



ISSN : 2339 - 1871

BETRIK BESEMAH TEKNOLOGI INFORMASI & KOMPUTER

Editor Office : Pusat Penelitian & Pengabdian Pada Masyarakat
(PPPM) ITPA

Phone : 0857-9716-9578

email : betriktpa@itpa.ac.id

Prediksi *Cryptocurrency* Berbasis LSTM Menggunakan Multi Modal Indikator *Trading* (Studi: *Ethereum* dan *Solana*)

Arya Ramadhan¹, Yogi Isro Mukti², Alfis Arif³, Sigit Candra Setya⁴
Teknik Informatika, Institut Teknologi Pagar Alam, Pagar Alam, Indonesia^{1,2,3,4}
Sur-el : *cam.yak25@gmail.com¹, yogie.isro.mukti@itpa.ac.id², alfisarif@yahoo.com³,
sigitcs1969@gmail.com⁴

Penulis Korespondensi: Arya Ramadhan, cam.yak25@gmail.com

Abstrak: Perkembangan pasar *cryptocurrency* yang dinamis menyebabkan harga aset digital mengalami fluktuasi yang tinggi sehingga menyulitkan investor dalam memprediksi pergerakan harga secara akurat. Oleh karena itu, diperlukan metode analisis yang mampu memodelkan pola pergerakan harga pada data deret waktu. Penelitian ini bertujuan untuk membangun model prediksi harga *cryptocurrency Ethereum* dan *Solana* menggunakan metode *Long Short-Term Memory* (LSTM) dengan pendekatan multi modal indikator trading. Dataset yang digunakan berupa data historis harga yang mencakup harga pembukaan, tertinggi, terendah, penutupan, volume perdagangan, serta indikator teknikal seperti *Exponential Moving Average* (EMA), *Relative Strength Index* (RSI), dan *Bollinger Bands*. Proses penelitian mengikuti tahapan CRISP-DM yang meliputi *business understanding*, *data understanding*, *data preparation*, *modelling*, *evaluation*, dan *deployment*. Data diproses melalui tahap normalisasi dan pembentukan *window time series* dengan pembagian data *training* dan *testing* sebesar 80:20. Hasil evaluasi menggunakan metrik *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE) menunjukkan bahwa model memiliki performa prediksi yang baik. Model *Ethereum* menghasilkan nilai RMSE 129,08 dan MAPE 3,26%, sedangkan model *Solana* menghasilkan RMSE 8.30 dan MAPE 3.63%. Model yang dihasilkan juga diimplementasikan dalam bentuk *dashboard* berbasis *Streamlit* untuk memvisualisasikan hasil prediksi secara interaktif sehingga dapat membantu pengguna dalam memantau dan menganalisis pergerakan harga *cryptocurrency*.

Kata kunci : *Cryptocurrency*, Indikator *Trading*, *Long Short Them Memory*, Multi Aset, Prediksi

Abstract. *The dynamic development of the cryptocurrency market causes digital asset prices to experience high volatility, making it difficult for investors to accurately predict price movements. Therefore, an analytical method is needed to model price movement patterns in time series data. This study aims to develop a cryptocurrency price prediction model for Ethereum and Solana using the Long Short-Term Memory (LSTM) method with a multi-modal trading indicator approach. The dataset used consists of historical price data including open, high, low, close, trading volume, and technical indicators such as Exponential Moving Average (EMA), Relative Strength Index (RSI), and Bollinger Bands. The research process follows the CRISP-DM methodology, which includes business understanding, data understanding, data preparation, modelling, evaluation, and deployment stages. The data were processed through normalization and time series windowing, with a training and testing data split of 80:20. The evaluation results using Root Mean Square Error (RMSE) and Mean Absolute Percentage Error (MAPE) indicate*

Received: 09-03-2026 | Accepted: 27-04-2026 | Published Online: 30-04-2026

All author: Arya Ramadhan, Yogi Isro Mukti, Alfis Arif, Sigit Candra Setya

that the model has good predictive performance. The Ethereum model produced an RMSE value of 129.08 and a MAPE of 3.26%, while the Solana model produced an RMSE of 8.30 and a MAPE of 3.63%. The developed model was also implemented in a Streamlit-based dashboard to visualize prediction results interactively, helping users monitor and analyze cryptocurrency price movements.

Keywords: *Cryptocurrency, Long Short Term Memory, Multi-Asset, Prediction, Trading Indicator*

1. PENDAHULUAN

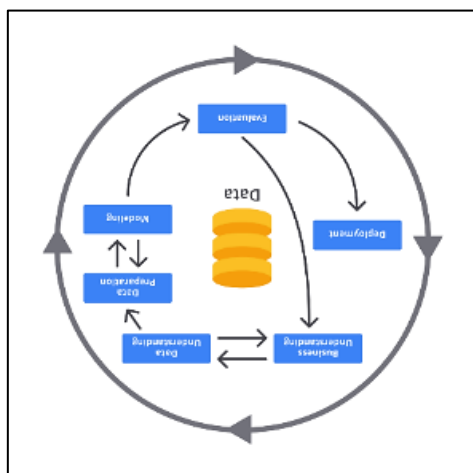
Perkembangan teknologi *blockchain* telah mendorong pertumbuhan pesat pasar *cryptocurrency* sebagai aset digital yang semakin diminati oleh investor global. Pasar *cryptocurrency* memiliki karakteristik perdagangan tanpa henti selama 24 jam, bersifat terdesentralisasi, serta menunjukkan volatilitas harga yang sangat tinggi, sehingga pergerakan harga sulit diprediksi secara akurat [1]. Aset kripto seperti *Ethereum* dan *Solana* merupakan dua *cryptocurrency* dengan kapitalisasi pasar besar yang memiliki pergerakan harga dinamis dan sensitif terhadap berbagai faktor teknikal maupun sentimen pasar [2]. Kondisi tersebut menyebabkan analisis manual dan pendekatan konvensional sering kali tidak mampu memberikan prediksi harga yang reliabel bagi pelaku pasar.

Permasalahan utama dalam prediksi harga *cryptocurrency* terletak pada keterbatasan metode statistik tradisional yang umumnya mengasumsikan data bersifat linear dan stasioner, sementara data harga kripto cenderung non-linear, fluktuatif, dan kompleks [3]. Dalam beberapa tahun terakhir, perkembangan teknologi *deep learning* membuka peluang baru dalam pemodelan data *time series*, khususnya melalui penggunaan *Long Short Term Memory* (LSTM) yang mampu menangkap ketergantungan temporal jangka pendek dan jangka panjang [4]. Selain itu, pemanfaatan indikator teknikal seperti *Exponential Moving Average* (EMA), *Bollinger Bands* (BB), dan *Relative Strength Index* (RSI) terbukti mampu merepresentasikan informasi tren, volatilitas, dan momentum pasar secara lebih komprehensif [5].

Penelitian ini mengusulkan model prediksi harga *cryptocurrency* berbasis LSTM dengan pendekatan indikator trading yang diterapkan pada dua aset kripto, yaitu *Ethereum* [6] dan *Solana* [7]. Novelty penelitian ini terletak pada integrasi data harga historis dan indikator EMA, BB serta RSI dalam model LSTM untuk skenario aset guna meningkatkan kemampuan prediksi terhadap dinamika pasar kripto yang kompleks. Hasil dari penelitian ini adalah mampu menghasilkan model prediksi harga pada *Ethereum* dan *Solana* dengan tingkat kesalahan rendah, yang diukur menggunakan metrik *Root Mean Square Error* (RMSE) [8] dan *Mean Absolute Percentage Error* (MAPE) [9].

2. METODOLOGI PENELITIAN

Metode penelitian ini dilakukan dengan melalui lima tahapan yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modelling*, *Evaluation*, dan *Deployment* seperti pada Gambar 1.



Gambar 1. Tahapan Penelitian CRISP-DM

2.1 Business Understanding

Tujuan utama dari penelitian ini adalah membangun model prediksi harga kripto menggunakan algoritma *Long Short Term Memory* dengan pendekatan indikator trading.

2.2 Data Understanding

Dataset yang digunakan dalam penelitian ini diperoleh dari platform *Yahoo Finance* dan terdiri dari data historis harga *cryptocurrency Ethereum* dan *Solana*. Data dikumpulkan dalam rentang waktu enam tahun dengan interval harian dan mencakup beberapa atribut utama, yaitu harga pembukaan (*open*), harga tertinggi (*high*), harga terendah (*low*), harga penutupan (*close*), serta volume transaksi (*volume*). Atribut-atribut tersebut merepresentasikan indikator fundamental yang umum digunakan dalam analisis teknikal untuk memahami dinamika pergerakan harga aset kripto. Selain itu, dari data historis ini dihitung sejumlah indikator teknikal [5], yaitu *Exponential Moving Average (EMA)*, *Bollinger Bands (BB)*, dan *Relative Strength Index (RSI)*, yang berfungsi untuk menangkap informasi tren, volatilitas, dan momentum pasar.

2.3 Data Preparation

Tahap ini bertujuan untuk memastikan kualitas dan kesesuaian data historis harga *cryptocurrency* sebelum digunakan pada tahap pemodelan. Dataset mentah yang diperoleh dari *Yahoo Finance* berisi atribut harga harian. Pada tahap ini dilakukan serangkaian proses untuk menyiapkan data agar dapat digunakan sebagai input model prediksi.

a) Seleksi Data

Dataset yang digunakan dalam penelitian ini merupakan data historis harga *cryptocurrency Ethereum* dan *Solana* dengan interval harian. Seluruh catatan data dipertahankan karena relevan dengana tujuan penelitian.

b) Pembersihan Data

Pembersihan data dilakukan untuk memastikan kualitas dataset sebelum proses pemodelan. Nilai yang hilang (*missing values*) pada data harga diidentifikasi dan dihapus mencegah gangguan pada proses pelatihan model.

c) Transformasi Data

Pada tahap ini, seluruh fitur numerik dinormalisasi menggunakan metode *Min-Max Scalling* untuk menskalakan nilai ke dalam rentang [0,1]. Selanjutnya data diubah ke dalam format deret waktu menggunakan pendekatan *sliding window*, dimana sejumlah data historis pada jendela waktu tertentu digunakan sebagai input untuk memprediksi harga pada periode berikutnya, Selain itu, dilakukan perhitungan indikator teknikal tambahan, yaitu EMA, BB serta RSI. Indikator-indikator ini digunakan untuk merepresentasikan informasi tren, volatilitas, dan momentum pasar secara lebih komprehensif.

Tabel 1. Data Indikator Trading

| EMA (14) | BB Upper | BB Middle | BB Lower | RSI |
|----------|----------|-----------|----------|-------|
| 3354.52 | 3362.32 | 3354.52 | 3294.51 | 40.00 |
| 3349.72 | 3387.43 | 3336.52 | 3285.61 | 30.00 |
| 3342.76 | 3381.19 | 3323.51 | 3265.83 | 32.50 |
| 3338.50 | 3369.11 | 3320.35 | 3271.58 | 38.99 |

d) Pembagian Data

Pada tahap akhir, dataset yang telah di proses dibagi menjadi data pelatihan dan data pengujian dengan rasio 80% untuk pelatihan dan 20% untuk pengujian. Pembagian ini bertujuan untuk memastikan model memiliki jumlah data yang cukup untuk mempelajari pola pergerakan harga *cryptocurrency*, sekaligus menyediakan data yang belum pernah dilihat sebelumnya untuk mengevaluasi kinerja model secara objektif.

2.4 Modelling

Tahap *modelling* dilakukan dengan membangun model prediksi menggunakan algoritma *Long Short Them Memory* [10]. Model memanfaatkan data deret waktu hasil *sliding window* yang telah diperkaya dengan indikator teknikal seperti EMA, BB dan RSI dengan harga penutupan sebagai variabel target.

Model LSTM disusun menggunakan beberapa lapisan LSTM dan *dropout* untuk mempelajari pola temporal harga secara efektif serta mengurangi risiko *overfitting*. Proses pelatihan dilakukan menggunakan fungsi kerugian *mean squared error* (MSE) dan optimizer *Adam*. Model dilatih secara terpisah untuk masing-masing aset agar dapat menangkap karakteristik pergerakan harga *Ethereum* dan *Solana* secara spesifik.

2.5 Evaluation

Tahap *evaluation* dilakukan untuk mengukur kinerja model prediksi harga *cryptocurrency* yang telah dibangun. Evaluasi dilakukan menggunakan dua metrik kesalahan, yaitu *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). RMSE digunakan untuk mengukur besarnya kesalahan prediksi dalam satuan harga aktual dan memberikan penalti lebih besar pada kesalahan ekstrem, sedangkan MAPE digunakan untuk mengukur tingkat kesalahan relatif dalam bentuk persentase sehingga memudahkan interpretasi akurasi model.

Perhitungan RMSE dan MAPE dilakukan dengan membandingkan nilai prediksi dan nilai aktual harga penutupan (*close*) pada data pengujian. Nilai RMSE dan MAPE yang lebih rendah menunjukkan

bahwa model memiliki kemampuan prediksi yang lebih baik dalam menangkap pola pergerakan harga *cryptocurrency*. Hasil evaluasi ini digunakan sebagai dasar untuk menilai efektivitas penerapan model LSTM dengan pendekatan indikator teknikal dalam memprediksi harga kripto.

2.6 Deployment

Tahap *deployment* dilakukan dengan mengintegrasikan model prediksi yang telah dilatih dan dievaluasi ke dalam sebuah *dashboard* interaktif berbasis *Streamlit*. Model LSTM yang memiliki performa terbaik berdasarkan nilai RMSE dan MAPE digunakan untuk menghasilkan prediksi harga kripto secara otomatis.

Dashboard Streamlit dirancang untuk menampilkan hasil prediksi harga, grafik perbandingan antara harga aktual dan harga prediksi, serta informasi yang digunakan dalam pemodelan. Melalui antarmuka ini, pengguna dapat menentukan aset kripto dan horizon waktu prediksi, sehingga sistem berfungsi sebagai *decision support system* dalam membantu proses analisis dan pengambilan keputusan trading berbasis data.

3. HASIL DAN PEMBAHASAN

3.1 Hasil

Penelitian ini bertujuan untuk membangun model prediksi harga *cryptocurrency* menggunakan algoritma *Long Short Term Memory* (LSTM) dengan pendekatan multi modal indikator trading. Model yang dikembangkan digunakan untuk memprediksi harga dua aset kripto yaitu *Ethereum* dan *Solana*.

Metodologi penelitian yang digunakan adalah CRISP-DM (*Cross Industry Standard Process for Data Mining*) yang terdiri dari enam tahapan utama yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*. Pendekatan ini dipilih karena mampu memberikan kerangka kerja yang sistematis dalam pengembangan model berbasis *data mining*.

3.2 Pembahasan

3.2.1 Business Understanding

Tujuan utama dari penelitian ini adalah untuk mengembangkan mode prediksi harga *cryptocurrency* berbasis *Long Short-Term Memory* yang mampu mempelajari pola volatilitas pasar dan menghasilkan prediksi harga yang lebih akurat dibandingkan analisis manual.

3.2.2 Data Understanding

Data yang digunakan merupakan data historis harga *cryptocurrency* yang diperoleh dari platform *Yahoo Finance* dengan atribut utama yaitu *open*, *high*, *low*, dan *close* dengan jumlah data 2.298 data dengan rentang data selama enam tahun. Data tersebut merupakan data *time series* yang merepresentasikan pergerakan harga dari waktu ke waktu.

Selain data harga, penelitian ini juga menambahkan beberapa indikator teknikal untuk meningkatkan kemampuan model dalam menangkap pola pasar. Indikator yang digunakan meliputi EMA, RSI, dan BB.

Tabel 2. Sampel Dataset *Ethereum*

| <i>Date</i> | <i>Close</i> | <i>High</i> | <i>Low</i> | <i>Open</i> |
|-------------|--------------|-------------|------------|-------------|
| 2026-01-14 | 3354.52 | 3397.90 | 3283.38 | 3333.2 |
| 2026-01-15 | 3318.52 | 3384.45 | 3277.82 | 3354.77 |
| 2026-01-16 | 3297.49 | 3326.25 | 3253.81 | 3318.34 |
| 2026-01-17 | 3310.86 | 3329.28 | 3283.66 | 3296.48 |

Sumber : *Yahoo Finance*

Tabel 3. Sampel Dataset *Solana*

| <i>Date</i> | <i>Close</i> | <i>High</i> | <i>Low</i> | <i>Open</i> |
|-------------|--------------|-------------|------------|-------------|
| 2026-01-14 | 146.75 | 148.21 | 143.52 | 145.36 |
| 2026-01-15 | 142.33 | 141.76 | 141.03 | 146.75 |
| 2026-01-16 | 144.86 | 145.38 | 140.43 | 142.33 |
| 2026-01-17 | 143.76 | 144.86 | 143.57 | 144.86 |

Sumber : *Yahoo Finance*

3.2.3 Data Preparation

Pada tahap ini, dilakukan proses persiapan data sebelum digunakan dalam pemodelan. Tahapan ini meliputi pembersihan data untuk memastikan tidak ada nilai kosong atau tidak valid, serta perhitungan beberapa indikator teknikal.

Contoh perhitungan pada tanggal 15 Januari 2026:

1. Close = 3318.52
2. EMA sebelumnya = 3354.52

$$EMA=(3318.52 \times 0.1333)+(3354.52 \times 0.8667)$$

$$EMA=442.44+2907.28=3349.72$$

Selanjutnya, data yang telah diproses dilakukan normalisasi menggunakan metode *Min-MaxScaler* untuk mengubah rentang nilai data ke dalam skala 0 hingga 1 sehingga dapat meningkatkan stabilitas pelatihan model. Dataset kemudian dibentuk menjadi *window time series* dengan *window size* 30 hari agar model dapat mempelajari pola historis harga. Setelah itu, data dibagi menjadi data pelatihan dan data pengujian dengan rasio 80:20 untuk mengevaluasi performa model.

Tabel 4. *Min-Max Normalization Close*

| <i>Date</i> | <i>Real Close</i> | <i>Normalization Close</i> |
|-------------|-------------------|----------------------------|
| 2026-01-14 | 3354.52 | 1.00 |
| 2026-01-15 | 3318.52 | 0.42 |
| 2026-01-16 | 3297.49 | 0.00 |
| 2026-01-17 | 3310.86 | 0.28 |

Tabel 5. Sampel Data Latih *Window 30*

| <i>No</i> | <i>Input (Window)</i> | <i>Target</i> |
|-----------|-------------------------|---------------|
| 1 | [0.12, 0.15, ..., 0.45] | 0.50 |
| 2 | [0.15, 0.20, ..., 0.50] | 0.55 |

Tabel 6. Sampel Data Latih *Window 30*

| <i>No</i> | <i>Input (Window)</i> | <i>Target</i> |
|-----------|-------------------------|---------------|
| 1 | [0.60, 0.62, ..., 0.70] | 0.75 |
| 2 | [0.62, 0.65, ..., 0.75] | 0.78 |

3.2.4 Modelling

Pada tahap ini dilakukan pembangunan mode prediksi harga *cryptocurrency* yang dimana model ini dirancang untuk memproses data deret waktu yang telah disiapkan pada tahap sebelumnya. Data yang digunakan sebagai input mode merupakan antara data harga dan indikator teknikal yang telah dinormalisasi serta dibentuk menjadi *window time series*.

```
def build_model(input_shape):
    model = Sequential([
        LSTM(64, return_sequences=True, input_shape=input_shape),
        Dropout(0.2),
        LSTM(64, return_sequences=True),
        Dropout(0.2),
        LSTM(32),
        Dense(1)
    ])
```

Gambar 2. Pembangunan Model LSTM

| Layer (type) | Output Shape | Param # |
|---------------------|----------------|---------|
| lstm_6 (LSTM) | (None, 30, 64) | 16,896 |
| dropout_4 (Dropout) | (None, 30, 64) | 0 |
| lstm_7 (LSTM) | (None, 30, 64) | 33,024 |
| dropout_5 (Dropout) | (None, 30, 64) | 0 |
| lstm_8 (LSTM) | (None, 32) | 12,416 |
| dense_2 (Dense) | (None, 1) | 33 |

Total params: 62,369 (243.63 KB)
 Trainable params: 62,369 (243.63 KB)
 Non-trainable params: 0 (0.00 B)

Gambar 3. Output Model LSTM

Pada Gambar 2, arsitektur model yang digunakan terdiri dari beberapa lapisan LSTM bertingkat untuk menangkap pola temporal pada data. Mode dimulai dengan LSTM *layer* berukuran 64 *unit* dengan parameter *return_sequence=True*, kemudian diikuti *Dropout* sebesar 0.2 untuk mengurangi risiko *overfitting*. Selanjutnya ditambahkan LSTM *layer* kedua dengan 64 *unit*, serta LSTM *layer* ketiga dengan 32 *unit* untuk mengekstraksi pola yang lebih kompleks. Pada bagian akhir digunakan *Dense Layer* sebagai lapisan *output* yang menghasilkan nilai prediksi harga *cryptocurrency*.

Model kemudian dikompilasi menggunakan *optimizer Adam* dengan fungsi *loss Mean Squared Error* (MSE). Proses pelatihan dilakukan menggunakan 100 *epoch* dengan *batch size* sebesar 32 seperti yang dapat dilihat pada Gambar 3.

```
df_eth = add_indicators(load_data("ETH-USD"))

X_eth, y_eth, scaler_eth = prepare_data(df_eth)

X_train_eth, X_test_eth, y_train_eth, y_test_eth = split_data(X_eth, y_eth)

model_eth = build_model(X_train_eth.shape[1:])
model_eth.fit(X_train_eth, y_train_eth, epochs=100, batch_size=32, verbose=1)
```

Gambar 4. Training Model

```

Epoch 1/100
/usr/local/lib/python3.12/dist-packages/keras/src/layer
super().__init__(**kwargs)
56/56 ----- 15s 81ms/step - loss: 0.0189
Epoch 2/100
56/56 ----- 2s 33ms/step - loss: 0.0041
Epoch 3/100
56/56 ----- 2s 31ms/step - loss: 0.0030
Epoch 4/100
56/56 ----- 2s 31ms/step - loss: 0.0029
Epoch 5/100
56/56 ----- 3s 46ms/step - loss: 0.0024
Epoch 6/100
56/56 ----- 4s 31ms/step - loss: 0.0023
Epoch 7/100
56/56 ----- 2s 31ms/step - loss: 0.0028
Epoch 8/100
56/56 ----- 3s 31ms/step - loss: 0.0019
Epoch 9/100
56/56 ----- 2s 41ms/step - loss: 0.0018
Epoch 10/100
56/56 ----- 2s 43ms/step - loss: 0.0018
Epoch 11/100
56/56 ----- 2s 31ms/step - loss: 0.0017
Epoch 12/100
56/56 ----- 2s 31ms/step - loss: 0.0017
Epoch 13/100
56/56 ----- 2s 31ms/step - loss: 0.0015
Epoch 14/100
56/56 ----- 3s 31ms/step - loss: 0.0014
Epoch 15/100
    
```

Gambar 5. Output Training Model

3.2.5 Evaluation


Pada tahap ini bertujuan untuk mengukur performa model yang telah dibangun. Evaluasi dilakukan dengan membandingkan nilai hasil prediksi model dengan nilai aktual pada data pengujian. Evaluasi menggunakan dua metrik yaitu RMSE dan MAPE.

Tabel 7. Hasil Evaluasi Model

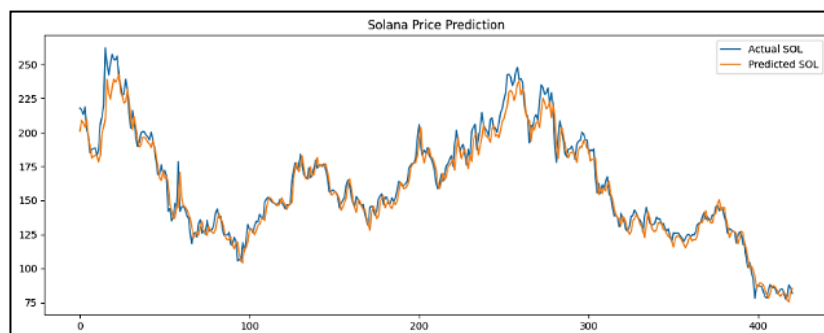
| <i>Cryptocurrency</i> | <i>RMSE</i> | <i>MAPE</i> |
|-----------------------|-------------|-------------|
| <i>Ethereum</i> | 129.08 | 3.26% |
| <i>Solana</i> | 8.30 | 3.63% |

Seperti yang dapat dilihat pada Tabel 4, hasil evaluasi menunjukkan bahwa model mampu menghasilkan tingkat kesalahan prediksi yang relatif rendah pada kedua aset *cryptocurrency*. Nilai MAPE sebesar 3.26% pada *Ethereum* dan 3.63% pada *Solana* menunjukkan bahwa model memiliki tingkat akurasi yang baik dalam memprediksi harga *cryptocurrency*

Selain evaluasi menggunakan metrik numerik, dilakukan juga analisis visual dengan membandingkan grafik harga aktual dan harga hasil prediksi. Berdasarkan grafik pada Gambar 4, terlihat bahwa garis prediksi model mampu mengikuti pola pergerakan harga aktual dengan cukup baik.



Gambar 6. Hasil Evaluasi Prediksi *Ethereum*

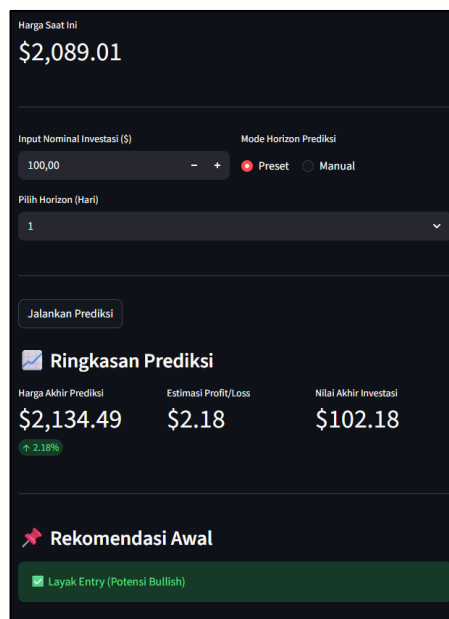


Gambar 7. Hasil Evaluasi Prediksi Solana

Secara keseluruhan, hasil evaluasi menunjukkan bahwa model LSTM mampu memberikan performa prediksi yang cukup baik dalam memodelkan pergerakan harga *cryptocurrency* *Ethereum* dan *Solana*. Model yang dibangun dapat digunakan sebagai alat bantu analisis dalam memahami potensi pergerakan harga di masa mendatang.

3.2.6 Deployment

Tahap *deployment* merupakan tahap akhir dalam penelitian, yaitu proses implementasi model yang telah dibangun agar dapat digunakan oleh pengguna. Model prediksi yang telah dilatih ini diimplementasikan dalam bentuk *dashboard* interaktif berbasis web menggunakan *framework* *Streamlit*, seperti pada Gambar 8.



Gambar 8. Halaman Prediksi

Proses dimulai dari *input* pengguna berupa nominal investasi dan horizon waktu, kemudian sistem mengambil data historis yang diproses melalui tahap pembersihan, normalisasi, dan pembentukan *window time series*. Data tersebut digunakan sebagai *input* model LSTM untuk menghasilkan prediksi harga di masa mendatang.

Berdasarkan hasil prediksi, harga *Ethereum* saat ini sebesar \$2,089.01 dan diperkirakan naik menjadi \$2,134.49 dalam 1 hari dengan kenaikan 2.18%. Dengan investasi sebesar \$100, diperoleh estimasi keuntungan sebesar \$2.18 sehingga nilai akhir investasi menjadi \$102.18. Berdasarkan hasil tersebut, sistem memberikan rekomendasi “*Layak Entry (Potensi Bullish)*”.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan dapat disimpulkan bahwa :

1. Model *Long Short-Term Memory* berhasil digunakan untuk memprediksi harga *cryptocurrency Ethereum* dan *Solana*.
2. Dataset yang digunakan berasal dari *Yahoo Finance* Periode Januari 2020 hingga data terbaru.
3. Pembagian data dilakukan dengan rasio 80% untuk pelatihan dan 20% untuk pengujian.
4. Proses pelatihan dilakukan sebanyak 100 *epoch*.
5. Waktu pelatihan rata-rata sekitar 2-5 detik per *epoch* menggunakan *Google Colab*.
6. Model menghasilkan RMSE sebesar 126.55 USD dan MAPE 3.12% untuk *Ethereum*.
7. Model menghasilkan RMSE sebesar 7.62 USD dan MAPE 3.44% untuk *Solana*.
8. Nilai kesalahan yang relatif rendah menunjukkan model mampu mempelajari pola pergerakan harga dengan baik.
9. Model berhasil diimplementasikan dalam sistem berbasis *Streamlit*.
10. Sistem memungkinkan pengguna melakukan prediksi dan melihat hasil secara interaktif.

5. UCAPAN TERIMA KASIH

Ucapan terima kasih kami sampaikan kepada dosen pembimbing yang telah memberikan arahan selama proses penelitian dan PPPM (Pusat Penelitian dan Pengabdian kepada Masyarakat) Institut Teknologi Pagar Alam.

DAFTAR RUJUKAN

- [1] J. Almeida and T. C. Gonçalves, ‘Cryptocurrency Market Microstructure: A Systematic Literature Review’, *Ann. Oper. Res.*, vol. 332, no. 1–3, pp. 1035–1068, Jan. 2024, doi: 10.1007/s10479-023-05627-5.
- [2] M. F. Rizkilloh and S. Widiyanesti, ‘Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM)’, *Jurnal RESTI*, vol. 6, no. 1, pp. 25–31, Feb. 2022, doi: 10.29207/resti.v6i1.3630.
- [3] R. Chandra, ‘Intermarket Influence Between Traditional Stock Markets and Cryptocurrencies: A Case Study of JSX and BTC’.
- [4] M. Aswadi and U. Ependi, ‘Predicting Bitcoin and Ethereum Prices Using the Long Short- Term Memory (LSTM) Model’, *Journal of Information Systems and Informatics*, vol. 7, no. 3, pp. 3046–3061, Sep. 2025, doi: 10.51519/journalisi.v7i3.1228.

- [5] A. Hafid *et al.*, 'Predicting Market Trends with Enhanced Technical Indicator Integration and Classification Models', Nov. 2025, [Online]. Available: <http://arxiv.org/abs/2410.06935>
- [6] Y. Xue *et al.*, 'A Review on the Security of the Ethereum-Based DeFi Ecosystem', 2023, *Tech Science Press*. doi: 10.32604/cmes.2023.031488.
- [7] D. P. Mishra, S. R. Behera, S. S. Behera, A. R. Patro, and S. R. Salkuti, 'Solana blockchain technology: a review', *International Journal of Informatics and Communication Technology*, vol. 13, no. 2, pp. 197–205, Aug. 2024, doi: 10.11591/ijict.v13i2.pp197-205.
- [8] T. O. Hodson, 'Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not', Jul. 19, 2022, *Copernicus GmbH*. doi: 10.5194/gmd-15-5481-2022.
- [9] F. Rodrigues and M. Machado, 'High-Frequency Cryptocurrency Price Forecasting Using Machine Learning Models: A Comparative Study', *Information (Switzerland)*, vol. 16, no. 4, Apr. 2025, doi: 10.3390/info16040300.
- [10] 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, pp. 136–147, 2022.