

Perbandingan Performa Model Prediksi Volatilitas BTC/IDR Menggunakan LSTM dan ARIMA

Fahren Affandi, Imam Akbar, Sella Juniastia Marsya Saputri*, Zwesty Quatra, Allsela Meiriza, Ken Ditha Tania, Ahmad Rifai

Sistem Informasi, Fakultas Ilmu Komputer, Universitas Sriwijaya, Indonesia

Email: ¹09031282328057@student.unsri.ac.id, ²09031282328104@student.unsri.ac.id,

^{3,*}09031282328074@student.unsri.ac.id, ⁴09031182328015@student.unsri.ac.id, ⁵allsela@unsri.ac.id,

⁶kenya.tania@gmail.com, ⁷ahmadrifai@ilkom.unsri.ac.id

Email Penulis Korespondensi: 09031282328074@student.unsri.ac.id*

Submitted: 22/04/2026; Accepted: 26/05/2026; Published: 30/06/2026

Abstrak—Karakteristik fluktuatif pasar aset kripto yang ekstrem menuntut ketersediaan model peramalan yang andal sebagai penunjang strategi manajemen risiko investasi. Penelitian ini bertujuan untuk membandingkan pendekatan Long Short-Term Memory (LSTM) sebagai model deep learning sekuensial dan Autoregressive Integrated Moving Average (ARIMA) sebagai model statistik deret waktu dalam memprediksi log-volatilitas Bitcoin pada pasangan BTC/IDR periode 2018–2025. Dataset historis harian BTC/IDR diperoleh dari platform Binance dengan periode observasi Januari 2018 hingga Desember 2025, kemudian diproses melalui perhitungan log-return, estimasi realized volatility berbasis jendela 7 hari, transformasi logaritmik, serta normalisasi data. Evaluasi model menggunakan metode walk-forward validation dengan metrik Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan koefisien determinasi (R^2). Hasil penelitian menunjukkan bahwa model LSTM memperoleh MAE sebesar 0,5126, RMSE sebesar 1,0408, dan R^2 sebesar 0,6803, sedangkan model ARIMA menghasilkan MAE sebesar 0,5430, RMSE sebesar 1,0217, dan R^2 sebesar 0,7052 pada konfigurasi terbaiknya. Meskipun LSTM memiliki MAE yang lebih rendah, model ARIMA menunjukkan performa yang lebih unggul berdasarkan nilai RMSE yang lebih kecil dan R^2 yang lebih tinggi, sehingga lebih efektif dalam menjelaskan variasi data serta menangkap fluktuasi ekstrem pada volatilitas Bitcoin. Secara keseluruhan, hasil penelitian menunjukkan bahwa model ARIMA lebih representatif dalam memodelkan dinamika log-volatilitas Bitcoin dibandingkan model LSTM. Temuan ini menegaskan bahwa pemilihan model prediksi volatilitas perlu mempertimbangkan karakteristik data yang dinamis dan fluktuatif. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan model prediksi volatilitas yang adaptif, khususnya pada pasar cryptocurrency di Indonesia.

Kata Kunci: ARIMA; BTC/IDR; LSTM; Volatilitas; Time Series

Abstract—The highly volatile nature of *cryptocurrency* markets requires reliable *forecasting* models to support investment risk management strategies. This study aims to compare the *Long Short-Term Memory* (LSTM) approach as a sequential *deep learning* model and the *Autoregressive Integrated Moving Average* (ARIMA) as a statistical *time series* model in predicting Bitcoin *log-volatility* for the BTC/IDR pair during the 2018–2025 period. Historical daily BTC/IDR data were obtained from the Binance platform covering the observation period from January 2018 to December 2025, then processed through log-return calculation, 7-day window based realized volatility estimation, logarithmic transformation, and data normalization. Model evaluation was conducted using *walk-forward validation* with *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), and the coefficient of determination (R^2) as performance metrics. The results show that the LSTM model achieved an MAE of 0.5126, RMSE of 1.0408, and R^2 of 0.6803, while the ARIMA model obtained an MAE of 0.5430, RMSE of 1.0217, and R^2 of 0.7052 under its best configuration. Although LSTM produced a lower MAE, ARIMA demonstrated superior performance based on its lower RMSE and higher R^2 values, indicating a better capability in explaining data variability and capturing extreme fluctuations in Bitcoin volatility. Overall, the findings indicate that ARIMA is more representative in modeling Bitcoin *log-volatility* dynamics compared to LSTM. These results highlight that selecting an appropriate volatility *forecasting* model should consider the dynamic and highly fluctuating nature of the data. This study is expected to contribute to the development of adaptive volatility prediction models, particularly in the Indonesian *cryptocurrency* market.

Keywords: ARIMA; BTC/IDR; LSTM; Volatility; Time Series

1. PENDAHULUAN

Perkembangan teknologi *blockchain* telah mendorong transformasi signifikan dalam sistem keuangan global melalui kemunculan *cryptocurrency* sebagai instrumen aset digital yang terdesentralisasi. Sebagai aset kripto dengan kapitalisasi pasar terbesar, Bitcoin menunjukkan karakteristik risiko dan imbal hasil yang berbeda dibandingkan aset keuangan tradisional, dengan volatilitas yang relatif tinggi dan dinamika *return* yang unik [1]. Tingginya volatilitas tersebut menjadikan Bitcoin sebagai instrumen investasi dengan potensi imbal hasil signifikan namun disertai tingkat ketidakpastian yang besar. Di Indonesia, peningkatan minat terhadap *cryptocurrency* sebagai alternatif investasi telah dikaji dalam beberapa penelitian domestik, yang menunjukkan relevansi dan urgensi kajian risiko serta dinamika harga Bitcoin dalam konteks pasar nasional [2].

Volatilitas merupakan indikator utama dalam mengukur tingkat risiko suatu aset keuangan. Pada pasar *cryptocurrency*, volatilitas Bitcoin dikenal memiliki pola yang kompleks, termasuk *volatility clustering* serta dinamika non-linear yang sulit dimodelkan dengan pendekatan sederhana [3]. Penelitian empiris juga

menunjukkan bahwa pergerakan harga Bitcoin memiliki implikasi terhadap volatilitas pasar keuangan lainnya, yang menegaskan pentingnya pemodelan volatilitas secara akurat [4]. Secara konvensional, pendekatan *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) telah banyak diterapkan dalam studi volatilitas Bitcoin dan terbukti mampu menangkap fenomena *volatility clustering* [3], namun studi komparatif menunjukkan bahwa model statistik tradisional belum optimal dalam menghadapi pola non-linear dan kompleksitas dinamika pasar *cryptocurrency*, sehingga pendekatan berbasis *machine learning* mulai banyak digunakan sebagai alternatif yang lebih fleksibel [5].

Perkembangan *machine learning* dan *deep learning* memberikan peluang baru dalam *forecasting* volatilitas aset digital. Berbagai penelitian menunjukkan bahwa metode *machine learning* mampu meningkatkan performa prediksi volatilitas dibandingkan pendekatan statistik klasik dalam konteks *cryptocurrency* [5], [6], [7]. Pendekatan komparatif antara model statistik dan *deep learning* banyak digunakan dalam peramalan deret waktu, seperti perbandingan SARIMA, ARIMA, dan LSTM, yang menunjukkan bahwa model *deep learning* lebih efektif dalam menangkap pola kompleks pada data temporal [8], [9]. Model *Long Short-Term Memory* (LSTM), sebagai bagian dari *Recurrent Neural Network* (RNN), dirancang untuk menangkap dependensi jangka panjang pada data runtun waktu dan telah digunakan dalam peramalan harga maupun volatilitas Bitcoin [10], [11]. Studi komparatif juga menunjukkan bahwa pendekatan *deep learning* sering kali memberikan hasil yang kompetitif dalam memodelkan dinamika pasar kripto yang fluktuatif [10].


Di sisi lain, model berbasis *time series* statistik seperti *Autoregressive Integrated Moving Average* (ARIMA) masih banyak digunakan dalam pemodelan volatilitas Bitcoin karena kemampuannya dalam menangkap struktur linear dan dependensi temporal pada data deret waktu. ARIMA efektif dalam merepresentasikan pola autokorelasi serta dinamika jangka pendek yang sering muncul pada data volatilitas. Selain itu, model ini memiliki keunggulan dari sisi interpretabilitas karena parameter yang dihasilkan dapat dianalisis secara statistik. Temuan ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa model ARIMA tetap relevan dalam memodelkan dinamika Bitcoin, khususnya untuk prediksi jangka pendek dan pola deret waktu yang relatif stabil [12]. Karakteristik ini menjadikannya relevan untuk diterapkan pada data tabular seperti *return*, volume perdagangan, dan *lag volatility*.

Berdasarkan tinjauan literatur, terdapat beberapa kesenjangan yang perlu diperhatikan. Meskipun sejumlah penelitian telah membandingkan model *deep learning* dan statistik untuk *forecasting* volatilitas *cryptocurrency* [5], [11], kajian serupa yang secara spesifik menggunakan pasangan BTC/IDR dengan periode observasi panjang belum banyak dilakukan, padahal dinamika pasar domestik dapat dipengaruhi oleh faktor likuiditas dan karakteristik investor lokal yang berbeda. Selain itu, sebagian besar studi yang ada lebih menekankan perbandingan akurasi prediksi antar model tanpa menganalisis perbedaan karakteristik masing-masing model dalam merespons pola volatilitas, baik yang bersifat linear maupun non-linear [7].

Penelitian ini membandingkan LSTM dan ARIMA dalam memprediksi volatilitas Bitcoin pada pasangan BTC/IDR menggunakan metrik MAE, RMSE dan R², disertai analisis karakteristik masing-masing model dalam merespons fluktuasi volatilitas. Secara ilmiah, penelitian ini berkontribusi dalam memperluas kajian perbandingan *deep learning* dan model *time series* statistik untuk *forecasting* volatilitas *cryptocurrency* di pasar negara berkembang. Secara implementatif, hasil penelitian ini diharapkan mendukung pengembangan model prediksi risiko yang lebih adaptif terhadap dinamika pasar kripto Indonesia.

2. METODOLOGI PENELITIAN

Penelitian ini membandingkan kinerja model *Long Short-Term Memory* (LSTM) dan model ARIMA dalam memprediksi volatilitas Bitcoin terhadap Rupiah menggunakan data harian BTC/IDR dari Binance periode 2018–2025. Data harga dan volume diproses melalui penghitungan *log-return*, estimasi volatilitas terealisasi tujuh harian yang dianalisis, transformasi logaritmik, serta normalisasi Min-Max. Panjang jendela geser optimal ditentukan melalui eksperimen variasi 5 hingga 30 periode berdasarkan galat validasi terendah, kemudian data dibagi secara kronologis menjadi 80% latih dan 20% uji. Model LSTM menggunakan arsitektur dua lapis dengan regularisasi *dropout* dan *early stopping*. Sementara itu, model ARIMA digunakan untuk memodelkan dinamika volatilitas berdasarkan struktur linear dan dependensi temporal dalam deret waktu, dengan pengujian beberapa orde autoregressive (p) pada rentang 5 hingga 30 untuk menentukan konfigurasi terbaik. Evaluasi dilakukan secara *walk-forward* menggunakan metrik MAE, RMSE, dan R², serta seluruh implementasi dilakukan menggunakan bahasa Python.



Gambar 1. Alur Penelitian

2.1 Dataset History Bitcoin

Studi ini memanfaatkan data historis BTC/IDR dari platform Binance, yang dipilih berdasarkan perannya sebagai titik sentral transmisi volatilitas Bitcoin dan kontribusinya yang dominan dalam proses *price discovery* di tingkat global [13]. *Dataset* mencakup periode Januari 2018 hingga Desember 2025 dengan frekuensi harian, suatu rentang waktu yang cukup panjang untuk mengamati dinamika volatilitas Bitcoin yang bersifat tidak konstan serta menunjukkan karakteristik berbeda pada fase ekspansi, kontraksi, maupun transisi pasar [14]. Seluruh data historis yang digunakan diperoleh setelah periode observasi berakhir pada akhir tahun 2025 sehingga seluruh observasi bersifat lengkap (fully observed dataset) dan tidak mengandung data prediksi maupun observasi parsial. Pemilihan rentang waktu tersebut juga bertujuan untuk memastikan model dievaluasi pada berbagai kondisi pasar cryptocurrency, termasuk fase bullish, bearish, serta periode konsolidasi pasar yang merepresentasikan dinamika volatilitas Bitcoin secara lebih komprehensif. Variabel yang digunakan meliputi harga pembukaan, harga tertinggi, harga terendah, harga penutupan, dan volume transaksi. Kombinasi kelima variabel tersebut telah terbukti secara empiris mampu meningkatkan performa model dalam menangkap kompleksitas pasar kripto pada kerangka deret waktu *multivariat* [15], sehingga selaras dengan praktik yang umum diadopsi dalam literatur prediksi volatilitas aset digital. Seluruh data disimpan dalam format CSV dan diproses menggunakan bahasa pemrograman Python dengan dukungan pustaka Pandas dan NumPy.

Tabel 1. Dataset Bitcoin

Date	Open	High	Low	Close	Volume
2018-01-01	1371565	1381855	127500	133800	8609915844
2018-01-02	1338216	1547349	1289002	1467511	20078092111
2018-01-03	146900	1530756	141500	1491951	15905667639
2018-01-04	1491951	152800	1391804	1505954	21329649574
2018-01-05	1505956	1717624	146000	1696039	23251491125
2025-12-27	8736956	8741426	8725305	8734324	24529502
2025-12-28	878770	8796137	8770597	8780551	2990195
2025-12-29	8795271	8844419	8781317	8801412	74045293
2025-12-30	8723713	873594	8710509	8727323	31802196
2025-12-31	884855	8866111	8817215	8863712	42199548

2.2 Data Pre-Processing

Pra-pemrosesan data bertujuan memastikan kelayakan data deret waktu melalui pemeriksaan konsistensi dan penghapusan observasi tidak lengkap akibat *lagging* serta statistik bergerak. *Log-return* harian dihitung menggunakan transformasi logaritmik atas rasio harga penutupan berturut-turut. Secara matematis, *log-return* didefinisikan sebagai berikut:

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

Log-return pada Persamaan (1) dipilih karena aditif dan lebih stabil secara statistik dibandingkan *return* sederhana, sekaligus menjadi dasar penghitungan *realized volatility* [16]. Volatilitas terealisasi dihitung menggunakan standar deviasi bergerak tujuh hari dan dianualisasi dengan $\sqrt{365}$ sesuai karakteristik pasar kripto yang beroperasi tanpa henti. Secara matematis, volatilitas terealisasi dirumuskan sebagai:

$$r_t = \ln\left(\frac{1467511}{1338000}\right) = 0.0925$$

Hasil perhitungan menunjukkan nilai *log-return* sebesar 0,0925 yang mengindikasikan adanya kenaikan logaritmik harga Bitcoin pada periode pengamatan.

$$RV_{7,t} = \sqrt{365} \times \sqrt{\frac{1}{7} \sum_{i=0}^6 (r_{t-i} - \bar{r})^2} \tag{2}$$

Pendekatan pada Persamaan (2) konsisten dengan kerangka pengukuran volatilitas berbasis *realized measures* dalam penelitian keuangan kuantitatif [16]. Selanjutnya, nilai volatilitas ditransformasikan ke dalam bentuk logaritmik untuk mengurangi *skewness* distribusi dan meningkatkan stabilitas numerik dalam proses pelatihan model. Transformasi tersebut dinyatakan sebagai:

$$\text{LogVol}_t = \ln(RV_{7,t} + \epsilon) \quad (3)$$

Sebagai ilustrasi transformasi logaritmik pada persamaan (3), apabila diperoleh nilai *realized volatility* sebesar 0,4382 dan konstanta kecil $\epsilon = 10^{-8}$, maka transformasi logaritmik dilakukan untuk meningkatkan stabilitas distribusi data dan mengurangi *skewness* sebelum proses pelatihan model.

$$\text{LogVol}_t = \ln(0.4382 + 10^{-8}) = -0.8252$$

Transformasi tersebut membantu model dalam mempelajari pola volatilitas secara lebih stabil pada data deret waktu.

Sebelum proses pemodelan, seluruh fitur dinormalisasi menggunakan metode *Min-Max Scaling* agar berada dalam rentang [0,1] guna meningkatkan stabilitas optimasi. Data kemudian disusun menggunakan pendekatan *sliding window* sepanjang 10 hari, di mana setiap sampel input terdiri atas 10 observasi historis untuk memprediksi volatilitas pada periode berikutnya. Teknik jendela waktu tetap ini umum digunakan dalam pemodelan deret waktu berbasis jaringan saraf untuk menangkap dependensi temporal dan dinamika sekuensial dalam data *time series* [17]. *Dataset* selanjutnya dibagi secara kronologis menjadi data pelatihan dan pengujian guna menjaga validitas evaluasi model dan mencegah terjadinya *data leakage*.

2.3 Pembentukan Data Time Series

Data yang telah dinormalisasi kemudian disusun menggunakan pendekatan *sliding window* ke dalam format deret waktu. Untuk model LSTM, pembentukan data dilakukan menggunakan pendekatan *look-back window* dengan pengujian pada rentang 5, 10, 15, 20, dan 30 periode. Rentang eksperimen ini dipilih untuk mengakomodasi pencarian pola dependensi temporal, mulai dari siklus mingguan (5–7 hari) hingga bulanan (30 hari). Hasil eksperimen menunjukkan bahwa *look-back* sepanjang 30 periode menghasilkan galat paling rendah, sehingga data masukan di-*reshape* ke dalam format tiga dimensi (*samples, timesteps, features*).

Sementara itu, pada model ARIMA dilakukan pengujian terhadap beberapa orde *autoregressive* (p) pada rentang 5 hingga 30 untuk menangkap dinamika memori jangka pendek dan menengah pada pola deret waktu linear. Setelah format data terbentuk, *dataset* dibagi secara kronologis menjadi 80% data latih dan 20% data uji. Proporsi 80:20 ini dipilih karena merupakan komposisi standar yang terbukti optimal dalam studi *machine learning*. Komposisi ini memberikan volume observasi masa lalu yang memadai untuk pelatihan model, sekaligus menyisakan jumlah sampel yang representatif (kurang lebih 1,5 tahun terakhir pengamatan) untuk menguji keandalan prediksi pada dinamika pasar terkini. Pembagian secara kronologis wajib dilakukan untuk mempertahankan urutan temporal serta mencegah terjadinya kebocoran informasi (*data leakage*).

2.4 Proses Pelatihan dan Validasi

Pada tahap pelatihan, arsitektur LSTM dieksplorasi dengan variasi unit bertingkat, yaitu dua lapis dengan masing-masing 64 dan 32 unit. Untuk mengurangi risiko *overfitting*, diterapkan regularisasi *dropout* sebesar 0,3 pada setiap lapisannya. Model dioptimasi menggunakan *optimizer* Adam dan fungsi kerugian *Mean Squared Error* (MSE). Pelatihan dilakukan maksimal 100 *epoch* dengan *batch size* 32, serta dilengkapi mekanisme *early stopping* dengan *patience* 20 *epoch* pada 10% proporsi data validasi untuk menghentikan proses iterasi apabila model tidak lagi menunjukkan peningkatan performa. Pada model ARIMA, proses pencarian parameter terbaik dilakukan pada rentang orde yang telah ditetapkan di tahap sebelumnya menggunakan pendekatan *walk-forward validation* di tahap pengujian. Berdasarkan hasil evaluasi galat, konfigurasi model terbaik dan paling stabil diperoleh pada orde 10, yaitu ARIMA(10,0,0).

2.5 Model Evaluasi

Evaluasi performa model dilakukan pada data pengujian menggunakan tiga metrik utama yang umum dipakai dalam penelitian peramalan *time series*, yaitu *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan koefisien determinasi (R^2). MAE, RMSE, dan R^2 secara luas diadopsi dalam literatur untuk menilai kesesuaian prediksi model terhadap data aktual dalam konteks regresi dan peramalan *time series*, di mana MAE dan RMSE mengukur besarnya kesalahan prediksi dan R^2 mengukur proporsi variasi yang dapat dijelaskan oleh model (*regression performance metrics*) [18].

MAE digunakan untuk mengukur rata-rata selisih absolut antara nilai aktual dan nilai prediksi, sehingga mencerminkan besarnya deviasi tanpa memperhatikan arah kesalahan. Secara matematis dirumuskan sebagai:

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

Sebagai ilustrasi evaluasi model, digunakan tiga data aktual dan hasil prediksi model sampel. Berdasarkan persamaan (4), nilai MAE dihitung sebagai berikut:

$$MAE = \frac{|2.1-2.0| + |2.5-2.3| + |1.9-2.1|}{3} = 0.1667$$

Nilai tersebut menunjukkan rata-rata kesalahan absolut prediksi model terhadap data aktual sebesar 0,1667.

RMSE digunakan untuk mengukur akar rata-rata kuadrat kesalahan prediksi dan memberikan penalti lebih besar terhadap kesalahan ekstrem karena melibatkan proses pengkuadratan error. Rumus RMSE dinyatakan sebagai:

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

Berdasarkan data aktual dan prediksi yang sama, nilai RMSE dihitung sebagai berikut:

$$RMSE = \sqrt{\frac{(2.1-2.0)^2 + (2.5-2.3)^2 + (1.9-2.1)^2}{3}} = 0.1732$$

Nilai RMSE sebesar 0,1732 menunjukkan tingkat kesalahan prediksi model dengan penalti yang lebih besar terhadap kesalahan ekstrem. Sementara itu, koefisien determinasi (R^2) digunakan untuk menilai proporsi variasi data aktual yang dapat dijelaskan oleh model, dengan rumus:

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

Sebagai ilustrasi evaluasi model, koefisien determinasi dihitung menggunakan data aktual dan prediksi sampel sebagai berikut:

$$R^2 = 1 - \frac{(2.1-2.0)^2 + (2.5-2.3)^2 + (1.9-2.1)^2}{(2.1-2.1667)^2 + (2.5-2.1667)^2 + (1.9-2.1667)^2} = 0.73$$

Nilai R^2 sebesar 0,73 menunjukkan bahwa model mampu menjelaskan sekitar 73% variasi data aktual pada sampel pengujian. Model dengan nilai MAE dan RMSE yang lebih rendah serta nilai R^2 yang lebih tinggi menunjukkan performa prediksi yang lebih baik. Ketiga metrik ini digunakan untuk membandingkan kinerja model LSTM dan ARIMA dalam memprediksi volatilitas pada data pengujian.

3. HASIL DAN PEMBAHASAN

3.1 Pre-Processing

Tahap pra-pemrosesan bertujuan memastikan kelayakan data deret waktu melalui pemeriksaan kelengkapan harga penutupan, identifikasi nilai hilang akibat *lagging* dan statistik bergerak, serta penghapusan observasi tidak lengkap. *Log-return* harian dihitung sesuai Persamaan (1), lalu volatilitas terealisasi tujuh hari dianalisis dengan $\sqrt{365}$ berdasarkan Persamaan (2), dan nilai akhirnya ditransformasi logaritmik menurut Persamaan (3) dengan penambahan konstanta kecil ϵ . Seluruh proses diimplementasikan dalam Python.


Setelah penghapusan nilai NaN menggunakan fungsi `dropna()`, diperoleh 2.915 observasi harian yang siap digunakan dalam pemodelan. Data kemudian dinormalisasi menggunakan *Min-Max Scaling* ke dalam rentang $[0,1]$. *Dataset* dibagi secara kronologis menjadi 2.332 data *training* dan 583 data *testing* untuk menjaga validitas evaluasi serta mencegah *data leakage*.

Tabel 1. Statistik Deskriptif *Dataset*

Statistik	<i>Training</i>	<i>Testing</i>	Total
Jumlah Observasi	2.332	583	2.915
Mean Log-Volatility	2,2382	2,2377	2,2381
Std Dev Log-Volatility	1,7665	1,8859	1,7902
Min Log-Volatility	-2,3692	-2,1575	-2,3692
Max Log-Volatility	3,8449	3,8493	3,8493

Statistik deskriptif menunjukkan bahwa rata-rata *log-volatility* pada data *training* dan *testing* relatif konsisten (2,2382 dan 2,2377), menandakan distribusi data pengujian tetap representatif terhadap data pelatihan. Standar deviasi pada data *testing* sedikit lebih tinggi, mengindikasikan variasi volatilitas yang lebih besar pada

periode akhir pengamatan. Rentang nilai yang lebar (-2,3692 hingga 3,8493) mencerminkan fluktuasi volatilitas yang signifikan selama periode penelitian.



Gambar 3. Visualisasi Log-Volatility Bitcoin Harian Periode 2018–2025

Volatilitas Bitcoin menunjukkan pola *volatility clustering*, di mana periode volatilitas tinggi cenderung diikuti oleh periode tinggi berikutnya. Terlihat pula beberapa lonjakan tajam yang merefleksikan peristiwa pasar signifikan seperti fase *bull run* 2021 dan koreksi pasar 2022. Pola ini menegaskan bahwa volatilitas bersifat dinamis dan tidak konstan (*time-varying volatility*).

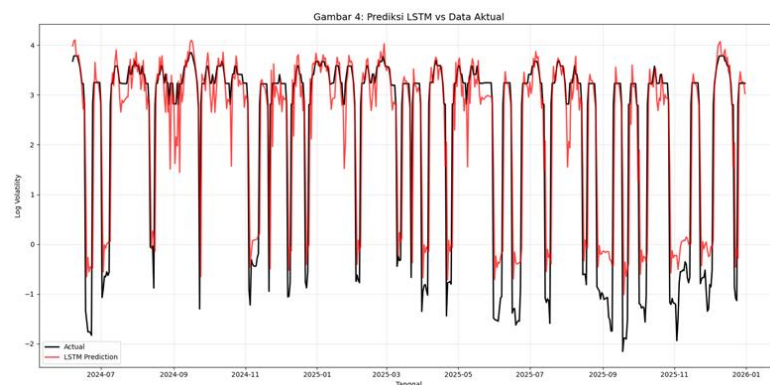
Secara keseluruhan, temuan ini menegaskan bahwa volatilitas Bitcoin memiliki struktur temporal yang kompleks dan bersifat *time-varying*, sehingga memerlukan pendekatan pemodelan yang mampu menangkap dinamika non-linear dalam data deret waktu.

3.2 Hasil Prediksi Model

3.2.1 Model Long Short-Term Memory

Model LSTM dibangun menggunakan dua lapis LSTM dengan masing-masing 64 dan 32 unit, dilengkapi *dropout* sebesar 0,3 pada setiap lapisan untuk mengurangi risiko *overfitting*. Lapisan *dense* dengan 16 unit digunakan sebelum menghasilkan satu output prediksi. Model menggunakan *look-back window* sepanjang 30 periode, *optimizer* Adam dengan *learning rate* 0,001, serta fungsi kerugian Mean Squared Error (MSE). Proses pelatihan menerapkan *early stopping* dengan *patience* 20 epoch, dan model terbaik diperoleh pada epoch ke-145 dengan *validation loss* sebesar 0,01961.

Berdasarkan evaluasi menggunakan pendekatan *walk-forward validation*, model LSTM dengan konfigurasi terbaik (*look-back* 30) menghasilkan nilai MAE sebesar 0,5126, RMSE sebesar 1,0408, dan R^2 sebesar 0,6803. Hasil ini menunjukkan bahwa model mampu menjelaskan sekitar 68,03% variasi log-volatilitas Bitcoin pada periode pengujian. Secara umum, model menunjukkan performa yang baik dalam mengikuti pola utama pergerakan volatilitas, khususnya pada kondisi tren yang relatif stabil. Namun, prediksi yang dihasilkan cenderung lebih halus (*smooth*), sehingga pada beberapa kondisi kurang responsif terhadap lonjakan volatilitas yang bersifat ekstrem.



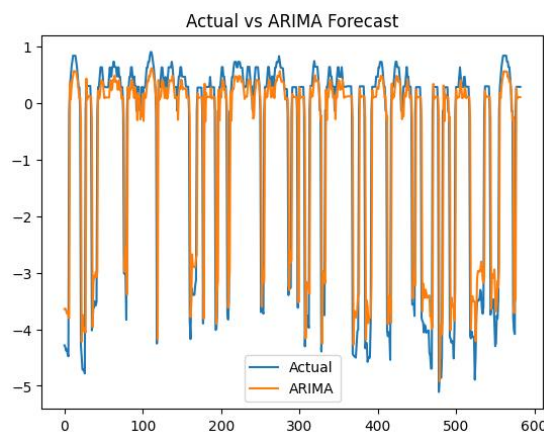
Gambar 4. Perbandingan Prediksi LSTM terhadap Data Aktual pada Data Uji

Berdasarkan visualisasi pada Gambar 4, ditunjukkan perbandingan nilai aktual dan hasil prediksi model LSTM pada data uji yang mencakup 20% akhir periode observasi, yaitu sekitar pertengahan tahun 2024 hingga awal tahun 2026. Dengan penggunaan *look-back window* sepanjang 30 periode, setiap prediksi didasarkan pada informasi dari 30 observasi sebelumnya, sehingga jumlah sampel efektif pada data uji sedikit berkurang

dibandingkan total data uji awal. Meskipun demikian, model tetap mampu merepresentasikan dinamika volatilitas secara memadai.

3.2.2 Model ARIMA

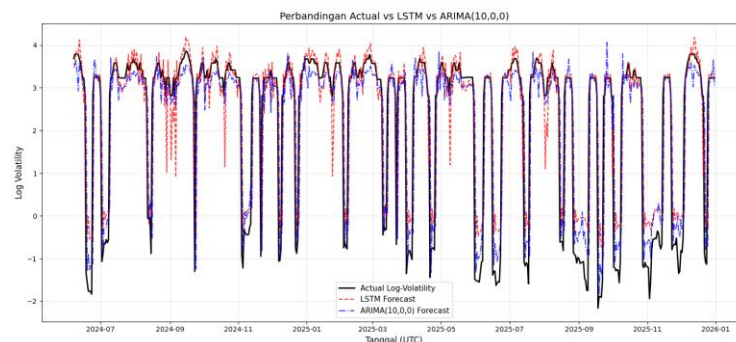
Model ARIMA digunakan untuk memodelkan dinamika volatilitas Bitcoin dengan memanfaatkan struktur linear dan dependensi temporal dalam data deret waktu. Evaluasi dilakukan pada data uji menggunakan pendekatan *walk-forward validation*. Berdasarkan hasil perhitungan, model menghasilkan nilai MAE sebesar 0,5430, RMSE sebesar 1,0217, dan R^2 sebesar 0,7052. Nilai tersebut menunjukkan bahwa model mampu menjelaskan sekitar 70,52% variasi *log-volatility* Bitcoin pada periode pengujian. Secara umum, model ARIMA menunjukkan performa yang cukup baik dalam merepresentasikan pola utama pergerakan volatilitas, khususnya dalam menangkap pola linear dan struktur *autokorelasi* pada data. Hal ini mengindikasikan bahwa pendekatan berbasis *time series* statistik masih relevan dalam memodelkan dinamika volatilitas, terutama pada kondisi yang relatif stabil. Capaian ini tergolong cukup baik mengingat karakteristik data volatilitas aset kripto yang memiliki tingkat *noise* tinggi dan fluktuasi yang dinamis. Hal ini menunjukkan bahwa model ARIMA mampu memberikan representasi yang memadai terhadap struktur dasar pergerakan volatilitas.



Gambar 5. Perbandingan Prediksi ARIMA terhadap Data Aktual pada Data Uji

Berdasarkan visualisasi pada Gambar 5, ditunjukkan perbandingan nilai aktual dan hasil prediksi model ARIMA pada data uji yang mencakup 20% akhir periode observasi. Visualisasi menunjukkan bahwa model ARIMA mampu mengikuti pola umum pergerakan volatilitas aktual dengan cukup baik, terutama dalam merepresentasikan tren dan dependensi temporal. Pada beberapa titik dengan lonjakan atau penurunan volatilitas yang tajam, terlihat adanya selisih antara nilai aktual dan hasil prediksi. Hal ini mengindikasikan bahwa dinamika volatilitas yang sangat fluktuatif mengandung komponen kompleks yang tidak sepenuhnya dapat direpresentasikan oleh model linear. Meskipun demikian, secara keseluruhan model ARIMA tetap menunjukkan kinerja yang stabil dalam menangkap pola utama pergerakan volatilitas. Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa model berbasis *time series* statistik seperti ARIMA efektif dalam memodelkan pola linear dan autokorelasi, serta tetap menjadi pendekatan yang andal dalam analisis volatilitas, meskipun pada kondisi tertentu diperlukan pendekatan tambahan untuk menangkap dinamika yang lebih kompleks [5].

3.2.3 Perbandingan Model

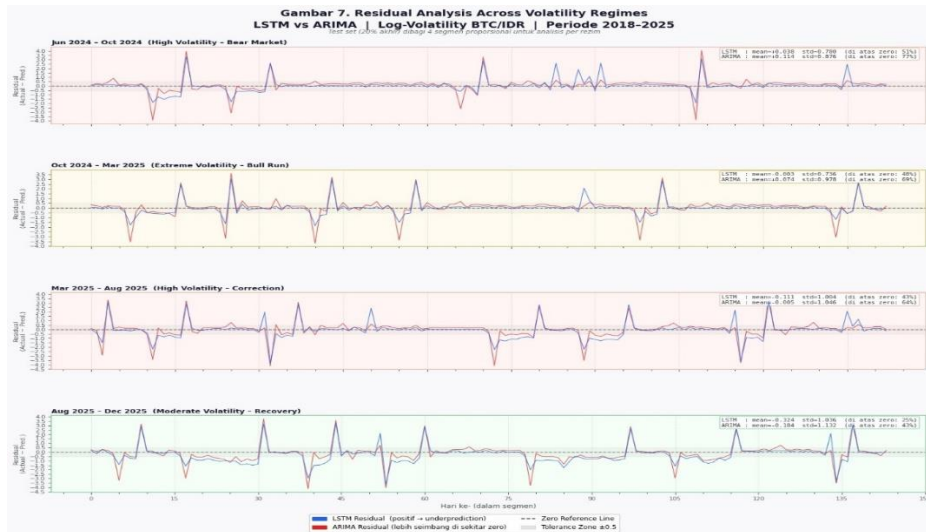


Gambar 6. Perbandingan Prediksi Model LSTM dan ARIMA terhadap Data Aktual Log-Volatibility Bitcoin

Gambar 6 menunjukkan perbandingan hasil prediksi model LSTM dan ARIMA terhadap data aktual *log-volatility* Bitcoin pada data uji yang mencakup 20% akhir periode observasi. Visualisasi menunjukkan bahwa

kedua model mampu menangkap dinamika *log-volatility* Bitcoin secara umum, meskipun jumlah sampel efektif sedikit berkurang akibat penggunaan *look-back window*. Data aktual memperlihatkan fluktuasi yang tinggi dengan penurunan tajam yang terjadi secara berulang, mencerminkan karakteristik volatilitas *cryptocurrency* yang dinamis dan tidak stabil. Model LSTM menghasilkan prediksi yang relatif lebih halus (*smooth*) dan stabil dalam mengikuti tren utama pergerakan volatilitas. Pendekatan ini memungkinkan LSTM untuk merepresentasikan arah umum data dengan cukup baik, meskipun pada beberapa periode fluktuasi ekstrem terlihat bahwa model cenderung kurang responsif terhadap perubahan yang terjadi secara mendadak. Sementara itu, model ARIMA juga mampu merepresentasikan pola umum data, khususnya dalam menangkap struktur linear dan autokorelasi pada deret waktu. Dibandingkan dengan LSTM, model ARIMA terlihat lebih responsif terhadap perubahan mendadak, terutama pada saat terjadi lonjakan atau penurunan volatilitas yang cepat. Kemampuan ini menjadi penting dalam pemodelan volatilitas *cryptocurrency* yang memiliki karakteristik fluktuasi ekstrem dan perubahan yang cepat dalam jangka waktu pendek.

Perbedaan kinerja kedua model menjadi lebih jelas pada periode dengan fluktuasi ekstrem. LSTM cenderung menghasilkan prediksi yang lebih stabil, namun kurang mampu menangkap kedalaman perubahan secara akurat. Sebaliknya, ARIMA menunjukkan kemampuan yang lebih baik dalam mengikuti pola fluktuasi tajam dan perubahan mendadak, meskipun pada beberapa titik masih terdapat deviasi terhadap nilai aktual. Secara keseluruhan, kedua model menunjukkan performa yang baik dalam merepresentasikan pola *log-volatility*. Namun demikian, model ARIMA menunjukkan kemampuan yang lebih baik dalam menangkap dinamika fluktuasi jangka pendek serta perubahan ekstrem, sehingga lebih sesuai untuk memodelkan karakteristik volatilitas Bitcoin yang bersifat dinamis dan tidak stabil.



Gambar 7. Analisis Residu Komparatif LSTM dan ARIMA pada Berbagai Regim Volatilitas Bitcoin

Untuk memperdalam analisis komparatif antar model, dilakukan analisis residual pada berbagai rezim volatilitas sebagaimana ditunjukkan pada Gambar 7. Residual dihitung berdasarkan selisih antara nilai aktual dan hasil prediksi model pada data pengujian yang dibagi menjadi empat segmen proporsional sesuai kondisi pasar *cryptocurrency*, yaitu fase bear market, bull run, correction, dan recovery. Pada segmen Juni 2024 hingga Oktober 2024, model LSTM menunjukkan standar deviasi residual yang lebih rendah dibandingkan ARIMA, yaitu 0,780 berbanding 0,876, yang menunjukkan prediksi LSTM relatif lebih stabil pada fase volatilitas tinggi awal pengamatan. Namun, ARIMA memiliki persentase residual di atas garis nol sebesar 77%, lebih tinggi dibandingkan LSTM sebesar 51%, yang mengindikasikan kecenderungan underprediction yang lebih dominan. Pada segmen Oktober 2024 hingga Maret 2025 yang merepresentasikan fase extreme volatility bull run, kedua model mengalami lonjakan residual pada beberapa titik pengamatan. LSTM memiliki rata rata residual mendekati nol sebesar $-0,003$ dengan standar deviasi 0,736, sedangkan ARIMA memiliki rata rata residual sebesar $+0,074$ dengan standar deviasi lebih tinggi sebesar 0,978. Hasil tersebut menunjukkan bahwa LSTM lebih stabil dan lebih seimbang dalam menghadapi volatilitas ekstrem.

Pada segmen Maret 2025 hingga Agustus 2025, pola residual kedua model mulai menunjukkan konvergensi. LSTM memiliki rata rata residual sebesar $-0,111$ dengan standar deviasi 1,004, sedangkan ARIMA menghasilkan rata rata residual yang lebih mendekati nol sebesar $-0,005$ dengan standar deviasi 1,046. Kondisi ini menunjukkan bahwa prediksi ARIMA cenderung lebih tidak bias dibandingkan LSTM pada fase koreksi pasar. Selanjutnya, pada segmen Agustus 2025 hingga Desember 2025, kedua model menunjukkan kecenderungan overprediction yang ditandai dominasi residual negatif. LSTM memiliki rata rata residual sebesar $-0,324$,

sedangkan ARIMA sebesar $-0,184$ dengan standar deviasi masing masing $1,036$ dan $1,132$. Secara keseluruhan, analisis residual menunjukkan bahwa LSTM cenderung lebih stabil pada periode volatilitas tinggi karena memiliki standar deviasi residual yang lebih rendah pada dua segmen awal, sementara ARIMA menunjukkan prediksi yang lebih tidak bias pada fase volatilitas yang mulai menurun karena menghasilkan rata rata residual yang lebih mendekati nol. Temuan ini memperkuat hasil evaluasi kuantitatif sebelumnya, di mana ARIMA memperoleh nilai RMSE lebih rendah sebesar $1,0217$ dan nilai R^2 lebih tinggi sebesar $0,7052$ dibandingkan LSTM dengan RMSE $1,0408$ dan R^2 $0,6803$.

3.3 Evaluasi Model

Tabel 2 dan Tabel 3 menyajikan hasil evaluasi performa dua model yang diimplementasikan dalam penelitian ini, yaitu LSTM dan ARIMA, berdasarkan tiga metrik utama: *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan koefisien determinasi (R^2).

Tabel 2. Evaluasi Performa LSTM

<i>Look-back</i>	MAE	RMSE	R^2
5	0,5210	1,0425	0,6870
10	0,5153	1,0467	0,6842
15	0,5318	1,0443	0,6866
20	0,5308	1,0521	0,6836
30	0,5126	1,0408	0,6803

Tabel 3. Evaluasi Performa ARIMA

<i>Orde (p)</i>	MAE	RMSE	R^2
5	0,5374	1,0414	0,6937
10	0,5430	1,0217	0,7052
15	0,5434	1,0225	0,7047
20	0,5430	1,0249	0,7033
30	0,5481	1,0292	0,7008

Evaluasi *walk-forward* pada data uji menunjukkan bahwa masing-masing model memiliki konfigurasi terbaik yang memberikan performa optimal berdasarkan metrik yang digunakan. Model LSTM mencapai kinerja terbaik pada *look-back* 30 dengan nilai MAE sebesar $0,5126$, RMSE sebesar $1,0408$, dan R^2 sebesar $0,6803$, yang berarti mampu menjelaskan sekitar $68,03\%$ variasi log-volatilitas. Sementara itu, model ARIMA menunjukkan performa terbaik pada orde (p) = 10 dengan nilai MAE sebesar $0,5430$, RMSE sebesar $1,0217$, dan R^2 sebesar $0,7052$. Hasil ini menunjukkan bahwa model ARIMA mampu menjelaskan sekitar $70,52\%$ variasi log-volatilitas Bitcoin.

Nilai MAE yang lebih rendah pada LSTM mengindikasikan bahwa model ini lebih akurat dalam meminimalkan kesalahan prediksi secara umum. Namun demikian, nilai RMSE yang lebih rendah serta nilai R^2 yang lebih tinggi pada ARIMA menunjukkan bahwa model ini lebih mampu menangkap variasi data serta lebih sensitif terhadap kesalahan berukuran besar. Dalam konteks prediksi volatilitas *cryptocurrency* yang memiliki karakteristik fluktuasi ekstrem, metrik RMSE menjadi penting karena memberikan penalti lebih besar terhadap kesalahan prediksi yang besar. Oleh karena itu, nilai RMSE yang lebih rendah pada model ARIMA menunjukkan bahwa model ini lebih efektif dalam menangkap dinamika volatilitas yang kompleks. Secara keseluruhan, berdasarkan metrik evaluasi yang digunakan, model ARIMA menunjukkan performa yang lebih unggul dalam merepresentasikan variasi log-volatilitas Bitcoin dibandingkan model LSTM.

3.4 Pembahasan

Hasil analisis menunjukkan bahwa kedua model memiliki kemampuan yang baik dalam memodelkan volatilitas Bitcoin, namun model ARIMA menunjukkan performa yang lebih unggul secara keseluruhan. Model LSTM mencapai kinerja terbaik pada *look-back* 30 dengan nilai MAE sebesar $0,5126$, RMSE sebesar $1,0408$, dan R^2 sebesar $0,6803$. Nilai MAE yang lebih rendah dibandingkan ARIMA menunjukkan bahwa LSTM lebih akurat dalam meminimalkan kesalahan prediksi secara umum. Namun demikian, model ARIMA menunjukkan performa yang lebih baik pada metrik RMSE dan R^2 . Model ARIMA dengan orde (p) = 10 menghasilkan nilai RMSE sebesar $1,0217$ yang lebih rendah dibandingkan LSTM sebesar $1,0408$. Hal ini menunjukkan bahwa ARIMA lebih mampu mengendalikan kesalahan prediksi berukuran besar yang sering muncul pada data volatilitas *cryptocurrency*. Karena RMSE memberikan penalti lebih besar terhadap error ekstrem, hasil ini mengindikasikan bahwa ARIMA lebih efektif dalam menangkap lonjakan volatilitas mendadak dibandingkan LSTM. Selain itu, nilai R^2 pada model ARIMA sebesar $0,7052$ juga lebih tinggi dibandingkan model LSTM sebesar $0,6803$, yang menunjukkan bahwa ARIMA mampu menjelaskan variasi log-volatilitas Bitcoin dengan lebih baik pada periode pengujian.

Perbedaan pendekatan antara kedua model menjadi faktor utama yang memengaruhi hasil tersebut. LSTM sebagai model berbasis deep learning mampu mempelajari hubungan non linear dan dependensi temporal yang kompleks, sehingga menghasilkan prediksi yang lebih halus dan stabil. Sebaliknya, ARIMA yang mengandalkan struktur autoregresif menunjukkan kemampuan yang lebih baik dalam menangkap dinamika jangka pendek dan fluktuasi ekstrem. Analisis residual pada berbagai rezim volatilitas juga menunjukkan bahwa LSTM cenderung lebih stabil pada fase volatilitas tinggi, sedangkan ARIMA menghasilkan residual yang lebih mendekati nol pada fase koreksi dan pemulihan pasar sehingga prediksinya lebih tidak bias. Karakteristik log-volatility BTC/IDR pada penelitian ini menunjukkan adanya pola autokorelasi jangka pendek yang cukup dominan pada horizon harian, sehingga pendekatan autoregressive seperti ARIMA masih mampu merepresentasikan dinamika data secara efektif. Selain itu, jumlah observasi sekitar 2.915 data harian masih tergolong moderat untuk pendekatan deep learning, sehingga kompleksitas model LSTM belum memberikan keunggulan yang signifikan dibandingkan model statistik yang lebih sederhana dan stabil. Dari sisi interpretabilitas, model ARIMA juga memiliki keunggulan karena parameter yang dihasilkan lebih mudah diinterpretasikan secara statistik, sedangkan model LSTM cenderung bersifat black-box sehingga interpretasi model menjadi lebih terbatas.

Dari sisi implementasi praktis, model LSTM lebih sesuai digunakan untuk memantau kecenderungan volatilitas yang lebih stabil dan mengurangi sensitivitas terhadap noise pasar. Sebaliknya, ARIMA lebih sesuai digunakan untukantisipasi perubahan volatilitas jangka pendek dan deteksi lonjakan risiko karena lebih responsif terhadap perubahan ekstrem pada data cryptocurrency. Oleh karena itu, model ARIMA dinilai lebih representatif untuk monitoring volatilitas harian BTC/IDR dan manajemen risiko jangka pendek pada penelitian ini. Perbandingan dengan penelitian terdahulu menunjukkan temuan yang beragam. Dudek et al. [5] membandingkan berbagai metode statistik dan machine learning untuk volatilitas cryptocurrency dan menyimpulkan bahwa ARIMA tetap kompetitif, terutama untuk data dengan jumlah observasi sedang (<5.000), sejalan dengan hasil kami. Namun, Huang et al. [6] menemukan bahwa LSTM lebih unggul pada dataset frekuensi tinggi (per jam) dengan jumlah observasi >20.000, yang mengindikasikan bahwa keunggulan LSTM bergantung pada skala data. Wang et al. [7] menambahkan bahwa penambahan variabel eksternal (sentimen media sosial, volume perdagangan) dapat meningkatkan performa LSTM secara signifikan, sementara ARIMA lebih sensitif terhadap overfitting jika terlalu banyak variabel. Penelitian kami mengonfirmasi bahwa pola linear dan autokorelasi masih dominan, sehingga ARIMA lebih representatif. Hal ini juga didukung oleh Kareem & Aue [19] yang menyatakan bahwa untuk prediksi volatilitas jangka pendek, model klasik seringkali lebih stabil dibandingkan deep learning.

4. KESIMPULAN

Penelitian ini membandingkan performa model Long Short-Term Memory (LSTM) dan Autoregressive Integrated Moving Average (ARIMA) dalam memprediksi log-volatilitas Bitcoin pada pasangan BTC/IDR periode 2018-2025. Berdasarkan evaluasi dengan walk-forward validation menggunakan metrik MAE, RMSE, dan R^2 , model ARIMA dengan orde autoregressive (p)=10 menunjukkan performa unggul dengan RMSE 1,0217 dan R^2 0,7052, dibandingkan LSTM dengan look-back 30 yang menghasilkan RMSE 1,0408 dan R^2 0,6803. Meskipun LSTM memiliki MAE lebih rendah (0,5126 vs 0,5430), ARIMA lebih efektif dalam menangkap fluktuasi ekstrem dan menjelaskan variasi data. Karakteristik LSTM cenderung menghasilkan prediksi yang lebih halus dan stabil, sementara ARIMA lebih responsif terhadap perubahan mendadak. Keterbatasan penelitian ini adalah penggunaan data univariat tanpa variabel eksternal seperti volume perdagangan atau sentimen pasar, serta jumlah dataset yang relatif terbatas (~2.915 observasi) sehingga LSTM belum menunjukkan keunggulan maksimal. Penelitian selanjutnya disarankan untuk menambahkan variabel eksogen, menggunakan data frekuensi lebih tinggi, serta menguji pada aset kripto lain seperti Ethereum atau Binance Coin untuk meningkatkan generalisasi model. Secara keseluruhan, ARIMA direkomendasikan sebagai model prediksi volatilitas Bitcoin yang lebih representatif untuk pasar Indonesia.

REFERENCES

- [1] Y. Liu et al., "Risks and Returns of Cryptocurrency," 2018. [Online]. Available: <https://ssrn.com/abstract=3226952>
- [2] B. Dharma, P. Gusniati, and T. Wardani, "ANALISIS PEMANFAATAN CRYPTOCURRENCY BITCOIN SEBAGAI ALAT ALTERNATIF INVESTASI," 2023.
- [3] M. Zahid, F. Iqbal, and D. Koutmos, "Forecasting Bitcoin Volatility Using Hybrid GARCH Models with Machine Learning," 2022, doi: 10.3390/risks.
- [4] E. Bouri, A. A. Salisu, and R. Gupta, "The predictive power of Bitcoin prices for the realized volatility of US stock sector returns," *Financial Innovation*, vol. 9, no. 1, Dec. 2023, doi: 10.1186/s40854-023-00464-8.
- [5] G. Dudek, P. Fiszeder, P. Kobus, and W. Orzeszko, "Forecasting cryptocurrencies volatility using statistical and machine learning methods: A comparative study," *Appl. Soft Comput.*, vol. 151, Jan. 2024, doi: 10.1016/j.asoc.2023.111132.
- [6] Z. C. Huang, I. Sangiorgi, and A. Urquhart, "Forecasting Bitcoin volatility using machine learning techniques," *Journal of International Financial Markets, Institutions and Money*, vol. 97, Dec. 2024, doi: 10.1016/j.intfin.2024.102064.

- [7] Y. Wang, G. Andreeva, and B. Martin-Barragan, "Machine learning approaches to forecasting cryptocurrency volatility: Considering internal and external determinants," *International Review of Financial Analysis*, vol. 90, Nov. 2023, doi: 10.1016/j.irfa.2023.102914.
- [8] N. A. Sofiah, K. D. Tania, A. Meiriza, and A. Wedhasmara, "A Comparative Assessment SARIMA and LSTM Models for the Gurugram Air Quality Index's Knowledge Discovery," in *2024 International Conference on Electrical Engineering and Computer Science (ICECOS)*, 2024, pp. 26–31. doi: 10.1109/ICECOS63900.2024.10791243.
- [9] F. A. Miranda, K. D. Tania, and R. D. Kurnia, "Comparative Performance Evaluation of ARIMA, SARIMA, and LSTM for Daily Shallot Price Forecasting in Palembang City," *Electronic Journal of Education, Social Economics and Technology*, vol. 6, no. 2, p. 1323, Dec. 2025, doi: 10.33122/ejeset.v6i2.1323.
- [10] M. L. Pratama and H. Utama, "PENDEKATAN DEEP LEARNING MENGGUNAKAN METODE LSTM UNTUK PREDIKSI HARGA BITCOIN," *IJCSR: The Indonesian Journal of Computer Science Research*, vol. 2, no. 2, 2023, doi: 10.37905.
- [11] N. Urooj, L. Asif, and Z. Jabin, "Bitcoin Price Forecasting: A Comparative Study of Machine Learning, Statistical and Deep Learning Models," 2024.
- [12] A. Kareem and A. Aue, "Bitcoin Forecasting with Classical Time Series Models on Prices and Volatility," Nov. 2025, [Online]. Available: <http://arxiv.org/abs/2511.06224>
- [13] C. Alexander, D. F. Heck, and A. Kaeck, "The Role of Binance in Bitcoin Volatility Transmission," *Appl. Math. Finance*, vol. 29, no. 1, pp. 1–32, 2022, doi: 10.1080/1350486X.2022.2125885.
- [14] P. Anand and A. M. Sharan, "Bitcoin Return Dynamics Volatility and Time Series Forecasting," *International Journal of Financial Studies*, vol. 13, no. 2, Jun. 2025, doi: 10.3390/ijfs13020108.
- [15] S. H. Sung, J. M. Kim, B. K. Park, and S. Kim, "A Study on Cryptocurrency Log-Return Price Prediction Using Multivariate Time-Series Model," *Axioms*, vol. 11, no. 9, Sep. 2022, doi: 10.3390/axioms11090448.
- [16] J. Chevallier and B. Sanhaji, "Jump-Robust Realized-GARCH-MIDAS-X Estimators for Bitcoin and Ethereum Volatility Indices," *Stats (Basel)*, vol. 6, no. 4, pp. 1339–1370, Dec. 2023, doi: 10.3390/stats6040082.
- [17] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997, doi: 10.1162/neco.1997.9.8.1735.
- [18] S. Kim, "Innovating knowledge and information for a firm-level automobile demand forecast system: A machine learning perspective," *Journal of Innovation and Knowledge*, vol. 8, no. 2, Apr. 2023, doi: 10.1016/j.jik.2023.100355.