

# Analisis Prediktif Harga Penutupan Harian Bitcoin Menggunakan Arsitektur Jaringan Saraf Tiruan Long Short-Term Memory

Suyanti\*, Chandy Ophelia S, Lies Aryani

Fakultas Ilmu Komputer, Program Studi Sistem Informasi, Universitas Dinamika Bangsa, Jambi

Jl. Jendral Sudirman, The Hok, Kec. Jambi Selatan, Kota Jambi, Jambi, Indonesia

Email: <sup>1</sup>\*Suyanti272@gmail.com, <sup>2</sup>Chandyophelia94@gmail.com, <sup>3</sup>Liesaryani6@gmail.com

Email Penulis Korespondensi: Suyanti272@gmail.com

Submitted: 02/06/2025; Accepted: 21/10/2025; Published: 22/10/2025

**Abstrak**—Harga Bitcoin yang sangat fluktuatif menjadi tantangan utama bagi para pelaku pasar keuangan, menciptakan ketidakpastian dan risiko investasi yang tinggi. Sifat data harga Bitcoin yang non-linear dan kompleks menyulitkan metode prediksi tradisional untuk menghasilkan akurasi yang andal, sehingga dibutuhkan pendekatan canggih untuk memodelkan pola pergerakan harga secara efektif. Penelitian ini menjawab tantangan tersebut dengan membangun model prediksi harga penutupan harian Bitcoin menggunakan jaringan saraf Long Short-Term Memory (LSTM). Data harga Bitcoin periode 1 Januari 2014 hingga 9 Mei 2025 diambil dari Yahoo Finance, dinormalisasi dengan MinMaxScaler, dan dibagi menjadi 80% data pelatihan serta 20% data pengujian. Model LSTM, yang terdiri dari dua lapisan LSTM (masing-masing 50 unit) dan dua lapisan dense, dilatih dengan optimasi Adam dan fungsi kerugian mean squared error. Model menggunakan urutan harga 60 hari untuk memprediksi harga hari berikutnya. Hasil evaluasi menunjukkan akurasi tinggi dengan Root Mean Squared Error (RMSE) 105,80, Mean Squared Error (MSE) 2.822.880,74, Mean Absolute Error (MAE) 1.103,42, dan R-squared ( $R^2$ ) 0,995. Model ini menjadi salah satu alat prediksi yang andal untuk keputusan keuangan dengan menggunakan data historis. Penelitian ini memperkaya solusi prediksi harga bitcoin berbasis machine learning.

**Kata Kunci:** Bitcoin; Prediksi Harga; Deret Waktu; LSTM; Jaringan Saraf Tiruan; Deep Learning.

**Abstract**—The highly volatile price of Bitcoin makes it difficult for financial market players. This research aims to build a Bitcoin daily closing price prediction model using Long Short-Term Memory (LSTM) neural network. Bitcoin price data from January 1, 2014 to May 9, 2025 was taken from Yahoo Finance, normalized with MinMaxScaler, and divided into 80% training data and 20% testing data. The LSTM model, which consists of two LSTM layers (50 units each) and two dense layers, was trained with Adam optimization and mean squared error loss function. The model uses the 60-day price sequence to predict the next day's price. The evaluation results show high accuracy with Root Mean Squared Error (RMSE) 105.80, Mean Squared Error (MSE) 2,822,880.74, Mean Absolute Error (MAE) 1,103.42, and R-squared ( $R^2$ ) 0.995. This model becomes one of the reliable prediction tools for financial decisions using historical data. This research enriches machine learning-based bitcoin price prediction solutions.

**Keywords:** Bitcoin; Price Prediction; Time Series; LSTM; Neural Network; Deep Learning.

## 1. PENDAHULUAN

Bitcoin, sebagai kriptokurensi terdesentralisasi yang pertama kali diperkenalkan pada tahun 2008, telah mengubah lanskap keuangan global dengan potensi keuntungan besar namun juga volatilitas harga yang tinggi [1], [2]. Fluktuasi harga Bitcoin yang signifikan, dipengaruhi oleh sentimen pasar, regulasi, dan inovasi teknologi, menjadikan prediksi harga sebagai tantangan utama bagi investor dan pedagang [3], [4]. Prediksi harga yang akurat sangat penting untuk mendukung strategi investasi, manajemen risiko, dan analisis pasar dalam pasar kriptokurensi yang dinamis [5], [6]. Oleh karena itu, pengembangan metode prediksi yang mampu menangani sifat kompleks data harga Bitcoin menjadi kebutuhan mendesak untuk mendukung pengambilan keputusan keuangan [7].

Masalah utama dalam prediksi harga Bitcoin adalah sifat datanya yang non-linear dan memiliki ketergantungan jangka panjang, yang sulit ditangani oleh metode statistik tradisional seperti ARIMA [7], [8]. Pendekatan machine learning dan deep learning, khususnya Long Short-Term Memory (LSTM), telah menunjukkan potensi untuk mengatasi tantangan ini karena kemampuannya dalam memodelkan pola temporal dalam data deret waktu [9], [10]. Namun, banyak penelitian sebelumnya menggunakan dataset yang relatif pendek atau tidak menyediakan evaluasi performa yang komprehensif, sehingga membatasi generalisasi model [2], [11]. Penelitian ini bertujuan untuk mengatasi keterbatasan tersebut dengan mengembangkan model LSTM yang memanfaatkan dataset jangka panjang dan evaluasi yang mendalam untuk prediksi harga Bitcoin.

Penelitian terkait dalam lima tahun terakhir telah mengeksplorasi berbagai pendekatan machine learning dan deep learning untuk prediksi harga Bitcoin. Jaquart et al. meneliti prediksi jangka pendek pasar Bitcoin menggunakan algoritma random forest dan support vector machine, menyoroti pentingnya metode ensemble untuk menangkap dinamika pasar yang cepat [2]. Coco et al. mengevaluasi berbagai kerangka machine learning untuk prediksi harga Bitcoin, menekankan pentingnya pendekatan berbasis data untuk meningkatkan performa. Seabe et al. (2023) membandingkan LSTM, GRU, dan Bi-Directional LSTM untuk prediksi harga kriptokurensi, menemukan bahwa pendekatan dua arah memberikan keunggulan dalam menangkap konteks masa lalu dan masa depan [8]. Kervanci et al. mengeksplorasi optimasi hiperparameter seperti Bayesian optimization dan grid search untuk model LSTM dan GRU, menunjukkan peningkatan akurasi untuk prediksi jangka pendek [11]. Wen dan Ling. mengevaluasi model LSTM dan Convolutional Neural Network (CNN) untuk prediksi harga kriptokurensi, menegaskan bahwa kombinasi arsitektur dapat meningkatkan performa dibandingkan metode tunggal [10]. Cheng et al. mengkombinasikan LSTM, SARIMA, dan Facebook Prophet untuk prediksi harga Bitcoin, menyoroti keunggulan LSTM dalam menangani data non-linear, terutama pada periode



volatilitas tinggi seperti pandemi COVID-19 dan konflik geopolitik, meskipun metode tradisional seperti SARIMA dan Facebook Prophet menunjukkan keterbatasan dalam penyesuaian [12].

Penelitian lokal di Indonesia juga telah berkontribusi pada prediksi harga Bitcoin. Giyanda dan Saidah menggunakan H2O AutoML untuk memprediksi harga Bitcoin, menunjukkan bahwa pendekatan otomatisasi dapat menghasilkan akurasi tinggi dengan efisiensi tinggi, cocok untuk pengguna non-akademik [13]. Nirraca dan Hartati (2023) mengembangkan sistem berbasis web menggunakan LSTM untuk prediksi jangka pendek, mencapai RMSE rendah untuk prediksi 7 hari, yang mendukung aplikasi praktis dalam perdagangan [14]. Feb timestepriansyah (2024) mengevaluasi LSTM dengan data harga Bitcoin dari 2020 hingga 2024, menghasilkan MAPE rendah untuk data pelatihan, menegaskan keunggulan LSTM dalam menangkap pola temporal [14]. Saadah dan Salsabila (2021) menggunakan Random Forest Regression untuk memprediksi harga Bitcoin dengan data acak selama awal pandemi COVID-19, mencapai MAPE 1,50% dan akurasi 98,50%, menunjukkan efektivitas metode ensemble untuk data volatil [15]. Julianto (2023) menggunakan RNN untuk prediksi harga Bitcoin di platform Indodax [16], menyoroti pentingnya data spesifik platform untuk strategi investasi. Maliki et al. menggunakan LSTM untuk memprediksi harga Bitcoin terhadap Rupiah, mencapai MSE 0,00374 dengan parameter seperti hidden\_size 64 dan sequence data 18, menunjukkan efektivitas LSTM dalam konteks mata uang lokal [17].

Pendekatan terbaru menunjukkan inovasi lebih lanjut dalam prediksi harga Bitcoin. Arslan mengkombinasikan analisis sentimen dengan empirical mode decomposition dan LSTM, menunjukkan bahwa dekomposisi deret waktu dapat meningkatkan akurasi prediksi [3]. Raj dan Chattopadhyay memperkenalkan LSTM autoencoder dengan regularisasi false nearest neighbor untuk mengurangi overfitting dan meningkatkan generalisasi model [18]. Koo dan Kim mengusulkan pendekatan dekomposisi terpusat dalam LSTM untuk fokus pada komponen frekuensi yang berbeda dalam data harga Bitcoin [19]. Omole dan Enke membandingkan model deep learning untuk prediksi arah harga Bitcoin, menyoroti keunggulan LSTM dalam menangkap tren pasar [6]. Anitha Rajakumari et al. mengoptimalkan model LSTM dan GRU melalui grid search, menghasilkan prediksi harga yang lebih akurat [9]. Pendekatan hibrid yang menggabungkan arsitektur berbeda juga menunjukkan hasil yang kuat, seperti yang ditunjukkan oleh Abdullah dan Salah yang berhasil menerapkan model CNN-BiLSTM dan CNN-BiLSTM-AM untuk prediksi harga saham, sebuah metodologi yang relevan untuk diadaptasi ke pasar kriptokurensi [20], [21]. Mehrdoust dan Noorani. mengevaluasi model deep learning untuk prediksi harga Bitcoin dan Ethereum, menegaskan efektivitas LSTM dalam konteks kriptokurensi [22]. Belalova et al. mengembangkan model hibrid yang menggabungkan deep learning dengan metode lain, mencapai hasil kompetitif untuk prediksi harga Bitcoin [23]. Khedr et al. menyediakan survei komprehensif tentang teknik prediksi harga kriptokurensi, menyoroti pergeseran dari metode statistik ke deep learning sebagai pendekatan yang lebih robust [7].

Penelitian ini bertujuan untuk mengembangkan model LSTM yang akurat untuk memprediksi harga penutupan harian Bitcoin menggunakan data historis dari 1 Januari 2014 hingga 9 Mei 2025. Tujuannya adalah membangun model yang mampu menangkap ketergantungan temporal, mengevaluasi performa dengan metrik seperti RMSE, MSE, MAE, dan  $R^2$ , serta membandingkan hasil dengan metode terkini [8], [9]. Kepentingan penelitian ini terletak pada kebutuhan akan alat prediksi yang handal untuk mendukung investor dan pedagang dalam mengelola risiko di pasar kriptokurensi yang volatil [5], [6]. Dengan meningkatnya adopsi Bitcoin, model prediksi yang akurat dapat meningkatkan kepercayaan pasar dan efisiensi perdagangan [2], [3].

Solusi yang diusulkan adalah model LSTM dengan dua lapisan LSTM (masing-masing 50 unit) dan dua lapisan dense, dioptimalkan dengan algoritma Adam dan fungsi kerugian MSE [9], [18]. Data akan dinormalisasi menggunakan MinMaxScaler dan dibagi menjadi 80% data pelatihan dan 20% data pengujian, dengan mekanisme early stopping untuk mencegah overfitting [4], [19]. Kontribusi penelitian ini meliputi pengembangan model prediksi yang akurat dengan dataset jangka panjang, evaluasi komprehensif menggunakan empat metrik, dan visualisasi mendalam seperti plot harga dan distribusi residual, yang dapat digunakan untuk strategi perdagangan otomatis dan manajemen risiko [22], [23].

State-of-the-art dalam prediksi harga Bitcoin telah berkembang pesat, dengan fokus pada deep learning untuk meningkatkan akurasi [10], [19]. Namun, banyak penelitian sebelumnya terbatas pada dataset pendek atau evaluasi yang tidak lengkap [2], [11]. Penelitian ini membedakan dirinya dengan dataset 11 tahun dan analisis visual yang mendalam, memberikan wawasan yang lebih komprehensif tentang performa model [3], [9]. Dengan demikian, penelitian ini diharapkan menjadi langkah maju dalam prediksi harga bitcoin, menawarkan solusi praktis dan akademik yang signifikan.

## 2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif berbasis machine learning untuk memprediksi harga penutupan harian Bitcoin dengan jaringan saraf Long Short-Term Memory (LSTM). Pendekatan ini dipilih karena kemampuan LSTM dalam menangkap ketergantungan jangka panjang pada data deret waktu, sebagaimana ditunjukkan dalam penelitian terkait [8], [9]. Bagian ini menjelaskan kerangka dasar penelitian dan tahapan penelitian secara rinci, mencakup pengumpulan data, pemrosesan data, pengembangan model, pelatihan model, serta strategi pengujian dan evaluasi, dengan fokus pada implementasi teknis untuk bidang Engineering.

### 2.1 Kerangka Dasar Penelitian

Penelitian ini bersifat eksperimental dengan fokus pada pengembangan model prediktif untuk harga Bitcoin. Jenis penelitian adalah pemodelan prediktif, bertujuan menghasilkan prediksi harga penutupan harian berdasarkan data historis


[1]. Hipotesis penelitian adalah bahwa model LSTM dapat memprediksi harga Bitcoin secara akurat dengan memanfaatkan urutan harga 60 hari sebagai masukan [4]. Variabel penelitian meliputi:

- a) Variabel Independen: Urutan harga penutupan Bitcoin selama 60 hari yang telah dinormalisasi.
- b) Variabel Dependen: Harga penutupan Bitcoin pada hari berikutnya.

Metode analisis yang digunakan adalah evaluasi performa model dengan metrik Root Mean Squared Error (RMSE), Mean Squared Error (MSE), Mean Absolute Error (MAE), dan R-squared (R<sup>2</sup>), yang merupakan standar dalam prediksi harga kriptokurensi. Data harga Bitcoin diperoleh dari Yahoo Finance untuk periode 1 Januari 2014 hingga 9 Mei 2025, yang kemudian dibagi menjadi 80% data pelatihan dan 20% data pengujian untuk memastikan pembelajaran dan pengujian yang robust. Kerangka ini didasarkan pada sifat non-linear data harga Bitcoin, yang dapat dimodelkan secara efektif menggunakan LSTM.

## 2.2 Tahapan Penelitian

Penelitian ini dilakukan melalui lima tahapan utama untuk memastikan pengembangan model yang sistematis dan terukur. Proses ini dirangkum dalam alur kerja yang menggambarkan langkah-langkah dari pengumpulan data hingga evaluasi, seperti ditunjukkan pada **Gambar 1**.



**Gambar 1.** Alur Penelitian

### 2.2.1 Pengumpulan Data

Pengumpulan data dilakukan dengan mengambil data harga penutupan harian Bitcoin dari Yahoo Finance untuk periode 1 Januari 2014 hingga 9 Mei 2025. Penggunaan Yahoo Finance sebagai sumber data konsisten dengan praktik dalam penelitian prediksi harga kriptokurensi [2]. Data diunduh menggunakan pustaka yfinance dalam lingkungan Python, menghasilkan dataset yang hanya berfokus pada kolom harga penutupan untuk menyederhanakan pemodelan. Pemeriksaan kualitas data dilakukan untuk mendeteksi nilai hilang atau anomali, yang ditangani dengan interpolasi linier [4]. **Tabel 1** berikut merupakan sampel 10 data pertama dan 10 data terakhir bitcoin yang digunakan.

**Tabel 1.** Dataset Open dan Closing Harga Bitcoin

No.	Date	Open (BTC-USD)	Close (BTC-USD)
0	2014-09-17	465.864	457.334
1	2014-09-18	456.860	424.440
2	2014-09-19	424.103	394.796
3	2014-09-20	394.673	408.904
4	2014-09-21	408.085	398.821
5	2014-09-22	399.100	402.152
6	2014-09-23	402.092	435.791
7	2014-09-24	435.751	423.205
8	2014-09-25	423.156	411.574
9	2014-09-26	411.429	404.425
.....			
3878	2025-04-30	94286.469	94207.313
3879	2025-05-01	94212.859	96492.336
3880	2025-05-02	96494.969	96910.070
3881	2025-05-03	96904.633	95891.797
3882	2025-05-04	95877.188	94315.977
3883	2025-05-05	94319.563	94748.055
3884	2025-05-06	94748.383	96802.477
3885	2025-05-07	96800.195	97032.320
3886	2025-05-08	97034.250	103241.461
3887	2025-05-09	103239.125	102970.852

### 2.2.2 Pemrosesan Data

Pemrosesan data melibatkan normalisasi dan pembentukan urutan. Data harga dinormalisasi ke rentang [0, 1] menggunakan MinMaxScaler, sebuah teknik yang umum digunakan untuk memastikan konsistensi skala dalam pelatihan model deep learning.


$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{1}$$

dengan (x) sebagai harga asli, (x<sub>min</sub>) dan (x<sub>max</sub>) sebagai nilai minimum dan maksimum, dan (x') sebagai harga ternormalisasi. Data kemudian diubah menjadi urutan 60 hari sebagai masukan, dengan harga hari ke-61 sebagai keluaran,

untuk mencerminkan ketergantungan temporal. Dataset dibagi menjadi 80% data pelatihan dan 20% data pengujian, dengan pembagian dihitung menggunakan fungsi `math.ceil` untuk memastikan proporsi yang tepat.

### 2.2.3 Pengembangan Model

Pengembangan model dilakukan dengan merancang arsitektur LSTM menggunakan pustaka Keras dan TensorFlow. Arsitektur ini, seperti yang diilustrasikan pada **Gambar 2**, dipilih berdasarkan keberhasilannya dalam menangkap pola temporal kompleks pada data deret waktu.



**Gambar 2.** Arsitektur Model LSTM untuk Prediksi Harga Bitcoin

Arsitektur model terdiri dari empat lapisan utama:

1. Lapisan LSTM Pertama memiliki 50 unit LSTM dan berfungsi sebagai lapisan input yang menerima sekuens data historis. Parameter `return_sequences=True` digunakan agar setiap unit LSTM pada lapisan ini menghasilkan output sekuens yang akan diteruskan ke lapisan LSTM berikutnya. Ini penting untuk membangun model yang dalam (deep) dan mampu menangkap pola hierarkis.
2. Lapisan LSTM Kedua terdiri dari 50 unit LSTM. Lapisan ini menerima output dari lapisan pertama dan bertugas untuk memproses lebih lanjut informasi temporal. Karena ini adalah lapisan LSTM terakhir sebelum lapisan Dense, parameter `return_sequences` tidak diatur ke `True`, sehingga hanya output terakhir dari sekuens yang diteruskan.
3. Lapisan Dense Pertama adalah lapisan fully-connected dengan 25 neuron. Fungsinya adalah untuk melakukan transformasi non-linear terhadap fitur-fitur yang diekstrak oleh lapisan-lapisan LSTM sebelumnya, yang berfungsi sebagai kepala regresi (regression head).
4. Lapisan Dense Kedua (Output) adalah lapisan output dengan 1 neuron, yang menghasilkan nilai prediksi tunggal, yaitu harga penutupan Bitcoin pada hari berikutnya.

Model ini dikompilasi dengan optimasi Adam, yang efisien secara komputasi dan cocok untuk dataset besar, serta fungsi kerugian Mean Squared Error (MSE), yang merupakan standar untuk tugas regresi [18].

### 2.2.4 Pelatihan model

Pelatihan model dilakukan dengan melatih model pada data pelatihan selama maksimum 10 epoch dengan ukuran batch 1. Ukuran batch kecil dipilih untuk memungkinkan pembelajaran pola yang lebih rinci, sebagaimana direkomendasikan dalam penelitian terkait [11]. Mekanisme early stopping dengan `patience=2` diterapkan untuk mencegah overfitting, sebuah teknik yang telah terbukti efektif dalam meningkatkan generalisasi model [9], [18]. Berikut merupakan rumus RMSE (2), MAE (3), dan R<sup>2</sup> (4)

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

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

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

dengan ( $y_i$ ) sebagai harga aktual, ( $\hat{y}_i$ ) sebagai harga prediksi, dan ( $n$ ) sebagai jumlah data. Visualisasi plot harga aktual vs. prediksi dan distribusi residual akan dibuat menggunakan Matplotlib dan Seaborn untuk menganalisis pola kesalahan. Pengujian tambahan melibatkan prediksi harga menggunakan 60 hari terakhir untuk mensimulasikan aplikasi dunia nyata.

### 2.2.5 Implementasi dan Pengujian

Implementasi model dilakukan dalam lingkungan Python menggunakan pustaka TensorFlow, Keras, scikit-learn, dan yfinance. Proses pengujian dirancang untuk memastikan model dapat menangkap pola temporal tanpa kebocoran data,

dengan penalaan hiperparameter seperti laju pembelajaran dan jumlah unit LSTM untuk meningkatkan performa [8]. Pendekatan ini memungkinkan pengembangan model yang robust untuk prediksi harga Bitcoin.

### 3. HASIL DAN PEMBAHASAN


Bagian ini menyajikan hasil penelitian secara sistematis sesuai dengan tahapan yang diuraikan pada Gambar 1, mulai dari pengumpulan data hingga evaluasi model. Selanjutnya, dilakukan pembahasan mendalam dengan membandingkan temuan penelitian ini dengan studi-studi relevan sebelumnya untuk menyoroti kontribusi dan kebaruan.

#### 3.1 Pengumpulan dan Pemrosesan Data

Tahap pertama adalah pengumpulan data harga historis Bitcoin dari Yahoo Finance, yang mencakup periode dari 1 Januari 2014 hingga 9 Mei 2025. Total data yang berhasil dikumpulkan adalah 3.888 titik data harga penutupan harian. Setelah melalui tahap pemrosesan awal, termasuk penanganan nilai yang hilang dengan interpolasi linier dan normalisasi menggunakan MinMaxScaler, data dibagi menjadi dua set: 80% data (3.110 titik data) digunakan untuk pelatihan model, dan 20% sisanya (778 titik data) digunakan untuk pengujian dan validasi. Data ini kemudian diubah menjadi sekuens sepanjang 60 hari untuk input model, yang bertujuan untuk memprediksi harga pada hari ke-61.

#### 3.2 Hasil Pelatihan Model

Model LSTM dengan arsitektur yang dijelaskan pada Gambar 2 dilatih menggunakan data pelatihan. Proses pelatihan berlangsung selama 10 epoch dengan ukuran batch 1. Performa pelatihan dipantau melalui nilai loss (kerugian) yang dihitung menggunakan Mean Squared Error (MSE). **Gambar 3** menunjukkan grafik penurunan nilai loss selama proses pelatihan.



**Gambar 3.** Grafik loss selama training

Performa pelatihan model juga divisualisasikan melalui grafik loss selama 10 epoch, seperti ditunjukkan pada Gambar 3. Grafik ini menampilkan penurunan loss dari awal pelatihan hingga epoch terakhir, dengan nilai awal sekitar 0,006 dan menurun tajam hingga mendekati 0,001 pada epoch ke-10. Penurunan yang signifikan terjadi pada dua epoch pertama, diikuti oleh penurunan yang lebih lambat namun konsisten hingga epoch ke-6, setelah itu loss stabil dengan sedikit fluktuasi. Tren ini mengindikasikan bahwa model cepat konvergen pada tahap awal dan terus meningkatkan akurasi selama pelatihan, yang didukung oleh penggunaan optimasi Adam dan mekanisme early stopping dengan  $patience=2$ . Stabilitas loss pada epoch akhir menunjukkan bahwa model telah mencapai titik optimal tanpa tanda-tanda overfitting, yang konsisten dengan performa tinggi yang ditunjukkan oleh metrik evaluasi

#### 3.3 Hasil Pengujian dan Evaluasi Model

Setelah pelatihan selesai, model diuji menggunakan 20% data pengujian yang belum pernah dilihat sebelumnya. Evaluasi dilakukan secara kuantitatif dan kualitatif.

##### 3.3.1 Evaluasi Kuantitatif

Performa model diukur menggunakan empat metrik standar untuk masalah regresi, yaitu RMSE, MSE, MAE, dan  $R^2$ . Hasil evaluasi disajikan pada **Tabel 2**.

**Tabel 2.** Metrik Evaluasi Model LSTM


Metrik	Nilai
RMSE	105,80
MSE	2.822.880,74

Metrik	Nilai
MAE	1.103,42
R <sup>2</sup>	0,995

Hasil evaluasi menunjukkan bahwa model mampu memprediksi harga penutupan harian dengan tingkat akurasi yang tinggi. Nilai RMSE sebesar 105,80 menunjukkan kesalahan rata-rata prediksi yang relatif kecil dibandingkan skala harga Bitcoin, yang berkisar dari puluhan hingga ratusan ribu dolar AS. MSE sebesar 2.822.880,74 mencerminkan variansi kesalahan kuadrat, sementara MAE sebesar 1.103,42 mengindikasikan kesalahan absolut rata-rata. Nilai R<sup>2</sup> sebesar 0,995 menunjukkan bahwa model menjelaskan 99,5% variansi data harga aktual, mengindikasikan kecocokan yang sangat baik antara prediksi dan data aktual.


### 3.3.2 Evaluasi Kualitatif

Evaluasi kualitatif dilakukan melalui visualisasi. Gambar 4 membandingkan harga aktual (data latih dan validasi) dengan harga yang diprediksi oleh model pada data validasi.



**Gambar 4.** Visualisasi Hasil Prediksi penutupan harga bitcoin

Dari Gambar 4, memperlihatkan visualisasi hasil prediksi harga penutupan Bitcoin menggunakan Model berbasis jaringan LSTM yang telah dilatih selama 10 epoch. Tujuan dari pelatihan ini adalah untuk mengevaluasi kemampuan model dalam mempelajari serta menggeneralisasi pola historis pergerakan harga Bitcoin. Data historis yang digunakan mencakup periode mulai dari awal tahun 2014 hingga 9 Mei 2025, yang kemudian dibagi menjadi dua subset, yaitu 80% sebagai data pelatihan dan 20% sebagai data validasi. Berdasarkan visualisasi, data pelatihan (garis biru) mencakup pergerakan harga hingga awal 2023, sementara data validasi (garis oranye) mencerminkan harga aktual dari awal 2023 hingga pertengahan 2025. Adapun hasil prediksi model terhadap data validasi digambarkan melalui garis hijau. Secara umum, model menunjukkan kemiripan pola yang cukup kuat dengan tren aktual, terutama selama periode kenaikan harga signifikan pada tahun 2023 hingga 2025, menandakan bahwa model mampu menangkap tren jangka panjang dengan baik. Selanjutnya, Gambar 5 menunjukkan distribusi residual (selisih antara nilai aktual dan prediksi).



**Gambar 5** distribusi Residual

Dari Gambar 5 menunjukkan distribusi residual yang merupakan selisih antara nilai aktual harga penutupan Bitcoin yang digunakan untuk mengevaluasi akurasi prediktif model secara statistik. Hasil visualisasi menunjukkan bahwa residual tersebar secara simetris dan membentuk kurva menyerupai distribusi normal dengan pusat distribusi



berada di sekitar nol. Hal ini mengindikasikan bahwa model tidak menunjukkan bias sistematis dalam memprediksi harga, yakni tidak cenderung secara konsisten melakukan prediksi yang terlalu tinggi (overestimation) atau terlalu rendah (underestimation). Mayoritas residual berada dalam kisaran  $-2000$  hingga  $+2000$  USD, yang mencerminkan tingkat kesalahan prediksi yang relatif kecil dan dapat diterima mengingat volatilitas tinggi pada aset kripto seperti Bitcoin.

### 3.4 Pembahasan dan Perbandingan Hasil

Hasil penelitian ini menunjukkan bahwa model LSTM yang dikembangkan mampu memprediksi harga penutupan harian Bitcoin dengan akurasi yang sangat tinggi. Kebaruan utama dari penelitian ini terletak pada penggunaan dataset jangka panjang (11 tahun) yang memungkinkan model untuk mempelajari siklus pasar bullish dan bearish secara lebih komprehensif, serta evaluasi performa yang mendalam.

Berikut Merupakan perbandingan dari beberapa penelitian sejenis:

1. Nirraca dan Hartati (2023) [14] yang juga menggunakan LSTM untuk prediksi jangka pendek di Indonesia melaporkan RMSE sebesar 1304,3, yang jauh lebih tinggi dibandingkan RMSE 105,80 yang dicapai dalam penelitian ini. Hal ini menunjukkan model kami lebih akurat, kemungkinan karena dataset yang lebih panjang dan arsitektur yang lebih optimal.
2. Febriansyah (2024) [24] melaporkan RMSE sebesar 17318,40 pada data pelatihan, yang juga secara signifikan lebih tinggi.
3. Saadah dan Salsabila (2021) [15] menggunakan Random Forest Regression dan mencapai akurasi 98,50% (setara  $R^2$  0,985) pada data selama pandemi. Meskipun kuat, nilai  $R^2$  sebesar 0,995 pada penelitian ini menunjukkan performa yang sedikit lebih unggul, dan LSTM lebih cocok secara teoretis untuk data deret waktu dibandingkan Random Forest.
4. Raj dan Chattopadhyay (2024) [18] yang mengusulkan LSTM autoencoder juga melaporkan RMSE yang rendah, namun penelitian ini unggul dengan menyediakan evaluasi yang lebih lengkap termasuk  $R^2$  dan analisis residual yang jelas.

Kontribusi utama penelitian ini adalah menyediakan sebuah model prediktif yang terbukti andal dan dapat diaplikasikan secara praktis oleh investor untuk strategi perdagangan dan manajemen risiko. Nilai  $R^2$  0,995 jauh melampaui metode statistik tradisional seperti ARIMA yang sering kali kesulitan melampaui  $R^2$  0,85 pada data kriptokurensi yang volatile [7].

## 4. KESIMPULAN

Penelitian ini berhasil mengembangkan sebuah model Long Short-Term Memory (LSTM) yang efektif untuk memprediksi harga penutupan harian Bitcoin, dengan menggunakan data historis dari 1 Januari 2014 hingga 9 Mei 2025. Temuan utama menunjukkan bahwa model yang diusulkan mencapai performa yang sangat tinggi, dibuktikan dengan nilai R-squared ( $R^2$ ) sebesar 0,995. Hal ini berarti model mampu menjelaskan 99,5% variabilitas data harga aktual. Metrik evaluasi lainnya, seperti Root Mean Squared Error (RMSE) sebesar 105,80 dan Mean Absolute Error (MAE) sebesar 1.103,42, mengonfirmasi tingkat kesalahan prediksi yang rendah, sehingga model ini dapat dianggap akurat dan andal. Kontribusi utama dari penelitian ini adalah penyediaan model prediktif yang solid, yang kebaruannya terletak pada penggunaan dataset jangka panjang (11 tahun) dan evaluasi performa yang komprehensif. Model ini terbukti mampu menangkap pola temporal kompleks pada data harga Bitcoin, bahkan pada periode volatilitas tinggi, dan melampaui performa yang umumnya dicapai oleh metode statistik tradisional. Secara praktis, model ini dapat menjadi alat bantu yang berharga bagi investor untuk strategi perdagangan dan manajemen risiko di pasar kriptokurensi. Meskipun demikian, penelitian ini memiliki keterbatasan karena hanya berfokus pada data harga historis. Faktor eksternal seperti sentimen pasar dari media sosial atau volume perdagangan tidak diikutsertakan. Oleh karena itu, untuk penelitian di masa depan, disarankan untuk mengintegrasikan variabel-variabel tambahan tersebut, menguji model pada aset kripto lain seperti Ethereum, atau mengembangkan sistem prediksi real-time berbasis data streaming untuk meningkatkan relevansi dan akurasi model.

## REFERENCES

- [1] K. John, M. O'Hara, and F. Saleh, "Bitcoin and beyond," *Annual Review of Financial Economics*, vol. 14, no. 1, pp. 95–115, 2022, doi: <https://doi.org/10.1146/annurev-financial-111620-011240>.
- [2] P. Jaquart, D. Dann, and C. Weinhardt, "Short-term bitcoin market prediction via machine learning," *The Journal of Finance and Data Science*, vol. 7, pp. 45–66, Nov. 2021, doi: [10.1016/j.jfds.2021.03.001](https://doi.org/10.1016/j.jfds.2021.03.001).
- [3] S. Arslan, "Bitcoin Price Prediction Using Sentiment Analysis and Empirical Mode Decomposition," *Computational Economics*, vol. 65, no. 4, Art. no. 4, May 2024, doi: [10.1007/s10614-024-10588-3](https://doi.org/10.1007/s10614-024-10588-3).
- [4] R. Hajare, C. Puri, and P. M. Gote, "Bitcoin Price Prediction Using Deep Learning Models," in *2025 4th International Conference on Sentiment Analysis and Deep Learning (ICSADL)*, Feb. 2025, pp. 1678–1683. doi: [10.1109/ICSADL65848.2025.10933412](https://doi.org/10.1109/ICSADL65848.2025.10933412).
- [5] L. Cocco, R. Tonelli, and M. Marchesi, "Predictions of bitcoin prices through machine learning based frameworks," *PeerJ Computer Science*, vol. 7, p. e413, Mar. 2021, doi: [10.7717/peerj-cs.413](https://doi.org/10.7717/peerj-cs.413).
- [6] O. Omole and D. Enke, "Deep learning for Bitcoin price direction prediction: models and trading strategies empirically compared," *Financial Innovation*, vol. 10, no. 1, p. 117, Aug. 2024, doi: [10.1186/s40854-024-00643-1](https://doi.org/10.1186/s40854-024-00643-1).



- [7] A. M. Khedr, I. Arif, P. R. P V, M. El-Bannany, S. M. Alhashmi, and M. Sreedharan, “Cryptocurrency price prediction using traditional statistical and machine-learning techniques: A survey,” *Intelligent Systems in Accounting, Finance and Management*, vol. 28, no. 1, pp. 3–34, 2021, doi: 10.1002/isaf.1488.
- [8] P. L. Seabe, C. R. B. Moutsinga, and E. Pindza, “Forecasting Cryptocurrency Prices Using LSTM, GRU, and Bi-Directional LSTM: A Deep Learning Approach,” *Fractal and Fractional*, vol. 7, no. 2, Art. no. 2, Feb. 2023, doi: 10.3390/fractalfract7020203.
- [9] P. Anitha Rajakumari, S. Karthick, S. Gupta, S. Gupta, R. P. Mahapatra, and S. Vinoth Kumar, “Enhancing Bitcoin Price Prediction Using LSTM and GRU Models,” in *Proceedings of International Conference on Recent Trends in Computing*, R. P. Mahapatra, S. Roy, and P. Parwekar, Eds., Singapore: Springer Nature Singapore, 2025, pp. 177–188.
- [10] N. S. Wen and L. S. Ling, “Evaluation of Cryptocurrency Price Prediction Using LSTM and CNNs Models | Wen | JOIV : International Journal on Informatics Visualization,” Nov. 2023, doi: <http://dx.doi.org/10.30630/joiv.7.3-2.2344>.
- [11] I. S. Kervanci, M. F. Akay, E. Özceylan, IT Department, Gaziantep University, Gaziantep, 27300, Turkey, Computer Engineering Department, Çukurova University, Adana, 01250, Turkey, and Industrial Engineering Department, Gaziantep University, Gaziantep, 27300, Turkey, “Bitcoin price prediction using LSTM, GRU and hybrid LSTM-GRU with bayesian optimization, random search, and grid search for the next days,” *JIMO*, vol. 20, no. 2, pp. 570–588, 2024, doi: 10.3934/jimo.2023091.
- [12] J. Cheng, S. Tiwari, D. Khaled, M. Mahendru, and U. Shahzad, “Forecasting Bitcoin prices using artificial intelligence: Combination of ML, SARIMA, and Facebook Prophet models,” *Technological Forecasting and Social Change*, vol. 198, p. 122938, Jan. 2024, doi: 10.1016/j.techfore.2023.122938.
- [13] G. Giyanda and S. Saidah, “Auto Machine Learning dengan Menggunakan H2O AutoML untuk Prediksi Harga Bitcoin: Array,” *Jurnal Ilmiah Komputasi*, vol. 20, no. 2, Art. no. 2, Jun. 2021.
- [14] M. Nirraca and E. Hartati, “Prediksi Harga Bitcoin Menggunakan Metode Long Short Term Memory,” *Jurnal Digital Teknologi Informatika*, vol. 7, no. 1, Art. no. 1, Mar. 2024, doi: 10.32502/digital.v7i1.7974.
- [15] S. Saadah and H. Salsabila, “Prediksi Harga Bitcoin Menggunakan Metode Random Forest: (Studi Kasus: Data Acak Pada Masa Pandemi Covid-19),” *Jurnal Komputer Terapan*, vol. 7, no. 1, Art. no. 1, May 2021, doi: 10.35143/jkt.v7i1.4618.
- [16] J. Julianto, “Analisis Investasi Dalam Memprediksi Pergerakan Harga Bitcoin Dengan Menggunakan Recurrent Neural Network Pada Platform Indodax,” *Jurnal Ilmiah Rekayasa dan Manajemen Sistem Informasi*, vol. 8, no. 2, Art. no. 2, Sep. 2022, doi: 10.24014/rmsi.v8i2.17233.
- [17] M. A. Maliki, I. Cholissodin, and N. Yudistira, “Prediksi Pergerakan Harga Cryptocurrency Bitcoin terhadap Mata Uang Rupiah menggunakan Algoritme LSTM,” *J-PTIHK*, vol. 6, no. 7, pp. 3259–3268, Aug. 2022.
- [18] C. Raj and M. Chattopadhyay, “Bitcoin price prediction using LSTM autoencoder regularized by false nearest neighbor loss,” *Soft Computing*, vol. 28, no. 21, pp. 12827–12834, Nov. 2024, doi: 10.1007/s00500-024-10301-4.
- [19] E. Koo and G. Kim, “Centralized decomposition approach in LSTM for Bitcoin price prediction,” *Expert Systems with Applications*, vol. 237, p. 121401, Mar. 2024, doi: 10.1016/j.eswa.2023.121401.
- [20] W. Abdullah and A. Salah, “A novel hybrid deep learning model for price prediction,” *International Journal of Electrical and Computer Engineering*, vol. 13, no. 3, pp. 3420–3431, 2023.
- [21] W. Lu, J. Li, J. Wang, and L. Qin, “A CNN-BiLSTM-AM method for stock price prediction,” *Neural Computing and Applications*, vol. 33, no. 10, pp. 4741–4753, May 2021, doi: 10.1007/s00521-020-05532-z.
- [22] F. Mehrdoust and M. Noorani, “Prediction of cryptocurrency prices by deep learning models: A case study for Bitcoin and Ethereum,” *J. Finan. Eng.*, vol. 10, no. 04, p. 2350032, Dec. 2023, doi: 10.1142/S2424786323500329.
- [23] G. Belalova, S. Mannanova, and B. Karimov, “The Future of Bitcoin Price Predictions Integrating Deep Learning and the Hybrid Model Method,” in *Proceedings of the 7th International Conference on Future Networks and Distributed Systems*, Dubai United Arab Emirates: ACM, Dec. 2023, pp. 202–211. doi: 10.1145/3644713.3644739.
- [24] F. Febriansyah, A. Sujjada, and F. Sembiring, “Prediksi Harga Bitcoin Menggunakan Algoritma Long Short Term Memory (LSTM),” *INOVTEK Polbeng - Seri Informatika*, vol. 9, no. 1, Art. no. 1, Jun. 2024, doi: 10.35314/isi.v9i1.4247.