

Penggunaan Algoritma LSTM Dengan Mekanisme Attention Untuk Prediksi Harga Cryptocurrency

Alwi Rihad^{*1}, Nenden Siti Fatonah², Agung Mulyo Widodo³, Arief Ichwani⁴

^{1,2,3,4}Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Esa Unggul Jakarta, Indonesia

ABSTRACT

Cryptocurrency, particularly Ethereum, is a digital asset with high price volatility, making price prediction a challenging task for investors. This study aims to develop an Ethereum price prediction model using the Long Short-Term Memory (LSTM) algorithm with an attention mechanism. The dataset includes daily closing prices of Ethereum from November 2017 to October 2024, obtained from Yahoo Finance. The research methodology involves data preprocessing, LSTM model development, and the integration of an attention mechanism to enhance prediction accuracy. Model evaluation was conducted using Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and Mean Absolute Percentage Error (MAPE). The results show that the LSTM model with an attention mechanism achieved a lower MAPE of 2.72% and an RMSE of 102.78, demonstrating better adaptability to significant price fluctuations. Meanwhile, the standard LSTM model exhibited greater stability in consistent market conditions, with a MAPE of 3.28% and an RMSE of 115.00. This study contributes to the advancement of cryptocurrency price prediction technology and serves as a reference for future research.

Keywords: LSTM, Attention Mechanism, Price Prediction, Ethereum, Cryptocurrency

ABSTRAK

Cryptocurrency, khususnya Ethereum, merupakan aset digital dengan volatilitas harga yang tinggi, sehingga menimbulkan tantangan besar bagi investor dalam memprediksi harga. Penelitian ini bertujuan untuk mengembangkan model prediksi harga Ethereum menggunakan algoritma Long Short-Term Memory (LSTM) dengan mekanisme attention. Data yang digunakan mencakup harga penutupan harian Ethereum dari November 2017 hingga Oktober 2024 yang diperoleh dari Yahoo Finance. Metode penelitian meliputi preprocessing data, pengembangan model LSTM, dan integrasi mekanisme attention untuk meningkatkan akurasi prediksi. Evaluasi model dilakukan menggunakan metrik Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Hasil menunjukkan bahwa model LSTM dengan mekanisme attention menghasilkan prediksi yang lebih adaptif terhadap perubahan harga signifikan, dengan MAPE sebesar 2,72% dan RMSE sebesar 102,78. Sementara itu, model LSTM standar memiliki MAPE sebesar 3,28% dan RMSE sebesar 115,00, menunjukkan performa yang lebih stabil pada kondisi pasar yang lebih konsisten. Penelitian ini memberikan kontribusi signifikan dalam pengembangan teknologi prediksi harga cryptocurrency dan menjadi referensi untuk studi lanjutan.

Kata Kunci: LSTM, Mekanisme Attention, Prediksi Harga, Ethereum, Cryptocurrency

Corresponding Author E-mail: alwirihad8@gmail.com *

Received Januari 2025; revised Februari 2025; accepted Maret 2025; published Juni 2025

1. Pendahuluan

Cryptocurrency, atau mata uang kripto, merupakan inovasi revolusioner dalam dunia keuangan digital yang terus berkembang pesat. Salah satu *cryptocurrency* paling populer adalah Ethereum, yang tidak hanya berfungsi sebagai alat pembayaran, tetapi juga sebagai platform untuk pengembangan aplikasi terdesentralisasi (*decentralized applications/DApps*) dan kontrak pintar (*smart contracts*). Dalam beberapa tahun terakhir, minat terhadap *cryptocurrency* meningkat signifikan, baik sebagai alat investasi maupun sebagai bagian dari teknologi *blockchain* yang lebih luas. Namun, volatilitas harga *cryptocurrency*, termasuk Ethereum, menjadi tantangan besar bagi para investor dan pelaku pasar [1].

Volatilitas harga yang tinggi pada *cryptocurrency* dipengaruhi oleh berbagai faktor, termasuk sentimen pasar, regulasi, adopsi teknologi, dan berita terkini. Untuk membantu memahami dan memprediksi fluktuasi ini, teknologi kecerdasan buatan (*Artificial Intelligence/AI*) telah banyak digunakan, khususnya dalam analisis data deret waktu. Model *Long Short-Term Memory* (LSTM), sebagai salah satu jenis *Recurrent Neural Network* (RNN), telah terbukti efektif dalam menangani pola data deret waktu yang kompleks dan non-linear [2]. Namun, LSTM memiliki keterbatasan dalam menangkap elemen data yang paling relevan untuk prediksi. Oleh karena itu, mekanisme *attention* ditambahkan untuk memperbaiki performa model dengan memberikan bobot lebih besar pada informasi yang penting dalam data historis [3].

Penelitian ini bertujuan untuk mengembangkan model prediksi harga Ethereum menggunakan algoritma LSTM yang dilengkapi dengan mekanisme *attention*. Dengan menggunakan data historis harga penutupan harian Ethereum dari November 2017 hingga Oktober 2024, penelitian ini berfokus pada peningkatan akurasi prediksi harga dan mengevaluasi kinerja model dengan metrik seperti *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Diharapkan penelitian ini dapat memberikan kontribusi signifikan, baik secara akademis untuk literatur terkait, maupun secara praktis bagi pelaku pasar dalam pengambilan keputusan investasi.

2. Tinjauan Pustaka

2.1. Machine Learning

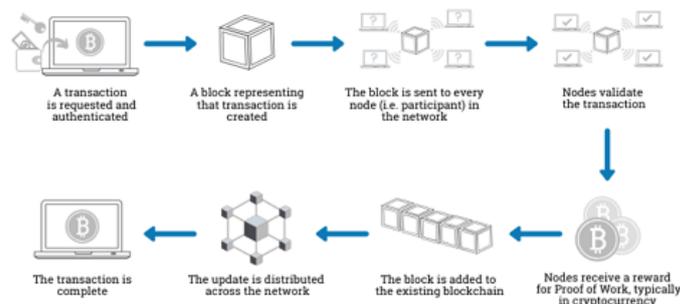
Machine learning merupakan bagian dari kecerdasan buatan (*Artificial Intelligence/AI*) yang berorientasi pada penciptaan algoritma agar komputer dapat mempelajari pola dari data dan menghasilkan prediksi atau keputusan secara mandiri tanpa perlu pengaturan manual secara langsung. Dalam konteks prediksi harga *cryptocurrency*, *machine learning* telah

diterapkan secara luas menggunakan berbagai algoritma, seperti *Support Vector Machine* (SVM), *Random Forest*, dan *Neural Network*. Model-model ini mampu menangkap pola data historis dan menghasilkan prediksi dengan tingkat akurasi yang bervariasi tergantung pada kompleksitas data [1], [4], [5].

2.2. Deep Learning

Deep learning merupakan subbidang dari machine learning yang menggunakan jaringan saraf buatan dengan struktur berlapis untuk menganalisis pola data yang rumit. Teknologi ini telah mengalami kemajuan pesat dalam beberapa tahun terakhir dan diterapkan dalam berbagai bidang, seperti pengenalan citra, analisis bahasa alami, serta prediksi data berbasis deret waktu [6].

Menurut Sari et al. [6], menyatakan bahwa salah satu kekuatan utama deep learning adalah kemampuannya dalam mengekstraksi fitur penting secara otomatis dari data yang tidak terstruktur. Dalam penelitian tersebut, deep learning berhasil meningkatkan akurasi pada tugas prediksi harga saham menggunakan arsitektur Long Short-Term Memory (LSTM). Hal ini menunjukkan bahwa jaringan saraf dalam dapat menangani data dengan pola temporal yang rumit, seperti fluktuasi harga aset keuangan yang tersaji pada Gambar 1.



Gambar 1. Alur kerja *cryptocurrency* di *Blockchain*

Selain itu, Puteri [7] menyoroti bahwa deep learning unggul dalam menangani data yang kompleks dan non-linear, terutama ketika dikombinasikan dengan mekanisme tambahan seperti *attention*. Mekanisme *attention* memungkinkan model untuk memfokuskan perhatian pada bagian data yang paling relevan, sehingga meningkatkan akurasi prediksi. Dalam penelitian ini, kombinasi LSTM dan mekanisme *attention* digunakan untuk memprediksi harga *cryptocurrency*, dengan hasil yang menunjukkan peningkatan akurasi hingga 10% dibandingkan metode tradisional.

Secara keseluruhan, deep learning telah membuktikan dirinya sebagai alat yang sangat efektif untuk menangani masalah prediksi dalam data deret waktu. Penerapan arsitektur seperti LSTM dan integrasi mekanisme *attention* memungkinkan model untuk

mengatasi tantangan seperti volatilitas harga dan pola data yang kompleks, menjadikannya pilihan yang sangat baik untuk aplikasi di sektor keuangan.

2.3. Cryptocurrency

Cryptocurrency merupakan jenis aset digital yang berfungsi sebagai media transaksi dengan memanfaatkan teknologi kriptografi untuk menjaga keamanan, mengatur penciptaan unit baru, serta memastikan validitas proses transfer aset. Teknologi *blockchain* menjadi dasar dari *cryptocurrency*, memungkinkan transaksi yang transparan dan terdesentralisasi. Salah satu tantangan terbesar dalam *cryptocurrency* adalah volatilitas harga yang tinggi, yang dipengaruhi oleh berbagai faktor seperti regulasi, sentimen pasar, dan adopsi teknologi. Ethereum adalah salah satu *cryptocurrency* utama yang memiliki karakteristik unik dibandingkan dengan Bitcoin karena kemampuannya dalam mendukung pengembangan aplikasi terdesentralisasi [8], [9].

2.4. Ethereum

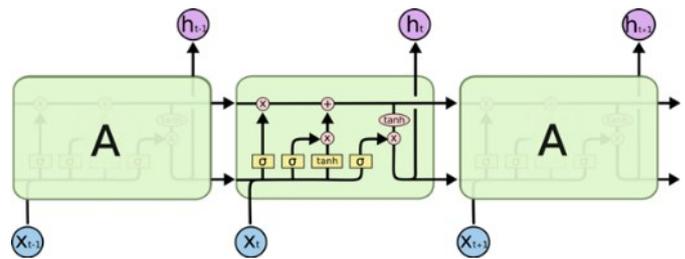
Ethereum adalah sebuah platform berbasis blockchain yang dirancang untuk menjalankan kontrak pintar (*smart contracts*) dan mengembangkan aplikasi terdesentralisasi (dApps). Selain sebagai alat pembayaran, Ethereum memungkinkan pengembang untuk menciptakan aplikasi berbasis *blockchain* yang lebih aman dan otonom. Dengan teknologi ini, Ethereum memiliki peran signifikan dalam ekosistem *cryptocurrency* global. Volatilitas harga Ethereum dipengaruhi oleh perkembangan teknologi, regulasi pemerintah, dan sentimen pasar global, yang menjadikannya target utama untuk prediksi harga menggunakan model seperti LSTM [10].

2.5. Long Short-Term Memory (LSTM)

LSTM merupakan salah satu jenis *Recurrent Neural Network* (RNN) yang dikembangkan untuk mengatasi kendala *vanishing gradient* dalam analisis data deret waktu. LSTM menggunakan struktur memori internal untuk menyimpan informasi penting dari data historis dalam jangka waktu panjang, yang menjadikannya alat yang sangat efektif untuk analisis deret waktu, termasuk prediksi harga *cryptocurrency*. Penelitian oleh [2] menunjukkan bahwa LSTM mampu menangkap pola data yang kompleks, seperti fluktuasi harga saham dan *cryptocurrency*, dengan tingkat akurasi yang lebih tinggi dibandingkan dengan metode tradisional.

Gambar 2, menunjukkan Model LSTM memproses informasi melalui mekanisme gerbang untuk menjaga dan memperbarui status memori dalam sel. Komponen gerbang ini meliputi input gate, forget gate, serta output

gate, di mana masing-masing sel memori terdiri dari tiga lapisan sigmoid dan satu lapisan tanh [11], [12].



Gambar 2. Jaringan LSTM

Fungsi sigmoid ditunjukkan pada persamaan (1).

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (1)$$

Fungsi ini digunakan untuk memetakan nilai input x ke dalam rentang antara 0 dan 1, sehingga cocok untuk berbagai tugas, termasuk pengkodean probabilitas dalam jaringan saraf.

2.6. Mekanisme Attention

Mekanisme *attention* adalah pendekatan dalam *deep learning* yang dirancang untuk meningkatkan performa model dalam menangani data kompleks. Mekanisme ini bekerja dengan memberikan bobot yang lebih besar pada elemen data yang relevan, sehingga model dapat fokus pada informasi yang paling penting. Dalam konteks prediksi harga *cryptocurrency*, mekanisme *attention* membantu model untuk lebih adaptif terhadap perubahan pola harga yang signifikan, seperti yang ditunjukkan dalam penelitian oleh [3]. Kombinasi mekanisme *attention* dengan LSTM terbukti mampu meningkatkan akurasi prediksi dalam data deret waktu yang dinamis [13], [14], [15].

Secara matematis, mekanisme *attention* dapat dijelaskan dengan persamaan (2).

$$e_t = f(W_e \cdot h_t + b_e) \quad (2)$$

Dalam mekanisme *attention*, skor perhatian e_t dihitung menggunakan persamaan $e_t = f(W_e \cdot h_t + b_e)$, di mana h_t merupakan hidden state dari LSTM pada waktu t , yang berfungsi sebagai representasi dari data input. Nilai e_t diperoleh dengan menerapkan fungsi aktivasi f , seperti tanh atau ReLU, pada hasil perkalian matriks bobot W_e dengan hidden state h_t , ditambah dengan bias b_e . Matriks bobot W_e dan bias b_e dipelajari selama proses pelatihan untuk meningkatkan kemampuan model dalam menangkap hubungan non-linear antara hidden state dan skor perhatian.

$$\alpha_t = \frac{\exp(e_t)}{\sum_{k=1}^T \exp(e_k)} \tag{3}$$

Bobot perhatian α_t kemudian dihitung dengan menerapkan fungsi softmax pada skor perhatian e_t , yang dirumuskan sebagai $\alpha_t = \frac{\exp(e_t)}{\sum_{k=1}^T \exp(e_k)}$. Fungsi *softmax* memastikan bahwa bobot perhatian tersebar dalam rentang 0 hingga 1, sehingga memungkinkan model untuk memberikan penekanan lebih besar pada langkah waktu yang lebih relevan dalam proses prediksi.

$$c_t = \sum_{i=1}^T \alpha_i \cdot h_i \tag{4}$$

Konteks vektor c_t diperoleh dengan menghitung jumlah tertimbang dari hidden state pada seluruh langkah waktu menggunakan rumus $c_t = \sum_{i=1}^T \alpha_i \cdot h_i$. Dalam persamaan ini, setiap hidden state h_i dikalikan dengan bobot perhatian α_i yang sesuai, menghasilkan representasi konteks yang lebih informatif berdasarkan pola yang ditangkap oleh model. Dengan demikian, mekanisme *attention* memungkinkan model untuk lebih fokus pada informasi yang paling relevan, meningkatkan performa dalam menangkap pola yang kompleks dalam data.

3. Metode penelitian

3.1. Dataset

Dataset yang digunakan dalam penelitian ini adalah data harga penutupan harian Ethereum yang diambil dari Yahoo Finance untuk periode November 2017 hingga Oktober 2024, sebagaimana tersaji di Tabel 1.

Tabel 1. Sampel Dataset

Sumber: <https://finance.yahoo.com/quote/ETH-USD/>

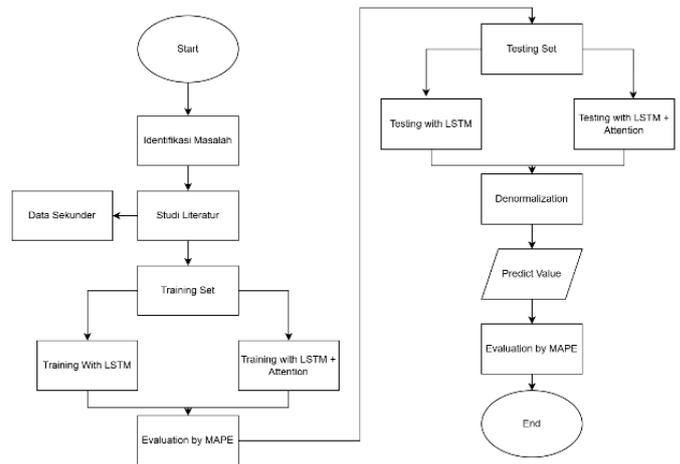
No	Tanggal	Close Price
1	2017-11-09	320.884003
2	2017-11-10	299.252991
3	2017-11-11	314.681000
4	2017-11-12	307.907990
5	2017-11-13	316.716003
6	2024-10-26	2479.603271
7	2024-10-27	2505.940674
8	2024-10-28	2565.348145
9	2024-10-29	2637.957520
10	2024-10-30	2657.372559

Dataset ini mencakup informasi seperti harga pembukaan, harga tertinggi, harga terendah, harga penutupan, dan volume perdagangan. Data ini dipilih karena merepresentasikan fluktuasi harga Ethereum yang relevan untuk analisis prediksi. Sebelum digunakan dalam pelatihan model, dataset melalui proses

preprocessing, yang mencakup penghapusan nilai kosong, normalisasi data menggunakan metode Min-Max Scaling, dan pembagian dataset menjadi training set (80%) dan testing set (20%).

3.2. Rancangan Metode

Penelitian ini menggunakan metode kuantitatif untuk mengembangkan dan mengevaluasi model prediksi harga Ethereum dengan algoritma Long Short-Term Memory (LSTM) dan mekanisme attention, dengan alur kerja seperti Gambar 3. Langkah-langkah utama dalam penelitian ini meliputi: (1) pengumpulan data dari sumber terpercaya, (2) preprocessing data untuk memastikan kualitas dan konsistensi, (3) pengembangan model LSTM standar, (4) pengembangan model LSTM dengan mekanisme attention, dan (5) evaluasi kinerja model menggunakan metrik seperti Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE).



Gambar 3. Alur Kerja

3.3. Implementasi Model LSTM

Model LSTM dirancang untuk memproses data deret waktu dan menangkap pola jangka panjang serta pendek. Arsitektur model mencakup input layer untuk menerima data terproses, satu atau lebih LSTM layers untuk menangkap pola temporal, dan dense layer pada lapisan output untuk menghasilkan prediksi harga. Optimasi model dilakukan menggunakan Adam Optimizer dengan fungsi loss Mean Squared Error (MSE). Model dilatih selama 100 epoch dengan batch size sebesar 16 untuk memastikan konvergensi.

3.4. Implementasi Model LSTM dengan Mekanisme Attention

Model LSTM dengan mekanisme attention dikembangkan untuk meningkatkan kemampuan model dalam menangkap elemen data yang paling relevan.

Mekanisme attention ditambahkan setelah lapisan LSTM untuk memberikan bobot lebih besar pada data historis yang signifikan dalam proses prediksi. Mekanisme ini memungkinkan model untuk fokus pada pola yang relevan, sehingga meningkatkan akurasi prediksi, terutama dalam kondisi data dengan volatilitas tinggi. Implementasi dilakukan dengan menggunakan library deep learning seperti TensorFlow dan Keras, yang mendukung arsitektur LSTM dan attention secara modular.

3.5. Evaluasi Model

Evaluasi model dilakukan dengan membandingkan kinerja LSTM standar dan LSTM dengan mekanisme attention menggunakan metrik evaluasi utama, yaitu Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Metrik-metrik ini digunakan untuk mengukur sejauh mana prediksi model mendekati data aktual. Selain itu, hasil prediksi model divisualisasikan dalam bentuk grafik untuk melihat kesesuaian dengan data aktual dan mengidentifikasi kekuatan serta kelemahan masing-masing model. Model dengan performa terbaik diharapkan dapat digunakan sebagai alat prediksi yang andal untuk analisis pasar cryptocurrency.

4. Hasil dan pembahasan

Penelitian ini berhasil mengembangkan model *Long Short-Term Memory* (LSTM) dengan mekanisme *attention* untuk memprediksi harga Ethereum berdasarkan data historis. Hasil evaluasi menunjukkan bahwa model LSTM dengan mekanisme *attention* memiliki performa yang cukup baik dalam menangkap pola data deret waktu dibandingkan dengan LSTM standar, terutama dalam kondisi data yang kompleks dan fluktuatif.

4.1. Hasil Evaluasi Model

Evaluasi kinerja model dilakukan menggunakan tiga metrik utama: *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Hasil perbandingan kinerja model ditampilkan dalam Tabel 2.

Tabel 2. Hasil Evaluasi Model

Metrik	LSTM Biasa	LSTM + Attention
MAE	87.429051	70.553032
RMSE	115.000347	102.784783
MAPE	0.032759	0.027283
R2 Score	97.1%	97.7%

Berdasarkan Tabel 2, nilai metrik evaluasi seperti MAE, RMSE, MAPE, dan R² Score menunjukkan bahwa model LSTM dengan mekanisme attention memiliki performa yang lebih baik dalam hal akurasi prediksi. Model dengan mekanisme *attention* menghasilkan nilai MAE dan RMSE yang lebih rendah dibandingkan dengan LSTM biasa, yang mengindikasikan error prediksi yang lebih kecil. Selain itu, nilai R² Score yang lebih tinggi pada model dengan mekanisme *attention* menunjukkan kemampuannya dalam menjelaskan variasi harga Ethereum dengan lebih baik. Meskipun model LSTM biasa menunjukkan prediksi yang lebih stabil, mekanisme *attention* memberikan fleksibilitas yang lebih tinggi dalam menangkap pola harga yang kompleks dan perubahan pasar yang lebih dinamis.

4.2. Analisis Visual

Setelah proses pelatihan dan evaluasi selesai dilakukan, hasil prediksi dari model dibandingkan dengan data aktual untuk menilai tingkat akurasi masing-masing model. Grafik perbandingan antara harga aktual dan prediksi digunakan untuk memberikan gambaran visual tentang performa model.



Gambar 4. Grafik Model LSTM biasa

Pada Gambar 4 model LSTM biasa cenderung memberikan prediksi yang lebih stabil, tetapi kurang responsif terhadap perubahan harga yang cepat. Meskipun model ini dapat mengikuti tren data aktual dengan baik, terdapat keterlambatan dalam menangkap perubahan harga yang tiba-tiba. Hal ini menyebabkan model LSTM biasa kurang optimal dalam kondisi pasar yang memiliki volatilitas tinggi.



Gambar 5. Grafik Model LSTM dengan Mekanisme Attention

Sebaliknya, pada Gambar 5 model LSTM dengan mekanisme *attention* menunjukkan keunggulan dalam menangkap pola harga yang kompleks. Mekanisme *attention* memungkinkan model untuk lebih fokus pada bagian data yang relevan, sehingga prediksi lebih adaptif terhadap perubahan harga yang signifikan. Model ini mampu mengikuti tren harga Ethereum dengan baik, termasuk saat terjadi lonjakan harga pada tahun 2021 dan penurunan drastis di tahun 2022. Selain itu, model dengan mekanisme *attention* lebih responsif dalam mendeteksi pergerakan harga mendadak, yang menjadikannya lebih efektif dalam kondisi pasar yang dinamis.



Gambar 6. Grafik Perbandingan Model

Pada Gambar 6, secara keseluruhan hasil prediksi menunjukkan bahwa model LSTM dengan mekanisme *attention* lebih unggul dalam menangkap pola harga yang kompleks dan fluktuatif dibandingkan dengan model LSTM biasa. Grafik prediksi mengindikasikan bahwa model dengan mekanisme *attention* memiliki fleksibilitas yang lebih baik dalam menyesuaikan diri terhadap pergerakan pasar, meskipun terkadang dapat menghasilkan prediksi yang lebih bervariasi.

Hasil ini menunjukkan bahwa model LSTM dengan mekanisme *attention* lebih cocok untuk memprediksi harga Ethereum, terutama dalam aplikasi yang memerlukan analisis pola harga yang kompleks dan kemampuan adaptasi terhadap perubahan mendadak. Model LSTM biasa tetap memiliki keunggulan dalam stabilitas prediksi, tetapi model dengan mekanisme *attention* menawarkan tingkat responsivitas yang lebih baik, menjadikannya pilihan yang lebih efektif dalam kondisi pasar yang dinamis.

4.3. Pembahasan

Sebagai langkah akhir dari analisis prediksi, dilakukan perbandingan langsung antara harga aktual dengan hasil prediksi dari model LSTM biasa dan model LSTM dengan mekanisme *attention*. Hasil perbandingan tersebut disajikan dalam Tabel 3.

Dari Tabel 3, terlihat bahwa model LSTM dan LSTM dengan mekanisme *attention* memiliki perbedaan dalam menangkap pola harga asli. Model LSTM

cenderung menghasilkan prediksi yang lebih stabil dan lebih dekat dengan harga aktual pada beberapa tanggal, seperti pada 2024-10-23 (1722.54 vs. 1727.75) dan 2024-10-29 (1677.92 vs. 1705.81). Model ini menunjukkan kemampuan yang baik dalam mempertahankan konsistensi prediksi, terutama pada periode dengan volatilitas harga yang lebih rendah.

Di sisi lain, model dengan mekanisme *attention* menunjukkan responsivitas yang lebih tinggi terhadap fluktuasi harga. Hal ini terlihat dari prediksi pada 2024-10-20 (1866.24 vs. 1721.44) dan 2024-10-25 (1768.44 vs. 1624.14), di mana model ini menghasilkan estimasi yang lebih tinggi dibandingkan harga aktual. Meskipun terkadang menghasilkan deviasi yang lebih besar, mekanisme *attention* memungkinkan model untuk lebih adaptif terhadap perubahan harga yang lebih kompleks.

Tabel 3. Hasil Prediksi Model

Tanggal	Harga Asli	Prediksi LSTM	Prediksi LSTM +Attention
2024-10-20	1721.443115	1802.981079	1866.240845
2024-10-21	1741.110474	1800.670288	1862.543701
2024-10-22	1722.906372	1749.292603	1844.227539
2024-10-23	1727.749878	1722.541260	1815.921387
2024-10-24	1637.187744	1705.875854	1788.069824
2024-10-25	1624.138306	1698.985596	1768.444580
2024-10-26	1653.170898	1647.484009	1742.954224
2024-10-27	1714.150879	1630.121460	1716.468018
2024-10-28	1718.111450	1654.728638	1705.470703
2024-10-29	1705.813477	1677.916992	1712.890747
2024-10-30	1715.342529	1686.842896	1728.864136

Secara keseluruhan, perbandingan ini menunjukkan bahwa kedua model memiliki keunggulan masing-masing. Model LSTM memberikan prediksi yang lebih konsisten dan stabil, menjadikannya pilihan yang lebih baik untuk kondisi pasar dengan volatilitas rendah. Sementara itu, model LSTM dengan mekanisme *attention* lebih unggul dalam menangkap pola harga yang fluktuatif, meskipun terkadang kurang stabil dalam estimasi. Optimalisasi lebih lanjut dapat dilakukan untuk meningkatkan akurasi model dengan mekanisme *attention* agar tetap responsif tanpa kehilangan stabilitas prediksi.

5. Penutup

Penelitian ini berhasil mengembangkan model *Long Short-Term Memory* (LSTM) dengan mekanisme

attention untuk memprediksi harga Ethereum berdasarkan data historis. Berdasarkan hasil evaluasi, model LSTM dengan mekanisme *attention* menunjukkan performa yang lebih baik dalam menangkap pola data yang kompleks dan perubahan harga yang signifikan. Nilai *Mean Absolute Percentage Error* (MAPE) untuk model LSTM standar adalah 3,28%, sedikit lebih tinggi dibandingkan model dengan mekanisme *attention* yang mencapai 2,72%. Selain itu, model dengan mekanisme *attention* juga memiliki nilai *Root Mean Squared Error* (RMSE) yang lebih rendah, yaitu 102,78 dibandingkan dengan 115,00 pada model LSTM biasa, menunjukkan bahwa mekanisme *attention* dapat mengurangi *error* prediksi secara keseluruhan.

Meskipun model dengan mekanisme *attention* memberikan fleksibilitas lebih tinggi dalam menangkap fluktuasi harga, prediksinya terkadang lebih variatif dibandingkan dengan model LSTM standar yang menunjukkan hasil lebih stabil. Performa ini terlihat dari hasil prediksi pada tanggal tertentu, seperti 2024-10-20, di mana model dengan mekanisme *attention* memperkirakan harga sebesar 1866,24 dibandingkan harga aktual 1721,44, sementara model LSTM standar menghasilkan prediksi yang lebih dekat sebesar 1802,98. Namun, pada tanggal 2024-10-25, model dengan mekanisme *attention* menangkap pergerakan harga dengan lebih responsif dibandingkan model LSTM biasa, menunjukkan keunggulannya dalam mendeteksi perubahan mendadak di pasar.

Sebagai saran untuk penelitian selanjutnya, pengembangan model dapat dilakukan dengan mengombinasikan mekanisme *attention* dengan arsitektur *deep learning* lain, seperti Transformer atau Bidirectional LSTM, untuk meningkatkan akurasi prediksi dan stabilitas model dalam berbagai kondisi data. Selain itu, penggunaan dataset yang lebih luas dengan mempertimbangkan faktor eksternal seperti volume transaksi, sentimen pasar, dan berita keuangan dapat memberikan hasil yang lebih komprehensif. Optimasi hyperparameter yang lebih mendalam, termasuk eksperimen dengan jumlah neuron, dropout rate, dan fungsi aktivasi, juga dapat menjadi strategi untuk meningkatkan performa model secara keseluruhan.

6. Referensi

[1] D. M. Gunarto, S. Sa'adah, and D. Q. Utama, "Predicting Cryptocurrency Price Using RNN and LSTM Method," *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 12, no. 1, pp. 1–8, 2023, doi: 10.32736/sisfokom.v12i1.1554.

[2] L. Hu *et al.*, "Supervised Machine Learning Techniques: An Overview with Applications to Banking," *International Statistical Review*, vol. 89, no. 3, pp. 573–604, 2021, doi: 10.1111/insr.12448.

[3] M. A. Ammer and T. H. H. Aldhyani, "Deep Learning Algorithm to Predict Cryptocurrency Fluctuation Prices: Increasing Investment Awareness," *Electronics (Switzerland)*, vol. 11, no. 15, pp. 1–22, 2022, doi: 10.3390/electronics11152349.

[4] N. J. Shafana and A. Senthilselvi, "Analysis of recent advancement in unsupervised deep learning," *International journal of health sciences*, vol. 6, no. March, pp. 2766–2782, 2022, doi: 10.53730/ijhs.v6ns1.5199.

[5] F. M. Riese, S. Keller, and S. Hinz, "Supervised and semi-supervised self-organizing maps for regression and classification focusing on hyperspectral data," *Remote Sensing*, vol. 12, no. 1, 2020, doi: 10.3390/RS12010007.

[6] R. Sari, K. Kusriani, T. Hidayat, and T. Orphanoudakis, "Improved LSTM Method of Predicting Cryptocurrency Price Using Short-Term Data," *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 17, no. 1, p. 33, 2023, doi: 10.22146/ijccs.80776.

[7] D. I. Puteri, "Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah," *Euler : Jurnal Ilmiah Matematika, Sains dan Teknologi*, vol. 11, no. 1, pp. 35–43, 2023, doi: 10.34312/euler.v11i1.19791.

[8] M. Samin-Al-Wasee, P. S. Kundu, I. Mahzabeen, T. Tamim, and G. R. Alam, "Time-Series Forecasting of Ethereum Price Using Long Short-Term Memory (LSTM) Networks," *8th International Conference on Engineering and Emerging Technologies, ICEET 2022*, no. May, 2022, doi: 10.1109/ICEET56468.2022.10007377.

[9] H. Parikh, N. Panchal, and A. Sharma, "Cryptocurrency Price Prediction Using Machine Learning," *Lecture Notes in Networks and Systems*, vol. 428, no. July, pp. 275–285, 2023, doi: 10.1007/978-981-19-2225-1_25.

[10] B. B. Likhitha, C. H. A. Raj, and M. S. U. Islam, "Unveiling Ethereum's Future: LSTM-Based Price Prediction and a Systematic Blockchain Analysis," *BIO Web of Conferences*, vol. 86, 2024, doi: 10.1051/bioconf/20248601117.

[11] J. Qiu, B. Wang, and C. Zhou, "Forecasting stock prices with long-short term memory neural network based on attention mechanism," *PLoS ONE*, vol. 15, no. 1, pp. 1–15, 2020, doi: 10.1371/journal.pone.0227222.

[12] T. Ericko, M. Dolok Lauro, and T. Handhayani, "Prediksi Harga Pangan Di Pasar Tradisional Kota Surabaya Dengan Metode Lstm," *Jurnal Ilmu Komputer dan Sistem Informasi*, vol. 11, no. 2, 2023, doi: 10.24912/jiksi.v11i2.26012.

- [13] Hadrian and G. P. Kusuma, "Stock Price Prediction on Indonesia Stock Market With the Influence of External Factors Using Recurrent Neural Network With Attention Mechanism," *Communications in Mathematical Biology and Neuroscience*, vol. 2023, pp. 1–20, 2023, doi: 10.28919/cmbn/8168.
- [14] C. Jin and Y. Li, "Cryptocurrency Price Prediction Using Frequency Decomposition and Deep Learning," *Fractal and Fractional*, vol. 7, no. 10, pp. 1–29, 2023, doi: 10.3390/fractalfract7100708.
- [15] G. Kim, D. H. Shin, J. G. Choi, and S. Lim, "A Deep Learning-Based Cryptocurrency Price Prediction Model That Uses On-Chain Data," *IEEE Access*, vol. 10, pp. 56232–56248, 2022, doi: 10.1109/ACCESS.2022.3177888.