

Perbandingan Metode XGBoost dan LSTM dalam Memprediksi Nilai Tukar Rupiah terhadap Dolar Amerika Serikat

RIVA DIAN ARDIANSYAH, ATIK WINTARTI, ULFA SITI NURAINI*

Program Studi Sarjana Sains Data, Universitas Negeri Surabaya, Indonesia

Abstrak

Nilai tukar Rupiah terhadap Dolar Amerika Serikat merupakan indikator ekonomi yang dinamis dan sensitif terhadap kondisi makroekonomi global maupun domestik. Penelitian ini bertujuan mendeskripsikan karakteristik data deret waktu nilai tukar USD/IDR, membangun model *Extreme Gradient Boosting* (XGBoost) dan *Long Short-Term Memory* (LSTM) yang optimal, serta membandingkan akurasi prediksi kedua model. Data yang digunakan adalah data harian Kurs Transaksi Bank Indonesia periode 2 Januari 2015 hingga 31 Desember 2025 dengan total 2.687 observasi, menggunakan 27 fitur turunan yang meliputi *lag*, *simple moving average*, *return* harian, volatilitas, dan indikator tren. Evaluasi dilakukan menggunakan skema *rolling forecast* satu langkah ke depan dengan pembagian data 80:10:10 serta metrik RMSE, MAPE, Adjusted R^2 , dan *Directional Accuracy*. Hasil analisis menunjukkan bahwa data bersifat non-stasioner dengan tren depresiasi jangka panjang dan volatilitas tertinggi pada April 2020. Model XGBoost dan LSTM kemudian dioptimalkan sebelum dilakukan evaluasi. Pada data uji, LSTM memberikan kinerja terbaik dengan RMSE sebesar Rp57,30, MAPE sebesar 0,2621%, dan Adjusted R^2 sebesar 0,9381, sedangkan XGBoost memperoleh RMSE sebesar Rp163,20, MAPE sebesar 0,6308%, dan Adjusted R^2 sebesar 0,5049. Sebaliknya, XGBoost menghasilkan *Directional Accuracy* yang lebih tinggi, yaitu sebesar 67,67%, dibandingkan LSTM sebesar 48,30%. Validasi menggunakan data aktual periode 5–9 Januari 2026 juga menunjukkan bahwa LSTM menghasilkan prediksi yang lebih akurat dengan MAPE sebesar 0,1548%, sedangkan XGBoost memperoleh MAPE sebesar 5,8971%. Dengan demikian, LSTM lebih direkomendasikan untuk prediksi nilai absolut kurs jangka pendek, sedangkan XGBoost lebih sesuai digunakan untuk memprediksi arah pergerakan nilai tukar.

Kata Kunci nilai tukar USD/IDR; LSTM; XGBoost; prediksi

Abstract

The exchange rate of the rupiah against the U.S. dollar is a dynamic economic indicator that is sensitive to both global and domestic macroeconomic conditions. This study aims to describe the characteristics of the USD/IDR exchange rate time series data, build optimal *Extreme Gradient Boosting* (XGBoost) and *Long Short-Term Memory* (LSTM) models, and compare the predictive accuracy of the two models. The data used consists of daily Bank Indonesia Transaction Exchange Rates from January 2, 2015, to December 31, 2025, with a total of 2,687 observations, utilizing 27 derived features including *lag*, *simple moving average*, daily *return*, volatility, and trend indicators. Evaluation was conducted using a one-step-ahead *rolling forecast* scheme with an 80:10:10 data split, along with the metrics RMSE, MAPE, Adjusted R^2 , and *Directional*

*Corresponding author. Email: atikwintarti@unesa.ac.id or ulfanuraini@unesa.ac.id.

Accuracy. The analysis results indicate that the data is non-stationary, exhibiting a long-term depreciation trend and peak volatility in April 2020. The XGBoost and LSTM models were then optimized prior to evaluation. On the test data, LSTM delivered the best performance with an RMSE of Rp57.30, a MAPE of 0.2621%, and an Adjusted R^2 of 0.9381, while XGBoost achieved an RMSE of Rp163.20, a MAPE of 0.6308%, and an Adjusted R^2 of 0.5049. Conversely, XGBoost produced a higher *Directional Accuracy* of 67.67%, compared to LSTM's 48.30%. Validation using actual data from January 5-9, 2026, also showed that LSTM produced more accurate predictions with a MAPE of 0.1548%, while XGBoost achieved a MAPE of 5.8971%. Thus, LSTM is more recommended for predicting short-term absolute exchange rates, while XGBoost is more suitable for predicting the direction of exchange rate movements.

Keywords *exchange rate USD/IDR; LSTM; XGBoost; prediction*

1 Pendahuluan

Nilai tukar adalah variabel ekonomi yang menunjukkan harga sebuah mata uang terhadap mata uang negara lain secara relatif. Dalam perekonomian yang terbuka, perubahan nilai tukar mata uang tidak hanya memengaruhi transaksi valuta asing, tetapi juga berdampak pada perdagangan internasional, aliran modal, daya saing produk ekspor, serta harga barang yang diimpor (Mishkin, 2019; Krugman et al., 2018). Sejak Indonesia menerapkan sistem nilai tukar mengambang bebas setelah krisis moneter Asia tahun 1997, nilai Rupiah bergerak sesuai dengan mekanisme pasar valuta asing, bukan lagi kurs tetap (Bank Indonesia, 2024b), sehingga perubahan nilainya perlu diawasi terus-menerus sebagai salah satu indikator stabilitas perekonomian dalam negeri. Urgensi pengamatan ini semakin nyata mengingat Rupiah tercatat mengalami episode depresiasi tajam pada krisis moneter 1997 serta volatilitas ekstrem pada awal pandemi COVID-19 tahun 2020, sehingga pemantauan berkelanjutan terhadap pergerakan USD/IDR menjadi krusial baik bagi otoritas moneter maupun pelaku usaha yang bergantung pada transaksi valuta asing. Sebagai otoritas moneter, Bank Indonesia menyediakan data Kurs Transaksi yang dihitung menggunakan pendekatan rata-rata tertimbang berdasarkan volume transaksi spot USD/IDR (Bank Indonesia, 2024a), sehingga data ini banyak digunakan sebagai acuan resmi dalam analisis dan pengambilan keputusan terkait nilai tukar.

Perkembangan metode komputasi dalam beberapa tahun terakhir mendorong penggunaan *machine learning* dan *deep learning* dalam peramalan data finansial. Sejumlah penelitian terdahulu secara konsisten melaporkan keunggulan LSTM pada berbagai pasangan mata uang: Yang dkk. menerapkan LSTM dengan mekanisme *attention* pada nilai tukar Renminbi Tiongkok dan memperoleh RMSE yang lebih rendah dibandingkan ARIMA dan GARCH (Yang et al., 2021), sementara Chen dkk. menggabungkan LSTM dengan transformasi *wavelet* dan mencatat peningkatan akurasi hingga 23% dibandingkan LSTM standar (Chen et al., 2022). Pada nilai tukar India Rupee, Kumar dkk. menunjukkan bahwa LSTM dengan optimasi hiperparameter sistematis menghasilkan prediksi yang lebih stabil dibandingkan model ekonometrik konvensional, terutama pada periode volatilitas tinggi (Kumar et al., 2023), sedangkan pada data finansial Indonesia, Devi dan Hendikawati menegaskan bahwa pendekatan *deep learning* seperti LSTM merupakan solusi yang tepat untuk mengatasi keterbatasan model linear pada kondisi pasar yang dinamis (Devi and Hendikawati, 2024). Untuk kawasan ASEAN, Zhang dkk. menerapkan *bidirectional* LSTM dan melaporkan akurasi yang lebih unggul dalam menangkap dinamika pasar yang cepat berubah (Zhang et al., 2024). Di sisi lain, XGBoost banyak diterapkan pada kasus prediksi karena mampu menangani hubungan kompleks antarfitur serta memiliki efisiensi komputasi yang baik

(Chen et al., 2016). Perbedaan cara kerja kedua model ini membuat perbandingan kinerjanya menjadi relevan, khususnya pada data nilai tukar Rupiah terhadap Dolar Amerika Serikat.

Meskipun penelitian-penelitian tersebut menunjukkan performa LSTM yang unggul pada beragam pasangan mata uang dan konteks data finansial, sebagian besar studi menggunakan kurs Rupiah secara umum atau mengutamakan pada pengembangan model hibrida, sedangkan penggunaan Kurs Transaksi Bank Indonesia sebagai acuan resmi serta evaluasi langsung antara XGBoost dan LSTM sebagai model individual masih terbatas (Makridakis et al., 2018). Karena ada keterbatasan tersebut, penelitian ini bertujuan untuk membandingkan kemampuan model XGBoost dan LSTM dalam memprediksi nilai tukar Rupiah terhadap Dolar Amerika Serikat dengan menggunakan data kurs transaksi yang dikeluarkan oleh Bank Indonesia dari periode 2015 sampai 2025.

Evaluasi performa model menggunakan metrik RMSE (*Root Mean Square Error*), MAPE (*Mean Absolute Percentage Error*), dan Adjusted R^2 (Hyndman and Athanasopoulos, 2021), dilengkapi *Directional Accuracy* untuk menilai kemampuan model memprediksi arah pergerakan nilai tukar. Penelitian ini juga menerapkan pendekatan *rolling forecast* sebagai skema evaluasi, di mana periode pelatihan dan pengujian digeser secara bertahap mengikuti urutan waktu (Bergmeir et al., 2018), sehingga lebih mencerminkan kondisi peramalan di dunia nyata dibandingkan pembagian data yang tetap.

Rumusan masalah dalam penelitian ini adalah: (1) bagaimana karakteristik data deret waktu nilai tukar USD/IDR berdasarkan Kurs Transaksi Bank Indonesia periode 2015–2025; (2) bagaimana model XGBoost dan LSTM yang optimal untuk memprediksi nilai tukar tersebut; dan (3) bagaimana perbandingan kinerja kedua model yang telah dilatih.

2 Metode

Penelitian ini mengikuti tahapan sistematis mulai dari pengumpulan data hingga penarikan kesimpulan, sebagaimana digambarkan pada diagram alir penelitian (Gambar 1). Sebagaimana terlihat pada Gambar 1, alur penelitian dimulai dari pengumpulan data dan analisis eksplorasi (EDA), dilanjutkan dengan pra-pemrosesan, rekayasa fitur, pembagian data, normalisasi, hingga pembangunan dan penalaan hiperparameter model XGBoost dan LSTM secara paralel. Kedua model kemudian dilatih dan dievaluasi validitasnya sebelum masuk ke tahap pengujian, perbandingan performa, pemilihan model terbaik, dan peramalan (*forecasting*).

2.1 Dataset

Sumber data penelitian ini adalah data sekunder berupa data harian Kurs Transaksi Bank Indonesia USD/IDR yang dipublikasikan melalui portal statistik resmi Bank Indonesia (Bank Indonesia, 2024a). Data mencakup periode 2 Januari 2015 sampai dengan 31 Desember 2025 dengan total 2.687 observasi harian. Data tidak tersedia pada hari libur Bank Indonesia, sehingga hanya data pada hari kerja yang digunakan dalam analisis.

2.2 Variabel dan Rekayasa Fitur

Variabel endogen dalam penelitian ini terdiri dari kurs beli (x_t^{beli}) dan kurs jual (x_t^{jual}) USD/IDR, yang digunakan untuk menghitung kurs tengah sebagai target prediksi (Safitri and Jamal, 2020):

$$y_t = \frac{x_t^{\text{beli}} + x_t^{\text{jual}}}{2} \quad (1)$$




Figure 1: Diagram Alir Penelitian

Keterangan :

y_t = Nilai kurs tengah pada hari ke- t ,

x_t^{jual} = Nilai kurs jual pada hari ke- t ,

x_t^{beli} = Nilai kurs beli pada hari ke- t ,

Dimana x_t^{jual} adalah nilai kurs jual dan x_t^{beli} adalah nilai kurs beli USD/IDR pada hari ke- t . Kurs tengah (y_t) merepresentasikan nilai tukar rata-rata antara kurs jual dan kurs beli, sehingga lebih mencerminkan nilai wajar transaksi USD/IDR dibandingkan menggunakan kurs jual atau kurs beli secara terpisah, yang masing-masing dipengaruhi oleh margin *spread* yang diterapkan bank.

Pembentukan variabel eksogen mengikuti praktik umum rekayasa fitur pada peramalan deret waktu finansial, dengan tujuan membantu model mengenali ketergantungan waktu, tren, serta tingkat fluktuasi data. Fitur lag dipilih karena merepresentasikan nilai historis variabel target yang menangkap pola autokorelasi dan ketergantungan temporal data, sehingga model yang tidak memiliki memori internal seperti XGBoost tetap dapat mengenali konteks historisnya (Hyndman and Athanasopoulos, 2021). Fitur SMA digunakan untuk menghaluskan fluktuasi jangka pendek dan menonjolkan kecenderungan tren, sehingga membantu mereduksi *noise* pada data (Hassani et al., 2025). Fitur return digunakan untuk merepresentasikan dinamika perubahan nilai dari waktu ke waktu serta membantu mengurangi efek non-stasioneritas pada data (Tsay, 2010). Sementara itu, fitur volatilitas berupa *rolling standard deviation* digunakan untuk merepresentasikan tingkat ketidakstabilan dan risiko pada data finansial, sehingga membantu model membedakan kondisi pasar yang relatif stabil maupun bergejolak (Godoy Pulecio and Ojeda Echeverri, 2025).

Berdasarkan pertimbangan tersebut, variabel eksogen dibentuk dari nilai historis ketiga variabel endogen (kurs jual, beli, dan tengah), terdiri atas 24 fitur dasar: fitur lag pada periode 1, 7, dan 30 hari (9 fitur), *Simple Moving Average* (SMA) dengan window 7 dan 30 hari (6 fitur), return harian (3 fitur), serta volatilitas berupa *rolling standard deviation* dengan window 7 dan 30 hari (6 fitur). Pemilihan rentang lag dan window (1, 7, dan 30 hari) didasarkan pada kombinasi antara praktik umum rekayasa fitur deret waktu finansial dan hasil analisis ACF/PACF pada

Subbab 3.1. SMA dirumuskan sebagai (Nugroho, 2020) :

$$\text{SMA}_n(t) = \frac{1}{n} \sum_{i=0}^{n-1} y_{t-i}, \quad (2)$$

sedangkan return sederhana dirumuskan sebagai (Hartono, 2022) :

$$R_t = \frac{y_t - y_{t-1}}{y_{t-1}}. \quad (3)$$

Tiga fitur tren tambahan ditambahkan, yaitu `time_index` untuk merepresentasikan urutan waktu observasi, serta `price_vs_ma7` dan `price_vs_ma30` yang masing-masing menunjukkan selisih kurs tengah aktual terhadap SMA 7 dan 30 hari sebagai indikator posisi harga relatif terhadap tren jangka pendek dan menengah. Dengan demikian, total fitur input yang digunakan oleh kedua model adalah **27 fitur**. Rekapitulasi lengkap 27 fitur eksogen yang digunakan disajikan pada Tabel 1.

Table 1: Rekapitulasi Fitur yang Digunakan

Type Fitur	Keterangan	Variabel Sumber	Jumlah
Lag (1, 7, 30 hari)	Nilai historis y_{t-k}	Kurs Jual, Beli, Tengah	9
SMA (7 dan 30 hari)	$\text{SMA}_n(t)$	Kurs Jual, Beli, Tengah	6
Return (1 hari)	$R_t = \frac{y_t - y_{t-1}}{y_{t-1}}$	Kurs Jual, Beli, Tengah	3
Volatilitas (7, 30)	$\sigma_n(t)$	Kurs Jual, Beli, Tengah	6
Total Fitur Dasar			24
Fitur Tren Tambahan (XGBoost dan LSTM)	<code>time_index</code> , <code>price_vs_ma7</code> , <code>price_vs_ma30</code> , Kurs Tengah		3
TOTAL FITUR XGBOOST & LSTM			27

2.3 Analisis Autokorelasi (ACF dan PACF)

Sebelum pembentukan fitur lag, dilakukan analisis *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) pada ketiga variabel endogen hingga lag ke-40. ACF mengukur tingkat korelasi antara suatu observasi deret waktu dengan observasi pada lag-lag sebelumnya dan digunakan untuk mengidentifikasi keberadaan memori jangka pendek maupun jangka panjang dalam data (Box et al., 2015; Hamilton, 1994), sedangkan PACF mengukur korelasi antara Y_t dan Y_{t-k} setelah pengaruh lag-lag di antaranya dikendalikan, sehingga memberikan gambaran mengenai lag-lag yang memiliki pengaruh dominan terhadap nilai saat ini (Wei, 2019).

Dalam penelitian ini, ACF dan PACF tidak digunakan untuk menentukan parameter model statistik klasik seperti ARIMA, melainkan sebagai alat bantu analisis struktur temporal data. Pada model XGBoost, informasi dari ACF dan PACF dimanfaatkan sebagai dasar pertimbangan dalam pemilihan jumlah dan rentang lag yang digunakan sebagai fitur input, mengingat XGBoost tidak memiliki mekanisme memori temporal secara eksplisit (Sezer et al., 2020; Bentejac et al.,

2021). Pada model LSTM, analisis ACF dan PACF digunakan untuk memberikan gambaran mengenai panjang ketergantungan temporal data sebagai pertimbangan dalam penentuan *time steps* yang diuji, meskipun pemodelan ketergantungan temporal pada LSTM tetap dilakukan secara internal melalui mekanisme memori pada arsitekturnya (Hochreiter and Schmidhuber, 1997). Hasil analisis ACF dan PACF disajikan pada Subbab 3.1.

2.4 Pembagian Data dan Skema Evaluasi




Figure 2: Pembagian Data (Train, Validation, Test) Kurs Tengah USD/IDR

Data dibagi secara kronologis tanpa pengacakan (*shuffle*) dengan proporsi 80:10:10, menghasilkan 2.125 observasi data latih (13 Februari 2015–9 Oktober 2023), 266 observasi data validasi (10 Oktober 2023–15 November 2024), dan 266 observasi data uji (18 November 2024–31 Desember 2025). Normalisasi dilakukan menggunakan *MinMaxScaler* ke rentang $[0, 1]$ yang hanya di-fit pada data latih untuk mencegah kebocoran data (*data leakage*).

Evaluasi performa model menggunakan skema *rolling forecast* satu langkah ke depan (*one-step-ahead*), di mana model dilatih menggunakan data historis hingga periode t untuk memprediksi nilai tukar pada periode $t + 1$. Setelah prediksi dibuat, data aktual periode $t + 1$ ditambahkan ke data pelatihan, dan proses diulang untuk periode berikutnya. Gambar 2 memvisualisasikan pembagian data latih, validasi, dan uji tersebut secara kronologis sepanjang periode pengamatan 2015–2025.

2.5 Pemodelan XGBoost

XGBoost membangun prediksi dengan menggabungkan sejumlah pohon keputusan secara bertahap, dengan prediksi untuk observasi ke- i dirumuskan sebagai

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), \quad (4)$$

dengan K adalah jumlah total pohon dan f_k adalah fungsi pohon keputusan ke- k (Chen et al., 2016). Optimasi hiperparameter dilakukan melalui *RandomizedSearchCV* dengan *PredefinedSplit*

satu *split* untuk menjaga urutan kronologis data, menguji 30 kombinasi hiperparameter ($n_iter = 30$).

2.6 Pemodelan LSTM

Secara arsitektural, LSTM dapat dipandang sebagai rantai unit berulang yang masing-masing memiliki mekanisme regulasi informasi berupa sejumlah gerbang (*gate*). Setiap gerbang merupakan lapisan jaringan saraf dengan fungsi aktivasi sigmoid yang menghasilkan nilai antara 0 dan 1 untuk mengatur banyaknya informasi yang diteruskan.

Long Short-Term Memory (LSTM) merupakan varian *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi masalah *vanishing gradient* pada RNN standar, sehingga mampu mempelajari dependensi jangka panjang pada data sekuensial (Hochreiter and Schmidhuber, 1997). Pada RNN standar, gradien terhadap parameter pada langkah waktu awal diperoleh melalui perkalian berulang turunan fungsi aktivasi dan matriks bobot sepanjang langkah waktu, sehingga nilainya cenderung mengecil secara eksponensial seiring bertambahnya panjang sekuens. LSTM mengatasi keterbatasan ini melalui *cell state* (C_t), yaitu jalur memori yang membawa informasi antar langkah waktu dengan interaksi linear minimal dan diperbarui secara aditif, bukan melalui perkalian matriks berulang, sehingga gradien dapat mengalir lebih stabil. Aliran informasi pada cell state ini dikendalikan oleh tiga mekanisme gerbang, yaitu *forget gate*, *input gate*, dan *output gate*.

Forget gate menentukan informasi pada cell state sebelumnya (C_{t-1}) yang dipertahankan atau dibuang, dengan persamaan sebagai berikut.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (5)$$

sedangkan *input gate* menentukan seberapa besar informasi baru yang akan disimpan ke dalam cell state,

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (6)$$

yang dikombinasikan dengan kandidat cell state yang merepresentasikan nilai informasi baru yang berpotensi ditambahkan,

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C). \quad (7)$$

Cell state kemudian diperbarui dengan mengombinasikan hasil perkalian forget gate dengan cell state sebelumnya dan hasil perkalian input gate dengan kandidat cell state pada Persamaan (7),

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t. \quad (8)$$

Selanjutnya, *output gate* menentukan bagian dari cell state yang akan digunakan sebagai hidden state pada waktu ke- t ,

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (9)$$

sehingga hidden state akhirnya dihasilkan sebagai

$$h_t = o_t \odot \tanh(C_t), \quad (10)$$

dengan $\sigma(\cdot)$ adalah fungsi aktivasi sigmoid, $\tanh(\cdot)$ adalah fungsi aktivasi hiperbolik tangen, $\odot$ menyatakan operasi perkalian elemen-wise (*Hadamard product*), W_f, W_i, W_C, W_o adalah matriks bobot, dan b_f, b_i, b_C, b_o adalah vektor bias (Hochreiter and Schmidhuber, 1997). Kemampuan

LSTM dalam menyeleksi dan mempertahankan informasi jangka panjang menjadikannya sesuai untuk pemodelan data nilai tukar USD/IDR, yang bersifat non-linear, fluktuatif, dan dipengaruhi oleh pola historis yang tidak selalu berjarak dekat secara temporal.

Mekanisme gerbang tersebut memungkinkan LSTM mempertahankan informasi relevan dalam jangka panjang melalui cell state dengan perubahan minimal, sekaligus membuang informasi yang tidak lagi relevan dan menyerap informasi baru yang penting, sehingga model mampu menghasilkan prediksi yang lebih stabil dibandingkan RNN standar (Hochreiter and Schmidhuber, 1997). Eksplorasi dilakukan pada empat nilai *time steps* ($ts \in \{1, 7, 14, 30\}$) untuk menentukan panjang sekuens input optimal. Arsitektur LSTM yang digunakan dalam penelitian ini terdiri atas lima lapisan, sebagaimana dirangkum pada Tabel 2.

Lapisan *input* menerima data dengan bentuk $(ts, 27)$, dengan ts adalah *time steps* yang diuji ($ts \in \{1, 7, 14, 30\}$) dan 27 adalah jumlah fitur input. Lapisan output berupa *Dense* dengan 3 unit dirancang untuk memprediksi ketiga variabel endogen (Kurs Jual, Beli, dan Tengah) secara simultan dalam satu model, meskipun pembahasan hasil pada artikel ini difokuskan pada variabel Kurs Tengah sebagai target utama sesuai rumusan masalah penelitian. Konfigurasi pelatihan model LSTM disajikan pada Tabel 3.

2.7 Metrik Evaluasi

Performa kedua model dibandingkan menggunakan empat metrik, yaitu RMSE, MAPE, Adjusted R^2 , dan *Directional Accuracy* (DA), dengan y_t adalah nilai aktual pada periode ke- t , $\hat{y}_t$ adalah nilai prediksi pada periode ke- t , y_{t-1} adalah nilai aktual pada periode ke- $(t-1)$, n adalah jumlah observasi pada data evaluasi, p adalah jumlah variabel prediktor, dan R^2 adalah koefisien determinasi. Fungsi $\text{sign}(\cdot)$ pada rumus DA menghasilkan nilai +1 jika terjadi kenaikan, -1 jika terjadi penurunan, dan 0 jika tidak terdapat perubahan pada argumennya (Hyndman and Athanasopoulos, 2021; Armstrong, 2001). RMSE dirumuskan sebagai

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}, \quad (11)$$

MAPE dirumuskan sebagai

$$\text{MAPE} = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|, \quad (12)$$

Adjusted R^2 dirumuskan sebagai

$$\text{Adjusted } R^2 = 1 - (1 - R^2) \frac{n-1}{n-p-1}, \quad (13)$$

dan *Directional Accuracy* (DA) dirumuskan sebagai

$$DA = \frac{1}{n} \sum_{t=1}^n \mathbf{1}_{\text{sign}(\hat{y}_t - y_{t-1}) = \text{sign}(y_t - y_{t-1})} \quad (14)$$

Interpretasi nilai MAPE mengacu pada kriteria yang ditetapkan oleh Makridakis (1993), yaitu MAPE di bawah 10% menunjukkan akurasi model yang sangat baik, 10%-20% tergolong

baik, 20%–50% tergolong wajar, dan di atas 50% tergolong tidak akurat serta kurang dapat diandalkan untuk peramalan.

Penggunaan *Directional Accuracy* sebagai metrik tambahan didasarkan pada pertimbangan bahwa RMSE, MAPE, dan Adjusted R^2 hanya mengukur besar kesalahan prediksi secara angka, tanpa mempertimbangkan kemampuan model dalam menangkap arah pergerakan nilai tukar yang bermanfaat untuk pengambilan keputusan, seperti dalam strategi lindung nilai (*hedging*) atau keputusan bertransaksi valuta asing (Costantini et al., 2016). Dengan menggabungkan metrik yang mengukur kesalahan angka dan metrik yang mengukur arah perubahan, performa XGBoost dan LSTM bisa dinilai lebih lengkap, baik dalam hal ketepatan nilai maupun ketepatan arah, sesuai dengan tujuan penelitian untuk membandingkan kedua model secara menyeluruh

3 Hasil dan Pembahasan

3.1 Karakteristik Data

Statistik deskriptif variabel kurs tengah USD/IDR selama periode 2015–2025 disajikan pada Tabel 4.

Berdasarkan Tabel 4, kurs tengah USD/IDR selama 2015–2025 memiliki rata-rata Rp 14.516,98 dengan standar deviasi Rp 1.044,55, nilai minimum Rp 12.444,00 (23 Januari 2015), dan nilai maksimum Rp 16.943,00 (10 April 2025). Deteksi outlier menggunakan metode IQR (batas $3 \times \text{IQR}$) tidak menemukan outlier ekstrem pada seluruh 2.687 observasi.

Analisis tren jangka panjang menggunakan SMA 7 dan 30 hari pada Gambar 3 menunjukkan pola depresiasi Rupiah yang konsisten sepanjang periode pengamatan, dengan volatilitas tertinggi tercatat di sekitar 22 April 2020, bertepatan dengan awal gejolak pasar keuangan global akibat pandemi COVID-19.

Analisis Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF) pada ketiga variabel endogen, sebagaimana ditampilkan pada Gambar 4, memperlihatkan pola *gradual decay* pada ACF yang tetap signifikan hingga lag ke-40, mengindikasikan data bersifat non-stasioner dengan memori jangka panjang (*long memory*). Sebaliknya, PACF menunjukkan korelasi parsial paling dominan berada pada lag pertama, yang menjadi dasar pemilihan fitur lag (1, 7, dan 30 hari) serta mendukung penggunaan *time steps* = 1 sebagai konfigurasi LSTM terbaik.

3.2 Model Optimal

Hasil optimasi hiperparameter XGBoost melalui `RandomizedSearchCV` menghasilkan konfigurasi terbaik berupa $n_estimators = 300$, $max_depth = 4$, $learning_rate = 0.08$, $subsample = 0.9$, dan $colsample_bytree = 0.7$, dengan Best CV RMSE (scaled) sebesar 0.069906 (Tabel 5).

Eksplorasi konfigurasi *time steps* pada LSTM menunjukkan bahwa $ts = 1$ menghasilkan MAPE terendah secara konsisten pada seluruh variabel target (Tabel 6). Arsitektur LSTM terbaik terdiri dari satu lapisan LSTM dengan 64 unit, *Dropout* sebesar 0.2, serta lapisan *Dense* (32 unit, aktivasi ReLU) dengan regularisasi L2 (1×10^{-4}) sebelum lapisan output.

3.3 Perbandingan Kinerja Model

Tabel 7 merangkum hasil evaluasi kedua model pada 266 observasi data uji untuk variabel Kurs Tengah USD/IDR.

Table 2: Arsitektur Model LSTM yang Digunakan

Lapisan	Tipe	Parameter	Keterangan
1	Input	Shape ($ts, 27$)	Ditentukan otomatis saat <i>training</i>
2	LSTM	64 unit, aktivasi tanh	Menangkap dependensi temporal
3	Dropout	Rate = 0,2	Regularisasi <i>overfitting</i>
4	Dense (hidden)	32 unit, ReLU, L2 (1×10^{-4})	Representasi non-linear <i>output</i>
5	Dense (output)	3 unit	<i>Output</i> : Kurs Jual, Beli, Tengah

Table 3: Konfigurasi Pelatihan Model LSTM

Parameter	Nilai	Keterangan
Optimizer	Adam, $lr = 0.001$	Mengoptimalkan bobot model
Loss Function	Mean Squared Error (MSE)	Mengukur kesalahan prediksi
Batch Size	32	Jumlah data per proses pelatihan
Early Stopping	Patience = 10, monitor = val_loss	Mencegah overfitting
Max Epochs	200	Batas maksimum pelatihan

Table 4: Statistik Deskriptif Kurs Tengah USD/IDR (2015–2025)

Statistik	Nilai (Rp)
Rata-rata (Mean)	14.516,98
Standar Deviasi	1.044,55
Minimum (23-01-2015)	12.444,00
Kuartil 1 (Q1)	13.643,50
Median (Q2)	14.342,00
Kuartil 3 (Q3)	15.252,50
Maksimum (10-04-2025)	16.943,00




Figure 3: Analisis Tren Jangka Panjang Kurs Tengah USD/IDR dengan SMA 7 dan 30 Hari




Figure 4: Plot ACF dan PACF Variabel Endogen (Kurs Jual, Beli, Tengah)

Table 5: Hiperparameter Terbaik Model XGBoost

Hiperparameter	Ruang Pencarian	Nilai Terpilih
n_estimators	{300, 500, 700, 900, 1000}	300
max_depth	{3, 4, 5, 6, 7}	4
learning_rate	{0.01, 0.02, 0.05, 0.08, 0.1}	0.08
subsample	{0.6, 0.7, 0.8, 0.9, 1.0}	0.9
colsample_bytree	{0.6, 0.7, 0.8, 0.9, 1.0}	0.7
reg_lambda	{0.5, 1.0, 1.5}	0.5

Table 6: Perbandingan Kinerja LSTM Berdasarkan Time Steps untuk Kurs Tengah (Data Uji)

Time Steps	RMSE (Rp)	MAPE (%)	Adjusted R^2
1	57.30	0.2621	0.9381
7	196.79	1.0964	0.1871
14	143.18	0.7829	0.5079
30	94.02	0.4811	0.7352

Table 7: Hasil Evaluasi Metrik Model XGBoost dan LSTM pada Data Uji (Kurs Tengah)

Model	RMSE (Rp)	MAPE (%)	Adjusted R^2	DA (%)
XGBoost	163.20	0.6308	0.5049	67.67
LSTM ($ts = 1$)	57.30	0.2621	0.9381	48.30

Berdasarkan Tabel 7, LSTM unggul pada tiga metrik kesalahan absolut: RMSE, MAPE, dan Adjusted R^2 . Nilai Adjusted R^2 LSTM sebesar 0.9381 menunjukkan model mampu menjelaskan sebagian besar variasi data uji, jauh di atas XGBoost sebesar 0.5049. Sebaliknya, XGBoost unggul pada *Directional Accuracy* sebesar 67.67% dibandingkan LSTM sebesar 48.30%, nilai yang bahkan berada di bawah ambang 50%, mengindikasikan kemampuan LSTM memprediksi arah pergerakan tidak lebih baik dibandingkan tebakan acak (*random guess*).

3.4 Validasi pada Data Test Januari 2026

Validasi eksternal dilakukan menggunakan data test Kurs Transaksi Bank Indonesia periode 5–9 Januari 2026, yaitu periode di luar data pelatihan maupun pengujian utama. Tabel 9 menyajikan rincian nilai aktual dibandingkan dengan hasil prediksi kedua model untuk setiap hari pada periode tersebut.

Table 8: Evaluasi Kinerja Prediksi Minggu 5–9 Januari 2026 (Kurs Tengah)

Metrik	XGBoost	LSTM
RMSE (Rp)	1.610.54	30.45
MAPE (%)	5.8971	0.1548

Berdasarkan Tabel 8, rata-rata MAPE selama periode validasi 5–9 Januari 2026 dihitung sebesar 5.8971% untuk XGBoost dan 0.1548% untuk LSTM. Selisih ini mengonfirmasi keunggulan LSTM sebagaimana disebutkan pada bagian abstrak, dengan tingkat kesalahan LSTM sekitar 38 kali lebih kecil dibandingkan XGBoost pada periode validasi eksternal ini.

Table 9: Perbandingan Prediksi vs Test Kurs Tengah USD/IDR, 5–9 Januari 2026

Tanggal	Aktual (Rp)	XGBoost (Rp)	Err XGB (Rp)	LSTM (Rp)	Err LSTM (Rp)
05 Jan 2026	16.725,00	16.423,97	301,04	16.763,36	38.36
06 Jan 2026	16.748,00	16.634,60	113,40	16.755,95	7.95
07 Jan 2026	16.762,00	13.280,19	3.481,81	16.754,93	7.07
08 Jan 2026	16.785,00	15.949,55	835,45	16.754,78	30.22
09 Jan 2026	16.801,00	16.589,51	211,49	16.754,76	46.24

Berdasarkan Tabel 9, hasil prediksi LSTM secara umum lebih mendekati nilai aktual dibandingkan XGBoost. Kesalahan harian pada model LSTM relatif kecil dan stabil, yaitu berada pada kisaran Rp 7,07 hingga Rp 46,24. Sebaliknya, XGBoost menunjukkan kesalahan prediksi yang lebih besar dan cenderung tidak konsisten. Penyimpangan paling mencolok terjadi pada 7 Januari 2026, ketika XGBoost memprediksi kurs tengah sebesar Rp 13.280,19, sedangkan nilai aktualnya mencapai Rp 16.762,00. Dengan demikian, selisih kesalahan pada tanggal tersebut melebihi Rp 3.480. Temuan ini menunjukkan bahwa LSTM lebih konsisten dalam mengikuti perubahan kurs tengah selama periode validasi eksternal, sedangkan XGBoost lebih rentan mengalami penyimpangan tajam pada observasi tertentu.

Namun, penyimpangan ekstrem XGBoost pada 7 Januari 2026 tidak berlangsung secara berkelanjutan. Pada 8 dan 9 Januari 2026, hasil prediksi XGBoost kembali mendekati kisaran nilai aktual, dengan selisih kesalahan masing-masing menurun menjadi Rp 835.45 dan Rp 211.49. Kesalahan tersebut lebih mencerminkan sensitivitas model terhadap pembaruan fitur lag dan

moving average, khususnya ketika data baru mulai berada di luar pola yang dominan selama proses pelatihan.




Figure 5: Prediksi XGBoost dan LSTM vs Aktual Kurs Tengah Periode 5–9 Januari 2026

Gambar 5 memperlihatkan bahwa garis prediksi LSTM (segitiga biru) hampir berhimpit dengan garis aktual data BI (lingkaran hitam) sepanjang periode validasi, sedangkan garis prediksi XGBoost (kotak merah) menunjukkan penyimpangan tajam pada 7 Januari 2026 sebelum kembali mendekati nilai aktual pada hari-hari berikutnya.

Analisis *confidence interval* 95% pada Gambar 6 memperlihatkan rentang ketidakpastian XGBoost (Rp 507–Rp 1.133) jauh lebih lebar dibandingkan LSTM (Rp 225–Rp 503) sepanjang periode validasi, mengindikasikan XGBoost lebih rentan terhadap data yang bergerak di luar rentang nilai pada data latihnya, sebagai konsekuensi dari penggunaan *MinMaxScaler* statis yang hanya di-*fit* pada data latih historis.

4 Kesimpulan

Data kurs tengah USD/IDR dari tahun 2015 hingga 2025 menunjukkan sifat yang tidak stabil, dengan tren penurunan nilai tukar jangka panjang dan adanya pola ketergantungan terhadap waktu. Volatilitas yang paling tinggi terjadi pada awal wabah COVID-19. Dalam penelitian ini, model XGBoost dan LSTM dibuat dengan cara mengoptimalkan parameter-parameter secara sistematis menggunakan 27 fitur input yang sama. Hasil perbandingan kemampuan menunjukkan bahwa LSTM terus-menerus memberikan hasil yang lebih baik dalam memperkirakan nilai kurs jangka pendek secara absolut, baik pada data uji maupun pada pengujian eksternal menggunakan data aktual Januari 2026. Kinerja prediksi LSTM termasuk dalam kategori yang sangat baik karena tingkat kesalahannya, yang diukur dengan MAPE, berada di bawah 10% sesuai kriteria yang telah dijelaskan pada bagian metode. Sementara itu, XGBoost menunjukkan performa yang lebih baik dalam memprediksi arah pergerakan nilai tukar, dengan akurasi arah mencapai 67.67%.

Dalam prakteknya, LSTM lebih direkomendasikan untuk kebutuhan memperkirakan nilai tukar mata uang yang membutuhkan tingkat ketepatan yang tinggi, terutama dalam perencanaan keuangan jangka pendek. Di sisi lain, XGBoost tetap bisa dipertimbangkan sebagai




Figure 6: Prediksi Kurs Tengah USD/IDR dengan Interval Kepercayaan 95% Periode 5–9 Januari 2026

model acuan, terutama dalam menganalisis arah pergerakan pasar. Penelitian selanjutnya sebaiknya menggali lebih dalam tentang arsitektur gabungan XGBoost dan LSTM, menambahkan variabel-variabel makroekonomi dari luar, serta menerapkan metode normalisasi yang lebih fleksibel, seperti normalisasi dengan *rolling window*, untuk mengatasi kekurangan dari metode normalisasi *MinMaxScaler* yang statis.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Program Studi Sarjana Sains Data Universitas Negeri Surabaya serta seluruh pihak yang telah memberikan dukungan dan masukan selama pelaksanaan penelitian ini.

References

- Armstrong, J. S. (2001). Combining forecasts. In Armstrong, J. S., editor, *Principles of Forecasting: A Handbook for Researchers and Practitioners*, pages 417–439. Springer, Boston, MA.
- Bank Indonesia (2024a). Jisdor - jakarta interbank spot dollar rate. <https://www.bi.go.id/id/statistik/informasi-kurs/jisdor/default.aspx>. Diakses: 1 November 2025.
- Bank Indonesia (2024b). Kebijakan nilai tukar. <https://www.bi.go.id/id/fungsi-utama/moneter/default.aspx>. Diakses: 1 November 2025.
- Bentejac, C., Csorgo, A., and Martinez-Munoz, G. (2021). A survey on tree-based machine learning methods and their applications. *ACM Computing Surveys*, 54(6):1–45.

- Bergmeir, C., Hyndman, R. J., et al. (2018). A note on the validity of cross-validation for evaluating autoregressive time series prediction. *Computational Statistics & Data Analysis*, 120:70–83.
- Box, G. E. P., Jenkins, G. M., et al. (2015). *Time Series Analysis: Forecasting and Control*. Holden-Day, San Francisco.
- Chen, T., Guestrin, C., et al. (2016). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pages 785–794. ACM.
- Chen, Y., Li, M., and Zhang, H. (2022). Hybrid lstm-wavelet transform for exchange rate forecasting. *Expert Systems with Applications*, 189:116067.
- Costantini, M., Cuaresma, J. C., and Hlouskova, J. (2016). Forecasting errors, directional accuracy and profitability of currency trading: The case of eur/usd exchange rate. *Journal of Forecasting*, 35(8).
- Devi, K. and Hendikawati, P. (2024). Deep learning methods for financial time series forecasting in indonesia. *Journal of Physics: Conference Series*, 2543(1):012045.
- Godoy Pulecio, D. A. and Ojeda Echeverri, C. A. (2025). An autoregressive moving average model for time series with irregular time intervals. *Computer Sciences & Mathematics Forum*, 11(1).
- Hamilton, J. D. (1994). *Time Series Analysis*. Princeton University Press, Princeton, NJ.
- Hartono, J. (2022). *Teori portofolio dan analisis investasi*. UGM Press.
- Hassani, H., Mashhad, L. M., et al. (2025). White noise and its misapplications: Impacts on time series model adequacy and forecasting. *Forecasting*, 7(1):8.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8):1735–1780.
- Hyndman, R. J. and Athanasopoulos, G. (2021). *Forecasting: Principles and Practice*. OTexts, Melbourne, Australia, 3rd edition. Diakses: 1 November 2025.
- Krugman, P. R., Obstfeld, M., and Melitz, M. J. (2018). *International Economics: Theory and Policy*. Pearson, New York, 11th edition.
- Kumar, A., Sharma, R., and Patel, V. (2023). Forecasting exchange rates with deep learning: A comprehensive study. *International Journal of Forecasting*, 39(2):654–672.
- Livieris, I. E., Pintelas, E., and Pintelas, P. (2020). A cnn-lstm model for gold price time-series forecasting. *Neural Computing and Applications*, 32(23):17351–17360.
- Makridakis, S. (1993). Accuracy measures: Theoretical and practical concerns. *International Journal of Forecasting*, 9(4):527–529.
- Makridakis, S., Spiliotis, E., and Assimakopoulos, V. (2018). Statistical and machine learning forecasting methods: Concerns and ways forward. *PLOS ONE*, 13(3):e0194889.
- Mishkin, F. S. (2019). *The Economics of Money, Banking, and Financial Markets*. Pearson, New York, 12th edition.
- Nugroho, A. (2020). Simple moving average pada sistem peramalan. *Jurnal Sainstech*, 7(2).
- Safitri, A. and Jamal, S. W. (2020). Analisis inflasi, kurs rupiah dan bi rate terhadap volume perdagangan saham di bursa efek indonesia (2016–2018). *Borneo Student Research*, 1(3):—.
- Sezer, O. B., Gudelek, U., and Ozbayoglu, M. U. (2020). Financial time series forecasting with deep learning: A systematic literature review. *Applied Soft Computing*, 90:106181.
- Susanto, D. (2024). Studi kasus: Analisis penggunaan teknologi machine translation dalam pen-erjemahan otomatis. *Tugas Mahasiswa Program Studi Informatika*, 1(2).
- Tsay, R. (2010). *Analysis of Financial Time Series*. Wiley, 3rd edition.

- Wei, W. W. S. (2019). *Time Series Analysis: Univariate and Multivariate Methods*. Pearson Addison Wesley, Boston, MA, 2nd edition.
- Yang, W., Wang, J., and Wang, R. (2021). Exchange rate forecasting with lstm and attention mechanism. *Computational Economics*, 58(4):1011–1035.
- Zhang, L., Chen, W., and Liu, J. (2024). Deep learning approaches for asean currency exchange rate prediction. *Journal of Forecasting*, 43(1):112–130.