prediksi Harga Emas

Setelah model LSTM dilatih dan divalidasi, tahap selanjutnya adalah melakukan prediksi harga emas untuk 365 hari ke depan. Prediksi ini bertujuan untuk memberikan gambaran mengenai pergerakan harga emas di masa mendatang berdasarkan pola historis yang telah dipelajari oleh model. Hasil prediksi harga emas 365 hari ke depan disajikan pada Gambar 6 yang memperlihatkan nilai-nilai prediksi terhadap waktu.




Gambar 6. Prediksi Harga Emas 1 Tahun Ke Depan

Hasil prediksi juga disusun dalam bentuk tabel, seperti yang disajikan pada Tabel 7 berikut:

Tabel 7. Hasil Prediksi 1 Tahun Kedepan

Date	Prediksi Harga Emas IDR (Per Troy Ounce)	Time	Prediksi Harga Emas IDR (Per Troy Ounce)
11/16/2024	41,760,613.90	11/23/2024	42,132,471.16
11/17/2024	41,789,810.84	11/24/2024	42,175,645.43
11/18/2024	41,812,219.54	11/25/2024	42,208,826.09
11/19/2024	41,896,572.23	11/26/2024	43,300,685.18
11/20/2024	41,935,928.23		
11/21/2024	42,000,440.24	11/14/2025	53,392,498.24
11/22/2024	42,076,101.78	11/15/2025	53,426,953.42

untuk melihat secara jelas nilai kenaikan dan penurunan hasil forecasting harga emas dapat dilihat pada gambar 7 berikut:



Gambar 7. Prediksi Harga Emas 1 Tahun Ke Depan

Berdasarkan hasil prediksi, harga emas menunjukkan tren meningkat secara bertahap selama periode satu tahun ke depan. Hal ini terlihat dari nilai prediksi harga emas sebesar Rp41.760.613,90 pada 16 November 2024 yang terus meningkat hingga mencapai Rp53.426.953,42 pada 15 November 2025. Kenaikan ini berlangsung secara konsisten setiap hari, meskipun dengan perubahan yang relatif kecil dari satu hari ke hari berikutnya. Hasil prediksi ini sepenuhnya didasarkan pada pola data historis dan asumsi yang telah dipelajari oleh model LSTM. Jika terjadi perubahan drastis dalam kondisi pasar, seperti resesi global, konflik geopolitik, atau lonjakan inflasi, hasil prediksi dapat menjadi kurang akurat.

3.6 Analisis Kritis dan Keterbatasan Penelitian

Meskipun model LSTM dengan optimasi Adam menunjukkan performa prediksi yang baik, terdapat sejumlah keterbatasan yang perlu diperhatikan. Model ini hanya bergantung pada data historis harga emas, sehingga belum mampu merepresentasikan pengaruh faktor eksternal seperti krisis ekonomi, kebijakan moneter, konflik geopolitik, maupun pandemi. Selain itu, pendekatan yang digunakan bersifat univariat, sehingga hanya memanfaatkan data harga emas harian tanpa melibatkan variabel fundamental lain seperti inflasi, suku bunga, nilai tukar, dan harga minyak yang diketahui berpengaruh terhadap pergerakan harga emas.

Lebih lanjut, model ini secara implisit mengasumsikan pola data bersifat relatif stasioner, padahal harga emas sering dipengaruhi oleh kejadian yang sulit diprediksi. Penelitian ini juga terbatas pada periode data 2000–2024, sehingga hasilnya belum tentu dapat digeneralisasikan pada kondisi pasar yang berbeda, terutama saat terjadi krisis global atau perubahan kebijakan ekonomi. Dengan demikian, meskipun hasil yang diperoleh cukup menjanjikan, keterbatasan teknis dan metodologis tersebut perlu menjadi pertimbangan dalam penerapan maupun pengembangan model di masa mendatang.

4. PENUTUP

Berdasarkan hasil penelitian, dapat disimpulkan bahwa penerapan model *Long Short-Term Memory* (LSTM) yang dioptimalkan dengan *Adaptive Moment Estimation* (Adam) terbukti efektif dalam memprediksi harga emas. Model ini mampu mencapai akurasi yang sangat tinggi dengan nilai MAPE sebesar 0.96% dan MSE sebesar 320,854,198, yang menunjukkan kemampuannya menangkap pola temporal dan fluktuasi harga emas secara konsisten. Hasil perbandingan dengan model lain menguatkan keunggulan LSTM-Adam. Dibandingkan dengan GRU, ARIMA, dan *Random Forest*, model LSTM memberikan nilai error paling rendah, sementara ARIMA dan *Random Forest* menunjukkan performa yang jauh lebih rendah akibat keterbatasan dalam menangani pola non-linearitas dan dependensi jangka panjang. Dengan demikian, kombinasi LSTM-Adam terbukti lebih unggul dalam mengatasi kompleksitas data deret waktu harga emas.

Prediksi untuk periode satu tahun ke depan juga menunjukkan tren peningkatan harga emas yang konsisten, sehingga hasil penelitian ini dapat memberikan wawasan berharga bagi investor dalam merumuskan strategi investasi. Secara keseluruhan, penelitian ini menegaskan bahwa penggunaan LSTM dengan optimasi Adam merupakan pendekatan yang akurat dan andal untuk peramalan harga emas, sekaligus memberikan dasar bagi pengembangan model prediksi harga komoditas lainnya.

DAFTAR PUSTAKA

- [1] S. H. Y. Tyas dan S. Z. Fajriyah, "Tinjauan Pustaka Sistematis: Perkembangan Metode Peramalan Harga Emas," *Journal of Informatics and Communications Technology*, vol. 4, no. 1, pp. 1–10, 2022.
- [2] D. R. Alghifari, M. Edi, dan L. Firmansyah, "Implementasi Bidirectional LSTM untuk Analisis Sentimen Terhadap Layanan Grab Indonesia". *Jurnal Manajemen Informatika*, vol. 12, no. 2, pp. 89–99, 2022.
- [3] K. K. Chandriah dan R. V. Naraganahalli, "RNN/LSTM with modified Adam optimizer in deep learning approach for automobile spare parts demand forecasting," *Springer Nature*, 2021.
- [4] J. Cahyani, S. Mujahidin, dan T. P. Fiqar, "Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional," *Jurnal Sistem dan Teknologi Informasi*, vol. 11, no. 2, pp. 346–357, 2023.
- [5] X. Kong, Z. Chen, W. Liu, K. Ning, L. Zhang, S. M. Marier, Y. Liu, Y. Chen, dan F. Xia, "Deep learning for time series forecasting: a survey," *International Journal of Machine Learning and Cybernetics*, vol. 16, no. 7–8, pp. 5079–5112, 2025.
- [6] R. N. Silalahi and M. Muljono, "Perbandingan Kinerja Metode Linear Regression, LSTM dan GRU Untuk Prediksi Harga Penutupan Saham Coca-Cola," *Komputika: Jurnal Sistem Komputer*, vol. 13, no. 2, pp. 201–211, 2024.
- [7] L. Wiranda and M. Sadikin, "Penerapan Long Short Term Memory Pada Data Time Series Untuk Memprediksi Penjualan Produk Pt. Metiska Farma," *Jurnal Nasional Pendidikan Teknik Informatika*, vol. 8, no. 3, pp. 184–196, 2019.
- [8] Z. Zhang, D. Wang, Y. Mei, J. Zhu, dan X. Xiao, "Developing an explainable deep learning module based on the LSTM framework for flood prediction," *Frontiers in Water*, vol. 7, 2025.
- [9] L. Skovajsová, "Long short-term memory description and its application in text processing," in *2017 Communication and Information Technologies*, Vysoké Tatry, Slovakia, Oct. 2017, pp. 1–4.
- [10] X. Song, Y. Liu, L. Xue, J. Wang, J. Zhang, J. Wang, L. Jiang, dan Z. Cheng, "Time-series well performance prediction based on Long Short-Term Memory (LSTM) neural network model," *Journal of Petroleum Science and Engineering*, vol. 186, 2020.
- [11] Y. A. Hakim, R. E. Saputra, dan A. S. R. Ansori, "Sistem Pendukung Keputusan Penyiraman Tanaman Cabai dengan Memanfaatkan Kecerdasan Buatan Menggunakan Algoritma LSTM," *e-Proceeding of Engineering*, vol. 7, no. 2, pp. 4959–4967, 2020.
- [12] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Computation*, MIT Press, 1997.
- [13] W. Sun, J. Dang, L. Zhang, Q. Wei, C. Li, Y. Liu, H. Jing, K. Huang, Y. Zhang, dan B. Li, "The effect of training data size on real-time respiration prediction using long short-term memory model," *Radiation Oncology*, vol. 20, art. 97, 2025.
- [14] Z. Chang, Y. Zhang, dan W. Chen, "Electric Price Prediction based on Hybrid Model of Adam Optimized LSTM Neural Network and Wavelet Transform," *International Journal of Energy Research*, 2019.
- [15] A. Wibowo, P. W. Wiryawan, and N. I. Nuqoyati, "Optimization of neural network for cancer microRNA biomarkers classification," *Journal of Physics: Conference Series*, vol. 1217, no. 1, pp. 012124, 2019.
- [16] H. Putra dan N. U. Walmi, "Penerapan prediksi produksi padi menggunakan artificial neural network algoritma backpropagation," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 6, no. 2, pp. 100–107, 2020.