

Prediksi Harga Komoditi Emas Menggunakan Metode *Long Short-Term Memory* Dengan Penambahan Optimalisasi

Wahyutama Fitri Hidayat^{1*}, Kartika Handayani², Yesni Malau³, Rachmat Adi Purnama⁴, Ahmad Setiadi⁵

^{1,2,3,4,5}Universitas Bina Sarana Informatika

e-mail: ¹wahyutama.wfh@bsi.ac.id, ²kartika.kth@bsi.ac.id, ³yesni.ymu@bsi.ac.id,
⁴rachmat.rap@bsi.ac.id, ⁵ahmad.ams@bsi.ac.id

Diterima	Direvisi	Disetujui
01-11-2024	11-11-2024	06-12-2024

Abstrak - Seiring dengan perkembangan teknologi, peluang muncul di setiap aspek kehidupan. Sektor ekonomi merupakan salah satu bidang yang terkena dampak kemajuan teknologi. Salah satu aspek ekonomi yang dipengaruhi secara positif oleh teknologi adalah komoditas emas. Di era saat ini, investor terlibat dalam perdagangan emas harian. Dengan memanfaatkan teknologi, pembelian atau penjualan komoditas emas dapat dihitung dengan cermat. Berdasarkan hal tersebut, model pembelajaran mesin dirancang menggunakan LSTM dan eksperimen dilakukan dengan penambahan pengoptimalan ADAM, NADAM, dan ADAMAX untuk menemukan nilai terbaik. Eksperimen mengungkapkan bahwa optimasi terbaik dicapai dengan menggunakan pemisahan data untuk pelatihan dan pengujian 80:20 dengan optimasi NADAM. Hasil penelitian menggunakan model LSTM dengan optimasi NADAM pada data pelatihan menghasilkan nilai RMSE 0,0199, nilai MSE 0,0003, dan Skor R2 0,9804. Sementara itu, dengan menggunakan data pengujian menghasilkan nilai RMSE sebesar 0,0260, nilai MSE sebesar 0,0003.

Kata Kunci: Emas, LSTM, ADAM, NADAM, ADAMAX

Abstract - As technology develops, opportunities emerge in every aspect of life. The economic sector is one of the areas affected by technological progress. One aspect of the economy that is positively influenced by technology is the gold commodity. In today's era, investors are involved in daily gold trading. By utilizing technology, purchases or sales of gold commodities can be calculated carefully. Based on this, a machine learning model was designed using LSTM and experiments were carried out with the addition of ADAM, NADAM, and ADAMAX optimizations to find the best value. Experiments reveal that the best optimization is achieved using a data split for training and testing of 80:20 with NADAM optimization. The results of research using the LSTM model with NADAM optimization on training data produced an RMSE value of 0.0199, an MSE value of 0.0003, and an R2 score of 0.9804. Meanwhile, using test data produces an RMSE value of 0.0260, an MSE value of 0.0003.

Keywords: Gold, LSTM, ADAM, NADAM, ADAMAX

PENDAHULUAN

Emas merupakan komoditas berharga dan penting di pasar karena dapat mendukung perkembangan keuangan baik bagi individu maupun pemerintah (Trivedi et al., 2022). Peran emas sangat krusial dalam perekonomian global karena sering digunakan sebagai alat tukar perdagangan dan sebagai standar anggaran berbagai negara (Ferdinandus et al., 2023).

Investor mengandalkan harga emas untuk memeriksa osilasi di pasar. Namun naik turunnya suku bunga emas tidak stabil menjadikannya lebih berisiko dan menimbulkan ketakutan bagi investor untuk berinvestasi di pasar emas (Tripurana et al., 2021). Oleh karena itu, memprediksi harga emas sangat penting di pasar keuangan karena nilai logam

dan kerentanan terhadap faktor ekonomi (K et al., 2024). Memprediksi harga emas berguna untuk mengidentifikasi pola, tren, dan hubungan antara berbagai faktor yang mempengaruhi harga emas, seperti indikator ekonomi, peristiwa geopolitik, dan dinamika penawaran serta permintaan (Dr. S. Sasikala, 2024).

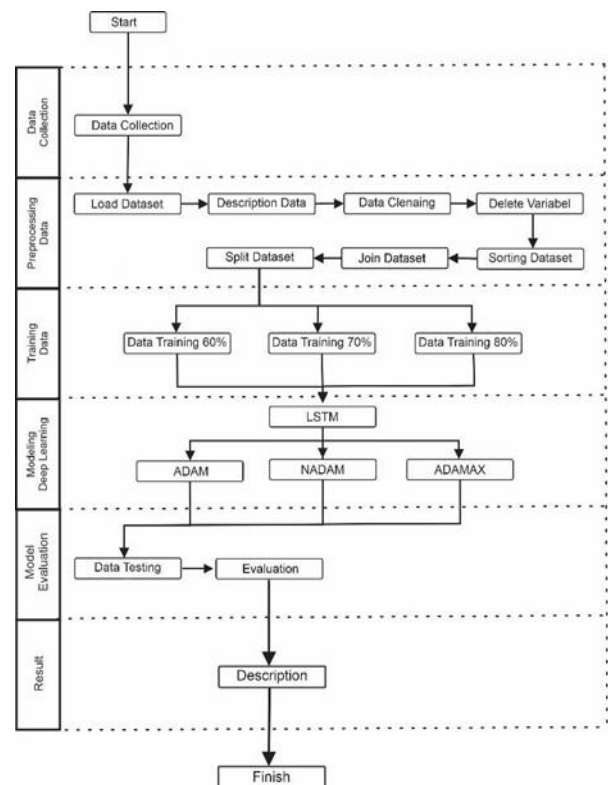
Pemanfaatan teknik pembelajaran mesin tingkat lanjut, seperti *Regresi Logistik*, *Random Forest*, *Decision Tree*, dan *Support Vector Machine* (SVM) telah digunakan pada penelitian sebelumnya untuk memprediksi harga emas (Singh, 2024). Pada penelitian lain menggunakan jaringan syaraf tiruan (JST) untuk memprediksi fluktuasi pasar saham emas, yang bertujuan untuk menghasilkan perkiraan yang tepat guna membantu pengguna dalam memaksimalkan keuntungan meskipun pasarnya

rumit (Salis et al., 2019). Selain itu, metode *Monte Carlo* telah digunakan untuk memprediksi harga emas selama setahun, membantu perusahaan dalam perencanaan strategis dan pengambilan keputusan (Jevtić et al., 2024). Pada penelitian lain Pendekatan *Machine Learning* berbasis ansambel menggabungkan *Decision Tree*, *SVM*, *Random Forest*, *Gradient Boosting* untuk memperkirakan harga emas secara akurat. Ini membantu para pedagang, investor, dan pembuat kebijakan dalam pengambilan keputusan untuk investasi emas (Mahajan et al., 2023).

Pada penelitian sebelumnya digunakan model mesin vektor pendukung (SVM) yang dioptimalkan dengan optimisasi kawanan partikel berbobot nonlinier (IPSO) untuk deret waktu. Model ini dilatih dengan data set pelatihan dan divalidasi menggunakan data set pengujian. Nilai indeks evaluasi model R^2 , MAE, MBE, dan MAPE menunjukkan bahwa algoritma ini dapat memprediksi harga saham emas dengan sangat baik, dan hasil prediksi dalam data set pengujian tidak menyimpang jauh dari data set pelatihan (Wang et al., 2024). Pada penelitian lain menggunakan jaringan syaraf tiruan dan algoritma genetika yang terdiri dari tiga langkah konstruksi model prediksi akan dilatih oleh database *World Gold Council* Hasilnya menunjukkan bahwa sistem yang diusulkan mencapai keputusan yang cepat dengan akurasi prediksi yang lebih tinggi dan tingkat nuansa antara nilai aktual dan prediksi harga saham emas berikutnya setelah 5 menit dalam jangka pendek, yang memakan waktu 18 ms untuk jangka waktu prediksi harga (El-Rashidy, 2021). Penelitian sebelumnya menggunakan model regressor Randomforest. Indeks statistik R-squared error kemudian digunakan untuk mendapatkan ketepatan. Berdasarkan hasil error R-squared, dibuat prediksi harga emas di masa depan. Di sini kami telah mengambil nomornya estimator untuk mendapatkan akurasi yang baik (Dasari Siva Sankar, 2013). Penelitian sebelumnya mengusulkan Tiga algoritma pembelajaran mesin, linier regresi, regresi hutan acak dan peningkatan gradien regresi. Dilakukan untuk memahami hubungan tersebut antara harga emas dan faktor-faktor tertentu yang mempengaruhi harganya, yaitu pasar saham, harga minyak mentah, kurs rupee dolar tingkat suku bunga, inflasi dan tingkat suku bunga. Disimpulkan bahwa mesin algoritma pembelajaran sangat berguna dalam analisis, tetapi karakteristik data mempengaruhi keakuratannya sehingga dibutuhkan penelitian lebih lanjut dengan teknik yang berbeda (Manjula & Karthikeyan, 2019). Penelittian paling mendekati yaitu penelitian (Hidayat et al., 2023) dengan menggunakan model LST dan optimasi ADAM serta melakukan optimasi menggunakan adam, dapat menemukan hasil terbaik yaitu dengan alokasi data 60% data training dan 40% data training. Selain itu juga dilakukan eksperimen perbandingan epoch dengan hasil terbaik 100 kali.

Berdasarkan penelitian sebelumnya yang telah dilakukan untuk memprediksi harga emas. Penulis mengusulkan menggunakan *Long Short-Term Memory (LSTM)* dengan penambahan perbandingan optimisasi ADAM, NADAM dan ADAMAX. LSTM adalah model pembelajaran mendalam yang kuat dengan struktur gerbang untuk meningkatkan memori jangka panjang, LSTM dipilih karena cara kerja lapisan tersembunyi dari model meneruskan status sel dan status tersembunyi, yang menyimpan informasi jangka pendek dan jangka panjang secara terpisah. Struktur baru ini mengurangi efek jeda waktu yang besar, sehingga secara signifikan meningkatkan stabilitas dan akurasi LSTM dibandingkan dengan RNN tradisional (Chen, 2024).

METODE PENELITIAN



Sumber: Penulis (2024)

Gambar 1. Alur Penelitian

1. Data Collections

Koleksi dataset menggunakan data primer mengenai harga emas dengan harga emas berjangka dalam satuan mata uang rupiah. Sumber dari dataset didapatkan dari laman <https://id.investing.com/commodities/gold-historical-data> dengan rincian data dimulai dari tanggal 1 Juli 2019 sampai dengan 31 Juli 2024 atau dalam kurun waktu 5 tahun.

2. Preprocessing Data

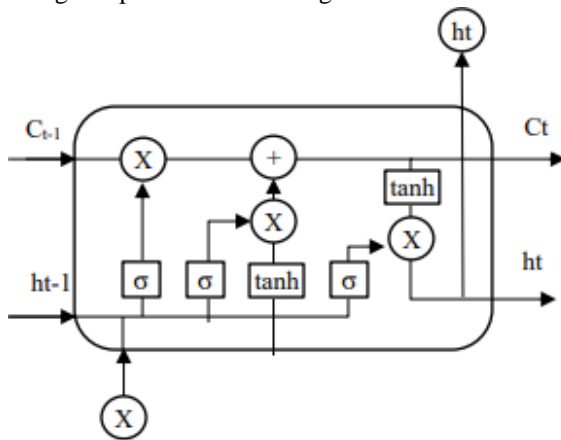
Preprocessing data bertujuan untuk menyesuaikan dataset sehingga dapat emningkatkan kualitas dataset yang digunakan sehingga dapat dilanjutkan pada tahapan berikutnya. Preprocessing data yang digunakan diantaranya adalah menghilangkan nilai kosong, merubah jenis data, menghilangkan variabel yang tidak digunakan, serta menggabungkan rata-rata nilai berdasarkan bulan dan tahun.

3. Training Data

Tahapan alokasi data yaitu bertujuan untuk membagi data menjadi dua bagian yaitu data training dan data testing. Pembagian data digunakan perbandingan 80:40, 70:30, dan 60:40 dari total data yang digunakan.

4. Modeling Machine Learning

Pemodelan machine learning digunakan model Long Short-Term Memory (LSTM). Pemodelan ini dipilih karena berdasarkan penelitian sebelumnya dapat menghasilkan prediksi paling baik terutama untuk jenis data time series. Penjelasan singkat mengenai proses LSTM sebagai berikut.



Sumber: Bastian Sianturi et al., (2023)

Gambar 2. Skema Long-Short Term Memory

Gambar.2. mengilustrasikan tiga bagian dari sel memori LSTM: gerbang input, gerbang lupakan, dan gerbang keluaran. Gerbang input (i_t) mengontrol aliran nilai baru ke dalam sel dan menyimpan beberapa informasi tentang nilai saat ini. Gerbang lupa (g_t) menentukan apakah nilai perlu dipertahankan atau dilupakan. Juga, gerbang keluaran (O_t) memilih informasi yang berguna dari keadaan sel saat ini. Output dari setiap sel yang ditransfer ke sel berikutnya adalah keadaan tersembunyi (h_t) dan keadaan sel (c_t)

U dan W adalah matriks berat dalam persamaan di bawah ini, b adalah istilah bias a , (σ) adalah fungsi

aktivasi sigmoid, dan simbol * mewakili perkalian. Persamaan berikut menyajikan arsitektur jaringan LSTM.

$$i_t = \sigma(U_i x_t + W_i h_{t-1} + b_i) \dots\dots\dots (1)$$

$$g_t = \sigma(U_g x_t + W_g h_{t-1} + b_f) \dots\dots\dots (2)$$

$$o_t = \sigma(U_o x_t + W_o h_{t-1} + b_o) \dots\dots\dots (3)$$

Persamaan (1), (2), (3) mewakili ekspresi gerbang input, lupakan, dan output, yang mengambil jumlah tertimbang dari keadaan tersembunyi pada waktu $t-1$ (h_{t-1}), and the input at time t (x_t) sebagai input fungsi aktivasi untuk menentukan output. Persamaan (4), (5), (6) adalah sebagai berikut untuk negara kandidat (c^t),

$$C_t = \tanh(U_c x_t + W_c h_{t-1} + b_c) \dots\dots\dots (4)$$

$$c_t = g_t * c_{t-1} + i_t * C_t \dots\dots\dots (5)$$

$$h_t = o_t * \tanh(c_t) \dots\dots\dots (6)$$

Selain model LSTM ditambahkan juga optimasi seleksi fitur bertujuan sebagai optimalisasi nilai prediksi yang terbaik. Optimasi seleksi fitur yang digunakan dalam penelitian ini terdiri dari tiga yaitu ADAM, NADAM, dan ADAMAX.

Adam merupakan algoritma dipergunakan sebagai optimalisasi laju pembelajaran dalam pelatihan jaringan saraf dalam yang bekerja secara dinamis dengan menyesuaikan laju pembelajaran untuk setiap parameter secara independen selama proses pelatihan (Nugroho & Hidayat, 2024). optimisasi ADAM dijelaskan sebagai dengan persamaan (7), (8), (9) berikut (Yi et al., 2020).

$$m_1 = \beta_1 m_{i-1} + (1 - \beta_1) \frac{\partial C}{\partial w} \dots\dots\dots (7)$$

Momentum kedua diperoleh dengan

$$v_i = \beta_2 v_{i-1} + (1 - \beta_2) \left(\frac{\partial C}{\partial w}\right)^2 \dots\dots\dots (8)$$

$$w_{i-1} = w_i - \eta \frac{m_i}{\sqrt{v_i + \epsilon}} \dots\dots\dots (9)$$

Where $m^i = m_i / (1 - \beta_1)$ and $v^i / (1 - \beta_2)$

Algoritma Nesterov-accelerated Adaptive Moment (NADAM) adalah perpaduan dari algoritma Adam dan Nesterovaccelerated Gagasan di balik jenis algoritma ini adalah untuk menambah dan mengurangi faktor peluruhan β dari waktu ke waktu (Mustapha et al., 2021). NADAM dapat ditulis sebagai persamaan (10), (11), (12).

$$g_t \leftarrow \nabla_{\theta_{t-1}} J_t(\theta_{t-1}) \dots\dots\dots (10)$$

$$m_t \leftarrow \beta_t m_{t-1} + \eta g_t \dots\dots\dots (11)$$

$$\theta_t \leftarrow \theta_{t-1} - (\beta_{t+1} m_t + \eta g_t) \dots\dots\dots (12)$$

Adamax merupakan rumus yang ditemukan oleh Jimmy Lei Ba dan Diederik Kingma. Optimasi ini merupakan perluasan dari optimasi penurunan

gradien yang banyak digunakan oleh astronomi (Shanmugavadivu et al., 2022). Persamaan Adamax dapat dituliskan sebagai berikut (Obayya et al., 2023).

$$w_t^i = w_{t-1}^i - \frac{\eta}{v_t + \epsilon} \cdot m_t^i \dots\dots\dots (13)$$

$$m_t^i = \frac{m_{t-1}^i}{1 - \beta_1^t} \dots\dots\dots (14)$$

$$v_t = \max(\beta_2 \cdot v_{t-1}, |G_t|) \dots\dots\dots (15)$$

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) G \dots\dots\dots (16)$$

$$G = \nabla_w C(w_t) \dots\dots\dots (17)$$

Berdasarkan persamaan (13), (14), (15), (16), (17) dapat dijelaskan dalam ekspresi, η menunjukkan tingkat pembelajaran, w_t mewakili berat pada langkah t , $C(.)$ menunjukkan fungsi biaya dan $\nabla_w C(w_t)$ menentukan gradien w_t variabel berat. β_i dieksploitasi untuk memilih data yang diperlukan untuk peningkatan lama, di mana $\beta_i \in [0,1]$. m_t dan v_t mewakili momen pertama dan kedua.

5. Model Evaluation

Model evaluasi digunakan untuk melakukan validasi terhadap model dan optimasi yang sudah dibuat pada tahap modelling machine learning. Selain itu bertujuan untuk membandingkan skema keseluruhan yang diusulkan [21]. Model evaluasi dilakukan berdasarkan alokasi data data training dengan hasil nilai terbaik. Evaluasi model digunakan dua acuan model yaitu nilai MSE dan nilai RMSE. Menunjukkan tingkat akurasi, besarnya nilai error yang digunakan adalah *Root Mean Square Error* (RMSE) dan *Mean Square Error* (MSE). Metrik RMSE dapat mengevaluasi seberapa baik model untuk prediksi, semakin kecil RMSE maka semakin baik pula kinerja model. Penjelasan evaluasi menggunakan RMSE dijelaskan dalam persamaan (18).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_t - f_t)^2}{n}} \dots\dots\dots(18)$$

Where:

- x_t : data aktual pada periode t
- f_t : Nilai perkiraan pada periode t
- n : jumlah data

Sementara itu, MSE merupakan salah satu metode yang digunakan sebagai evaluasi model prediktif berdasarkan kemungkinan kesalahan kecil yang dapat berdampak besar. Penjelasan evaluasi menggunakan MSE dijelaskan pada persamaan (19).

$$MSE = \frac{\sum_{t=1}^n (X_t - F_t)^2}{n} \dots\dots\dots(19)$$

Where:

- X_t : actual value in period t
- F_t : forecasting value in period t
- n : the amount of data

HASIL DAN PEMBAHASAN

Tahapan hasil dan pembahasan memaparkan hasil penelitian berdasarkan enam tahapan penelitian yaitu pengumpulan data, praproses data, alokasi data, desain LSTM dan optimasi, evaluasi RMSE dan MSE, serta hasil penelitian.

A. Data Collection

Dataset yang digunakan adalah data harga emas harian yang terdiri dari variabel tanggal, pembukaan, terakhir, tertinggi, terendah, volume, dan perubahan. Harga emas yang digunakan berdasarkan rentang waktu mulai dari 1 Juli 2019 sampai dengan 31 Juli 2024. Jumlah data yang digunakan sebanyak 1281 data.

Tabel 1. Koleksi Data

	Date	Close	Open	Max	Min	Vol	%
1	2019-07-01	1.3893	1.4018	1.4019	1.3847	176.27K	0.86
2	2019-07-02	1.4080	1.3862	1.4240	1.3862	172.97K	2.09
4	2019-07-03	1.4209	1.4247	1.4410	1.4147	26.11K	-0.11
5	2019-07-04	1.4001	1.4216	1.4268	1.3886	14.23K	1.17
6	2019-07-08	1.4000	1.4010	1.4099	1.3938	28.16K	-2.58
...
1277	2024-07-25	2.3766	2.4205	2.4238	2.3751	318.69K	-0.01
1278	2024-07-26	2.4045	2.3865	2.4133	2.3780	577.38K	-1.46
1279	2024-07-29	2.4018	2.4101	2.4253	2.3916	419.61K	0.92
1280	2024-07-30	2.4519	2.4290	2.4583	2.4215	383.25K	1.35
1281	2024-07-31	2.4730	2.4556	2.4966	2.4492	389.76K	-1.73

Sumber : id.investing.com

B. Preprocessing Data

Preprocessing data diawali dengan menambahkan dataset ke Google Colabs menggunakan python agar nantinya dataset tersebut dapat digunakan untuk pengolahan data selanjutnya. Langkah selanjutnya adalah melakukan pengecekan pada dataset apakah terdapat nilai yang kosong, jika terdapat nilai yang kosong maka data akan dihapus sehingga dapat dipastikan bahwa data yang digunakan sudah sesuai. Proses pengecekan data kosong ditunjukkan pada Gambar 3.

```
print('Null Value:',maindf.isnull().values.sum())
print('value NA:',maindf.isnull().values.any())

Null Value: 2
value NA: True
```

Sumber: Penulis (2024)

Gambar 3. Pengecekan Nilai Kosong

Pada penelitian ini ditemukan dua jenis data yang masih memiliki nilai kosong sehingga perlu dilakukan penghapusan data yang menyebabkan data tersebut berkurang menjadi 1279 data. Proses penghapusan data kosong ditunjukkan pada Gambar 4.

```
maindf=maindf.dropna()
print('Null Value:',maindf.isnull().values.sum())
print('Value NA:',maindf.isnull().values.any())
```

Null Value: 0
Value NA: False

Sumber: Penulis (2024)

Gambar 4. Pengecekan Nilai Kosong Setelah Penghapusan

Mengurutkan dataset berdasarkan tanggal paling awal. Hal ini bertujuan untuk mengatur data dalam urutan kronologis. Proses pengurutan data diilustrasikan pada Gambar 5.

```
maindf['Tanggal'] = pd.to_datetime(maindf['Tanggal'])
maindf.sort_values(by='Tanggal', ascending=True, inplace=True)
maindf.reset_index(drop=True, inplace=True)
```

Sumber: Penulis (2024)

Gambar 5. Pengurutan Berdasarkan Tanggal

Langkah selanjutnya adalah membuang dua variabel yang tidak digunakan dalam penelitian ini. Variabel yang tidak digunakan adalah volume dan perubahan. Proses pembuangan variabel ditunjukkan pada Gambar 6.

```
maindf.drop(['Vol', '%'], axis=1, inplace=True)
```

Sumber: Penulis (2024)

Gambar 6. Menghapus Variabel Volumen dan Persen

Selanjutnya, setelah disortir, model penggabungan dataset akan diterapkan. Di sini, "penggabungan" mengacu pada penggabungan data berdasarkan bulan dan tahun, yang menghasilkan nilai rata-rata untuk variabel pembukaan dan penutupan setiap bulan. Hasil pengelompokan ini ditunjukkan pada Gambar 7.

```
monthwise = y_2019.groupby(y_2019['Tanggal'].dt.strftime('%B'))[['Pembukaan', 'Terakhir']]
new_order = ['January', 'February', 'March', 'April', 'May', 'June', 'July', 'August',
             'September', 'October', 'November', 'December']
monthwise = monthwise.reindex(new_order, axis=0)
monthwise
```

Sumber: Penulis (2024)

Gambar 7. Menggabungkan Berdasarkan Bulan

Langkah terakhir adalah membagi data menjadi dua bagian: data pelatihan dan data pengujian.

C. Data Allocation

Alokasi data berdasarkan proses praproses menghasilkan pembagian data sebagai berikut, seperti yang ditunjukkan pada Tabel 2

Tabel 2. Alokasi Data

Training		Testing	
60%	768	40%	512
70%	896	30%	384

80%	1024	20%	256
-----	------	-----	-----

Sumber : Penulis (2024)

Berdasarkan Tabel I, alokasi data dengan rasio 60:40 menghasilkan 768 data latih dan 512 data uji. Dengan rasio 70:30 menghasilkan 896 data latih dan 384 data uji. Sementara itu, dengan rasio 80:20 menghasilkan 1.024 data latih dan 256 data uji.

D. LSTM Design

Pemodelan LSTM dilakukan menggunakan Keras dengan bahasa pemrograman Python dan *Google Colaboratory* sebagai alat bantu. Parameter yang digunakan adalah default, sedangkan variabel lainnya merupakan hasil dari beberapa percobaan. Setelah parameter diinisialisasi, langkah selanjutnya adalah memilih data yang akan digunakan untuk memprediksi harga penutupan komoditas emas. Selain itu, optimasi dilakukan menggunakan Adam, Nadam, dan Adamax. Berdasarkan pengukuran dengan ketiga optimasi tersebut, hasilnya ditunjukkan pada Tabel

Tabel 3. Hasil Pengukuran

Data Alokasi	Epoch	Optimization	RMSE	MSE	R2 Score
60:40	100	ADAM	0.0235	0.0005	0.9730
		NADAM	0.0256	0.0006	0.9679
		ADAMAX	0.0321	0.0010	0.9498
70:30	100	ADAM	0.2339	0.0005	0.9686
		NADAM	0.0242	0.0005	0.9678
		ADAMAX	0.0319	0.0010	0.9441
80:20	100	ADAM	0.0221	0.0004	0.9760
		NADAM	0.0199	0.0003	0.9804
		ADAMAX	0.3112	0.0009	0.9524

Sumber : Penulis (2024)

Berdasarkan Tabel III, ditemukan bahwa penggunaan alokasi data pelatihan 80% beserta optimasi NADAM menghasilkan hasil terbaik. Istilah "terbaik" mengacu pada menghasilkan nilai RMSE terkecil dibandingkan dengan eksperimen lain, yaitu 0,0199, yang secara langsung sesuai dengan nilai MSE sebesar 0,0003 dan Skor R² sebesar 0,9804.

E. Model Evaluation

Evaluasi model bertujuan untuk implementasi hasil pelatihan menggunakan data pengujian, hasil nilai RMSE sebesar 0,0260, nilai MSE sebesar 0,0003, dan Skor R² sebesar 0,9798, seperti yang ditunjukkan pada Tabel 4

Tabel 4. Hasil Pengukuran Terbaik

Data Alokasi	Epoch	Optimization	RMSE	MSE	R2 Score
80:20	100	NADAM	0.0260	0.0003	0.9798

Sumber : Penulis (2024)


Setelah memastikan bahwa hasilnya masih bagus dengan data pengujian, langkah selanjutnya adalah membuat titik-titik untuk memprediksi harga emas. Penelitian ini menggunakan harga penutupan atau harga terakhir setiap hari sebagai patokan, sehingga menghasilkan data yang ditunjukkan pada Gambar 8.



Sumber: Penulis (2024)

Gambar 8. Alur Harga Tutup


Setelah menentukan titik-titik yang akan digunakan untuk memprediksi harga penutupan emas, langkah selanjutnya adalah melakukan pengujian dan membandingkannya dengan harga yang diprediksi. Hasil pengujian menggunakan harga yang diprediksi diilustrasikan pada Gambar 9.



Sumber: Penulis (2024)

Gambar 9. Prediksi Harga

Berdasarkan Gambar 9, dapat dilihat bahwa harga yang diprediksi sangat sesuai dengan harga aktual. Misalnya, harga penutupan aktual pada tanggal 14 Maret 2024 adalah 2,1675, dibandingkan dengan harga yang diprediksi pada tanggal yang sama, yaitu 2,1590. Perbedaan antara kedua nilai ini tidak signifikan. Langkah selanjutnya adalah membuat prediksi harga untuk 30 hari ke depan, dimulai dari tanggal 1 Agustus 2024. Hasil prediksi diilustrasikan pada Gambar 10.



Sumber: Penulis (2024)

Gambar 10. Hasil Prediksi

KESIMPULAN

Kesimpulan dari penelitian ini adalah bahwa dengan menggunakan dataset harga emas historis dengan langkah-langkah praproses termasuk menangani nilai yang hilang, mengurutkan data berdasarkan tanggal sebelumnya, menghapus variabel yang tidak digunakan, dan mengelompokkan data ke dalam rata-rata bulanan dengan alokasi data, model diproses menggunakan LSTM dengan optimasi tambahan ADAM, NADAM, dan ADAMAX. Hasilnya menunjukkan bahwa optimasi NADAM dengan alokasi data 80:20 mencapai kinerja terbaik, dengan data pelatihan menghasilkan RMSE sebesar 0,0199, MSE sebesar 0,0003, dan Skor R² sebesar 0,9804. Untuk data pengujian, hasilnya adalah RMSE sebesar 0,0260, MSE sebesar 0,0003, dan Skor R² sebesar 0,9798. Ketika diimplementasikan untuk memprediksi harga, pola prediksi selaras erat dengan harga sebenarnya. Model yang dilatih kemudian digunakan untuk memprediksi harga emas untuk 30 hari ke depan. Program ini dapat langsung dimanfaatkan oleh para investor, khususnya di pasar komoditas emas, untuk mengambil keputusan secara tepat dalam melakukan transaksi harian, apakah akan membeli atau menjual.

REFERENSI

- Bastian Sianturi, T., Cholissodin, I., & Yudistira, N. (2023). Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 7(3), 1101–1107. <http://j-ptiik.ub.ac.id>
- Chen, N. (2024). Exploring the development and application of LSTM variants. *Applied and Computational Engineering*, 53(1), 103–107. <https://doi.org/10.54254/2755-2721/53/20241288>
- Dasari Siva Sankar, H. S. (2013). Gold Prices Prediction Using Random Forest. *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 11(V), 1–23.
- Dr. S. Sasikala, D. R. B. (2024). An Enhanced Study on Gold Price Prognosis using Machine Learning. *International Journal of Advanced Research in Science, Communication and Technology*, 2024, p. 1-7. <https://doi.org/https://doi.org/10.48175/ijarsct-18401>
- El-Rashidy, M. A. (2021). A novel system for fast and accurate decisions of gold-stock markets in the short-term prediction. *Neural Comput & Applic.* <https://doi.org/https://doi.org/10.1007/s00521-020-05019-x>

- Ferdinandus, Y. R. M., Kusriani, K., & Hidayat, T. (2023). Gold Price Prediction Using the ARIMA and LSTM Models. *Sinkron*, 8(3), 1255–1264. <https://doi.org/10.33395/sinkron.v8i3.12461>
- Hidayat, W. F., Julianto, M. F., Malau, Y., Setiadi, A., & Sriyadi. (2023). Implementation of LSTM and Adam Optimization as a Cryptocurrency Polygon Price Predictor. *2023 International Conference on Information Technology Research and Innovation, ICITRI 2023*, 123–127. <https://doi.org/10.1109/ICITRI59340.2023.10249571>
- Jevtić, A., Riznić, D., & Tomić, M. (2024). *Gold price prediction based on the Monte Carlo method*. XX(May), 201–209. <https://doi.org/10.5937/imcsm24020j>
- K, D. S., B, S., Y, R., Shreya, A., & Kavitha, D. (2024). Data Mining Strategies for Gold Price Prediction Using Multi-Factorial Influences. *International Journal For Multidisciplinary Research*, 6(3), 1–15. <https://doi.org/10.36948/ijfmr.2024.v06i03.18567>
- Mahajan, R., Patil, P., Chikmurge, D., & Barve, S. (2023). Forecasting Gold Price using Ensemble based Machine Learning Approach. *2023 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems (ICSES)*, 1–6. <https://doi.org/10.1109/ICSES60034.2023.10465360>
- Manjula, K. A., & Karthikeyan, P. (2019). Gold price prediction using ensemble based machine learning techniques. *Proceedings of the International Conference on Trends in Electronics and Informatics, ICOEI 2019, 2019-April(Icoei)*, 1360–1364.
- Mustapha, A., Mohamed, L., & Ali, K. (2021). Comparative study of optimization techniques in deep learning: Application in the ophthalmology field. *Journal of Physics: Conference Series*, 1743(1). <https://doi.org/10.1088/1742-6596/1743/1/012002>
- Nugroho, N. C. T., & Hidayat, E. Y. (2024). Implementation of Adam Optimizer using Recurrent Neural Network (RNN) Architecture for Diabetes Classification. *Jurnal Media Informatika Budidarma*, 8(1), 421–429. <https://doi.org/10.30865/mib.v8i1.7254>
- Obayya, M., Maashi, M. S., Nemri, N., Mohsen, H., Motwakel, A., Osman, A. E., Alneil, A. A., & Alsaid, M. I. (2023). Hyperparameter Optimizer with Deep Learning-Based Decision-Support Systems for Histopathological Breast Cancer Diagnosis. *Cancers*, 15(3). <https://doi.org/10.3390/cancers15030885>
- Salis, V. E., Kumari, A., & Singh, A. (2019). Prediction of Gold Stock Market Using Hybrid Approach. *Emerging Research in Electronics, Computer Science and Technology*. https://doi.org/10.1007/978-981-13-5802-9_70
- Shanmugavadivu, P., Mary Shanthi Rani M, Chitra P, Lakshmanan S, Nagaraja P, & Vignesh U. (2022). Bio-Optimization of Deep Learning Network Architectures. *Security and Communication Networks*, 2022(ii). <https://doi.org/10.1155/2022/3718340>
- Singh, N. (2024). Artificial Intelligence-Driven Model for Gold Price Prediction. *International Journal of Scientific Research in Engineering and Management*, 08(05), 1–5. <https://doi.org/10.55041/ijrsrem33199>
- Tripurana, N., Kar, B., Chakravarty, S., Paikaray, B. K., & Satpathy, S. (2021). Gold Price Prediction Using Machine Learning Techniques. *CEUR Workshop Proceedings*, 3283, 274–281. <https://doi.org/10.54097/gdm0kc53>
- Trivedi, U. B., Somvanshi, T. V. S., & J, S. P. (2022). Gold prices prediction: Comparative study of multiple forecasting models. *YMER Digital*, 21(07), 745–764. <https://doi.org/10.37896/ymer21.07/60>
- Wang, H., Dong, X., Qu, H., Liao, J., & Ma, D. (2024). Gold Stock Price Forecasting Based on Nonlinear Weighted Particle Swarm (IPSO) Optimised Support Vector Machine (SVM) Time Series. *Advances in Economics, Management and Political Sciences*, 85(1), 118–124. <https://doi.org/10.54254/2754-1169/85/20240857>
- Yi, D., Ahn, J., & Ji, S. (2020). An effective optimization method for machine learning based on ADAM. *Applied Sciences (Switzerland)*, 10(3). <https://doi.org/10.3390/app10031073>