Journal of Innovative and Creativity
Journal Homepage: https://joecy.org/index.php/joecy
e-mail: journaljoecy@gmail.com

Faculty of Education
University of Pahlawan Tuanku Tambusai
ISSN 2776-771X (Online)
ISSN 2962-570X (Printed)
6 (2) 2026, Page: 31385-31395

PREDIKSI HARGA CRYPTOCURRENCY XRP MENGGUNAKAN METODE LONG SHORT-TERM MEMORY (LSTM) DENGAN BAYESIAN OPTIMIZATION

Muhammad Resa Oktavianto[1], Hidayatus Sibyan[2], Dimas Prasetyo Utomo[3]

[1,2,3] Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Sains Al-Qur'an, Wonosobo

Corresponding Author: Muhammad Resa Oktavianto, e-mail: rezaoktaviantomuhammad@gmail.com

Published: May , 2026

ABSTRAK

Volatilitas harga cryptocurrency XRP yang sangat tinggi menjadi tantangan utama bagi investor dalam pengambilan keputusan investasi. Penelitian ini membangun model prediksi harga XRP/USD menggunakan Long Short-Term Memory (LSTM) yang dioptimasi dengan Bayesian Optimization (BO-LSTM). Data harga penutupan harian XRP/USD dari Yahoo Finance periode 14 April 2021 hingga 13 April 2026 sebanyak 1.823 data dibagi dengan proporsi 60% pelatihan, 20% validasi, dan 20% pengujian. Optimasi hyperparameter dilakukan dengan 50 trial menggunakan Optuna mencakup enam parameter. Model BO-LSTM menghasilkan MAPE 3,0846% (highly accurate forecasting), MAE 0,0703 USD, RMSE 0,0984 USD, dan akurasi 96,92%, dengan penurunan MAPE sebesar 82,13% dibandingkan model LSTM baseline.

Kata Kunci: Cryptocurrency, XRP, Long Short-Term Memory, Bayesian Optimization, Prediksi Harga

ABSTRACT

The highly volatile price of XRP cryptocurrency poses a major challenge for investors in making investment decisions. This study develops an XRP/USD price prediction model using Long Short-Term Memory (LSTM) optimized with Bayesian Optimization (BO-LSTM). Daily dosing prices from Yahoo Finance (April 14, 2021 – April 13, 2026) totaling 1,823 records were split into 60% training, 20% validation, and 20% testing. Hyperparameter optimization was conducted with 50 trials via Optuna covering six parameters. The BO-LSTM model achieved MAPE of 3.0846% (highly accurate), MAE of 0.0703 USD, RMSE of 0.0984 USD, and accuracy of 96.92%, reducing MAPE by 82.13% compared to the baseline LSTM.

Keywords: Cryptocurrency, XRP, Long Short-Term Memory, Bayesian Optimization, Price Prediction.

© The Author(s). 2021 Open Access This article is licensed under a Creative Commons Atibution 4.0 International License, which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source, provide a link to the Creative Commons licence, and indicate if changes were made. The images or other third party material in this article are included in the article's Creative Commons licence, unless indicated otherwise in a credit line to the material. To view a copy of this licence, visit http://creativecommons.org/licenses/by/4.0

PENDAHULUAN

Cryptocurrency merupakan aset digital berbasis teknologi blockchain yang beroperasi secara terdesentralisasi dan diantara berbagai aset kripto, XRP menempati posisi strategis sebagai cryptocurrency yang digunakan oleh jaringan ripple untuk memfasilitasi transaksi lintas batas secara cepat dan berbiaya rendah(Islam et al., 2022). Di Indonesia, cryptocurrency diakui sebagai komoditas digital yang dapat diperdagangkan secara legal di bursa berjangka, mendorong pertumbuhan investor kripto domestik dari tahun ke tahun (Handayani et al., 2025). Berdasarkan data Yahoo Finance (2024) harga XRP/USD mengalami kenaikan dari $0,48 pada Januari 2024 menjadi $0,62 pada Maret 2024, kemudian turun ke $0,51 pada Mei 2024 hanya dalam lima bulan. Volatilitas ini dipengaruhi sentimen pasar global, kebijakan regulasi seperti SEC, tingkat adopsi RippleNet, serta kondisi makroekonomi global. Rahmawan dan Mafruhat (2023) yang menyimpulkan bahwa cryptocurrency memiliki dampak

positif berupa kemudahan akses dan efisiensi transaksi lintas batas, namun sekaligus membawa dampak negatif berupa ketidakstabilan nilai tukar yang dapat mengganggu stabilitas sistem keuangan. Kondisi ini menjadikan prediksi harga sebagai kebutuhan penting bagi investor, karena tanpa acuan prediksi yang memadai, investor cenderung mengambil keputusan berbasis spekulasi yang berisiko menyebabkan *buy high* atau *sell low*, sehingga mengakibatkan kerugian langsung pada portofolio.

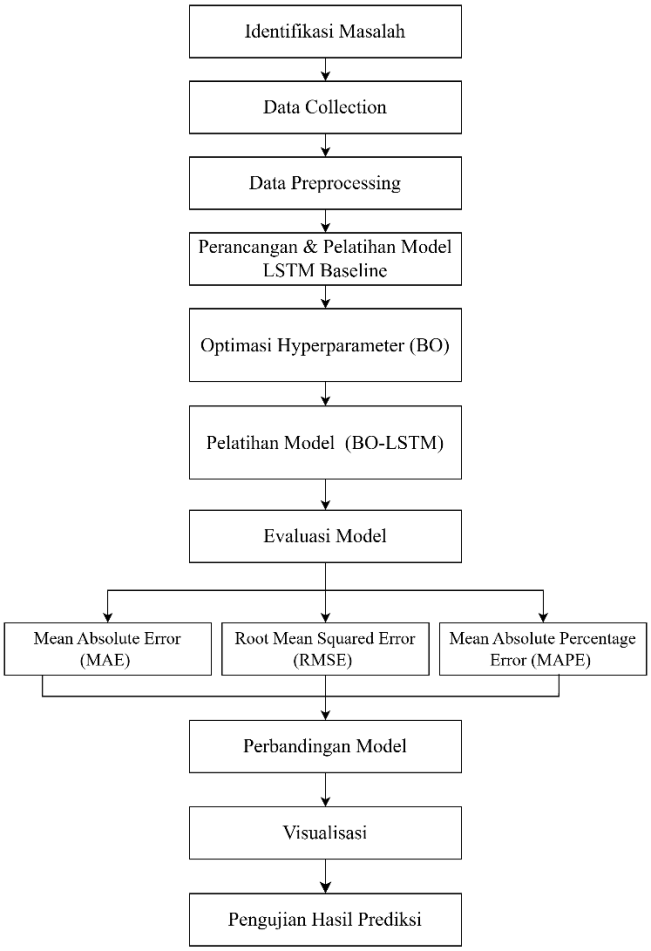
Oleh karena itu, diperlukan pendekatan prediksi harga yang memadai untuk membantu investor membuat keputusan yang lebih rasional dan berbasis data, salah satunya melalui pendekatan deep learning. *Long Short-Term Memory* (LSTM), sebagai arsitektur *Recurrent Neural Network* (RNN), dirancang untuk mengatasi masalah *vanishing gradient* dan mampu mempelajari ketergantungan data jangka panjang melalui mekanisme gerbang (*forget gate, input gate, output gate*). Kemampuan LSTM dalam menangkap dependensi temporal jangka panjang menjadikannya sangat efektif untuk memodelkan pola nonlinear data harga kripto yang bersifat fluktuatif.

Rizkilloh dan Widiyanesti (2022) memprediksi harga lima aset kripto (BNB, ETH, BTC, ADA, DOGE) menggunakan LSTM dan menghasilkan nilai RMSE yang bervariasi antar aset, dengan RMSE terbaik 0,0544 pada koin DOGE dan RMSE tertinggi 61,886 pada Epoch 20 pada koin BNB, namun penelitian ini belum menyertakan *tuning* hyperparameter sistematis dan hanya menggunakan RMSE sebagai metrik evaluasi. Nirraca dan Hartati (2024) memprediksi harga Bitcoin dengan rata-rata RMSE 1.304,3, MSE 1799568,14 dan MAE 910,85, tetapi pemilihan hyperparameter masih dilakukan secara manual. Dapubeang dan Malahina (2025) membandingkan LSTM dan GRU pada data XRP dengan pemilihan hyperparameter secara manual melalui variasi parameter tanpa menggunakan metode optimasi otomatis. Ketiga penelitian tersebut memiliki celah serupa hyperparameter dipilih secara manual, evaluasi terbatas pada satu atau dua metrik, dan belum ada yang mengombinasikan optimasi hyperparameter otomatis dengan LSTM secara khusus pada aset XRP.

Untuk mengatasi celah tersebut, Bayesian Optimization (BO) dipilih sebagai solusi optimasi hyperparameter yang lebih sistematis. Bayesian Optimization (BO) merupakan metode pencarian hyperparameter berbasis probabilistik menggunakan *surrogate model Gaussian Process* dan *acquisition function Expected Improvement*, yang terbukti lebih efisien dibandingkan *Grid Search* maupun *Random Search* (Yu & Zhu, 2020). Habtemariam et al. (2023) membuktikan bahwa BO-LSTM mampu meningkatkan akurasi prediksi daya angin pada data nonlinear dibandingkan LSTM tanpa optimasi. Almuhaini dan Sultana (2023) menerapkan BO-LSTM untuk peramalan konsumsi listrik jangka panjang dan menghasilkan akurasi yang superior dibandingkan metode regresi konvensional. Simamora et al. (2025) mengonfirmasi bahwa Bayesian Optimization mampu menemukan konfigurasi *hyperparameter* optimal pada model BiLSTM untuk prediksi harga saham dengan MAPE terbaik sebesar 1,2027%, lebih rendah dibandingkan model *Grid Search*-BiLSTM yang menghasilkan MAPE 10,83%. Meskipun ketiga penelitian tersebut membuktikan efektivitas BO-LSTM di berbagai domain, penerapannya secara khusus pada prediksi harga XRP masih sangat terbatas. Penelitian ini mengembangkan model BO-LSTM menggunakan optuna dengan ruang pencarian beberapa hyperparameter (*Window, Units, Dropout, Learning Rate, Batch Size, Epoch*) pada data harga XRP/USD, dan mengevaluasi performanya secara komprehensif menggunakan tiga metrik (RMSE, MAE, MAPE) dibandingkan model LSTM baseline.

METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen komputasional berbasis *time series forecasting* dengan membandingkan model LSTM sebelum dan sesudah optimasi hyperparameter menggunakan Bayesian Optimization. Penelitian dilaksanakan pada lingkungan Google Colaboratory dan Visual Studio Code. Gambar 1 menunjukkan alur penelitian secara keseluruhan.



Gambar 1. Alur Penelitian

1. Identifikasi Masalah

Langkah pertama adalah mengidentifikasi permasalahan utama penelitian, yaitu bagaimana memprediksi harga XRP/USD menggunakan algoritma LSTM. Tujuannya adalah mengetahui tingkat akurasi model menggunakan MAPE sebagai metrik utama, serta MAE dan RMSE sebagai metrik tambahan.

2. Data Collection

Data historis harga XRP/USD diperoleh dari Yahoo Finance menggunakan pustaka yfinance pada Python dengan periode 14 April 2021 hingga 13 April 2026 berfrekuensi harian, menghasilkan 1.825 baris data (Yahoo Finance, 2024). Pemilihan XRP sebagai objek penelitian didasarkan pada posisinya sebagai salah satu cryptocurrency dengan kapitalisasi pasar terbesar yang dirancang khusus untuk transaksi lintas batas melalui jaringan RippleNet, sehingga memiliki karakteristik volatilitas yang representatif untuk dimodelkan. Periode April 2021 hingga April 2026 dipilih karena mencakup berbagai kondisi pasar kripto yang beragam, termasuk periode *bull market, bear market,* dan pemulihan, sehingga data yang digunakan cukup representatif untuk pelatihan model prediksi. Dataset memuat atribut *Open, High, Low, Close*, dan *Volume* (Yahoo Finance, 2024). Pada penelitian ini hanya kolom *Date* dan *Close* yang digunakan karena harga penutupan menjadi acuan harga pembukaan di hari berikutnya sehingga paling representatif sebagai data input prediksi(Julian & Pribadi, 2021).

3. Data Preprocessing

Tahap praproses data mencakup beberapa proses utama untuk mempersiapkan data mentah menjadi dataset yang siap digunakan dalam pemodelan.

a. Data Cleaning

Proses data cleaning dilakukan untuk memastikan integritas dataset dengan menangani data duplikat yang dapat menyebabkan bias pada model dan mengganggu urutan data deret waktu.

b. Data Splitting

Dataset dibagi secara berurutan (time series split) untuk menjaga karakteristik temporal data dengan proporsi 60% pelatihan, 20% validasi, dan 20% pengujian. Rumus pembagian dataset adalah:

$$D_{train} = N \times p_{train} \quad (1)$$

$$D_{val} = N \times p_{val} \quad (2)$$

$$D_{test} = N \times p_{test} \quad (3)$$

Keterangan:

- D : Jumlah data
- N : Total jumlah keseluruhan data
- P : Proporsi Data

c. Feature Scaling

Feature scaling dilakukan menggunakan metode *Min-Max Normalization* melalui *MinMaxScaler* dari Scikit-learn untuk menormalkan data ke rentang [0, 1]. Proses fitting scaler hanya dilakukan pada data pelatihan untuk menghindari *data leakage*, kemudian diterapkan pada data validasi dan pengujian. Rumusnya adalah:

$$X_{scaled} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (4)$$

Keterangan

- X_{scaled} : Nilai data setelah melalui proses normalisasi.
- X : Nilai data asli.
- X_{min} : Nilai minimum dari keseluruhan data pada fitur tersebut.
- X_{max} : Nilai maksimum dari keseluruhan data pada fitur tersebut.

d. Data Windowing

Data windowing mengubah data deret waktu menjadi format supervised learning menggunakan teknik *sliding window*. Setiap sampel input X terdiri dari W nilai historis berurutan dan satu nilai target Y sebagai nilai prediksi periode berikutnya.

4. Perancangan dan Pelatihan Model LSTM Baseline

Model baseline dirancang sebagai acuan performa awal dengan arsitektur bertingkat yang terdiri dari dua lapisan LSTM, lapisan Dropout, dan lapisan Dense sebagai output. Seluruh parameter model ditetapkan secara manual meliputi window size, learning rate, batch size, dan epoch. Model dilatih menggunakan fungsi loss Mean Squared Error (MSE) dan optimizer Adam dengan data validasi sebagai pemantau overfitting.

5. Optimasi Hyperparameter (BO)

Optimasi hyperparameter dilakukan menggunakan Bayesian Optimization melalui library Optuna. Ruang pencarian didefinisikan untuk beberapa hyperparameter meliputi window size, jumlah unit pada setiap lapisan LSTM, dropout rate, learning rate, dan batch size. MAPE digunakan sebagai *objective function* yang diminimalkan menggunakan data validasi.

6. Pelatihan Model BO-LSTM

Setelah hyperparameter terbaik diperoleh, model BO-LSTM dirancang ulang menggunakan parameter optimal tersebut. Arsitektur BO-LSTM dengan jumlah unit yang ditetapkan berdasarkan hasil optimasi. Pada pelatihan final, data pelatihan dan data validasi digabungkan untuk memaksimalkan jumlah data pembelajaran, kemudian dievaluasi pada data pengujian yang sepenuhnya terpisah

7. Evaluasi Model

Evaluasi dilakukan pada model baseline dan BO-LSTM menggunakan tiga metrik kuantitatif berikut:

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i| \quad (5)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \quad (6)$$

$$MAPE = \sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right| \times 100\% \quad (7)$$

Keterangan:

- n : Jumlah total sampel data
- y_i : Nilai aktual harga penutupan XRP data ke-*i*
- $\hat{y}_i$: Nilai prediksi harga penutupan XRP data ke-*i*

Interpretasi tingkat akurasi mengacu pada kategori MAPE Lewis (Montaño Moreno et al., 2013) sebagaimana ditunjukkan pada Tabel 1.

Tabel 1. Interpretasi Nilai MAPE

Skala MAPE	Interpretasi
< 10%	Sangat Akurat (*Highly Accurate*)
10% - 20%	Akurat (*Good Forecasting*)
20% - 50%	Cukup (*Reasonable Forecasting*)
> 50%	Tidak Akurat (*Inaccurate*)

8. Perbandingan Model

Setelah kedua model dievaluasi, dilakukan perbandingan performa antara model LSTM baseline dan model BO-LSTM menggunakan metrik MAE, RMSE, dan MAPE untuk mengetahui seberapa besar optimasi hyperparameter meningkatkan akurasi prediksi.

9. Visualisasi

Hasil prediksi dari kedua model divisualisasikan dalam bentuk grafik perbandingan antara nilai aktual dan nilai prediksi pada data pengujian menggunakan library Matplotlib dan Plotly untuk memberikan gambaran intuitif mengenai kemampuan model dalam mengikuti tren harga XRP.

10. Pengujian Hasil Prediksi

Pengujian dilakukan terhadap 10 data terakhir pada test set untuk memvalidasi kemampuan generalisasi model BO-LSTM pada data yang belum pernah dilihat sebelumnya. Kategori akurasi ditentukan berdasarkan threshold yang ditetapkan dari nilai MAPE model BO-LSTM yang dibulatkan satu desimal, sehingga setiap data prediksi dapat diklasifikasikan sebagai akurat atau tidak akurat.

HASIL DAN PEMBAHASAN

1. Data Collection

Data historis harga XRP/USD berhasil diunduh dari Yahoo Finance menggunakan library yfinance pada Google Colab. Proses pengambilan data menghasilkan total 1.825 baris data harian untuk periode 14 April 2021 hingga 13 April 2026. Dari seluruh atribut yang tersedia, yaitu *Open, High, Low, Close,* dan *Volume,* hanya kolom *Date* dan *Close* yang digunakan sebagai variabel target prediksi karena harga penutupan mencerminkan nilai akhir kesepakatan pasar pada setiap hari perdagangan. Tabel 2 menampilkan sampel data teratas hasil pengumpulan.

Tabel 2. Sampel Data Harga Harian XRP/USD

Date	Close (USD)

2021-04-14	1,839236
2021-04-15	1,766067
2021-04-16	1,557527
2021-04-17	1,560055
2021-04-18	1,405998

2. *Data Preprocessing*

a. *Data Cleaning*

Hasil pengecekan duplikasi data menemukan 2 baris data duplikat yang kemudian dihapus. Setelah proses ini, jumlah data berkurang dari 1.825 menjadi 1.823 baris data bersih. Selanjutnya dilakukan pengecekan missing value pada kolom *Close*, dan hasilnya menunjukkan tidak ada nilai kosong sehingga dataset dinyatakan lengkap dan siap dilanjutkan ke tahap berikutnya.

b. *Data Splitting*

Berdasarkan total N = 1.823 baris data bersih dengan proporsi 60:20:20, menghasilkan 1.093 data pelatihan, 364 data validasi, dan 366 data pengujian. Pembagian dilakukan secara berurutan untuk mempertahankan karakteristik temporal data deret waktu.

c. *Feature Scaling*

Proses normalisasi menggunakan MinMaxScaler menghasilkan dataset dengan rentang nilai [0, 1]. Scaler hanya di-fit pada data pelatihan untuk mencegah data leakage, kemudian ditransformasikan ke seluruh subset. Berdasarkan data pelatihan diperoleh X_min = 0,308090 dan X_max = 1,839236. Tabel 3 menampilkan sampel perbandingan nilai harga asli dengan nilai setelah normalisasi.

Tabel 3. Sampel Data Setelah Normalisasi MinMaxScaler

Date	Harga Asli (USD)	Nilai Setelah Scaling
2021-04-14	1,839236	1,000000
2021-07-12	0,630178	0,210357
……..	……	……
2023-08-07	0,621931	0,204971
2024-04-05	0,587523	0,182499

d. *Data Windowing*

Proses sliding window mengubah data deret waktu menjadi format *supervised learning*. Setiap sampel terdiri atas W nilai input berurutan dan satu nilai target yang merupakan harga pada periode berikutnya. Model baseline menggunakan window size W = 20, sedangkan model BO-LSTM menggunakan W = 44 yang diperoleh dari proses optimasi.

3. *Perancangan dan Pelatihan Model LSTM Baseline*

Model baseline dibangun dengan arsitektur bertingkat yang terdiri atas lapisan Input, dua lapisan LSTM dengan masing-masing 16 dan 8 neuron, dua lapisan Dropout dengan nilai 0,4, serta lapisan Dense sebagai output. Model dilatih selama 30 epoch dengan batch size 64, learning rate 0,01, dan optimizer Adam menggunakan data pelatihan, sementara data validasi digunakan sebagai pemantau overfitting. Pada epoch pertama, training loss tercatat 0,0167 dan validation loss 0,1236 yang menunjukkan generalisasi awal yang belum optimal. Seiring pelatihan berlanjut, pada epoch ke-30 training loss turun menjadi 0,0035 dan validation loss menjadi 0,0678, namun validation

loss menunjukkan fluktuasi yang cukup besar sepanjang pelatihan, mengindikasikan generalisasi model yang belum sepenuhnya stabil.

Tabel 4. Sampel Proses Pelatihan Model LSTM Baseline

Epoch	Training Loss	Validation Loss
1	0,0167	0,1236
5	0,0052	0,0804
9	0,0041	0,0638
10	0,0038	0,0687
15	0,0044	0,0715
20	0,0032	0,0710
25	0,0034	0,0635
27	0,0038	0,0563
30	0,0035	0,0678

4. Optimasi Hyperparameter (BO)

Proses optimasi hyperparameter dilakukan sebanyak 50 trial menggunakan library Optuna. Setiap trial mengevaluasi kombinasi hyperparameter yang berbeda pada data validasi dengan MAPE sebagai objective function yang diminimalkan. Tabel 5 menyajikan sampel hasil *trial* yang representatif dari keseluruhan proses optimasi, termasuk *trial* terbaik.

Tabel 5. Sampel Hasil Trial Bayesian Optimization

Trial	W	U1	U2	Dropout	LR	BS	Epoch	MAPE Val (%)
1	34	125	56	0,19	0,00082	16	48	4,6682
2	40	110	32	0,25	0,00168	16	33	5,2208
3	32	98	46	0,14	0,00133	32	37	7,3654
4	36	115	38	0,18	0,00130	32	33	4,3638
5	26	125	63	0,22	0,00096	32	39	4,7177
10	25	117	55	0,21	0,00157	32	32	3,9694
11	49	64	51	0,10	0,00155	32	30	3,6912
14	50	66	52	0,10	0,00197	32	44	3,6811
15	45	83	51	0,13	0,00191	32	44	3,5973
21	47	81	53	0,12	0,00172	32	46	3,5042
37	48	68	55	0,17	0,00175	16	38	3,5253
46	44	121	52	0,12	0,00070	16	42	3,4788
50	48	83	37	0,12	0,00150	16	49	3,4909

Trial ke-46 menghasilkan nilai MAPE validasi terbaik sebesar 3,4788% dengan kombinasi hyperparameter optimal sebagaimana ditunjukkan pada Tabel 6.

Tabel 6. Hyperparameter Terbaik Hasil Bayesian Optimization

Hyperparameter	Ruang Pencarian	Nilai Optimal
Window	25 - 50	44
Units Layer 1	64 - 128	121
Units Layer 2	32 - 64	52
Dropout	0,10 - 0,25	0,12
Learning Rate	0,0007 - 0,002	0,000703
Batch Size	16, 32	16
Epoch	30 - 50	42
MAPE		3,4788%

Hyperparameter terbaik pada trial ke-46 dengan MAPE validasi 3,4788%. Window size 44 dipilih karena memungkinkan model melihat data historis yang lebih panjang sehingga pola harga XRP dapat ditangkap dengan lebih baik. Jumlah unit 121 pada lapisan LSTM pertama dan 52 pada lapisan kedua memberikan kapasitas yang cukup bagi model untuk mempelajari pola yang kompleks. Dropout rate 0,12 yang kecil menunjukkan bahwa regularisasi berlebihan tidak diperlukan pada data ini. Learning rate 0,000703 dan batch size 16 membantu model belajar secara lebih hati-hati dan stabil. Dari 50 trial yang dijalankan, Bayesian Optimization berhasil menemukan kombinasi terbaik secara efisien karena setiap trial memanfaatkan informasi dari trial sebelumnya, berbeda dengan Grid Search yang mencoba semua kombinasi secara acak tanpa arah.

5. Pelatihan Model BO-LSTM

Berdasarkan hyperparameter terbaik tersebut, model BO-LSTM dibangun dengan arsitektur: Input LSTM(121) dropout(0,12), LSTM(52) dropout(0,12) , Dense(32, ReLU) dense(1). Model kemudian dilatih menggunakan data gabungan pelatihan dan validasi yang berjumlah 1.457 data untuk memaksimalkan informasi yang dipelajari. Proses pelatihan berlangsung selama 42 epoch dan menunjukkan konvergensi yang stabil, dengan training loss turun dari 0,0212 pada epoch pertama hingga 0,0025 pada epoch terakhir tanpa indikasi overfitting yang berarti.

Tabel 7. Sampel Proses Pelatihan Model BO-LSTM

Epoch	Training Loss	Learning Rate
1	0,0212	0,000703
5	0,0071	0,000703
10	0,0042	0,000703
16	0,0032	0,000703
22	0,0029	0,000703
30	0,0029	0,000703
31	0,0029	0,000352
34	0,0024	0,000352
36	0,0023	0,000352
42	0,0025	0,000352

6. Evaluasi Model

a. Evaluasi Model LSTM Baseline

Model baseline dievaluasi menggunakan 346 data uji. Hasil evaluasi menunjukkan performa yang terbatas dalam mengikuti pergerakan harga XRP, terutama pada periode awal

pengujian. Model baseline memperoleh MAE 0,4401 USD, RMSE 0,5423 USD, MAPE 17,2608%, dan akurasi 82,7392% yang masuk kategori *Good Forecasting* berdasarkan kriteria MAPE yang di kembangkan Lewis (Montaño Moreno et al., 2013).

b. Evaluasi Model BO-LSTM

Model BO-LSTM dievaluasi menggunakan 322 data uji. Hasil evaluasi menunjukkan peningkatan performa yang signifikan, dengan garis prediksi yang mampu mengikuti pola harga aktual XRP secara konsisten sepanjang periode pengujian. Model BO-LSTM memperoleh MAE 0,0703 USD, RMSE 0,0984 USD, MAPE 3,0846%, dan akurasi 96,9154% yang masuk kategori *Highly Accurate Forecasting* berdasarkan kriteria MAPE yang di kembangkan Lewis (Montaño Moreno et al., 2013).

7. Perbandingan Model

Tabel 8 menyajikan perbandingan hasil evaluasi antara model LSTM Baseline dan BO-LSTM pada seluruh metrik yang digunakan.

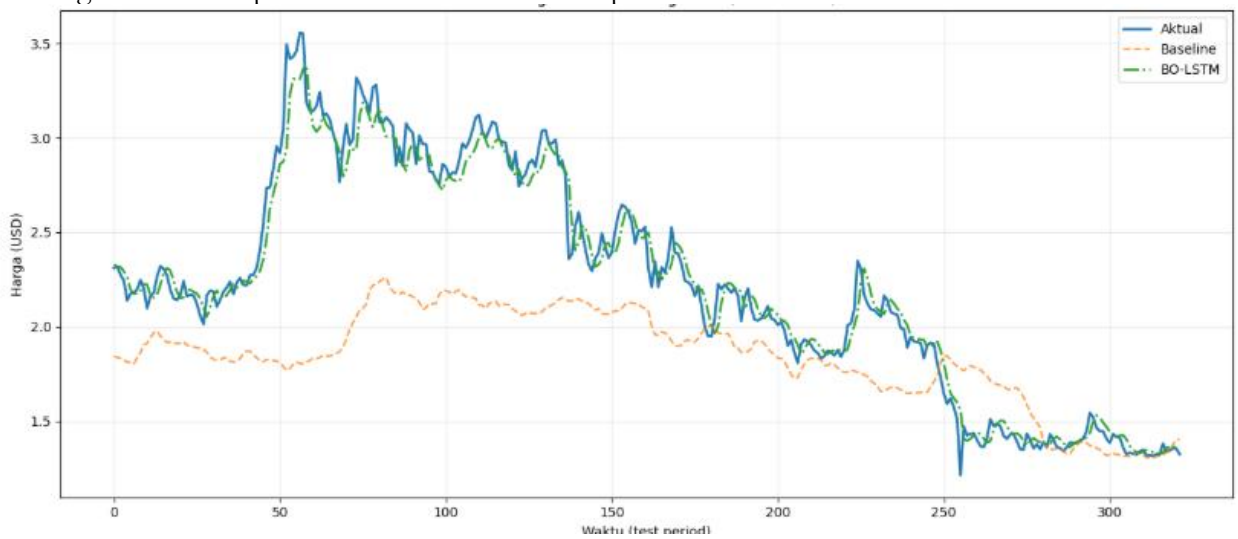
Tabel 8. Perbandingan Hasil Evaluasi Model

Metrik	Baseline LSTM	BO-LSTM	Penurunan/Peningkatan
MAE (USD)	0,4401	0,0703	Turun 84,02%
RMSE (USD)	0,5423	0,0984	Turun 81,86%
MAPE (%)	17,2608	3,0846	Turun 82,13%
Akurasi (%)	82,7392	96,9154	Naik 14,18%
Kategori MAPE	*Good Forecasting* (10-20%)	*Highly Accurate* (< 10%)	

Berdasarkan Tabel 8, model BO-LSTM secara konsisten lebih baik dari model baseline pada seluruh metrik evaluasi. MAE turun 84,02%, RMSE turun 81,86%, dan MAPE turun 82,13%, sementara akurasi meningkat 14,18 poin persentase menjadi 96,9154%. Penurunan error lebih dari 80% pada seluruh metrik membuktikan bahwa Bayesian Optimization secara signifikan meningkatkan performa model LSTM dalam memprediksi harga XRP. Nilai MAPE 3,0846% menempatkan model BO-LSTM pada kategori *Highly Accurate Forecasting* (MAPE < 10%), meningkat dari kategori *Good Forecasting* (10–20%) yang diperoleh model baseline.

8. Visualisasi

Hasil prediksi model BO-LSTM divisualisasikan dalam bentuk grafik perbandingan antara nilai aktual dan nilai prediksi pada data pengujian. Gambar 2 menampilkan grafik perbandingan harga aktual dan prediksi model baseline dan prediksi model BO-LSTM.



Gambar 2. Perbandingan Harga Aktual dan Prediksi Model Baseline & BO-LSTM

Berdasarkan Gambar 2, grafik prediksi model baseline memperlihatkan pola yang cenderung tertinggal dalam mengikuti pergerakan harga aktual, khususnya pada periode awal pengujian ketika harga XRP bergerak dengan cepat. Hal ini tercermin dari gap yang cukup lebar antara garis prediksi dan garis aktual yang berkontribusi pada nilai MAPE sebesar 17,2608%. Sebaliknya, grafik prediksi model BO-LSTM memperlihatkan kemampuan yang jauh lebih baik dalam mengikuti pola pergerakan harga aktual XRP. Garis prediksi terlihat sangat berdekatan dengan garis aktual sepanjang seluruh periode pengujian, termasuk pada saat terjadi fluktuasi tajam. Hasil ini konsisten dengan nilai MAPE 3,0846% yang masuk kategori *highly accurate forecasting*.

9. Pengujian Hasil Prediksi

Pengujian dilakukan terhadap 10 data terakhir pada test set yang belum pernah dilihat model. Threshold yang digunakan adalah <= 3,1% berdasarkan nilai MAPE model BO-LSTM sebesar 3,0846% yang dibulatkan satu desimal.

Tabel 9. Pengujian Hasil Prediksi BO-LSTM (10 Data Terakhir)

No	Tanggal	Aktual (USD)	Prediksi (USD)	Selisih	Error (%)	Kategori
1	2026-04-02	1,3187	1,3476	-0,0289	-2,19%	Akurat
2	2026-04-03	1,3179	1,3426	-0,0247	-1,87%	Akurat
3	2026-04-04	1,3156	1,3352	-0,0196	-1,49%	Akurat
4	2026-04-05	1,3255	1,3289	-0,0034	-0,26%	Akurat
5	2026-04-06	1,3212	1,3298	-0,0086	-0,65%	Akurat
6	2026-04-07	1,3815	1,3307	0,0508	3,68%	Tidak Akurat
7	2026-04-08	1,3424	1,3574	-0,0151	-1,12%	Akurat
8	2026-04-09	1,3441	1,3635	-0,0193	-1,44%	Akurat
9	2026-04-10	1,3566	1,3624	-0,0058	-0,43%	Akurat
10	2026-04-11	1,3554	1,3649	-0,0094	-0,69%	Akurat

Dari 10 data yang diuji, sebanyak 9 data masuk kategori akurat sehingga tingkat kesesuaian mencapai 90,00%. Satu-satunya data yang tidak akurat terjadi pada tanggal 2026-04-07 dengan nilai error 3,68% yang sedikit melampaui threshold. Penyebabnya adalah lonjakan harga yang tidak terpola pada hari tersebut, yang merupakan karakteristik umum aset kripto bervolatilitas tinggi.

KESIMPULAN

Penelitian ini membuktikan bahwa penerapan Bayesian Optimization secara signifikan meningkatkan performa model LSTM dalam memprediksi harga XRP/USD. Model BO-LSTM yang dihasilkan mencapai akurasi 96,92% dengan MAPE 3,0846% yang masuk kategori highly accurate forecasting, MAE 0,0703 USD, dan RMSE 0,0984 USD. Hasil ini jauh lebih baik dari model baseline yang hanya mencapai akurasi 82,74% dengan MAPE 17,2608%, dengan penurunan error rata-rata lebih dari 82% pada seluruh metrik evaluasi. Pengujian terhadap 10 data terakhir menunjukkan tingkat kesesuaian 90%, memvalidasi kemampuan generalisasi model pada data yang belum pernah dilihat sebelumnya. Penelitian ini membuktikan bahwa kombinasi LSTM dan Bayesian Optimization merupakan pendekatan yang baik untuk memprediksi harga aset kripto yang bersifat volatil dan nonlinear.

REFERENCES

Almuhaini, S. H., & Sultana, N. (2023). Bayesian-optimization-based LSTM super learner for long-term electricity consumption. Sustainability, 15(18), 13409. https://doi.org/10.3390/su151813409

Dapubeang, M. S. R. A. S., & Malahina, E. U. (2025). Prediksi harga mata uang kripto XRP menggunakan LSTM dan GRU. MIFORTEKH, 5(2), 107–124. https://doi.org/10.51903/yewbm358

Habtemariam, E. T., Kekeba, K., Martinez-Ballesteros, M., & Martinez-Alvarez, F. (2023). A Bayesian optimization-based LSTM model for wind power forecasting. Energies, 16(5), 2317. https://doi.org/10.3390/en16052317

Handayani, A. T., Purnama, M., Pattiasina, F. L., & Nurliyantika, R. (2025). Tinjauan legalitas cryptocurrency dalam pertumbuhan pasar kripto di Indonesia. Jurnal Thengkyang, 10(1), 46–56.

Islam, M. R., Rashid, M. M., Rahman, M. A., Mohamad, M. H. S., & Embang, A. H. (2022). Analysis of blockchain-based Ripple and SWIFT. Asian Journal of Electrical and Electronic Engineering, 2(1). https://doi.org/10.69955/ajoeee.2022.v2i1.26

Julian, R., & Pribadi, M. R. (2021). Peramalan harga saham pertambangan menggunakan long short-term memory. JATISI, 8(3), 1570–1580. https://doi.org/10.35957/jatisi.v8i3.1159

Montaño Moreno, J. J., Palmer Pol, A., Sesé Abad, A., & Cajal Blasco, B. (2013). El índice R-MAPE como medida resistente del ajuste en la previsiońn. Psicothema, 25(4), 500–506. https://doi.org/10.7334/psicothema2013.23

Nirraca, M., & Hartati, E. (2024). Prediksi Harga Bitcoin Menggunakan Metode Long Short Term Memory. *Jurnal Digital Teknologi Informasi*, 7(1), 55–65. https://doi.org/10.32502/digital.v7i1.7974

Rahmawan, B. A., & Mafruhat, A. Y. (2023). Pengaruh cryptocurrency terhadap aktivitas ekonomi: Sebuah tinjauan pustaka sistematis. Jurnal Riset Ilmu Ekonomi dan Bisnis, 3(1), 61–68. https://doi.org/10.29313/jrieb.v3i1.1974

Rizkilloh, M. F., & Widiyanesti, S. (2022). Prediksi harga cryptocurrency menggunakan algoritma long short-term memory (LSTM). Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi), 6(1), 25–31. https://doi.org/10.29207/resti.v6i1.3630

Simamora, F. P., Purba, R., & Pasha, M. F. (2025). Optimisasi *hyperparameter* BiLSTM menggunakan Bayesian Optimization untuk prediksi harga saham. *Jambura Journal of Mathematics*, *7*(1), 8–13. https://doi.org/10.37905/jjom.v7i1.27166

Yu, T., & Zhu, H. (2020). Hyper-parameter optimization: A review of algorithms and applications. *arXiv preprint arXiv:2003.05689*.

Yahoo Finance. (2024). *XRP USD (XRP-USD) historical data.* https://finance.yahoo.com/quote/XRP-USD/history/