



PREDIKSI HARGA EMAS MENGGUNAKAN ALGORITMA *LONG SHORT TERM MEMORY* (LSTM) & *GATED RECURRENT UNIT* (GRU)

Zana Vania Hendra^{1*}, Monica Alya Ramadhani², Indri Chintya³, Yuvi Rahmatullah⁴, Edi Ismanto⁵

^{1,2,3,4}Teknik Informatika, Fakultas Ilmu Komputer, Universitas Muhammadiyah Riau

⁵Pendidikan Informatika, Fakultas Keguruan Dan Ilmu Pendidikan, Universitas Muhammadiyah Riau

¹230401343@student.umri.ac.id, ²230401337@student.umri.ac.id, ³230401303@student.umri.ac.id,

⁴230401301@student.umri.ac.id, ⁵edi.ismanto@umri.ac.id

Abstract

Gold is an asset that has a hedge against inflation and global economic volatility, making it interesting to analyze as an investment instrument. This study aims to compare the performance of Long Short Term Memory (LSTM) and Gated Recurrent Unit (GRU) models in predicting gold prices using historical data from 2013 to 2022. The data used includes daily gold prices and goes through a preprocessing stage before being divided into training (80%) and testing (20%) data. LSTM and GRU models were trained with epoch and batch size variations, then evaluated using MAE, RMSE, MSE, and MAPE metrics. The results showed that the GRU model with 50 epochs performed best, with MAE 0.0145, RMSE 0.0186, MSE 0.0003, and MAPE 1.9209%, better than LSTM which produced higher errors. The residual graph also shows that GRU produces stable predictions with a random error distribution that is close to zero. These findings confirm that GRU is more accurate and efficient in modeling gold price time series, and has the potential to be implemented in artificial intelligence-based commodity price prediction systems.

Keywords: Gold Price Prediction, GRU, LSTM, Time Series, Model Evaluation

Abstrak

Emas merupakan aset yang memiliki nilai lindung terhadap inflasi dan volatilitas ekonomi global, sehingga menarik untuk dianalisis sebagai instrumen investasi. Penelitian ini bertujuan untuk membandingkan performa model Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) dalam memprediksi harga emas menggunakan data historis dari tahun 2013 hingga 2022. Data yang digunakan mencakup harga harian emas dan melalui tahap preprocessing sebelum dibagi menjadi data pelatihan (80%) dan pengujian (20%). Model LSTM dan GRU dilatih dengan variasi epoch dan batch size, lalu dievaluasi menggunakan metrik MAE, RMSE, MSE, dan MAPE. Hasil penelitian menunjukkan bahwa model GRU dengan 50 epoch memiliki performa terbaik, dengan MAE 0.0145, RMSE 0.0186, MSE 0.0003, dan MAPE 1.9209%, lebih baik dibandingkan LSTM yang menghasilkan error lebih tinggi. Grafik residual juga memperlihatkan bahwa GRU menghasilkan prediksi yang stabil dengan distribusi error yang acak dan mendekati nol. Temuan ini menegaskan bahwa GRU lebih akurat dan efisien dalam memodelkan deret waktu harga emas, serta memiliki potensi untuk diimplementasikan dalam sistem prediksi harga komoditas berbasis kecerdasan buatan.

Keywords: Prediksi Harga Emas, GRU, LSTM, Deret Waktu, Evaluasi Model

PENDAHULUAN

Emas memiliki peran penting dalam sektor keuangan karena berfungsi sebagai aset yang memberikan perlindungan nilai secara stabil, khususnya ketika terjadi ketidakstabilan dalam perekonomian (Dalimuthe et al., 2024). Sebagai logam mulia, emas menunjukkan performa yang unggul dan tetap stabil meskipun terjadi krisis ekonomi global, saat sektor keuangan lainnya


cenderung mengalami penurunan kinerja (Tholib et al., 2023). Pengambilan keputusan untuk berinvestasi dalam emas hendaknya didahului oleh analisis menyeluruh terhadap kondisi pasar, termasuk potensi imbal hasil dan risiko yang mungkin muncul. Prediksi terhadap fluktuasi harga emas di masa depan perlu mempertimbangkan berbagai aspek, seperti dinamika ekonomi global,

kebijakan moneter dari otoritas bank sentral, serta permintaan terhadap emas di pasar.

Oleh karena itu, para investor dan pelaku pasar diwajibkan untuk secara konsisten memantau perkembangan ekonomi global dan melakukan analisis yang mendalam sebelum mengambil keputusan investasi. Terdapat berbagai metode peramalan yang telah diteliti, diantaranya adalah metode *Long Short Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) (Bidang et al., 2023).

Algoritma *Long Short Term Memory* (LSTM) merupakan salah satu jenis algoritma yang diterapkan dalam bidang kecerdasan buatan (*Artificial Intelligence*) dan pembelajaran mesin (*Machine Learning*) (Marwondo & Hidayah, 2023). Metode ini merupakan bentuk pengembangan dari algoritma *Recurrent Neural Network* (RNN) yang memiliki kemampuan untuk mempertahankan dan memanfaatkan informasi dari waktu sebelumnya dalam proses pembelajaran (Fauzi et al., 2024). Selama beberapa tahun terakhir, algoritma *Long Short Term Memory* (LSTM) telah menjadi pilihan utama dalam berbagai aplikasi, termasuk dalam bidang pengenalan suara, pengolahan bahasa alami, dan prediksi deret waktu, karena kemampuannya yang unggul dalam menangani data berurutan. (Julian & Pribadi, 2021). Kelebihan utama dari LSTM terletak pada kemampuannya untuk mengatasi tantangan dalam mempelajari ketergantungan jangka panjang (*long-term dependencies*) dalam data berurutan (Bidang et al., 2023).

Gated Recurrent Unit (GRU) merupakan arsitektur jaringan saraf berulang yang dirancang secara cermat untuk menciptakan keseimbangan optimal antara efisiensi komputasi dan akurasi kinerja (Alkahfi & Chiuloto, 2021). Seperti halnya model berulang lainnya, GRU juga tersusun atas unit pemrosesan berulang, sebagaimana dapat diamati pada ilustrasi gambar 1.



Gambar 1 Perulangan Layer Pada GRU

Kelebihan utama dari GRU terletak pada struktur komputasinya yang lebih sederhana dibandingkan dengan LSTM, namun tetap mampu mempertahankan tingkat akurasi yang sebanding. Selain itu, GRU juga efektif dalam mengatasi permasalahan hilangnya gradien yang sering terjadi pada jaringan saraf berulang (RNN) konvensional (Sudiatmika et al., 2024). Pada penelitian terdahulu, penelitian pertama (Dalimuthe et al., 2024)

menggunakan model LSTM untuk menunjukkan performa yang baik dalam memprediksi harga emas dengan hasil MAPE sebesar 0,83% mengindikasikan tingkat akurasi yang sangat tinggi, dengan kesalahan prediksi kurang dari 1% dari nilai sebenarnya.

Penelitian (Lasijan et al., 2023) berhasil membangun model LSTM optimal dengan MAPE 2.71%, MAE 49.99, dan RMSE 52.59, mengkonfirmasi efektivitas LSTM untuk prediksi harga emas. Meskipun akurasinya lebih rendah dibandingkan studi Dalimuthe dkk. (2024) yang mencapai MAPE 0.83%, model dengan konfigurasi 70% data training, batch size 1, optimizer AdaGrad (LR=0.1, 500 epochs) ini tetap handal dalam menangkap pola time series.

Pada penelitian yang dilakukan oleh (Husaini et al., 2024) nilai MAPE yang diperoleh 0,5087 untuk memprediksi produksi kelapa sawit untuk tujuh bulan kedepan.

Metode yang diterapkan mencakup pengumpulan data historis harga emas, pra-pemrosesan data (normalisasi dan windowing), pelatihan model LSTM serta GRU, dan evaluasi dengan menggunakan metrik MAE, MAPE, dan RMSE. Hasil penelitian ini diharapkan mampu memberikan kontribusi dalam pengembangan strategi investasi yang lebih cerdas dan didasarkan pada data, serta memperluas literatur mengenai penerapan deep learning dalam analisis pasar komoditas.

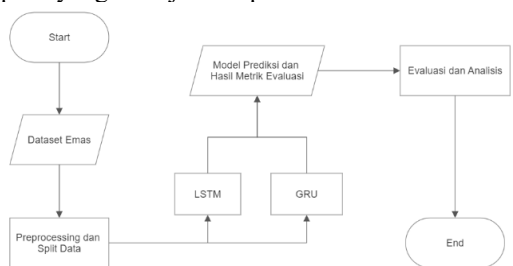
Meskipun penelitian terdahulu telah membuktikan bahwa LSTM dan GRU bekerja dengan baik dalam berbagai konteks, perubahan harga emas yang sangat tidak menentu sebagai akibat dari ketidakpastian ekonomi di seluruh dunia memerlukan pertimbangan yang lebih menyeluruh tentang arsitektur mana yang paling efisien dan akurat pada dataset terbaru. Salah satu masalah utama dalam penelitian ini adalah bagaimana menemukan konfigurasi terbaik untuk model LSTM dan GRU agar dapat menangkap pola time series harga emas yang kompleks dengan tingkat kesalahan yang minimal. Selain itu, terdapat kebutuhan untuk melakukan analisis tentang seberapa besar pengaruh perbedaan struktur komputasi antara LSTM yang kompleks dan GRU yang lebih sederhana pada stabilitas prediksi pada periode data pascapandemi.

Tujuan penelitian ini adalah untuk membandingkan kinerja kuantitatif algoritma LSTM dan GRU dalam memprediksi harga emas harian dengan menggunakan metrik evaluasi komprehensif seperti MAE, RMSE, MSE, dan MAPE. Penggunaan rentang data historis selama sepuluh tahun terakhir (2013–2022), yang mencakup periode volatilitas ekstrem, merupakan kebaruan (novelty) penelitian ini. Selain itu, untuk

mengevaluasi stabilitas distribusi error pada kedua model, penelitian ini menganalisis secara menyeluruh melalui visualisasi *plot residual*. Ini adalah elemen yang jarang dibahas secara menyeluruh dalam penelitian sebelumnya. Metode ini diharapkan akan memungkinkan penelitian untuk memberikan rekomendasi model yang tidak hanya akurat secara matematis tetapi juga konsisten dalam menghadapi perubahan yang terjadi di pasar komoditas.

METODOLOGI PENELITIAN

Untuk memastikan prediksi harga emas yang paling akurat, tahapan penelitian ini disusun secara sistematis. Penelitian ini dimulai dengan pengumpulan data berakhir dengan evaluasi model, seperti yang ditunjukkan pada **Gambar 2**.



Gambar 2 Diagram Alur (*Flowchart*) Penelitian

Penelitian ini merupakan penelitian kuantitatif dengan pendekatan eksperimental komparatif. Fokus utama penelitian adalah membandingkan kinerja dua algoritma *Deep Learning*, yaitu *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU), dalam memprediksi data deret waktu (*time series*) harga emas. Pendekatan metodologi yang digunakan mengikuti alur kerja sistematis mulai dari pengumpulan data, pra-pemrosesan (*preprocessing*), pembagian data (*data splitting*), pelatihan model (*training*), hingga evaluasi kinerja model (Tholib et al., 2023).

Model *Long Short Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) kemudian dilatih menggunakan data pelatihan dengan berbagai variasi hyperparameter. Selain itu, kinerja model dievaluasi menggunakan metrik evaluasi, yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Selanjutnya, dilakukan evaluasi dan analisis untuk menentukan model dengan kinerja terbaik dan paling akurat untuk memprediksi harga emas (Tholib et al., 2023)

1. Dataset



Gambar 3 Data Historis Harga Emas 2013-2022

Data yang digunakan adalah data sekunder historis harga emas harian dari periode 2 Januari 2013 hingga 30 Desember 2022. Pendekatan ini dipilih karena kemampuan LSTM dan GRU dalam menangkap pola non-linear dan ketergantungan jangka panjang (*long-term dependencies*) pada data fluktuatif, yang sering kali sulit ditangani oleh metode statistik konvensional. Dataset ini terdiri dari tujuh atribut utama, yaitu Tanggal (*Date*), Harga Penutupan (*Price*), Harga Pembukaan (*Open*), Harga Tertinggi (*High*), Harga Terendah (*Low*), Volume (*Vol.*), dan Persentase Perubahan (*Change%*).

Dalam penelitian ini, arsitektur model LSTM dan GRU dirancang dengan struktur *Sequential*. Lapisan Input (*Input Layer*) yang menerima data fitur harga emas (*Price*) yang telah melalui proses normalisasi dan *windowing* untuk membentuk urutan waktu (*sequence*) yang dapat diproses oleh algoritma.

1. Lapisan Tersembunyi (*Hidden Layers*)
Model LSTM menggunakan blok memori yang terdiri dari *input gate*, *forget gate*, dan *output gate* untuk mengatur aliran informasi dan mencegah masalah *vanishing gradient*. Model GRU menggunakan struktur yang lebih sederhana dengan *update gate* dan *reset gate* untuk menyeimbangkan efisiensi komputasi dan akurasi.
2. Lapisan Output (*Output Layer*)
Terdiri dari satu neuron *Dense* yang berfungsi untuk menghasilkan nilai prediksi harga emas (regresi) untuk satu langkah waktu ke depan (*one-step ahead prediction*).

Tabel 1 Sampel Data Set Emas

Date	Price	Open	High	Low
2013-01-02	1,689.90	1,675.80	1,695.00	1,672.10
2013-01-03	1,675.60	1,688.00	1,689.30	1,664.30
2013-01-04	1,649.90	1,664.40	1,664.40	1,630.00
2013-01-07	1,647.20	1,657.30	1,663.80	1,645.30
2013-01-08	1,663.20	1,651.50	1,662.60	1,648.80

Tabel di atas menyajikan sampel dari lima entri teratas dalam dataset harga emas. Data yang ditampilkan memuat informasi dari tanggal 2 Januari 2013 hingga 8 Januari 2013, dengan harga yang berfluktuasi sehari-hari. Kolom “Date” menunjukkan tanggal observasi data, “Open” mencerminkan harga pada saat pembukaan di tanggal tersebut, kolom “High” mencatat harga tertinggi pada tanggal yang sama, kolom “Low” menunjukkan harga terendah, kolom “Price” mempresentasikan harga emas pada tanggal tersebut. Atribut “Price” akan digunakan sebagai fitur untuk melatih model dalam penelitian ini, dan memprediksi harga emas di masa depan berdasarkan data historis.

2. Preprocessing dan Split Data

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


[ ] NumCols = df.columns.drop('Date')
df[NumCols] = df[NumCols].replace({' ',''}, regex=True)
df[NumCols] = df[NumCols].astype('float64')
```

Gambar 4 Preprocessing Data

Proses pembersihan data dilakukan dengan beberapa langkah penting untuk memastikan kualitas dan konsistensi data yang akan dianalisis. Pertama, kolom 'Date' dalam *DataFrame* diubah menjadi format waktu dengan menggunakan fungsi `pd.to_datetime()`, yang memungkinkan sistem untuk memahami dan memanipulasi data tanggal dengan lebih baik. Setelah itu, data diurutkan berdasarkan kolom 'Date' dengan urutan menaik menggunakan `sort_values()`, dan indeks direset agar lebih rapi dengan `reset_index()`, di mana parameter tertentu memastikan indeks lama dihapus dan perubahan diterapkan di tempat.

Selanjutnya, kolom-kolom numerik lainnya disiapkan dengan mengeluarkan kolom 'Date' dari

daftar kolom yang ada. Kemudian, fungsi `replace()` digunakan untuk menghapus karakter yang tidak diperlukan dalam kolom-kolom numerik tersebut, seperti spasi atau tanda baca, agar dapat diproses dengan benar. Akhirnya, kolom-kolom numerik diubah ke dalam tipe data *float64* menggunakan `astype()` untuk memastikan bahwa semua data numerik dapat diolah secara numerik dalam analisis selanjutnya. Dengan langkah-langkah ini, data menjadi bersih dan siap untuk analisis lebih lanjut.



Gambar 5 Pembagian Data Testing dan Training

Grafik ini menggambarkan pembagian data (split data) yang digunakan dalam penelitian ini. Data dibagi menjadi dua subset utama, yaitu *training set* dan *test set*, untuk memastikan model dapat dievaluasi dengan baik. *Training set* mencakup data harga emas dari tahun 2013 hingga 2021, yang digunakan untuk melatih model agar mempelajari pola historis. Sementara itu, *test set* hanya terdiri dari data tahun 2022, yang berfungsi untuk menguji performa model dalam memprediksi harga emas pada periode yang tidak termasuk dalam data pelatihan. Pembagian ini dilakukan untuk memvalidasi kemampuan generalisasi model, di mana model diharapkan dapat memberikan prediksi yang akurat pada data baru yang belum pernah dilihat sebelumnya. Dengan memisahkan data secara kronologis, penelitian ini juga menguji ketahanan model terhadap perubahan pasar yang terjadi di masa mendatang. Pendekatan ini sesuai dengan praktik standar dalam pemodelan time series, di mana menjaga urutan waktu sangat penting untuk menghindari kebocoran data (*data leakage*) dan memastikan evaluasi yang realistis.

a) Epoch

Jumlah *epoch* divariasikan untuk menemukan titik konvergensi optimal di mana model tidak mengalami *underfitting* maupun *overfitting*. Berdasarkan hasil eksperimen, model GRU mencapai kinerja terbaik pada 50 epoch, sedangkan LSTM membutuhkan 150 epoch untuk mencapai stabilitas prediksi. Perbedaan ini mengonfirmasi karakteristik GRU yang cenderung lebih cepat konvergen dan efisien secara komputasi dibandingkan LSTM.

b) Batch Size

Ukuran *batch* ditentukan untuk menyeimbangkan kecepatan pelatihan dan stabilitas gradien selama proses *backpropagation*.

c) Optimizer & Loss Function

Model dilatih dengan tujuan meminimalkan fungsi kerugian (*loss function*) yang diukur menggunakan *Mean Squared Error* (MSE), yang sensitif terhadap kesalahan besar, sehingga memaksa model untuk lebih presisi.

3. Training Model LSTM dan GRU

Selanjutnya, dilakukan pelatihan pada masing-masing model (LSTM dan GRU) menggunakan data pelatihan dengan beberapa variasi hyperparameter, yaitu ukuran *batch* dan jumlah *epoch*. Tujuan dari tahap ini adalah untuk menemukan metode pelatihan yang paling optimal dengan performa terbaik.

4. Pemodelan (Modeling)


Setelah proses pelatihan pada model selesai, langkah selanjutnya adalah melakukan prediksi menggunakan data pengujian. Data pengujian (aktual) kemudian dibandingkan dengan hasil prediksi, dan nilai error diukur menggunakan matrik evaluasi MAE, RMSE, dan MAPE. Dalam penelitian ini, kami juga menggunakan matrik MAPE untuk mengevaluasi akurasi prediksi, yang memberikan informasi tentang persentase kesalahan relatif terhadap nilai aktual

5. Evaluasi dan Analisis

Hasil evaluasi model berdasarkan matriks performa akan ditelaah secara detail dan divisualisasikan menggunakan grafik. Tujuan dari proses ini adalah untuk mengeksplorasi kombinasi terbaik antara ukuran *batch* dan jumlah *epoch* yang mampu menghasilkan prediksi mendekati nilai aktual. Selain itu, perhitungan akurasi model dilakukan untuk menilai efektivitas dari setiap konfigurasi yang diuji.


HASIL DAN PEMBAHASAN

Setelah dilakukan tahapan-tahapan seperti dalam metode penelitian, pada bagian ini akan dipaparkan hasil dari training model dan prediksi yang didapat.



Gambar 6 Grafik Visualisasi Kinerja Model


Grafik di atas menyajikan visualisasi kinerja model dalam memprediksi harga emas berdasarkan data historis dari tahun 2013 hingga awal 2023. Garis berwarna hitam menunjukkan data pelatihan (*training data*), yaitu data historis harga emas yang digunakan untuk melatih model. Setelah model dilatih, kinerjanya diuji pada data yang belum pernah dilihat sebelumnya, yang ditampilkan dengan garis biru sebagai data aktual (*actual test data*). Adapun hasil prediksi model terhadap data uji tersebut digambarkan dengan garis merah (*predicted test data*). Dari grafik ini terlihat bahwa garis merah mengikuti pola pergerakan garis biru dengan cukup baik, menunjukkan bahwa model mampu mengenali tren dan fluktuasi harga emas secara akurat. Meskipun terdapat sedikit perbedaan antara nilai aktual dan nilai prediksi di beberapa titik, secara umum model dapat menangkap dinamika harga dengan cukup presisi.



Gambar 7 Grafik Nilai Aktual dan Hasil Prediksi Model GRU

Grafik di atas memperlihatkan perbandingan antara nilai aktual dan hasil prediksi model GRU (*Gated Recurrent Unit*) dalam memprediksi harga emas. Garis berwarna biru dengan penanda lingkaran menunjukkan data aktual, sementara garis oranye dengan penanda silang menunjukkan hasil prediksi dari model GRU. Sumbu horizontal merepresentasikan dimensi waktu, sedangkan sumbu vertikal menunjukkan nilai harga yang telah dinormalisasi.

Dari grafik ini dapat diamati bahwa hasil prediksi GRU sangat mendekati nilai aktual, yang terlihat dari pola garis yang hampir berimpit di sepanjang waktu. Model GRU mampu mengikuti arah tren naik maupun turun dengan cukup presisi, bahkan pada titik-titik perubahan yang tajam.



Gambar 8 Grafik Selisih Nilai Aktual dan Hasil Prediksi GRU


Grafik di atas menunjukkan *plot residual*, yaitu selisih antara nilai aktual dan hasil prediksi model GRU terhadap harga emas (*Actual - Predicted*). Sumbu horizontal merepresentasikan waktu, sedangkan sumbu vertikal menunjukkan nilai error atau *residual*. Garis merah yang berfluktuasi menggambarkan distribusi *residual* terhadap waktu, sementara garis putus-putus horizontal berwarna hitam menandakan garis nol sebagai acuan tidak adanya error.

Dari grafik terlihat bahwa sebagian besar nilai residual berada sangat dekat dengan garis nol, yang berarti prediksi model GRU cukup akurat dan tidak menunjukkan penyimpangan sistematis. *Fluktuasi residual* tersebar secara acak di atas dan di bawah garis nol dengan rentang error yang relatif kecil, yakni sekitar -0.04 hingga 0.06. Penyebaran yang acak dan tidak berpola ini mengindikasikan bahwa model GRU tidak mengalami bias tertentu dan tidak gagal menangkap pola tertentu dari data.

Secara keseluruhan, grafik ini memperkuat kesimpulan bahwa model GRU bekerja secara efektif dan menghasilkan prediksi yang mendekati nilai aktual dengan tingkat kesalahan yang rendah dan konsisten.

Tabel 2 Hasil Evaluasi

N0	Batch Size	Epo chs	MAE	RMSE	MSE	MAPE
1	GRU	50	0.0145	0.0186	0,0003	1,9209 %
2	LSTM	150	0.0278	0.0356	0,0013	3,9508 %



Gambar 9 Visualisasi Hasil Perbandingan

Hasil analisis menunjukkan bahwa model GRU secara konsisten menghasilkan nilai error yang lebih rendah dibandingkan LSTM, yaitu MAE sebesar 0.0145 (dibandingkan dengan 0.0278 pada LSTM), MSE sebesar 0.0003 (vs. 0.0013), RMSE sebesar 0.0186 (vs. 0.0356), serta MAPE sebesar 1.9209% (vs. 3.9508%). Selain itu, GRU juga mencatat tingkat akurasi yang lebih tinggi, yakni 98.0791%, dibandingkan LSTM yang memperoleh akurasi 96.0492%. Berdasarkan hasil tersebut, dapat disimpulkan bahwa model GRU menunjukkan performa yang lebih unggul dalam konteks evaluasi ini.

SIMPULAN DAN SARAN

Penelitian ini telah berhasil mencapai tujuan utamanya, yaitu mengevaluasi dan membandingkan kinerja algoritma *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dalam memprediksi harga emas. Berdasarkan hasil pengujian menggunakan data historis periode 2013–2022, disimpulkan bahwa:

1. Model GRU terbukti lebih unggul dibandingkan LSTM dalam menangani karakteristik data deret waktu harga emas pada penelitian ini. GRU dengan konfigurasi 50 *epoch* mencatatkan tingkat kesalahan yang konsisten lebih rendah pada seluruh metrik evaluasi, dengan nilai MAPE 1,9209%, MAE 0,0145, dan RMSE 0,0186. Sebaliknya, LSTM membutuhkan 150 *epoch* untuk mencapai konvergensi namun tetap menghasilkan *error* yang lebih tinggi (MAPE 3,9508%).
2. Penelitian ini memberikan bukti empiris bahwa untuk dataset harga emas harian dengan volatilitas tinggi, arsitektur GRU yang lebih sederhana secara komputasi mampu memberikan akurasi prediksi yang lebih baik dan stabil dibandingkan arsitektur LSTM yang lebih kompleks. Kontribusi ini menegaskan potensi penggunaan GRU sebagai model yang efisien dalam sistem prediksi harga komoditas berbasis kecerdasan buatan.

Meskipun model yang dikembangkan menunjukkan performa yang baik, terdapat beberapa keterbatasan yang perlu diperhatikan dalam menginterpretasikan hasil penelitian ini. Keterbatasan utama terletak pada periode dan cakupan data, di mana penelitian hanya menggunakan data historis harga emas dari tahun 2013 hingga 2022, sehingga pola pergerakan harga di luar periode tersebut mungkin memiliki karakteristik berbeda yang belum terpelajari oleh model. Selain itu, model ini bersifat *univariate* karena prediksi hanya didasarkan pada satu variabel fitur, yaitu harga penutupan historis (*closing price*). Penelitian ini belum memperhitungkan variabel

eksternal fundamental yang secara nyata dapat memengaruhi fluktuasi harga emas, seperti tingkat inflasi, nilai tukar mata uang, suku bunga bank sentral, atau kondisi geopolitik global.

Berdasarkan hasil analisis dan keterbatasan yang telah dipaparkan, pengembangan penelitian selanjutnya dapat dilakukan dengan mengeksplorasi arsitektur model yang lebih mutakhir, seperti model *Hybrid* (misalnya kombinasi CNN-LSTM) atau model berbasis *Transformer*, untuk menguji apakah akurasi dapat ditingkatkan lebih jauh dibandingkan GRU. Selain itu, disarankan untuk menerapkan pendekatan *multivariate* dengan menambahkan indikator ekonomi makro, seperti harga minyak dunia atau tingkat inflasi Amerika Serikat, sebagai fitur input agar model dapat menangkap hubungan kausalitas yang lebih kompleks dan tidak hanya bergantung pada pola historis semata. Terakhir, pengujian implementasi model pada sistem data *real-time* atau data *streaming* juga perlu dilakukan untuk menguji ketahanan dan kecepatan respons model dalam memprediksi harga emas di kondisi pasar yang sesungguhnya.

TERIMA KASIH

Penulis mengucapkan terima kasih kepada Universitas Muhammadiyah Riau dan pihak terkait yang telah memberikan dukungan terhadap pelaksanaan penelitian ini, khususnya dalam penyediaan fasilitas, data, serta bantuan administratif dan teknis. Dukungan tersebut sangat berkontribusi terhadap kelancaran proses penelitian, pengolahan data, hingga penyusunan artikel ini, sehingga dapat diselesaikan dengan baik.

DAFTAR PUSTAKA

- Alkahfi, I., & Chiuloto, K. (2021). Penerapan Model Gated Recurrent Unit Pada Masa Pandemi Covid-19 Dalam Melakukan Prediksi Harga Emas Dengan Menggunakan Model Pengukuran Mean Square Error. *Prosiding SNASTIKOM: Seminar Nasional Teknologi Informasi & Komunikasi*, 225–232.
- Bidang, P., Sains, K., Informatika, P., Putro, S., Hermawan, A., & Avianto, D. (2023). Prediksi Harga Emas Menggunakan Algoritma Long Short-Term Memory (LSTM) dan Linear Regression (LR). *Jurnal Edik Informatika*, 9(2), 76–86. <http://dx.doi.org/10.22202/ei.2023.v9i2.6990>
- Dalimuthe, R. A., Adek, R. T., & Agusniar, C. (2024). Prediksi Harga Emas Menggunakan Algoritma Long Short-Term Memory (Lstm). *SENASTIKA Universitas Malikussaleh PREDIKSI*, 1–10.
- Fauzi, F., Aulia, S., Syaifullah, A. R., & Utami, T. W. (2024). Peramalan Harga Emas Menggunakan Pendekatan Long-Short Term Memory (LSTM). *Jurnal Edukasi Dan Penelitian Informatika (JEPIN)*, 10(2), 252. <https://doi.org/10.26418/jp.v10i2.78332>
- Husaini, F., Permana, I., Afdal, M., & Salisah, F. N. (2024). Penerapan Algoritma Long Short-Term Memory untuk Prediksi Produksi Kelapa Sawit. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(2), 366–374. <https://doi.org/10.57152/malcom.v4i2.1187>
- Julian, R., & Pribadi, M. R. (2021). Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM). *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 8(3), 1570–1580. <https://doi.org/10.35957/jatisi.v8i3.1159>
- Lasijan, T. G., Santoso, R., & Hakim, A. R. (2023). Prediksi Harga Emas Dunia Menggunakan Metode Long-Short Term Memory. *Jurnal Gaussian*, 12(2), 287–295. <https://doi.org/10.14710/j.gauss.12.2.287-295>
- Marwondo, M., & Hidayah, T. (2023). Perbandingan Algoritma Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) Untuk Prediksi Harga Emas Dunia. *In Search*, 21(2), 230–239. <https://doi.org/10.37278/insearch.v21i2.600>
- Sudiatmika, I. P. G. A., Putra, I. M. A. W., & Artana, W. W. (2024). The Implementation of Gated Recurrent Unit (GRU) for Gold Price Prediction Using Yahoo Finance Data: A Case Study and Analysis. *Brilliance: Research of Artificial Intelligence*, 4(1), 176–184. <https://doi.org/10.47709/brilliance.v4i1.3865>
- Tholib, A., Agusmawati, N. K., & Khoiriyah, F. (2023). Prediksi Harga Emas Menggunakan Metode Lstm Dan Gru. *Jurnal Informatika Dan Teknik Elektro Terapan*, 11(3), 620–627. <https://doi.org/10.23960/jitet.v11i3.3250>