

Perbandingan Kinerja Model ARIMA dan LSTM dalam Peramalan Harga Crypto Solana (SOL-USD) Berbasis Data Yahoo Finance

Wadiyan¹, Permata^{2,*}, Adhie Thyo Priandika², Rakhmat Dedi Gunawan²

¹ Fakultas Teknik dan Ilmu Komputer, Program Studi Informatika, Universitas Teknokrat Indonesia, Bandar Lampung, Indonesia

² Fakultas Teknik dan Ilmu Komputer, Program Studi Informatika, Universitas Teknokrat Indonesia, Bandar Lampung, Indonesia

Email: ¹wadiyan@teknokrat.ac.id, ^{2,*}permata@teknokrat.ac.id, ³adhie_thyo@teknokrat.ac.id, ⁴rakhmatdedig@teknokrat.ac.id

Email Penulis Korespondensi: permata@teknokrat.ac.id

Submitted: 24/02/2026; Accepted: 19/03/2026; Published: 19/03/2026

Abstrak—Mata uang kripto, khususnya Solana (SOL), telah menarik perhatian investor global karena volatilitas harganya yang tinggi dan potensi keuntungan yang besar. Volatilitas ekstrem dan pola non-linear pada data Solana (SOL), yang dipicu oleh mekanisme konsensus unik serta volume transaksi masif, menuntut metode peramalan yang akurat untuk memitigasi risiko investasi. Penelitian ini membandingkan metode statistik *Autoregressive Integrated Moving Average* (ARIMA) dan *Deep Learning Long Short-Term Memory* (LSTM) menggunakan data harga penutupan harian SOL-USD periode April 2020 hingga Maret 2025 dari Yahoo Finance. Model ARIMA dikembangkan dengan parameter optimal (0,1,0), sementara arsitektur LSTM menggunakan 50 unit *neuron* dengan *timesteps* 60 hari. Hasil evaluasi menunjukkan model LSTM mengungguli ARIMA secara signifikan dengan nilai RMSE 13,1352 dan MAPE 6,07% (kategori sangat baik), dibandingkan ARIMA yang menghasilkan RMSE 31,1241 dan MAPE 14,03%. Penelitian menyimpulkan bahwa pendekatan jaringan saraf tiruan lebih efektif dan adaptif dibandingkan metode statistik tradisional dalam menangkap dinamika harga aset kripto yang sangat fluktuatif.

Kata Kunci: ARIMA; Deep Learning; LSTM; Solana; Time Series; Volatility

Abstract—The extreme volatility and non-linear patterns of Solana (SOL) data, driven by its unique consensus mechanism and massive transaction volume, demand accurate forecasting methods to mitigate investment risks. This study compares the statistical method *Autoregressive Integrated Moving Average* (ARIMA) and *Deep Learning Long Short-Term Memory* (LSTM) using daily closing price data of SOL-USD from April 2020 to March 2025 obtained from Yahoo Finance. The ARIMA model was developed with optimal parameters (0,1,0), while the LSTM architecture utilized 50 hidden layer units with a 60-day timestep. Evaluation results indicate that the LSTM model significantly outperforms ARIMA, achieving an RMSE of 13.1352 and a MAPE of 6.07% (classified as highly accurate), compared to ARIMA's RMSE of 31.1241 and MAPE of 14.03%. The study concludes that neural network approaches are more effective and adaptive than traditional statistical methods in capturing the highly volatile price dynamics of crypto assets.

Keywords: ARIMA; Deep Learning; LSTM; Solana; Time Series; Volatility

1. PENDAHULUAN

Perkembangan teknologi finansial (*Fintech*) yang pesat telah melahirkan instrumen investasi digital baru, salah satunya adalah mata uang kripto (*cryptocurrency*) [1]. Di tengah ribuan aset kripto yang beredar, Solana (SOL) muncul sebagai salah satu aset dengan kapitalisasi pasar terbesar yang menawarkan karakteristik teknis berbeda dibandingkan pendahulunya, seperti Bitcoin dan Ethereum. Arsitektur Solana mengintegrasikan mekanisme konsensus *Proof of History* (PoH) dengan *Proof of Stake* (PoS) yang memungkinkan *throughput* transaksi sangat tinggi dengan biaya rendah [2]. Keunggulan teknis ini memicu volume transaksi yang masif dan kecepatan perputaran aset yang tinggi, sehingga pergerakan harganya memiliki volatilitas yang lebih ekstrem dan pola fluktuasi yang lebih kompleks dibandingkan aset kripto "*blue chip*" lainnya. Tingkat volatilitas Solana yang tinggi ini terdokumentasi secara spesifik dalam beberapa literatur yang mencatat bahwa dinamika pasarnya seringkali melampaui fluktuasi Bitcoin dalam periode waktu yang sama.

Fluktuasi harga yang ekstrem dan dipengaruhi oleh faktor eksternal yang kompleks ini menjadikan Solana sulit diprediksi jika hanya mengandalkan intuisi atau metode konvensional biasa. Penggunaan metode statistik tradisional sering kali menghadapi risiko kegagalan karena asumsi linearitas yang kaku, sehingga gagal menangkap lonjakan harga mendadak (*volatility shocks*) yang menjadi ciri khas aset digital. Ketidakpastian ini menuntut adanya model peramalan yang lebih adaptif dan presisi untuk meminimalkan risiko investasi.

Dalam literatur runtun waktu (*time series*), terdapat dua pendekatan utama yang sering dibandingkan kinerjanya: metode statistik linier dan metode kecerdasan buatan (*machine learning*) [3]. Metode *Autoregressive Integrated Moving Average* (ARIMA) telah lama menjadi standar karena efisiensinya dalam menangani data stasioner dengan tren linier [4]. Di sisi lain, *Long Short-Term Memory* (LSTM) menawarkan keunggulan dalam menangani data sekuensial dengan ketergantungan jangka panjang (*long-term dependencies*) dan pola non-linier yang kompleks [5].

Berbagai penelitian terdahulu telah mengeksplorasi komparasi kedua metode ini. Khotibul Umam dan Ardiansyah [6] membandingkan ARIMA dan LSTM untuk prediksi pengunjung perpustakaan, di mana mereka menemukan bahwa ARIMA lebih unggul dan efisien pada data dengan pola musiman yang teratur dan kurang kompleks. Sebaliknya, penelitian oleh Divanda et al. [7] pada kasus prediksi inflasi menunjukkan bahwa pendekatan model non-linier seperti LSTM cenderung memberikan hasil yang lebih akurat ketika data mengandung unsur volatilitas tinggi yang tidak dapat dijelaskan oleh model linier. Temuan ini didukung oleh Mandala dan Septi [8] yang

membandingkan ARIMA dan LSTM, menyimpulkan bahwa LSTM lebih adaptif terhadap dataset besar dengan fluktuasi dinamis dan perubahan iklim yang tidak menentu.

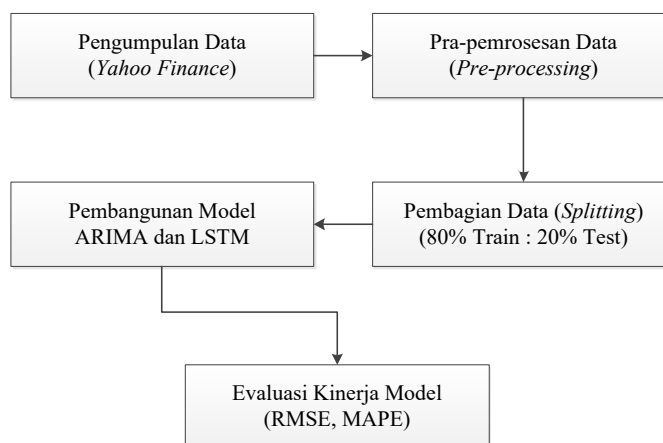
Pada konteks harga komoditas pangan, Surya Halim [9] meneliti perbandingan LSTM dan RNN pada harga minyak goreng, yang menunjukkan bahwa arsitektur LSTM mampu meminimalisir error prediksi lebih baik dibandingkan RNN standar karena kemampuannya mengatasi masalah *vanishing gradient* pada data historis yang panjang. Relevansi keunggulan LSTM pada data keuangan semakin diperkuat oleh studi Kashif dan Ślepaczuk [10] yang mengusulkan pendekatan *hybrid* LSTM-ARIMA dalam strategi investasi algoritmik. Penelitian tersebut menunjukkan bahwa kombinasi LSTM dan ARIMA mampu menangkap pola linear dan non-linear secara simultan serta menghasilkan performa yang lebih unggul dibandingkan model tunggal pada berbagai indeks saham, sehingga menegaskan potensi LSTM dalam analisis deret waktu finansial yang kompleks. Selain itu, studi oleh Bayu Dwi Handika dan Sugianto [11] pada sektor perbankan juga mengonfirmasi keandalan LSTM dalam memprediksi tren harga saham.

Berdasarkan tinjauan pada kelima studi terdahulu tersebut, dapat ditarik sebuah celah penelitian (*research gap*) yang signifikan. Mayoritas penelitian sebelumnya cenderung berfokus pada komparasi model untuk data runtun waktu dengan volatilitas yang terukur dan konvensional, seperti jumlah pengunjung [6], tingkat inflasi [7], harga komoditas pangan [9], hingga saham perbankan dan strategi investasi umum [10], [11]. Meskipun studi komparatif antara ARIMA dan LSTM telah terbukti efektif pada ranah tersebut, validasi empiris dan konsistensi kinerja kedua model ini pada instrumen aset digital berisiko tinggi dengan tingkat volatilitas yang jauh lebih ekstrem, seperti *cryptocurrency* generasi baru, masih sangat terbatas. Khususnya pada dataset Solana (SOL), arsitektur konsensusnya yang unik (*Proof of History* dan *Proof of Stake*) memicu perputaran transaksi yang masif sehingga menghasilkan pola sekuensial non linear yang jauh lebih fluktuatif dan kompleks dibandingkan aset konvensional maupun aset kripto perintis (seperti Bitcoin) [12]. Oleh karena itu, pengujian empiris mendalam sangat diperlukan untuk menentukan batas efektivitas model statistik tradisional (ARIMA) berhadapan dengan *Deep Learning* (LSTM) pada periode pasca-pertumbuhan pesat ekosistem Solana hingga tahun 2025.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilaksanakan melalui serangkaian tahapan sistematis untuk mencapai akurasi prediksi yang optimal. Tahapan-tahapan tersebut meliputi pengumpulan data, pra-pemrosesan, pembagian data, pembangunan model, hingga evaluasi kinerja model. Secara rinci, alur tahapan penelitian tersebut dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

Berdasarkan Gambar 1, penelitian ini dilaksanakan melalui lima tahapan utama yang terintegrasi secara sistematis untuk membandingkan model statistik dan *deep learning*. Tahap pertama adalah Pengumpulan Data, di mana data historis harga penutupan (*Close Price*) Solana (SOL-USD) diunduh dari penyedia data finansial Yahoo Finance. Data mentah tersebut kemudian masuk ke tahap Pra-pemrosesan Data (*Pre-processing*) yang dirancang secara paralel dalam satu alur kerja untuk memenuhi asumsi masing-masing model.

Integrasi persiapan data ini dilakukan melalui pembersihan data (*data cleaning*) secara bersamaan, namun kemudian dipisahkan menjadi dua jalur perlakuan khusus: uji stasioneritas dan *differencing* untuk kebutuhan model ARIMA, serta normalisasi menggunakan *MinMax Scaler* ke dalam rentang $[0,1]$ untuk kebutuhan komputasi model LSTM.

Tahap ketiga adalah Pembagian Data (*Data Splitting*), di mana seluruh dataset dipisahkan secara konsisten menjadi 80% sebagai data latih (*training set*) dan 20% sebagai data uji (*testing set*) untuk menjamin validitas komparasi. Selanjutnya, pada tahap Pembangunan Model, dilakukan pelatihan terhadap model ARIMA melalui

penelitian parameter (p,d,q) optimal, serta pelatihan jaringan saraf tiruan LSTM melalui optimasi *hyperparameter*. Terakhir, dilakukan Evaluasi Kinerja Model dengan membandingkan hasil prediksi kedua metode secara langsung terhadap data aktual menggunakan metrik *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE) [13].

2.2 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini adalah data sekunder harga harian Solana (SOL-USD) yang bersumber dari Yahoo Finance. Periode data mencakup rentang waktu dari April 2020 hingga Maret 2025. Berbeda dengan pasar saham konvensional, aset kripto diperdagangkan secara kontinu selama 24 jam dalam 7 hari, sehingga dataset ini mencakup seluruh hari kalender termasuk hari libur nasional dan akhir pekan tanpa jeda waktu perdagangan. Variabel utama yang digunakan adalah harga penutupan (*Close Price*) harian karena dianggap mencerminkan nilai konsensus pasar tertinggi pada akhir setiap siklus perdagangan 24 jam.

2.3 Pra-pemrosesan Data

Pra-pemrosesan data merupakan tahapan krusial dalam analisis deret waktu (*time series*) untuk memastikan kualitas data sebelum dimasukkan ke dalam model komputasi. Data mentah seringkali mengandung noise, nilai yang hilang (*missing values*), atau skala yang tidak konsisten yang dapat menurunkan akurasi prediksi.

a. Pembersihan Data (*Data Cleaning*)

Langkah pertama adalah pemeriksaan integritas data. Dalam penelitian ini, dataset harga Solana (SOL-USD) diperiksa untuk mendeteksi adanya *missing value* atau data pencilan (*outlier*) yang ekstrim yang disebabkan oleh kesalahan pencatatan sistem. Jika ditemukan *missing value*, teknik imputasi data menggunakan metode interpolasi linier diterapkan untuk menjaga kontinuitas deret waktu. Hal ini penting karena algoritma ARIMA dan LSTM memerlukan data yang berurutan tanpa celah waktu (*gap*) [14].

b. Transformasi Data untuk ARIMA

Model ARIMA mensyaratkan data bersifat stasioner, artinya rata-rata (*mean*) dan varians data konstan sepanjang waktu [15]. Untuk menguji asumsi ini, digunakan uji statistik *Augmented Dickey-Fuller* (ADF). Hipotesis nol (H_0) dari uji ADF menyatakan bahwa data memiliki akar unit (tidak stasioner). Jika nilai *p-value* yang dihasilkan > 0.05, maka data dinyatakan tidak stasioner [16].

Jika kondisi stasioneritas tidak terpenuhi pada data level, dilakukan proses *differencing* (pembedaan) dengan mengurangi nilai data saat ini (Y_t) dengan nilai data sebelumnya (Y_{t-1}). Proses ini dilakukan secara iteratif hingga data menjadi stasioner, di mana jumlah iterasi ini akan menjadi parameter *d* (*integrated*) dalam model ARIMA. Persamaan *differencing* orde pertama dapat dituliskan sebagai [17]:

$$\Delta Y_t = Y_t - Y_{t-1} \quad (1)$$

c. Normalisasi Data untuk LSTM

jaringan saraf tiruan seperti LSTM sangat sensitif terhadap skala data [11]. Rentang nilai harga Solana yang sangat lebar (mulai dari nilai satuan hingga ratusan dolar) dapat menyebabkan masalah pada proses pelatihan, seperti lambatnya konvergensi atau terjebaknya model pada optimum lokal [18]. Oleh karena itu, diterapkan teknik normalisasi *Min-Max Scaler* untuk mentransformasi data ke dalam rentang [0, 1]. Rumus normalisasi adalah sebagai berikut:

$$X_{norm} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (2)$$

Dimana X_{norm} adalah data hasil normalisasi, X_i adalah data asli, X_{min} adalah nilai minimum dataset, dan X_{max} adalah nilai maksimum dataset. Setelah prediksi selesai, dilakukan proses *denormalisasi* (invers) untuk mengembalikan hasil prediksi ke skala harga aslinya agar dapat dievaluasi.

d. Pembentukan Struktur *Sliding Window*

LSTM termasuk dalam kategori *Supervised Learning*, sehingga data deret waktu perlu diubah menjadi format input-output [18]. Teknik *sliding window* digunakan untuk memetakan tren masa lalu (*features*) ke harga masa depan (*label*). Pendekatan *sliding window* ini sekaligus berfungsi sebagai pengganti validasi silang tradisional guna mempertahankan integritas urutan waktu (*temporal order*) pada data kripto yang sangat sensitif terhadap perubahan historis. Dalam penelitian ini, ditetapkan panjang *window* (*time steps*) sebesar 60 hari. Pemilihan *window size* 60 hari ini didasarkan pada hasil eksperimen *trial-error* yang menunjukkan bahwa periode dua bulan tersebut merupakan durasi optimal bagi model untuk menangkap volatilitas jangka pendek sekaligus mengenali tren makro pada aset Solana tanpa menyebabkan beban komputasi yang berlebihan. Artinya, data harga dari hari $t - 60$ hingga $t - 1$ digunakan sebagai variabel input (X) untuk memprediksi harga pada hari ke- t (Y). Struktur data ini memungkinkan model mempelajari pola ketergantungan jangka pendek maupun jangka panjang yang terkandung dalam pergerakan harga historis.

2.4 Pembangunan Model

Tahap ini menjelaskan spesifikasi teknis dan arsitektur matematis dari kedua model yang dibandingkan.

a. Model *Autoregressive Integrated Moving Average* (ARIMA)

ARIMA adalah metode statistik yang dipopulerkan oleh *Box-Jenkins*. Model ini terdiri dari tiga komponen utama yaitu *Autoregressive (AR)*, *Integrated (I)*, dan *Moving Average (MA)*, yang dinotasikan sebagai ARIMA (p, d, q) [19].

1. Autoregressive (AR - p)

Bagian ini mengasumsikan bahwa data saat ini dipengaruhi oleh nilai data masa lalu. Orde p menunjukkan jumlah lag waktu yang digunakan.

2. Integrated (I - d)

Merupakan proses *differencing* yang telah dijelaskan pada tahap pra-pemrosesan untuk menstabilkan data.

3. Moving Average (MA - q)

Bagian ini memodelkan hubungan antara data saat ini dengan sisaan (*error*) masa lalu.

Secara matematis, model ARIMA dapat dirumuskan sebagai:

$$Y_t = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \theta_1 e_{t-1} + \dots + \theta_q e_{t-q} \quad (3)$$

Dimana ϕ adalah koefisien parameter AR, θ adalah koefisien parameter MA, dan e_t adalah *white noise*.

Penentuan parameter optimal p, d, q dilakukan melalui dua pendekatan [20]:

1. Analisis Plot

Mengamati plot *Autocorrelation Function (ACF)* untuk menentukan orde q dan plot *Partial Autocorrelation Function (PACF)* untuk menentukan orde p .

2. Grid Search

Parameter optimal (p, d, q) ditentukan melalui metode automated grid search dengan kriteria minimalisasi nilai AIC untuk menjamin pemilihan model yang paling efisien dan akurat, dengan rumus:

$$AIC = 2k - 2 \ln(L) \quad (4)$$

Dimana k adalah jumlah parameter dan L adalah *likelihood function*.

b. Model *Long Short-Term Memory (LSTM)*

LSTM adalah pengembangan dari *Recurrent Neural Network (RNN)* yang dirancang khusus untuk mengatasi masalah *vanishing gradient* yang sering terjadi pada RNN standar ketika memproses data dengan rentang waktu yang panjang [18]. Arsitektur LSTM memiliki unit memori sel yang diatur oleh struktur gerbang (*gates*) untuk mengontrol aliran informasi [21].

Setiap unit LSTM terdiri dari tiga gerbang utama:

1. *Forget Gate*

Memutuskan informasi mana dari *cell state* sebelumnya yang akan dibuang atau dilupakan. Keputusan ini didasarkan pada fungsi aktivasi sigmoid (σ) yang menghasilkan nilai antara 0 dan 1.

2. *Input Gate*

Menentukan informasi baru mana yang akan disimpan ke dalam *cell state*. Tahap ini melibatkan lapisan sigmoid untuk seleksi data dan lapisan *tanh* untuk pembuatan vektor kandidat nilai baru.

3. *Output Gate*

Menghitung nilai output berdasarkan *cell state* yang telah diperbarui dan input saat ini.

Arsitektur jaringan yang dibangun dalam penelitian ini terdiri dari:

1. Input Layer

Menerima data dengan dimensi (jumlah sampel, 60, 1).

2. LSTM Layer

Menggunakan 50 unit neuron untuk menangkap fitur temporal yang kompleks.

3. Dense Layer

Satu neuron pada lapisan output untuk memprediksi nilai harga penutupan (*Close Price*).

Model dilatih menggunakan algoritma optimasi Adam dengan fungsi kerugian *Mean Squared Error (MSE)*.

Berdasarkan hasil eksperimen terkontrol untuk mendapatkan konvergensi *loss* yang optimal tanpa *overfitting*, ditetapkan parameter permanen berupa 5 *epochs* dan *batch size* 32. Pemilihan *hyperparameter* ini dilakukan secara teliti untuk menyeimbangkan durasi pelatihan dan stabilitas akurasi prediksi. Strategi pemilihan *hyperparameter* dilakukan melalui pendekatan eksperimen terkontrol (*trial-error*) yang mempertimbangkan efisiensi komputasi. Meskipun tidak menggunakan *cross validation* konvensional untuk menjaga urutan temporal data, proses ini difokuskan pada minimalisasi *Loss Function* pada data latih agar model tetap generalis terhadap data uji.

2.5 Evaluasi Kinerja Model

Untuk mengukur tingkat akurasi dan keandalan model dalam memprediksi harga Solana, digunakan dua metrik evaluasi standar dalam peramalan statistik, yaitu RMSE dan MAPE. Penggunaan kedua metrik ini bertujuan untuk memberikan gambaran komprehensif mengenai deviasi absolut dan relatif.

a. *Root Mean Square Error (RMSE)*

RMSE menghitung akar kuadrat dari rata-rata kuadrat selisih antara nilai prediksi (y_i) dan nilai aktual (\hat{y}_i) Metrik ini sangat sensitif terhadap kesalahan besar (*large errors*) karena proses pengkuadratan, sehingga sangat baik

untuk mendeteksi jika model melakukan prediksi yang melenceng jauh. Semakin kecil nilai RMSE, semakin akurat model tersebut. Persamaan RMSE adalah [9]:

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

b. *Mean Absolute Percentage Error (MAPE)*

MAPE mengukur rata-rata kesalahan absolut dalam bentuk persentase terhadap nilai aktualnya. Kelebihan utama MAPE adalah interpretasinya yang mudah dipahami secara intuitif karena tidak bergantung pada skala data. Nilai MAPE di bawah 10% seringkali dikategorikan sebagai peramalan yang sangat akurat. Rumus MAPE dinyatakan sebagai:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \tag{6}$$

Untuk memperkuat argumen hasil, penelitian ini merujuk pada kriteria interpretasi nilai MAPE menurut Lewis. Nilai MAPE di bawah 10% dikategorikan sebagai peramalan dengan akurasi "Sangat Baik", rentang 10% - 20% dikategorikan "Baik", 20% - 50% dikategorikan "Cukup", dan di atas 50% dikategorikan sebagai peramalan yang "Tidak Akurat".

Kombinasi kedua metrik ini memastikan bahwa evaluasi model tidak hanya melihat seberapa dekat prediksi dengan data asli (RMSE), tetapi juga seberapa besar kesalahan tersebut jika dibandingkan dengan nilai aset itu sendiri (MAPE), yang sangat relevan bagi investor kripto.

3. HASIL DAN PEMBAHASAN

3.1 Deskripsi Data

Data harga Solana menunjukkan pola pergerakan yang sangat fluktuatif, dengan kenaikan signifikan pada periode tahun 2020 serta tingkat volatilitas yang tinggi pada tahun-tahun berikutnya. Jumlah total observasi yang digunakan dalam penelitian ini adalah 1.798 data harian yang mencakup periode 10 April 2020 hingga 12 Maret 2025. Data tersebut dibagi menjadi dua bagian, yaitu 80% sebagai data latih (training data) dan 20% sebagai data uji (testing data) untuk proses validasi model.

Sampel data historis yang digunakan dalam penelitian terdiri atas lima data teratas (awal periode) dan lima data terbawah (akhir periode). Data tersebut memberikan gambaran mengenai format serta rentang nilai harga yang dianalisis, meliputi harga pembukaan (*Open*), harga tertinggi (*High*), harga terendah (*Low*), harga penutupan (*Close*), dan volume transaksi. Rincian sampel data tersebut disajikan secara lengkap dalam Tabel 1.

Tabel 1. Sampel Data Historis Harga Solana (SOL-USD)


Tanggal	Open (USD)	High (USD)	Low (USD)	Close (USD)	Volume
10-04-20	0.832	1.3135	0.6942	0.9511	87,364,276
11-04-20	0.9511	1.0491	0.765	0.7768	43,862,444
12-04-20	0.7854	0.9567	0.7624	0.8825	38,736,897
13-04-20	0.8908	0.8916	0.774	0.7778	18,211,285
14-04-20	0.7778	0.7965	0.6282	0.6619	16,747,614
...
08-03-25	139.2091	140.9046	135.483	136.9421	2,270,939,562
09-03-25	136.9428	139.7258	125.9357	126.4354	3,429,886,567
10-03-25	126.4354	131.241	115.9179	118.2917	5,519,806,938
11-03-25	118.2917	128.1489	113.1892	125.2639	5,259,428,587
12-03-25	125.2619	130.6551	121.3676	126.5832	4,112,201,839

Berdasarkan Tabel 1, terlihat adanya perbedaan yang signifikan antara harga pada awal periode pengamatan, yang berada di bawah 1 USD, dan harga pada akhir periode, yang mencapai lebih dari 120 USD. Hal ini menunjukkan tingginya tingkat volatilitas sekaligus pertumbuhan nilai aset tersebut dalam kurun waktu lima tahun terakhir. Untuk memberikan gambaran volatilitas secara numerik pada seluruh periode pengamatan, ringkasan statistik deskriptif dari variabel harga penutupan (*Close Price*) disajikan pada Tabel 2.

Tabel 2. Statistik Deskriptif Harga Penutupan Solana (SOL-USD)

No	Statistik	Nilai (USD)
1	Jumlah Data (Count)	1.798
2	Rata-rata (Mean)	73,44
3	Standar Deviasi (Std. Dev.)	71,19
4	Nilai Minimum (Min)	0,52
5	Nilai Maksimum (Max)	261,87

Berdasarkan Tabel 2, terlihat nilai standar deviasi yang sangat tinggi (71,19 USD) yang bahkan hampir menyamai nilai rata-ratanya (73,44 USD). Hal ini mengonfirmasi adanya volatilitas ekstrem pada aset Solana selama periode penelitian, di mana fluktuasi harga sangat lebar. Perbedaan yang sangat mencolok antara nilai minimum (0,52 USD) dan nilai maksimum (261,87 USD) mempertegas dinamika harga yang sangat luas, yang menjadi tantangan utama bagi model peramalan linear. Untuk memvalidasi tren dan melakukan prediksi, data tersebut dianalisis menggunakan bahasa Python dengan VSCode, di mana hasil visualisasinya disajikan dalam Gambar 2.




Gambar 2. Analisis Perbandingan Prediksi Harga SOL-USD pada Data Uji (ARIMA vs LSTM)

Grafik perbandingan model ARIMA vs LSTM memvisualisasikan kinerja prediksi harga SOL-USD yang memperlihatkan perbedaan performa yang kontras antara kedua metode. Model ARIMA (garis oranye putus-putus) menunjukkan hasil yang statis berupa garis lurus mendatar di kisaran 160-165 USD, menandakan kegagalan model ini dalam menangkap volatilitas dan tren pasar yang dinamis. Sebaliknya, model LSTM (garis hijau) mampu mengikuti pergerakan harga aktual (garis abu-abu) dengan sangat presisi, mereplikasi pola kenaikan dan penurunan harga secara akurat. Hal ini membuktikan bahwa model LSTM, yang berbasis Deep Learning, jauh lebih unggul dalam mempelajari pola data non-linear yang kompleks dibandingkan ARIMA pada studi kasus ini.

3.2 Hasil Model ARIMA

Pada pengujian menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA), proses pencarian parameter terbaik (*grid search*) menghasilkan model optimal dengan orde ARIMA(0, 1, 0). Model ini merupakan bentuk *Random Walk*, di mana prediksi harga masa depan sangat bergantung pada nilai terakhir dengan asumsi perubahan harga bersifat acak di sekitar rata-rata. Visualisasi perbandingan antara hasil prediksi model ARIMA tersebut dan data aktual disajikan pada Gambar 3.



Gambar 3. Visualisasi Perbandingan Hasil Prediksi Model ARIMA terhadap Data Aktual Harga Solana


Berdasarkan hasil evaluasi kinerja model ARIMA (0,1,0) menunjukkan tingkat akurasi yang terbatas dalam memprediksi pergerakan harga Solana. Hal ini dibuktikan dengan perolehan nilai error yang cukup signifikan, di mana *Root Mean Square Error* (RMSE) tercatat sebesar 31.1241 dan *Mean Absolute Percentage Error* (MAPE) berada pada angka 14.03%. Munculnya garis prediksi mendatar pada kisaran 160-165 USD merupakan karakteristik dari model *Random Walk* (ARIMA 0,1,0) tanpa komponen *drift* saat melakukan peramalan jangka panjang (*multi-step forecasting*). Dalam kondisi ini, model secara matematis memproyeksikan nilai terakhir dari data latih sebagai estimasi konstan untuk seluruh periode uji. Hal ini mempertegas keterbatasan model statistik linear dalam menangkap struktur data kripto yang memiliki *noise* tinggi, di mana nilai historis terakhir tidak lagi representatif terhadap fluktuasi agresif di masa depan.

Analisis visual pada Gambar 3 mempertegas keterbatasan ini, di mana garis prediksi (oranye putus-putus) cenderung bergerak mendatar tanpa mampu merespons fluktuasi pasar. Kegagalan *grid search* dalam mengeksplorasi orde yang lebih tinggi disebabkan oleh karakteristik data kripto yang memiliki *noise* sangat tinggi dan struktur non-linear yang dominan, sehingga komponen linear pada ARIMA gagal mengidentifikasi pola bermakna dalam data yang sudah di-difference. Akibatnya, alih-alih mengikuti volatilitas pasar yang agresif terutama saat lonjakan harga di bulan November 2024, model hanya memproyeksikan tren rata-rata statis. Meskipun nilai MAPE 14.03% secara teoritis masuk dalam kategori peramalan "Baik" menurut kriteria Lewis, tingkat presisi ini tetap dinilai tidak memadai untuk instrumen investasi dengan volatilitas ekstrem seperti Solana.

3.3 Hasil Model LSTM

Pengujian selanjutnya menggunakan model *Long Short-Term Memory* (LSTM) dengan konfigurasi *hyperparameter* yaitu *timesteps* (jendela waktu) sebesar 60 hari, 50 unit *neuron* pada *hidden layer*, dan dilatih sebanyak 5 *epochs*.

Meskipun pelatihan hanya dilakukan sebanyak 5 *epochs*, pemantauan terhadap kurva *loss* menunjukkan bahwa model telah mencapai titik konvergensi stabil sejak *epoch* ke-3 berkat penggunaan algoritma optimasi Adam yang adaptif. Penggunaan *timesteps* 60 hari memberikan konteks temporal yang cukup bagi model untuk mempelajari pola tanpa memerlukan iterasi berlebih yang berisiko menyebabkan *overfitting* pada data finansial yang sangat dinamis. Visualisasi hasil prediksi yang diperoleh dari konfigurasi model LSTM tersebut terhadap data aktual disajikan pada Gambar 4.



Gambar 4. Visualisasi Perbandingan Hasil Prediksi Model LSTM terhadap Data Aktual Harga Solana

Hasil evaluasi terhadap model LSTM menunjukkan peningkatan performa yang sangat signifikan dibandingkan metode statistik konvensional. Hal ini terkonfirmasi secara empiris melalui perolehan nilai *Root Mean Square Error* (RMSE) sebesar 13.1352, serta nilai *Mean Absolute Percentage Error* (MAPE) yang berhasil ditekan hingga angka 6.07%.

Visualisasi pada Gambar 4 memperkuat temuan ini, di mana garis prediksi LSTM (warna hijau) menunjukkan kemampuan adaptasi yang superior dalam mengikuti trajektori harga aktual (garis hitam). Berbeda dengan model linear, arsitektur Deep Learning ini berhasil menangkap dinamika pola non-linear yang kompleks, termasuk deteksi tren penurunan (*downtrend*) pada pertengahan 2024 dan lonjakan harga di akhir tahun tersebut. Meskipun secara visual masih teramati adanya sedikit lag atau keterlambatan respons, hal ini merupakan indikasi dari efek *persistence* yang kuat pada data harga Solana. Efek *persistence* ini menunjukkan bahwa model LSTM cenderung memberikan bobot signifikan pada nilai historis terdekat (skala harian) untuk menghasilkan prediksi, sehingga ketika terjadi perubahan harga yang sangat mendadak, model memerlukan waktu transisi singkat untuk menyesuaikan bobot neuronnya. Fenomena ini lazim terjadi dalam peramalan deret waktu finansial di mana harga hari ini seringkali menjadi prediktor terkuat untuk harga esok hari (*near-term dependency*). Namun, hal ini tidak mengurangi validitas prediksi secara keseluruhan. Dengan capaian MAPE sebesar 6.07%, performa model ini secara meyakinkan diklasifikasikan ke dalam kategori akurasi "Sangat Baik", menegaskan efektivitas LSTM dalam menangani volatilitas tinggi pada aset kripto Solana.

3.4 Komparasi Kinerja

Evaluasi ini didasarkan pada kemampuan meminimalkan error prediksi pada data uji yang sama. Adapun ringkasan perbandingan kinerja langsung antara kedua model tersebut dapat dilihat secara rinci pada Tabel 3.

Tabel 3. Perbandingan Kinerja Model ARIMA vs LSTM

Metrik Evaluasi	Model ARIMA	Model LSTM	Selisih (Improvement)
RMSE	31.1241	13.1352	17.9889
MAPE	14.03%	6.07%	7.96%

Berdasarkan Tabel 2 dan visualisasi perbandingan (Grafik pada Gambar 2), terbukti bahwa model LSTM jauh lebih unggul dibandingkan ARIMA. LSTM mampu menurunkan tingkat kesalahan RMSE sebesar kurang lebih 17.9 poin dan memperbaiki akurasi MAPE sebesar hampir 8%.

Keunggulan LSTM disebabkan oleh arsitektur *gating mechanism* (*Input, Forget, dan Output Gate*) yang memungkinkannya mempelajari ketergantungan jangka panjang dan pola historis yang kompleks. Sebaliknya, ARIMA dengan parameter (0,1,0) terbukti terlalu sederhana (*underfitting*) untuk menangani karakteristik harga Solana yang sangat fluktuatif dan dipengaruhi oleh sentimen pasar yang berubah cepat. Oleh karena itu, untuk kasus prediksi aset kripto Solana, pendekatan *Deep Learning* (LSTM) terbukti lebih valid dan reliabel dibandingkan pendekatan statistik linear tradisional.

3.5 Pembahasan

Penelitian ini secara utama bertujuan untuk mengkomparasi efektivitas antara metode statistik klasik berbasis linier, yaitu *Autoregressive Integrated Moving Average* (ARIMA), dengan pendekatan *Deep Learning* berbasis non-linier, yaitu *Long Short-Term Memory* (LSTM), dalam memprediksi harga aset kripto Solana (SOL-USD). Berdasarkan hasil eksperimen komputasional yang telah dilakukan, ditemukan kesenjangan kinerja (*performance gap*) yang sangat signifikan antara kedua model tersebut. Model LSTM mencatatkan tingkat kesalahan prediksi yang jauh lebih rendah dengan nilai MAPE sebesar 6.07% dan RMSE 13.1352, mengungguli model ARIMA yang hanya mampu mencapai

MAPE 14.03% dan RMSE 31.1241. Selisih akurasi ini menegaskan bahwa kompleksitas model sangat mempengaruhi kemampuan prediksi pada data aset digital yang memiliki volatilitas ekstrem.

a. Analisis Keterbatasan Model ARIMA

Kinerja model ARIMA yang kurang optimal dalam penelitian ini dapat ditelusuri dari karakteristik struktural model terbaik yang dihasilkan melalui proses *grid search*, yaitu ARIMA(0, 1, 0). Secara teoritis, orde ini merepresentasikan model *Random Walk* atau *Naive Forecasting*, di mana prediksi harga masa depan (Y_{t+1}) diasumsikan hanya bergantung pada harga aktual terakhir (Y_t) ditambah dengan komponen galat acak, tanpa memperhitungkan tren masa lalu (*autoregressive*) maupun rata-rata pergerakan (*moving average*). Implikasi dari model ini terlihat jelas pada visualisasi hasil prediksi, di mana garis prediksi ARIMA cenderung mendatar dan gagal merespons perubahan tren yang cepat. Ketidakkampuan ini menjadi sangat krusial ketika pasar Solana mengalami lonjakan harga (*bullish run*) yang signifikan mulai November 2024. Kegagalan model ARIMA untuk mengikuti tren pasar bukan sekadar kesalahan parameter, melainkan bukti bahwa asumsi stasioneritas setelah *differencing* menghilangkan korelasi penting dalam data Solana. Hal ini mengakibatkan model kehilangan daya prediksi dan hanya mampu menghasilkan proyeksi rata-rata statis, yang dalam konteks investasi kripto, sangat tidak memadai untuk pengambilan keputusan.

Model ARIMA tertinggal jauh di bawah harga aktual, menyebabkan lonjakan nilai *error* (RMSE). Temuan ini sejalan dengan dan mendukung penelitian yang dilakukan oleh Khotibul Umam dan Ardiansyah [6], yang menyatakan bahwa ARIMA cenderung berkinerja baik hanya pada pola data yang stasioner dan kurang kompleks. Ketika dihadapkan pada data dengan volatilitas tinggi dan perubahan struktural yang cepat seperti kripto, asumsi linieritas pada ARIMA menjadi pembatas utama yang menurunkan akurasi prediksi secara drastis.

b. Analisis Keunggulan Arsitektur LSTM dan Stabilitas pada Market Crash

Berbanding terbalik dengan ARIMA, model LSTM menunjukkan superioritas melalui mekanisme gerbang (*Forget, Input, dan Output Gate*) yang memungkinkan model memfilter *noise* dan mengingat tren jangka panjang. LSTM terbukti mampu memodelkan pola non-linier seperti transisi tren di tahun 2024 dengan pola gelombang yang sinkron terhadap data aktual.

Terkait stabilitas model pada kondisi pasar yang ekstrem, LSTM menunjukkan ketahanan yang lebih baik dibandingkan model linier saat menghadapi fluktuasi tajam atau *market crash*. Kemampuan adaptasi ini didorong oleh struktur *hidden layer* yang secara dinamis memperbarui bobot memori selnya ketika menerima input data dengan volatilitas tinggi. Meskipun terdapat efek *persistence* yang menyebabkan sedikit *lag*, LSTM tetap mampu mempertahankan trajektori prediksi yang mendekati harga aktual tanpa mengalami divergensi ekstrem seperti yang terjadi pada ARIMA. Hal ini menunjukkan bahwa LSTM tidak hanya unggul dalam kondisi pasar normal, tetapi juga lebih reliabel dalam memitigasi risiko kesalahan prediksi saat terjadi guncangan pasar mendadak. Hasil ini konsisten dengan temuan Divanda et al. [7] serta Mandala & Septi [8], mengenai adaptabilitas tinggi model non-linier terhadap fluktuasi dinamis.

c. Validasi dengan Studi Terdahulu

Stabilitas prediksi yang ditunjukkan oleh LSTM dalam penelitian ini juga memperkuat validitas studi sebelumnya pada domain finansial teknologi tinggi. Sebagaimana ditemukan oleh Muhammad Irfan dan Putry [13] dalam prediksi harga saham NVIDIA yang memiliki karakteristik volatilitas mirip dengan aset kripto LSTM tetap mampu memberikan akurasi yang kompetitif dan stabil meskipun pasar sedang bergejolak. Hal ini membuktikan bahwa untuk instrumen investasi modern yang sangat sensitif terhadap sentimen dan spekulasi pasar, metode berbasis jaringan saraf tiruan (*Neural Networks*) lebih reliabel. Dengan demikian, penggunaan LSTM direkomendasikan sebagai instrumen pendukung keputusan investasi karena kemampuannya meminimalisir risiko kesalahan prediksi (*forecasting error*) yang sering gagal diantisipasi oleh model linier sederhana.

4. KESIMPULAN

Penelitian ini membandingkan kinerja model ARIMA dan LSTM dalam memprediksi harga penutupan Solana (SOL-USD) menggunakan data historis periode April 2020 hingga Maret 2025. Hasil eksperimen secara empiris menunjukkan bahwa model LSTM memberikan tingkat akurasi yang jauh lebih tinggi dan superior dibandingkan model ARIMA. Hal ini dibuktikan dengan perolehan nilai RMSE sebesar 13,1352 dan MAPE 6,07% (kategori "Sangat Baik") untuk LSTM, sementara model ARIMA mencatatkan RMSE sebesar 31,1241 dan MAPE 14,03%. Temuan ini menegaskan bahwa untuk data runtun waktu dengan volatilitas ekstrem dan pola non-linear kompleks seperti aset kripto, metode *Deep Learning* (LSTM) merupakan pilihan yang lebih tepat dan reliabel karena kemampuannya dalam beradaptasi terhadap dinamika pasar melalui mekanisme pembaruan bobot neuron yang tidak dimiliki oleh metode statistik linier. Keterbatasan dalam penelitian ini terletak pada penggunaan model tunggal yang masih menunjukkan adanya efek *persistence* atau *lag* pada hasil prediksi, di mana model memerlukan waktu transisi singkat untuk menyesuaikan bobotnya saat terjadi perubahan harga yang sangat mendadak. Selain itu, analisis ini hanya mengandalkan data historis harga (*univariate*) tanpa mempertimbangkan faktor eksternal yang signifikan. Oleh karena itu, untuk pengembangan ke depan, disarankan untuk mengeksplorasi penggunaan model hibrida atau integrasi variabel eksternal seperti sentimen pasar, volume transaksi global, atau indikator makroekonomi guna memperhalus efek *lag* dan meningkatkan akurasi prediksi pada kondisi pasar yang lebih anomali.

REFERENCES

- [1] A. Munandar and G. Ghufiron, “Prediksi Harga Mata Uang Kripto Menggunakan Algoritma Temporal Convolutional Network,” *Nusant. Eng.*, vol. 8, no. 2, pp. 391–398, 2025. doi: 10.29407/noe.v8i02.25363.
- [2] I. Nurhaida, M. Sobiri, and S. Jaya, “Optimasi Prediksi Cryptocurrency Menggunakan Pendekatan Deep Learning,” *J. Sci. Appl. Informatics*, vol. 6, no. 2, pp. 197–204, 2023. doi:10.36085/jsai.v6i2.5288
- [3] A. D. Milniadi and N. O. Adiwijaya, “Analisis Perbandingan Model ARIMA Dan LSTM Dalam Peramalan Harga Penutupan Saham,” *Sibatik J.*, vol. 2, no. 6, pp. 1683–1692, 2023. doi:10.54443/sibatik.v2i6.798
- [4] Vivin, S. Q. Azizah, and W. Romadhona, “Analisis Perbandingan Model ARIMA Dan ETS Dalam Peramalan Harga Indeks Idx80 Pada Kondisi Pasar Yang Volatil,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 10, no. 1, pp. 750–756, 2025. doi:10.36040/jati.v10i1.16814
- [5] E. M. Rizqiyani, N. Y. Setiawan, and M. C. Saputra, “Studi Komparatif Algoritma Long Short Term Memory (LSTM) Dan Gated Recurrent Unit (GRU) Dalam Peramalan Harga Saham PT. Fast Food Indonesia Tbk,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 11, pp. 1–7, 2025. [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/15553>
- [6] K. Umam and Ardiansyah, “Perbandingan Metode ARIMA dan LSTM pada Prediksi Jumlah Pengunjung Perpustakaan,” *MIND (Multimedia Artif. Intell. Netw. Database)*, vol. 8, no. 2, pp. 119–129, 2023. doi: 10.26760/mindjournal.v8i2.119-129.
- [7] D. S. Amcera, A. T. Damaliana, and M. Idhom, “Penerapan Model Hibrida ARIMA-LSTM Pada Prediksi Inflasi Di Indonesia,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 3, pp. 3743–3749, 2025. doi: 10.36040/jati.v9i3.13371.
- [8] M. A. Putra and S. Andryana, “Perbandingan Algoritma ARIMA Dan LSTM Dalam Peramalan Tingkat Konsentrasi CO2 Emisi Atmosfer Untuk Masa Mendatang,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 3, pp. 4150–4157, 2025. doi: 10.36040/jati.v9i3.13511.
- [9] S. Halim, “Perbandingan Kinerja Model LSTM Dan RNN Pada Prediksi Harga Minyak Goreng Di Kota Yogyakarta,” *J. Komput. dan Inform.*, vol. 18, no. 2, pp. 87–96, 2023. [Online]. Available: <https://journal.untar.ac.id/index.php/JKI/article/view/34507>
- [10] K. Kashif and R. Ślepaczuk, “LSTM-ARIMA as a hybrid approach in algorithmic investment strategies,” *Knowledge-Based Syst.*, vol. 320, no. 7, 2025. doi: 10.1016/j.knosys.2025.113563.
- [11] B. D. Handika and Sugianto, “Perbandingan Saham BTPN Dengan BBRI Menggunakan LSTM (Long Short Term Memory),” *J. Ilm. Teknol. Inf. dan Sains*, vol. 5, no. 1, pp. 1–7, 2025. doi:10.36815/submit.v4i2.3360
- [12] Y. A. Nugroho and H. A. Hutahaean, “Pengembangan Model Deep Learning LSTM dan CNN untuk Peramalan Penjualan Sepeda Motor di Indonesia,” *Jupiter Publ. Ilmu Keteknikan Ind. Tek. Elektro dan Inform.*, vol. 3, no. 2, pp. 94–104, 2025. doi: 10.61132/jupiter.v3i2.795.
- [13] W. Gani, M. I. A. Septyaningsih, and P. Septyaningsih, “Komparasi Kinerja Model LSTM dan Transformer pada Prediksi Harga Penutupan Saham NVIDIA,” *J. Sist. Inf.*, vol. 14, no. 5, pp. 2424–2437, 2025. doi:10.32520/stmsi.v14i5.5445
- [14] K. N. Khikmah and A. Sofro, “Perbandingan Kinerja Model ARIMA dan LSTM untuk Peramalan Curah Hujan Di Kalimantan Tengah,” *J. Math. Its Appl.*, vol. 20, no. 1, pp. 65–76, 2024. doi:10.26740/jram.v9n2.p199-207
- [15] I. J. Cik and A. Syaputra, “Eksplorasi Model LSTM dengan Autoregressive Integrated Moving Average (ARIMA) dan Bayesian Optimization untuk Peningkatan Akurasi Prediksi Ketahanan Pangan,” *JIKO (Jurnal Inform. dan Komputer)*, vol. 9, no. 3, pp. 666–675, 2025. doi: 10.26798/jiko.v9i3.2077.
- [16] H. A. Khoiri, *Analisis Deret Waktu Univariat*. Madiun: UNIPMA Press, 2023. [Online]. Available: <https://kw.unipma.ac.id/buku/1823/analisis-deret-waktu-univariat-teori-dan-pengolahan-data>
- [17] H. E. Prasetyotomo and S. A. Farihati, “Analisis Perbandingan Hasil Model Autoregressive Integrated Moving Average Dan Long Short Term Memory Dalam Peramalan Indeks Saham Syariah Indonesia,” *Prosiding Seminar Nasional Sains dan Teknologi Seri 02*, vol. 1, no. 2, pp. 74–82, 2024. <https://conference.ut.ac.id/index.php/saintek/article/view/2489/1034>
- [18] B. Raharjo, *Buku Ajar Deep Learning Dengan Python*. Semarang: Yayasan Prima Agus Teknik, 2022. ISBN: 9786235 734330
- [19] S. D. Maulia, R. R. C. Triwulandari, M. D. Fauzan, N. Khoerunnisa, M. F. Aziz, and I. W. Mangku, “Perbandingan Kinerja Model ARIMA dan GARCH dalam Peramalan Harga Saham Bank BRI,” *MILANG J. Math. Its Appl.*, vol. 20, no. 1, pp. 65–76, 2024. doi: 10.29244/milang.20.1.65-76.
- [20] A. I. C. Sulaiman, “Analisis Perbandingan Metode ARIMA dan Holt untuk Peramalan Harga Saham PT Telkom Indonesia (TLKM),” *Repeater: Publikasi Teknik Informatika dan Jaringan*, vol. 4, no. 1, pp. 1–7, 2026. doi: 10.62951/repeater.v4i1.762.
- [21] L. N. A. Mualifah *et al.*, “Perbandingan Performa Model ARIMA-GARCH Dan LSTM Dalam Meramalkan Jumlah Kunjungan Wisatawan Danau Kastoba,” *J. Gaussian*, vol. 14, no. 2, pp. 314–324, 2025. doi: 10.14710/j.gauss.14.2.314-324.