

Jurnal Teknologi Informasi dan Multimedia

e-ISSN: 2684-9151
p-ISSN: 2715-2529

https://journal.sekawan-org.id/index.php/jtim

Aplikasi G-Trend Berbasis LSTM untuk Prediksi *Trend Continuation* dan Pengambilan Keputusan Investasi Emas

Alwi Syahri Arjuna[1*], **Ledy Elsera Astrianty**[1]

[1] Program Studi Informatika, Universitas Teknologi Yogyakarta, Indonesia
[*] Corresponding author: aalwisyahri@gmail.com

Sitasi: A. S. Arjuna, and L. E. Astrianty, "Aplikasi G-Trend Berbasis LSTM untuk Prediksi *Trend Continuation* dan Pengambilan Keputusan Investasi Emas," *Jurnal Teknologi Informasi dan Multimedia*, vol. 8, no. 4, pp. 1056–1072, 2026.

Diterima : 08-10-2026
Direvisi : 02-11-2026
Disetujui : 17-11-2026
Diterbitkan : 25-11-2026

Copyright: © 2026 oleh para penulis. Karya ini dilisensikan di bawah Creative Commons Attribution-Share Alike 4.0 International License.

Abstrak. Emas dikenal sebagai instrumen investasi pelindung nilai (*safe-haven*) dengan volatilitas harian yang tinggi, sehingga menyulitkan investor menentukan momentum transaksi tanpa alat proyeksi yang objektif. Penelitian ini mengembangkan G-Trend, sistem berbasis *web* yang memproyeksikan harga emas dalam Rupiah per gram dan menurunkan sinyal kelanjutan tren (*trend continuation*) pada horizon harian dan mingguan, dilengkapi chatbot interaktif. Sistem menggunakan model *Long Short-Term Memory* (LSTM) dua lapis dan *backend Flask* yang menarik data langsung dari API finansial tanpa basis data permanen. *Chatbot* berbasis API Gemini menjelaskan keluaran model kepada pengguna. Pada data uji, model harian memperoleh RMSE Rp 39.517, MAPE 1,26%, dan R^2 0,9904, sedangkan model mingguan memperoleh RMSE Rp 73.353, MAPE 2,51%, dan R^2 0,9636. Namun, galat tersebut setara dengan pembanding *naive* dan *drift*, sehingga penelitian ini tidak mengklaim keunggulan akurasi harga. Pada pengujian di luar sampel selama 22 hari perdagangan, akurasi arah sebesar 72,7%. Kontribusi penelitian ini terletak pada integrasi prediksi harian dan mingguan, sinyal kelanjutan tren, dan *chatbot* penjelas hasil dalam satu sistem *web* yang dapat digunakan sebagai alat bantu informasi bagi investor emas.

Kata kunci: Emas; *Long Short-Term Memory*; Prediksi multi-horizon; *Trend continuation*; *Chatbot*.

Abstract. Gold is widely regarded as a safe-haven investment with high daily volatility, making it difficult for investors to time transactions without objective projection tools. This study develops G-Trend, a web-based system that projects gold prices in Rupiah per gram and derives a trend continuation signal at daily and weekly horizons, complemented by an interactive chatbot. The system uses a two-layer Long Short-Term Memory (LSTM) model and a Flask backend that retrieves data directly from financial APIs without a permanent database. The chatbot, built on the Gemini API, explains the model outputs to users. On the test data, the daily model achieved an RMSE of Rp 39,517, a MAPE of 1.26%, and an R^2 of 0.9904, while the weekly model achieved an RMSE of Rp 73,353, a MAPE of 2.51%, and an R^2 of 0.9636. However, these errors are comparable to naive and drift baselines, so no price accuracy advantage is claimed. In an out-of-sample test over 22 trading days, directional accuracy was 72.7%. The contribution of this study lies in integrating daily and weekly predictions, trend continuation signals, and an explanatory chatbot into a single web system that can serve as an informational aid for gold investors.

Keywords: Gold; Long Short-Term Memory; Multi-horizon prediction; Trend Continuation; Chatbot.

1. Pendahuluan

Komoditas emas merupakan salah satu instrumen investasi utama yang berfungsi sebagai pelindung nilai aset di tengah fluktuasi ekonomi global yang tidak menentu[1]. Tingginya minat masyarakat terhadap investasi emas didorong oleh tingkat risikonya yang relatif rendah serta sifatnya yang cenderung stabil untuk simpanan jangka panjang[2]. Meskipun demikian, dinamika pergerakan harga emas secara riil dipengaruhi oleh berbagai faktor makroekonomi yang sangat kompleks, mulai dari volatilitas nilai tukar mata uang, tingkat inflasi, hingga kebijakan suku bunga bank sentral[3]. Harga emas dapat berfluktuasi tajam sehingga prediksi harga diperlukan investor untuk menentukan waktu yang tepat dalam membeli dan menjual emas[4]. Interaksi berbagai faktor eksternal tersebut memicu pergerakan harga harian yang memiliki tingkat volatilitas cukup tinggi, sehingga pengambilan keputusan investasi yang adaptif menjadi sangat krusial dalam mempersiapkan ketahanan finansial.

Permasalahan krusial yang sering dihadapi oleh investor akibat tingginya volatilitas tersebut adalah kesulitan dalam membedakan antara fase koreksi harga yang sifatnya sementara dengan pembalikan arah tren utama, serta mengidentifikasi apakah suatu tren pergerakan harga akan terus berlanjut[5]. Analisis pergerakan harga yang dilakukan oleh sebagian besar investor ritel saat ini masih didominasi oleh pendekatan teknikal yang bersifat visual, manual, dan statis. Pendekatan semacam ini sangat rentan terhadap bias psikologis pengguna dan membutuhkan waktu evaluasi yang lama. Ketiadaan alat proyeksi yang objektif dan adaptif menyebabkan pengambilan keputusan investasi sering kali bersifat spekulatif, sehingga pada akhirnya justru meningkatkan risiko kerugian finansial akibat keliru dalam mengantisipasi pergerakan arah tren di masa depan.

Untuk mengatasi tantangan analisis data runtun waktu komoditas tersebut, pemanfaatan model jaringan saraf tiruan berjenis *Long Short-Term Memory* (LSTM) telah terbukti secara empiris mampu mengekstrak ketergantungan fitur jangka panjang dengan tingkat kesalahan yang sangat minim[6]. LSTM memiliki gerbang memori internal yang dirancang untuk mengatasi masalah gradien menghilang (*vanishing gradient*) pada RNN[7] serta *memory cell* yang menyimpan informasi jangka panjang sehingga mampu mengatasi ketergantungan jangka panjang pada data runtun waktu. Metode konvensional seperti ARIMA dinilai terbatas dalam menyimpan informasi jangka panjang[4]. LSTM telah diterapkan pada prediksi harga emas dengan galat rendah, misalnya MAPE 1,08% pada LSTM dengan optimasi Adam[6] dan MAPE 0,83% pada aplikasi *web* berbasis LSTM[5] serta telah dimanfaatkan untuk prediksi harga emas sebagai instrumen investasi[3]. Seiring perkembangannya, beberapa penelitian terkini juga mengombinasikan ekstraksi fitur spasial dan temporal melalui kombinasi arsitektur CNN-LSTM guna mengenali pola volatilitas[8], membandingkan LSTM dengan Prophet[9], serta membandingkan LSTM dan GRU[10]. Di samping itu, algoritma turunan lainnya seperti *Gated Recurrent Unit* (GRU) juga mulai dieksplorasi secara luas untuk meningkatkan efisiensi komputasi dalam peramalan harga emas secara komputasional[11].

Penelitian[8] memusatkan target peramalan pada nilai harga emas tanpa secara spesifik mengklasifikasikan arah pergerakan tren itu sendiri. Penelitian[5] menampilkan proyeksi harga emas pada aplikasi *web*. Penelitian[4] menyajikan prediksi harga 30 hari pada sistem *real-time*, dengan akurasi prediksi arah perubahan harga harian sebesar 50,67%, relatif rendah dibandingkan R^2 pengujiannya sebesar 0,9725. Penelitian[11] memprediksi harga emas tujuh hari ke depan, sedangkan penelitian[2] memprediksi harga emas Antam. Selain itu, sepengetahuan penulis, penelitian-penelitian tersebut belum menyediakan fasilitas percakapan otomatis yang dapat menjembatani pemahaman pengguna awam terhadap hasil prediksi, padahal *chatbot* telah dimanfaatkan sebagai media penyampaian informasi yang interaktif kepada pengguna[12]. Dengan demikian, sepengetahuan penulis, kesenjangan yang tersisa terletak pada belum tersedianya penyajian

sinyal kelanjutan tren (*trend continuation*) pada horizon harian dan mingguan yang dilengkapi fasilitas percakapan otomatis untuk menjelaskan hasil prediksi.

Penelitian ini mengusulkan G-Trend, sistem prediksi harga emas dan sinyal kelanjutan tren berbasis *web*. Sistem dibangun dengan Python, yang pustakanya seperti `TensorFlow` dan Keras banyak dipilih untuk penerapan machine learning[13], serta framework Flask, yaitu *micro web framework* yang mempercepat pengembangan aplikasi karena menyediakan pustaka dan kode siap pakai[14]. Harga emas dunia dan kurs USD/IDR ditarik langsung melalui API tanpa basis data permanen, lalu dikonversi menjadi harga emas dalam Rupiah per gram. Penggunaan kurs mengacu pada pengaruh nilai tukar terhadap harga emas di Indonesia dan penelitian yang mengombinasikan kurs dolar AS dengan harga emas[11]. Berbeda dari penelitian-penelitian yang dikaji pada paragraf sebelumnya, kebaruan penelitian ini terletak pada penyajian sinyal kelanjutan tren (*trend continuation*), yaitu penanda apakah arah pergerakan harga yang sedang berlangsung diperkirakan berlanjut atau berbalik, sebagai keluaran sistem pada dua kerangka waktu, yaitu harian dan mingguan, serta integrasi *chatbot* berbasis API Gemini[15] untuk menjelaskan hasil prediksi kepada pengguna. Oleh karena itu, penelitian ini bertujuan merancang dan mengevaluasi arsitektur LSTM guna memprediksi harga emas dan menurunkan sinyal kelanjutan tren pada horizon harian dan mingguan, serta mengimplementasikannya bersama *chatbot* ke dalam antarmuka *web* G-Trend menggunakan data terkini dari API.

2. Bahan dan Metode

Pendekatan eksperimental digunakan dalam penelitian ini untuk memprediksi pola pergerakan dan kelanjutan tren (*trend continuation*) harga emas secara multi-horizon, serta merancang fitur *chatbot* interaktif pendukung pada sistem G-Trend. Proses penelitian disusun secara sistematis melalui berbagai tahap terintegrasi untuk memastikan model komputasi memiliki tingkat akurasi yang optimal. Secara visual, seluruh tahapan dan proses sistematis dalam penelitian ini ditunjukkan pada Gambar 1.

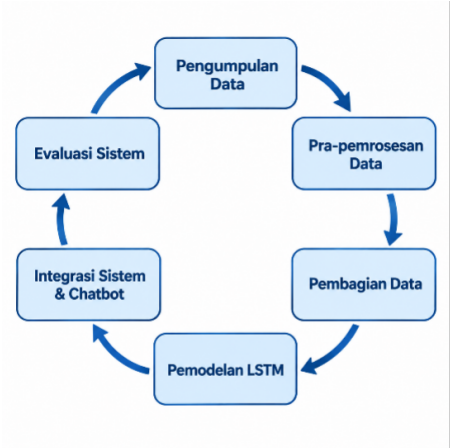

Gambar 1. Alur Penelitian.

Untuk mengubah data historis mentah menjadi informasi proyeksi harga dan arah tren yang terukur, penelitian ini dirancang secara sistematis dalam beberapa tahapan utama yang saling berkesinambungan. Proses dimulai dengan Pengumpulan Data melalui penarikan *Application Programming Interface* (API), dilanjutkan dengan Pra-pemrosesan Data (*Preprocessing*) untuk membersihkan distorsi, Pembagian Data (*Data Splitting*), Pelatihan Model menggunakan *Long Short-Term Memory* (LSTM), Integrasi Sistem Web, dan diakhiri dengan Evaluasi Model.

2.1. Pengumpulan Data

Tahap pertama dalam penelitian ini adalah mengumpulkan data deret waktu historis pasar keuangan global secara dinamis melalui penarikan data berbasis *Application Programming Interface* (API) menggunakan pustaka `yfinance`. Rentang waktu pengumpulan data historis mencakup periode panjang dari Januari 2015 hingga periode pengujian di tahun 2026. Kemudian harga emas dunia dikonversi menjadi harga emas dalam Rupiah per gram (Gold_IDR) dengan mengalikan kurs USD/IDR dan membagi 31,1035 gram per troy ounce. Penggunaan kurs sebagai variabel pendamping didasarkan pada pengaruh nilai tukar terhadap harga emas di Indonesia serta penelitian yang mengombinasikan kurs dolar AS dengan harga emas[11]. Berdasarkan hasil ekstraksi data, dataset mentah memiliki beberapa atribut kolom utama yang merepresentasikan kondisi pasar harian. Cuplikan sampel dari data historis yang berhasil dikumpulkan dan digunakan dalam sistem G-Trend dapat dilihat pada Tabel 1.

Tabel 1. Sampel Pengumpulan Data

Date	Gold_Close	Gold_High	Gold_Low	Gold_Volume	USDIDR	Gold_IDR
2026-10-02	4,162.2998	4,259.0000	4,153.7998	169001	17,922.8008	2,398,446.1617
2026-10-05	4,156.7998	4,198.8999	4,150.3999	112195	17,909.0000	2,393,432.4980
2026-10-06	4,187.1001	4,212.3999	4,130.7002	112195	17,887.9004	2,408,038.6282

Berdasarkan Tabel 1, atribut Date menunjukkan indeks waktu perdagangan harian. Kolom Gold_Close, Gold_High, dan Gold_Low masing-masing menyatakan harga penutupan, harga tertinggi, dan harga terendah kontrak berjangka emas dunia dalam satuan dolar AS per troy ounce, sementara Gold_Volume merekam volume transaksi harian di bursa global. Selanjutnya, atribut USDIDR mencatat pergerakan nilai tukar harian mata uang Rupiah terhadap Dolar AS. Seluruh variabel eksternal tersebut dikomputasi secara matematis untuk menghasilkan variabel target utama pada kolom Gold_IDR, yang menyatakan estimasi harga fisik emas dalam satuan Rupiah per gram yang menjadi fokus acuan prediksi sistem G-Trend. Dataset gabungan yang berhasil dikumpulkan mencakup periode Januari 2015 hingga Oktober 2026 dengan tujuh kolom atribut.

2.2. Pra-pemrosesan Data

Tahap pra-pemrosesan data adalah langkah esensial yang bertujuan untuk mengubah data runtun waktu yang belum diproses menjadi representasi bersih yang siap untuk diolah oleh algoritma pembelajaran mesin. Harga emas merupakan data deret waktu karena diamati secara berurutan dalam interval waktu tertentu[16]. Alur pra-pemrosesan ini dilakukan melalui lima tahapan utama yang saling berkaitan, di mana rincian pergeseran dimensi serta penyusutan jumlah baris data pada setiap tahapnya disajikan pada Tabel 2.

Tabel 2. Jumlah data sebelum dan sesudah setiap tahap pra-pemrosesan

Tahap	Sebelum	Sesudah
Konversi Gold_IDR	2.956 baris	2.956 baris
Rekayasa Fitur	2.956 × 6 kolom	2.907 × 20 kolom
Seleksi Fitur	2.907 baris × 20 kolom	2.907 baris × 11 kolom
Penskalaan (*Scaling*)	2.907 baris × 11 kolom	2.907 baris × 11 kolom
Pembentukan Sekuens	2.907 baris	2.847 baris

Proses diawali dengan penyelarasan indeks tanggal antara harga bursa emas dan kurs USD/IDR. Nilai kurs yang kosong pada hari libur bursa diisi menggunakan nilai observasi terakhir (*forward fill*). Harga penutupan emas mentah (Gold_Close) kemudian dikonversi menjadi variabel nominal Rupiah per gram (Gold_IDR) dengan cara mengalikannya terhadap kurs USD/IDR, lalu dibagi dengan rasio konversi 31,1035 gram per troy ounce.

Mengingat karakteristik data keuangan global sangat rentan terhadap divergensi akibat sifatnya yang non-stasioner, model tidak dilatih pada harga mentah. Variabel harga Gold_IDR ditransformasikan menjadi imbal hasil logaritma harian (*daily log return*) menggunakan Persamaan (1)

$$R_t = \ln\left(\frac{P_t}{P_{t-1}}\right) \tag{1}$$

di mana R_t adalah imbal hasil logaritma pada waktu ke-t, P_t adalah harga penutupan emas pada hari ini, dan P_{t-1} adalah harga penutupan pada hari sebelumnya. Transformasi ini bertujuan untuk menstabilkan varians data agar lebih mudah dipelajari oleh jaringan saraf tiruan. Selain variabel target tersebut, dilakukan rekayasa fitur (*feature engineering*) dengan mengekstraksi 14 fitur turunan dari data mentah meliputi indikator SMA, EMA, RSI 14 hari, *Bollinger Bands*, dan momentum. Baris observasi awal yang mengandung nilai kosong (NaN) akibat komputasi indikator teknikal ini selanjutnya dihapus dari dataset.

Setelah fitur diekstraksi, dilakukan tahap seleksi fitur (*feature selection*) menggunakan korelasi Spearman. Fitur prediktor yang memiliki nilai mutlak korelasi terhadap *log return* di bawah 0,05 dieliminasi, sehingga menyisakan 11 fitur utama yang paling relevan. Ke-11 fitur tersebut dilakukan penskalaan data (*scaling*) menggunakan metode *RobustScaler*. Metode ini diimplementasikan secara khusus untuk mereduksi efek distorsi dari lonjakan harga ekstrem (*outliers*) akibat sentimen pasar global yang tiba-tiba, tanpa merusak sinyal volatilitas intrinsik dari pergerakan harga emas murni, dengan Persamaan (2)

$$x' = \frac{x - \texttt{median}(x)}{IQR(x)} \tag{2}$$

dengan IQR merupakan selisih antara kuartil ketiga dan kuartil pertama. Guna mencegah kebocoran informasi masa depan (*data leakage*), nilai median dan IQR dihitung secara eksklusif hanya dari himpunan data pelatihan, yang selanjutnya diimplementasikan untuk menskalakan data validasi dan data pengujian.

Data yang telah dilakukan normalisasi dan diskalakan tersebut dibentuk kembali menjadi matriks tiga dimensi menggunakan teknik *sliding window* dengan ukuran rentang 60 hari perdagangan sebagai masukan (*input*) dan *log return* satu hari berikutnya sebagai target. Mengingat 60 hari pertama diakumulasikan murni sebagai parameter masukan awal, total himpunan data yang sebelumnya berjumlah 2.907 baris menyusut menjadi 2.847 sekuens data.

2.3. Pembagian Data

Setelah fitur diekstraksi dan menghasilkan matriks angka, dataset dibagi menjadi beberapa subset yang terpisah, yaitu data latih (*training set*), data validasi, dan data uji (*testing set*). Pembagian data merupakan langkah krusial untuk menilai kemampuan generalisasi model pada data baru yang belum pernah dikenali sebelumnya, sehingga hasil evaluasi yang diperoleh dapat mencerminkan kinerja model secara objektif.

Guna mencegah terjadinya kebocoran informasi masa depan ke masa lalu (*data leakage*), pembagian data tidak dilakukan secara acak, melainkan dikonfigurasi secara ketat berdasarkan urutan kronologis waktu. Proporsi data dialokasikan dengan rasio pembagian sekitar 70% untuk data pelatihan, 15% untuk data validasi, dan 15% untuk data pengujian. Pemilihan rasio ini didasarkan pada praktik terbaik dalam pemodelan pembelajaran mesin, di mana porsi 70% dipastikan cukup memadai bagi model untuk mengidentifikasi pola fluktuasi jangka panjang, sementara porsi 15% masing-masing cukup representatif untuk proses penyetelan *hyperparameter* secara objektif dan evaluasi akhir yang independen. Distribusi spesifik tersebut dirangkum pada Tabel 3

Tabel 3. Pembagian Data

Kategori Data	Jumlah Data
Data Pelatihan (*Training*)	1992
Data Validasi (*Validation*)	427
Data Pengujian (*Testing*)	428

Berdasarkan Tabel 3, proporsi terbesar dialokasikan untuk data pelatihan guna memastikan model dapat mengenali pola fluktuasi historis harga emas dalam jangka panjang, sementara rentang waktu terbaru dialokasikan murni sebagai data pengujian independen. Jumlah data setiap subset dihitung dengan pembulatan ke bawah, yaitu 1.992 sekuens pelatihan ($70\% \times 2.847 = 1.992,9$) dan 427 sekuens validasi ($15\% \times 2.847 = 427,05$). Sisanya, 428 sekuens, dialokasikan ke data pengujian agar tidak ada sampel yang terbuang. Karena itu jumlah data validasi dan pengujian berbeda satu sekuens (15,00% dan 15,03%).

2.4. Pemodelan LSTM

Algoritma *Long Short-Term Memory* (LSTM) merupakan metode *Deep Learning* yang dipilih karena rancangan gerbang memori internalnya terbukti efektif mengatasi masalah gradien menghilang (*vanishing gradient*), sehingga sistem mampu mempelajari pola fluktuatif data keuangan berdimensi tinggi dalam jangka panjang[1]. Arsitektur model pada penelitian ini dikonstruksikan secara berlapis. LSTM memproses informasi melalui tiga gerbang, yaitu *forget gate*, *input gate*, dan *output gate*[16]. *Forget gate* menentukan informasi yang dipertahankan atau dihapus dari *cell state*, *input gate* menambahkan informasi baru, dan *output gate* menentukan informasi yang dikeluarkan sebagai *hidden state*[1]. Pada langkah waktu t, perhitungan dilakukan sebagai berikut

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{3}$$
$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{4}$$
$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \tag{5}$$
$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{c}_t \tag{6}$$
$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{7}$$
$$h_t = o_t \odot \tanh(C_t) \tag{8}$$

dengan σ adalah fungsi sigmoid, W dan b masing-masing adalah bobot dan bias tiap gerbang, x_t adalah masukan, h_t adalah *hidden state*, C_t adalah cell state, dan $\odot$ adalah perkalian elemen demi elemen.

Arsitektur model dirancang berlapis (*stacked*) dan disederhanakan untuk mengurangi risiko underfitting sambil menjaga sensitivitas terhadap perubahan momentum harga. Konfigurasi lengkap ditunjukkan pada Tabel 4. Model terdiri atas dua lapisan LSTM (64 dan 32 unit) yang masing-masing diikuti *Dropout*, satu lapisan dense dengan aktivasi ReLU, dan satu neuron keluaran yang menghasilkan *log return* satu hari perdagangan ke depan. Lapisan *Dropout* ditempatkan setelah lapisan LSTM guna mengurangi risiko *overfitting* dengan menonaktifkan sejumlah unit secara acak selama pelatihan[7], seperti pada penelitian harga emas harian dalam Rupiah yang menempatkan *Dropout* setelah setiap lapisan LSTM[17]. Hiperparameter ditetapkan dengan memperhatikan bahwa kinerja LSTM bergantung pada penyetelan parameter yang tepat[9] dan konfigurasi yang dilaporkan pada penelitian terdahulu[16]. Pelatihan dibatasi maksimal 80 *epoch* dengan *Early Stopping* dan *ReduceLROnPlateau* yang memantau *loss* validasi, sedangkan pengacakan data dinonaktifkan untuk menjaga urutan waktu.

Tabel 4. Konfigurasi Arsitektur LSTM

Komponen	Konfigurasi
Lapisan LSTM 1	64 unit, *return_sequences* = *True*
Dropout 1	0,1
Lapisan LSTM 2	32 unit, *return_sequences* = *False*
Dropout 2	0,1
Lapisan *dense*	16 neuron, aktivasi ReLU
Lapisan keluaran	1 neuron (*log return* hari berikutnya)
Optimizer	Adam, *learning rate* 0,001, *clipnorm* 1,0
Loss / metrik	MSE / MAE
Epoch maks. / *batch size*	80 / 32 (tanpa *shuffle*)
Early Stopping	Pantau *val_loss*, *patience* 12, *min_delta* 10^{-5}, bobot terbaik dipulihkan
ReduceLROnPlateau	Pantau *val_loss*, *factor* 0,5, *patience* 5, *min_lr* 10^{-6}

Keluaran model berupa *log return* diubah kembali menjadi harga fisik dalam Rupiah per gram menggunakan Persamaan (9)

$$\widehat{P_{t+1}} = P_t \cdot \exp(\widehat{r_{t+1}}) \tag{9}$$

Proses pelatihan dipantau melalui kurva pembelajaran (*learning curves*) berdasarkan *Mean Squared Error* (MSE) sebagai fungsi loss dan *Mean Absolute Error* (MAE). Keduanya dihitung menggunakan Persamaan (10) dan Persamaan (11)

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(y_i - \widehat{y}_i)^2 \tag{10}$$

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - \widehat{y}_i|^2 \tag{11}$$

Kinerja model pada data validasi dan pengujian diukur menggunakan *Root Mean Squared Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi (R^2) [1, 16]. Metrik dihitung pada skala harga fisik (Rupiah per gram) setelah rekonstruksi, dengan Persamaan (12), Persamaan (13), dan Persamaan (14)

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \widehat{y}_i)^2} \tag{12}$$

$$MAPE = \frac{100\%}{n}\sum_{i=1}^{n}\left\|\frac{y_i - \widehat{y}_i}{\widehat{y}_i}\right\| \tag{13}$$

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \widehat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y}_i)^2} \tag{14}$$

dengan n adalah jumlah data, y_i adalah nilai aktual, $\hat{y}_i$ adalah nilai prediksi, dan $\hat{y}$ adalah rata-rata nilai aktual. RMSE yang semakin kecil dan MAPE yang semakin rendah menunjukkan prediksi yang semakin akurat, sedangkan R^2 yang mendekati 1 menunjukkan variasi data aktual yang semakin baik dijelaskan oleh model.

2.5. Integrasi Sistem

Model yang telah dilatih dan *scaler* dimuat ke memori server saat aplikasi dijalankan. *Backend Flask* bertindak sebagai pengendali utama yang menerima permintaan dari Nginx pada *Virtual Private Server* (VPS), menarik data GC=F dan IDR=X periode tiga bulan berfrekuensi harian melalui `yfinance`, melakukan pra-pemrosesan dengan *scaler* yang sama, menjalankan inferensi model,

menentukan sinyal tren, dan menyajikan grafik serta teks pada antarmuka[14]. Perancangan alur interaksi sistem mengacu pada pendekatan perancangan sistem informasi berbasis *web* melalui diagram aktivitas dan diagram sekuen.

Fungsionalitas prediksi pada sistem akhir G-Trend dirancang menggunakan arsitektur pipa data langsung (*direct API consumption*) tanpa menggunakan basis data permanen, guna memastikan bahwa seluruh kalkulasi proyeksi selalu berakar pada data pasar penutupan teraktual. Sistem ini mendukung dua luaran utama (*multi-horizon*):

1. Prediksi Harian: Model *single-step forecasting* untuk memproyeksikan probabilitas pergerakan satu hari perdagangan ke depan.
2. Prediksi Mingguan: Fitur *multi-step forecasting* untuk mengeksekusi iterasi proyeksi kelanjutan arah tren dalam rentang lima hari perdagangan ke depan.

Guna menjembatani interaksi pengguna awam dengan hasil analitika statistik tersebut, antarmuka *web* dilengkapi dengan fitur asisten virtual yang dinamakan "G-Trend Assistant". Fitur *chatbot* ini dikembangkan berdasarkan tombol pertanyaan cepat maupun mengetik pertanyaan sendiri. *Chatbot* memanfaatkan API Gemini dengan versi model gemini-3.8-flash yang memungkinkan pengembang membangun aplikasi *chatbot* dengan LLM Gemini melalui kunci API[15] untuk memahami pertanyaan pengguna dan menyusun jawaban. *Chatbot* dimanfaatkan sebagai media penyampaian informasi yang interaktif kepada pengguna. *Chatbot* hanya menjelaskan hasil model dan tidak mengubah keluaran prediksi.

2.6. Evaluasi Sistem

Evaluasi sistem dilakukan terhadap aplikasi G-Trend yang telah terintegrasi untuk memastikan seluruh komponen berjalan sesuai rancangan. Evaluasi mencakup empat hal. Pertama, kelengkapan alur fungsi, yaitu penarikan data GC=F dan IDR=X, pra-pemrosesan, inferensi model, penentuan sinyal, dan penyajian grafik pada halaman *Dashboard* dan Prediksi Mingguan. Kedua, keluaran prediksi harian dan mingguan, meliputi harga terkini, harga prediksi, selisih harga, sinyal tren, serta ukuran keyakinan atau akurasi yang ditampilkan. Ketiga, kesesuaian jawaban *chatbot* dengan nilai yang ditampilkan pada *dashboard*. Keempat, kemampuan sinyal *trend continuation*, yang diukur menggunakan akurasi pada data uji.

3. Hasil

Bab ini menyajikan serangkaian hasil empiris yang diperoleh dari seluruh tahapan eksperimen, mulai dari proses pelatihan model LSTM, evaluasi performa pada data uji independen, hingga keluaran fungsional dari sistem *web* G-Trend.

3.1. Hasil Pengumpulan dan Pra-pemrosesan Data

Data harga *Gold Futures* (GC=F) dan kurs USD/IDR (IDR=X) berhasil diunduh melalui `yfinance` dan digabungkan menjadi deret harga emas dalam Rupiah per gram (Gold_IDR). Deret tersebut ditransformasikan menjadi *daily log return*, diskalakan dengan *RobustScaler*, dan dibentuk menjadi sekuens dengan jendela 60 hari perdagangan. Jumlah data pada setiap subset ditunjukkan pada Tabel 5.

Tabel 5. Jumlah Data Setiap Subset

Subset	Jumlah Data
Pelatihan	1992
Validasi	427
Pengujian	428

Berdasarkan Tabel 5, sekuens dibagi secara kronologis dengan proporsi 70:15:15. Jumlah data validasi 427 dan pengujian 428 berbeda satu sekuens karena pembulatan ke bawah pada pembagian 70:15:15, dan sisa satu sekuens dialokasikan ke data pengujian agar tidak ada sampel yang terbuang. Data pelatihan dialokasikan paling besar agar model memiliki cukup contoh pola harga jangka panjang. Data validasi dipisahkan karena *Early Stopping* dan penurunan laju belajar memerlukan data yang tidak dipakai memperbarui bobot.

3.2. Hasil Pelatihan Model

Pelatihan dikonfigurasi hingga maksimal 80 *epoch*. Berdasarkan log pelatihan, proses dihentikan oleh *Early Stopping* pada *epoch* ke-22 dan bobot model dipulihkan dari *epoch* ke-10, yang memiliki loss validasi terkecil sebesar 0,7805. *Early Stopping* dikonfigurasi dengan *patience* 12 *epoch*: loss validasi terendah dicapai pada *epoch* ke-10, tetapi pelatihan tidak langsung dihentikan karena diberi toleransi 12 *epoch* berikutnya untuk memastikan tidak ada perbaikan lebih lanjut. *ReduceLROnPlateau* menurunkan laju belajar secara bertahap dari 1×10^{-3} menjadi 5×10^{-4} mulai *epoch* ke-16 dan $2,5 \times 10^{-4}$ mulai *epoch* ke-21. Pergerakan loss dan MAE selama pelatihan ditunjukkan pada Gambar 2. Karena pelatihan berhenti pada *epoch* ke-22, jauh sebelum batas 80, menaikkan batas *epoch* tidak akan mengubah hasil pelatihan. Selain itu, setelah *epoch* ke-10 loss pelatihan terus menurun sedangkan loss validasi naik, sehingga *epoch* tambahan cenderung memperbesar selisih keduanya (*overfitting*). Hal ini sejalan dengan penelitian [5] yang melaporkan bahwa jumlah *epoch* di atas 100 cenderung meningkatkan risiko *overfitting*.

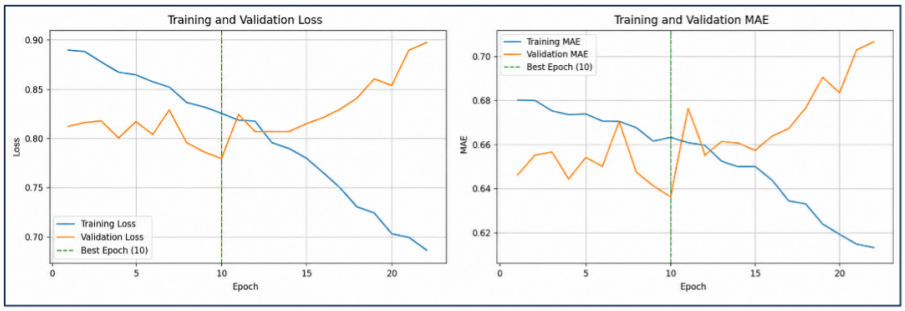

Gambar 2. Kurva Riwayat Pelatihan

Pada Gambar 2, loss pelatihan cenderung menurun dari 0,8896 menjadi 0,6892 pada *epoch* ke-22, sedangkan loss validasi berfluktuasi antara 0,7805 dan 0,8972 dengan simpangan baku 0,0290, termasuk lonjakan sementara pada *epoch* ke-11 (0,8250). Pada *epoch* ke-1 hingga ke-10 dan ke-12, loss validasi lebih rendah daripada loss pelatihan karena loss pelatihan dihitung dengan *Dropout* aktif, sedangkan loss validasi dihitung tanpa *Dropout*. Mulai *epoch* ke-13, loss validasi selalu berada di atas loss pelatihan. Loss validasi terendah dicapai pada *epoch* ke-10 (0,7805) dan tidak membaik selama 12 *epoch* berikutnya, sehingga *Early Stopping* menghentikan pelatihan pada *epoch* ke-22 dan memulihkan bobot dari *epoch* ke-10. Dari *epoch* terbaik hingga *epoch* ke-22, loss pelatihan turun 16,5% sedangkan loss validasi naik 15,0%, sehingga pada *epoch* ke-22 loss validasi 30,2% lebih tinggi daripada loss pelatihan. Pola serupa terlihat pada MAE: MAE validasi terendah (0,6363) dicapai pada epoch ke-10 dan naik menjadi 0,7063 pada *epoch* ke-22 (naik 11,0%), sementara MAE pelatihan turun dari 0,6628 menjadi 0,6153 (turun 7,2%). Pola ini menunjukkan *overfitting* setelah *epoch* terbaik. Nilai metrik pada *epoch* terbaik dirangkum pada Tabel 6.

Tabel 6. Nilai Metrik Pelatihan Pada *Epoch* Terbaik.

Metrik	***Epoch* 10**
MSE pelatihan	0,8258
MAE pelatihan	0,6628
MSE validasi	0,7805
MAE validasi	0,6363

3.3. Hasil Evaluasi Model

Model dievaluasi pada data validasi dan data pengujian setelah *log return* hasil prediksi direkonstruksi ke harga fisik emas dalam Rupiah per gram. Hasil perhitungan RMSE, MAPE, dan R^2 harian ditunjukkan pada Tabel 7.

Tabel 7. Hasil Evaluasi Model Harian.

Periode	**Model**	**RMSE (Rp/gram)**	**MAPE (%)**	**R^2**
Pelatihan	*Naive*	8.515	0,82	0,9969
	Drift	8.513	0,82	0,9969
	LSTM	8.081	0,79	0,9972
Pengujian	*Naive*	39.833	1,27	0,9902
	Drift	39.812	1,27	0,9903
	LSTM	39.517	1,26	0,9904

Berdasarkan Tabel 7, hasil LSTM dibandingkan dengan dua *baseline* pada data yang sama. *Baseline naive* menggunakan harga hari ini sebagai prediksi harga besok, dan *baseline drift* menambahkan rata-rata *log return* data pelatihan. Pada data pengujian, RMSE LSTM Rp 39.517 lebih rendah daripada *naive* Rp 39.833 dan 0,7% lebih rendah daripada *drift* Rp 39.812, dengan MAPE 1,26% dibandingkan 1,27% untuk kedua *baseline*. Adapun hasil perhitungan mingguan ditunjukkan pada Tabel 8.

Tabel 8. Hasil Evaluasi Model Mingguan.

Periode	**Model**	**RMSE (Rp/gram)**	**MAPE (%)**	**R^2**
Pelatihan	*Naive*	15.429	1,49	0,9895
	Drift	15.398	1,49	0,9896
	LSTM	15.691	1,54	0,9892
Pengujian	*Naive*	73.641	2,61	0,9633
	Drift	73.321	2,57	0,9636
	LSTM	73.353	2,51	0,9636

Berdasarkan Tabel 8, pada horizon mingguan RMSE LSTM Rp 73.353 lebih rendah sekitar 0,4% daripada *naive forecast* Rp 73.641 dan sedikit lebih tinggi daripada *drift* Rp 73.321, dengan selisih kurang dari 0,1%. Dengan demikian, LSTM tidak menunjukkan keunggulan yang berarti terhadap kedua pembanding pada horizon mingguan.

Untuk menguji kinerja model pada data di luar periode pelatihan, dilakukan pengujian *out-of-sample* pada 22 hari perdagangan, yaitu 8 Oktober hingga 6 November 2026, menggunakan model yang dilatih dengan data sampai 5 Oktober 2026. Pengujian ini mengevaluasi dua aspek utama, yaitu akurasi nilai nominal harga dan ketepatan arah pergerakan harian (Naik/Turun), dengan arah didefinisikan sebagai perbandingan harga terhadap penutupan hari sebelumnya. Rincian hasil pengujian harian disajikan pada Tabel 9.

Tabel 9. Hasil Pengujian Model pada Data Aktual

Tanggal	**Prediksi**	**Aktual**	**Prediksi Tren**	**Aktual Tren**
2026-10-08	2,376,061	2.389.337	Naik	Naik
2026-10-09	2,386,093	2.413.932	Turun	Naik
2026-10-12	2,407,231	2.413.029	Turun	Turun
2026-10-13	2,405,408	2.405.773	Turun	Turun
2026-10-14	2,400,626	2.359.663	Turun	Turun

Tanggal	Prediksi	Aktual	Prediksi Tren	Aktual Tren
2026-10-15	2,362,658	2.389.654	Naik	Naik
2026-10-16	2,386,127	2.422.358	Turun	Naik
2026-10-19	2,411,496	2.414.994	Turun	Turun
2026-10-20	2,408,358	2.402.837	Turun	Turun
2026-10-21	2,399,481	2.399.711	Turun	Turun
2026-10-22	2,396,781	2.350.850	Turun	Turun
2026-10-23	2,354,741	2.326.253	Naik	Turun
2026-10-26	2,330,289	2.347.591	Naik	Naik
2026-10-27	2,345,692	2.376.888	Turun	Naik
2026-10-28	2,369,422	2.362.885	Turun	Turun
2026-10-29	2,359,695	2.341.500	Turun	Turun
2026-10-30	2,341,651	2.265.168	Naik	Turun
2026-11-02	2,273,502	2,311,796	Naik	Naik
2026-11-03	2,308,762	2,213,495	Turun	Turun
2026-11-04	2,225,823	2.296,350	Naik	Naik
2026-11-05	2,291,825	2,315,627	Turun	Naik
2026-11-06	2,308,039	2,289,967	Turun	Turun

Selain evaluasi nilai nominal harga, evaluasi ketepatan arah pergerakan harian (Naik/Turun) dianalisis menggunakan matriks konfusi (*Confusion Matrix*) pada Tabel 10.

Tabel 10. Hasil Evaluasi Sinyal Trend

Prediksi \ Aktual	Turun (Aktual)	Naik (Aktual)	Total
Turun (Prediksi)	11 (*True Negative*)	4 (*False Negative*)	15
Naik (Prediksi)	2 (*False Positive*)	5 (*True Positive*)	7

Berdasarkan *Confusion Matrix* pada Tabel 10, analisis kinerja klasifikasi arah tren dan sinyal pergerakan model berhasil memprediksi secara tepat 16 dari 22 sampel pola pergerakan bursa.

Sinyal *trend continuation* ditentukan dengan membandingkan arah berjalan harga dengan arah prediksi. Arah berjalan adalah arah perubahan harga aktual pada hari bursa sebelumnya (naik atau turun), sedangkan arah prediksi adalah tanda selisih antara harga prediksi dan harga penutupan terakhir. Jika kedua arah sama, sistem menampilkan *Trend Continuation*. Jika berlawanan, sistem menampilkan *Trend Reversal*.

Perbandingan harga aktual dan harga hasil prediksi pada seluruh periode pelatihan, validasi, dan pengujian ditampilkan pada Gambar 3, sedangkan rincian periode validasi dan pengujian ditampilkan pada Gambar 4. Pada kedua gambar, garis prediksi mengikuti arah pergerakan harga aktual, (a) merupakan perbandingan harga aktual dan prediksi pada periode pelatihan, sedangkan (b) merupakan perbandingan harga aktual dan prediksi pada periode pengujian.



Gambar 3. Kurva Riwayat Pelatihan

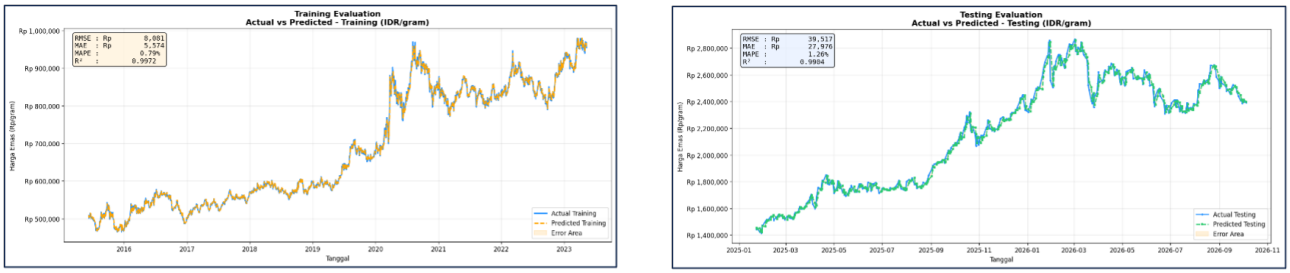

(a) Periode Pelatihan (b) Periode Pengujian

Gambar 4. Perbandingan Harga Aktual Dan Prediksi

Hasil evaluasi prediksi harian ditunjukkan pada Gambar 5. (a) Pada data pelatihan model harian memperoleh RMSE Rp 8.081, MAE Rp 5.574, MAPE 0,79%, dan R^2 0,9972. (b) Pada data pengujian RMSE Rp 39.517, MAE Rp 27.976, MAPE 1,26%, dan R^2 0,9904.

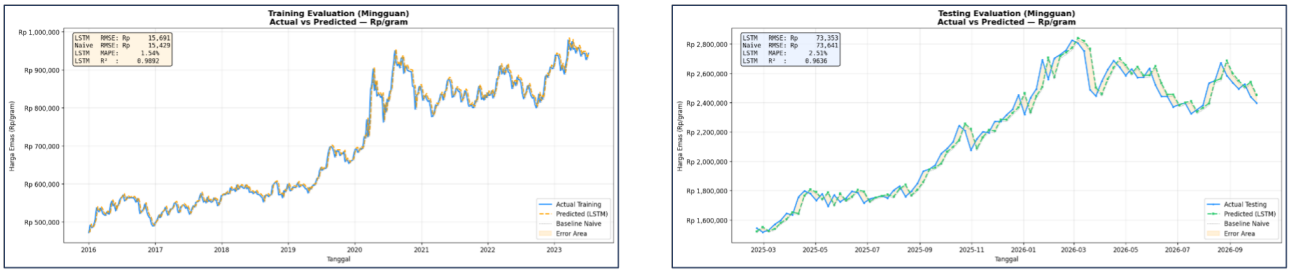

(a) Periode Pelatihan (b) Periode Pengujian

Gambar 5. Evaluasi Prediksi Mingguan

Hasil evaluasi prediksi mingguan ditunjukkan pada Gambar 5. (a) Pada data pelatihan model mingguan memperoleh RMSE Rp 15.691, MAPE 1,54%, dan R^2 0,9892. (b) Pada data pengujian RMSE Rp 73.353, MAPE 2,51%, dan R^2 0,9636.

3.4. Hasil Implementasi Sistem

Model dan *scaler* berhasil diintegrasikan ke dalam aplikasi *web* G-Trend. Tampilan halaman *Dashboard* pada prediksi harian ditunjukkan pada Gambar 6. Pada tampilan tersebut, harga emas penutupan 6 Oktober 2026 tercatat sebesar Rp 2.397.687 per gram, sedangkan harga prediksi untuk 7 Oktober 2026 sebesar Rp 2.405.415 per gram, atau naik Rp 7.728 (0,32%).

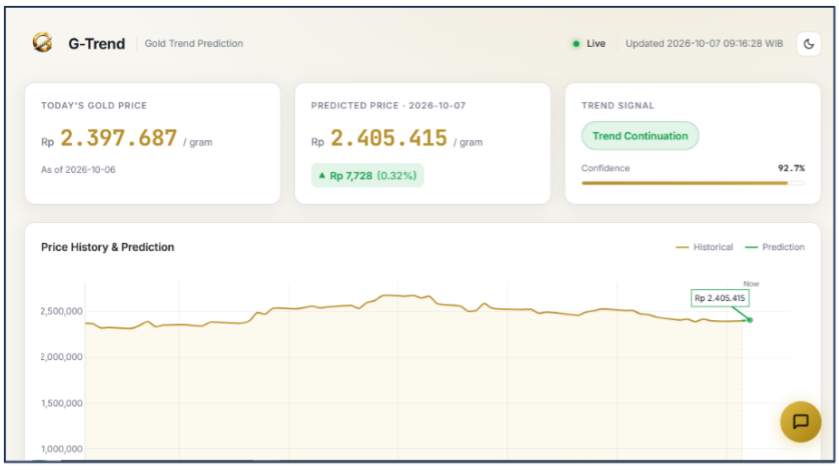

Gambar 6. Tampilan *Dashboard* prediksi harian G-Trend.

Halaman Prediksi Mingguan ditunjukkan pada Gambar 7 dan Gambar 8. Dengan harga emas Rp 2.398.446 per gram per 2 Oktober 2026, sistem memprediksi harga pada 9 Oktober 2026 sebesar Rp 2.396.632 per gram, atau turun Rp 1.814 (0,08%). Sinyal mingguan yang ditampilkan adalah *Trend Continuation*. Grafik pada halaman ini memuat riwayat harga dan prediksi untuk 5 hari bursa ke depan.



Gambar 7. Ringkasan Harga Prediksi Mingguan

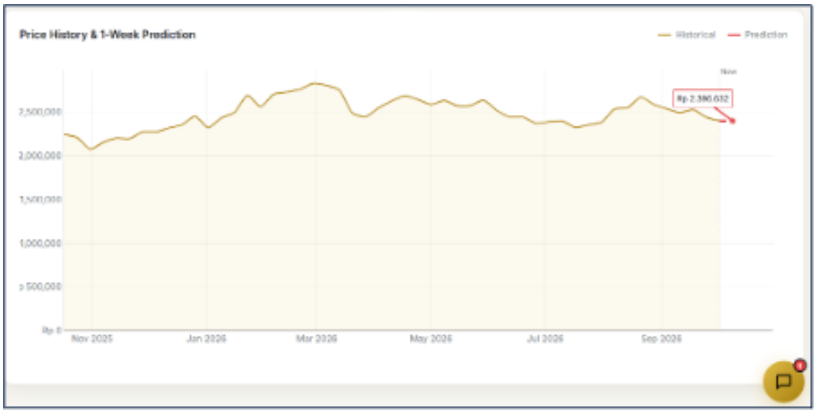

Gambar 8. Halaman Chart Prediksi Mingguan

Tampilan *chatbot* G-Trend Assistant ditunjukkan pada Gambar 9. *Chatbot* menyapa pengguna dan menyebutkan topik yang dapat ditanyakan, yaitu harga emas, prediksi harian atau mingguan, indikator, dan cara kerja model. Ketika pengguna mengajukan pertanyaan "Bagaimana prediksi emas saat ini?", *chatbot* menjawab dengan harga emas terkini beserta ringkasan prediksi harian serta mingguan. Tombol pertanyaan cepat tersedia di bagian bawah jendela percakapan, di samping kolom input teks, selain itu juga bisa memasukkan pertanyaan tentang sistem G-Trend di kolom pertanyaan.

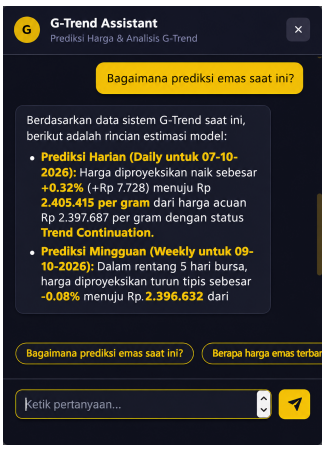

Gambar 9. Tampilan *chatbot G-Trend Assistant*

Ringkasan keluaran prediksi harian dan mingguan yang ditampilkan sistem dirangkum pada Tabel 11.

Tabel 11. Ringkasan keluaran sistem G-Trend pada prediksi harian dan mingguan.

Keluaran	Harian	Mingguan
Harga terkini (Rp/gram)	2.397.687	2.398.446
Harga prediksi (Rp/gram)	2.405.415	2.396.632
Selisih	+Rp 7.728 (+0,32%)	−Rp 1.814 (−0,08%)
Sinyal tren	*Trend Continuation*	*Trend Continuation*

4. Pembahasan

Penelitian ini mengembangkan sistem prediksi harga emas dan sinyal *trend continuation* berbasis LSTM yang diintegrasikan ke dalam aplikasi *web* G-Trend dengan data terkini dari `yfinance`. Pada data pengujian, model harian mencapai MAPE 1,26%, RMSE Rp 39.517, dan R^2 0,9904 pada Tabel 7. Perbandingan dengan *baseline* pada tabel yang sama menunjukkan bahwa galat tersebut hanya sedikit lebih rendah daripada *naive forecast* dan *drift* dan kemampuan model memprediksi arah tren masih terbatas.

Pada proses pelatihan, loss validasi terendah dicapai pada *epoch* ke-10 dan tidak membaik selama 12 *epoch* berikutnya, sementara loss pelatihan terus menurun pada Gambar 2. Pola ini menunjukkan adanya selisih generalisasi antara data pelatihan dan validasi, sehingga *Early Stopping* yang memulihkan bobot terbaik berperan penting dalam membatasi *overfitting*. Temuan ini sejalan dengan pendapat bahwa performa LSTM sangat bergantung pada penyetelan parameter yang tepat[9].

Pada horizon harian, RMSE LSTM Rp 39.517 lebih rendah sekitar 0,8% daripada *naive forecast* Rp 39.833 dan 0,7% daripada *drift* Rp 39.812, dengan MAPE 1,26% dibandingkan 1,27%. Keunggulan LSTM pada data pelatihan yaitu Rp 8.081 dibandingkan Rp 8.515. Hal ini dapat dipahami dari cara prediksi direkonstruksi. Karena *log return* harian bernilai kecil, galat pada skala harga terutama mencerminkan kesinambungan harga dari hari ke hari, sehingga MAPE yang rendah dan R^2 yang tinggi belum menunjukkan kemampuan model memprediksi perubahan harga. Pada horizon mingguan, RMSE LSTM Rp 73.353 lebih rendah sekitar 0,4% daripada *naive forecast* Rp 73.641 dan setara dengan *drift*. Selisih sekecil ini belum cukup untuk menyatakan keunggulan, sehingga penelitian ini tidak mengklaim keunggulan akurasi harga LSTM terhadap pembanding sederhana pada kedua horizon.

Penelitian [1] melaporkan bahwa LSTM efektif untuk memprediksi harga emas dunia dan menyediakan informasi prediksi yang stabil bagi pengambilan keputusan. Penelitian [11] memakai GRU dengan pendekatan multivariat yang memasukkan kurs dolar AS dan saham Antam, dengan akurasi 0,97 untuk prediksi tujuh hari. Penelitian ini juga memanfaatkan kurs, yaitu USD/IDR, untuk mengonversi harga emas dunia ke Rupiah per gram. Perbedaannya, penelitian ini baru melakukan prediksi satu hari untuk tampilan harian dan lima hari bursa untuk tampilan mingguan, serta belum membandingkan GRU. Penelitian [18] yang membandingkan LSTM dan GRU pada harga emas harian 2013-2022 melaporkan bahwa GRU menghasilkan MAPE lebih rendah dari LSTM. Penelitian [8] menunjukkan bahwa model hibrida CNN-LSTM mampu mengenali pola volatilitas harga lebih baik daripada model tunggal.

Penelitian ini tidak menguji model hibrida, sehingga belum ada bukti apakah LSTM dua lapis lebih baik atau lebih buruk daripada CNN-LSTM. Adapun penelitian [2] yang menggabungkan BiLSTM dan Cuckoo Search Optimization pada harga emas Antam, lalu mengimplementasikannya ke dalam aplikasi *web*, memperoleh MAPE 0,81%. Nilai ini secara numerik lebih rendah daripada MAPE penelitian ini, tetapi keduanya tidak dapat dibandingkan langsung karena jenis harga, periode data, dan metodenya berbeda. Penelitian [16] melaporkan

konfigurasi 16 *hidden neuron*, *learning rate* 0,01, dan 100 *epoch* sebagai yang terbaik, sedangkan penelitian ini memakai arsitektur 64 dan 32 unit, *learning rate* 0,001, dan *Early Stopping*. Pengaruh perbedaan konfigurasi tersebut terhadap hasil belum diuji dan menjadi bahan penelitian selanjutnya.

Dari sisi sistem, G-Trend berhasil menjalankan alur mulai dari penarikan data, pra-pemrosesan, inferensi, hingga penyajian grafik pada halaman *Dashboard* dan Prediksi Mingguan secara langsung dari API tanpa basis data lokal, sehingga informasi yang ditampilkan mengikuti data terkini. Dengan demikian, kontribusi G-Trend terletak pada integrasi prediksi harian dan mingguan, penyajian sinyal kelanjutan tren sebagai indikator deskriptif yang diturunkan dari keluaran model, dan *chatbot* penjelas hasil dalam satu sistem *web*, bukan pada keunggulan akurasi terhadap pembanding sederhana. Peningkatan akurasi, misalnya melalui fitur tambahan dan model lain, menjadi arah penelitian lanjutan. Selain itu, *chatbot* yang memanfaatkan API Gemini dengan konteks nilai prediksi terbaru dari *backend* membuat jawabannya selaras dengan *dashboard* pada Gambar 6 dan memudahkan investor ritel memperoleh informasi secara interaktif [19].

Penelitian ini memiliki beberapa keterbatasan. Model hanya memakai harga *Gold Futures* dan kurs USD/IDR, sehingga faktor seperti inflasi dan suku bunga bank sentral belum tercakup. Harga yang diprediksi adalah harga emas dunia yang dikonversi ke Rupiah per gram, bukan harga jual-beli emas ritel di Indonesia. Pembanding hanya mencakup *naive forecast dan drift*, belum GRU atau CNN-LSTM. Seleksi fitur berbasis korelasi Spearman dihitung pada seluruh data, sehingga berpotensi memasukkan informasi data uji. Pengujian pada data aktual hanya mencakup 22 hari perdagangan, dan kualitas jawaban *chatbot* belum dievaluasi.

5. Kesimpulan

Berdasarkan hasil penelitian, model LSTM dua lapis yaitu 64 dan 32 unit dapat diimplementasikan ke dalam sistem *web* G-Trend. Sistem tersebut menarik data harga emas dan kurs USD/IDR langsung dari *API Yahoo Finance* serta menyajikan prediksi harian, prediksi mingguan, sinyal *trend continuation*, dan *chatbot* berbasis API Gemini. Pada data pengujian horizon harian, model menghasilkan MAPE 1,26%, RMSE Rp 39.517, dan R^2 0,9904 pada skala harga fisik, dengan bobot terbaik diperoleh pada *epoch* ke-10 melalui *Early Stopping*. Pada horizon mingguan, model menghasilkan MAPE 2,51%, RMSE Rp 73.353, dan R^2 0,9636. Namun, perbandingan dengan *naive forecast* dan *drift* menunjukkan bahwa galat harga LSTM setara dengan kedua pembanding tersebut pada kedua horizon, sehingga penelitian ini tidak menyimpulkan adanya keunggulan akurasi harga. Pada pengujian data aktual 22 hari perdagangan, akurasi arah LSTM sebesar 72,7% (16 dari 22 hari), sehingga kemampuan model memprediksi arah belum terbukti kuat. Kontribusi penelitian ini terletak pada integrasi prediksi harian dan mingguan, sinyal kelanjutan tren, dan *chatbot* penjelas hasil dalam satu sistem *web*.

Penelitian ini memiliki keterbatasan, yaitu variabel masukan hanya berupa harga *Gold Futures* dan kurs USD/IDR, harga yang diprediksi adalah harga emas dunia terkonversi dan bukan harga emas ritel di Indonesia, serta seleksi fitur berbasis korelasi Spearman dihitung pada seluruh data. Selain itu, pembanding hanya mencakup *naive forecast* dan *drift*, dan kualitas jawaban *chatbot* belum dievaluasi. Penelitian selanjutnya disarankan membandingkan model dengan GRU dan CNN-LSTM, menambahkan data sentimen berita sebagai variabel masukan di samping data historis harga, menguji akurasi arah pada periode yang lebih panjang, serta mengevaluasi kualitas jawaban *chatbot*.

Pernyataan Penggunaan *Artificial Intelligence*. Penulis menggunakan *Claude* untuk membantu proses pemeriksaan tata bahasa, penyuntingan bahasa, dan peningkatan kejelasan naskah. Seluruh keluaran yang dihasilkan oleh AI telah

diperiksa dan diverifikasi oleh penulis. Penulis bertanggung jawab sepenuhnya atas keakuratan, orisinalitas, dan integritas isi artikel.

Pernyataan Kontribusi Penulis. **ASA** berkontribusi dalam konseptualisasi, metodologi, pengumpulan data, dan analisis penelitian. **LEA** berkontribusi dalam peninjauan, penyuntingan, dan pembimbingan naskah. Seluruh penulis telah membaca, meninjau, dan menyetujui versi akhir artikel serta bertanggung jawab atas seluruh aspek penelitian dan publikasi.

Pernyataan Konflik Kepentingan. Penulis menyatakan bahwa tidak terdapat konflik kepentingan yang berkaitan dengan penelitian, kepengarangan, dan publikasi artikel ini.

Pernyataan Pendanaan. Penelitian ini tidak menerima pendanaan khusus dari lembaga pemerintah, komersial, maupun organisasi nirlaba.

Daftar Pustaka

[1] T. G. Lasijan, R. Santoso, and A. R. Hakim, "Prediksi Harga Emas Dunia Menggunakan Metode Long-Short Term Memory," *Jurnal Gaussian*, vol. 12, no. 2, pp. 287–295, 2023. https://doi.org/10.14710/j.gauss.12.2.287-295.

[2] M. N. Taukid, Y. V. Via, and E. Y. Puspaningrum, "Implementasi Bilstm Dan Cuckoo Search Optimization Pada Aplikasi Prediksi Harga Emas Antam," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 3, pp. 5499–5506, 2025. https://doi.org/10.36040/jati.v9i3.14310.

[3] J. K. Sulaiman and T. Haryanto, "Pemanfaatan Model Long Short Term Memory (LSTM) Untuk Prediksi Harga Emas Sebagai Instrumen Investasi Dalam Mempersiapkan Ancaman Resesi Global 2023," *Indonesian Journal of Computer Science Attribution*, vol. 12, no. 2, pp. 614–621. https://doi.org/10.33022/ijcs.v12i2.3176.

[4] M. R. Pahlevi and D. W. Nugraha, "Pengembangan Sistem Prediksi Harga Emas Real-Time Berbasis Lstm Untuk Optimalisasi Waktu Investasi Bisnis Info Artikel Abstrak," *Business Journal*, vol. 11, no. 1, pp. 20–33, 2025. https://doi.org/10.25124/jbs.v11i1.10777.

[5] R. A. Dalimuthe, R. T. Adek, and C. Agusniar, "Prediksi Harga Emas Menggunakan Algoritma Long Short-Term Memory (Lstm)," in *Prosiding Seminar Nasional Teknologi dan Teknik Informatika (SENASTIKA)*, vol. 1, 2024. https://proceedings.unimal.ac.id/senastika/article/view/852/.

[6] S. Amryliana, S. Bahri, and M. R. Alfian, "Optimization of Long Short Term Memory Model for Gold Price Prediction Using Adaptive Moment Estimation," *Jurnal Matematika, Statistika dan Komputasi*, vol. 21, no. 3, pp. 669–683, 2025. https://doi.org/10.20956/j.v21i3.42872.

[7] M. Hadrianto, A. N. I. Rahman, A. S. Haris, A. Juzril, and N. Rahmadani, "Prediksi Harga Emas Menggunakan Algoritma Long-Short Term Memory dengan Optimasi Adaptive Momen Estimation," *Faktor Exacta*, vol. 18, no. 2, p. 183, 2025. https://doi.org/10.30998/faktorexacta.v18i2.26841.

[8] R. Septiana *et al.*, "Prediksi Harga Emas Indonesia Menggunakan Model CNN-LSTM," *Infomatek*, vol. 27, no. 1, pp. 131–138, 2025. https://doi.org/10.23969/infomatek.v27i1.24417.

[9] A. Primawati, F. A. Mustika, and Y. Wibawanti, "Analisis Tren Dan Prediksi Harga Emas Menggunakan Prophet Dan Long Short Term Memory (LSTM)," *Jurnal SIMETRIS*, vol. 16, no. 2, pp. 1–15, 2025. https://doi.org/10.24176/simet.v16i2.15580.

[10] A. Tholib, N. K. Agusmawati, and F. Khoiriyah, "Prediksi Harga Emas Menggunakan Metode LSTM Dan GRU," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, pp. 620–627, 2023. https://doi.org/10.23960/jitet.v11i3.3250.

[11] T. Handhayani, C. Tanudy, and J. Hendryli, "Prediksi Harga Emas di Indonesia Menggunakan Gated Recurrent Unit," *Jurnal Fasilkom*, vol. 13, no. 3, pp. 480–488, 2023. https://doi.org/10.37859/jf.v13i3.6185.

[12] D. Soyusiawaty and F. G. Putra, "Pengembangan chatbot untuk layanan Pimpinan Daerah Muhammadiyah Kota Yogyakarta menggunakan metode rule-based," *J. Penerapan Sist. Inf.(Komputer Manajemen)*, vol. 4, no. 2, pp. 354–363, 2023.

[13] M. R. S. Alfarizi, M. Z. Al-farish, M. Taufiqurrahman, G. Ardiansah, and M. Elgar, "Penggunaan Python sebagai bahasa pemrograman untuk machine learning dan deep learning," *Karya Ilmiah Mahasiswa Ber-*

tauhid (KARIMAH TAUHID), vol. 2, no. 1, pp. 1–6, 2023. https://ojs.unida.info/karimahtauhid/article/view/7518.

[14] R. Jonathan and N. Setiyawati, "Implementasi Framework Flask Pada Pembangunan Aplikasi Monitoring Dan Store Visit It Support Pada Pt. Xyz," *Jurnal Informatika*, vol. 23, no. 01, pp. 91–101, 2023. https://doi.org/10.30873/ji.v23i1.3637.

[15] N. Rachmat and D. P. Kesuma, "Implementasi LLM Gemini Pada Pengembangan Aplikasi Chatbot Berbasis Android," *Jurnal Ilmu Komputer (JUIK)*, vol. 4, no. 1, pp. 40–52, 2024. https://journal.umgo.ac.id/index.php/juik/article/view/2831.

[16] F. Defina, S. Alhamdani, G. I. Marthasari, C. Sri, and K. Aditya, "Prediksi Harga Emas Menggunakan Metode Time Series Long Short-Term Memory Neural Network," *REPOSITOR*, vol. 3, no. 4, pp. 375–386, 2021. https://ejournal.umm.ac.id/index.php/repositor/article/view/31959.

[17] M. O. G. Sibannang and I. G. N. L. Wijayakusuma, "Implementation of LSTM for Gold Price Prediction in Indonesia," *Journal of Applied Informatics and Computing*, vol. 10, no. 1, pp. 964–968, 2026. https://doi.org/10.30871/jaic.v10i1.11860.

[18] Z. V. Hendra, M. A. Ramadhani, I. Chintya, Y. Rahmatullah, and E. Ismanto, "Prediksi Harga Emas Menggunakan Algoritma Long Short Term Memory (LSTM) & Gated Recurrent Unit (GRU)," *Journal of Software Engineering and Information System (SEIS)*, vol. 6, no. 1, pp. 31–37, 2026. https://ejurnal.umri.ac.id/index.php/SEIS/article/view/9809.

[19] R. Fitria, R. P. Tulodo, and A. Sofyan, "Pemanfaatan chatbot untuk informasi pendaftaran calon mahasiswa baru di perguruan tinggi," *IT-Explore: Jurnal Penerapan Teknologi Informasi Dan Komunikasi*, vol. 4, no. 2, pp. 221–232, 2025. https://doi.org/10.24246/itexplore.v4i2.2025.pp221-232.