

Model Hibrida PSO-LSTM dan Interpretasi SHAP untuk Peramalan Harga Emas Domestik Multivariat

PSO-LSTM Hybrid Model and SHAP Interpretation for Multivariate Domestic Gold Price Forecasting

Fajar Arafat*, Nugroho Dwi Saputro, Aris Tri Joko Harjanto

Fakultas Teknik dan Informatika, Program Studi Informatika, Universitas PGRI Semarang, Semarang, Indonesia

Email: ^{1,*}fajararafat10@gmail.com, ²nugputra@upgris.ac.id, ³aristrijaka@gmail.com

Email Penulis Korespondensi: fajararafat10@gmail.com

Received: 06/09/2026, Revised: 27/09/2026, Accepted: 27/09/2026, Published: 27/09/2026

Abstrak—Peramalan harga emas domestik yang fluktuatif memerlukan model prediktif yang tidak hanya akurat, tetapi juga transparan. Meskipun arsitektur *Long Short-Term Memory* (LSTM) unggul dalam menangkap dependensi temporal pada data deret waktu, kinerjanya sangat sensitif terhadap pengaturan *hyperparameter* dan bersifat *black-box*. Untuk mengatasi keterbatasan optimasi manual dan kurangnya transparansi tersebut, penelitian ini mengusulkan model peramalan multivariat hibrida PSO-LSTM yang diintegrasikan dengan metode *SHapley Additive exPlanations* (SHAP). Berdasarkan kerangka kerja CRISP-DM dan memanfaatkan data historis harian periode 2020–2026, algoritma *Particle Swarm Optimization* (PSO) digunakan untuk mengoptimasi jumlah neuron, laju pembelajaran (*learning rate*), dan ukuran *batch* secara otomatis. Selanjutnya, metode SHAP dengan teknik reduksi latar belakang K-Means diterapkan untuk memetakan urgensi kontribusi fitur masukan. Hasil eksperimen menunjukkan bahwa model PSO-LSTM berhasil mengungguli *baseline* LSTM dengan mereduksi *Root Mean Squared Error* (RMSE) sebesar 11,70% dan *Mean Absolute Error* (MAE) sebesar 14,08%, serta mencatatkan *Mean Absolute Percentage Error* (MAPE) sebesar 2,62% yang tergolong sangat akurat. Pengujian statistik Diebold-Mariano juga membuktikan bahwa keunggulan akurasi model PSO-LSTM bersifat signifikan. Analisis SHAP menunjukkan bahwa memori harga historis emas domestik memberikan kontribusi marginal tertinggi terhadap prediksi, disusul oleh penyesuaian nilai tukar USD/IDR dan sentimen harga emas global. Secara keseluruhan, penelitian ini memberikan kontribusi berupa kerangka kerja pemodelan finansial terintegrasi yang tidak hanya meningkatkan akurasi pada data sarat volatilitas, tetapi juga menyajikan interpretasi fitur yang rasional sebagai landasan nilai bagi investor dan pembuat kebijakan.

Kata Kunci: Harga Emas Domestik; Long Short-Term Memory; Particle Swarm Optimization; SHapley Additive exPlanations; Peramalan Deret Waktu

Abstract—Forecasting volatile domestic gold prices requires a predictive model that is not only accurate but also transparent. Although the Long Short-Term Memory (LSTM) architecture excels at capturing temporal dependencies in time-series data, its performance is highly sensitive to hyperparameter tuning and suffers from a black-box nature. To overcome the limitations of manual optimization and lack of transparency, this study proposes a hybrid multivariate PSO-LSTM forecasting model integrated with the SHapley Additive exPlanations (SHAP) method. Built upon the CRISP-DM framework using daily historical data from 2020 to 2026, the Particle Swarm Optimization (PSO) algorithm is employed to automatically optimize the number of neurons, learning rate, and batch size. Furthermore, the SHAP method with K-Means background reduction is applied to map the contribution of input features. Experimental results demonstrate that the PSO-LSTM model outperforms the baseline LSTM by reducing Root Mean Squared Error (RMSE) by 11.70% and Mean Absolute Error (MAE) by 14.08%, while achieving a highly accurate Mean Absolute Percentage Error (MAPE) of 2.62%. Statistical testing using the Diebold-Mariano test confirms that the predictive superiority of the PSO-LSTM model is statistically significant. SHAP analysis indicates that historical memory of domestic gold prices provides the highest marginal contribution to model predictions, followed by USD/IDR exchange rate adjustments and global gold price sentiment. Overall, this study contributes an integrated financial modeling framework that not only enhances accuracy on highly volatile data but also provides rational feature interpretability as a foundation for hedging decisions by investors and policymakers.

Keywords: Domestic Gold Price; Long Short-Term Memory; Particle Swarm Optimization; SHapley Additive exPlanations; Time-Series Forecasting

1. PENDAHULUAN

Emas merupakan salah satu instrumen investasi *safe haven* yang memiliki tingkat likuiditas sangat tinggi dan sering dijadikan acuan dalam mengukur stabilitas perekonomian makro. Di Indonesia, volatilitas pergerakan harga emas sangat dinamis; data historis menunjukkan fluktuasi yang tajam pada periode krisis global yang dipicu oleh dinamika nilai tukar mata uang [1]. Secara teoretis, harga emas domestik dipengaruhi secara multivariat oleh tren harga emas global dan nilai tukar Rupiah terhadap Dolar Amerika Serikat (Kurs USD/IDR) [2]. Karena emas di pasar global diperdagangkan dalam mata uang USD, setiap depresiasi Rupiah akan memberikan efek ganda (*multiplier effect*) terhadap lonjakan harga emas fisik di pasar domestik. Mengingat tingginya sensitivitas dan volatilitas tersebut, peramalan (*forecasting*) harga emas berbasis data deret waktu (*time-series*) yang akurat menjadi krusial, terutama ketika pengambil kebijakan dan investor dihadapkan pada ketidakpastian kondisi geopolitik serta makro ekonomi modern.

Dalam konteks pemodelan data finansial, pemilihan rentang waktu observasi sangat menentukan ketahanan (*robustness*) model yang dibangun. Penelitian ini secara spesifik menggunakan dataset historis periode 2020 hingga 2026. Pemilihan periode ini didasarkan pada urgensi untuk melatih model pada rentang volatilitas ekstrem sebagai uji tekanan (*stress test*) empiris. Periode 2020-2022 merupakan fase anomali struktural akibat pandemi global COVID-19, di mana terjadi pergeseran drastis pada rantai pasok global, kontraksi permintaan, dan kepanikan pasar finansial yang memicu pelarian modal secara masif ke aset *safe haven* jauh di luar tren normal historisnya [3]. Membangun model prediktif pada rentang data yang sarat anomali ini menghadirkan tantangan bias yang signifikan. Oleh karena itu, untuk menangani anomali struktural tersebut, penelitian ini tidak hanya bergantung pada teknik prapemrosesan data statistik konvensional seperti interpolasi. Penanganan utama bertumpu pada karakteristik arsitektur *Long Short-Term Memory* (LSTM) yang memiliki mekanisme *gating*, khususnya *forget gate* [4]. Mekanisme ini bekerja melalui fungsi aktivasi sigmoid untuk secara matematis menyaring dan membuang fluktuasi (*noise*) jangka pendek dari anomali pandemi, sekaligus mempertahankan memori tren harga jangka panjang di dalam *cell state* [5]. Untuk memastikan bahwa mekanisme arsitektural tersebut tidak menjadi sekadar klaim teoretis, penelitian ini mengimplementasikan strategi evaluasi validasi berurutan waktu (*time-series split validation*) yang memisahkan pengujian pada periode syok pandemi dengan periode normal pascapandemi. Melalui pendekatan ini, ketahanan model terhadap bias *overfitting* dari syok ekonomi sesaat dapat dibuktikan secara empiris.

Dalam analisis deret waktu, algoritma *Deep Learning* seperti LSTM mampu menangkap dependensi temporal yang kompleks, menjadikannya standar baru dalam pemodelan data finansial yang non-linear dan fluktuatif [6]. Guna menempatkan penelitian ini dalam koridor kebaruan (*novelty*) ilmiah, analisis literatur terhadap *state of the art* dari berbagai penelitian terdahulu perlu dikaji secara kritis. Penelitian terdahulu membuktikan bahwa arsitektur LSTM memiliki kinerja superior dalam peramalan deret waktu dibandingkan metode konvensional seperti ARIMA, khususnya pada data dengan pola fluktuatif dan tidak linear [7]. Meskipun demikian, kinerja LSTM konvensional memiliki keterbatasan fundamental, yaitu sangat sensitif terhadap kombinasi *hyperparameter* (seperti jumlah neuron, *learning rate*, dan ukuran *batch*). Pendekatan heuristik manual (*trial and error*) yang umum digunakan saat ini rentan terjebak pada *local optima* dan sangat tidak efisien mengingat terjadinya ledakan kombinatorial (*combinatorial explosion*) pada luasnya ruang pencarian (*search space*) arsitektur jaringan saraf tiruan [8].

Sebagai solusi atas inefisiensi pencarian parameter tersebut, *state of the art* pemodelan saat ini mengarah pada pemanfaatan algoritma *Particle Swarm Optimization* (PSO). Algoritma metaheuristik berbasis kecerdasan kawanan (*swarm intelligence*) ini bekerja dengan meniru perilaku sosial organisme seperti pergerakan kelompok burung (*flocking*), di mana setiap partikel akan terus memperbarui posisi dan kecepatannya dalam ruang pencarian berdasarkan pengalaman posisi terbaik individu (*personal best*) dan posisi terbaik kelompok (*global best*) [9]. Studi komparatif membuktikan bahwa PSO lebih superior dibandingkan optimasi konvensional seperti *Grid Search*, di mana model berbasis PSO berhasil menekan tingkat kesalahan (MAPE) hingga 3,11%, mengungguli *Grid Search* yang berada di angka 3,36% [10]. Hal ini menegaskan bahwa PSO mampu menemukan konfigurasi optimal secara cerdas dan paralel tanpa beban komputasi *brute-force*. Secara empiris, integrasi PSO pada arsitektur LSTM terbukti mampu mengotomatisasi pencarian parameter global sekaligus menurunkan tingkat kesalahan prediksi (MAE) sebesar 11,78% dibandingkan dengan model LSTM standar [11]. Dalam kaitannya dengan dataset 2020-2026, optimasi parameter oleh PSO menjadi krusial untuk menemukan rasio *learning rate* dan parameter memori yang paling presisi, sehingga LSTM dapat beradaptasi dengan anomali struktural tanpa kehilangan kapabilitas generalisasinya pascapandemi.

Di samping tantangan pada optimasi parameter, kelemahan fundamental lainnya adalah model *Deep Learning* kerap beroperasi sebagai *black-box* yang hanya berfokus pada minimalisasi eror (RMSE/MAPE) tanpa mampu memberikan penjelasan (*explainability*) mengenai fitur mana yang paling memengaruhi hasil prediksi [12]. Hal ini menyulitkan analis ekonomi untuk memvalidasi apakah keputusan prediktif model didasarkan pada kausalitas ekonomi yang valid, atau sekadar korelasi bias dari gangguan data. Oleh karena itu, penerapan metode *Explainable AI* (XAI) seperti *SHapley Additive exPlanations* (SHAP) menjadi sangat relevan. SHAP berlandaskan pada teori permainan kooperatif (*cooperative game theory*) untuk menghitung nilai marginal dari setiap variabel, sehingga mampu mendistribusikan kontribusi prediksi secara presisi kepada masing-masing fitur [13]. Integrasi metode SHAP terbukti efektif dalam memetakan kontribusi setiap variabel secara adil dan transparan pada model prediksi non-linier, tanpa mengorbankan performa tinggi dari model prediktif itu sendiri, sebagaimana dibuktikan pada penelitian sebelumnya di mana model tetap beroperasi transparan pada tingkat akurasi 81% dan nilai AUC 0.88 [14]. Bagi peramalan harga emas, SHAP akan mengkuantifikasi dengan pasti seberapa besar dominasi guncangan nilai tukar USD/IDR dibandingkan sentimen harga emas global pada setiap titik prediksi.


Meskipun literatur sebelumnya telah mengkaji *deep learning*, optimasi, dan *explainability* secara terpisah, evaluasi terhadap empat penelitian terdahulu menunjukkan beberapa kesenjangan mendasar. Pertama, Adha dkk. [7] membuktikan keunggulan LSTM dalam peramalan harga emas, namun masih bergantung pada konfigurasi parameter manual yang rentan terjebak *local optima*. Kedua, Aprianto dkk. [11] berhasil mengatasi masalah tersebut dengan mengintegrasikan PSO pada LSTM hingga menekan galat MAE sebesar 11,78%, tetapi model hibridanya masih bersifat *black-box*. Ketiga, Çelik dkk. [12] menggarisbawahi pentingnya XAI pada pemodelan finansial, namun belum menyajikannya dalam kerangka kerja terintegrasi dengan optimasi metaheuristik sekuensial. Keempat, Teddy Syamkalla dkk. [14] membuktikan efektivitas SHAP untuk transparansi prediksi, tetapi penerapannya masih terbatas

pada algoritma non-sekuensial (CatBoost). Berdasarkan evaluasi tersebut, *research gap* dalam studi ini adalah minimnya model peramalan harga emas multivariat yang secara simultan mengintegrasikan otomatisasi *hyperparameter* berbasis PSO dan transparansi keputusan berbasis XAI (SHAP dengan reduksi *background* K-Means) di dalam kerangka kerja CRISP-DM [15] pada rentang data sarat volatilitas (2020–2026).

Berdasarkan *research gap* tersebut, tujuan dari penelitian ini adalah merancang, mengoptimasi, dan mengevaluasi model peramalan harga emas domestik multivariat berbasis hibrida PSO-LSTM serta menganalisis kontribusi variabel prediktor menggunakan SHAP. Penelitian ini memberikan tiga kontribusi utama bagi pengembangan ilmu pengetahuan dan praktik pemodelan finansial. Pertama, dari segi metodologis, penelitian ini menghadirkan kerangka kerja peramalan terintegrasi berbasis CRISP-DM yang menggabungkan otomatisasi pencarian *hyperparameter* (PSO) pada arsitektur LSTM dengan teknik XAI berbasis SHAP (menggunakan reduksi *background* K-Means) untuk menghasilkan model deret waktu yang tidak hanya berakurasi tinggi tetapi juga transparan. Kedua, sebagai kontribusi empiris, penelitian ini menyajikan evaluasi ketahanan model *deep learning* dalam meredam bias dan *noise* akibat anomali struktural (seperti syok pandemi COVID-19) pada rentang data historis 2020–2026 melalui strategi *time-series split validation*. Ketiga, dari aspek praktis dan analitis, penelitian ini memberikan bukti kuantitatif mengenai hierarki dan rasio dampak interaksi variabel makroekonomi (harga emas global, kurs USD/IDR, dan memori harga lokal) terhadap pembentukan harga emas domestik, sehingga dapat menjadi rujukan yang rasional dan valid bagi investor maupun pembuat kebijakan dalam mengambil keputusan lindung nilai (*hedging*).

2. METODOLOGI PENELITIAN

Penelitian ini menerapkan metode eksperimental berbasis pembelajaran mendalam (*deep learning*) dan algoritma optimasi heuristik untuk mengatasi tantangan fluktuasi dinamis serta *non-linearitas* pada peramalan harga emas domestik [16]. Guna menjamin standarisasi dan struktur pengerjaan rekayasa data, kerangka kerja penelitian dirancang menggunakan pendekatan *Cross-Industry Standard Process for Data Mining* (CRISP-DM) [17]. Metodologi ini diadaptasi ke dalam empat tahapan utama secara berkesinambungan, meliputi: *Data Understanding*, *Data Preparation*, *Modeling*, dan *Evaluation*. Alur logis dari implementasi komputasi ini direpresentasikan secara visual melalui diagram alir (*flowchart*) pada Gambar 1.



Gambar 1. Alur Diagram Kerangka Penelitian

2.1 Pengumpulan Data

Data historis harian diekstraksi melalui API Yahoo Finance menggunakan pustaka *yfinance* pada bahasa pemrograman Python untuk rentang waktu 1 Januari 2020 hingga 6 Agustus 2026 [18]. Data multivariat yang ditarik mencakup harga penutupan emas global (*ticker*: GC=F) dan nilai tukar Rupiah terhadap Dolar Amerika Serikat (Kurs USD/IDR, *ticker*: IDR=X). Kedua variabel tersebut disinkronkan berdasarkan indeks tanggal, kemudian ditransformasikan menjadi variabel target Harga Emas Domestik (IDR/Gram) menggunakan formula perhitungan berikut:

$$\text{Harga_IDR}_t = \frac{\text{Gold_USD}_t \times \text{Kurs_IDR}_t}{31,1034768} \quad (1)$$

Proses ekstraksi tersebut menghasilkan total 1.718 observasi. Cuplikan struktur data mentah ditunjukkan pada Tabel 1.

Tabel 1. Struktur Data Mentah Historis

Date	Gold USD	Kurs IDR	Harga IDR
2020-01-01	NaN	13690.372070	NaN
2020-01-02	1524.500000	13689.231445	670961.432144
2020-01-03	1549.199951	13884.786133	691572.525390
....			
2026-08-13	4423.600098	17877.000000	2542504.385412

Berdasarkan inspeksi awal, terdeteksi anomali *missing values* (NaN) sebanyak 59 baris pada Gold_USD dan 1 baris pada Kurs_IDR, yang berakumulasi menjadi 60 baris kosong pada target Harga_IDR. Ketidaksinkronan jadwal libur perdagangan antara pasar komoditas global dan pasar valas domestik ini merupakan karakteristik umum yang sering ditemui pada pengumpulan data deret waktu *finansial multivariat* [19].

2.2 Exploratory Data Analysis

Tahap ini dilakukan untuk mengidentifikasi karakteristik awal dataset, pola pergerakan deret waktu, serta hubungan linear antarvariabel menggunakan matriks korelasi *Pearson* sebelum data masuk ke tahap pemodelan [20].

2.3 Data Preparation

Tahap persiapan data dilakukan untuk mengondisikan dataset agar siap diumpankan ke dalam arsitektur model komputasi. Pemrosesan ini mencakup empat tahapan sistematis berikut:

a. Penanganan *Missing Values*

Pada tahap pembersihan data, terdeteksi anomali missing values sebanyak 59 baris pada Gold_USD dan 1 baris pada Kurs_IDR (berakumulasi pada 60 baris observasi). Guna menghindari risiko kerusakan kontinuitas deret waktu akibat penghapusan baris, celah kosong pada data dipulihkan menggunakan metode interpolasi linear [21]. Melalui teknik imputasi ini, seluruh rentang waktu tetap terjaga utuh menghasilkan dataset bersih sebanyak 1.718 baris.

b. Partisi Data

Dataset dipartisi secara kronologis tanpa pengacakan (*no shuffling*) guna menjaga integritas dependen urutan waktu deret berkala. Dataset dibagi menjadi tiga bagian dengan rasio 70% untuk data pelatihan (*training set* / 1.202 baris), 20% untuk data validasi (*validation set* / 344 baris), dan 10% sisanya sebagai data pengujian (*testing set* / 172 baris) [22].

c. Normalisasi Data

Penskalaan fitur dilakukan ke dalam rentang fungsional [0, 1] menggunakan teknik *Min-Max Scaler* guna mengeliminasi bias magnitudo angka riil selama proses pembaruan bobot pada jaringan saraf. Secara matematis, proses transformasi normalisasi ini dirumuskan pada Persamaan (2).

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

Berdasarkan Persamaan (2) tersebut, variabel x' merupakan nilai data baru hasil penskalaan yang berada pada rentang nol hingga satu, sedangkan x merepresentasikan nilai observasi data asli (harga emas atau nilai tukar) sebelum dilakukan transformasi. Variabel $x_{\min}$ merupakan nilai observasi terendah, dan $x_{\max}$ menunjukkan nilai observasi tertinggi dari fitur terkait. Untuk mencegah terjadinya kebocoran data (*data leakage*) pada fase evaluasi, proses kalibrasi skala berupa pencarian nilai $x_{\min}$ dan $x_{\max}$ (*fitting*) dilakukan secara eksklusif hanya pada himpunan data latih. Nilai parameter batas yang dihasilkan dari data latih tersebut kemudian ditetapkan dan digunakan untuk mentransformasikan seluruh himpunan data, termasuk data uji [23].

d. Transformasi Sekuensial (*Windowing*)

Data ditransformasikan ke dalam format pembelajaran terawasi (*supervised learning*) menggunakan metode *Windowing Sequence* dengan penetapan panjang jendela historis sebesar 7 hari (LOOKBACK = 7) [24]. Nilai fitur dari 7 hari sebelumnya digunakan untuk memprediksi 1 nilai target harga emas domestik pada hari berikutnya (t). Proses ini menghasilkan bentuk tensor masukan 3D berdimensi (1195, 7, 3), (337, 7, 3), dan (165, 7, 3).

2.4 Pemodelan Arsitektur Long Short-Term Memory (LSTM) Baseline

Tahap pemodelan dalam kerangka CRISP-DM ini berfokus pada pelatihan model *Long Short-Term Memory* (LSTM). Algoritma ini dipilih karena keunggulan inherennya dalam memelihara memori jangka panjang guna memitigasi masalah *vanishing gradient* pada data sekuensial multivariat [25]. Sebagai langkah awal, dibangun model dasar (*baseline*) untuk mengekstraksi performa awal sebelum memasuki tahap optimasi parameter.

Model *baseline* dikonstruksi menggunakan pendekatan sekuensial dengan rincian arsitektur yang meliputi: lapisan tersembunyi (*hidden layer*) LSTM berkapasitas 64 neuron yang menerima masukan berbentuk tensor tiga dimensi, lapisan *Dropout* dengan probabilitas 0,2 untuk meminimalisasi risiko *overfitting*, serta lapisan *Dense* tunggal sebagai keluaran proyektif satu dimensi. Model dikompilasi menggunakan optimasi *Adaptive Moment Estimation* (Adam) dengan laju pembelajaran (*learning rate*) 0,002. Fungsi kerugian (*loss function*) yang diminimalkan selama proses pembaruan bobot jaringan adalah *Mean Squared Error* (MSE). Proses pelatihan dikonfigurasi maksimum 100 *epochs* dengan ukuran *batch size* 32. Untuk menjaga efisiensi komputasi, diimplementasikan mekanisme *Early Stopping* dengan *patience* sebesar 10 berdasarkan pemantauan galat validasi (*val_loss*), yang secara dinamis akan menghentikan pelatihan dan merestorasi bobot arsitektur terbaik.

2.5 Optimasi Menggunakan Particle Swarm Optimization (PSO)

Tahap optimasi bertujuan untuk menemukan kombinasi *hyperparameter* optimal pada arsitektur LSTM secara otomatis guna menghindari kelemahan metode pencarian manual (*trial-and-error*) [26]. Algoritma *Particle Swarm Optimization* (PSO) digunakan untuk mengoptimasi tiga parameter utama dengan batasan ruang pencarian (*search space*): jumlah neuron [16, 128], *learning rate* [0,0001, 0,002], dan *batch size* [16, 64]. Penentuan rentang batas ruang pencarian ini tidak bersifat arbitrer, melainkan didasarkan pada uji coba pendahuluan (*preliminary trials*) untuk mengevaluasi konvergensi model serta merujuk pada praktik umum dan literatur optimasi LSTM terdahulu [26], [27]. Pendekatan ini diterapkan guna memberikan keseimbangan optimal antara kapasitas representasi memori arsitektur jaringan dengan efisiensi beban komputasi.

Konfigurasi *random seed* 11 (*set_seed* (11)) digunakan untuk menjaga stabilitas inisialisasi pada lingkungan komputasi saat eksperimen. Meskipun demikian, disadari bahwa penetapan nilai ini tidak menjamin reproduksibilitas absolut lintas perangkat keras (seperti CPU vs. GPU), mengingat adanya eksekusi operasi matriks paralel yang bersifat non-deterministik pada arsitektur GPU [28]. Selanjutnya, tahap optimasi menggunakan 10 partikel untuk 10 iterasi, dengan parameter $w = 0,7$ serta $c_1 = c_2 = 1,5$. Pembulatan nilai integer diterapkan secara dinamis pada dimensi *neuron* dan *batch size*. Setiap partikel dievaluasi melalui fungsi objektif berbasis *Validation MAPE* (*val_mape*) dari model LSTM sementara selama 30 *epochs* dengan *early stopping* (*patience* = 5). Pembaruan kecepatan (v) dan posisi (x) partikel pada setiap iterasi dihitung berdasarkan persamaan matematis berikut:

$$v_{id}^{t+1} = W \cdot v_{id}^t + C_1 \cdot r_1 \cdot (pbest_{id} - x_{id}^t) + C_2 \cdot r_2 (gbest_d - x_{id}^t) \quad (3)$$

$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1} \quad (4)$$

Dimana v_{id}^{t+1} dan v_{id}^t merepresentasikan kecepatan partikel I dimensi d pada iterasi $t + 1$ dan t ; x_{id}^{t+1} dan x_{id}^t adalah Posisi partikel i dimensi d pada iterasi $t + 1$ dan t ; W menyatakan bobot inersia (*inertia weight*); C_1 dan C_2 berturut-turut adalah koefisien akselerasi kognitif dan sosial; serta r_1 dan r_2 merupakan bilangan acak seragam pada interval [0,1]. Adapun $pbest_{id}$ dan $gbest_d$ masing-masing menyatakan posisi terbaik personal partikel i dan posisi terbaik global kawanan (*swarm*) pada dimensi d . Parameter terbaik (*Global Best*) yang kelak direkam pada akhir siklus konvergensi PSO selanjutnya diimplementasikan untuk membangun dan melatih model final PSO-LSTM. Pelatihan final ini dialokasikan maksimum 100 *epochs* dengan parameter *Early Stopping* (*patience* = 10) yang diukur berdasarkan penurunan *validation loss* secara keseluruhan.

2.6 Evaluasi Kinerja Model

Sebelum kalkulasi galat dilakukan, seluruh luaran prediksi dari model LSTM Baseline maupun PSO-LSTM dikonversi kembali ke satuan finansial aslinya (Rupiah per gram) melalui proses denormalisasi (*inverse transform*). Kinerja peramalan kemudian dievaluasi secara kuantitatif pada himpunan data uji (*test set*) menggunakan tiga metrik statistik deret waktu standar [29].

Metrik pertama adalah *Root Mean Squared Error* (RMSE) yang berfungsi untuk mengukur besaran galat (*error*) serta sensitivitas model terhadap galat ekstrem atau *outlier*. Semakin kecil nilai RMSE, semakin dekat nilai prediksi dengan nilai aktual. Perhitungan RMSE dirumuskan pada Persamaan (5).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

Metrik kedua adalah *Mean Absolute Error* (MAE). MAE mengukur rata-rata besaran absolut selisih antara luaran prediksi dengan nilai observasi aktual tanpa mempertimbangkan arah galat, baik positif maupun negatif. Perhitungan MAE dirumuskan pada Persamaan (6).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5)$$

Metrik ketiga adalah *Mean Absolute Percentage Error* (MAPE) yang bertindak sebagai indikator utama untuk mengetahui tingkat akurasi model dalam bentuk persentase relatif. MAPE sangat berguna dan memudahkan interpretasi kinerja model karena nilainya tidak bergantung pada skala besaran data aslinya. Perhitungan MAPE ditunjukkan pada Persamaan (7).

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (7)$$

Berdasarkan Persamaan (5), (6), dan (7) tersebut, variabel n merepresentasikan jumlah total data atau observasi pada himpunan data uji. Variabel y_i merupakan nilai aktual dari harga emas domestik pada pengamatan waktu ke- i , sedangkan $\hat{y}_i$ menunjukkan luaran nilai hasil peramalan atau prediksi dari model pada waktu ke- i . Adapun simbol Σ merupakan notasi matematika yang melambangkan operasi penjumlahan dari keseluruhan nilai selisih galat, yang dikalkulasi dari data pertama hingga data terakhir secara berurutan. Sebagai kriteria evaluasi akhir, model teroptimasi (PSO-LSTM) dinyatakan memiliki performa yang lebih baik apabila mampu menghasilkan nilai galat RMSE, MAE, dan MAPE yang lebih rendah dibandingkan dengan model dasar (LSTM Baseline).

Selain pengukuran besaran galat kuantitatif, penelitian ini juga mengimplementasikan uji signifikansi statistik *Diebold-Mariano* (DM) guna memastikan bahwa keunggulan performa model PSO-LSTM atas Baseline LSTM bukan sekadar variasi kebetulan pada sampel pengujian [30]. Uji DM secara spesifik membandingkan deret waktu galat sisa (*residual error*) dari kedua arsitektur model berdasarkan kriteria *Squared Error Loss*. Pengujian ini merumuskan hipotesis nol (H_0) bahwa tidak terdapat perbedaan tingkat akurasi peramalan yang nyata secara statistik antara kedua model, yang akan diuji terhadap hipotesis alternatif (H_1) bahwa terdapat perbedaan yang signifikan. Dengan menggunakan tingkat signifikansi (α) sebesar 0,05, hipotesis nol akan ditolak apabila pengujian menghasilkan nilai *p-value* kurang dari 0,05. Penolakan terhadap hipotesis nol tersebut akan menjadi landasan empiris yang membuktikan secara meyakinkan bahwa algoritma PSO teruji valid dalam meningkatkan kemampuan peramalan model LSTM dasar.

2.7 Interpretasi Keputusan Model Menggunakan SHAP

Guna mengatasi keterbatasan sifat *black-box* pada arsitektur *deep learning* yang berfokus pada minimalisasi galat, penelitian ini menerapkan metode *SHapley Additive exPlanations* (SHAP) sebagai pendekatan *Explainable AI* (XAI) [31]. Evaluasi ini bertujuan membongkar logika internal model dengan mengukur kontribusi marginal (*Shapley Value*) dari setiap fitur masukan multivariat (Gold_USD, Kurs_IDR, serta *lagged features*) terhadap hasil peramalan. Kalkulasi nilai kontribusi didasarkan pada persamaan (8):

$$\phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(|N|-|S|-1)!}{|N|!} [v(S \cup \{i\}) - v(S)] \quad (8)$$

Dimana ϕ_i merepresentasikan nilai kontribusi marginal (*Shapley value*) untuk fitur ke- i . Kalkulasi ini melibatkan N yang merupakan himpunan dari seluruh fitur masukan (lag jendela waktu), serta S yang mendefinisikan sub-himpunan (*subset*) fitur tanpa melibatkan fitur ke- i ($S \subseteq N \setminus \{i\}$). Komponen $|S|!$, $|N|!$ masing-masing menunjukkan nilai faktorial dari jumlah elemen pada subset S dan total elemen pada himpunan N . Terakhir, selisih output prediksi model ketika menyertakan fitur ke- i dibandingkan dengan tanpa menyertakan fitur tersebut diformulasikan secara matematis melalui komponen $v(S \cup \{i\}) - v(S)$.

Guna mengoptimalkan beban komputasi dalam menghitung nilai ekspektasi marginal SHAP pada data *time-series*, diterapkan teknik *K-Means background reduction* pada data latih yang telah dinormalisasi. Algoritma K-Means dikonfigurasi menggunakan metode inisialisasi *k-means++* dan *random state* 11 untuk merangkum seluruh observasi data latih menjadi 50 sentroid berbobot (*weighted centroids*, $k = 50$) sebagai *background dataset* [32]. Penentuan jumlah kluster $k = 50$ didasarkan pada pertimbangan analisis sensitivitas awal, di mana $k = 50$ dinilai memadai dalam menjaga representasi variansi distribusi ruang fitur serta kestabilan estimasi nilai Shapley, tanpa menimbulkan beban komputasi berlebih seperti pada penggunaan *full background dataset*. Hasil kalkulasi SHAP selanjutnya divisualisasikan melalui *Summary Plot* untuk mengidentifikasi tingkat urgensi fitur, serta *Dependence Plot* untuk memetakan arah hubungan korelasi antara variabel ekonomi global dan domestik terhadap proyeksi harga emas.

3. HASIL DAN PEMBAHASAN


Bab ini menyajikan hasil eksperimen dan pembahasan mengenai peramalan harga emas domestik menggunakan pemodelan *Long Short-Term Memory* (LSTM) yang dioptimasi berbasis *Particle Swarm Optimization* (PSO). Seluruh alur eksperimen dipaparkan secara sistematis mengikuti kerangka kerja CRISP-DM yang telah dirancang. Pembahasan mencakup empat tahapan utama, diawali dari analisis eksplorasi dan prapemrosesan data, pembentukan model baseline serta hasil pencarian hyperparameter optimal oleh PSO, evaluasi kinerja komparatif pada data uji, hingga interpretasi transparansi keputusan model menggunakan *SHapley Additive exPlanations* (SHAP).

3.1 Hasil Analisis Eksplorasi dan Prapemrosesan Data


Eksplorasi data awal dilakukan untuk memahami karakteristik pergerakan tren historis target Harga Emas Domestik (Harga_IDR) yang dibentuk dari konversi variabel Gold_USD dan Kurs_IDR, seperti disajikan pada Gambar 2.

Berdasarkan matriks korelasi Pearson seperti disajikan pada Gambar 3, fitur harga emas global (*Gold_USD*) memiliki korelasi positif yang nyaris sempurna terhadap harga emas domestik (*Harga_IDR*) dengan nilai $r = 0,997$. Sementara itu, nilai tukar (*Kurs_IDR*) juga menunjukkan korelasi positif yang kuat dengan nilai $r = 0,860$. Hal ini

mengonfirmasi bahwa kedua variabel eksternal tersebut sangat relevan dan valid untuk digunakan sebagai prediktor dalam pemodelan LSTM.



Gambar 2. Grafik Pergerakan Tren Historis Harga Emas Domestik (2020–2026).



Gambar 3. Heatmap Matriks Korelasi Pearson Antarvariabel Masukan dan Target.

Pada tahap pembersihan data, ditemukan 60 baris celah data kosong (*missing values*) akibat diskrepansi libur pasar komoditas global dan valuta asing domestik. Celah tersebut berhasil dipulihkan secara tepat menggunakan metode interpolasi linear. Dataset kemudian dipartisi secara temporal tanpa pengacakan dengan rasio 70% data latih, 20% data validasi, dan 10% data uji. Selanjutnya, dilakukan normalisasi fitur ke dalam rentang $[0, 1]$ menggunakan *MinMaxScaler*, di mana proses *fitting* dilakukan secara eksklusif hanya pada data latih guna mencegah kebocoran data (*data leakage*). Tahap akhir prapemrosesan dilanjutkan dengan transformasi *sequence windowing* (observasi 7 hari ke belakang) yang menghasilkan formasi tensor 3D yang siap diumpankan ke arsitektur LSTM, seperti dirangkum pada Tabel 2.

Tabel 2. Rincian Pemisahan Data Temporal dan Dimensi Tensor Masukan

Partisi Data	Jumlah Observasi	Dimensi Tensor Input	Dimensi Target
Data Latih 70%	1.202	(1195,7,3)	(1195,1)
Data Validasi 20%	344	(337,7,3)	(337,1)
Data Uji 10%	172	(165,7,3)	(165,1)

3.2 Hasil Pemodelan dan Optimasi Hyperparameter (PSO-LSTM)

Pemodelan diawali dengan menguji arsitektur *Baseline LSTM* menggunakan konfigurasi standar (64 *neuron*, *Dropout* 0,2, *learning rate* 0,002, dan *batch size* 32). Selanjutnya, algoritma *Particle Swarm Optimization* (PSO) dieksekusi menggunakan 10 partikel selama 10 iterasi dengan parameter bobot inersia $w = 0,7$ serta koefisien akselerasi $c_1 = c_2 = 1,5$. Proses pencarian oleh kawanan partikel PSO menghasilkan kombinasi parameter terbaik (*gbest*) dengan


minimum Validation MAPE sebesar 2,04% (2,0352%). Perbandingan konfigurasi antara model *Baseline* LSTM dan hasil optimasi PSO dirangkum pada Tabel 3.

Tabel 3. Komparasi Konfigurasi Parameter Baseline dan Hasil Optimasi PSO

Parameter	Search Space	Baseline	Dimensi Target
Jumlah Neuron	[16, 128]	64	128
Learning Rate	[0,0001, 0,002]	0,002	0,0020
Ukuran Batch	[16, 64]	32	16
Validation Mape	Minimasi	-	2,0352%

Berdasarkan Tabel 3, hasil optimasi PSO menunjukkan bahwa peningkatan kapasitas neuron hingga 128 unit serta penggunaan *batch size* yang lebih kecil (16) mampu mengekstrak pola sekuensial deret waktu secara lebih presisi. Penggunaan *learning rate* 0,0020 yang berada pada batas atas ruang pencarian PSO terbukti mempercepat konvergensi pembaruan bobot jaringan tanpa memicu *overshooting*. Parameter *gbest* ini selanjutnya diimplementasikan penuh untuk melatih model final PSO-LSTM.

Dengan kombinasi parameter *gbest* tersebut, model final PSO-LSTM dilatih kembali menggunakan mekanisme *Early Stopping* dengan *patience* = 10 untuk mencegah *overfitting*. Pelatihan berhenti secara otomatis pada *epoch* ke-19 setelah nilai *loss* validasi mencapai titik konvergensi terstabil, seperti disajikan pada Gambar 4.



Gambar 4. Kurva Loss Pelatihan Model Final PSO-LSTM

Berdasarkan Gambar 4, terlihat bahwa nilai *training loss* dan *validation loss* mengalami penurunan drastis pada *epoch* awal dan melandai secara stabil mendekati nol tanpa menunjukkan celah diskrepansi yang lebar (*gap*). Hal ini membuktikan bahwa arsitektur PSO-LSTM yang terbentuk bebas dari masalah *underfitting* maupun *overfitting*.

3.3 Evaluasi Kinerja Model dan Analisis Komparatif

Setelah model Baseline LSTM dan PSO-LSTM selesai dilatih, pengujian dilakukan pada data uji (*test set*) sebanyak 165 observasi sekuensial yang belum pernah dilihat oleh model selama proses pelatihan. Performa peramalan dari kedua model diukur menggunakan metrik *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Ringkasan hasil evaluasi komparatif disajikan pada Tabel 4.

Tabel 4. Perbandingan Evaluasi Model Baseline LSTM dan PSO-LSTM pada Data Uji


Parameter	RMSE (IDR)	MAE(IDR)	MAPE(IDR)	DM Statistic	<i>p</i> -value
Baseline LSTM	Rp 91.907,03	Rp 78.633,78	3,03%	Ref.	Ref.
PSO-LSTM	Rp 78.633,78	Rp 67.565,70	2,62%	8,2098	< 0,0001

Berdasarkan Tabel 4, model PSO-LSTM terbukti secara konsisten mengungguli arsitektur Baseline LSTM pada seluruh metrik evaluasi data uji. Pengoptimalan hyperparameter melalui algoritma PSO berhasil menekan nilai RMSE dari Rp 91.907,03 menjadi Rp 81.151,47 (penurunan galat sebesar 11,70%), serta menurunkan nilai MAE dari Rp 78.633,78 menjadi Rp 67.565,70 (penurunan galat sebesar 14,08%). Ditinjau dari metrik MAPE, model PSO-LSTM mencapai tingkat galat relatif sebesar 2,62%, lebih unggul dibandingkan Baseline LSTM yang mencatatkan 3,03%. Nilai MAPE yang berada jauh di bawah ambang batas 10% ini mengategorikan performa peramalan model PSO-LSTM ke dalam kriteria sangat akurat (*very accurate forecasting*).

Guna memastikan bahwa penurunan galat pada sampel data uji bernilai signifikan, pengujian signifikansi statistik dilakukan menggunakan Diebold-Mariano (DM) Test. Hasil pengujian menghasilkan nilai statistik *DM* =

8,2098 dengan $p\text{-value} < 0,0001$ ($p < 0,05$). Karena nilai $p\text{-value}$ berada jauh di bawah tingkat signifikansi $\alpha = 0,05$, maka hipotesis nol (H_0) ditolak secara meyakinkan. Nilai statistik DM positif (+8,2098) mengonfirmasi bahwa akumulasi galat pada model Baseline LSTM secara signifikan lebih besar dibandingkan model PSO-LSTM. Hal ini memberikan bukti empiris yang kuat bahwa keunggulan akurasi peramalan model PSO-LSTM bersifat signifikan secara statistik, sekaligus memvalidasi ketahanan model dalam memetakan pergerakan harga emas yang fluktuatif.

Untuk memberikan gambaran visual mengenai kemampuan model dalam mengikuti pergerakan harga aktual, perbandingan kurva peramalan kedua model pada data uji disajikan pada Gambar 5.




Gambar 5. Grafik Perbandingan Harga Emas Aktual dengan Peramalan Baseline LSTM dan PSO-LSTM

Visualisasi pada Gambar 5 menunjukkan bahwa prediksi model PSO-LSTM (garis hijau solid) memiliki simpangan yang lebih kecil terhadap pergerakan tren harga aktual dibandingkan arsitektur *baseline* (garis putus-putus merah). Sepanjang periode pengujian, lintasan prediksi PSO-LSTM secara konsisten lebih mendekati nilai sebenarnya (*ground truth*), baik pada saat tren harga naik maupun turun. Pada fase lonjakan harga ekstrem antara hari ke-25 hingga ke-60, model belum sepenuhnya mampu memprediksi titik puncak absolut dari harga aktual. Kondisi ini mengindikasikan bahwa arsitektur LSTM mempertahankan batasan bobot (*weight constraints*) untuk meminimalisasi risiko *overfitting* saat merespons anomali nilai yang melampaui distribusi data latih. Meskipun terdapat deviasi pada titik-titik puncak tersebut, optimasi PSO terbukti mampu mereduksi galat dari model *baseline*, sehingga sistem hibrida ini menghasilkan akurasi pemetaan tren yang lebih baik secara keseluruhan.

3.4 Interpretabilitas Fitur Menggunakan SHapley Additive exPlanations (SHAP)

Analisis *Explainable AI* (XAI) menerapkan metode SHAP (*SHapley Additive exPlanations*) untuk membongkar sifat *black-box* dari model PSO-LSTM. Metode ini mengukur kontribusi marginal serta tingkat urgensi dari masing-masing variabel masukan (Gold_USD), (Kurs_IDR), dan historis (Harga_IDR) terhadap pembentukan nilai peramalan harga emas domestik pada data uji. Hasil pemetaan kontribusi dan tingkat signifikansi dari masing-masing fitur tersebut divisualisasikan secara lebih rinci pada Gambar 6.



Gambar 6. Visualisasi Rata-rata Kontribusi Fitur Berdasarkan Nilai Absolut SHAP

Berdasarkan grafik rata-rata dampak absolut nilai SHAP (mean |SHAP value|) pada Gambar 6, hierarki kontribusi variabel masukan terhadap hasil peramalan harga emas menunjukkan bahwa prediktor paling dominan ditempati oleh variabel Harga_IDR (harga emas domestik) dengan nilai rata-rata kontribusi absolut tertinggi sebesar 0,0773. Hal ini menunjukkan bahwa pola sekuensial tren harga lokal sebelumnya menjadi pijakan utama jaringan

LSTM dalam memproyeksikan harga mendatang. Kontribusi sekunder yang signifikan disusul oleh variabel Kurs_IDR (nilai tukar Rupiah terhadap Dolar AS) dengan nilai sebesar 0,0350. Peran nilai tukar ini terbukti krusial karena perubahan fluktuasi valuta asing secara langsung memengaruhi penyesuaian nilai konversi komoditas emas di pasar domestik. Pada urutan terakhir, variabel Gold_USD (harga emas pasar global) mencatatkan nilai sebesar 0,0051. Meskipun dampaknya secara langsung lebih kecil dibandingkan kedua variabel sebelumnya, masukan harga global tersebut tetap memberikan basis acuan tren internasional yang esensial bagi model peramalan.

Secara keseluruhan, analisis SHAP mengonfirmasi bahwa transparansi keputusan model PSO-LSTM sangat rasional dan hierarkis. Penilaian model didominasi mutlak oleh memori harga lokal (0,0773), yang kontribusinya 120% lebih besar (2,2 kali lipat) dibandingkan penyesuaian nilai tukar domestik (0,0350). Lebih jauh, pengaruh dominan harga lokal ini memiliki jarak yang ekstrem hingga 15 kali lipat jika dibandingkan dengan dampak langsung harga emas global (0,0051). Kesenjangan (*gap*) signifikansi ini sangat logis dan sejalan dengan realitas pasar Indonesia, di mana tren historis lokal dan fluktuasi kurs bertindak sebagai penggerak responsif harga harian, sementara pergerakan harga global lebih berfungsi sebagai sentimen latar yang dampaknya sering kali telah terserap oleh dinamika valuta asing.

3.5 Pembahasan

Hasil evaluasi kinerja menunjukkan bahwa model hibrida PSO-LSTM yang diusulkan mencapai tingkat akurasi peramalan dengan nilai MAPE sebesar 2,62% dan menekan galat MAE sebesar 14,08% dibandingkan model LSTM baseline. Selain evaluasi performa prediksi, integrasi metode *Explainable AI* (XAI) melalui SHAP berbasis reduksi background K-Means memberikan penjelasan pada model black-box dengan mengkuantifikasi kontribusi masing-masing variabel prediktor secara lebih terukur.

Bila dibandingkan dengan temuan penelitian terdahulu, hasil penelitian ini menunjukkan peningkatan dalam hal optimasi parameter dan evaluasi galat peramalan. Dibandingkan dengan penelitian Adha et.al. [7] yang menggunakan LSTM konvensional dengan konfigurasi parameter manual, penelitian ini mengindikasikan bahwa penerapan metaheuristik PSO dapat mengurangi subjektivitas penentuan parameter dan membantu menghasilkan nilai galat yang lebih rendah pada rentang data observasi. Selanjutnya, jika dibandingkan dengan studi Aprianto dkk. [11] yang menerapkan PSO-LSTM pada data aset kripto dengan penurunan MAE sebesar 11,78%, pemodelan PSO-LSTM pada peramalan harga emas multivariat periode 2020–2026 dalam penelitian ini mencatatkan penurunan error MAE sebesar 14,08%, sekaligus memperlihatkan kemampuan adaptasi model terhadap fluktuasi data pada periode krisis.

Dari perspektif keterjelasan model (*explainability*), penelitian ini juga berupaya melengkapi kajian XAI terdahulu pada domain finansial. Penelitian ini mengisi batasan pada studi Çelik dkk. [12] yang menyoroti pentingnya transparansi XAI pada pemodelan finansial namun belum mengintegrasikannya secara langsung dengan optimasi *deep learning* sekuensial. Selain itu, berbeda dengan penelitian Syamkalla dkk. [14] yang mengimplementasikan SHAP pada algoritma non-sekuensial (CatBoost), penelitian ini mengimplementasikan pendekatan SHAP pada arsitektur sekuensial hibrida PSO-LSTM.

Melalui penerapan metode SHAP tersebut, penelitian ini dapat memetakan dinamika kontribusi variabel prediktor pada pemodelan data finansial domestik. Analisis SHAP secara kuantitatif menunjukkan bahwa memori harga emas lokal secara historis memiliki proporsi kontribusi prediktif yang lebih dominan dalam pembentukan harga emas domestik saat ini, yang kemudian disusul oleh faktor dinamika nilai tukar USD/IDR dan pergerakan harga emas global.

4. KESIMPULAN

Secara keseluruhan, penelitian ini memberikan tiga kontribusi utama bagi pengembangan ilmu pengetahuan dan praktik pemodelan data finansial. Pertama, secara metodologis, penelitian ini berhasil merancang model peramalan multivariat yang presisi dan transparan dengan mengintegrasikan otomatisasi hyperparameter PSO dan metode XAI berbasis SHAP ke dalam arsitektur sekuensial LSTM. Kedua, secara empiris, optimasi PSO terbukti mereduksi tingkat galat secara signifikan dibandingkan baseline konvensional, membuktikan ketahanan (*robustness*) model dalam meredam bias pada data historis. Ketiga, secara praktis, analisis SHAP memberikan sintesis penting bagi dinamika pasar domestik: memori harga historis emas lokal terbukti sebagai prediktor yang jauh lebih dominan dalam pembentukan harga dibandingkan fluktuasi nilai tukar USD/IDR maupun harga emas global secara langsung. Implikasi dari temuan ini memberikan landasan empiris bagi investor dan pembuat kebijakan bahwa strategi lindung nilai (*hedging*) yang efektif sebaiknya lebih menitikberatkan pada analisis tren harga lokal daripada sekadar reaktif terhadap sentimen global. Meskipun berkinerja tinggi pada kondisi normal, penelitian ini secara terbuka mengakui sebuah keterbatasan fundamental; model *deep learning* ini sangat bergantung pada distribusi data historis dan rentan mengalami kegagalan prediksi apabila dihadapkan pada volatilitas sistemik pasar atau guncangan ekonomi ekstrem di luar rentang data latih. Oleh karena itu, riset lanjutan mendesak untuk mengintegrasikan teknik dekomposisi sinyal seperti Variational Mode Decomposition (VMD) atau mekanisme Attention, serta memasukkan indikator makroekonomi eksternal guna memperkuat resiliensi model terhadap anomali pasar yang tidak terduga.

5. PERNYATAAN PENULIS

5.1 Kontribusi Penulis

Konseptualisasi: F. A.;

Metodologi: F. A.;

Perangkat Lunak: F. A.;

Validasi: F. A.;

Analisis Formal: F. A.;

Investigasi: F. A.;

Sumber Daya: F. A.;

Kurasi Data: F. A.;

Penulisan Draf Awal: F. A.;

Penulisan, Peninjauan, dan Penyuntingan: F. A., N. D. S., dan A. T. J. H.;

Visualisasi: F. A.;

Seluruh penulis telah membaca dan menyetujui versi manuskrip yang telah diterbitkan.

5.2 Ketersediaan Data

Data historis pergerakan harga emas dan kurs USD/IDR yang disajikan dalam penelitian ini bersumber dari data publik (Yahoo Finance) dan dataset hasil prapemrosesan tersedia berdasarkan permintaan kepada penulis korespondensi.

5.3 Pendanaan

Penelitian ini tidak menerima hibah pendanaan eksternal dari instansi pemerintah maupun swasta.

5.4 Pernyataan Dewan Peninjau Institusional

Tidak Berlaku (*Not applicable*).

5.5 Pernyataan Persetujuan Berdasarkan Informasi

Tidak Berlaku (*Not applicable*).

5.6 Pernyataan Konflik Kepentingan

Para penulis menyatakan bahwa mereka tidak memiliki kepentingan keuangan yang bersaing atau hubungan pribadi yang diketahui yang dapat dianggap memengaruhi pekerjaan yang dilaporkan dalam artikel ini.

5.7 Penggunaan AI Generatif dan Teknologi Berbantuan AI dalam Proses Penulisan

Para penulis menggunakan teknologi AI Generatif secara terbatas murni untuk membantu meningkatkan kejelasan penulisan teks, penyusunan struktur narasi, dan perbaikan tata bahasa (*copyediting*) dalam artikel ini. Para penulis telah membaca, meninjau, dan menyunting ulang seluruh konten yang dihasilkan secara manual, serta bertanggung jawab penuh atas keakuratan, orisinalitas, dan versi akhir publikasi.

REFERENCES

- [1] Fathoni, M. Aziiz Irwansyah, A. Triana, E. Darmayanti Simanullang, Y. Nur Alinda, and A. Ibrahim, "Prediksi Harga dan Volatilitas Emas Dunia Harian: Perbandingan Model GARCH dan Long Short-Term Memory," *Zo. J. Sist. Inf.*, vol. 7, no. 2, May 2025, doi: <https://doi.org/10.31849/zn.v7i2.26764>.
- [2] Y. Eka Herliana and R. Sofia, "Pengaruh Inflasi, Suku Bunga, dan Nilai Tukar Terhadap Harga Emas di Indonesia Tahun 2025," *JMA*, vol. 4, no. 5, pp. 3031–5220, 2026, doi: <https://doi.org/10.62281/2a8b1d94>.
- [3] C. Gharib, S. Mefteh-Wali, and S. Ben Jabeur, "The Bubble Contagion Effect of COVID-19 Outbreak: Evidence from Crude Oil and Gold Markets," *Financ. Res. Lett.*, vol. 38, p. 101703, Jan. 2021, doi: 10.1016/j.frl.2020.101703.
- [4] P. Wang, X. Zheng, G. Ai, D. Liu, and B. Zhu, "Time Series Prediction for the Epidemic Trends of COVID-19 Using the Improved LSTM Deep Learning Method: Case Studies in Russia, Peru and Iran," *Chaos, Solitons and Fractals*, vol. 140, p. 110214, Nov. 2020, doi: 10.1016/j.chaos.2020.110214.
- [5] M. Mroua and A. Lamine, "Financial Time Series Prediction Under Covid-19 Pandemic Crisis With Long Short-Term Memory (LSTM) Network," *Humanit. Soc. Sci. Commun.*, vol. 10, no. 1, Dec. 2023, doi: 10.1057/s41599-023-02042-w.
- [6] C. Alkahfi, A. Kurnia, and A. Saefuddin, "Perbandingan Kinerja Model Berbasis RNN pada Peramalan Data Ekonomi dan Keuangan Indonesia," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 4, pp. 1235–1243, Jul. 2024, doi: 10.57152/malcom.v4i4.1415.
- [7] D. A. Adha, A. Ramadhan, H. Maulana, P. P. H. Harahap, and E. Ismanto, "Peramalan Harga Emas Berbasis Time Series Menggunakan Arsitektur LSTM Deep Learning," *J. CoSciTech (Computer Sci. Inf. Technol.)*, vol. 6, no. 2, pp. 329–336, Sep. 2025, doi: 10.37859/coscitech.v6i2.9980.
- [8] N. Syahputri and O. Alfina, "Optimasi Kinerja Model LeNet Berbasis Deep Learning untuk Klasifikasi Citra Menggunakan Pendekatan Hyperparameter Tuning," *J. Comput. Sci. Inf. Technol.*, vol. 6, no. 2, 2026, doi: 10.47065/explorer.v6i2.2670.
- [9] T. M. Shami, A. A. El-Saleh, M. Alswaiti, Q. Al-Tashi, M. A. Summakieh, and S. Mirjalili, "Particle Swarm Optimization: A Comprehensive Survey," *IEEE Access*, vol. 10, pp. 10031–10061, 2022, doi: 10.1109/ACCESS.2022.3142859.

- [10] A. Pranolo *et al.*, “Exploring LSTM-Based Attention Mechanisms with PSO and Grid Search under Different Normalization Techniques for Energy Demands Time Series Forecasting,” *Knowl. Eng. Data Sci.*, vol. 7, no. 1, pp. 1–12, Apr. 2024, doi: 10.17977/um018v7i12024p1-12.
- [11] K. Aprianto, U. Mahdiyah, and R. Wulanningrum, “Analisis Perbandingan Model PSO-LSTM dan LSTM Konvensional untuk Prediksi Harga Bitcoin di Market Cryptocurrency,” *SEMNAS INOTEK (Seminar Nas. Inov. Teknol.)*, vol. 9, pp. 1733–1742, 2025, doi: <https://doi.org/10.29407/71q6xr58>.
- [12] T. B. Çelik, Ö. İcan, and E. Bulut, “Extending Machine Learning Prediction Capabilities by Explainable AI in Financial Time Series Prediction,” *Appl. Soft Comput.*, vol. 132, p. 109876, Jan. 2023, doi: 10.1016/j.asoc.2022.109876.
- [13] A. Barredo Arrieta *et al.*, “Explainable Artificial Intelligence (XAI): Concepts, Taxonomies, Opportunities and Challenges Toward Responsible AI,” *Inf. Fusion*, vol. 58, pp. 82–115, Jun. 2020, doi: 10.1016/j.inffus.2019.12.012.
- [14] M. Teddy Syamkalla, S. Khomsah, and Y. Setiya Rafika Nur, “Implementasi Algoritma Catboost dan Shapley Additive Explanations (SHAP) dalam Memprediksi Popularitas Game Indie pada Platform Steam,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 4, pp. 777–786, Aug. 2024, doi: 10.25126/jtiik.1148503.
- [15] N. S. Aji, F. Natsir, and S. Istianah, “Penentuan Penjualan Barang Berdasarkan Pengelompokan Produk dengan K-Means Clustering Metode CRISP-DM pada CV.Sembako Dina,” *J. Zetroem*, vol. 5, no. 2, 2023, doi: <https://doi.org/10.36526/ztr.v5i2.3041>.
- [16] 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,” *Fakt. Exacta*, vol. 18, no. 2, p. 183, Oct. 2025, doi: 10.30998/faktorexacta.v18i2.26841.
- [17] A. H. Nababan, R. Nauli, L. Gaol, and F. Rahmadhani, “Pemodelan Biaya Sewa pada Data Pendidikan Internasional Menggunakan Pendekatan Machine Learning dan CRISP-DM,” *Bull. Inf. Technol.*, vol. 7, no. 1, pp. 22–30, 2026, doi: 10.47065/bit.v5i2.2557.
- [18] Yahoo Finance, “Gold (GC=F) and USD/IDR (IDR=X) Historical Data,” Yahoo Finance. Accessed: Sep. 05, 2026. [Online]. Available: <https://finance.yahoo.com/>
- [19] D. K. Sari, I. Kresna, and D. D. Septiani, “Penerapan Fuzzy Time Series Markov Chain dalam Peramalan Harga Cabai Merah Berbasis Data Harian di Kabupaten Banyumas,” *Euler J. Ilm. Mat. Sains dan Teknol*, vol. 14, no. 2, pp. 321–332, 2026, doi: 10.37905/euler.v14i2.37987.
- [20] D. Fatikasari, M. Walid, Muhsni, and M. A. Hamzah, “Comparative Evaluation of Random Forest, GRU, and Transformer Models for Soil Moisture Prediction Using Reanalysis and Meteorological Time Series Data,” *J. Soft Comput. Explor.*, vol. 7, no. 2, pp. 300–311, May 2026, doi: 10.52465/josce.v7i2.54.
- [21] A. Pradasyah and A. Baita, “Comparative Study of Support Vector Regression and Long Short-Term Memory for Stock Price Prediction,” *J. Appl. Informatics Comput.*, vol. 9, no. 4, p. 1301, 2025, doi: <https://doi.org/10.30871/jaic.v9i4.9425>.
- [22] M. K. Najib and S. Nurdianti, “Pemodelan Deret Waktu Menggunakan Non-linear Autoregressive Neural Network: Studi Kasus Prediksi Harga Saham Mandiri,” *Jambura J. Math.*, vol. 7, no. 2, pp. 213–220, Aug. 2025, doi: 10.37905/jjom.v7i2.33397.
- [23] A. Ichwani, R. Indra Kesuma, A. Setiawan, E. Wicaksono, and R. Hanifah, “Preventing Data Leakage in Classification via Integrated Machine Learning Pipelines: Preprocessing, Feature Transformation, and Hyperparameter Tuning,” *J. Tek. Inform.*, vol. 7, no. 1, pp. 391–410, 2026, doi: <https://doi.org/10.52436/1.jutif.2026.7.2.5490>.
- [24] A. Rahmawati, W. Sulandari, S. Subanti, and Y. Yudhanto, “Penerapan Metode Recurrent Neural Network dengan Pendekatan Long Short-Term Memory (LSTM) untuk Meramalkan Harga Saham Hybe Corporation,” *J. Bumigora Inf. Technol.*, vol. 5, no. 1, pp. 65–76, 2023, doi: 10.30812/bite/v5i1.2973.
- [25] Oktavian M.D.S, R. Parlita, and F.P. Aditiawan, “Analisis Studi Literatur: Perbandingan Model Prediksi Harga Bitcoin Berbasis Long Short-Term Memory (LSTM),” *Semin. Nas. Inform. Bela Negara*, vol. 5, no. 2, 2025, Accessed: Sep. 17, 2026. [Online]. Available: <https://santika.upnjatim.ac.id/submissions/index.php/santika/article/view/879>
- [26] Wilson Wiranata and Yohanes Calvinus, “Optimasi Prediksi Sisa Umur Penggunaan Baterai dengan Model PSO-LSTM,” *Electron J. Ilm. Tek.*, vol. 6, no. 1, Mar. 2025, doi: <https://doi.org/10.33019/electron.v6i1.242>.
- [27] J. F. Ruma, M. S. G. Adnan, A. Dewan, and R. M. Rahman, “Particle Swarm Optimization Based LSTM Networks for Water Level Forecasting: A Case Study on Bangladesh River Network,” *Results Eng.*, vol. 17, p. 100951, Mar. 2023, doi: <https://doi.org/10.1016/j.rineng.2023.100951>.
- [28] TensorFlow Developers, “Determinism in TensorFlow,” TensorFlow Documentation. Accessed: Sep. 15, 2026. [Online]. Available: https://www.tensorflow.org/api_docs/python/tf/config/experimental/enable_op_determinism
- [29] T. A. D. Kurniawan, A. Setiawan, and F. Tita, “Perbandingan Kinerja Metode Support Vector Regression dan Metode Regresi Linier Berganda dalam Memprediksi BMI pada Dataset ASTHMA,” *J. Sains dan Edukasi Sains*, vol. 8, no. 2, pp. 133–142, Aug. 2025, doi: 10.24246/juses.v8i2p133-142.
- [30] R. Roshanpour, M. Parsanejad, and M. S. Pishvae, “Differential LSTM (D-LSTM): Integrating Differential Operators Into LSTM Cells for Financial Time-Series Forecasting,” *IEEE Access*, vol. 14, pp. 21674–21705, Feb. 2026, doi: 10.1109/ACCESS.2026.3662286.
- [31] Aditia Ananda Sutrisno, Ahmad Abdul Chamid, and R. Meimaharani, “Klasifikasi Risiko Gagal Bayar Kredit Menggunakan XGBoost dengan Model Explainable Berbasis SHAP,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 10, no. 1, Feb. 2026, doi: <https://doi.org/10.36040/jati.v10i1.16673>.
- [32] G. Ranjbaran, D. R. Recupero, C. K. Roy, and K. A. Schneider, “C-SHAP: A Hybrid Method for Fast and Efficient Interpretability,” *Appl. Sci.*, vol. 15, no. 2, Jan. 2025, doi: 10.3390/app15020672.