

# PREDIKSI HARGA BITCOIN MENGGUNAKAN LONG SHORT TERM MEMORY DENGAN OPTIMASI HYPERPARAMETER

Garin Legantoro Adi; Azizah Fatmawati, S.T, M.Cs.

Program Studi Teknik Informatika, Fakultas Komunikasi dan Informatika,  
Universitas Muhammadiyah Surakarta

## Abstrak

Volatilitas harga *Bitcoin* yang tinggi menjadikannya sulit diprediksi, namun sekaligus membuka peluang bagi pengembangan model prediksi yang andal. Penelitian ini berbasis deep learning dengan memanfaatkan arsitektur *Long Short Term Memory* (LSTM) yang dioptimalkan melalui metode *Grid Search* untuk menemukan konfigurasi *hyperparameter* terbaik. Data harga penutupan harian Bitcoin (BTC-USD) periode 2021–2025 diperoleh dari *Yahoo Finance* dan melewati proses normalisasi serta pembentukan sekuens data sebelum dimasukkan ke dalam model. Eksperimen dilakukan dengan membandingkan dua skenario: model LSTM dengan konfigurasi awal (default) dan model yang telah melalui proses optimasi. Kinerja model diukur menggunakan *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Error* (MAE). Konfigurasi optimal yang diperoleh meliputi 100 unit LSTM, *batch size* 32, dan *learning rate* 0,01. Penerapan *Grid Search* terbukti meningkatkan akurasi prediksi secara signifikan, ditandai dengan penurunan RMSE sebesar 23,18% dari USD 2.968,22 menjadi USD 2.280,21, serta MAE yang turun dari USD 2.251,83 menjadi USD 1.750,84. Selanjutnya, pengujian eksternal dilakukan menggunakan 59 data eksternal periode 1 Januari hingga 28 Februari 2026 dengan metode *rolling one-step-ahead forecasting* tanpa melakukan pelatihan ulang. Pada pengujian eksternal, model default memperoleh RMSE sebesar USD 9.986,93 dan MAE sebesar USD 7.560,51, sedangkan model *Grid Search* memperoleh RMSE sebesar USD 11.945,32 dan MAE sebesar USD 10.080,43. Hasil tersebut menunjukkan bahwa model *default* memiliki kemampuan generalisasi yang lebih baik pada data eksternal. Dengan demikian, optimasi *hyperparameter* dapat meningkatkan performa pada pengujian internal, tetapi konfigurasi terbaik tetap perlu diuji pada data baru untuk memastikan kemampuan generalisasi model.

**Kata Kunci:** *Bitcoin*, LSTM, *Grid Search*, *time series*, prediksi harga.

## Abstract

The high price volatility of Bitcoin presents both a significant forecasting challenge and an opportunity for developing robust predictive models. This study proposes a deep learning based approach by utilizing the Long Short-Term Memory (LSTM) architecture optimized through Grid Search hyperparameter tuning. Daily Bitcoin closing price data (BTC-USD) spanning 2021 to 2025 were collected from Yahoo Finance and processed through normalization and sequence construction stages prior to model training. Two experimental scenarios were compared: an LSTM model with default parameter settings and one subjected to systematic hyperparameter optimization. Model performance was assessed using Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and Mean Absolute Error (MAE). The optimal configuration identified consisted of 100 LSTM units, a batch size of 32, and a learning rate of 0.01. Grid Search optimization yielded a substantial improvement in predictive accuracy, reducing RMSE by 23.18% from USD 2,968.22 to USD 2,280.21 and lowering MAE from USD 2,251.83 to USD 1,750.84. Subsequently, external testing was conducted using 59 external data points from the period of January 1 to February 28, 2026, employing a rolling one-step-ahead forecasting method without retraining. In the external testing, the default model achieved an RMSE of USD 9,986.93 and an MAE of USD 7,560.51, whereas the Grid Search model yielded an RMSE of USD 11,945.32 and an MAE of USD 10,080.43. These results indicate that the default model possesses superior generalization

*capabilities on external data. Thus, while hyperparameter optimization can enhance performance during internal testing, the optimal configuration must still be tested on new data to verify the model's generalization ability.*

**Keywords:** *Bitcoin, LSTM, Grid Search, time series, price prediction.*

## 1. PENDAHULUAN

Penulisan *Bitcoin* merupakan *cryptocurrency* pertama yang diperkenalkan oleh (Nakamoto, 2008), sebagai aset digital yang bersifat terdesentralisasi, *Bitcoin* menghadirkan alternatif dalam sistem keuangan global tanpa ketergantungan pada otoritas pusat seperti bank sentral maupun pemerintah. Meski demikian, karakteristik khas *Bitcoin* seperti tingkat volatilitas yang tinggi, kecenderungan spekulatif, serta pengaruh berbagai dinamika pasar menjadikan proses peramalan harga *Bitcoin* sebagai suatu tantangan yang kompleks (Tripathi & Kumar, 2023). Dalam perspektif hukum Islam, Muhammadiyah (2026) menyatakan bahwa *Bitcoin* dapat dianggap halal secara syariah karena termasuk dalam kategori *maal* (harta) dan memiliki nilai yang diakui oleh masyarakat.

Data *time series* seperti *Bitcoin* pada bidang keuangan umumnya memiliki karakteristik berupa tren, pola musiman, fluktuasi acak, serta keterkaitan antara nilai pada periode yang berbeda. Berbagai metode statistik konvensional, seperti *Moving Average* dan *Exponential Moving Average*, umumnya didasarkan pada asumsi hubungan yang linier, sehingga kurang efektif dalam menangkap pola non-linier dan kompleksitas yang sering muncul pada pergerakan harga Bitcoin (Boongasame & Songram, 2023). Keterbatasan metode statistik tradisional tersebut mendorong penggunaan pendekatan yang lebih canggih, khususnya metode berbasis *deep learning*. LSTM atau *Long Short Term Memory* merupakan salah satu basis *deep learning* yang banyak digunakan, yang merupakan arsitektur jaringan saraf tiruan atau *Neural Network* yang dirancang untuk menganalisa data yang bersifat sekuensial. Metode ini memiliki kemampuan untuk mengenali hubungan antar data dalam rentang waktu tertentu, sehingga sangat sesuai digunakan untuk analisis dan prediksi pada data *time series* (Aprianto et al., 2025). Dalam melakukan prediksi yang akurat maka dibutuhkan kemampuan LSTM dalam membaca dan memahami pola data yang berupa *time series* (Febriansyah et al., 2024).

Meskipun berbagai penelitian telah menerapkan metode LSTM untuk memprediksi harga *cryptocurrency*, sebagian besar studi tersebut belum secara khusus menekankan proses optimasi *hyperparameter* secara sistematis, misalnya menggunakan *Grid Search*, pada dataset historis *Bitcoin* terbaru. Padahal, optimasi *hyperparameter* merupakan aspek penting dalam meningkatkan kinerja model. Sebagian besar penelitian sebelumnya masih menentukan parameter model secara manual atau melalui pendekatan *trial and error*. Metode ini cenderung kurang efisien dan tidak menjamin diperolehnya konfigurasi parameter yang optimal (Duha & Putra, 2025). Model LSTM akan berpotensi mengalami *overfitting* karena adanya perbedaan nilai *training* dan *validation* (Fitriani &


Ummah, 2026).

Berbagai metode optimasi hyperparameter telah banyak diterapkan dalam penelitian *machine learning*, di antaranya *Random Search*, *Bayesian Optimization*, dan *Grid Search*. *Random Search* melakukan pencarian dengan memilih kombinasi parameter secara acak, sehingga prosesnya relatif lebih efisien, tetapi berisiko tidak menemukan kombinasi yang paling optimal (Bischl et al., 2023). Sementara itu, *Bayesian Optimization* memanfaatkan pendekatan probabilistik untuk mengarahkan pencarian menuju kombinasi parameter yang menjanjikan dengan jumlah iterasi yang lebih sedikit, meskipun implementasinya cenderung lebih kompleks (Kervanci et al., 2024). Berbeda dengan kedua metode tersebut, secara sistematis *Grid Search* melakukan evaluasi pada kombinasi parameter yang telah ditentukan. Walaupun memerlukan waktu komputasi yang lebih besar, metode ini mampu menghasilkan pencarian yang lebih menyeluruh, mudah diterapkan, serta memberikan hasil yang lebih konsisten dan mudah untuk dianalisis, sehingga dipilih dalam penelitian ini (Ogunsanya et al., 2023).

Berdasarkan berbagai keunggulan yang dimiliki, penelitian ini menggunakan *Grid Search* sebagai metode optimasi *hyperparameter* untuk menghasilkan parameter yang lebih optimal pada LSTM. Kemudian mengukur besarnya akurasi prediksi yang dihasilkan menggunakan RMSE dan MAE pada model. Berdasarkan itu, dengan harapan dapat memperoleh model dalam prediksi yang lebih baik serta memberikan kontribusi terhadap pengembangan metode analisis dan pemodelan data *time series* berbasis *deep learning* pada aset digital. Selain hal tersebut, diharapkan dapat memperkaya literatur ilmiah bidang kecerdasan buatan dan analisis data.

## **2. METODE**

Penerapan pendekatan kuantitatif dengan eksperimen akan digunakan pada penelitian, karena fokus penelitian adalah melakukan analisis data berupa numerik seperti harga historis *Bitcoin* serta pengukuran kinerja model menggunakan metrik evaluasi MSE, RMSE, dan MAE. Metode eksperimen dilakukan dengan pembangunan model LSTM dan mengoptimalkan hyperparameter dengan *Grid Search* untuk mendapatkan konfigurasi parameter yang paling efisien dan optimal dengan sistematis. Sebelum digunakan, data pada harga *Bitcoin* akan melalui tahap *preprocessing*. Tahapan pada penelitian ini ditunjukkan pada Gambar 1.



Gambar 1. Tahapan penelitian

## 2.1 Pengumpulan Data

Data historis pada harga *Bitcoin* yang didapatkan dari *website Yahoo Finance* akan digunakan pada penelitian melalui *library yfinance* pada *Python*. Dataset berasal dari periode pengamatan dari 1 Januari 2021 sampai 31 Desember 2025 dengan total 1.826 data. Harga *Bitcoin* dinyatakan dalam satuan USD (*United States Dollar*). Pemilihan rentang waktu tersebut dilakukan untuk menggambarkan pergerakan harga *Bitcoin* dalam jangka panjang, sehingga model dapat mempelajari pola dan karakteristik perubahan harga secara lebih menyeluruh.

## 2.2 Preprocessing

Berdasarkan data historis *Bitcoin* yang diperoleh, harga penutupan (*Close*) dipilih sebagai variabel *input* karena dianggap mampu menggambarkan nilai akhir perdagangan harian serta menjadi variabel yang paling sering digunakan dalam pergerakan harga bidang analisis. Zhang & Tumibay (2024) menyatakan bahwa variabel *close* memiliki tingkat korelasi yang tinggi terhadap pergerakan harga secara keseluruhan dan paling stabil untuk digunakan dalam model prediksi. Data harian *Bitcoin* setelah dilakukan pemilihan variabel *Close* disajikan pada Tabel 1.

Tabel 1. Data harian *Bitcoin* (BTC-USD) setelah dilakukan pemilihan variabel *Close*

| Tanggal    | Close     |
|------------|-----------|
| 2021-01-01 | 29.374,15 |
| 2021-01-02 | 32.127,26 |
| 2021-01-03 | 32.782,02 |
| -          | -         |
| 2025-12-29 | 87.138,14 |
| 2025-12-30 | 88.430,13 |
| 2025-12-31 | 87.508,82 |

### 2.3 Normalisasi Data

*MinMaxScaler* akan digunakan pada normalisasi data dengan rentang nilai (0,1). Teknik tersebut diterapkan untuk menyamakan skala seluruh data yang digunakan, sehingga setiap fitur memiliki rentang nilai yang seragam (Widiarto & Pamungkas, 2024). Dengan demikian, perbedaan nilai yang terlalu besar antar data dapat dikurangi, sehingga akan menjadi lebih stabil pada saat model melakukan *training*. Selain itu, normalisasi juga membantu model dalam mengenali pola data dengan lebih baik dan mendukung peningkatan akurasi hasil prediksi (Nugraha & Ariatmanto, 2025). Persamaan menghitung *Min-Max* terdapat pada Persamaan 1.

$$x_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

### 2.4 Pembentukan Data *Time Series*

Setelah melalui proses normalisasi, data historis selanjutnya ditransformasikan ke dalam bentuk *supervised learning* menggunakan metode *sliding window*. Pada pendekatan ini, data harga penutupan selama 30 hari digunakan input untuk memprediksi harga untuk periode berikutnya. Dengan cara tersebut, model dapat mempelajari pola serta hubungan ketergantungan antar waktu yang terdapat pada data *time series*. Penelitian ini menerapkan skema *one-step-ahead forecasting* (t+1), di mana prediksi dilakukan untuk periode yang ditentukan ke depan berdasarkan informasi dari periode yang ditentukan sebelumnya (Andi & Suhirman, 2025).


### 2.5 Pembagian Data

Pembagian pada data menggunakan rasio 80:20. Di mana 80% untuk *training* dan 20% untuk *testing*. Pembagian data dilakukan berdasarkan urutan waktu tanpa proses pengacakan untuk mempertahankan karakteristik data *time series*. Data *training* digunakan untuk melatih model agar mampu mengenali dan mempelajari pola pergerakan harga berdasarkan data historis yang tersedia. Sementara itu, data *testing* digunakan untuk mengevaluasi kemampuan model dalam melakukan prediksi terhadap data yang belum pernah dilihat sebelumnya. Pembagian data dengan rasio 80% *training* dan 20% *testing* dipilih karena dapat memberikan proporsi yang seimbang antara kebutuhan data untuk proses pembelajaran model dan kebutuhan data untuk pengujian kinerja model (Munir et al., 2025).

### 2.6 Pembangunan Model LSTM

Model LSTM awal merupakan *default* pada penelitian ini, bukan seluruh parameter bawaan dari *library*. Model LSTM awal dibangun menggunakan konfigurasi 100 unit LSTM, *batch size* 32, *learning rate* 0,001, dan *dropout* 0,2 atau 20%. Konfigurasi tersebut digunakan sebagai model awal

untuk mempelajari pola pergerakan harga Bitcoin dari data historis. Untuk mengurangi kemungkinan terjadinya *overfitting*, diterapkan nilai *dropout* sebesar 0,2 yang bekerja dengan menonaktifkan sebagian neuron secara acak selama proses pelatihan. Selain itu, *learning rate* menggunakan algoritma Adam karena mampu menyesuaikan *learning rate* secara otomatis. Tetapi pada model parameter *default* menggunakan bawaan Adam yaitu learning rate 0,001 sehingga dapat mendukung proses pembelajaran yang lebih efektif dan stabil (Kaur et al., 2025). Arsitektur model LSTM ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur model LSTM (Ingolfsson, 2021)

LSTM memiliki cell state sebagai jalur utama untuk membawa informasi dari satu periode ke periode berikutnya. Aliran informasi tersebut dikendalikan oleh tiga gerbang, yaitu forget gate, input gate, dan output gate. Forget gate menentukan informasi lama yang perlu dipertahankan atau dihapus, input gate menentukan informasi baru yang akan disimpan ke dalam cell state, sedangkan output gate menentukan informasi yang dikeluarkan sebagai hidden state. Dengan mekanisme tersebut, LSTM mampu mempelajari hubungan jangka pendek dan jangka panjang pada data time series. Pada penelitian ini, LSTM menerima sequence harga penutupan Bitcoin selama 30 hari untuk memprediksi harga pada satu hari berikutnya. Hasil dari lapisan LSTM kemudian diteruskan ke lapisan Dense dengan satu neuron untuk menghasilkan nilai prediksi harga Bitcoin.

## 2.7 Optimasi Hyperparameter Grid Search

Optimasi untuk menentukan parameter yang terbaik dilakukan menggunakan metode *Grid Search* dengan menentukan ruang pencarian yang terdiri atas beberapa parameter utama, yaitu jumlah unit LSTM (*units*), ukuran *batch* (*batch size*), dan *learning rate*. Proses optimasi seluruh parameter yang ditentukan akan diuji, meliputi jumlah unit LSTM sebesar 32, 64, 100, dan 128, *batch size* sebesar 16, 32, dan 64, serta *learning rate* sebesar 0,001, 0,01, dan 0,1, dengan jumlah *epoch* tetap sebanyak 20 (Hidayah & Putra, 2024). Algoritma Adam digunakan sebagai *optimizer* karena efektif dalam menentukan atau menyesuaikan *learning rate* (Kaur et al., 2025). Rentang nilai setiap hyperparameter

ditetapkan berdasarkan hasil kajian literatur dan praktik umum dalam penelitian prediksi data seperti *time series* berbasis *deep learning*.

Jumlah unit LSTM yang digunakan dalam proses optimasi terdiri atas 32, 64, 100, dan 128. Penggunaan jumlah unit yang terlalu sedikit dapat menyebabkan model tidak mampu menangkap pola yang kompleks (*underfitting*), sedangkan jumlah unit yang terlalu besar dapat meningkatkan kompleksitas model dan berpotensi menyebabkan *overfitting*. Oleh karena itu, beberapa jumlah unit digunakan untuk memperoleh kapasitas model yang paling sesuai (Widiarto & Pamungkas, 2024).

Nilai *batch size* yang diuji adalah 16, 32, dan 64. *Batch size* menentukan jumlah data yang diproses dalam satu kali pembaruan bobot selama proses pelatihan. Penggunaan *batch size* yang lebih kecil memungkinkan pembaruan bobot dilakukan lebih sering sehingga model dapat mempelajari variasi data secara lebih rinci. Sebaliknya, *batch size* yang lebih besar dapat meningkatkan efisiensi komputasi dan menghasilkan proses pelatihan yang lebih stabil. Oleh karena itu, ketiga nilai tersebut dipilih untuk mengetahui ukuran *batch* yang memberikan performa terbaik.

Parameter *learning rate* yang digunakan terdiri atas 0,001, 0,01, dan 0,1. Parameter ini berfungsi mengatur besar kecilnya perubahan bobot pada setiap proses optimasi. Nilai *learning rate* yang terlalu kecil dapat memperlambat proses pembelajaran, sedangkan nilai yang terlalu besar dapat menyebabkan proses pelatihan menjadi kurang stabil. Nilai 0,001 digunakan karena merupakan nilai *default* pada optimizer Adam, sedangkan nilai 0,01 dan 0,1 digunakan untuk mengevaluasi pengaruh perubahan laju pembelajaran terhadap performa model (Hidayah & Putra, 2024). Adapun 36 kombinasi parameter *Grid Search* disajikan pada Tabel 2.

Tabel 2. *Range Parameter Grid Search*

| Parameter                 | Nilai yang Diuji |
|---------------------------|------------------|
| Jumlah unit LSTM (units)  | 32, 64, 100, 128 |
| Ukuran batch (batch size) | 16, 32, 64       |
| Learning rate             | 0.001, 0.01, 0.1 |

## 2.8 Evaluasi Model

Untuk mengetahui efektivitas optimasi hyperparameter menggunakan *Grid Search*, dilakukan perbandingan antara model LSTM dengan konfigurasi parameter awal dan model LSTM yang menggunakan konfigurasi terbaik hasil optimasi. Kinerja kedua model kemudian dilakukan evaluasi dengan metrik MSE, MAE dan RMSE. Metrik-metrik tersebut digunakan untuk melihat dan mengukur seberapa besar kecilnya tingkat *error* antara nilai prediksi dan nilai aktual pada pengujian. MSE dimanfaatkan sebagai dasar dalam menentukan kombinasi hyperparameter terbaik, MAE dan RMSE akan digunakan untuk menggambarkan besarnya *error* prediksi model dilihat dari satuan yang lebih mudah diinterpretasikan. Jika nilai *error* semakin kecil yang dihasilkan, semakin lebih baik pada

kemampuan model saat menghasilkan prediksi yang mendekati nilai sebenarnya.

Selain melakukan evaluasi internal menggunakan data testing yang berasal dari periode dataset penelitian, penelitian ini juga melakukan pengujian eksternal menggunakan data riil harga Bitcoin periode 1 Januari 2026 hingga 28 Februari 2026. Pengujian eksternal dilakukan untuk mengetahui kemampuan generalisasi model default dan model hasil optimasi Grid Search ketika diterapkan pada data baru yang tidak digunakan selama proses pelatihan maupun pemilihan hyperparameter. Dengan demikian, penelitian tidak hanya mengevaluasi akurasi model pada data historis, tetapi juga menguji kestabilan performanya terhadap perubahan pola harga pada periode berikutnya.

### 2.8.1 MSE

*Mean Squared Error* (MSE) yaitu metrik yang digunakan untuk menghitung selisih antara nilai aktual  $y_i$  dan nilai prediksi  $\hat{y}_i$  yang dikuadratkan yang dihasilkan model. Nilai MSE yang lebih rendah menunjukkan bahwa hasil prediksi semakin mendekati nilai sebenarnya, sehingga mencerminkan performa model yang lebih baik. Karena selisih antara nilai aktual dan prediksi dikuadratkan, metrik ini memberikan bobot yang lebih besar terhadap kesalahan prediksi yang tinggi. Oleh karena itu, MSE sering digunakan untuk mengevaluasi kinerja model prediksi dalam meminimalkan kesalahan yang signifikan. Rumus perhitungan MSE ditunjukkan pada Persamaan 2.

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

### 2.8.2 RMSE

*Root Mean Squared Error* atau RMSE yang merupakan akar kuadrat dari nilai MSE yang digunakan untuk mengukur tingkat kesalahan prediksi dalam satuan yang sama dengan data asli. Pada penelitian ini, nilai RMSE juga dinyatakan dalam satuan USD sehingga lebih mudah untuk diinterpretasikan. Selain itu, RMSE juga disajikan dalam bentuk persentase terhadap rata-rata harga Bitcoin pada data pengujian agar tingkat kesalahan prediksi dapat dipahami dengan lebih jelas. Semakin kecil nilai RMSE yang diperoleh, semakin dekat hasil prediksi model dengan nilai aktual. Oleh karena itu, RMSE digunakan sebagai salah satu metrik utama untuk mengevaluasi akurasi dan kinerja model prediksi. Persamaan RMSE terdapat pada Persamaan 3.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

### 2.8.3 MAE

*Mean Absolute Error* (MAE) merupakan metrik yang digunakan untuk menghitung rata-rata selisih absolut antara nilai aktual dan nilai prediksi yang dihasilkan model. Berbeda dengan MSE dan RMSE, MAE tidak memberikan bobot yang lebih besar terhadap kesalahan prediksi yang ekstrem, sehingga nilai yang dihasilkan lebih mudah untuk diinterpretasikan. Melalui MAE, dapat diketahui besarnya rata-rata kesalahan prediksi model terhadap nilai sebenarnya. Semakin kecil nilai MAE, semakin baik kemampuan model dalam menghasilkan prediksi yang mendekati harga Bitcoin aktual. Persamaan MAE terdapat pada Persamaan 4.

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

## 2.9 Visualisasi Data

Visualisasi data yang akan digunakan untuk menampilkan perbandingan nilai aktual dan nilai hasil prediksi yang dihasilkan oleh model LSTM. Visualisasi disajikan dalam bentuk grafik garis (*line chart*) yang menggambarkan pergerakan harga *Bitcoin* sepanjang periode pengamatan. Grafik tersebut memuat dua kurva utama, yaitu kurva harga aktual (*actual price*) dan kurva hasil prediksi (*predicted price*) pada data pengujian. Melalui visualisasi ini, grafik dari harga antara hasil prediksi dan data aktual dapat diamati dengan mudah, sehingga membantu pembaca dalam memahami tren yang muncul selama penelitian berlangsung (Lusiara & Thamrin, 2025). Kemudian visualisasi grafik hasil prediksi model *default* dan model optimasi yang akan dibandingkan dengan data eksternal dari *Yahoo Finance* mulai Januari sampai Februari 2026.

## 3. HASIL DAN PEMBAHASAN

### 3.1 Deskripsi Dataset

Data harga *Bitcoin* yang diperoleh dari Yahoo Finance melalui library *yfinance* pada Python. Data yang digunakan dari periode Januari 2021 sampai akhir Desember 2025 total 1.826 data harian. Variabel yang dipilih sebagai input model adalah harga penutupan (*Close*) karena merepresentasikan harga akhir perdagangan pada setiap hari dan merupakan variabel yang biasa digunakan pada penelitian prediksi harga. Nilai terendah sebesar USD 15.787,28 pada November 2021 dan nilai tertinggi mencapai USD 124.752,53 pada Oktober 2025. Rata-rata harga Bitcoin tercatat sebesar USD 54.426,35 dengan standar deviasi sebesar USD 29.463,81. Besarnya nilai standar deviasi menunjukkan tingginya tingkat fluktuasi harga Bitcoin selama periode pengamatan. Setelah dilakukan pembentukan data menggunakan metode *sliding window* dengan ukuran 30 hari, diperoleh sebanyak 1796 pasang sampel input-target.

### 3.2 Hasil Pelatihan Model Default

Model LSTM awal dibangun menggunakan konfigurasi standar yang meliputi 100 unit LSTM, *batch size* sebesar 32, *optimizer* Adam *learning rate* 0,001, serta jumlah *epoch* 20. Berdasarkan pengujian, model tersebut menunjukkan nilai RMSE sebesar USD 2.968,22 dan MAE sebesar USD 2.251,83. Hasil tersebut sudah menunjukkan bahwa model awal atau *default* mampu membaca pola pergerakan harga Bitcoin. Meskipun demikian, masih ditemukan perbedaan yang terasa besar antara nilai prediksi dan nilai aktual, terutama saat terjadi perubahan harga yang cukup tajam atau signifikan naik dan turun. Kondisi tersebut mengindikasikan bahwa konfigurasi parameter *default* belum sepenuhnya mampu menangkap karakteristik volatilitas harga *Bitcoin* secara optimal.

### 3.3 Hasil Optimasi Hyperparameter Grid Search

Konfigurasi hyperparameter terbaik diperoleh pada model dengan jumlah unit LSTM sebanyak 100, *batch size* 32, *learning rate* 0,01, dan *epoch* 20. Konfigurasi tersebut menghasilkan nilai MSE sebesar USD<sup>2</sup> 5.199.402,03 dengan nilai RMSE sebesar USD 2.280,21. Dari hasil tersebut menunjukkan bahwa kombinasi pada parameter yang ditentukan tersebut dapat memberikan hasil dari prediksi yang paling baik dari konfigurasi lainnya. Rincian konfigurasi *hyperparameter* terbaik dapat dilihat pada Tabel 3.

Tabel 3. Konfigurasi Hyperparameter Terbaik Hasil *Grid Search*

| Hyperparameter   | Nilai Terbaik |
|------------------|---------------|
| Jumlah unit LSTM | 100           |
| Batch size       | 32            |
| Learning rate    | 0,01          |
| Epoch            | 20            |

### 3.4 Perbandingan Performa Model Default dan Model Optimasi Grid Search

Evaluasi performa dilakukan dengan membandingkan model LSTM *default* dan model LSTM dengan konfigurasi terbaik hasil optimasi *Grid Search*. Evaluasi untuk menilai seberapa optimal optimasi *hyperparameter* dapat meningkatkan kinerja model dalam melakukan prediksi harga pada *Bitcoin*. Selain digunakan untuk membandingkan performa antar model, evaluasi ini juga bertujuan untuk mengukur besar kecilnya kesalahan atau *error* prediksi yang dihasilkan dan mengidentifikasi model dengan performa terbaik. Pengukuran kinerja dilakukan menggunakan metrik evaluasi *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Error* (MAE), yang dihitung pada data pengujian setelah hasil prediksi dikembalikan ke skala harga USD melalui proses *inverse transform*. Hasil perbandingan performa kedua model disajikan pada Tabel 4.

Tabel 4. Perbandingan Performa Model Default dan Model Optimasi *Grid Search*


| Metrik                  | Model Default | Model Grid Search |
|-------------------------|---------------|-------------------|
| MSE (USD <sup>2</sup> ) | 8.810.358,57  | 5.199.402,03      |
| RMSE (USD)              | 2.968,22      | 2.280,21          |
| MAE (USD)               | 2.251,83      | 1.750,84          |
| RMSE (%)                | 2,91%         | 2,24%             |

Berdasarkan Tabel 4, model LSTM dengan konfigurasi *hyperparameter* terbaik hasil optimasi *Grid Search* mampu menghasilkan performa yang lebih baik dibandingkan model dengan parameter *default*. Nilai RMSE berkurang dari USD 2.968,22 menjadi USD 2.280,21 (turun 23,18%). Nilai MAE juga mengalami penurunan dari USD 2.251,83 menjadi USD 1.750,84. Jika nilai RMSE dibandingkan dengan rata-rata harga *Bitcoin* pada data uji yang berada di kisaran USD 101.703,71, nilai RMSE model *default* setara dengan 2,91%, sedangkan nilai RMSE model *Grid Search* setara dengan 2,24%. Hasil ini menunjukkan bahwa optimasi *hyperparameter* menggunakan *Grid Search* efektif dalam meningkatkan akurasi dan kualitas prediksi model LSTM pada periode data uji.

### 3.5 Analisis Hasil Prediksi

#### 3.5.1 Hasil Prediksi Model Default pada Data Uji


Model LSTM dengan konfigurasi awal yang terdiri atas 100 unit LSTM, *batch size* 32, *learning rate* 0,001, dan 20 *epoch* menghasilkan nilai RMSE sebesar USD 2.968,22 serta MAE sebesar USD 2.251,83 pada data pengujian. Secara umum, model mampu menangkap pola pergerakan harga *Bitcoin* dan mengikuti tren yang terjadi selama periode pengamatan. Namun, pada saat terjadi kenaikan harga yang cukup tajam, hasil prediksi masih cenderung berada di atas nilai aktual. Selain itu, model juga menunjukkan respons yang sedikit terlambat dalam mengikuti perubahan harga yang berlangsung cepat. Meskipun demikian, model telah mampu mempelajari pola historis harga *Bitcoin* dengan cukup baik dan menghasilkan prediksi yang relatif mendekati data aktual, sehingga dapat dijadikan sebagai model acuan sebelum dilakukan optimasi *hyperparameter*. Visualisasi hasil prediksi model *default* ditampilkan pada Gambar 3.



Gambar 3. Visualisasi hasil prediksi model *default*

### 3.5.2 Hasil Prediksi Model Optimasi *Grid Search* pada Data Uji

Model LSTM dengan konfigurasi *hyperparameter* terbaik hasil optimasi *Grid Search*, yaitu 100 unit LSTM, *batch size* 32, *learning rate* 0,01, dan 20 *epoch*, menghasilkan nilai MSE sebesar USD<sup>2</sup> 5.199.402,03, RMSE sebesar USD 2.280,21 serta MAE sebesar USD 1.750,84. Jumlah unit tetap LSTM memungkinkan model memahami dan mempelajari pola dan hubungan temporal pada data harga *Bitcoin* dengan baik. Jumlah unit LSTM dan *batch size* pada model hasil optimasi sama dengan model *default*, yaitu 100 unit LSTM dan *batch size* 32. Perbedaan utama kedua model terletak pada *learning rate*, yaitu 0,001 pada model *default* dan 0,01 pada model hasil optimasi.. Hasil prediksi menunjukkan bahwa model yang telah dioptimasi mampu menghasilkan nilai yang lebih mendekati harga aktual dibandingkan model *default*, dengan tingkat keterlambatan prediksi yang lebih rendah. Meskipun demikian, model masih memiliki keterbatasan dalam memprediksi pergerakan harga yang berubah secara sangat cepat dan ekstrem. Visualisasi hasil prediksi model hasil optimasi *Grid Search* ditunjukkan pada Gambar 4.




Gambar 4. Visualisasi hasil prediksi model *Grid Search*

### 3.6 Pengujian Model dengan Data Riil

Pengujian model melakukan prediksi harga di luar data uji, yaitu melakukan prediksi harga *Bitcoin* dari tanggal 1 Januari sampai 28 Februari 2026 (prediksi 59 hari) dengan menerapkan skema Rolling one-step-ahead forecasting ( $t+1$ ), di mana pada penelitian ini menggunakan 30 hari sebagai input untuk melakukan prediksi hari ke-31 dan seterusnya sampai hari ke-59. Kemudian dilakukan perbandingan hasil prediksi model parameter *default* dan hasil prediksi model optimasi *Grid Search* dengan harga aktual. Harga aktual yang diambil dari *Yahoo Finance* untuk mengetahui seberapa besar kesalahan model dalam melakukan prediksi terhadap data periode baru.

### 3.7 Hasil Pengujian Model dengan Data Riil

Model *default* pada pengujian dengan data eksternal menghasilkan RMSE sebesar USD 9.986,93 dan MAE sebesar USD 7.560,51. Model optimasi pada pengujian ini menghasilkan error lebih besar, dengan RMSE sebesar USD 11.945,32 dan MAE sebesar USD 10.080,43. Dari hasil tersebut menunjukkan prediksi model default lebih unggul dibandingkan dengan model optimasi pada saat melakukan prediksi terhadap data di luar data uji, yaitu periode bulan Januari sampai Februari 2026. Perlu diingat penelitian ini menggunakan variabel *Close* atau penutupan harga tanpa variabel eksternal. Grafik perbandingan model dengan data riil disajikan pada Gambar 5.



Gambar 5. Perbandingan model dengan data eksternal

Kedua model menunjukkan tren penurunan harga Bitcoin selama periode Januari hingga Februari. Pada bulan Januari, model *default* mengalami *lag* yang cukup besar, di mana hasil prediksi berada pada kisaran USD 75.000-80.000, sedangkan harga aktual berada pada kisaran USD 85.000-95.000. Memasuki bulan Februari, hasil prediksi model *default* mulai mendekati harga aktual, yaitu pada kisaran USD 65.000-70.000. Sementara itu, model hasil optimasi menghasilkan prediksi yang lebih mendekati harga aktual pada bulan Januari, meskipun masih cenderung berada sedikit di bawah nilai aktual, yaitu sekitar USD 84.000-90.000. Pada bulan Februari, model hasil optimasi masih

menunjukkan *lag* terhadap perubahan harga yang terjadi secara tajam. Prediksi model optimasi berada pada kisaran USD 85.000-90.000, sedangkan harga aktual mengalami fluktuasi yang lebih besar pada periode tersebut, yaitu sekitar USD 65.000-70.000. Rincian harga prediksi kedua model periode bulan Januari sampai Februari 2026 disajikan pada Tabel 5 dan Tabel 6.

Tabel 5. Rincian harga prediksi model bulan Januari 2026

| Tanggal    | Prediksi Default (USD) | Prediksi Optimasi (USD) | Harga Aktual (USD) |
|------------|------------------------|-------------------------|--------------------|
| 2026-01-01 | 86161.87               | 87507.87                | 88731.98           |
| 2026-01-02 | 85747.65               | 87510.77                | 89944.7            |
| 2026-01-03 | 85111.51               | 87471.62                | 90603.19           |
| 2026-01-29 | 71972.61               | 85632.73                | 84561.59           |
| 2026-01-30 | 71670.08               | 85569.38                | 84128.66           |
| 2026-01-31 | 71375.53               | 85509.59                | 78621.12           |

Tabel 6. Rincian harga prediksi model bulan Februari 2026

| Tanggal    | Prediksi Default (USD) | Prediksi Optimasi (USD) | Harga Aktual (USD) |
|------------|------------------------|-------------------------|--------------------|
| 2026-02-01 | 71088.88               | 85449.23                | 76974.45           |
| 2026-02-02 | 70810.13               | 85389.03                | 78688.77           |
| 2026-02-03 | 70539.14               | 85330.03                | 75633.55           |
| 2026-02-26 | 65926.33               | 84136.74                | 67453.77           |
| 2026-02-27 | 65777.74               | 84090.38                | 65881.8            |
| 2026-02-28 | 65632.45               | 84044.5                 | 66995.86           |

#### 4. PENUTUP

Penelitian ini telah menerapkan metode *Long Short-Term Memory* (LSTM) untuk memprediksi harga *Bitcoin* menggunakan data historis BTC-USD periode 1 Januari 2021 hingga 31 Desember 2025. Hasil dari penelitian menunjukkan bahwa optimasi hyperparameter menggunakan metode *Grid Search* mampu meningkatkan kinerja model LSTM. Dari 36 kombinasi hyperparameter yang dievaluasi, diperoleh konfigurasi terbaik berupa 100 unit LSTM, *batch size* 32, *learning rate* 0,01, *epoch* 20, dan *dropout* 0,2. Konfigurasi tersebut menghasilkan nilai MSE sebesar USD<sup>2</sup> 5.199.402,03, RMSE sebesar USD 2.280,21, dan MAE sebesar USD 1.750,84. Dibandingkan dengan model yang menggunakan parameter *default*, model hasil optimasi menunjukkan peningkatan akurasi yang lebih baik. Nilai RMSE berhasil diturunkan dari USD 2.968,22 menjadi USD 2.280,21. Namun pengujian diluar data uji periode 1 Januari sampai 28 Februari 2026, model default lebih akurat dengan RMSE sebesar USD 9.986,93 dibandingkan model optimasi dengan RMSE sebesar USD 11.945,32. Berdasarkan dari hasil visualisasi tersebut, model hasil optimasi mampu membaca dan mengikuti pola pergerakan pada harga *Bitcoin* dengan lebih baik dibandingkan model *default* pada data uji, tetapi model default lebih baik pada pengujian atau prediksi data riil. Meskipun masih terdapat keterbatasan dalam memprediksi perubahan harga yang terjadi secara tiba tiba dan ekstrem. Dengan demikian, optimasi *hyperparameter* dapat meningkatkan performa pada pengujian internal, tetapi konfigurasi terbaik tetap perlu diuji pada data baru untuk memastikan kemampuan generalisasi model.

#### DAFTAR PUSTAKA

- Andi, M. B., & Suhirman. (2025). Penerapan Long Short-Term Memory untuk Prediksi Harga Mingguan Bitcoin Data Historis. *Jurnal Pustaka AI*, 5(3), 688–694. <https://doi.org/10.55382/jurnalpustakaai.v5i3.1582>
- Aprianto, K., Mahdiyah, U., & Wulanningrum, R. (2025). Analisis Perbandingan Model PSO-LSTM dan LSTM Konvensional untuk Prediksi Harga Bitcoin di Market Cryptocurrency. *Jurnal Inovasi Teknologi*, 9, 1733–1742. <https://proceeding.unpkediri.ac.id/index.php/inotek/>
- Bischi, B., Richter, J., Becker, M., Binder, M., & Pielok, T. (2023). *Hyperparameter optimization: Foundations, algorithms, best practices, and open challenges*. November 2022, 1–43. <https://doi.org/10.1002/widm.1484>
- Boongasame, L., & Songram, P. (2023). Cryptocurrency price forecasting method using long short-term memory with time-varying parameters. *Indonesian Journal of Electrical Engineering and Computer Science*, 30(1), 435–443. <https://doi.org/10.11591/ijeecs.v30.i1.pp435-443>
- Duha, A. M., & Putra, A. T. (2025). Optimasi Hyperparameter Pada Model Hybrid Bidirectional LSTM-GRU Untuk Prediksi Harga Saham Bank. 6(1), 332–341. <https://doi.org/10.47065/bulletincsr.v6i1.903>
- Febriansyah, F., Sujjada, A., & Sembiring, F. (2024). Prediksi Harga Bitcoin Menggunakan Algoritma Long Short Term Memory (LSTM). *INOVTEK Polbeng - Seri Informatika*, 9(1), 55–65. <https://doi.org/10.35314/isi.v9i1.4247>
- Fitriani, D. S., & Ummah, K. R. (2026). Penerapan Sistem Ensemble Learning Untuk Analisis Sentiment Pembaruan One UI 7 Pada Perangkat Samsung Menggunakan Algoritma Naive Bayes, SVM, LSTM, BI-LSTM, Dan Indobert.
- Hidayah, A. K., & Putra, R. E. (2024). Penerapan Metode Long Short Term Memory untuk Memprediksi Harga Beras di Indonesia. 06, 720–729.
- Ingolfsson, T. M. (2021). *Insights into LSTM architecture*. [https://thorirmar.com/post/insight\\_into\\_lstm/](https://thorirmar.com/post/insight_into_lstm/)
- Kaur, R., Uppal, M., Gupta, D., Juneja, S., Arafat, S. Y., Rashid, J., Kim, J., & Alroobaea, R. (2025). Development of a cryptocurrency price prediction model: leveraging GRU and LSTM for Bitcoin, Litecoin and Ethereum. *PeerJ Computer Science*, 11, 1–30. <https://doi.org/10.7717/peerj-cs.2675>
- Kervanci, I. S., Akay, M. F., & Ozceylan, E. (2024). (Communicated by Gerhard-Wilhelm Weber). 20(2), 570–588. <https://doi.org/10.3934/jimo.2023091>
- Lusiara, R., & Thamrin, H. (2025). Analisis Dan visualisasi Data Stunting Di Kecamatan Indramayu Menggunakan Python. *Artikel Journal*.
- Muhammadiyah. (2026). *Fatwa Majelis Tarjih Dan Tajdid Pimpinan Pusat Muhammadiyah Tentang Kripto Sebagai Aset Keuangan Digital*.
- Munir, M. S., Maariful Huda, M., & Prabowo, T. (2025). Prediksi Harga Dan Kinerja Aset Bitcoin Menggunakan Algoritma Long Short-Term Memory. *Jurnal Fasilkom*, 15(1), 68–76. <https://doi.org/10.37859/jf.v15i1.8902>
- Nakamoto, S. (2008). *Bitcoin: A Peer-to-Peer Electronic Cash System*. <https://bitcoin.org/bitcoin.pdf>
- Nugraha, D. M., & Ariatmanto, D. (2025). Meningkatkan Akurasi Prediksi Harga Bitcoin dengan Algoritma GRU-LSTM Hibrida. 11(April).

- Ogunsanya, M., Isichei, J., & Desai, S. (2023). Grid search hyperparameter tuning in additive manufacturing processes. *Manufacturing Letters*, 35, 1031–1042. <https://doi.org/https://doi.org/10.1016/j.mfglet.2023.08.056>
- Tripathi, B., & Kumar, R. (2023). Modeling Bitcoin Prices using Signal Processing Methods , Optimization, Bayesian Networks, Deep Neural. *Computational Economics*, 62(4), 1919–1945. <https://doi.org/10.1007/s10614-022-10325-8>
- Widiarto, K. A., & Pamungkas, E. W. (2024). *Implementasi Algoritma LSTM Untuk Prediksi Harga Saham Pada Situs Yahoo Finance Dengan Menerapkan Microservice*. 32(3), 167–186.
- Zhang, Y., & Tumibay, G. M. (2024). Stock Price Prediction Based on the Bi-GRU-Attention Model. *Journal of Computer and Communications*, 12(04), 72–85. <https://doi.org/10.4236/jcc.2024.124007>

