

Prediksi Kurs Rupiah terhadap Dolar dan Yuan Menggunakan LSTM-PSO dan XGBoost

Oktaria Indi Cahyani¹, Joan Angelina Widians², Fahrul Agus³

¹Program Studi Informatika, Universitas Mulawarman, oktariaindi@gmail.com

²Program Studi Magister Informatika, Universitas Mulawarman, angelwidians@gmail.com

³Program Studi Informatika, Universitas Mulawarman, fahrulagus@unmul.ac.id

Keywords:

Geopolitical Risk Daily, LSTM, Particle Swarm Optimization, Time Series Forecasting, XGBoost.

ABSTRACT

The Indonesian rupiah exchange rate is a key determinant of Indonesia's economic conditions and is vulnerable to global geopolitical dynamics, yet geopolitical risk is still rarely incorporated explicitly into exchange rate forecasting models. This study compares the accuracy of XGBoost and Long Short-Term Memory optimized with Particle Swarm Optimization (LSTM-PSO) in forecasting IDR/USD and IDR/CNY, using the Geopolitical Risk Daily (GPRD) index as an external predictor. The dataset comprises daily IDR/USD, IDR/CNY, and GPRD observations from February 2022 to February 2026. The workflow includes data collection, cleaning, and integration, feature engineering, normalization, chronological data splitting, and model evaluation using RMSE, MAE, MAPE, and R^2 . Under the tested scenario, LSTM-PSO yielded lower errors than XGBoost for both currency pairs, with a MAPE below 1% and an R^2 above 0.89, whereas XGBoost produced a negative R^2 . These findings indicate the potential of LSTM-PSO as an exchange rate forecasting model that incorporates geopolitical risk information, and may serve as a consideration for banks, investors, and international businesses in monitoring exchange rate movements.

Kata Kunci:

Geopolitical Risk Daily, LSTM, Particle Swarm Optimization, Peramalan Deret Waktu, XGBoost.

ABSTRAK

Kurs rupiah merupakan salah satu penentu kondisi ekonomi Indonesia dan rentan terhadap dinamika geopolitik global, tetapi aspek ini masih jarang dilibatkan secara eksplisit dalam pemodelan prediksi nilai tukar. Studi ini membandingkan akurasi XGBoost dan LSTM yang dioptimasi dengan *Particle Swarm Optimization* (LSTM-PSO) dalam memprediksi IDR/USD dan IDR/CNY dengan *Geopolitical Risk Daily* (GPRD) sebagai variabel prediktor eksternal. Data harian IDR/USD, IDR/CNY, dan GPRD mencakup periode Februari 2022 hingga Februari 2026. Tahapan studi meliputi pengumpulan, pembersihan, dan integrasi data, rekayasa fitur, normalisasi, pembagian data berdasarkan urutan waktu, serta evaluasi dengan RMSE, MAE, MAPE, dan R^2 . Pada skenario pengujian ini, LSTM-PSO menghasilkan galat lebih rendah daripada XGBoost pada kedua pasangan kurs, dengan MAPE kurang dari 1% dan R^2 di atas 0,89, sedangkan XGBoost menghasilkan R^2 negatif. Temuan ini menunjukkan potensi LSTM-PSO sebagai model prediksi kurs yang menggunakan informasi risiko geopolitik, dan dapat menjadi bahan pertimbangan bagi perbankan, investor, dan pelaku usaha lintas negara dalam memantau perubahan kurs.

Korespondensi Penulis:

Joan Angelina Widians,
Universitas Mulawarman, Samarinda
Telfon: +6282144911888
Email: angelwidians@unmul.ac.id

Submitted : 10-09-2026; Accepted : 12-10-2026;
Published : 13-10-2026

Copyright (c) 2026 The Author (s) This article is distributed under a Creative Commons Attribution-ShareAlike 4.0 International License (CC BY-SA 4.0)

1. PENDAHULUAN

Sebagai salah satu variabel makroekonomi yang paling menentukan, kurs mata uang memberi pengaruh langsung terhadap laju inflasi, kondisi neraca perdagangan, dan laju pertumbuhan ekonomi suatu negara [1]. Dalam konteks Indonesia yang menganut sistem perekonomian terbuka, dua pasangan kurs yang memegang peranan paling strategis adalah IDR/USD dan IDR/CNY, karena keduanya menggambarkan ketergantungan ekonomi domestik terhadap dua mitra dagang terbesar, yaitu Amerika Serikat dan Tiongkok [2]. Kurs IDR/USD selama ini menjadi rujukan utama pasar valas domestik sekaligus indikator kepercayaan investor asing, sedangkan IDR/CNY kian relevan sejalan dengan nilai perdagangan bilateral Indonesia-Tiongkok yang telah menembus angka USD 127 miliar pada

2022, menempatkan Tiongkok sebagai mitra dagang terbesar Indonesia selama lebih dari sepuluh tahun terakhir [3]. Kendati begitu, kajian yang mengkaji kedua pasangan kurs tersebut secara simultan masih jarang dijumpai, sehingga gambaran komparatif mengenai respons masing-masing kurs terhadap guncangan dari luar belum banyak terungkap dalam literatur yang ada.

Salah satu faktor eksternal yang justru sering luput dari pemodelan prediktif adalah dinamika geopolitik global. Konflik Rusia–Ukraina yang dimulai Februari 2022 memicu kenaikan harga energi global hingga 50% dan harga pangan sebesar 20%, mendorong inflasi kawasan ASEAN dari 3,1% pada 2021 menjadi 4,7% pada 2022 [4]. Ketegangan di Timur Tengah, termasuk konflik Iran–Amerika Serikat, menambah lapisan ketidakpastian pada pasar keuangan internasional. Geopolitik bekerja melalui dua jalur transmisi yang terukur. Meningkatnya persepsi risiko mendorong *flight-to-quality* yang memicu *capital outflow* dari negara berkembang dan memberikan tekanan depresiasi langsung pada rupiah [5], sementara gangguan rantai pasok global memperlebar defisit neraca perdagangan yang secara tidak langsung melemahkan kurs [6]. Dengan jalur transmisi yang konkret dan berulang ini, faktor geopolitik semestinya tidak dapat diabaikan dalam model prediksi nilai tukar. Namun, faktor geopolitik masih belum banyak dimasukkan secara eksplisit dalam pendekatan prediksi nilai tukar yang ada.

Untuk mengkuantifikasi intensitas risiko geopolitik, Caldara dan Iacoviello [7] mengembangkan indeks *Geopolitical Risk* berbasis frekuensi pemberitaan media internasional dengan versi harian bernama *Geopolitical Risk Daily* disingkat menjadi GPRD yang telah divalidasi luas dalam literatur ekonomi keuangan. Secara empiris, peningkatan GPRD berkorelasi dengan pelemahan nilai tukar negara berkembang dan meningkatnya volatilitas pasar keuangan [8]. Khusus untuk Indonesia, peningkatan GPRD dikaitkan dengan pelemahan rupiah dan mendestabilisasi pasar keuangan domestik [9]. Namun, integrasi GPRD sebagai variabel prediktor dalam model *machine learning* untuk memprediksi IDR/USD maupun IDR/CNY belum pernah diteliti.


Kajian mengenai prediksi kurs rupiah telah melalui beberapa fase metodologis, dan masing-masing fase menyisakan celah studi yang berbeda-beda. Pada fase awal, pendekatan statistik klasik seperti ARIMA digunakan oleh Teja dkk. [2] untuk meramalkan USD/IDR dan CNY/IDR, namun hasilnya menunjukkan akurasi yang terbatas untuk peramalan jangka panjang karena metode ini kurang mampu menangkap pola nonlinear pada data kurs yang fluktuatif. Keterbatasan tersebut mendorong beralihnya riset ke metode *machine learning* yang lebih adaptif; Hidayat dkk. [10] misalnya membuktikan bahwa LSTM memberikan hasil jauh lebih baik dibandingkan Random Forest dalam memprediksi kurs SGD/IDR, khususnya setelah variabel ekspor-impor dimasukkan sebagai fitur tambahan [11], [12]. Kemampuan LSTM dalam menangkap dependensi temporal jangka panjang kembali diperkuat oleh temuan Multiyaningrum dkk. [13] yang mencatat MAPE sebesar 0,334% pada USD/IDR. Meski unggul, kinerja LSTM sangat bergantung pada pemilihan *hyperparameter* yang tepat, di mana kesalahan pemilihan dapat menurunkan akurasi model secara berarti. Untuk mengatasi hal ini, *Particle Swarm Optimization* (PSO) terbukti efektif dalam mengotomasi pencarian kombinasi *hyperparameter* terbaik secara efisien pada data finansial [14], [15]. Sementara itu, XGBoost dikenal unggul dalam menangkap pola non-linear pada data tabular nonsekuensial, termasuk variabel makroekonomi [16], [17], namun belum banyak diperbandingkan secara langsung dengan LSTM dalam konteks kurs rupiah. Perbandingan antara keduanya yang dilakukan oleh Ullah dkk. [18] hanya terbatas pada pasangan CNY/USD dari sudut pandang global, tanpa melibatkan variabel makro eksternal apa pun. Kondisi inilah yang menjadikan XGBoost dan LSTM sebagai dua kandidat pembanding paling relevan untuk diteliti, sebab keduanya merepresentasikan dua paradigma pemodelan yang berbeda berbasis fitur tabular di satu sisi dan berbasis sekuens temporal di sisi lain yang belum banyak diadu secara langsung dalam konteks kurs rupiah dengan melibatkan variabel geopolitik.

Dari pemetaan literatur tersebut, terlihat belum ada riset yang secara serentak membandingkan XGBoost dan LSTM dalam memprediksi IDR/USD dan IDR/CNY sekaligus mengintegrasikan indeks GPRD sebagai variabel prediktor eksternal; bahkan studi yang memprediksi kedua kurs secara simultan seperti Amri dkk. [19] pun belum melibatkan indeks risiko geopolitik. Kesenjangan inilah yang mendasari riset ini dilakukan, yaitu membandingkan tingkat akurasi XGBoost dengan LSTM yang dioptimasi menggunakan algoritma *Particle Swarm Optimization* (PSO) dalam memprediksi IDR/USD dan IDR/CNY dengan mengintegrasikan indeks GPRD sebagai variabel prediktor eksternal [20]. Data yang digunakan mencakup periode Februari 2022 hingga Februari 2026.

Hasil studi ini diharapkan dapat memberikan manfaat praktis bagi Bank Indonesia serta otoritas kebijakan moneter dalam merumuskan langkah antisipatif menghadapi guncangan geopolitik, bagi investor dan pelaku pasar keuangan dalam mengelola risiko nilai tukar, serta bagi para eksportir dan importir yang secara langsung terdampak oleh fluktuasi IDR/USD dan IDR/CNY dalam aktivitas bisnis lintas negara mereka.

2. METODE PENELITIAN

Studi ini dirancang dengan pendekatan kuantitatif bersifat komparatif, dengan tujuan membandingkan tingkat akurasi prediksi antara XGBoost dan LSTM-PSO pada dua pasangan kurs rupiah, yaitu IDR/USD dan IDR/CNY, dengan menyertakan indeks GPRD sebagai variabel prediktor eksternal. Alur kerja dibagi menjadi tujuh tahapan yang berurutan dan saling terkait, sebagaimana digambarkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1 Pengumpulan Data

Data yang digunakan dalam studi ini terdiri dari tiga *dataset* yang berbeda yang diakses secara publik dan mencakup periode dari Februari 2022 hingga Februari 2026. Pemilihan periode tersebut mempertimbangkan keberadaan dua episode geopolitik utama, yaitu invasi Rusia ke Ukraina yang dimulai pada Februari 2022 dan konflik Iran–AS yang kembali meningkat sejak Oktober 2023. Sehingga rentang penelitian mencakup kondisi pasar valuta asing pada periode dengan tingkat risiko geopolitik yang berbeda.

Dataset pertama berupa data harian kurs IDR/USD yang bersumber dari Investing.com [21], menampilkan nilai rupiah terhadap dolar Amerika Serikat yang menjadi acuan utama pasar valas dalam negeri. *Dataset* kedua adalah data harian kurs IDR/CNY, juga diambil dari Investing.com [22], yang menggambarkan nilai rupiah terhadap yuan Tiongkok, pasangan kurs yang semakin signifikan seiring meningkatnya volume perdagangan bilateral antara kedua negara. Contoh data IDR/USD dan IDR/CNY masing-masing disajikan pada Tabel 1 dan Tabel 2.

Tabel 1. Data IDR/USD

Tanggal	Terakhir	Pembukaan	Tertinggi	Terendah	Vol.	Change%
2/27/2026	16.765,00	16.767,50	16.788,50	16.761,50	-	0,06%
2/26/2026	16.755,00	16.757,50	16.781,00	16.732,50	-	-0,18%
.....						
2/3/2022	14.375,00	14.365,00	14.390,00	14.357,50	0,11K	0,14%
2/2/2022	14.355,00	14.315,00	14.362,50	14.315,00	0,18K	-0,17%

Tabel 2. Data IDR/CNY

Tanggal	Terakhir	Pembukaan	Tertinggi	Terendah	Vol.	Perubahan%
27/2/2026	2.444,52	2.442,12	2.448,48	2.442,10	-	-0,19%
26/2/2026	2.449,11	2.449,26	2.453,28	2.444,61	-	0,23%
.....						
2/2/2022	2.256,54	2.250,43	2.257,90	2.250,43	-	-0,20%
1/2/2022	2.260,97	2.260,97	2.260,97	2.260,97	-	0,02%

Dataset ketiga berupa GPRD yang bersumber dari basis data resmi *Geopolitical Risk* [7]. GPRD merupakan indikator harian yang mengukur tingkat risiko geopolitik global berdasarkan intensitas pemberitaan media internasional terhadap peristiwa-peristiwa geopolitik, seperti konflik bersenjata, ketegangan antarnegara, dan ancaman terorisme. Contoh data GPRD disajikan pada Tabel 3.

Tabel 3. Data GPRD

Day	N10D	GPRD	GPRD_ACT	GPRD_THREAT	Date	GPRD_MA30	GPRD_MA7
19850101	216	230,04	275,20	153,03	1/1/1985	230,04	230,04
.....							
20260227	605	197,11	141,92	273,17	2/27/2026	120,85	139,97
20260228	629	110,59	105,00	140,13	2/28/2026	118,62	144,61

2.2 Data Preprocessing

Proses *preprocessing* dalam riset ini dilakukan secara bertahap mulai dari menghapus data yang tidak perlu, memilih periode yang sesuai, mengubah bentuk data, menggabungkan data, membuat fitur baru, hingga menormalisasi

data [23]. Proses pembersihan data dilaksanakan secara terpisah pada masing-masing *dataset* guna memperbaiki inkonsistensi serta menjaga kualitas data sebelum masuk ke tahap pemodelan [24].

Pada *dataset* IDR/USD dan IDR/CNY, kolom-kolom yang dianggap tidak diperlukan seperti *Volume* dan *Change (%)* dihilangkan, sementara nama-nama kolom yang tersisa diseragamkan menjadi *Date*, *Open*, *High*, *Low*, dan *Close*. Nilai harga yang semula berformat teks dengan tanda pemisah ribuan juga dikonversi ke bentuk numerik. Untuk *dataset* GPRD, hanya kolom tanggal dan nilai indeks yang dipertahankan, dengan format tanggal yang semula berupa bilangan bulat YYYYMMDD diubah menjadi format tanggal standar. Hari libur nasional dan cuti bersama disesuaikan berdasarkan kalender hari libur yang digunakan pada periode penelitian, sedangkan hari tanpa observasi harga pada *dataset* kurs tidak digunakan dalam pemodelan. Pemeriksaan nilai kosong (*missing value*) dilakukan terhadap seluruh variabel, dan hasilnya menunjukkan tidak ditemukan nilai yang hilang pada ketiga *dataset*. Ketiga *dataset* kemudian difilter agar hanya mencakup periode Februari 2022 hingga Februari 2026. Proses integrasi selanjutnya dilakukan untuk memastikan seluruh variabel merujuk pada tanggal observasi yang sama, sehingga keterkaitan antara data kurs dan nilai GPRD tetap terjaga sepanjang proses pemodelan. Dari proses ini dihasilkan dua *dataset* akhir, yakni *df_usd_final* dan *df_cny_final*.

Setelah proses integrasi selesai, tahap *feature engineering* dilakukan untuk membangun fitur-fitur yang dapat merepresentasikan karakteristik historis serta dinamika pergerakan nilai tukar. Fitur *lag* pada $t-1$, $t-2$, $t-3$, $t-7$, $t-14$, dan $t-30$ diterapkan untuk menangkap keterkaitan antarwaktu (*dependensi temporal*) [25]. Di samping itu, dibentuk pula fitur *moving average* untuk periode 7, 14, dan 30 hari, fitur momentum, serta fitur volatilitas berbasis *rolling standard deviation* untuk periode 7 dan 14 hari, guna merepresentasikan tren, kekuatan pergerakan harga, dan tingkat ketidakpastian pasar [26], [27]. Dalam pemodelan, nilai *Close* pada waktu t digunakan sebagai informasi historis untuk memprediksi nilai *Close* pada waktu $t+1$, sehingga fitur berbasis *rolling* yang dihitung hingga waktu t hanya memanfaatkan informasi yang telah tersedia sebelum periode target. Dengan demikian, pembentukan fitur tidak menggunakan nilai target pada waktu $t+1$ dan dilakukan untuk menghindari *target leakage*.

Setelah seluruh fitur terbentuk, baris data yang mengandung nilai kosong akibat proses *lag* dan *rolling window* dibuang sebelum tahap normalisasi dijalankan. *Dataset* kemudian dibagi secara kronologis menjadi *training set*, *validation set*, dan *testing set*. Selanjutnya, seluruh variabel dinormalisasi menggunakan metode *Min-Max Scaling* ke rentang $[0,1]$. *Scaler* di-fit hanya menggunakan data pada *training set* untuk memperoleh nilai minimum dan maksimum, sedangkan *validation set* dan *testing set* ditransformasikan menggunakan *scaler* yang telah di-fit pada *training set*. Prosedur yang sama diterapkan pada variabel fitur dan target. Dengan demikian, informasi statistik dari periode validasi dan pengujian tidak digunakan dalam proses pembentukan skala data untuk pelatihan, sehingga risiko *data leakage* dapat dihindari. Normalisasi dilakukan untuk menyamakan skala antarvariabel sebelum digunakan dalam pemodelan, terutama pada arsitektur LSTM yang sensitif terhadap perbedaan skala data [28], [29].

2.3 Data Splitting

Setelah tahap *feature engineering* rampung, *dataset* kemudian dibagi menjadi tiga bagian, yaitu data pelatihan (*training set*), data validasi (*validation set*), dan data pengujian (*testing set*), dengan proporsi masing-masing 70:15:15. Pembagian dilakukan secara kronologis (*time series split*) tanpa pengacakan urutan, sehingga struktur waktu data tetap terjaga dan informasi dari periode mendatang tidak ikut memengaruhi proses pelatihan model. Praktik ini merupakan pendekatan yang direkomendasikan dalam evaluasi model deret waktu [30]. Pada *dataset* IDR/USD dan IDR/CNY, *training set* mencakup observasi dari 18 Maret 2022 hingga 31 Desember 2024, *validation set* mencakup 1 Januari 2025 hingga 30 Juli 2025, sedangkan *testing set* mencakup 31 Juli 2025 hingga 27 Februari 2026.

2.4 Implementasi Model

Pada tahap implementasi model, studi ini menggunakan dua algoritma *machine learning* dengan pendekatan yang berbeda, yaitu XGBoost yang beroperasi pada representasi fitur tabular dan LSTM yang dioptimalkan dengan *Particle Swarm Optimization* (LSTM-PSO) untuk menangkap ketergantungan sekuensial dalam data deret waktu. Kedua model dilatih secara terpisah untuk setiap pasangan kurs, yaitu IDR/USD dan IDR/CNY.

1) XGBoost

XGBoost (*Extreme Gradient Boosting*) merupakan algoritma *ensemble* berbasis *boosting* yang membentuk sekumpulan pohon keputusan secara bertahap, di mana setiap pohon baru dibangun untuk mengoreksi kesalahan residual pohon-pohon sebelumnya, dengan regularisasi untuk membatasi kompleksitas model dan mengurangi risiko *overfitting* [31].

Model XGBoost diimplementasikan menggunakan *library* *xgboost* melalui *class* *XGBRegressor* dengan fungsi objektif *reg:squarederror* yang sesuai untuk permasalahan regresi dengan target kontinu. Konfigurasi parameter ditentukan berdasarkan praktik umum dan uji coba awal pada data pelatihan untuk memperoleh konfigurasi yang stabil dan efisien, sebagaimana disajikan pada Tabel 4, sedangkan parameter lainnya menggunakan nilai bawaan (*default*) *library*.

Tabel 4. Parameter XGBoost

Parameter	Nilai	Keterangan
<i>learning_rate</i>	0,01	Laju pembelajaran konservatif untuk boosting bertahap
<i>max_depth</i>	4	Membatasi kompleksitas pohon

Parameter	Nilai	Keterangan
<i>subsample</i>	0,9	Regularisasi berbasis sampling baris
<i>colsample_bytree</i>	0,9	Regularisasi berbasis sampling fitur
<i>n_estimators</i>	1000	Jumlah pohon keputusan

2) LSTM-PSO

Long Short-Term Memory (LSTM) adalah salah satu varian *Recurrent Neural Network* yang dikembangkan khusus untuk menangkap dependensi temporal jangka panjang, melalui mekanisme *forget gate*, *input gate*, dan *output gate* yang mengendalikan proses penyimpanan dan pembaruan informasi pada *cell state* [32]. Karakteristik inilah yang membuat LSTM menjadi salah satu arsitektur yang paling banyak digunakan dalam peramalan deret waktu di bidang finansial [33]. Pada studi ini, data disusun menjadi bentuk sekuens menggunakan teknik *sliding window* sepanjang 30 langkah waktu. Dengan demikian, setiap sekuens yang terdiri atas 30 observasi historis digunakan untuk memprediksi nilai kurs satu langkah waktu ke depan (*one-step-ahead forecasting*), yaitu nilai pada waktu ($t+1$). Sekuens tersebut direpresentasikan dalam bentuk tensor tiga dimensi (*batch*, *timestep*, fitur).

Karena performa LSTM diketahui sangat bergantung pada pemilihan *hyperparameter*, studi ini menerapkan *Particle Swarm Optimization* (PSO) untuk mengotomasi proses pencarian kombinasi *hyperparameter* terbaik [14], [15]. PSO bekerja dengan memodelkan sekelompok partikel yang bergerak dalam ruang pencarian, di mana posisi setiap partikel diperbarui berdasarkan nilai *personal best* dan *global best*, sebagaimana dirumuskan pada persamaan (1) dan (2).

$$v_i(t+1) = w \cdot v_i(t) + c_1 r_1 (pbest_i - x_i(t)) + c_2 r_2 (gbest - x_i(t)) \quad (1)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (2)$$

di mana v_i dan x_i berturut-turut adalah kecepatan dan posisi partikel ke- i , w adalah bobot inersia, c_1 dan c_2 adalah koefisien akselerasi kognitif dan sosial, serta r_1, r_2 adalah bilangan acak pada rentang $[0,1]$.

Empat *hyperparameter* dioptimasi menggunakan PSO, yaitu jumlah unit pada LSTM layer pertama, jumlah unit pada LSTM layer kedua, *dropout rate*, dan *learning rate*. Nilai *fitness* setiap partikel dihitung berdasarkan *loss* validasi (*validation MSE*) yang diperoleh dari hasil pelatihan model dengan maksimum 100 *epoch*. Untuk mempercepat proses pencarian, pelatihan dilengkapi dengan *EarlyStopping* (*patience* 15) dan *ReduceLROnPlateau* (faktor 0,5, *patience* 5, *learning rate minimum* 1×10^{-6}). Ruang pencarian serta konfigurasi PSO untuk masing-masing pasangan kurs disajikan pada Tabel 5.

Tabel 5. Ruang Pencarian dan Konfigurasi PSO

Parameter	IDR/USD	IDR/CNY
<i>Units Layer 1</i>	96 – 128	64 – 128
<i>Units Layer 2</i>	32 – 64	32 – 64
<i>Dropout Rate</i>	0,10 – 0,25	0,10 – 0,50
<i>Learning Rate</i>	0,0005 – 0,0020	0,0005 – 0,0050
Jumlah Partikel	15	20
Jumlah Iterasi	15	20
c_1 (kognitif)	0,8	1,5
c_2 (sosial)	1,8	1,5
w (inersia)	0,5	0,7

Setelah kombinasi *hyperparameter* terbaik berhasil ditemukan melalui proses optimasi, model akhir dilatih kembali menggunakan keseluruhan data pelatihan, dengan konfigurasi *EarlyStopping* (*patience* 20) dan *ReduceLROnPlateau* yang sama seperti sebelumnya, batas maksimum 200 *epoch*, ukuran *batch* 32, serta tanpa pengacakan urutan data (*shuffle=False*) demi mempertahankan struktur temporal. Hasil *hyperparameter* terbaik untuk masing-masing pasangan kurs dapat dilihat pada Tabel 6.

Tabel 6. Hasil Optimasi *Hyperparameter* LSTM-PSO

Pasangan Kurs	<i>Units Layer 1</i>	<i>Units Layer 2</i>	<i>Dropout</i>	<i>Learning Rate</i>
IDR/USD	108	49	0,1198	0,001522
IDR/CNY	109	62	0,1312	0,004888

2.5 Evaluasi Model

Kinerja model dievaluasi dengan membandingkan nilai hasil prediksi terhadap nilai aktual pada data pengujian, setelah keduanya dikembalikan ke skala aslinya melalui proses *inverse transform*. Untuk menilai performa

model secara menyeluruh, penelitian ini menggunakan empat metrik evaluasi, yaitu *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi (R^2), yang masing-masing menangkap sisi kesalahan prediksi dari sudut pandang yang berbeda [34], [35]. Formula perhitungan dari keempat metrik tersebut ditampilkan berturut-turut pada Persamaan (3) sampai (6).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (6)$$

3. HASIL DAN PEMBAHASAN

Evaluasi model LSTM-PSO pada pasangan kurs IDR/USD dan IDR/CNY dilakukan menggunakan konfigurasi *hyperparameter* terbaik hasil optimasi PSO, sebagaimana telah ditunjukkan pada Tabel 6, dengan cara membandingkan nilai prediksi terhadap nilai aktual pada data pengujian setelah dikembalikan ke skala asli.


Tabel 7. Hasil Evaluasi Model LSTM-PSO

Pasangan Kurs	RMSE	MAE	MAPE	R^2
IDR/USD	49,20	38,10	0,23%	0,9276
IDR/CNY	17,38	14,06	0,59%	0,8913

Berdasarkan Tabel 7, performa pada IDR/CNY sedikit lebih rendah dibandingkan IDR/USD. Nilai MAPE yang masih di bawah 1% mengindikasikan bahwa model tetap menghasilkan prediksi dengan tingkat kesalahan relatif yang sangat kecil pada kedua pasangan kurs. Perbedaan performa antara kedua pasangan kurs berkaitan dengan karakteristik volatilitas dan pola tren masing-masing data. IDR/CNY menunjukkan tren kenaikan yang lebih tajam dan berkelanjutan dibandingkan IDR/USD, sehingga model dituntut menangkap dinamika pergerakan yang lebih curam, tercermin dari nilai R^2 IDR/CNY yang sedikit lebih rendah dibandingkan IDR/USD.



Gambar 2. Perbandingan Nilai Aktual dan Prediksi Model LSTM-PSO pada IDR/USD



Gambar 3. Perbandingan Nilai Aktual dan Prediksi Model LSTM-PSO pada IDR/CNY

Perbandingan visual antara nilai aktual dan hasil prediksi model LSTM-PSO pada data pengujian ditunjukkan pada Gambar 2 dan Gambar 3. Pada Gambar 2 garis prediksi mengikuti pola pergerakan garis aktual dengan rapat di sepanjang periode pengujian, termasuk pada fase penurunan tajam di awal periode dan fase kenaikan menjelang akhir periode, meskipun masih terdapat sedikit keterlambatan (*lag*) dalam menangkap puncak dan lembah pergerakan yang tajam.

Gambar 3 menunjukkan pola yang tidak jauh berbeda dengan Gambar 2, di mana model secara umum masih mampu mengikuti arah pergerakan garis aktual. Namun, pada saat terjadi kenaikan secara tajam, hasil prediksi cenderung sedikit lebih rendah daripada nilai aktual. Kecenderungan *underestimate* ini sejalan dengan nilai R^2 IDR/CNY yang memang sedikit lebih rendah dibandingkan IDR/USD, yang menunjukkan bahwa model relatif lebih kesulitan menangkap dinamika kenaikan yang curam pada IDR/CNY. Sebagai pembandingan terhadap LSTM-PSO, studi ini juga mengukur performa XGBoost dalam memprediksi IDR/USD dan IDR/CNY, dengan skema pembagian data latih-uji yang sama serta metrik evaluasi yang identik, yakni RMSE, MAE, MAPE, dan R^2 . Tujuan perbandingan ini adalah untuk melihat sejauh mana model berbasis pohon keputusan seperti XGBoost dapat menangani karakteristik data deret waktu nilai tukar, jika dibandingkan dengan arsitektur LSTM yang telah dioptimasi melalui PSO. Hasil evaluasi XGBoost pada kedua pasangan kurs ditampilkan pada Tabel 8.


Tabel 8. Hasil Evaluasi Model XGBoost

Pasangan Kurs	RMSE	MAE	MAPE	R^2
IDR/USD	353,30	320,60	1,92%	-3,1312
IDR/CNY	114,11	101,47	4,26%	-3,7924

Berbeda dengan LSTM-PSO, model XGBoost menghasilkan nilai R^2 negatif pada kedua pasangan kurs (-3,1312 untuk IDR/USD dan -3,7924 untuk IDR/CNY), yang mengindikasikan bahwa performa model lebih buruk dibandingkan sekadar memprediksi nilai rata-rata data aktual. Hal ini terlihat pada Gambar 4 dan Gambar 5, di mana sumbu X merepresentasikan urutan hari ke-n pada data pengujian dan sumbu Y menunjukkan nilai tukar aktual dalam IDR/USD dan IDR/CNY, dengan garis prediksi XGBoost cenderung datar dan gagal mengikuti tren kenaikan maupun fluktuasi jangka pendek pada data aktual, berbeda dengan garis prediksi LSTM-PSO pada Gambar 2 dan Gambar 3 yang mengikuti pola pergerakan kurs dengan rapat.



Gambar 4. Perbandingan Nilai Aktual dan Prediksi Model XGBoost pada IDR/USD



Gambar 5. Perbandingan Nilai Aktual dan Prediksi Model XGBoost pada IDR/CNY

Perbedaan performa tersebut sejalan dengan karakteristik masing-masing algoritma. XGBoost merupakan model berbasis pohon keputusan yang beroperasi pada data tabular tanpa dilengkapi mekanisme untuk menangkap dependensi antarwaktu, sehingga kurang tepat diterapkan pada data deret waktu bertren jangka panjang seperti nilai tukar. Secara teknis, buruknya performa XGBoost dapat dijelaskan oleh keterbatasan mendasar model berbasis pohon dalam mengekstrapolasi nilai di luar rentang data pelatihan. Cara kerja XGBoost dalam memprediksi nilai baru adalah dengan mengarahkan sampel menuju daun (*leaf*) pohon yang paling sesuai, sehingga keluaran model dibatasi oleh

rentang nilai target yang telah dipelajari selama pelatihan. Ketika data pengujian menunjukkan tren kenaikan berkelanjutan yang melampaui nilai maksimum pada data pelatihan sebagaimana terjadi pada IDR/USD dan IDR/CNY model tidak mampu memproyeksikan nilai di luar rentang tersebut, dan cenderung menghasilkan prediksi yang stagnan mendekati nilai maksimum yang pernah dipelajarinya.

Hal ini sejalan dengan pola yang terlihat pada Gambar 4 dan Gambar 5, di mana garis prediksi XGBoost tampak mendatar dan tidak mengikuti tren kenaikan data aktual, sehingga menghasilkan R^2 negatif pada kedua pasangan kurs. Pola ini kemungkinan berkaitan dengan dua faktor. Pertama, XGBoost memperlakukan tiap sampel data secara independen tanpa mekanisme bawaan untuk mempelajari keterkaitan antarwaktu, berbeda dengan LSTM yang dirancang secara arsitektural untuk menangkap pola sekuensial melalui unit memorinya. Kedua, model berbasis pohon keputusan pada dasarnya tidak mengekstrapolasi di luar rentang nilai data latih, sehingga sulit mengikuti tren yang terus naik. Kombinasi kedua faktor tersebut dapat menjelaskan mengapa XGBoost kurang sesuai untuk data nilai tukar yang memiliki tren jangka panjang pada konfigurasi yang diuji. Secara keseluruhan, perbandingan pada Tabel 9 menunjukkan bahwa LSTM-PSO memiliki kinerja yang lebih baik daripada XGBoost dalam memprediksi IDR/USD dan IDR/CNY berdasarkan metrik evaluasi yang digunakan, baik dari sisi akurasi (RMSE, MAE, MAPE) maupun kemampuan menjelaskan variabilitas data (R^2).

Tabel 9. Perbandingan Hasil Evaluasi Model LSTM-PSO dan XGBoost

Model	Pasangan Kurs	RMSE	MAE	MAPE	R^2
LSTM-PSO	IDR/USD	49,20	38,10	0,23%	0,9276
	IDR/CNY	17,38	14,06	0,59%	0,8913
XGBoost	IDR/USD	353,30	320,60	1,92%	-3,1312
	IDR/CNY	114,11	101,47	4,26%	-3,7924

Tabel 9 menunjukkan bahwa LSTM mampu memodelkan dependensi temporal pada data nilai tukar melalui pemanfaatan informasi historis dalam bentuk sekuens. Pada penelitian ini, PSO digunakan untuk mencari kombinasi *hyperparameter* LSTM yang optimal berdasarkan fungsi objektif yang telah ditentukan. Proses optimasi tersebut menghasilkan konfigurasi *hyperparameter* yang selanjutnya digunakan dalam pelatihan model LSTM-PSO. Sebaliknya, XGBoost mengalami kesulitan mengikuti tren kenaikan jangka panjang karena model berbasis pohon keputusan tidak memiliki mekanisme intrinsik untuk mempelajari hubungan sekuensial antarwaktu maupun melakukan ekstrapolasi terhadap nilai di luar rentang data pelatihan. Temuan ini juga memperkuat bahwa LSTM mampu melakukan prediksi lebih tepat dibandingkan XGBoost pada pasangan CNY/USD, meskipun pada kajian ini selisih terdapat perbedaan performa antara kedua model pada *dataset* yang digunakan. Namun perbedaan tersebut belum dapat dikaitkan secara khusus dengan keterlibatan GPRD karena penelitian ini tidak melakukan eksperimen perbandingan dengan dan tanpa variabel GPRD.

Selain mengkaji kinerja LSTM-PSO dan XGBoost, studi ini juga menyertakan indeks risiko geopolitik harian Geopolitical Risk Daily sebagai variabel prediktor tambahan pada kedua model. Namun, kontribusi GPRD terhadap akurasi prediksi belum dapat disimpulkan secara khusus karena penelitian ini tidak melakukan eksperimen perbandingan dengan dan tanpa GPRD.

4. KESIMPULAN

Penelitian ini membandingkan kinerja XGBoost dan LSTM-PSO dalam memprediksi kurs IDR/USD dan IDR/CNY satu langkah ke depan dengan indeks *Geopolitical Risk Daily* (GPRD) sebagai variabel prediktor eksternal. Pada data dan skenario pengujian ini, LSTM-PSO menghasilkan galat lebih rendah daripada XGBoost pada kedua pasangan kurs, dengan MAPE 0,23% (IDR/USD) dan 0,59% (IDR/CNY) serta R^2 di atas 0,89, sedangkan XGBoost menghasilkan R^2 negatif pada keduanya. Prediksi XGBoost cenderung mendatar ketika kurs naik melampaui rentang data latih, sementara LSTM-PSO tetap mengikuti arah pergerakan kurs.

Penelitian ini memiliki beberapa keterbatasan. Pertama, kontribusi GPRD terhadap akurasi belum dapat dipisahkan karena tidak ada eksperimen perbandingan dengan dan tanpa GPRD. Kedua, *hyperparameter* XGBoost tidak dioptimasi dengan prosedur yang setara dengan PSO, sehingga selisih kinerja belum sepenuhnya mencerminkan perbedaan arsitektur. Ketiga, periode pengamatan terbatas pada Februari 2022 hingga Februari 2026 dan hanya satu variabel eksternal yang digunakan. Penelitian selanjutnya disarankan menguji model dengan dan tanpa GPRD, mengoptimasi XGBoost secara setara, serta menambah indikator makroekonomi seperti suku bunga, inflasi, dan harga komoditas energi, juga pasangan kurs lain seperti IDR/EUR atau IDR/JPY.

REFERENSI

- [1] W. Khamidah and R. R. Sugiharti, "Faktor yang Mempengaruhi Nilai Tukar Rupiah terhadap Dollar Amerika, Euro dan Poundsterling," *Ecoplan*, vol. 5, no. 1, pp. 40–52, 2022, doi: 10.20527/ecoplan.v5i1.425.
- [2] S. D. A. Teja, L. Derick, M. L. Tauryawati, and A. F. Zainuddin, "Prediksi nilai kurs mata uang Dollar Amerika (USD) dan Yuan China (CNY) dengan Rupiah (IDR) menggunakan metode ARIMA prediction," *Var. J. Stat. Its Appl.*, vol. 6, no. 1, pp. 99–112, 2025, doi: 10.30598/variancevol6iss1page99-112.

- [3] M. D. Kurnia and M. Anitasari, "Pengaruh neraca perdagangan barang dan jasa pada nilai tukar rupiah terhadap yuan," *Converg. J. Econ. Perspect.*, vol. 3, no. 2, pp. 159–178, 2021, doi: 10.33369/convergence-jep.v3i2.22386.
- [4] Y. Yudianto, D. Supriyadi, and Kosasih, "Dampak Perselisihan Ukraina-Rusia 2022 Terhadap Perekonomian, Inflasi, Perdagangan Internasional di Asia Tenggara," *COOPETITION J. Ilm. Manaj.*, vol. 14, no. 2, pp. 293–306, 2023, doi: 10.32670/coopetition.v14i2.3347.
- [5] Suherman *et al.*, "Bagaimana Dampak Perang Rusia Ukraina Terhadap Stabilitas Keuangan di Indonesia," *J. Ekon. Manaj. dan Akunt.* 3025-1192, vol. 2, no. 4, pp. 288–296, 2024, doi: 10.572349/neraca.v2i4.1281.
- [6] I. A. Badhan, "Currency Rate Fluctuations and Their Impact On Supply chain Risk Management: An Empirical Analysis," *Int. J. Bus. Manag. Sci.*, vol. 04, no. 10, pp. 6–26, 2024, doi: 10.55640/ijbms-04-10-02.
- [7] D. C. M. Iacoviello, "Geopolitical Risk Index," Economic Policy Uncertainty. Accessed: Jun. 28, 2026. [Online]. Available: <https://www.policyuncertainty.com/gpr.html>
- [8] J. R. Francis and R. C. Chia, "Geopolitical Risk (GPR) and its Predictability : A Systematic Literature Review," *Int. J. Acad. Res. Bus. Soc. Sci.*, vol. 13, no. 9, pp. 1082–1099, 2023, doi: 10.6007/IJARBS/v13-i9/16766.
- [9] A. Khaliq, S. Karimi, W. D. Taifur, and E. Ridwan, "Decision SciThe quest for explosive bubbles in the Indonesian Rupiah/US exchange rate: Does the uncertainty trinity matter?ence Letters," *Decis. Sci. Lett.*, vol. 13, no. 2, pp. 415–426, 2024, doi: 10.5267/dsl.2024.1.005.
- [10] I. Hidayat, L. A. Syamsul, I. Akbar, and A. S. Rachman, "Prediksi Nilai Tukar Mata Uang Menggunakan Algoritma Long Short-Term Memory dan Random Forest," *J. Comput. Syst. Informatics*, vol. 6, no. 1, pp. 107–116, 2024, doi: 10.47065/josyc.v6i1.6200.
- [11] G. S. Mahendra, S. R. Yahya, J. A. Widiyans, S. Sepriano, A. P. S. Iskandar, and D. Darwin, *ARTIFICIAL INTELLIGENCE TOOLS POPULER: Penerapan & Implementasi AI pada Dunia Kerja dan Industri*. PT. Sonpedia Publishing Indonesia, 2023.
- [12] M. S. Iswahyudi *et al.*, *Aplikasi Machine Learning di Berbagai Bidang: Solusi Cerdas Untuk Masa Depan*. PT. Sonpedia Publishing Indonesia, 2023.
- [13] R. Multiyaningrum, H. R. Dawi, R. Nurhaq, M. Hartanto, and M. Al, "Forecasting the Rupiah exchange rate against the US Dollar using the LSTM algorithm," *Factor M Focus Action Res. Math.*, vol. 8, no. 2, pp. 201–216, 2025, doi: 10.30762/f_m.v8i2.6530.
- [14] I. Talhartit, S. A. Jillali, and M. El Kabbouri, "Enhancing Stock Price Forecasting with LSTM Networks : A Comparative Study of Classic and PSO-Optimized Models on S & P 500 Stock," *Int. J. Econ. Financ.*, vol. 17, no. 8, pp. 87–94, 2025, doi: 10.5539/ijef.v17n8p87.
- [15] X. Zeng, C. Liang, Q. Yang, F. Wang, and J. Cai, "Enhancing stock index prediction : A hybrid LSTM-PSO model for improved forecasting accuracy," *PLoS One*, vol. 20, no. 1, pp. 1–31, 2025, doi: 10.1371/journal.pone.0310296.
- [16] S. F. N. Islam, A. Sholahuddin, and A. S. Abdullah, "Extreme gradient boosting (XGBoost) method in making forecasting application and analysis of USD exchange rates against rupiah Extreme gradient boosting (XGBoost) method in making forecasting application and analysis of USD exchange rates against rupi," *J. Phys. Conf. Ser. Pap.*, vol. 1722, no. 1, pp. 0–11, 2021, doi: 10.1088/1742-6596/1722/1/012016.
- [17] Pfahler and J. Felix, "Exchange rate forecasting with advanced machine learning methods Exchange Rate Forecasting with Advanced Machine Learning Methods," *J. Risk Financ. Manag. Provid.*, vol. 15, no. 1, pp. 1–17, 2022, doi: 10.3390/jrfm15010002.
- [18] I. Ullah, Usman Rehman, Dawood Khan, Sulaiman Rashid, Haroon Ullah, "Forecasting Foreign Exchange Rate with Machine Learning Techniques Chinese Yuan to US Dollar Using XGboost and LSTM Model," *iRASD J. Econ.*, vol. 6, no. 3, pp. 761–775, 2024, doi: 10.52131/joe.2024.0603.0238.
- [19] I. F. Amri, N. Yunanita, and F. A. Lestari, "MethodsX Rupiah exchange rate prediction against the US Dollar using a deep neural network with a multi-output sliding window approach," *MethodsX*, vol. 15, no. August, p. 103692, 2025, doi: 10.1016/j.mex.2025.103692.
- [20] I. F. Amri, N. Yunanita, and F. A. Lestari, "MethodsX Rupiah exchange rate prediction against the US Dollar using a deep neural network with a multi-output sliding window approach," *MethodsX*, vol. 15, p. 103692, 2025, doi: 10.1016/j.mex.2025.103692.
- [21] Investing.com, "USD/IDR - Historical Data." Accessed: Jun. 28, 2026. [Online]. Available: <https://www.investing.com/currencies/usd-idr-historical-data>
- [22] Investing.com, "CNY/IDR - Historical Data." Accessed: Jun. 28, 2026. [Online]. Available: <https://id.investing.com/currencies/cny-idr-historical-data>
- [23] A. Sahrin *et al.*, "Buku Ajar Data Mining," in 2026.
- [24] S. Borrohou, R. Fissoune, and H. Badir, "Data cleaning survey and challenges – improving outlier detection algorithm in machine learning," *J. Smart Cities Soc.*, vol. 2, no. 3, pp. 125–140, 2023, doi: 10.3233/SCS-230008.
- [25] C. Leites, José; Cerqueira, Vitor; Soares, "Lag Selection for Univariate Time Series Forecasting Using Deep Learning: An Empirical Study," *Prog. Artif. Intell. Lect. Notes Comput. Sci.*, vol. 14969, no. 3, pp. 321–332,

- 2024, doi: 10.48550/arXiv.2405.11237.
- [26] M. Billah, A. Sultana, F. Bhuiyan, and M. G. Kaosar, "Stock price prediction : comparison of different moving average techniques using deep learning model," *Neural Comput. Appl.*, vol. 36, no. 11, pp. 5861–5871, 2024, doi: 10.1007/s00521-023-09369-0.
- [27] K. Yan and Y. Li, "Machine learning-based analysis of volatility quantitative investment strategies for American financial stocks," *Quant. Financ. Econ.*, vol. 8, no. 11, pp. 364–386, 2024, doi: 10.3934/QFE.2024014.
- [28] D. R. Anamisa, F. A. Mufarroha, A. Jauhari, and B. K. Khotimah, "Mathematical Modelling of Engineering Problems Forecasting Ginger Harvest Yields : A Comparative Study of Double Exponential Smoothing and Long Short-Term Memory Models," *Int. Inf. Eng. Technol. Assoc.*, vol. 11, no. 6, pp. 1481–1490, 2024, doi: 10.18280/mmep.110609.
- [29] A. Khansa, A. Prasetya, A. Wida, and D. Rafifah, "Optimalisasi Rekonstruksi Data Hilang untuk Meningkatkan Presisi Prediksi Waktu Salat Berbasis GRU di Wilayah Empat Musim Optimizing Missing Data Reconstruction to Enhance GRU-Based Prayer Time Prediction Precision in Four-Season Regions," *Bul. Sist. Inf. dan Teknol. Islam*, vol. 7, no. 2, pp. 116–127, 2026, doi: 10.33096/busiti.v7i2.3458.
- [30] H. Hewamalage, K. Ackermann, and C. Bergmeir, "Forecast evaluation for data scientists : common pitfalls and best practices," *Data Min. Knowl. Discov.*, vol. 37, no. 2, pp. 788–832, 2023, doi: 10.1007/s10618-022-00894-5.
- [31] R. Sari and W. Kurniadi, "Penerapan Metode Machine Learning (Random Forest & XGBoost) untuk Memprediksi Prestasi Akademik Berdasarkan Faktor Internal dan Eksternal Siswa Application of Machine Learning Methods (Random Forest & XGBoost) to Predict Academic Achievement Based on," *Bul. Sist. Inf. dan Teknol. Islam*, vol. 6, no. 4, pp. 205–213, 2025, doi: 10.33096/busiti.v6i4.3205.
- [32] M. Jahron, J. A. Widians, and A. Tejawati, "Multivariate LSTM With the RSI-14 Technical Indicator for Stock Price Forecasting," *TEPIAN*, vol. 7, no. 3, pp. 270–279, 2026, doi: 10.51967/tepi.v7i3.3919.
- [33] H. Xiao, "Enhanced separation of long-term memory from short-term memory on top of LSTM : Neural network-based stock," *PLoS One*, vol. 20, no. 6, pp. 1–34, 2025, doi: 10.1371/journal.pone.0322737.
- [34] M. M. Mundu, "Comparative Analysis of Model Evaluation Metrics in Energy Systems , Environmental Modeling , and Sustainability Science," *Int. J. Energy Res.*, vol. 6, pp. 1–13, 2026, doi: 10.1155/er/6170467.
- [35] V. Kumar, N. Kedam, K. V. Sharma, and D. J. Mehta, "Advanced Machine Learning Techniques to Improve Hydrological Prediction : A Comparative Analysis of Streamflow Prediction Models," *MDPI*, vol. 15, no. 14, p. 2572, 2023, doi: 10.3390/w15142572.