

Application of CNN-BiLSTM Algorithm for Ethereum Price Prediction

Hakam Dzakwan Diash ^{1*}, Vannesa Nathania ^{2*}, Mohammad Idhom ^{3*}, Trimono ^{4*}

^{*} Sains Data, Universitas Pembangunan Nasional “Veteran” Jawa Timur

22083010069@student.upnjatim.ac.id ¹, 22083010044@student.upnjatim.ac.id ², idhom@upnjatim.ac.id ³, trimono.stat@upnjatim.ac.id ⁴

Article Info

Article history:

Received 2025-06-05

Revised 2025-07-16

Accepted 2025-07-19

Keyword:

Ethereum,
Price Prediction,
CNN-BiLSTM.

ABSTRACT

The volatile and dynamic Ethereum (ETH) market demands an accurate predictive model to support investment decision making. The complexity of ETH time series data and the influence of various external factors make price prediction a challenge in itself. This study aims to develop an ETH price prediction model using a combined architecture of Convolutional Neural Network (CNN) and also Bidirectional Long Short-Term Memory (BiLSTM). CNN is used to extract local features from historical ETH closing price data, while BiLSTM models bidirectional temporal patterns. The dataset used includes ETH daily price from January 2020 to January 2025, which are obtained from Yahoo Finance and have gone through a normalization process and transformation into sequential form. The model is trained for 100 epochs with an early stopping mechanism to prevent overfitting and evaluated using the MAPE and coefficient of determination (R^2) metrics. The evaluation results show that the CNN-BiLSTM model is able to predict ETH prices with a MAPE value of 2.8546% and an R^2 of 0.9415, indicating high performance in capturing actual data trends. This study shows that the hybrid CNN-BiLSTM approach is effective for Ethereum price prediction.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Pasar *cryptocurrency*, khususnya Ethereum (ETH), menunjukkan volatilitas harga yang tinggi dan dinamis, sehingga prediksi harga yang akurat menjadi sangat penting bagi investor dan pelaku pasar. Pada tahun 2024, tercatat bahwa adanya kenaikan sebanyak 335,9% transaksi tahunan dibandingkan dengan tahun sebelumnya di laporan Chanialysis [16]. Perkembangan teknologi kecerdasan buatan, khususnya *deep learning*, menawarkan metode yang potensial untuk mengatasi tantangan dalam prediksi harga aset digital ini [1].

Namun, kompleksitas data harga ETH yang bersifat *time series* dan dipengaruhi oleh berbagai faktor eksternal membuat prediksi harga menjadi sebuah permasalahan. Oleh karena itu, diperlukan pendekatan yang mampu menangkap pola temporal dan spasial dari data tersebut secara efektif [2].

Berdasarkan kapitalisasi pasar, yang merupakan nilai indikator total suatu aset berdasarkan harga pasar saat ini, Ethereum menempati posisi kedua setelah Bitcoin [3]. Pada akhir 2024, Ethereum tercatat terdapat kenaikan harga sebesar

63%. Namun demikian, kajian akademik mengenai Ethereum belum menjadi fokus utama akademisi. Sehingga, hal ini menjadi peluang untuk mengembangkan dan menerapkan model prediktif terhadap harga ETH.

Model *deep learning* yang mampu menggabungkan *Convolutional Neural Network* (CNN) dan *Bidirectional Long Short-Term Memory* (BiLSTM) menjadi pilihan yang menjanjikan karena CNN mampu mengekstraksi fitur penting dari data, sementara BiLSTM dapat menangkap dependensi temporal dua arah dalam data *time series* [4]. Hal ini dibuktikan dalam penelitian oleh Alessio Staffini memberikan hasil bahwa penerapan model CNN BiLSTM memberikan hasil lebih baik daripada model ARIMA dan Elastic Net dengan data *macroeconomic time series* [5]. Hal ini dikarenakan model ARIMA memiliki kekurangan dalam menangani data dengan volatilitas tinggi dan ketidakstabilan [6].

Penggunaan *Convolutional Neural Network* (CNN) dalam analisis data *time series* semakin berkembang karena kemampuannya dalam mengekstrak pola temporal secara otomatis tanpa memerlukan fitur manual. Seperti hasil

penelitian yang menunjukkan bahwa CNN mampu melakukan prediksi jumlah pengunjung unik pada jurnal elektronik dengan akurasi yang tinggi, memanfaatkan keunggulan CNN dalam menangkap dependensi temporal pada data multivariat [7].

Bidirectional Long Short-Term Memory (BiLSTM) merupakan pengembangan dari model LSTM yang mampu memproses data time series secara dua arah, yaitu dari masa lalu ke masa depan dan sebaliknya, sehingga meningkatkan kemampuan model dalam menangkap pola temporal yang kompleks. Model LSTM efektif dalam menangkap pola temporal data *time series* [9].

Kombinasi *Convolutional Neural Network* (CNN) dan *Bidirectional Long Short-Term Memory* (BiLSTM) telah menjadi pendekatan populer dalam pemodelan dan prediksi data time series karena kemampuannya yang saling melengkapi. CNN berfungsi sebagai ekstraktor fitur lokal yang efektif dalam menangkap pola spasial atau temporal jangka pendek dari data *time series*, sedangkan BiLSTM mampu memodelkan dependensi temporal jangka panjang secara dua arah, yakni dari masa lalu ke masa depan dan sebaliknya. Studi oleh Dewandra et al. menunjukkan bahwa model CNN-BiLSTM, khususnya dengan tambahan mekanisme *attention* [12]. *Attention Model* berperan sebagai pengatur penetapan bobot ke fitur-fitur informasi yang diekstrak oleh BiLSTM untuk eksplorasi korelasi temporal secara otomatis [13].

Penelitian yang dilakukan oleh Indolia S, et al dalam artikelnya yang berjudul *Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach* menjelaskan bahwa model CNN terbentuk dari empat komponen utama yaitu *convolutional layer*, *pooling layer*, *activation function*, dan *fully connected layer* [8].

Penelitian oleh Permatasari et al. menunjukkan bahwa penerapan BiLSTM dengan optimasi Nadam untuk memprediksi harga saham harian BBRI menghasilkan prediksi yang akurat dengan nilai kesalahan yang rendah. Selain itu, studi oleh Zhao et al. menunjukkan bahwa BiLSTM juga efektif dalam prediksi *multivariate time series*, seperti parameter cuaca, di mana model mampu menangkap keterkaitan antar variabel seperti temperatur dan kelembaban dengan baik. Namun demikian, prediksi terhadap variabel yang lebih fluktuatif seperti curah hujan masih menjadi tantangan [10] [11].

TABEL I
PEMBANDING DENGAN MODEL LAIN

Penelitian	Model	Market	Hasil Analisis
[17]	ARIMA	Ethereum	MAPE = 51.94%
[18]	LSTM	Ethereum	MAPE = 6.89%
[19]	GRU	Ethereum	MAPE = 18.17% R ² = 0.9442
	LSTM		MAPE = 18.08% R ² = 0.9282
[20]	BiGRU	Ethereum	MAPE = 20.735%
	BiLSTM		MAPE = 22.640%

Tabel 1 menyajikan studi pembandingan dari penerapan berbagai model prediksi harga Ethereum, dengan hasil analisis berdasarkan metrik evaluasi. Untuk menilai kinerja model prediksi yang dikembangkan, digunakan dua metrik evaluasi utama, yaitu *Mean Absolute Percentage Error* (MAPE) dan Koefisien Determinasi (R²). MAPE mengukur persentase kesalahan relatif antara nilai prediksi dan nilai aktual, sehingga memberikan gambaran yang mudah dipahami mengenai seberapa besar kesalahan prediksi dalam bentuk persentase. Bagi praktisi *evaluator* MAPE menjadi metode *evaluator* yang disukai karena memiliki interpretabilitas dan ketergantungan skala yang baik [14]. Sedangkan R² menunjukkan seberapa baik variabilitas data aktual dapat dijelaskan oleh model prediksi, dengan nilai yang mendekati 1 menandakan model memiliki kemampuan prediksi yang sangat baik [15]. Kombinasi kedua metrik ini memberikan gambaran yang komprehensif mengenai akurasi dan keandalan model dalam memprediksi harga Ethereum (ETH).

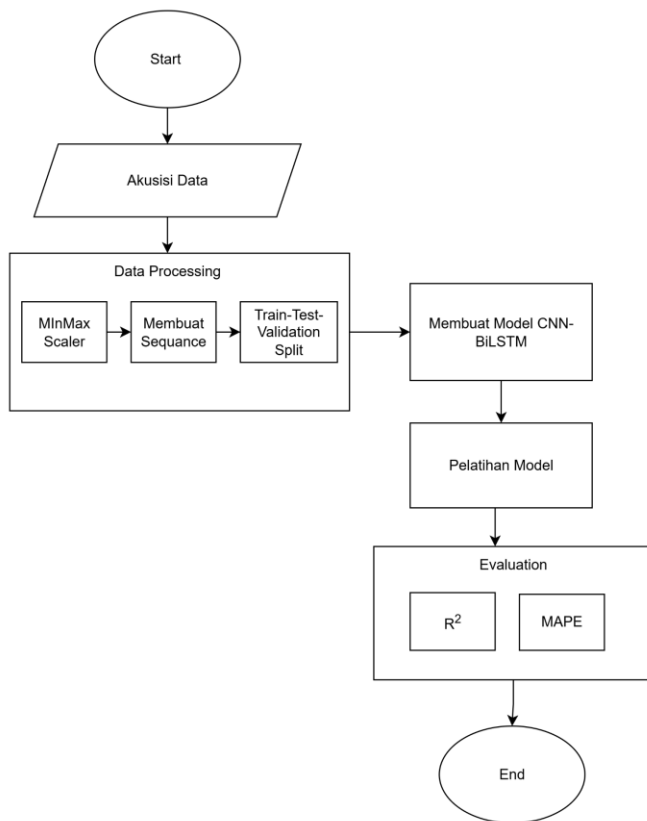
Penelitian ini bertujuan untuk merancang dan mengimplementasikan model CNN-BiLSTM dalam memprediksi harga ETH. Hasil penelitian diharapkan dapat memberikan kontribusi bagi pengembangan teknologi prediksi harga cryptocurrency serta membantu pengambilan keputusan investasi yang lebih tepat. Selain demikan, investor ritel maupun penyedia platform perdagangan aset kripto diharapkan memperoleh informasi yang lebih *reliable* untuk membuat sistem prediksi pergerakan harga ETH, sehingga dapat meminimalisir risiko dan memaksimalkan potensi keuntungan investasi.

II. METODE

Penelitian ini menerapkan metode deep learning menggunakan arsitektur CNN-BiLSTM untuk memprediksi harga Ethereum (ETH). Proses penelitian mencakup pengumpulan dan praproses data harga historis ETH, pembangunan model CNN-BiLSTM, serta evaluasi performa model menggunakan matrik evaluasi seperti Koefisien Determinasi (R²) dan *Mean Absolute Percentage Error* (MAPE).

A. Akuisisi Data

Data yang digunakan merupakan data historis pasar Ethereum yang mencakup tanggal (*Date*), harga pembukaan (*Open*), harga tertinggi (*High*), harga terendah (*Low*), harga penutupan (*Close*), dan volume perdagangan (*Volume*). Data ini diperoleh langsung dari Yahoo Finance menggunakan library Python bernama *yfinance*, yang menyediakan akses mudah dan terstruktur ke data keuangan pasar saham dan aset kripto. Variabel utama yang digunakan dalam penelitian ini adalah harga penutupan (*Close*) harian Ethereum. Dataset tersebut mencakup periode dari 1 Januari 2020 hingga 1 Januari 2025 dengan total 1.828 baris data.



Gambar 1. Flowchart metodologi penelitian

B. Data Preprocessing

Tahap pra pemrosesan data dilakukan untuk mempersiapkan data mentah sebelum digunakan dalam proses pelatihan model. Proses ini sangat penting untuk memastikan bahwa data memiliki kualitas yang memadai dan dalam format yang sesuai dengan kebutuhan arsitektur model yang digunakan, yakni CNN-BiLSTM. Langkah pertama dalam tahap ini adalah melakukan normalisasi data harga penutupan (*Close*) menggunakan metode *Min-Max Scaling*. Proses ini mengubah nilai-nilai data ke dalam rentang 0 hingga 1 dengan tujuan untuk meningkatkan stabilitas numerik dan mempercepat konvergensi model selama proses pelatihan.

Setelah data dinormalisasi, langkah selanjutnya adalah mengubah data deret waktu menjadi data sekuensial. Transformasi ini dilakukan dengan membentuk pasangan *input-output* menggunakan teknik *sliding window*. Setiap input terdiri dari urutan nilai historis sepanjang 16 langkah waktu, sedangkan output merupakan nilai berikutnya setelah urutan tersebut. Dengan demikian, model dapat mempelajari pola historis dalam data dan menggunakannya untuk memprediksi nilai masa depan.

Dataset yang telah dibentuk kemudian dibagi menjadi tiga bagian, yaitu data latih (*training set*) sebesar 70%, data validasi (*validation set*) sebesar 15%, dan data uji (*test set*) sebesar 15%. Pembagian ini dilakukan sebelum proses pembentukan *sequence* untuk menghindari terjadinya

kebocoran data (*data leakage*) antara subset, yang dapat menyebabkan hasil evaluasi model menjadi bias. Dengan demikian, setiap subset data benar-benar merepresentasikan bagian yang berbeda dari keseluruhan data.

Langkah terakhir dalam proses pra pemrosesan adalah mengubah bentuk data ke dalam format tiga dimensi, yaitu [*samples, timesteps, features*], agar sesuai dengan kebutuhan input model CNN-BiLSTM. Dalam format ini, *samples* merepresentasikan jumlah pasangan *input-output* yang tersedia, *timesteps* adalah panjang urutan waktu atau *sequence* yang digunakan sebagai *input*, dan *features* menunjukkan jumlah fitur yang digunakan pada setiap langkah waktu. Karena hanya digunakan satu fitur, maka nilai *features* adalah satu.

C. Membuat Model CNN-BiLSTM

Arsitektur model yang digunakan dalam penelitian ini merupakan kombinasi antara jaringan *Convolutional Neural Network* (CNN) dan *Bidirectional Long Short-Term Memory* (BiLSTM), yang dirancang untuk menangkap baik pola lokal maupun dependensi jangka panjang dalam data deret waktu. Model diawali dengan lapisan konvolusional satu dimensi (Conv1D) yang terdiri dari 128 filter dengan ukuran kernel sebesar 3 dan fungsi aktivasi ReLU. Lapisan ini bertugas mengekstraksi fitur lokal dari urutan data masukan. Setelah itu, diterapkan lapisan MaxPooling1D dengan ukuran *pool* sebesar 2, yang berfungsi untuk mereduksi dimensi spasial dari hasil ekstraksi fitur, sekaligus mengurangi kompleksitas komputasi.

TABEL II
DETAIL ARSITEKTUR CNN-BiLSTM

Layer Type	Detail
Convolutional 1D	Filters: 128, Kernel size: 3, Activation: ReLU
MaxPooling 1D	Pool size: 2
Bidirectional LSTM	Units: 150, Return sequences: True
Dropout	Rate: 0.2
Bidirectional LSTM	Units: 50, Return sequences: False
Dense	Units: 64, Activation: ReLU
Dense	Units: 32, Activation: ReLU
Dense	Units: 1
Kompilasi Model	Optimizer: Adam, Learning rate: 0.001, Loss: Mean Squared Error (MSE)

Selanjutnya, model dilengkapi dengan dua lapisan BiLSTM yang disusun secara berurutan. Lapisan pertama memiliki 150 unit dan diatur agar mengembalikan urutan penuh output (*return_sequences=True*) untuk memungkinkan lapisan selanjutnya mempelajari pola temporal lebih lanjut. Lapisan BiLSTM kedua terdiri dari 50 unit dan hanya mengembalikan output pada timestep terakhir (*return_sequences=False*) sebagai representasi akhir dari urutan masukan. Di antara kedua lapisan BiLSTM tersebut disisipkan lapisan *dropout* dengan tingkat 0.2 guna mencegah *overfitting* dengan cara menonaktifkan sebagian unit secara acak selama pelatihan.

Setelah melewati proses ekstraksi fitur dan pembelajaran konteks temporal, output model diproses lebih lanjut melalui dua lapisan *fully connected (Dense)* yang masing-masing memiliki 64 dan 32 unit dengan fungsi aktivasi ReLU. Terakhir, model ditutup dengan satu lapisan Dense berukuran 1 unit tanpa fungsi aktivasi untuk menghasilkan output akhir berupa prediksi nilai kontinu. Model ini dikompilasi menggunakan optimizer Adam dengan laju pembelajaran (*learning rate*) sebesar 0.001 serta menggunakan fungsi *loss Mean Squared Error (MSE)*. Detail lengkap dari arsitektur model CNN-BiLSTM ini dapat dilihat pada Tabel 2.

D. Pelatihan Model

Pada tahap pelatihan model, dilakukan pelatihan sebanyak 100 *epoch*. Untuk mencegah *overfitting* dan mempercepat proses pelatihan, digunakan mekanisme early stopping dengan *callback tf.keras.callbacks.EarlyStopping*. *Callback* ini memonitor nilai validasi loss dan akan menghentikan pelatihan jika tidak terjadi peningkatan performa pelatihan selama 10 *epoch* berturut-turut. Selain itu, pengaturan *restore_best_weights=True* memastikan model akan mengembalikan bobot terbaik yang diperoleh selama pelatihan, sehingga hasil akhir model merupakan bobot dengan performa validasi terbaik.

E. Evaluasi Model

Pada tahap evaluasi, kinerja model akan diukur menggunakan dua metrik utama, yaitu *Mean Absolute Percentage Error (MAPE)* dan koefisien determinasi (R^2). MAPE digunakan untuk menghitung rata-rata persentase kesalahan absolut antara nilai prediksi dan nilai aktual, yang memberikan gambaran tentang seberapa besar deviasi prediksi terhadap data sebenarnya. Sementara itu, R^2 digunakan untuk mengukur proporsi variasi data aktual yang dapat dijelaskan oleh model, di mana nilai yang mendekati 1 menunjukkan kemampuan prediksi yang lebih baik. Evaluasi dengan kedua metrik ini bertujuan untuk menilai sejauh mana model yang dibangun mampu menghasilkan prediksi harga Ethereum (ETH) dengan akurasi yang baik.

III. HASIL DAN PEMBAHASAN

A. Akuisisi Data

Data historis harga Ethereum terhadap Dolar Amerika Serikat (ETH/USD) diperoleh dari layanan Yahoo Finance melalui pustaka yahoo finance, dengan rentang waktu pengambilan mulai dari 1 Januari 2020 hingga 1 Januari 2025. Meskipun data pasar yang tersedia mencakup atribut *Open*, *High*, *Low*, *Close*, dan *Volume (OHLCV)*, penelitian ini hanya memanfaatkan fitur *Close* karena harga penutupan harian sering dijadikan acuan utama dalam analisis deret waktu aset kripto. Data yang diunduh disimpan dalam format CSV dan memuat dua komponen utama, yaitu tanggal dan harga penutupan. Setelah proses pengunduhan, fitur tanggal dikonversi ke dalam format *datetime* dan dijadikan sebagai indeks untuk memastikan urutan waktu yang konsisten, sehingga pola temporal dalam data dapat dianalisis secara

akurat oleh model prediktif. Sebagian contoh data historis pasar Ethereum yang digunakan dapat dilihat pada Tabel 3.

TABEL III
DATA HISTORIS ETHEREUM

Date	Close
2020-01-01	130
2020-01-02	127
...	...
2024-12-31	3332
2025-01-01	3353

B. Data Preprocessing

Tahapan awal pra pemrosesan dilakukan dengan menormalisasi nilai harga penutupan ke dalam rentang 0 hingga 1 menggunakan *MinMaxScaler*. Proses normalisasi ini bertujuan untuk menghindari dominasi nilai besar dan mempercepat konvergensi model selama pelatihan. Selanjutnya, data diubah ke dalam bentuk sekuensial berdimensi tetap, yaitu dengan panjang urutan sebanyak 16 langkah waktu. Setiap urutan akan dipasangkan dengan nilai target pada langkah waktu berikutnya.

Setelah transformasi, data dibagi menjadi tiga subset: 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian. Jumlah *sequence* yang dihasilkan pada masing-masing subset adalah sebagai berikut: 1263 *sequence* untuk pelatihan, 258 *sequence* untuk validasi, dan 259 *sequence* untuk pengujian. Berikut adalah contoh dua *sequence* pertama dan dua *sequence* terakhir pada data pelatihan beserta nilai targetnya.

TABEL IV
DATA PELATIHAN HASIL PRAPROSESAN


Sequence ke-	Sequence	Target
1	[0.00429569 0.00357426 ... 0.01183134 0.01144004]	0.01279896
2	[0.00357426 0.00501243 ... 0.01144004 0.01279896]	0.01377434
...
1262	[0.33072849 0.34160784 ... 0.37044098 0.38766144]	0.38582733
1263	[0.34160784 0.34384868 ... 0.38766144 0.38582733]	0.38856528

C. Membuat Model CNN-BiLSTM

Model yang dikembangkan merupakan kombinasi dari jaringan konvolusional satu dimensi (CNN) dan *Long Short-*

Term Memory dua arah (BiLSTM). Lapisan awal model adalah Conv1D dengan 128 filter dan ukuran kernel 3, yang bertugas mengekstraksi pola lokal dari deret waktu. Lapisan ini dilanjutkan dengan MaxPooling1D berukuran 2, yang berperan mereduksi dimensi output dan menyoroti fitur dominan. Selanjutnya, dua lapisan BiLSTM diterapkan secara berurutan. Lapisan pertama memiliki 150 unit dan mengembalikan urutan penuh, sementara lapisan kedua memiliki 50 unit dan hanya mengembalikan output terakhir sebagai representasi akhir. Di antara keduanya disisipkan Dropout sebesar 0.2 untuk mengurangi risiko *overfitting*.


Setelah representasi sekuens diperoleh, hasilnya diproses oleh dua lapisan Dense masing-masing dengan 64 dan 32 unit, yang keduanya mengaktifkan ReLU untuk menangkap hubungan nonlinier. Model diakhiri dengan satu lapisan Dense berisi satu unit tanpa fungsi aktivasi karena prediksi yang dihasilkan bersifat kontinu. Seluruh model dioptimasi dengan algoritma Adam dengan laju pembelajaran 0.001, serta menggunakan Mean Squared Error (MSE) sebagai fungsi loss karena permasalahan bersifat regresi.



Gambar 2. Ilustrasi pemodelan layer CNN dan BiLSTM

D. Pelatihan Model

Model dilatih selama 100 *epoch* dengan ukuran *batch* sebesar 16. Untuk mencegah pelatihan berlebihan, diterapkan mekanisme penghentian dini (*early stopping*), yaitu metode yang akan menghentikan pelatihan apabila tidak terjadi peningkatan pada nilai loss validasi selama 10 *epoch* berturut-turut. Proses pelatihan menunjukkan adanya penurunan nilai loss pada data pelatihan maupun validasi, sebagaimana ditunjukkan pada Gambar 4.



Gambar 4. Nilai *loss* selama pelatihan model

E. Evaluasi Model

Kinerja model dievaluasi menggunakan dua metrik utama, yaitu *Mean Absolute Percentage Error* (MAPE) dan koefisien determinasi (R^2). Hasil prediksi yang dihasilkan model dibandingkan dengan data aktual dari subset pengujian setelah nilai-nilai dikembalikan ke skala aslinya. Berdasarkan evaluasi, diperoleh nilai MAPE sebesar 2.8546% dan R^2 sebesar 0.9415. Nilai MAPE yang rendah menunjukkan bahwa kesalahan prediksi relatif kecil terhadap nilai aktual, sedangkan nilai R^2 yang mendekati 1 mengindikasikan bahwa model mampu menjelaskan variabilitas data dengan baik.

Visualisasi hasil prediksi data pengujian yang ditampilkan pada Gambar 5, menunjukkan bahwa model mampu mengikuti pola tren data aktual dengan akurasi yang tinggi. Secara visual, grafik memperlihatkan bahwa garis prediksi (*predicted*) sangat berdekatan dengan garis aktual (*actual*), baik dalam tren naik maupun turun. *Error trend* seiring waktu juga tampak relatif stabil tanpa fluktuasi besar, menunjukkan bahwa model tidak hanya akurat tetapi juga konsisten sepanjang waktu pengujian. Lebih lanjut, model tampak mampu menangkap perubahan mendadak atau lonjakan harga. Hal ini menunjukkan bahwa model cukup responsif terhadap dinamika pasar yang tajam, namun tetap menjaga stabilitas prediksi secara keseluruhan.



Gambar 5. Perbandingan nilai aktual dan prediksi pada dataset uji

Jika dibandingkan dengan model-model sebelumnya, model CNN-BiLSTM yang dikembangkan dalam penelitian ini menunjukkan performa yang lebih unggul dalam memprediksi harga Ethereum. Model ARIMA [17], sebagai pendekatan statistik tradisional, menghasilkan nilai MAPE sebesar 51.94%, yang menunjukkan tingkat kesalahan prediksi yang sangat tinggi. Sementara itu, model deep

learning seperti LSTM [18] dan GRU [19] memberikan hasil yang jauh lebih baik, dengan nilai MAPE masing-masing sebesar 6.89% dan 18.17%. LSTM dalam studi lain [19] mencatatkan nilai MAPE sebesar 18.08% dan R^2 sebesar 0.9282.

Adapun model BiGRU dan BiLSTM yang diusulkan dalam penelitian [20] justru menunjukkan performa yang kurang optimal, dengan nilai MAPE masing-masing sebesar 20.735% dan 22.640%. Jika dibandingkan dengan model-model tersebut, CNN-BiLSTM dalam penelitian ini mampu menghasilkan nilai MAPE yang lebih rendah, yaitu sebesar 2.8546%, serta nilai R^2 sebesar 0.9415. Hal ini menunjukkan bahwa integrasi CNN dan BiLSTM mampu mengatasi keterbatasan model tunggal dalam menangkap pola spasial dan temporal pada data deret waktu, sehingga menghasilkan prediksi harga yang lebih akurat dan stabil.

IV. KESIMPULAN

Berdasarkan hasil penelitian ini, model *deep learning* CNN-BiLSTM terbukti efektif dalam memprediksi harga Ethereum (ETH) dengan akurasi yang tinggi, ditunjukkan oleh nilai *Mean Absolute Percentage Error* (MAPE) sebesar 2.8546% dan koefisien determinasi (R^2) sebesar 0.9415. Keunggulan model ini terletak pada kemampuannya dalam mengekstraksi fitur lokal melalui CNN dan menangkap pola temporal dua arah melalui BiLSTM, sehingga mampu mengikuti tren data aktual secara akurat. Penelitian ini menunjukkan bahwa pendekatan *hybrid* seperti CNN-BiLSTM dapat menjadi solusi yang andal dalam menghadapi tantangan prediksi harga aset kripto yang bersifat fluktuatif. Untuk penelitian selanjutnya, disarankan untuk mengembangkan model dengan mempertimbangkan integrasi data eksternal seperti indikator teknikal dan sentimen pasar guna meningkatkan kinerja prediksi secara lebih komprehensif.

DAFTAR PUSTAKA

- [1] O. L. D. Warsito and R. Robiyanto, "Analisis Volatilitas Cryptocurrency, Emas, Dollar, Dan Indeks Harga Saham (Ihsg)," *Int. J. Soc. Sci. Bus.*, vol. 4, no. 1, pp. 40–46, 2020, doi: 10.23887/ijssb.v4i1.23887.
- [2] F. A. Ramadhan and N. D. Nathasia, "Prediksi Harga Dan Kinerja Aset Bitcoin Menggunakan Algoritma Long Short-Term Memory," vol. 15, no. 1, pp. 68–76, 2025.
- [3] P. H. Setianingrum and D. Prastuti, "The impact of macroeconomics and financial variables on sectors' index in Indonesia stock exchange market," *Int. J. Econ. Res.*, vol. 14, no. 17, pp. 41–49, 2017.
- [4] Q. Yang, Y. Sun, and Y. Wu, "Bitcoin Price Prediction Based on CNN-Bi-LSTM-Attention Model," *Highlights Business, Econ. Manag.*, vol. 16, pp. 80–86, 2023, doi: 10.54097/hbem.v16i.10540.
- [5] A. Staffini, "A CNN-BiLSTM Architecture for Macroeconomic Time Series Forecasting," *Eng. Proc.*, vol. 39, no. 1, 2023, doi: 10.3390/engproc2023039033.
- [6] M. J. Hamayel and A. Y. Owda, "A Novel Cryptocurrency Price Prediction Model Using GRU, LSTM and bi-LSTM Machine Learning Algorithms," *AI*, vol. 2, no. 4, pp. 477–496, 2021, doi: 10.3390/ai2040030.
- [7] A. R. F. Dewandra, A. P. Wibawa, U. Pujiyanto, A. B. P. Utama, and A. Nafalski, "Journal Unique Visitors Forecasting Based on Multivariate Attributes Using CNN," *Int. J. Artif. Intell. Res.*, vol. 6, no. 2, 2022, doi: 10.29099/ijair.v6i1.274.
- [8] S. Indolia, A. K. Goswami, S. P. Mishra, and P. Asopa, "Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach," *Procedia Comput. Sci.*, vol. 132, pp. 679–688, 2018, doi: 10.1016/j.procs.2018.05.069.
- [9] D. M. Gunarto, S. Sa'adah, and D. Q. Utama, "Predicting Cryptocurrency Price Using RNN and LSTM Method," *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 12, no. 1, pp. 1–8, 2023, doi: 10.32736/sisfokom.v12i1.1554.
- [10] S. H. Permatasari, I. M. Nur, and F. Fauzi, "Metode Bidirectional Long Short-Term Memory (BiLSTM) Untuk Memprediksi Harga Saham BBRI Dengan Optimasi Nesterov Adaptive Moment (Nadam)," pp. 1151–1159.
- [11] H. Awarulloh, D. F. Shiddieq, and D. Nurhayati, "Penggunaan Multivariat Model Bidirectional LSTM untuk Prediksi Cuaca : Optimalisasi Waktu Tanam Padi Petani Kabupaten Garut," no. 1, pp. 127–138, 2025.
- [12] M. Mushiha, "Implementasi CNN-BiLSTM untuk Prediksi Harga Saham Bank Syariah di Indonesia," *Jambura J. Math.*, vol. 6, no. 2, pp. 195–203, 2024, doi: 10.37905/jjom.v6i2.26509.
- [13] J. Zhang, L. Ye, and Y. Lai, "Stock Price Prediction Using CNN-BiLSTM-Attention Model," pp. 1–18, 2023.
- [14] S. Kim and H. Kim, "A new metric of absolute percentage error for intermittent demand forecasts," *Int. J. Forecast.*, vol. 32, no. 3, pp. 669–679, 2016, doi: 10.1016/j.ijforecast.2015.12.003.
- [15] J. Gao, "R-Squared (R^2) – How much variation is explained?" *Res. Methods Med. Heal. Sci.*, vol. 5, no. 4, pp. 104–109, 2024, doi: 10.1177/26320843231186398.
- [16] Chainalysis, "The 2024 Geography of Crypto Report," 2024.
- [17] D. Gunawan and I. Febrianti, "Ethereum Value Forecasting Model using Autoregressive Integrated Moving Average (ARIMA)," *Int. J. Adv. Soc. Sci. Humanit.*, vol. 2, no. 1, pp. 29–35, 2023, doi: 10.56225/ijassh.v2i1.151.
- [18] D. Xu, "Price Prediction of Cryptocurrency based on LSTM Model: Evidence from Ethereum," *Highlights Sci. Eng. Technol.*, vol. 39, pp. 744–748, 2023, doi: 10.54097/hset.v39i.6639.
- [19] M. Saputra, "Comparative Analysis of LSTM and GRU Models for Ethereum (ETH) Price Prediction," *Int. J. Business, Econ. Soc. Dev.*, vol. 6, pp. 132–132, 2025.
- [20] E. Mahdi, C. Martin-Barreiro, and X. Cabezas, "A Novel Hybrid Approach Using an Attention-Based Transformer + GRU Model for Predicting Cryptocurrency Prices," *Mathematics*, vol. 13, no. 9, pp. 1–24, 2025, doi: 10.3390/math13091484.