

Penerapan Metode LSTM untuk Prediksi Harga Ethereum

Aldi Bastiatul Fawait^{*1}, Muh. Jamil², Sitti Rahmah³, Sugiarto⁴

^{1,2,3,4} Program Studi Ilmu Komputer, Fakultas Teknik dan Informatika, Universitas Widya Gama Mahakam, Samarinda

e-mail: ^{*1}aldi.bas.fawait@uwgm.ac.id, ²jamil@uwgm.ac.id, ³sitti.rahmah@uwgm.ac.id,
⁴muhammadsugi17@gmail.com

Abstrak

Perkembangan teknologi *blockchain* dalam beberapa tahun terakhir memberikan dampak besar terhadap sistem keuangan global, salah satunya melalui Ethereum (ETH) yang berfungsi sebagai aset kripto sekaligus fondasi ekosistem smart contract. Namun, volatilitas tinggi harga ETH membuat metode prediksi tradisional sulit menangkap pola nonlinier yang kompleks. Penelitian ini menerapkan metode Long Short-Term Memory (LSTM) untuk memprediksi harga ETH menggunakan data time-series dari *investing.com* periode 1 Januari 2021 hingga 21 Agustus 2025. Model LSTM dengan tiga lapisan menghasilkan performa baik dengan MAE 0,0387 dan R^2 0,9741 pada data latih, serta MAE 22,59% dan R^2 80,55% pada data uji. Hasil ini membuktikan bahwa LSTM efektif dalam mempelajari pola fluktuasi harga ETH meskipun akurasi pada data baru masih dapat ditingkatkan. Kontribusi penelitian ini adalah memperkuat literatur terkait prediksi kripto berbasis data jangka panjang sekaligus memberikan manfaat praktis bagi investor dan regulator dalam memahami dinamika volatilitas ETH.

Kata kunci—Ethereum, LSTM, Machine Learning, Prediksi

1. PENDAHULUAN

Perkembangan teknologi *blockchain* dalam beberapa tahun terakhir membawa dampak besar terhadap sistem keuangan global, termasuk di Indonesia [1], [2], [3]. Ethereum (ETH) sebagai salah satu aset kripto utama bukan hanya berperan sebagai media investasi, tetapi juga sebagai *backbone* ekosistem *smart contract* dan aplikasi terdesentralisasi [4], [5]. Fluktuasi harga ETH yang sangat tinggi mencerminkan sifat pasar kripto yang volatil, dipengaruhi baik oleh faktor internal ekosistem maupun eksternal seperti kebijakan moneter global, ketidakpastian ekonomi, hingga perilaku investor ritel dan institusional [6].

Volatilitas yang tinggi membuat harga ETH sulit diprediksi dengan model konvensional [7], [8]. Sejumlah studi menegaskan bahwa model linier tradisional seperti ARIMA atau GARCH kurang mampu menangkap pola kompleks dan *nonlinier* dalam data kripto [9]. Dinamika harga ETH sering kali dipengaruhi oleh pola *long-range dependency* yang tidak dapat dijelaskan secara sederhana [10]. Hal ini mendorong penerapan metode berbasis *deep learning* seperti *Recurrent Neural Network* (RNN), khususnya *Long Short-Term Memory* (LSTM), yang memiliki kemampuan menyimpan informasi jangka panjang serta mengatasi masalah *vanishing gradient* [11], [12].

Sejumlah penelitian di Indonesia mulai fokus pada pemodelan harga Ethereum (ETH) menggunakan metode berbasis *deep learning*, khususnya (LSTM). Sianturi [13] menguji LSTM pada data harga Ethereum dan menunjukkan bahwa model mampu menangkap pola fluktuasi dengan cukup baik. Namun, penelitian ini hanya menekankan kemampuan prediksi jangka pendek tanpa mengevaluasi secara mendalam tingkat generalisasi model pada data uji. Pradhana

dan Batubulan [14] juga membuktikan bahwa LSTM lebih stabil dibandingkan metode klasik, tetapi penelitian tersebut tidak menguji variabilitas performa ketika parameter arsitektur diubah, sehingga sulit diketahui sejauh mana model dapat dioptimalkan. Sementara itu, Diash [10] yang memadukan CNN dengan Bi-LSTM untuk menggabungkan fitur spasial dan temporal. Meskipun kombinasi ini meningkatkan akurasi, kompleksitas komputasi yang dihasilkan cukup tinggi, sehingga belum jelas apakah model tersebut efisien untuk diterapkan dalam konteks praktis seperti perdagangan aset kripto *real-time*. Riziq [15] membandingkan LSTM dengan SVR dan menemukan bahwa LSTM lebih konsisten dalam prediksi, tetapi cakupan penelitian terbatas pada periode data yang relatif pendek sehingga belum sepenuhnya merepresentasikan volatilitas jangka panjang ETH.


Isu lain yang relevan adalah pemilihan metrik evaluasi. Umumnya penelitian menggunakan MAE, RMSE, atau MAPE, namun dalam konteks regresi, koefisien determinasi (R^2) menjadi metrik yang semakin populer karena mampu menjelaskan proporsi variasi data yang berhasil ditangkap oleh model. Nilai R^2 mendekati 1 menunjukkan bahwa model dapat menjelaskan sebagian besar variasi harga, sementara nilai negatif menandakan model lebih buruk dibanding rata-rata sederhana [16]. Beberapa penelitian Indonesia di bidang *machine learning non-kripto* juga telah menerapkan R^2 sebagai ukuran utama selain *error* absolut. Misalnya, Fiola [17] menekankan pentingnya R^2 dalam menilai kekuatan model regresi, Idris [16] menerapkan R^2 untuk prediksi harga mobil, dan Saputra [18] menggunakan R^2 dalam evaluasi model pohon keputusan. Bahkan penelitian terkait prediksi harga rumah di Indonesia menunjukkan nilai R^2 sebesar 0,81 sebagai indikator kuat keberhasilan model [19]. Jurnal lain juga menegaskan bahwa R^2 lebih informatif dalam menunjukkan konsistensi model regresi dibanding hanya mengandalkan error [20].

Dari analisis kritis terhadap penelitian terdahulu, dapat disimpulkan bahwa masih terdapat beberapa gap: (1) sebagian besar penelitian belum mengevaluasi performa model dengan metrik R^2 yang penting untuk regresi, (2) data historis yang digunakan relatif terbatas sehingga kurang merepresentasikan volatilitas ETH jangka panjang, dan (3) aspek efisiensi model dalam konteks praktis masih jarang dibahas.

Berdasarkan gap tersebut, penelitian ini secara eksplisit bertujuan untuk menerapkan metode LSTM dalam memprediksi harga Ethereum dengan memanfaatkan data historis yang lebih panjang (01 Januari 2021 sampai 21 Agustus 2025) serta melakukan evaluasi performa menggunakan MAE dan R^2 . Penelitian ini diharapkan berkontribusi dalam pengayaan literatur akademis di Indonesia sekaligus memberikan manfaat praktis bagi investor, regulator, dan pelaku pasar dalam memahami dinamika volatilitas ETH.

2. METODE PENELITIAN

Penelitian ini melalui tahapan studi literatur, *preprocessing* (pengumpulan dan normalisasi data), serta pembagian data menjadi *training* untuk melatih model dan *testing* untuk menguji kinerjanya dalam memprediksi harga Ethereum. Alur atau tahapan penelitian tersebut ditampilkan pada Gambar 1.



Gambar 1. Diagram alur penelitian

2.1. Pengumpulan Data

Dataset yang digunakan adalah data harga Ethereum diperoleh melalui situs *investing.com* [21] situs ini merupakan pusat informasi harga aset investasi *digital*. Ethereum adalah sebuah *platform blockchain* terdesentralisasi yang menggunakan *smart contract* untuk menyediakan layanan pertukaran secara *online*. Aset digital ini memungkinkan transaksi dilakukan tanpa memerlukan kartu kredit maupun keterlibatan bank sentral. Melalui jaringan internet, Ethereum memberikan kemudahan bagi penggunaanya dalam bertransaksi. Secara mendasar, Ethereum berfungsi sebagai komoditas digital yang berjalan dengan teknologi *peer-to-peer* [13]. Dataset dikumpulkan secara harian dengan rentang waktu 01 Januari 2021 hingga 21 Agustus 2025, total data yang berhasil dihimpun mencapai 1061 *record* data.

2.2. Preprocessing Data

Tahap *preprocessing* dimulai dengan melakukan pengembangan fitur dan juga melakukan pembersihan data. Sehingga nilai fitur pada dataset menjadi konsisten dan dapat dipelajari oleh algoritma yang digunakan.

Selain itu dilakukan proses normalisasi untuk mengubah skala data ke dalam rentang 0 hingga 1. Normalisasi dilakukan dengan menggunakan metode *min-max*, metode ini bekerja dengan cara mengurangi nilai data ke-*i* dengan nilai terkecil, kemudian membaginya dengan selisih antara nilai terbesar dan nilai terkecil. Tujuan dari penggunaan *min-max* adalah agar nilai pada fitur dataset memiliki rentang yang tidak terlalu jauh, rumus *min-max* yang digunakan ditunjukkan pada Persamaan 1.

$$X_{norm} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (1)$$

X_{norm} merupakan data yang telah dinormalisasi pada rentang 0–1, X_i menunjukkan data ke-*i*. X_{min} adalah nilai data terkecil, dan X_{max} adalah nilai data terbesar [22].

2.3. Alokasi Dataset

Tahap berikutnya adalah membagi data menjadi data latih, data validasi serta data uji. Proporsi data ditetapkan sebesar 80% data latih dan 20% data validasi yang berasal dari data 1 Januari 2021 sampai 31 Juli 2025 kemudian untuk data uji digunakan data tanggal 1 sampai 31 Agustus 2025, hal ini dimaksudkan agar data latih dan data validasi dapat dipelajari terlebih dahulu oleh algoritma pada proses pelatihan model. kemudian diuji kesalahannya menggunakan data yang sama sekali belum pernah dipelajari oleh model. Skema alokasi data yang digunakan ditunjukkan pada Tabel 1.

Tabel 1. Skema Alokasi Dataset

1061 Record Data		31 Record Data
80%	20%	data uji
data train	data validasi	

2.4. Long Short-Term Memory (LSTM)

LSTM merupakan varian RNN yang dirancang untuk mengatasi masalah *gradient vanishing* dan *long-term dependency* pada data deret waktu. Dengan memanfaatkan sel memori yang memiliki tiga gerbang utama (*input*, *forget*, dan *output*), LSTM mampu menyaring, menyimpan, serta memperbarui informasi sehingga pola jangka panjang dapat dipertahankan lebih efektif dibanding RNN biasa. Dalam arsitektur LSTM terdapat empat jenis *gate* unit, yaitu *forget gate*, *input gate*, *cell gate*, dan *output gate*. Adapun persamaan masing-masing *gate* adalah sebagai berikut:

1. *Input gate*:

$$i_t = \sigma(W_i \times X_i + U_i \times h_{t-1} + b_i) \quad (2)$$

2. *Forget gate*:

$$f_t = \sigma(W_f \times X_t + U_f \times h_{t-1} + b_f) \quad (3)$$

3. *Cell State*:

$$c_t = f_t \odot c_{t-1} + i_t \odot c'_t \quad (4)$$

4. *New Candidate*:

$$c'_t = \tanh(W_c \times X_c + U_c \times h_{t-1} + b_c) \quad (5)$$

5. *Output gate*:

$$o_t = \sigma(W_o \times X_o + U_o \times h_{t-1} + b_o) \quad (6)$$

6. *Hidden State*:

$$h_t = o_t \odot \sigma(c_t) \quad (7)$$

Simbol σ pada persamaan tersebut merepresentasikan fungsi aktivasi *sigmoid*, sedangkan $\tanh$ digunakan sebagai fungsi aktivasi *hyperbolic tangent (TanH)* [13].

Pada penelitian ini, arsitektur yang dipakai terdiri dari tiga lapisan LSTM (64, 32, 16 *neuron*), *dropout* 20%, dan *dense layer*. Jumlah *neuron* yang menurun dipilih untuk menyeimbangkan kompleksitas dan kemampuan model dalam menangkap pola *volatil* harga Ethereum, sementara *dropout* 20% berfungsi mencegah *overfitting*. *Dense layer* digunakan agar model langsung menghasilkan satu nilai prediksi. Konfigurasi ini dipilih karena memberikan akurasi tinggi dengan error relatif rendah sekaligus efisiensi komputasi yang baik.

2.5. Metode Evaluasi Model

Evaluasi model dilakukan menggunakan dua metrik, yaitu MAE untuk mengukur rata-rata *persentase* kesalahan prediksi terhadap nilai aktual, serta R^2 untuk menilai proporsi variasi data yang dapat dijelaskan oleh model, di mana nilai mendekati 1 menunjukkan performa prediksi yang baik. Penggunaan kedua metrik ini bertujuan untuk mengukur sejauh mana model yang dibangun mampu memprediksi harga *Ethereum (ETH)* dengan tingkat akurasi yang tinggi [10].

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengumpulan Data

Setelah dilakukan pengumpulan data, maka didapatkan dataset harga Ethereum yang terdiri dari 1061 *record* data latih dan validasi serta 31 *record* data untuk validasi model. Sampel dari dataset yang telah dikumpulkan ditampilkan pada Tabel 2.

Tabel 2. Sampel Dataset Ethereum

No.	Tanggal	Terakhir	Pembukaan	Tertinggi	Terendah	Volume	Perubahan
1	20/08/2025	4.335,37	4.075,81	4.375,03	4.069,39	775,52K	+6.37%
2	19/08/2025	4.075,57	4.313,46	4.353,58	4.067,90	886,22K	-5.47%
...	...	...	...	...	...	...	...
1060	02/01/2021	774,50	729,00	787,26	715,15	2,25M	+6.22%
1061	01/01/2021	729,12	735,87	748,96	715,74	1,64M	-0.93%

3.2 Hasil Preprocessing Data

1. Hasil Pembersihan Data

Pembersihan data difokuskan untuk mengubah bentuk dan tipe data dari *object string* ke dalam bentuk *float*. Hal ini dimaksudkan agar algoritma LSTM yang digunakan dapat membaca

dataset yang akan menjadi *input* pada proses pelatihan model. Sampel hasil pembersihan data ditunjukkan pada Tabel 3.

Tabel 3. Sampel Hasil Pembersihan Dataset

No.	Tanggal	Terakhir	Pembukaan	Tertinggi	Terendah	Volume	Perubahan
1	2025-07-31	3698.46	3807.11	3877.70	3685.32	576380.0	-2.90
2	2025-07-30	3808.91	3791.80	3833.91	3682.25	586470.0	0.39
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1060	2021-01-02	774.50	729.00	787.26	715.15	2250000.0	6.22
1061	2021-01-01	729.12	735.87	748.96	715.74	1640000.0	-0.93

2. Hasil Pengembangan Fitur

Agar algoritma dapat membaca data dengan lebih detail maka dilakukan pengembangan fitur pada kolom Tanggal baik pada data latih, validasi maupun data uji. Sehingga tercipta 3 kolom baru yaitu tahun, tanggal dan hari, setelah itu dilakukan lagi pengembangan fitur ke dua pada kolom bulan dan hari dengan menambahkan kolom *bulan_sin*, *bulan_cos*, *hari_sin* dan *hari_cos* yang merupakan bentuk *encode* dari kolom bulan dan hari. Hal tersebut dilakukan agar algoritma yang digunakan dapat memahami siklus periodisasi pada data *timeseries*. Sehingga hasil akhir dari pengembangan fitur pada dataset ditunjukkan pada Tabel 4.

Tabel 4. Sampel Hasil Pengembangan Fitur

No	Tahun	Bulan	Hari	...	Bulan_cos	Bulan_sin	Hari_cos	Hari_sin
1	2025	7	31	...	-0.866025	-0.5	1.000000	-2.449294e-16
2	2025	7	30	...	-0.866025	-0.5	0.979530	-2.012985e-01
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1060	2021	1	2	...	0.866025	0.5	0.918958	3.943559e-01
1061	2021	1	1	...	0.866025	0.5	0.979530	2.012985e-01

Setelah dilakukan pengembangan fitur maka fitur Tanggal dihapus karena tidak dapat diproses pada tahap selanjutnya. Sehingga total terdapat 13 fitur yang dapat diproses pada tahap selanjutnya yaitu fitur terakhir, pembukaan, tertinggi, terendah, vol, perubahan, tahun, bulan, hari, *bulan_cos*, *bulan_sin*, *hari_cos*, *hari_sin*.

3. Hasil Normalisasi Data

Metode normalisasi diterapkan pada keseluruhan dataset yang digunakan pada semua fitur. Hasil normalisasi data ditunjukkan pada Tabel 5.

Tabel 5. Sampel Hasil Normalisasi Data

No	Tahun	Bulan	Hari	...	Bulan_cos	Bulan_sin	Hari_cos	Hari_sin
1	1.0	1.0	1.000000	...	0.071797	0.000000	1.000000	0.500000
2	1.0	1.0	0.966667	...	0.071797	0.000000	0.989739	0.399221
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1060	0.0	0.0	0.033333	...	1.000000	0.666667	0.959375	0.697431
1061	0.0	0.0	0.000000	...	1.000000	0.666667	0.989739	0.600779

Setelah dilakukan normalisasi data maka tidak ada lagi pengurangan ataupun penambahan fitur. Hasil normalisasi membuat nilai pada data memiliki *scale* yang lebih dekat. Total keseluruhan fitur yang siap dilatih oleh algoritma adalah 13 fitur yang terdiri dari 12 fitur untuk variabel X (*input fitur*) dan 1 fitur sebagai variabel Y (*target fitur*) yang disajikan pada Tabel 6.

Tabel 6. Fitur dan *Input* dan Target Pelatihan

No.	Fitur	Tipe Data	Variabel
1	Pembukaan	<i>Float</i>	X
2	Tertinggi	<i>Float</i>	X
3	Terendah	<i>Float</i>	X
⋮	⋮	⋮	⋮
12	Hari_cos	<i>Float</i>	X
13	Terakhir	<i>Float</i>	Y

3.3 Hasil Uji Coba Model LSTM


Uji coba algoritma LSTM dilakukan menggunakan pustaka *tensorflow* pada bahasa pemrograman *python* dengan struktur jaringan terdiri dari 3 lapis LSTM dengan masing-masing jumlah *neuron* adalah 64, 32 dan 16. Masing-masing lapisan LSTM diikuti oleh *dropout* dengan jumlah *skip neuron* sebesar 20%, kemudian pada bagian akhir terdapat 1 *dense (fully connected layer)* yang memiliki *neuron* sebanyak 1. Fungsi dari *dense layer* adalah untuk menerima *output* dari lapisan sebelumnya. Desain lapisan LSTM yang berhasil dirancang ditampilkan pada Gambar 2.

Layer (type)	Output Shape	Param #
lstm_143 (LSTM)	(None, 7, 64)	19,712
dropout_141 (Dropout)	(None, 7, 64)	0
lstm_144 (LSTM)	(None, 7, 32)	12,416
dropout_142 (Dropout)	(None, 7, 32)	0
lstm_145 (LSTM)	(None, 16)	3,136
dropout_143 (Dropout)	(None, 16)	0
dense_65 (Dense)	(None, 1)	17
Total params: 35,264 (137.82 KB)		
Trainable params: 35,264 (137.82 KB)		
Non-trainable params: 0 (0.00 B)		


Gambar 2. Desain LSTM yang Dirancang.

Simulasi pelatihan data dilakukan menggunakan *hyper parameter* Nadam [23] dengan *learning_rate* = 0,005 *beta_1* = 0,9, *ema_momentum* = 0,99 dan *loss function* menggunakan *mae* dan *R²*. Selanjutnya *epoch* diatur sebanyak 100 kali dengan *batch_size* = 128. Namun pada proses *epoch* digunakan mekanisme *early stop* dengan nilai *patient* = 8 sehingga jika tidak ada *improvement* sebanyak 8 kali berturut-turut di dalam *epoch* maka proses *training* akan dihentikan dan bobot terbaik dari model akan disimpan, hal ini dimaksudkan untuk mencegah model mengalami *overfitting*.

Hasil dari proses *training* data yang dilakukan menunjukkan bahwa skor *train mae* adalah 0,0387 dan skor *validation mae* adalah 0,0138. Proses *training* berhenti pada *epoch* ke 97 karena model sudah tidak melakukan *improvement* sebanyak 8 kali berturut-turut. Hasil pelatihan menunjukkan bahwa nilai *error* memiliki fluktuasi penurunan dan kenaikan pada setiap metrik yang digunakan. Visualisasi hasil pelatihan model ditunjukkan pada Gambar 3.

Gambar 3. Visualisasi skor *Train Loss Mae* dan *Validation Loss Mae*.


Metrik selanjutnya yang menjadi perhatian adalah R^2 . Proses pelatihan mengalami fluktuasi yang cukup besar pada *epoch* 0 sampai dengan 15. Namun pada *epoch* 16 sampai dengan 97 fluktuasi sudah mulai berkurang dan lebih stabil dengan *improvement* yang linear antara *train* dan *validation score* sehingga proses *training* terhenti pada *epoch* 97 dengan skor *validation* R^2 sebesar 0,9741 dengan hasil visualisasi ditunjukkan pada Gambar 4.

Gambar 4. Visualisasi *Train R^2* dan *Validation R^2* .

Bagian terakhir dari proses pelatihan yang dilakukan adalah menyimpan model ke dalam ekstensi H5.

3.4 Hasil Evaluasi Model

Proses evaluasi model dilakukan dengan cara membaca kembali model yang telah disimpan pada proses pelatihan sebelumnya. Model yang telah dilatih kemudian diuji coba memprediksi data uji yang telah dipisahkan sebelumnya yaitu data dari tanggal 1 sampai 31 Agustus 2025. Visualisasi dari *output* yang dihasilkan oleh prediksi model dengan data uji ditunjukkan pada Gambar 5 dan Tabel 7.



Gambar 5. Visualisasi Perbandingan Hasil Prediksi Dengan Data Aktual

Tabel 7. Hasil Evaluasi Model

Metrik	Skor
<i>Mean Absolute Error</i>	22,59%
<i>R² Score</i>	80,55%

Berdasarkan data yang disajikan pada Tabel 7 menunjukkan bahwa model yang telah dirancang mampu melakukan prediksi harga *Ethereum* pada data uji yang sama sekali belum pernah dipelajari sebelumnya dengan skor kegagalan mencapai 22,59%.

4. KESIMPULAN

Berdasarkan hasil penelitian yang diperoleh maka dapat ditarik kesimpulan sebagai berikut:

1. Proses *preprocessing* berhasil menyiapkan dataset dengan 13 fitur optimal sebagai input bagi model LSTM. Arsitektur yang digunakan terdiri dari tiga lapisan (64, 32, dan 16 *neuron*), *dropout* 20%, serta satu *dense layer* tunggal yang memungkinkan model mempelajari pola historis harga *Ethereum* secara lebih efektif. Hasil pelatihan menunjukkan performa baik dengan MAE 0,0387 dan R^2 0,9741, sedangkan evaluasi pada data uji Agustus 2025 menghasilkan MAE 22,59% dan R^2 80,55%. Dengan demikian, penelitian ini berhasil membuktikan efektivitas LSTM dalam melakukan prediksi harga *Ethereum*, meskipun masih diperlukan pengembangan lanjutan untuk menekan *error* pada data baru agar model semakin adaptif dan sesuai dengan kebutuhan praktis, khususnya dalam konteks prediksi harga kripto secara *real-time*.
2. Penelitian ini berkontribusi secara akademis dengan memperkuat literatur terkait penerapan LSTM pada prediksi harga kripto berbasis data jangka panjang, serta secara praktis memberikan wawasan bagi investor dan regulator dalam memahami volatilitas ETH. Namun, efisiensi komputasi masih menjadi tantangan sehingga metode alternatif seperti GRU, CNN-LSTM, atau Transformer dapat dieksplorasi pada penelitian mendatang.

5. SARAN

1. Melakukan perbandingan kinerja LSTM dengan model lain seperti GRU, CNN-LSTM, atau Transformer, serta menambahkan variabel eksternal seperti sentimen pasar dan indikator ekonomi global agar prediksi harga *Ethereum* lebih optimal dan komprehensif.
2. Mengoptimalkan parameter model dengan teknik regularisasi maupun arsitektur *hybrid* guna meningkatkan akurasi prediksi sekaligus menekan kebutuhan komputasi yang tinggi.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Fakultas Teknik dan Informatika, Program Studi Ilmu Komputer Universitas Widya Gama Mahakam Samarinda, serta para dosen atas dukungan finansial dan bimbingan dalam pelaksanaan penelitian ini.

DAFTAR PUSTAKA

- [1] A. Widiana, F. E. B. Sitepu, N. Natasya, S. J. Nur'ain, and D. Sakuntala, "Dampak Digitalisasi Keuangan Terhadap Stabilitas Sistem Keuangan Global," *Jurnal Studi Ilmu Akuntansi*, vol. 3, no. 2, pp. 1–25, 2024.
- [2] E. P. Ningrum, Hartono, and N. Adriana, "Peran Teknologi Blockchain dalam Meningkatkan Transparansi dan Efisiensi Sistem Keuangan dan Akuntansi," *Journal Scientific of Mandalika*, vol. 6, no. 7, pp. 2809–0543, 2025.
- [3] A. Arwani and U. Priyadi, "Eksplorasi Peran Teknologi Blockchain dalam Meningkatkan Transparansi dan Akuntabilitas dalam Keuangan Islam: Tinjauan Sistematis," *Jurnal Ekonomi Bisnis dan Manajemen*, vol. 2, no. 2, pp. 23–37, Mar. 2024, doi: 10.59024/jise.v2i2.653.
- [4] T. Stiyo Famuji, Herman, and Sunardi, "Smart Contract Penyimpanan Data Genetika Manusia Berbiaya Murah Pada Blockchain Ethereum," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 11, no. 3, pp. 695–704, 2024, doi: 10.25126/jtiik.2024117558.
- [5] F. S. Fadilah, K. Agustin, A. Agustian, A. Rauf, and A. Reza, "Peningkatan Skalabilitas Jaringan Ethereum Melalui Implementasi Sharding: Studi Kasus dan Evaluasi Kinerja," *Jurnal SENTIMETER*, vol. 4, 2025.
- [6] R. Benediktus, Al-Amin, Rahmat, Zuwardi, and I. Izmuddin, "Memahami Nilai Tukar Kripto dalam Ekonomi Digital: Pendekatan Investasi di Masa Kini," *Jurnal Ilmu Pendidikan, Ekonomi dan Teknologi*, vol. 1, no. 6, pp. 560–571, 2024.
- [7] S. Darmawan and W. Azizah, "Analisis Volatilitas Harga Bitcoin Setelah Halving Terhadap Harga Ethereum, Tether, Binance Coin, dan USDC," *SAINS: Jurnal Manajemen dan Bisnis*, vol. 17, no. 2, 2025, doi: <http://dx.doi.org/10.35448/jmb.v17i2.28065>.
- [8] D. M. Nugraha and D. Ariatmanto, "Meningkatkan Akurasi Prediksi Harga Bitcoin dengan Algoritma GRU-LSTM Hibrida," *JURNAL BUFFER INFORMATIKA*, vol. 11, no. 1, pp. 16–26, 2025, [Online]. Available: <https://journal.fkom.uniku.ac.id/index.php/buffer>
- [9] I. Carolina and T. Haryanto, "Modeling Of Hyperparameter Tuned RNN-LSTM and Deep Learning For Garlic Price Forecasting In Indonesia," *JOURNAL OF INFORMATICS AND TELECOMMUNICATION ENGINEERING*, vol. 7, no. 2, pp. 502–513, Jan. 2024, doi: 10.31289/jite.v7i2.10714.
- [10] H. D. Diash, V. Nathania, M. Idhom, and Trimono, "Application of CNN-BiLSTM Algorithm for Ethereum Price Prediction," *Journal of Applied Informatics and Computing (JAIC)*, vol. 9, no. 4, pp. 1709–1714, 2025, doi: <https://doi.org/10.30871/jaic.v9i4.9757>.
- [11] S. M. Natzir and H. Jatiprasetya, "Prediksi Harga Cryptocurrency XLM Menggunakan Metode Deep Learning LSTM dan GRU," *JURNAL TEKNOLOGI INFORMASI*, vol. 16, no. 1, pp. 49–58, 2025, doi: 10.52972/hoaq.vol16no1.
- [12] N. Azzahra, M. D. Handayani, and A. Aliyah, "Evaluasi Kinerja AI berbasis Recurrent Neural Network (RNN) dalam Mengidentifikasi Ancaman Phising pada URL Website," *Bridge : Jurnal Publikasi Sistem Informasi dan Telekomunikasi*, vol. 3, no. 3, pp. 15–37, Jun. 2025, doi: 10.62951/bridge.v3i3.485.
- [13] T. B. Sianturi, I. Cholissodin, and N. Yudistira, "Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga

- Ethereum,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 7, no. 3, pp. 1101–1107, Mar. 2023, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [14] A. A. S. Pradhana and K. S. Batubulan, “LSTM Network Application for Forecasting Ethereum Price Changes and Trends,” *JSIKTI: Jurnal Sistem Informasi dan Komputer terapan Indonesia*, vol. 7, no. 2, pp. 64–73, Oct. 2024, doi: 10.26594/register.v8i2.2541.
- [15] I. F. Riziq and A. R. Dzirkillah, “Implementasi Algoritma LSTM Dan SVR Untuk Prediksi Harga Bitcoin Menggunakan Data Yahoo Finance,” *METIK JURNAL*, vol. 9, no. 2, p. 2025, 2025, doi: 10.47002/metik.v9i2.1077.
- [16] N. O. Idris and F. Pontoiyo, “Evaluasi Model Machine Learning untuk Prediksi Harga Mobil dengan Perbandingan Ensemble dan Regresi Linear,” *Jurnal Ilmu Komputer dan Sistem Informasi (JIRSI)*, vol. 2025, no. 1, pp. 129–143, 2025, [Online]. Available: <https://jurnal.unity-academy.sch.id/index.php/jirsi/index>
- [17] E. Fiola, F. Yulius, D. M. Risani, M. Alvionita, and F. D. Irawati, “Metode Seleksi Variabel dalam Pemodelan Regresi Linear Data Curah Hujan Provinsi Lampung,” *Seminar Nasional Sains Data*, vol. 2024, 2024.
- [18] R. A. Saputra and A. Pratama, “Implementasi Decision Tree untuk Prediksi Harga Rumah di Daerah Tebet,” *Journal of Information System Management (JOISM)*, vol. 6, no. 2, pp. 164–170, 2025.
- [19] R. R. Hallan and I. N. Fajri, “Prediksi Harga Rumah menggunakan Machine Learning Algoritma Regresi Linier,” *Jurnal Teknologi Dan Sistem Informasi Bisnis*, vol. 7, no. 1, pp. 57–62, Jan. 2025, doi: 10.47233/jteksis.v7i1.1732.
- [20] N. Syakrani and N. A. S. R, “Konsistensi Model Regresi Empat Variabel Pada Populasi dan Sampel untuk Prediksi Temperatur,” *Journal of Applied Computer Science and Technology*, vol. 6, no. 1, pp. 9–16, Jun. 2025, doi: 10.52158/jacost.v6i1.971.
- [21] Fusion Media Limited, “Data Historis Ethereum - Investing.com,” <https://id.investing.com/crypto/ethereum/historical-data>. Accessed: Aug. 25, 2025. [Online]. Available: <https://id.investing.com/crypto/ethereum/historical-data>
- [22] J. Cahyani, S. Mujahidin, and T. P. Fiqar, “Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional,” *Jurnal Sistem dan Teknologi Informasi (JustIN)*, vol. 11, no. 2, pp. 346–357, Apr. 2023, doi: 10.26418/justin.v11i2.57395.
- [23] Keras Team, “Nadam,” <https://github.com/keras-team/keras/blob/v3.11.3/keras/src/optimizers/nadam.py#L7>. Accessed: Aug. 25, 2025. [Online]. Available: <https://keras.io/api/optimizers/Nadam/>