

# Perbandingan Kinerja Model ARIMA-GARCH dan LSTM Dalam Peramalan Volatilitas Bitcoin

Miezan El Khoir, Fenty Ariany\*

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

Email: <sup>1</sup>miezan\_el\_khoir@teknokrat.ac.id, <sup>2</sup>\*fenty@teknokrat.ac.id

Email Penulis Korespondensi: fenty@teknokrat.ac.id

Submitted: 29/04/2026; Accepted: 02/06/2026; Published: 05/06/2026

**Abstrak**—Bitcoin merupakan aset kripto dengan tingkat volatilitas yang ekstrem, sehingga memerlukan model peramalan yang presisi untuk mitigasi risiko investasi. Penelitian ini bertujuan untuk menganalisis dan meramalkan volatilitas harga Bitcoin menggunakan pendekatan integrasi *Autoregressive Integrated Moving Average - Generalized Autoregressive Conditional Heteroskedasticity* (ARIMA-GARCH) serta membandingkan performanya dengan metode *Deep Learning* berupa *Long Short-Term Memory* (LSTM). Data yang digunakan adalah harga penutupan harian Bitcoin periode 2018 hingga 2025. Hasil penelitian menunjukkan bahwa model ARIMA(1,1,1)-GARCH(1,1) mampu menangkap fenomena *volatility clustering* dengan nilai parameter  $\beta$  yang signifikan (0,8704), mengindikasikan persistensi volatilitas jangka panjang. Namun, dalam hal akurasi prediksi harga, model LSTM jauh mengungguli model statistik konvensional. Berdasarkan pengujian, model ARIMA-GARCH menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 18,11%, yang masuk dalam kategori peramalan baik. Sementara itu, model LSTM mencapai nilai MAPE sebesar 3,09%, yang dikategorikan sebagai peramalan sangat akurat. Perbedaan signifikan pada nilai *Root Mean Square Error* (RMSE) juga mempertegas bahwa arsitektur LSTM lebih adaptif dalam memproses pola data non-linear dan fluktuasi harga Bitcoin yang kompleks. Penelitian ini menyimpulkan bahwa meskipun ARIMA-GARCH unggul dalam analisis struktur risiko, model LSTM memberikan hasil proyeksi harga yang lebih andal bagi para pelaku pasar kripto.

**Kata Kunci:** Bitcoin; ARIMA-GARCH; LSTM; Volatilitas; Peramalan Harga

**Abstract**—Bitcoin is a cryptocurrency asset with extreme volatility, necessitating precise forecasting models for investment risk mitigation. This study aims to analyze and forecast Bitcoin price volatility using an integrated *Autoregressive Integrated Moving Average - Generalized Autoregressive Conditional Heteroskedasticity* (ARIMA-GARCH) approach and compare its performance with a *Deep Learning* method, specifically *Long Short-Term Memory* (LSTM). The data used is the daily closing price of Bitcoin for the period 2018 to 2025. The results indicate that the ARIMA(1,1,1)-GARCH(1,1) model effectively captures the volatility clustering phenomenon, with a significant beta parameter value of 0.8691, indicating long-term volatility persistence. However, in terms of price prediction accuracy, the LSTM model significantly outperforms the conventional statistical model. Based on the testing, the ARIMA-GARCH model produced a *Mean Absolute Percentage Error* (MAPE) of 18.11%, which falls into the "good forecasting" category. In contrast, the LSTM model achieved a MAPE of 3.09%, categorized as "highly accurate forecasting." The significant difference in *Root Mean Square Error* (RMSE) values also reinforces that the LSTM architecture is more adaptive in processing non-linear data patterns and complex Bitcoin price fluctuations. This study concludes that while ARIMA-GARCH excels in risk structure analysis, the LSTM model provides more reliable price projection results for crypto market participants.

**Keywords:** Bitcoin; ARIMA-GARCH; LSTM; Volatility; Price Forecasting

## 1. PENDAHULUAN

Bitcoin, sebagai aset kripto pionir yang diperkenalkan oleh Satoshi Nakamoto pada tahun 2008, telah merevolusi lanskap keuangan global melalui sistem pembayaran elektronik berbasis *peer-to-peer* yang terdesentralisasi [1]. Seiring dengan perkembangannya, Bitcoin tidak hanya berfungsi sebagai alat transaksi, tetapi juga telah menjadi instrumen investasi digital yang diperdagangkan secara global dan menarik perhatian investor, akademisi, dan pembuat kebijakan [2]. Salah satu karakteristik utama Bitcoin adalah tingkat volatilitas harga yang tinggi. Volatilitas ini dipengaruhi oleh berbagai faktor, baik internal maupun eksternal. Dari sisi pelaku pasar, fenomena spekulatif seperti *fear of missing out* (FOMO) yang berkaitan dengan *irrational exuberance* turut mendorong fluktuasi harga yang signifikan [3]. Sementara itu, faktor eksternal seperti inflasi mata uang fiat, kondisi makroekonomi global, serta dinamika regulasi juga berkontribusi terhadap ketidakstabilan harga Bitcoin [4]. Kondisi ini menyebabkan Bitcoin sering dianggap sebagai *digital gold* atau aset lindung nilai [5], namun di sisi lain juga menghadirkan risiko tinggi dalam pengambilan keputusan investasi.

Kelangkaan Bitcoin dan teknologi *blockchain*, yang menjamin keamanan dan transparansi transaksi tanpa memerlukan otoritas pusat, adalah pendorong utama di balik fenomena ini. Namun, terlepas dari peningkatan popularitasnya yang cepat, Bitcoin memiliki fitur penting yang membedakannya dari aset keuangan tradisional seperti saham atau uang fiat yaitu tingkat volatilitas harga yang sangat tinggi [6], [7]. Fluktuasi harga yang tinggi merupakan cerminan dari tingkat ketidakpastian pasar yang parah ini, yang seringkali menyulitkan investor untuk mengelola risiko dan membuat keputusan investasi yang bijak [8]. Penelitian sebelumnya menunjukkan bahwa variasi harga Bitcoin dipengaruhi oleh berbagai faktor kompleks, seperti sentimen pasar, kondisi makroekonomi global, dan perkembangan regulasi [9].

Dalam perspektif keuangan, data pengembalian Bitcoin umumnya menunjukkan sifat heteroskedastisitas, yaitu varians yang berubah dari waktu ke waktu dan membentuk pola *volatility clustering* [10], [11]. Untuk menganalisis data deret waktu, model *Autoregressive Integrated Moving Average* (ARIMA) banyak digunakan karena

kemampuannya dalam menangkap pola linier dan hubungan temporal berdasarkan data historis [12]. Namun, model ini memiliki keterbatasan dalam memodelkan varians yang tidak konstan sehingga kurang optimal dalam merepresentasikan dinamika volatilitas yang kompleks.

Sebagai solusi, model *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) dikembangkan untuk menangkap perubahan varians secara dinamis. Integrasi ARIMA-GARCH terbukti mampu meningkatkan akurasi dalam memodelkan volatilitas, khususnya pada data keuangan [13], [14]. Meskipun demikian, pendekatan ini masih berbasis asumsi linearitas dan belum sepenuhnya mampu menangkap pola non-linear yang kompleks pada pasar kripto yang sangat dinamis.

Penggunaan data jangka panjang juga menjadi faktor penting dalam analisis harga Bitcoin, terutama untuk menangkap siklus pasar yang dipengaruhi oleh peristiwa fundamental seperti *halving* [15]. Studi terbaru menunjukkan bahwa model GARCH dapat digunakan untuk menganalisis risiko pasar kripto, meskipun sebagian besar penelitian masih berfokus pada analisis volatilitas tanpa melakukan prediksi harga secara komprehensif [5].

Seiring dengan kemajuan teknologi, pendekatan *Deep Learning* seperti *Long Short-Term Memory* (LSTM) mulai banyak diterapkan dalam analisis deret waktu. LSTM memiliki keunggulan dalam menangkap pola non-linear serta ketergantungan jangka panjang (*long-term dependencies*), sehingga dinilai lebih adaptif dalam memodelkan data yang kompleks dibandingkan metode statistik tradisional [8]. Hal ini menjadikan LSTM sebagai alternatif yang potensial dalam peramalan volatilitas aset kripto.

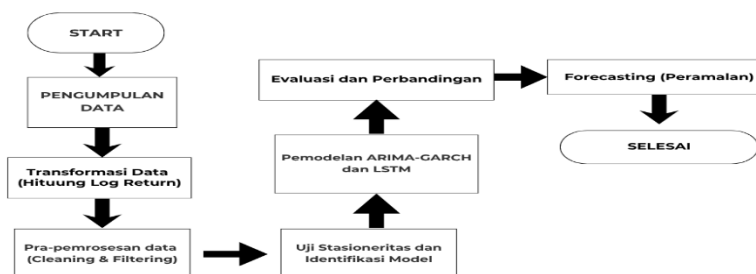
Meskipun berbagai penelitian telah mengkaji penggunaan ARIMA-GARCH maupun LSTM, masih terdapat kesenjangan penelitian dalam bentuk kurangnya studi komprehensif yang secara langsung membandingkan kinerja kedua pendekatan tersebut, khususnya pada data jangka panjang yang mencakup siklus pasar penting Bitcoin. Periode 2018 hingga awal 2025 merupakan fase krusial karena mencakup berbagai dinamika signifikan, seperti dampak pasca pandemi, perubahan tren pasar, serta peristiwa fundamental seperti *halving*. Sebagian besar penelitian sebelumnya masih terbatas pada data jangka pendek atau hanya berfokus pada satu pendekatan metode.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk membandingkan kinerja model ARIMA(1,1,1)-GARCH(1,1) dan LSTM dalam peramalan volatilitas Bitcoin. Kontribusi utama penelitian ini terletak pada penyusunan kerangka komparatif yang sistematis antara pendekatan statistik dan *Deep Learning* menggunakan dataset terbaru dari tahun 2018 – 2025 dan mencakup periode siklus pasar yang lengkap. Dengan demikian, penelitian ini diharapkan tidak hanya memberikan evaluasi empiris terhadap tingkat akurasi masing-masing model, tetapi juga memberikan wawasan yang lebih komprehensif mengenai pendekatan yang paling efektif dalam memodelkan volatilitas Bitcoin di tengah dinamika pasar yang kompleks.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode komparatif. Penelitian bertujuan untuk membandingkan kinerja dua model peramalan, yaitu ARIMA(1,1,1)-GARCH(1,1) dan LSTM dalam memprediksi volatilitas Bitcoin. Penelitian ini menggunakan data sekunder berupa harga penutupan (*closing price*) Bitcoin dengan frekuensi harian selama periode 2018–2025 yang diperoleh dari Kaggle. Tahapan studi ini disusun secara metodis untuk menjamin ketepatan dalam memprediksi harga dan volatilitas Bitcoin. Berikut urutan Langkah-langkah dalam penelitian ini digambarkan pada Gambar 1.



Gambar 1. Diagram Flow

Berdasarkan Gambar 1, alur penelitian ini terbagi menjadi beberapa tahapan proses data sebagai berikut:

- Pengumpulan data: Proses dimulai dengan pengambilan dataset historis Bitcoin dari Platform Kaggle dalam bentuk file csv yang berisi data historis Bitcoin (BTC/USDT) dengan rentang waktu 2018 hingga 2025 dengan interval harian (*Daily*).
- Pra-pemrosesan Data (*Cleaning & Filtering*): karena data dari Kaggle bersifat mentah, dilakukan tahap pembersihan untuk memastikan tidak ada nilai kosong (*missing values*) atau format waktu yang tidak sesuai. Selanjutnya, dilakukan filtrasi menggunakan Simple Moving Average (SMA) untuk menghaluskan fluktuasi harga harian yang ekstrim. Khusus untuk perbandingan model Deep Learning, dilakukan juga proses scalling data menggunakan Min-Max Scaler.



- c. Transformasi Data (*Log-Return*): karena data harga aset keuangan biasanya tidak stasioner, dilakukan transformasi data menjadi nilai *Log-Return*. Hal ini dilakukan untuk menstabilkan varians dan memudahkan proses pemodelan statistik.
- d. Uji Stasioneritas dan Identifikasi Model: Data hasil transformasi diuji menggunakan *Augmented Dickey-Fuller* (ADF) Test untuk memastikan stasioneritas [16]. Setelah itu, ditentukan parameter (p, d, q) yang paling optimal untuk model ARIMA melalui analisis plot ACF dan PACF.
- e. Pemodelan ARIMA-GARCH dan LSTM: Model ARIMA digunakan untuk menangkap pola rata-rata harga, sementara model GARCH digunakan untuk menangkap efek volatilitas (*heteroskedastisitas*). secara paralel, penelitian ini juga mengimplementasikan model LSTM (*Long Short-Term Memory*) untuk mengevaluasi kemampuan kecerdasan buatan dalam memprediksi data non-linear.
- f. Evaluasi dan Perbandingan: Hasil dari model kemudian diuji tingkat akurasi menggunakan metrik *Mean Absolute Percentage Error* (MAPE dan *Root Mean Square Error* (RMSE). Tahap ini bertujuan untuk membandingkan model mana yang paling presisi.
- g. Forecasting (Peramalan): Tahapan terakhir adalah melakukan proyeksi atau peramalan harga dan volatilitas Bitcoin untuk 30 hari ke depan berdasarkan model terbaik yang telah divalidasi.

**2.2 Sumber Data dan Pra-Pemrosesan**

Data yang digunakan dalam penelitian ini adalah data *historis* harian Bitcoin (BTC/USDT) yang mencakup periode 2018 sampai 2025 yang diperoleh dari platform Kaggle. Sumber nya dapat di akses melalui link tersebut [https://www.kaggle.com/datasets/novandraanugrah/bitcoin-historical-datasets-2018-2024?select= btc\\_1d\\_data\\_2018\\_to\\_2025.csv](https://www.kaggle.com/datasets/novandraanugrah/bitcoin-historical-datasets-2018-2024?select=btc_1d_data_2018_to_2025.csv). Langkah pra-pemrosesan sangat penting karena dataset ini berisi data mentah yang belum difilter. Data harga penutupan diproses terlebih dahulu untuk menghilangkan dampak *outlier* dan *noise* pasar jangka pendek sebelum melanjutkan ke langkah pemodelan ARIMA-GARCH. Atribut dataset yang digunakan dalam analisis ini dijelaskan pada Tabel 1.

**Tabel 1.** Deskripsi Kolom Dataset Bitcoin

Nama Atribut	Deskripsi	Unit
<i>Open Time</i>	Waktu pembukaan perdagangan	UTC
<i>Open</i>	Harga pembukaan Bitcoin pada periode tertentu	USD
<i>High</i>	Harga tertinggi harian	USD
<i>Low</i>	Harga terendah harian	USD
<i>Close</i>	Harga transaksi terakhir (penutupan) yang digunakan sebagai data utama analisis	USD
<i>Volume</i>	Total akumulasi jumlah unit Bitcoin yang berpindah tangan	BTC
<i>Number of trades</i>	Total frekuensi transaksi yang terjadi dalam satu hari	Count

Berdasarkan Tabel 1, untuk menangani *noise* (data acak) dan memastikan stasioneritas pada siklus data yang panjang, dilakukan transformasi harga penutupan menjadi *log-return* dengan persamaan (1):

$$rt = 1n \left( \frac{pt}{pt-1} \right) \tag{1}$$

Tahapan ini meliputi pembersihan data (*missing value*) dan perhitungan *return* Dimana *Rt* adalah *return* pada waktu *t*, *Pt* adalah harga penutupan pada waktu *t*, dan *Pt-1* adalah harga pada hari sebelumnya. Selain itu, digunakan *Simple Moving Average* (SMA) untuk menghaluskan fluktuasi jangka pendek agar komponen siklus panjang lebih mudah teridentifikasi. Penting untuk dicatat bahwa SMA ini hanya digunakan untuk keperluan visualisasi tren dan tidak mengubah nilai data asli yang digunakan dalam perhitungan *log-return* pada model ARIMA-GARCH.

Untuk kebutuhan pemodelan dengan Deep Learning LSTM, data harga penutupan (Close) juga melalui tahap normalisasi menggunakan *Min-Max Scaler*. Hal ini dilakukan karena algoritma jaringan saraf tiruan sangat sensitive Data ditransormasikan ke dalam rentang 0 hingga 1 menggunakan persamaan (2):

$$X_{norm} = \frac{(x - x_{min})}{(x_{max} - x_{min})} \tag{2}$$

Di mana *x* adalah nilai actual, *x<sub>{min}</sub>* alah nilai minimum dalam dataset, dan *x<sub>{max}</sub>* alah nilai maksimum dalam dataset. Tahap ini memastikan proses *training* model LTSM berjalan lebih stabil dan cepat mencapai konvergensi.

**2.3 Pemodelan ARIMA-GARCH**

Penelitian ini menggunakan pendekatan dua tahap. Tahap awal dimulai dengan uji stasioneritas menggunakan *Augmented Dickey-Fuller* (ADF). Langkahnya identifikasi model ARIMA (p, d, q), uji residual, memodelkan varians menggunakan GARCH(1,1) dan hasil akhir Prediksi volatilitas. Hasil pengujian pada data *log-return* menunjukkan nilai ADF Statistic sebesar -26,2647, jauh lebih kecil dari nilai kritis 5% (-2,86) dengan *p-value* 0,0000, sehingga data dinyatakan stasioner. Tahap selanjutnya adalah pemodelan ARIMA (p, d, q) untuk menangkap tren rata-rata harga.

Penentuan parameter optimal ARIMA(1,1,1) didasarkan pada nilai *Akaike Information Criterion* (AIC) terkecil dibandingkan model alternatif lainnya. Persamaan umum ARIMA dinyatakan dalam rumus (3):

$$\Delta Y_t = c + \phi_1 \Delta Y_{t-1} + \epsilon_t + \theta_1 \epsilon_{t-1} \quad (3)$$

Dimana  $Y_t'$  adalah nilai data setelah *differencing*,  $\phi_i$  adalah parameter AR, dan  $\theta_j$  adalah parameter MA. Tahap kedua adalah penerapan model GARCH (1, 1) untuk memodelkan volatilitas yang terkelompok. Persamaan varians kondisional GARCH dinyatakan dalam rumus (4):

$$\sigma_t^2 = \omega + \alpha \epsilon_{t-1}^2 + \beta \sigma_{t-1}^2 \quad (4)$$

Dimana  $\sigma_t^2$  adalah varians kondisional,  $\omega$  adalah konstanta,  $\alpha$  adalah koefisien ARCH (reaksi terhadap guncangan pasar), dan  $\beta$  adalah koefisien GARCH (persistensi volatilitas).

#### 2.4 Pemodelan Long Short-Term Memory (LSTM)

Selain menggunakan pendekatan statistik konvensional, penelitian ini mengimplementasikan model *Deep Learning* dengan arsitektur *Long Short-Term Memory* (LSTM). LSTM dipilih karena kemampuannya dalam mengatasi masalah *vanishing gradient* dan mampu menangkap ketergantungan jangka panjang (*long-term dependencies*) pada data deret waktu yang bersifat non-linear seperti Bitcoin. Struktur dasar LSTM terdiri dari *forget gate*, *input gate*, dan *output gate* yang mengatur aliran informasi pada *cell state*. Prosedur pemodelan LSTM dilakukan melalui tahapan sebagai berikut:

- Normalisasi Data (*Min-Max Scaling*) : Mengubah skala data ke rentang 0 hingga 1 untuk mempercepat proses konvergensi model.
- Membentuk Data Sequence (*Window Time Series*) : Mentransformasi data menjadi urutan waktu untuk memberikan konteks temporal pada model.
- Membangun Arsitektur LSTM : Membangun struktur jaringan saraf yang terdiri dari *input layer*, *hidden layer*, dan *output layer*.
- Training Model : Proses pembelajaran model menggunakan data historis untuk meminimalkan nilai kerugian (*loss*).
- Prediksi Volatilitas : Menggunakan model yang telah dilatih untuk meramalkan nilai volatilitas pada data pengujian.

Dalam penelitian ini, model LSTM dikonfigurasi menggunakan data *windowing* sebanyak 60 hari ke belakang untuk memprediksi harga pada hari berikutnya. Pemilihan 60 hari bertujuan agar model memiliki memori jangka pendek selama dua bulan perdagangan untuk menangkap pola siklus harian. Arsitektur model terdiri dari dua lapisan LSTM dengan masing-masing 50 unit, disertai dengan lapisan *Dropout* sebesar 0,2 untuk mencegah terjadinya *overfitting*. Konfigurasi dua lapisan ini dipilih melalui proses *tuning* untuk menyeimbangkan kompleksitas model dengan stabilitas konvergensi pada data Bitcoin yang sangat volatil. Proses optimasi model menggunakan algoritma Adam dengan fungsi kerugian *Mean Squared Error* (MSE).

#### 2.5 Metrik Evaluasi Performa

Untuk mengukur akurasi dan membandingkan performa antara model ARIMA-GARCH dan LSTM, digunakan beberapa metrik evaluasi statistik, antara lain:

- Root Mean Square Error* (RMSE): Menghitung akar kuadrat dari rata-rata selisih kuadrat antara nilai prediksi dan nilai aktual. RMSE sangat sensitif terhadap kesalahan (*error*) yang besar, sehingga metrik ini sangat cocok digunakan untuk mengevaluasi data yang sangat volatil seperti Bitcoin, nilai RMSE dihitung menggunakan persamaan (5)

$$RMSE = \sqrt{\frac{1}{n} \sum (y_{aktual} - y_{prediksi})^2} \quad (5)$$

- Mean Absolute Error* (MAE): Menghitung rata-rata selisih absolut antara nilai prediksi dan nilai aktual. Semakin kecil nilai MAE, maka performa model dianggap semakin baik dalam merepresentasikan data secara keseluruhan, nilai MAE dihitung menggunakan persamaan (6):

$$MAE = \frac{1}{n} \sum |y_{aktual} - y_{prediksi}| \quad (6)$$

- Mean Absolute Percentage Error* (MAPE): Menghitung persentase rata-rata kesalahan prediksi terhadap nilai aktual. Metrik ini memberikan gambaran akurasi dalam bentuk persentase sehingga lebih mudah diinterpretasikan, nilai MAPE dihitung menggunakan persamaan (7):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left[ \frac{|y_t - \hat{y}_t|}{y_t} \right] \times 100\% \quad (7)$$

Di mana  $y_t$  adalah harga aktual,  $\hat{y}_t$  adalah harga prediksi, dan  $n$  adalah jumlah *observasi*. Model dengan nilai MAPE terkecil menunjukkan tingkat akurasi yang paling tinggi.

## 2.6 Evaluasi Model

Hasil prediksi model ARIMA-GARCH dan model LSTM dibandingkan dengan data asli dari *dataset* Bitcoin untuk tahun 2018–2025 untuk menilai akurasi kedua metode tersebut. Prosedur penilaian ini penting untuk mengetahui seberapa baik masing-masing model menangkap pola pergerakan harga yang sangat fluktuatif, baik dari sisi statistik linier maupun pendekatan *Deep Learning*. Studi ini menggunakan tiga kriteria evaluasi utama, yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) untuk memberikan penilaian akurasi yang menyeluruh baik dari sisi linear, variasi kesalahan, maupun persentase presisi. Akurasi peramalan dinyatakan dalam persentase menggunakan MAPE untuk memudahkan interpretasi, di mana nilai di bawah 10% dikategorikan sebagai peramalan yang sangat akurat sesuai dengan kriteria kemampuan peramalan. Selanjutnya, besarnya perbedaan rata-rata antara data aktual dan hasil proyeksi diukur menggunakan MAE untuk melihat kesalahan linear, serta RMSE untuk memberikan bobot lebih besar pada kesalahan yang signifikan akibat fluktuasi ekstrem. Dengan menggabungkan ketiga metrik ini, penelitian dapat memberikan penilaian yang objektif mengenai model mana yang memiliki tingkat presisi paling tinggi. Model dengan nilai *error* terkecil pada ketiga metrik tersebut ditetapkan sebagai model terbaik dalam memproyeksikan harga dan volatilitas Bitcoin.

## 3. HASIL DAN PEMBAHASAN


### 3.1 Analisis Komponen Time Series dan Tren

Berdasarkan hasil dekomposisi data Bitcoin periode 2018-2025 menunjukkan adanya komponen tren yang dominan serta fluktuasi musiman tahunan. Unsur *noise* atau *residual* terlihat sangat acak, yang mengonfirmasi adanya volatilitas tinggi pada aset kripto. Dapat dilihat pada Gambar 2.



**Gambar 2.** Hasil Dekomposisi Time Series Bitcoin

Berdasarkan grafik dekomposisi pada Gambar 2. Terlihat bahwa komponen *trend* mengalami kenaikan eksponensial terutama pada periode akhir 2020 hingga awal 2024. Pola musiman (*seasonal*) menunjukkan adanya siklus yang berulang namun dengan intensitas yang berbeda, yang mencerminkan pola adopsi pasar global. Sementara itu, komponen residu menunjukkan lonjakan tajam pada beberapa titik, yang mengindikasikan peristiwa *black swan* atau berita fundamental makroekonomi yang menyebabkan anomali harga di luar pola teknis normal. Selanjutnya, dilakukan pembersihan *noise* menggunakan *Simple Moving Average* (SMA). Penggunaan SMA 200 menunjukkan arah tren jangka Panjang yang lebih halus, sementara SMA 50 menangkap pergerakan jangka pendek. Hal ini mengidentifikasi siklus bullish dan bearish Bitcoin beberapa tahun terakhir dapat dilihat pada Gambar 3.



**Gambar 3.** Pergerakan Rata-rata (SMA 50 dan SMA 200)

Berdasarkan Gambar 3, visualisasi menggunakan SMA 200 dan SMA 50 memberikan konfirmasi teknis mengenai momentum pasar. Penyilangan (*crossover*) antara kedua garis rata-rata tersebut sering kali menjadi indikator awal perubahan tren besar. SMA 200 yang cenderung landai menunjukkan bahwa meskipun terjadi koreksi harga harian yang tajam, fundamental tren jangka panjang Bitcoin dalam tujuh tahun terakhir tetap berada dalam koridor pertumbuhan positif.

### 3.2 Implementasi Model ARIMA dan GARCH

Bagian ini menyajikan hasil teknis dari pemodelan *time series* untuk menangkap tren rata-rata harga dan dinamika volatilitas Bitcoin.

#### 3.2.1 Hasil Uji Stasioneritas dan Log-Return

Sebelum pemodelan, data harga penutupan (*Closing price*) diubah menjadi log-return untuk menstabilkan varians dan menghilangkan tren non-stasioner. Berdasarkan pengujian statistic menggunakan metode *Augmented Dickey-Fuller* (ADF) yang dilakukan pada Google Colab, diperoleh nilai ADF Statistic sebesar -26,2647. Nilai statistik tersebut jauh lebih kecil dibandingkan nilai kritis pada tingkat signifikansi 1% (-3,43), 5% (-2,86), dan 10% (-2,57). Dengan P-value sebesar 0,0000 ( $p < 0,05$ ). Karena nilai tersebut jauh di bawah ambang batas 0,05, maka hipotesis nol yang menyatakan adanya *unit root* ditolak. Dengan demikian, dataset dinyatakan valid dan layak untuk diproses lebih lanjut menggunakan integrasi model ARIMA-GARCH.

#### 3.2.2 Estimasi Parameter Model

Model ARIMA (1,1,1) dipilih untuk memodelkan rata-rata harga, sedangkan model GARCH (1,1) digunakan untuk menangkap fenomena *heteroskedastisitas* pada data Bitcoin. Tabel 2 merangkum parameter signifikan dari hasil eksekusi program.

**Tabel 2.** Ringkasan Parameter Model ARIMA-GARCH

Parameter	Coefficient	Std Error	P> z
ar.L1 (ARIMA)	0,1254	0,287	0,662
ma.L1 (ARIMA)	-0,1683	0,284	0,553
alpha[1] (GARCH)	0,0939	0,0508	0,060
beta[1] (GARCH)	0,8704	0,0494	0,000


Berdasarkan hasil estimasi pada Tabel 2, model ARIMA(1,1,1) menunjukkan koefisien AR(1) sebesar 0,1254 dan MA(1) sebesar -0,1683. Meskipun nilai *p-value* pada komponen ini berada di atas ambang batas signifikansi 0,05, model ini tetap dipertahankan sebagai filter rata-rata (*mean equation*) sebelum melanjutkan ke pemodelan GARCH. Hal ini mengindikasikan bahwa pergerakan harga Bitcoin memiliki sifat *random walk* yang kuat, di mana pola masa lalu tidak secara signifikan menentukan harga masa depan dalam kerangka linier. Ketidaksignifikanan komponen ARIMA ini justru memperkuat argumen penelitian bahwa pendekatan statistik linier murni tidak cukup untuk menangkap dinamika Bitcoin, sehingga diperlukan model GARCH untuk menganalisis residu.

### 3.3 Analisis Volatilitas dan Peramalan

Bagian ini menyajikan interpretasi terhadap dinamika risiko pasar dan proyeksi harga Bitcoin berdasarkan model yang telah terestimasi.

#### 3.3.1 Proyeksi Harga 30 Hari ke Depan


Model ARIMA(1,1,1) memproyeksikan bahwa harga Bitcoin kemungkinan akan bergerak dalam fase konsolidasi atau mendatar selama 30 hari pertama tahun 2026, dengan perkiraan biaya rata-rata sekitar USD 65.000 (Gambar 4). Area berwarna merah muda pada grafik merepresentasikan interval kepercayaan, yang menunjukkan tingkat ketidakpastian yang realistis dengan batas atas dan bawah yang wajar. Hal ini mengindikasikan bahwa fluktuasi harga masih mungkin terjadi dalam koridor teknis yang terukur, meskipun garis perkiraan menunjukkan kecenderungan stabilitas. Yang dapat dilihat pada Gambar 4.



**Gambar 4.** Peramalan Harga Bitcoin 30 Hari ke Depan

### 3.3.2 Dinamika Volatilitas (Volatility Clustering).

Estimasi tingkat volatilitas kondisional Bitcoin yang dihasilkan oleh model GARCH(1,1) menunjukkan pola *volatility clustering* yang jelas yang divisualisasikan pada Gambar 5.

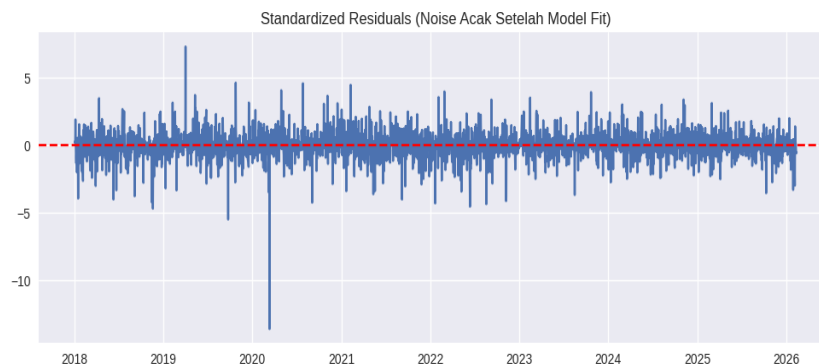


Gambar 5. Estimasi Volatilitas GARCH(1,1)

Berdasarkan Gambar 5, periode perubahan harga yang signifikan sering diikuti oleh fluktuasi signifikan serupa dalam jangka waktu tertentu. Lonjakan dramatis yang terlihat antara tahun 2018 dan 2025 merefleksikan reaksi pasar terhadap perkembangan fundamental atau guncangan eksternal. Model GARCH berhasil menangkap pola berulang ini, yang sangat berguna untuk manajemen risiko investasi.

### 3.4 Diagnostik Residual (Noise Data Acak)

Berdasarkan hasil dari uji diagnostic pada residu (*noise*) yang divisualisasi pada Gambar 6. Terlihat bahwa Residual model telah terdistribusi secara acak di sekitar garis nol dan menunjukkan karakteristik *white noise* seperti yang terlihat pada Gambar 6.



Gambar 6. Plot Standardized Residuals Model

Berdasarkan Gambar 6, kejadian ini menunjukkan bahwa informasi fundamental dan pola yang bergantung pada data dari nilai historis Bitcoin selama periode 2018–2025 telah berhasil ditangkap sepenuhnya oleh model ARIMA(1,1,1) dan GARCH(1,1), sehingga hanya menyisakan komponen acak yang tidak dapat diprediksi. Validitas model ini diperkuat secara statistik melalui uji *Ljung-Box* yang menghasilkan nilai Prob(Q) sebesar 0,94. Karena nilai tersebut jauh di atas ambang batas signifikansi 0,05, maka hipotesis nol diterima, yang berarti tidak terdapat masalah autokorelasi pada residual model. Secara visual, tidak ditemukan adanya *outlier* yang persisten, dan sebagian besar data residual berada dalam rentang deviasi standar yang wajar. Hal ini membuktikan bahwa model GARCH telah secara efektif mengatasi efek *heteroskedastisitas* (perubahan varians) yang sebelumnya ada pada data mentah. Dengan terpenuhinya asumsi diagnostik ini, model dianggap sah (*valid*) dan reliabel untuk digunakan dalam pengambilan keputusan investasi serta penilaian risiko di pasar mata uang kripto.

### 3.5 Evaluasi Akurasi Prediksi dan Pembahasan

Tahap akhir dari hasil penelitian ini adalah mengevaluasi tingkat akurasi model yang telah dibangun. Berdasarkan hasil pengujian pada dataset Bitcoin (2018–2025) performa model dirangkum dalam Tabel 3 berikut:

Tabel 3. Hasil Evaluasi akurasi Model

Metrik Evaluasi	Nilai Hasil	Keterangan
Mean Absolute Percentage Error (MAPE)	18,11%	Good Forecasting
Root Mean Square Error (RMSE)	18.793,66	Deviasi dalam USD
Mean Absolute Error (MAE)	1679,59	Rata-rata selisih dalam USD

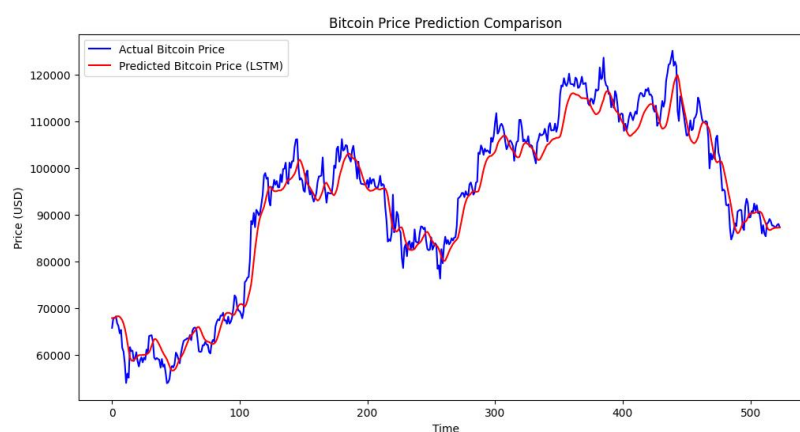
Berdasarkan Tabel 3, diperoleh nilai Mean Absolute Percentage Error (MAPE) sebesar **18.11%**. Meskipun nilai MAPE berada di atas 10%, hasil ini tetap dikategorikan sebagai peramalan yang baik (*good forecasting*) berdasarkan kriteria Lewis (1982) [17], [18], Kategori ini cukup memuaskan mengingat karakteristik volatilitas ekstrem Bitcoin. Nilai RMSE sebesar 18.793,66 mencerminkan rata-rata deviasi harga prediksi terhadap harga aktual dalam satuan USD. Meskipun model ini efektif menangkap pola tren dan struktur volatilitas, pengaruh eksternal yang tidak terduga tetap menjadi tantangan untuk mencapai akurasi sempurna.

### 3.5.1 Pembahasan Hasil dan Perbandingan

Berdasarkan hasil yang diperoleh, terlihat bahwa integrasi model GARCH(1,1) sangat krusial dalam menangkap fenomena *volatility clustering*. Hal ini sejalan dengan temuan pada penelitian terdahulu oleh S.Aras [19] Penelitian mereka mengungkapkan bahwa model deret waktu sangat berguna untuk prediksi harga jangka pendek, meskipun model peramalan harga Bitcoin memerlukan penanganan khusus terhadap data non-stasioner. Namun, rentang data yang digunakan sangat berpengaruh. Studi ini menawarkan kontribusi yang lebih komprehensif dibandingkan studi sebelumnya karena mencakup data historis dari tahun 2018 hingga 2025, sedangkan dengan penelitian terdahulu yang menggunakan periode data lebih terbatas. Sebagaimana dibuktikan oleh nilai MAPE sebesar 18,11%, penggunaan kumpulan data yang diperluas ini memungkinkan model ARIMA-GARCH untuk menangkap siklus pasar-termasuk fase *bullish*, *bearish*, hingga *konsolidasi atau sideways* yang lebih rumit. Hasil ini menegaskan bahwa meskipun Bitcoin memiliki volatilitas yang ekstrem, pendekatan statistik tetap mampu menghasilkan perkiraan reliabel asalkan menggunakan data yang memadai untuk menangkap memori jangka panjang pasar. Meskipun model ARIMA-GARCH memberikan hasil yang cukup memuaskan untuk analisis struktur risiko, perbandingan dengan metode LSTM menunjukkan perbedaan performa yang signifikan dalam hal akurasi prediksi harga. Model LSTM mampu menghasilkan nilai MAPE yang jauh lebih rendah dibandingkan ARIMA-GARCH. Hal ini membuktikan bahwa pendekatan *Deep Learning* lebih adaptif dalam menangkap pola non-linear dan dinamika harga Bitcoin yang kompleks dibandingkan model statistik konvensional. Perbedaan performa yang terukur ini menegaskan bahwa sementara ARIMA-GARCH unggul dalam menjelaskan persistensi volatilitas melalui parameter statistiknya, LSTM menjadi pilihan yang lebih superior untuk kebutuhan peramalan harga yang lebih presisi pada periode data 2018-2025.

### 3.6 Perbandingan dengan Metode Long Short-Term Memory (LSTM)

Model *Long Short-Term Memory* (LSTM) merupakan arsitektur khusus dari *Recurrent Neural Network* (RNN) yang diperkenalkan oleh Hochreiter dan Schmidhuber [20] untuk mengatasi masalah *vanishing gradient* pada data deret waktu yang panjang. Selain menggunakan model statistik, penelitian ini mengimplementasikan model tersebut untuk menangkap pola harga yang bersifat non-linear. Sebagai bentuk validasi dan perbandingan terhadap model statistik konvensional, penelitian ini juga mengimplementasikan model *Deep Learning* berbasis *Long Short-Term Memory* (LSTM) yang dijalankan melalui *platform* Google Colab. Berbeda dengan ARIMA-GARCH yang fokus pada struktur volatilitas, LSTM dirancang untuk menangkap pola non-linear pada harga penutupan Bitcoin. Hasil pengujian menunjukkan bahwa model LSTM mampu mengikuti pergerakan harga aktual dengan sangat presisi. Visualisasi perbandingan antara harga aktual dan harga prediksi menggunakan LSTM dapat dilihat pada Gambar 7.



Gambar 7. Hasil Evaluasi Model LSTM

Berdasarkan Gambar 7, garis prediksi pada model LSTM terlihat berhimpitan dengan harga riil, menunjukkan tingkat kesalahan yang sangat minimal.

### 3.7 Analisis Komparatif Performa Model

Untuk menyimpulkan hasil penelitian ini, dilakukan perbandingan metrik evaluasi antara model ARIMA-GARCH dan LSTM. Perbandingan ini bertujuan untuk menjawab metode mana yang paling efisien dalam melakukan peramalan harga aset kripto. Perbandingan performa model dapat dilihat pada Tabel 4.

**Tabel 4.** Perbandingan Metrik Evaluasi Akhir

Metrik Evaluasi	Model ARIMA-GARCH	Model LSTM (Deep Learning)
MAPE (%)	18,11%	3,09 %
RMSE	18.793,66	3.686,26
MAE	13.452,18	2.850,62

Berdasarkan Tabel 4. Terlihat adanya perbedaan akurasi yang sangat signifikan antara pendekatan statistik konvensional dengan pendekatan kecerdasan buatan. Model LSTM menghasilkan nilai MAPE sebesar 3,09%, yang menurut kriteria Lewis (1982) dikategorikan sebagai peramalan yang Sangat Akurat (*Highly Accurate*). Di sisi lain, model ARIMA-GARCH menghasilkan MAPE sebesar 18,11%, yang meskipun masih masuk dalam kategori peramalan yang "Baik", namun memiliki margin kesalahan yang jauh lebih lebar. Perbedaan performa ini disebabkan oleh karakteristik dasar masing-masing model. ARIMA-GARCH sangat bergantung pada asumsi linearitas dan stasioneritas data, sehingga cenderung mengalami kendala saat memprediksi titik harga (*point price*) pada aset yang memiliki volatilitas ekstrem seperti Bitcoin. Sebaliknya, arsitektur LSTM memiliki keunggulan berupa *memory gates* yang mampu menyimpan informasi pola jangka panjang dan memproses hubungan non-linear antar data tanpa perlu mematuhi asumsi statistik yang kaku. Hal ini membuat LSTM jauh lebih adaptif dalam memitigasi *noise* pasar dan memberikan proyeksi harga yang lebih mendekati nilai aktual. Kemampuan LSTM dalam mengungguli model statistik konvensional dalam memprediksi harga Bitcoin ini sejalan dengan penelitian yang dilakukan oleh Kim et al [21], yang menunjukkan bahwa arsitektur jaringan saraf lebih mampu menangkap ketidakpastian pasar kripto.

#### 4. KESIMPULAN

Berdasarkan hasil analisis, implementasi, dan pengujian yang telah dilakukan terhadap data harga Bitcoin periode 2018 hingga 2025, dapat ditarik beberapa kesimpulan utama. Pertama, penggunaan model integrasi ARIMA(1,1,1)-GARCH(1,1) terbukti efektif dalam menangkap karakteristik statistik aset kripto, khususnya dalam memetakan fenomena *volatility clustering*. Hasil estimasi parameter GARCH menunjukkan nilai *beta* yang sangat signifikan sebesar 0,8704, yang mengindikasikan bahwa volatilitas pada pasar Bitcoin bersifat persisten atau tahan lama dalam jangka panjang. Hal ini memberikan kontribusi penting bagi manajemen risiko investasi, di mana model mampu memberikan gambaran terukur mengenai dinamika risiko pasar meskipun Bitcoin memiliki fluktuasi yang ekstrem. Kedua, dari sisi akurasi peramalan harga, terdapat perbedaan performa yang sangat kontras antara metode statistik konvensional dengan pendekatan kecerdasan buatan. Model ARIMA-GARCH menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 18,11%, yang dikategorikan sebagai peramalan yang baik namun masih memiliki margin kesalahan yang cukup lebar saat menghadapi guncangan pasar (*market shocks*). Sebaliknya, implementasi model *Long Short-Term Memory* (LSTM) melalui *platform* Google Colab menunjukkan hasil yang jauh lebih presisi dengan perolehan nilai MAPE sebesar 3,09%. Pencapaian ini menempatkan model LSTM ke dalam kategori peramalan yang sangat akurat (*highly accurate*), membuktikan bahwa arsitektur jaringan saraf tiruan lebih adaptif dalam memproses data *time series* yang bersifat non-linear dan kompleks dibandingkan model linier tradisional. Secara keseluruhan, penelitian ini menegaskan bahwa untuk tujuan prediksi titik harga penutupan (*point forecasting*), pendekatan *Deep Learning* seperti LSTM menawarkan solusi yang lebih andal bagi para pelaku pasar. Namun, model ARIMA-GARCH tetap memegang peranan krusial sebagai instrumen analisis risiko melalui estimasi varians kondisional. Sebagai saran untuk pengembangan selanjutnya, penelitian dapat dikembangkan dengan mengintegrasikan variabel eksternal seperti indeks sentimen pasar global atau data makroekonomi guna meningkatkan ketajaman prediksi pada situasi anomali pasar yang tidak terduga.

#### REFERENCES

- [1] S. Nakamoto, "Bitcoin: A Peer-to-Peer Electronic Cash System," 2008. [Online]. Available: <https://bitcoin.org/bitcoin.pdf>. Accessed: May 12, 2026
- [2] D. G. Baur and T. Dimpfl, "The Volatility of Bitcoin and Its Role as a Medium of Exchange and a Store of Value," *Empir. Econ.*, vol. 61, no. 5, pp. 2663–2683, Nov. 2021, doi: 10.1007/s00181-020-01990-5.
- [3] S. Tanwar, N. P. Patel, S. N. Patel, J. R. Patel, G. Sharma, and I. E. Davidson, "Deep Learning-Based Cryptocurrency Price Prediction Scheme with Inter-Dependent Relations," *IEEE Access*, vol. 9, pp. 138633–138646, 2021, doi: 10.1109/ACCESS.2021.3117848.
- [4] Z. Shen, Q. Wang, and L. D. Shen, "Bitcoin Return Volatility Forecasting: A Comparative Study Between GARCH and RNN," *Journal of Risk and Financial Management*, vol. 14, no. 8, p. 337, 2021, doi: 10.3390/jrfm14080337.
- [5] M. Zahid, F. Iqbal, and D. Koutmos, "Forecasting Bitcoin Volatility Using Hybrid GARCH Models with Machine Learning," *Risks*, vol. 10, no. 12, p. 237, 2022, doi: 10.3390/risks10120237.
- [6] T. E. Pratas, F. R. Ramos, and L. Rubio, "Forecasting Bitcoin Volatility: Exploring the Potential of Deep Learning," *Eurasian Economic Review*, vol. 13, no. 2, pp. 285–305, Jun. 2023, doi: 10.1007/s40822-023-00232-0.
- [7] D. C. A. Mallqui and R. A. S. Fernandes, "Predicting the Direction, Maximum, Minimum and Closing Prices of Daily Bitcoin Exchange Rate Using Machine Learning Techniques," *Appl. Soft Comput.*, vol. 75, pp. 596–606, Feb. 2019, doi: 10.1016/j.asoc.2018.11.038.



- [8] T. K. Lian, I. A. A. Q. Al-Hadi, M. A. Alomari, M. N. Al-Andoli, M. B. Jasser, and A. G. S. A. Gaid, "A Comparative Study of Deep Learning Models for Bitcoin Price Prediction Using NeuralProphet, RNN, and LSTM," *Engineering, Technology and Applied Science Research*, vol. 16, no. 1, pp. 31263–31273, 2026, doi: 10.48084/etasr.11590.
- [9] W.-L. Zhao, Y. Fan, and Q. Ji, "Extreme Risk Spillover Between Crude Oil Price and Financial Factors," *Financ. Res. Lett.*, vol. 46, p. 102317, 2022, doi: 10.1016/j.frl.2021.102317.
- [10] R. F. Engle, "Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of United Kingdom Inflation," *Econometrica*, vol. 50, no. 4, pp. 987–1007, 1982, doi: 10.2307/1912773.
- [11] T. Bollerslev, "Generalized Autoregressive Conditional Heteroskedasticity," *J. Econom.*, vol. 31, no. 3, pp. 307–327, 1986, doi: 10.1016/0304-4076(86)90063-1.
- [12] N. Tripathy *et al.*, "Bitcoin Volatility Forecasting: A Comparative Analysis of Conventional Econometric Models with Deep Learning Models," *International Journal of Electrical and Computer Engineering*, vol. 15, no. 1, pp. 614–623, Feb. 2025, doi: 10.11591/ijece.v15i1.pp614-623.
- [13] Y. Peng, P. H. M. Albuquerque, J. M. Camboim de Sá, A. J. A. Padula, and M. R. Montenegro, "The Best of Two Worlds: Forecasting High Frequency Volatility for Cryptocurrencies and Traditional Currencies with Support Vector Regression," *Expert Syst. Appl.*, vol. 97, pp. 177–192, 2018, doi: 10.1016/j.eswa.2017.12.004.
- [14] S. Corbet, Y. (Greg) Hou, Y. Hu, C. Larkin, and L. Oxley, "Any Port in a Storm: Cryptocurrency Safe-Havens During the COVID-19 Pandemic," *Econ. Lett.*, vol. 194, no. 9, p. 109377, Sep. 2020, doi: 10.1016/j.econlet.2020.109377.
- [15] Y. Sun, X. Tang, and Y. Jiang, "Bitcoin Volatility Forecasting Based on Time Series Decomposition and Deep Learning Model," in *Frontiers in Artificial Intelligence and Applications*, IOS Press BV, Mar. 2025, pp. 194–201, doi: 10.3233/FAIA250121.
- [16] 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, p. 102064, Dec. 2024, doi: 10.1016/j.intfin.2024.102064.
- [17] H. Alizadegan, A. Radmehr, and M. A. Ilani, "Forecasting Bitcoin Prices: A Comparative Study of Machine Learning and Deep Learning Algorithms," Research Square, preprint, May 2024, doi: 10.21203/rs.3.rs-4390390/v1.
- [18] C. D. Lewis, *Industrial and Business Forecasting Methods*. London: Butterworths, 1982.
- [19] S. Aras, "On Improving GARCH Volatility Forecasts for Bitcoin via a Meta-Learning Approach," *Knowl. Based. Syst.*, vol. 230, p. 107393, Oct. 2021, doi: 10.1016/j.knosys.2021.107393.
- [20] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [21] G. Kim, D. H. Shin, J. G. Choi, and S. Lim, "A Deep Learning-Based Cryptocurrency Price Prediction Model That Uses On-Chain Data," *IEEE Access*, vol. 10, pp. 56232–56248, May 2022, doi: 10.1109/ACCESS.2022.3177888.