



## Penerapan *Long Short-Term Memory* untuk Prediksi Harga Mingguan Bitcoin Data Historis

Andi Muhammad Bintang<sup>1</sup>, Suhirman<sup>2</sup>

<sup>1</sup>Informatika, Sains & Teknologi, Universitas Teknologi Yogyakarta

<sup>2</sup>Program PascaSarjana, Teknologi Informasi, Universitas Teknologi Yogyakarta

[andimuhammadbintang@gmail.com](mailto:andimuhammadbintang@gmail.com), [suhirman@uty.ac.id](mailto:suhirman@uty.ac.id)

### Abstract

*This study aims to predict the weekly closing price of Bitcoin using a Long Short-Term Memory (LSTM) neural network based on historical time-series data. The dataset consists of 539 weekly records ranging from 4 January 2015 to 27 April 2025 obtained from the [investing.com](https://www.investing.com) Indonesia website. The closing price is used as the target variable while the historical weekly price data are used as input features. The data were pre-processed through cleaning, normalization and transformation into supervised time-series format. The LSTM model was trained and tested on the prepared dataset and model performance was evaluated using Mean Absolute Error (MAE), Mean Squared Error (MSE) and Mean Absolute Percentage Error (MAPE). The experimental results show that the proposed LSTM model is capable to capture the movement pattern of Bitcoin prices in the testing period. The obtained performance metrics indicate good predictive accuracy with MAE of 0.0703, MSE of 0.0072 and MAPE of 0.0896. These results demonstrate that the LSTM model is effective for short-term weekly Bitcoin price prediction based on historical data. For the further research, it could be added with other external variables such as macroeconomic indicators or sentiment data to improve prediction accuracy.*

**Keywords:** *Bitcoin, Long Short-Term Memory, Deep Learning, Weekly Price Prediction, Historical Data*

### Abstrak

Penelitian ini bertujuan untuk memprediksi harga penutupan mingguan Bitcoin menggunakan jaringan saraf Long Short-Term Memory (LSTM) berbasis data deret waktu historis. Dataset yang digunakan terdiri atas 539 data mingguan yang mencakup periode 4 Januari 2015 hingga 27 April 2025 yang diperoleh dari situs Investing.com Indonesia. Variabel yang diprediksi adalah harga penutupan, sedangkan data harga historis mingguan digunakan sebagai variabel masukan. Data diproses melalui tahapan pembersihan data, normalisasi, serta pembentukan data deret waktu dalam bentuk supervised learning. Model LSTM dilatih dan diuji menggunakan dataset tersebut, dan kinerjanya dievaluasi menggunakan Mean Absolute Error (MAE), Mean Squared Error (MSE), dan Mean Absolute Percentage Error (MAPE). Hasil pengujian menunjukkan bahwa model LSTM mampu menangkap pola pergerakan harga Bitcoin pada periode pengujian. Nilai evaluasi yang diperoleh menunjukkan tingkat akurasi yang baik, dengan MAE sebesar 0,0703, MSE sebesar 0,0072, dan MAPE sebesar 0,0896. Temuan ini menunjukkan bahwa model LSTM efektif digunakan untuk prediksi harga mingguan Bitcoin berbasis data historis. Pada penelitian selanjutnya, model dapat dikembangkan dengan menambahkan variabel eksternal seperti indikator makroekonomi atau analisis sentimen untuk meningkatkan akurasi prediksi.

**Kata kunci:** *Bitcoin, Long Short-Term Memory, Deep Learning, Prediksi Harga Mingguan, Data Historis*



## 1. Pendahuluan

Bitcoin merupakan salah satu aset kripto dengan kapitalisasi pasar terbesar dan tingkat volatilitas harga yang tinggi. Pergerakan harganya dipengaruhi oleh berbagai faktor, seperti dinamika pasar, regulasi, sentimen investor, serta kondisi ekonomi global. Tingginya volatilitas tersebut menyebabkan prediksi harga Bitcoin menjadi tantangan sekaligus peluang, terutama dalam pengambilan keputusan investasi dan analisis pasar keuangan.

Prediksi harga aset kripto umumnya dilakukan menggunakan pendekatan statistik konvensional maupun metode *machine learning*. Namun, metode statistik tradisional seperti ARIMA memiliki keterbatasan dalam menangani pola data nonlinier dan ketergantungan jangka panjang pada data deret waktu. Oleh karena itu, diperlukan metode yang mampu mempelajari hubungan jangka panjang dalam data sekuensial.

Salah satu metode yang banyak digunakan adalah *Long Short-Term Memory* (LSTM), yang merupakan pengembangan dari *Recurrent Neural Network* (RNN). LSTM dirancang untuk mengatasi permasalahan *vanishing gradient* serta mampu mempelajari pola jangka pendek maupun jangka panjang pada data deret waktu. Metode ini telah banyak diterapkan dalam berbagai bidang, termasuk peramalan harga saham, prediksi lalu lintas, hingga pemodelan sinyal deret waktu lainnya.

Penelitian ini bertujuan untuk menerapkan model LSTM dalam memprediksi harga penutupan mingguan Bitcoin berbasis data historis. Dataset yang digunakan terdiri atas 539 data mingguan periode 4 Januari 2015 hingga 27 April 2025. Kinerja model dievaluasi menggunakan metrik MAE, MSE, dan MAPE. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan model prediksi harga kripto berbasis *deep learning* serta menjadi referensi bagi penelitian selanjutnya.

## 2. Metode Penelitian

Metode penelitian ini terdiri dari beberapa tahapan, yaitu pengumpulan data, pra-pemrosesan data, pembentukan data deret waktu, pemodelan menggunakan LSTM, serta evaluasi kinerja model.

### 2.1. Jenis dan Pendekatan Penelitian

Penelitian ini merupakan penelitian kuantitatif dengan pendekatan eksperimental yang bertujuan untuk mengevaluasi kinerja model *Long Short-Term Memory* (LSTM) dalam memprediksi harga mingguan Bitcoin berdasarkan data historis. Pendekatan eksperimental digunakan karena penelitian ini melibatkan proses pelatihan dan pengujian model prediksi menggunakan dataset historis serta evaluasi kinerja model berdasarkan metrik kesalahan kuantitatif yang terukur.

### 2.2. Dataset Penelitian

Data yang digunakan dalam penelitian ini merupakan data historis harga Bitcoin dengan frekuensi mingguan. Dataset diperoleh dari situs Investing.com Indonesia dengan periode data mulai tahun 2015 hingga 2025, sehingga total data yang digunakan adalah 539 data mingguan. Atribut yang tersedia dalam dataset meliputi tanggal, harga pembukaan, harga tertinggi, harga terendah, harga penutupan, volume, dan persentase perubahan harga.

Pada penelitian ini, *closing price* digunakan sebagai variabel target karena dianggap merepresentasikan harga akhir transaksi pada setiap periode. Data yang digunakan merupakan data mingguan asli dari sumber penyedia data, bukan hasil agregasi dari data harian.

### 2.3. Pra-pemrosesan Data

Pra-pemrosesan data dilakukan untuk memastikan bahwa data yang digunakan berada dalam kondisi layak untuk tahap pemodelan. Langkah pertama yang dilakukan adalah memeriksa keberadaan nilai hilang (*missing values*) serta ketidakkonsistenan data. Apabila ditemukan data yang tidak lengkap atau tidak valid, maka dilakukan perbaikan atau penghapusan agar tidak memengaruhi hasil pelatihan model. Selain itu, dilakukan pula pengecekan

dan penghapusan data duplikat sehingga setiap entri dalam dataset merepresentasikan informasi unik. Format tanggal kemudian dikonversi ke dalam tipe data deret waktu (*datetime*) agar dapat diproses sesuai karakteristik time series. Setelah itu, nilai harga dinormalisasi menggunakan metode Min–Max Scaling sehingga seluruh data berada dalam rentang tertentu. Normalisasi ini bertujuan untuk meningkatkan stabilitas proses pelatihan jaringan saraf serta mempercepat konvergensi model. Pada tahap akhir pra-pemrosesan, ditetapkan bahwa variabel target yang akan diprediksi adalah harga penutupan mingguan Bitcoin.

#### 2.4. Pembentukan Data Deret Waktu

Setelah melalui tahap pra-pemrosesan, data historis diubah ke dalam bentuk *supervised learning* menggunakan pendekatan *sliding window*. Pada pendekatan ini, sejumlah data harga penutupan pada minggu-minggu sebelumnya diperlakukan sebagai data masukan, sedangkan harga penutupan pada minggu berikutnya dijadikan sebagai nilai target. Dengan cara tersebut, model dapat mempelajari hubungan ketergantungan antarwaktu pada data deret waktu. Penelitian ini menggunakan skema *one-step-ahead forecasting (t+1)*, yaitu model memprediksi harga untuk satu minggu ke depan berdasarkan informasi dari beberapa minggu sebelumnya yang berada di dalam jendela pengamatan.

#### 2.5. Pembagian Data

Dataset yang telah dibentuk kemudian dibagi ke dalam tiga bagian, yaitu data latih, data validasi, dan data uji. Pembagian dilakukan secara kronologis berdasarkan urutan waktu agar struktur alami data deret waktu tetap terjaga dan untuk menghindari terjadinya *data leakage*. Sebanyak 70% data digunakan sebagai data latih untuk membangun model, 15% data digunakan sebagai data validasi untuk memantau kinerja model selama proses pelatihan, dan 15% sisanya digunakan sebagai data uji untuk mengevaluasi kemampuan generalisasi model. Pembagian tidak dilakukan secara acak, melainkan mengikuti alur waktu sebenarnya.

#### 2.6. Pemodelan Long Short-Term Memory (LSTM)

Pemodelan dilakukan menggunakan jaringan saraf Long Short-Term Memory (LSTM). Model ini dipilih karena memiliki kemampuan untuk mempelajari ketergantungan jangka panjang pada data deret waktu dan mampu mengatasi permasalahan *vanishing gradient* yang sering muncul pada jaringan saraf berulang konvensional. Proses pelatihan model dilakukan dengan menggunakan fungsi loss Mean Squared Error (MSE) dan algoritma optimisasi Adam. Pelatihan dilaksanakan selama beberapa epoch hingga model mencapai konvergensi, yaitu kondisi ketika perubahan nilai loss sudah relatif stabil. Melalui proses ini, model diharapkan mampu mengenali pola pergerakan harga Bitcoin berdasarkan data historis yang tersedia.

#### 2.7. Pelatihan Model

Proses pelatihan model dilakukan dengan menggunakan algoritma optimisasi Adam dengan fungsi loss berupa Mean Squared Error (MSE). Selama proses pelatihan, data masukan yang telah melalui tahap pra-pemrosesan diberikan ke dalam model dalam beberapa epoch dengan ukuran batch tertentu hingga model mencapai kondisi konvergensi, yaitu saat nilai loss sudah relatif stabil. Selain data latih, digunakan pula data validasi untuk memantau kinerja model selama proses pelatihan. Penggunaan data validasi ini bertujuan untuk mendeteksi potensi terjadinya *overfitting*, yaitu kondisi ketika model hanya bekerja baik pada data pelatihan tetapi tidak mampu melakukan generalisasi dengan baik pada data baru. Dengan memanfaatkan data validasi, proses pelatihan dapat dihentikan pada saat yang tepat sehingga model yang dihasilkan memiliki kinerja yang optimal pada data uji.

#### 2.8. Evaluasi Model

Evaluasi kinerja model dilakukan dengan menggunakan tiga metrik kesalahan, yaitu Mean Absolute Error (MAE), Mean Squared Error (MSE), dan Mean Absolute Percentage Error (MAPE). MAE dan MSE digunakan untuk mengukur besarnya selisih numerik antara nilai prediksi dan nilai aktual, sedangkan MAPE digunakan untuk menyatakan tingkat kesalahan dalam bentuk persentase. Pada penelitian ini, MAPE dijadikan indikator utama kinerja model karena dapat memberikan gambaran yang lebih intuitif mengenai besar kecilnya kesalahan prediksi relatif terhadap nilai harga aktual. Semakin kecil nilai MAPE yang dihasilkan, maka semakin baik kemampuan model dalam melakukan prediksi.

### 3. Hasil dan Pembahasan

Bagian ini menyajikan hasil penelitian yang diperoleh dari penerapan metode Long Short-Term Memory (LSTM) dalam memprediksi harga mingguan Bitcoin berdasarkan data historis. Hasil yang ditampilkan merupakan keluaran dari tahapan metodologi penelitian yang telah dilakukan, meliputi pra-pemrosesan data, pembentukan data deret waktu, pemodelan, serta evaluasi kinerja model menggunakan data uji. Selanjutnya, hasil tersebut dianalisis dan dibahas untuk menginterpretasikan kemampuan serta keterbatasan model dalam memprediksi harga Bitcoin.

#### 3.1. Hasil Prediksi Harga Mingguan Bitcoin

Hasil prediksi harga mingguan Bitcoin diperoleh dari data uji yang telah melalui proses pra-pemrosesan, normalisasi, dan pembentukan data deret waktu sebagaimana dijelaskan pada bagian metodologi. Data uji tersebut kemudian digunakan sebagai masukan ke dalam model LSTM yang telah dilatih sebelumnya.

Berdasarkan hasil pengujian, model LSTM menghasilkan pola prediksi yang mendekati harga aktual dan mampu mengikuti arah tren pergerakan harga Bitcoin pada sebagian besar periode pengujian. Hal ini menunjukkan bahwa model mampu mempelajari pola historis harga Bitcoin berdasarkan data mingguan. Meskipun demikian, pada beberapa periode dengan perubahan harga yang sangat tajam, masih ditemukan selisih antara nilai prediksi dan nilai aktual.

#### 3.2. Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan dengan membandingkan nilai harga Bitcoin hasil prediksi dengan harga aktual pada data uji menggunakan metrik Mean Absolute Error (MAE), Mean Squared Error (MSE), dan Mean Absolute Percentage Error (MAPE). Hasil evaluasi disajikan pada Tabel 1 berikut.

Tabel 1. Hasil Evaluasi Kinerja Model LSTM


Metrik Evaluasi	Nilai
MAE	0.07033648
MSE	0.00727523
MAPE	0.08962047

Nilai MAE dan MSE pada tabel di atas dihitung pada data yang masih berada dalam skala normalisasi (0–1), sehingga tidak berada pada satuan harga asli (USD). Sementara itu, nilai MAPE bersifat independen terhadap skala, sehingga tetap dapat dijadikan acuan utama untuk menilai kinerja model. Nilai MAPE sebesar 0,0896 atau 8,96% menunjukkan bahwa rata-rata tingkat kesalahan prediksi berada di bawah 10%, yang mengindikasikan bahwa model memiliki kemampuan prediksi yang cukup baik pada data uji. Nilai MAE merepresentasikan rata-rata selisih absolut antara nilai aktual dan nilai prediksi, sedangkan MSE memberikan penalti lebih besar terhadap kesalahan prediksi yang bersifat ekstrem.

#### 3.3. Analisis Visual Hasil Prediksi

Analisis visual dilakukan untuk melihat kesesuaian antara pola harga aktual dengan hasil prediksi model. Grafik harga Bitcoin aktual pada data uji ditampilkan pada Gambar 1, sedangkan grafik hasil prediksi harga Bitcoin yang dihasilkan model LSTM ditampilkan pada Gambar 2. Selain itu, grafik perbandingan harga aktual dan prediksi dalam satu tampilan overlay juga disajikan untuk memperjelas hubungan keduanya.

Berdasarkan grafik tersebut, terlihat bahwa model LSTM mampu mengikuti arah tren pergerakan harga Bitcoin aktual pada sebagian besar periode. Namun, selisih antara keduanya cenderung meningkat ketika terjadi volatilitas harga yang tinggi. Hal ini menunjukkan bahwa perubahan harga yang sangat tajam masih menjadi tantangan bagi model yang hanya bergantung pada data historis.



Gambar 1. Harga Aktual Bitcoin



Gambar 2. Harga Prediksi Bitcoin

Berdasarkan perbandingan antara kedua grafik tersebut, dapat diamati bahwa hasil prediksi model LSTM mampu mengikuti arah tren pergerakan harga Bitcoin aktual. Meskipun demikian, selisih antara harga aktual dan harga prediksi cenderung meningkat pada periode dengan volatilitas harga yang tinggi. Kondisi ini menunjukkan bahwa fluktuasi harga yang tajam masih menjadi tantangan bagi model prediksi yang hanya mengandalkan data historis harga.

### 3.4 Pembahasan

Hasil penelitian menunjukkan bahwa model LSTM mampu mempelajari pola pergerakan harga Bitcoin berbasis data historis mingguan. Penggunaan data mingguan membantu mengurangi *noise* yang umumnya muncul pada data harian sehingga model lebih fokus dalam menangkap tren jangka menengah hingga panjang. Namun demikian, hasil penelitian juga menunjukkan keterbatasan model, khususnya pada periode perubahan harga yang sangat ekstrem, di mana kesalahan prediksi cenderung meningkat.

Selain itu, penelitian ini hanya menggunakan variabel harga historis tanpa melibatkan variabel eksternal non-harga. Oleh karena itu, hasil prediksi sepenuhnya bergantung pada pola historis yang terekam dalam data, sehingga pengaruh faktor eksternal seperti sentimen pasar, kebijakan pemerintah, berita global, maupun indikator ekonomi makro belum sepenuhnya tertangkap oleh model. Dengan demikian, penelitian ini memberikan gambaran mengenai kemampuan sekaligus keterbatasan model LSTM dalam memprediksi harga mingguan Bitcoin, serta

membuka peluang pengembangan lebih lanjut melalui penambahan variabel lain atau penggabungan dengan metode pemodelan yang lebih kompleks.

#### 4. Kesimpulan

Penelitian ini bertujuan untuk menerapkan metode Long Short-Term Memory (LSTM) dalam memprediksi harga mingguan Bitcoin berdasarkan data historis. Berdasarkan hasil pengujian, model LSTM mampu menghasilkan prediksi harga yang mengikuti pola dan arah tren pergerakan harga Bitcoin aktual pada sebagian besar periode pengujian. Evaluasi kinerja model menunjukkan bahwa nilai kesalahan prediksi berada pada tingkat yang cukup rendah, dengan nilai MAE sebesar 0,0703, MSE sebesar 0,0072, dan MAPE sebesar 0,0896 atau sekitar 8,96%. Nilai MAPE di bawah 10% menunjukkan bahwa model memiliki kemampuan prediksi yang baik pada data uji, sehingga metode LSTM dinilai layak digunakan untuk memodelkan pergerakan harga Bitcoin berbasis data historis mingguan.

Hasil penelitian ini juga menunjukkan bahwa penggunaan data dengan frekuensi mingguan dapat membantu menangkap tren pergerakan harga jangka menengah hingga panjang secara lebih stabil. Model yang dikembangkan berpotensi digunakan sebagai alat bantu analisis dalam memantau dan memprediksi pergerakan harga Bitcoin berbasis data historis. Meskipun demikian, model masih memiliki keterbatasan, terutama ketika menghadapi kondisi pasar dengan tingkat volatilitas yang sangat tinggi. Selain itu, model hanya memanfaatkan data historis harga tanpa mempertimbangkan variabel eksternal lainnya, sehingga perubahan harga akibat sentimen pasar, kebijakan, maupun peristiwa global belum sepenuhnya dapat ditangkap. Oleh karena itu, penelitian selanjutnya disarankan untuk mengembangkan model dengan menambahkan variabel eksternal atau mengombinasikan LSTM dengan metode lain guna meningkatkan kinerja prediksi.

#### Daftar Rujukan

- [1] Hochreiter, S. dan Schmidhuber, J. 1997. Long short-term memory. *Neural Computation*. 9(8): 1735–1780.
- [2] Bengio, Y., Simard, P., dan Frasconi, P. 1994. Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*. 5(2): 157–166.
- [3] Fischer, T. dan Krauss, C. 2018. Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*. 270(2): 654–669.
- [4] Selvin, S., Vinayakumar, R., Gopalakrishnan, E.A., Menon, V.K., dan Soman, K.P. 2017. Stock price prediction using LSTM, RNN and CNN sliding window model. *Proceedings of the International Conference on Advances in Computing, Communications and Informatics*. 1643–1647.
- [5] Siami-Namini, S., Tavakoli, N., dan Namin, A.S. 2018. A comparison of ARIMA and LSTM in forecasting time series. *Proceedings of the IEEE International Conference on Machine Learning and Applications*. 1394–1401.
- [6] Hyndman, R.J. dan Athanasopoulos, G. 2021. *Forecasting: Principles and Practice*. Melbourne: OTexts.
- [7] Brownlee, J. 2018. *Deep Learning for Time Series Forecasting*. Melbourne: Machine Learning Mastery.
- [8] Nugroho, A. dan Santoso, B. 2022. Prediksi harga saham menggunakan metode long short-term memory. *Jurnal Pustaka AI*. 2(1): 15–25.
- [9] Pratama, R. dan Wibowo, D. 2023. Penerapan deep learning untuk prediksi data deret waktu. *Jurnal Pustaka AI*. 3(2): 45–54.
- [10] Qin, L., Sun, Y., Wang, J., dan Cheng, S. 2020. Forecasting stock prices using LSTM. *Journal of Physics: Conference Series*. 1624(4): 1–6.
- [11] Karim, F., Majumdar, S., Darabi, H., dan Chen, S. 2017. LSTM fully convolutional networks for time series classification. *IEEE Access*. 6: 1662–1669.

- [12] Nelson, D.M.Q., Pereira, A.C.M., dan de Oliveira, R.A. 2017. Stock market's price movement prediction with LSTM neural networks. *Proceedings of the International Joint Conference on Neural Networks*. 1419–1426.
- [13] McNally, S., Roche, J., dan Caton, S. 2018. Predicting the price of Bitcoin using machine learning. *Proceedings of the 26th Euromicro International Conference on Parallel, Distributed and Network-based Processing*. 339–343.
- [14] Patel, J., Shah, S., Thakkar, P., dan Kotecha, K. 2015. Predicting stock market index using fusion of machine learning techniques. *Expert Systems with Applications*. 42(4): 2162–2172.
- [15] Politis, D.N. dan Romano, J.P. 1994. The stationary bootstrap. *Journal of the American Statistical Association*. 89(428): 1303–1313.