

# Kombinasi LSTM dan GRU Untuk Prediksi Harga Bitcoin

Derri Nuril Wardana<sup>1</sup>, Yuni Yamasari<sup>2</sup>

<sup>1,2</sup> Program Studi S1 Teknik Informatika, Universitas Negeri Surabaya

<sup>1</sup>[derri.22051@mhs.unesa.ac.id](mailto:derri.22051@mhs.unesa.ac.id)

<sup>2</sup>[yuniyamasari@unesa.ac.id](mailto:yuniyamasari@unesa.ac.id)

**Abstrak**— Bitcoin merupakan aset kripto yang memiliki tingkat besaran jarak naik dan turunnya harga yang sangat tinggi sehingga sulit diprediksi secara akurat. Pergerakan harga dipengaruhi dari berbagai faktor, termasuk sentimen pasar dari para pelaku pasar, situasi ekonomi global, dan aktivitas perdagangan. Tujuan penelitian ini adalah mengembangkan model peramalan harga Bitcoin menggunakan kombinasi *Long Short-Term Memory (LSTM)* dan *Gated Recurrent Unit (GRU)*. Dataset yang digunakan berbentuk data historis harga penutupan Bitcoin per USD yang diperoleh dari Yahoo Finance dengan periode Oktober 2014 hingga Februari 2023. Data diproses melalui tahap normalisasi menggunakan *Min-Max Scaling* dan menggunakan metode *sliding window* dengan ukuran window 30 dan 60. Pengujian dilakukan dengan beberapa skenario pembagian data, yaitu 90:10, 85:15, 80:20, 70:30, 60:40, dan 50:50, dengan jumlah epoch sebanyak 50 dan 100. Evaluasi model dilakukan menggunakan  $R^2$ , MAE, RMSE, dan MSE. Hasil penelitian menunjukkan bahwa model kombinasi LSTM dan GRU menghasilkan performa yang sangat baik dengan nilai yang diperoleh pada window size 30, pembagian data 60:40, dan epoch 50, yaitu  $R^2$  sebesar 0,991726, MAE sebesar 0,013888, RMSE sebesar 0,020943, dan MSE sebesar 0,000439.

**Kata Kunci**— Bitcoin, Prediksi Harga, Deep Learning, *Long Short-Term Memory*, *Gated Recurrent Unit*, *Time Series*.

## I. PENDAHULUAN

Bitcoin merupakan salah satu aset crypto dengan penganggaran modal pasar terbesar dan tingkat penggunaannya yang terus meningkat sejak diperkenalkan pada tahun 2009[1], [2], [3]. Hal itu menjadikan Bitcoin sebagai instrumen investasi yang menarik, Akan tetapi di sisi lain memiliki tingkat besaran jarak naik dan turunnya harga yang sangat tinggi. Pergerakan harga Bitcoin dapat di pengaruhi oleh berbagai hal, seperti sentimen pasar, volume perdagangan, kondisi ekonomi global, serta aktivitas investor berskala besar, sehingga menyulitkan proses prediksi harga secara akurat[2], [4], [5].

Pendekatan konvensional dalam analisis pasar keuangan, seperti metode statistik dan analisis teknikal tradisional, umumnya memiliki keterbatasan dalam menangkap pola non-linear dan dependensi jangka panjang yang terdapat pada data deret waktu harga Bitcoin[6]. Oleh karena itu, pembelajaran mesin dan pembelajaran mendalam semakin banyak digunakan

karena mereka dapat secara adaptif mengenali pola kompleks dari data historis[7].

Arsitektur pembelajaran mendalam yang banyak digunakan untuk peramalan deret waktu dengan menggunakan LSTM. LSTM dibentuk untuk mengatasi masalah gradien yang menghilang dan untuk mendeteksi ketergantungan jangka panjang[8], [9]. Akan Tetapi, LSTM memiliki kerumitan komputasi yang relatif tinggi dan membutuhkan waktu pelatihan yang cukup besar. Sebagai alternatif, *Gated Recurrent Unit* dipakai dengan struktur yang lebih sederhana dan efisien, namun tetap memiliki kemampuan dalam menangkap pola temporal[10], [11]. Beberapa penelitian terdahulu menunjukkan bahwa masing-masing model memiliki keunggulan dan keterbatasan dalam memprediksi data deret waktu yang bersifat volatil[1], [3].

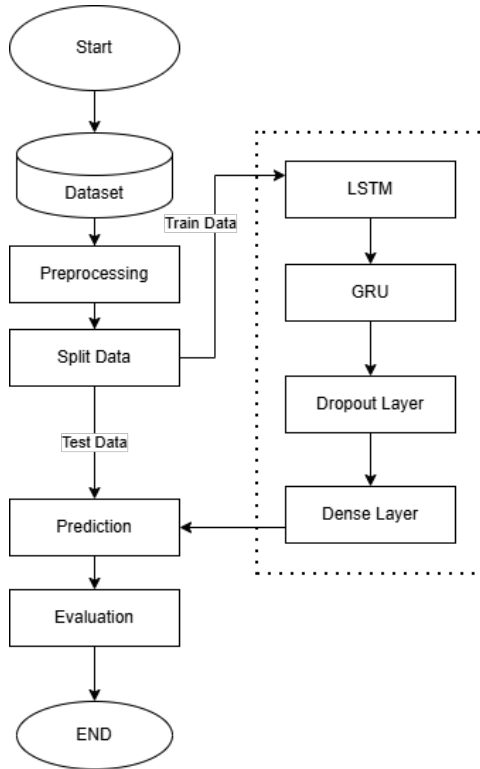
Untuk mengatasi keterbatasan tersebut, pendekatan kombinasi antara LSTM dan GRU mulai banyak diteliti karena mampu memanfaatkan keunggulan dalam arsitektur[12], [13]. LSTM berperan dalam menangkap ketergantungan jangka panjang, sementara GRU meningkatkan efisiensi komputasi dan stabilitas proses pembelajaran. Namun, performa model deep learning sangat dipengaruhi oleh pemilihan hyperparameter yang tepat. Penentuan hyperparameter secara manual atau menggunakan metode grid search dan random search sering kali membutuhkan waktu komputasi yang tinggi dan kurang efisien[14], [15].

Kontribusi utama dari penelitian ini berupa mengusulkan model prediksi harga Bitcoin berbasis kombinasi LSTM-GRU, mengevaluasi performa model pada berbagai skenario pembagian data yaitu 90:10, 85:15, 80:20, 70:30, 60:40, dan 50:50. Dengan data deret waktu di bagi menjadi pasangan input dan output menggunakan pendekatan *sliding window*, kemudian model dilatih menggunakan data pelatihan dengan jumlah epoch sebanyak 50 dan 100.

Oleh sebab itu, Penelitian ini mengusulkan model kombinasi LSTM-GRU. Mekanisme ini memungkinkan model untuk mengingat dan memperbarui informasi penting dalam jangka Panjang dengan menggunakan Periode data yang digunakan berupa rentang waktu dari Oktober 2014 hingga Februari 2023, dengan mengambil satuan utama berupa harga penutupan.

## II. METODOLOGI PENELITIAN

Pada Gambar 937 memberikan penjelasan mengenai alur dari metode kombinasi *Long Short-Term Memory* dan *Gated Recurrent Unit*.



Gambar 1 Diagram Alur Penelitian

#### A. Dataset

Dataset yang dipakai dalam penelitian ini menggunakan data riwayat harga Bitcoin per USD dengan frekuensi harian[16]. Dataset diperoleh dari Yahoo Finance melalui pustaka yfinance pada bahasa pemrograman Python. Periode data yang digunakan berupa rentang waktu dari Oktober 2014 hingga Februari 2023, dengan variabel utama berupa harga penutupan [17]. Harga penutupan dipilih karena merepresentasikan nilai akhir transaksi harian dan umum digunakan sebagai indikator utama dalam analisis pergerakan harga aset keuangan. Seluruh data disesuaikan menggunakan standar waktu *Coordinated Universal Time* untuk menjaga konsistensi temporal dan menghindari pergeseran waktu antar data[15], [18].

#### B. Normalisasi

Normalisasi di perlukan sebelum data digunakan dalam proses pelatihan, data terlebih dahulu melalui tahap praproses untuk meningkatkan kualitas dan kesesuaian dengan karakteristik model deep learning. Nilai yang hilang pada dataset ditangani menggunakan metode interpolasi linear guna menjaga kontinuitas data deret waktu tanpa menghilangkan pola historis. Selanjutnya, data dinormalisasi menggunakan metode Min-Max Scaling ke denang rentang angka yang digunakan 0 hingga 1. Normalisasi ini bertujuan untuk mempercepat konvergensi model dan mencegah dominasi nilai tertentu selama proses pembelajaran[1], [16].

#### C. Split Data

Setelah normalisasi, data urutan waktu di bagi menjadi bagian input dan output menggunakan pendekatan *sliding window*. Data historis dari periode sebelumnya berfungsi sebagai input untuk memprediksi harga untuk periode berikutnya. Pendekatan ini memungkinkan model untuk mempelajari pola temporal dan ketergantungan jangka pendek dan jangka panjang dengan lebih efisien. Dataset yang telah ditransformasi kemudian dipartisi menjadi data pelatihan dan pengujian menggunakan skenario, 90:10, 85:15, 80:20, 70:30, 60:40, dan 50:50


#### D. Model LSTM dan GRU

Model LSTM tunggal dibangun menggunakan *Sequential API* dari Keras dengan memanfaatkan satu atau lebih lapisan *Long Short-Term Memory* sebagai komponen utama pemodelan deret waktu. LSTM dirancang untuk mengatasi masalah gradien yang menghilang pada jaringan saraf berulang dengan memperkenalkan sel memori dan mekanisme gerbang yang terdiri dari gerbang masukan, gerbang lupakan, dan gerbang keluaran. Mekanisme ini memungkinkan model untuk mempertahankan dan memperbarui informasi jangka panjang yang penting, sehingga ideal untuk memodelkan dinamika harga Bitcoin yang dipengaruhi oleh tren historis dan tren jangka panjang.

$$\begin{aligned}
 f_t &= \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \\
 i_t &= \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \\
 \tilde{C}_t &= \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \\
 o_t &= \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \\
 C_t &= f_t * C_{t-1} + i_t * \tilde{C}_t \\
 h_t &= o_t * \tanh(C_t)
 \end{aligned} \tag{1}$$

Model GRU tunggal juga dibangun menggunakan *Sequential API* dari Keras dengan memanfaatkan lapisan *Gated Recurrent Unit* sebagai inti arsitektur. GRU merupakan varian dari jaringan saraf berulang yang menyederhanakan struktur LSTM dengan menggabungkan mekanisme Gerbang masuk dan gerbang lupa digabungkan menjadi satu gerbang pembaruan, dan gerbang pengaturan ulang digunakan untuk mengontrol aliran informasi. Struktur yang lebih sederhana ini memungkinkan GRU memiliki lebih sedikit parameter daripada LSTM, sehingga membuatnya lebih efisien secara komputasi. dan lebih cepat dalam proses pelatihan seperti yang terdapat pada Gambar 2.

$$\begin{aligned}
 z_t &= \sigma(w_z \cdot [h_{t-1}, x_t] + b_z) \\
 r_t &= \sigma(w_r \cdot [h_{t-1}, x_t] + b_r) \\
 \tilde{h}_t &= \tanh(w_h \cdot [r_t * h_{t-1}, x_t] + b_h) \\
 h_t &= (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t
 \end{aligned} \tag{2}$$



Gambar 2 Arsitektur Kombinasi LSTM dan GRU

E. Evaluasi Model

Model yang telah dioptimalkan kemudian dilatih menggunakan pengaturan epoch sebanyak 50 dan 100 epoch. Selanjutnya, model tersebut diuji menggunakan data uji untuk mengevaluasi kinerja prediksinya. Evaluasi dilakukan menggunakan berbagai macam, seperti *Mean Absolute Error*, *Root Mean Square Error*, *Mean Square Error*, dan  $R^2$ . Penggunaan metrik evaluasi ini bertujuan untuk memberikan gambaran umum tentang tingkat akurasi model, kesalahan prediksi, dan kemampuannya untuk merepresentasikan varians harga Bitcoin.

$$R^2 = 1 - \frac{\sum(x_i - \hat{x})^2}{\sum(x_i - \bar{x})^2} \quad (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n [x_i - \hat{x}]^2 \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x})^2} \quad (5)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x})^2 \quad (6)$$

III. HASIL DAN PEMBAHASAN

Eksperimen dilakukan untuk mengevaluasi kinerja model kombinasi LSTM-GRU dalam memprediksi harga Bitcoin. Pengujian dilakukan pada beberapa skenario pembagian data, yaitu 90:10, 85:15, 80:20, 70:30, 60:40, dan 50:50, dengan

jumlah epoch pelatihan sebanyak 50 dan 100 pada setiap skenario.

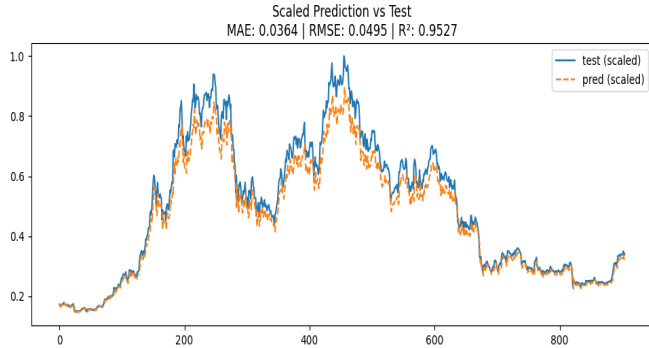
TABEL I HASIL LSTM-GRU WINDOW 30

Split Data	R <sup>2</sup>	MAE	RMSE	MSE
Epoch 50				
90:10	0.984690	0.008278	0.012947	0.000168
85:15	0.987471	0.016749	0.021784	0.000475
80:20	0.985507	0.018093	0.024495	0.000600
70:30	0.979195	0.023167	0.032855	0.001079
60:40	0.989348	0.016343	0.026275	0.000690
50:50	0.989778	0.015418	0.026108	0.000682
Epoch 100				
90:10	0.985351	0.008592	0.012665	0.000160
85:15	0.988376	0.015592	0.020983	0.000440
80:20	0.988331	0.016332	0.021979	0.000483
70:30	0.952689	0.036387	0.049546	0.002455
60:40	0.991726	0.014110	0.023157	0.000532
50:50	0.984797	0.020099	0.031840	0.001014

TABEL I, hasil pengujian model LSTM-GRU dengan window 30 menunjukkan jika model dapat menghasilkan performa prediksi yang tinggi pada sebagian besar skenario pembagian data. Pada epoch 50, nilai R<sup>2</sup> tertinggi diperoleh pada pembagian data 50:50, yaitu 0,989778, dengan nilai MAE 0,015418, RMSE 0,026108, dan MSE 0,000682. Hasil ini menunjukkan bahwa model dapat memperoleh sekitar 98,97% variasi dalam data nyata, menghasilkan akurasi prediksi yang sangat baik. Selain itu, pembagian data 60:40 juga mencapai kinerja terbaik, dengan nilai R<sup>2</sup> sebesar 0,989348, ditunjukkan bahwa model lebih akurat dalam membuat prediksi untuk kumpulan data pelatihan dan pengujian yang berbeda.


Untuk ke-100 kalinya, model 30-jendela menunjukkan kinerja terbaik dalam mengklasifikasikan data. Nilai R<sup>2</sup> tertinggi diperoleh untuk pembagian 60:40, dengan area 0,991726, MAE 0,014110, RMSE 0,023157, dan MSE 0,000532. Hasil ini ditunjukkan bahwa meningkatnya jumlah epoch dapat meningkatkan

kemampuan dari model untuk memprediksi pola data historis. sehingga kesalahan prediksi menjadi lebih kecil. Namun demikian, pada pembagian data 70:30, nilai R<sup>2</sup> menurun menjadi 0,952689, yang menunjukkan bahwa pada skenario tertentu peningkatan epoch tidak selalu meningkatkan performa model secara konsisten.




Gambar 3 Nilai Min-Max Akurasi Terendah LSTM-GRU Window 30

Gambar 3 menunjukkan hasil prediksi dengan tingkat akurasi terendah pada model kombinasi LSTM-GRU dengan window size 30, pada skenario split data 70:30 dan epoch 100. Nilai evaluasi yang diperoleh, yaitu R<sup>2</sup> sekitar 0,9527 USD, serta RMSE sebesar 0,0495 USD dan MAE 0,0364. Performa ini merupakan yang terendah dibandingkan skenario pengujian lainnya, sehingga menunjukkan bahwa model mengalami penurunan kemampuan generalisasi pada konfigurasi tersebut dan menghasilkan tingkat kesalahan prediksi yang lebih besar



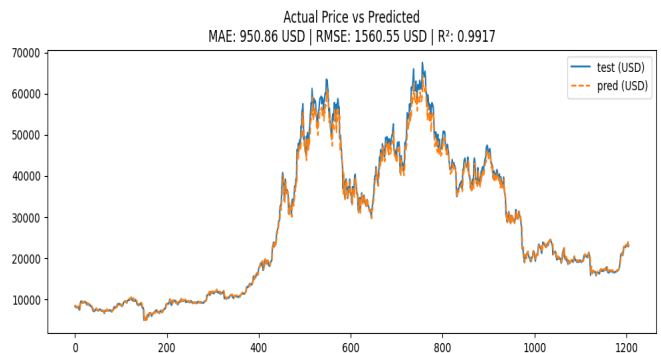
Gambar 4 Nilai Aktual Akurasi Terendah LSTM-GRU Window 30

Gambar 4 menunjukkan hasil prediksi dengan tingkat akurasi terendah pada model kombinasi LSTM-GRU dengan window size 30, pada skenario split data 70:30 dan epoch 100. Berdasarkan grafik nilai evaluasi yang diperoleh, yaitu MAE sekitar 2.452 USD, serta RMSE sebesar 3.338 USD. Performa ini merupakan yang terendah dibandingkan skenario pengujian lainnya, sehingga menunjukkan bahwa model mengalami penurunan kemampuan generalisasi pada konfigurasi tersebut dan menghasilkan tingkat kesalahan prediksi yang lebih besar.



Gambar 5 Nilai Min-Max Akurasi Tertinggi LSTM-GRU Window 30

Gambar 5 menunjukkan hasil prediksi dengan tingkat akurasi tertinggi pada model kombinasi LSTM-GRU dengan window size 30, pada skenario split data 60:40 dan epoch 100. Memiliki nilai R<sup>2</sup> sebesar 0,9917, MAE 0,0141, RMSE 0,0232 dan MSE 0,000532. Dengan nilai akurasi yang tinggi model mampu memprediksi berbagai harga actual, sedangkan nilai MAE, RMSE, dan MSE yang kecil menunjukkan tingkat kesalahan prediksi yang rendah. Hasil tersebut menunjukkan bahwa kombinasi LSTM-GRU dengan window size 30 dan epoch 100 mampu menghasilkan performa prediksi yang optimal, lebih baik dibandingkan dengan epoch 50.



Gambar 6 Nilai Aktual Akurasi Tertinggi LSTM-GRU Window 30


Gambar 6 menunjukkan hasil prediksi dengan tingkat akurasi tertinggi pada model kombinasi LSTM-GRU dengan window size 30, pada skenario split data 60:40 dan epoch 100. Pada grafik terlihat bahwa garis hasil prediksi hampir berimpit dengan garis data aktual, yang menunjukkan bahwa model mampu mengikuti pola pergerakan harga Bitcoin dengan sangat baik. Kesesuaian antara nilai aktual dan nilai prediksi ini tercermin pada nilai evaluasi yang diperoleh, MAE 950 usd, dan RMSE 1560 usd, Hasil tersebut menunjukkan bahwa kombinasi LSTM-GRU dengan window size 30 dan epoch 100 mampu menghasilkan performa prediksi yang optimal dalam mempelajari pola historis harga Bitcoin sehingga memberikan tingkat akurasi yang sangat tinggi.

TABEL II HASIL LSTM-GRU WINDOW 60

Split Data	R <sup>2</sup>	MAE	RMSE	MSE
Epoch 50				
90:10	0.983023	0.009060	0.013086	0.000171
85:15	0.990130	0.013290	0.018732	0.000351
80:20	0.989241	0.014665	0.021206	0.000450
70:30	0.965022	0.031415	0.042382	0.001796
60:40	0.991459	0.013888	0.020943	0.000439
50:50	0.989007	0.015808	0.027040	0.000731
Epoch 100				
90:10	0.981001	0.009648	0.013844	0.000192
85:15	0.979579	0.020279	0.026943	0.000726
80:20	0.982729	0.019938	0.026868	0.000722
70:30	0.948427	0.038531	0.051462	0.002648
60:40	0.977843	0.024431	0.037844	0.001432
50:50	0.984505	0.019963	0.032103	0.001031


TABEL II hasil pengujian model LSTM-GRU dengan window 60 juga ditunjukkan performa yang sangat baik. Pada epoch 50, nilai R<sup>2</sup> tertinggi diperoleh pada pembagian data 60:40, yaitu sebesar 0,991459, dengan nilai MAE sebesar 0,013888, RMSE sebesar 0,020943, dan MSE sebesar 0,000439. Hasil ini menunjukkan bahwa model dengan window size 60 mampu menghasilkan prediksi yang lebih akurat dibandingkan window size 30, terutama karena model memiliki lebih banyak data historis untuk mempelajari arah pergerakan harga Bitcoin.

Pada 100 epoch, performa model pada window 60 justru mengalami penurunan pada beberapa skenario pembagian data. Nilai R<sup>2</sup> tertinggi pada epoch 100 hanya mencapai 0,984505 pada pembagian data 50:50, dengan nilai MAE 0,019963, RMSE 0,032103, dan MSE 0,001031. Nilai ini lebih rendah dibandingkan hasil pada epoch 50, yang menunjukkan bahwa pelatihan yang terlalu lama pada window 60 berpotensi menyebabkan model mengalami *overfitting*, sehingga kemampuan generalisasi model terhadap data pengujian menurun.



Gambar 7 Nilai Min-Max Akurasi Terendah LSTM-GRU Window 60

Gambar 8 menunjukkan hasil prediksi dengan tingkat akurasi terendah pada model kombinasi LSTM-GRU dengan window size 60. Pada grafik terlihat bahwa garis hasil prediksi masih mampu mengikuti tren umum pergerakan harga Bitcoin, namun terdapat beberapa penyimpangan yang lebih besar dibandingkan hasil terbaik model, terutama pada periode ketika harga mengalami perubahan yang cukup signifikan. Kondisi ini sejalan dengan hasil evaluasi pada skenario pembagian data 70:30 dan epoch 100 yang menghasilkan nilai R<sup>2</sup> sebesar 0,9484, MAE 0,0385, RMSE 0,0515, dan MSE 0,002648. Nilai R<sup>2</sup> yang lebih kecil serta nilai salah yang lebih tinggi ditunjukkan bahwa model mengalami penurunan kemampuan dalam merepresentasikan pola data aktual. akurasi prediksi yang lebih rendah dibandingkan skenario lainnya



Gambar 8 Nilai Aktual Akurasi Terendah LSTM-GRU Window 60

Gambar 8 menunjukkan hasil prediksi dengan tingkat akurasi terendah pada model kombinasi LSTM-GRU dengan window size 60. Pada grafik terlihat bahwa garis hasil prediksi masih mampu mengikuti tren umum pergerakan harga bitcoin, namun terdapat beberapa penyimpangan yang lebih besar dibandingkan hasil terbaik model, terutama pada periode ketika harga mengalami perubahan yang cukup signifikan. Kondisi ini sejalan dengan hasil evaluasi pada skenario pembagian data 70:30 dan epoch 100 yang menghasilkan nilai R<sup>2</sup> 0,9484, MAE 2596 USD, RMSE 3467, sebesar Nilai R<sup>2</sup> yang lebih rendah serta nilai salah yang lebih banyak menunjukkan bahwa model mengalami penurunan kemampuan dalam merepresentasikan pola data actual.

#### IV. KESIMPULAN


Berdasarkan serangkaian eksperimen yang telah dilakukan, kombinasi metode *Long Short-Term Memory* dan *Gated Recurrent Unit* berhasil diterapkan untuk memprediksi harga Bitcoin berdasarkan data historis. Model yang dibangun dapat menghasilkan nilai yang bagus pada berbagai skenario pengujian dengan nilai  $R^2$  yang tinggi dan tingkat kesalahan yang rendah. Hasil terbaik diperoleh pada window size 60 dengan pembagian data 60:40 dan epoch 50 yang menghasilkan nilai  $R^2$  0,991459, MAE 0,013888, RMSE 0,020943, dan MSE 0,000439. Hasil tersebut menunjukkan bahwa kombinasi LSTM dan GRU mampu menangkap pola pergerakan harga Bitcoin secara efektif serta memberikan prediksi yang mendekati nilai aktual.

#### UCAPAN TERIMA KASIH

Puji syukur kepada Tuhan Yang Maha Esa atas segala rahmat dan karunia-Nya sehingga penelitian ini dapat selesai dengan baik. Saya mengucapkan terima kasih kepada kedua orang tua atas doa dan dukungannya, serta kepada Ibu Yuni Yamasari selaku dosen pembimbing karena telah memberikan arahan dan masukan selama proses penelitian. Terima kasih juga saya sampaikan kepada Universitas Negeri Surabaya khususnya Program Studi S1 Teknik Informatika


#### REFERENSI

- [1] S. Kazemina, H. Sajedi, and M. Arjmand, "Real-Time Bitcoin Price Prediction Using Hybrid 2D-CNN LSTM Model," 2023. doi: 10.1109/ICWR57742.2023.10139275.
- [2] S. Tanwar, N. P. Patel, S. N. Patel, J. R. Patel, G. Sharma, and I. E. Davidson, "Deep Learning-Based Cryptocurrency Price Prediction Scheme with Inter-Dependent Relations," *IEEE Access*, vol. 9, pp. 138633–138646, 2021, doi: 10.1109/ACCESS.2021.3117848.
- [3] R. M. Pattanayak, M. C. S. Raju, V. Vishnu, S. T. Vivek, and J. S. Rithwik, "Gated Recurrent Unit Based Deep Learning Model For Bitcoin Price Prediction," in *2nd IEEE International Conference on Integrated Intelligence and Communication Systems, ICHICS 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/ICHICS63763.2024.10859990.
- [4] P. L. Seabe, C. R. B. Moutsinga, and E. Pindza, "Forecasting Cryptocurrency Prices Using LSTM, GRU, and Bi-Directional LSTM: A Deep Learning Approach," *Fractal and Fractional*, vol. 7, no. 2, Feb. 2023, doi: 10.3390/fractalfrac7020203.
- [5] S. Mukherjee, B. Sadhukhan, N. Sarkar, D. Roy, and S. De, "Stock market prediction using deep learning algorithms," *CAAJ Trans. Intell. Technol.*, vol. 8, no. 1, pp. 82–94, Mar. 2023, doi: 10.1049/cit2.12059.
- [6] L. Cunha, "Deep learning with Python (2<sup>a</sup> ed) - François Chollet - Manning, outubro 2021, 504 pp.," *Interações: Sociedade e as novas modernidades*, no. 42, pp. 113–115, Jun. 2022, doi: 10.31211/interacoes.n42.2022.r1.
- [7] M. Javaid, A. Haleem, R. Pratap Singh, R. Suman, and S. Rab, "Significance of machine learning in healthcare: Features, pillars and applications," *International Journal of Intelligent Networks*, vol. 3, pp. 58–73, Jan. 2022, doi: 10.1016/j.ijin.2022.05.002.
- [8] J. Oruh, S. Viriri, and A. Adegun, "Long Short-Term Memory Recurrent Neural Network for Automatic Speech Recognition," *IEEE Access*, vol. 10, pp. 30069–30079, 2022, doi: 10.1109/ACCESS.2022.3159339.
- [9] G. Odiaga, N. Masinde, and C. Yoga, "Deep Learning for Cyberattack Detection: A Comparative Analysis of Deep Neural



Gambar 9 Nilai Min-Max Akurasi Tertinggi LSTM-GRU Window 60

Gambar 10 menunjukkan hasil prediksi dengan tingkatan akurasi tertinggi pada model kombinasi LSTM-GRU dengan window size, pada skenario split data 60:40 dan epoch 50. Berdasarkan grafik, garis hasil prediksi terlihat sangat dekat dengan garis data aktual, yang menandakan bahwa model mampu menangkap pola dan tren pergerakan harga Bitcoin secara akurat. Dengan nilai evaluasi yang diperoleh, yaitu  $R^2$  0,9915, MAE 935 Usd, dan RMSE 1411 Usd. Nilai  $R^2$  yang mendekati 1 menunjukkan bahwa model dapat menjelaskan sekitar 99,15% variasi data aktual, sedangkan nilai MAE, RMSE, dan MSE yang rendah menunjukkan tingkat kesalahan prediksi yang sangat kecil.



Gambar 10 Nilai Aktual Akurasi Tertinggi LSTM-GRU Window 60

Gambar 10 menunjukkan hasil prediksi dengan tingkat akurasi tertinggi pada model kombinasi LSTM-GRU dengan window size 60, yaitu pada skenario pembagian data 60:40 dan epoch 50. Berdasarkan grafik, garis hasil prediksi terlihat sangat dekat dengan garis data aktual, yang menandakan bahwa model mampu menangkap pola dan tren pergerakan harga Bitcoin secara akurat. Dengan nilai evaluasi yang diperoleh, yaitu  $R^2$  sebesar 0,9915, MAE sebesar 935 Usd, dan RMSE sebesar 1411 Usd. Nilai  $R^2$  yang mendekati 100 menunjukkan bahwa model tersebut memiliki nilai sekitar 99,15% nilai akurasi, sedangkan nilai MAE, RMSE, dan MSE yang rendah menunjukkan tingkat kesalahan prediksi yang sangat kecil. Dengan demikian, window size 60 dan epoch 50 dapat dianggap sebagai performa terbaik.

- Network (DNN), Long Short-Term Memory (LSTM), and Recurrent Neural Network (RNN),” *Journal of Soft Computing and Artificial Intelligence*, vol. 6, no. 2, pp. 39–54, Dec. 2025, doi: 10.55195/jsc.ai.1820478.
- [10] X. Song, L. Deng, H. Wang, Y. Zhang, Y. He, and W. Cao, “Deep learning-based time series forecasting,” *Artif. Intell. Rev.*, vol. 58, no. 1, Jan. 2025, doi: 10.1007/s10462-024-10989-8.
- [11] Q. Yu, G. Yang, X. Wang, Y. Shi, Y. Feng, and A. Liu, “A review of time series forecasting and spatio-temporal series forecasting in deep learning,” *Journal of Supercomputing*, vol. 81, no. 10, Jul. 2025, doi: 10.1007/s11227-025-07632-w.
- [12] S. M. Hasanat, M. Haris, K. Ullah, S. Z. Shah, U. Abid, and Z. Ullah, “Hybrid CNN–LSTM Model With Soft Attention Mechanism for Short-Term Load Forecasting in Smart Grid,” *Engineering Reports*, vol. 7, no. 5, May 2025, doi: 10.1002/eng.2.70163.
- [13] I. Akouaouch and A. Bouayad, “A new deep learning approach for predicting high-frequency short-term cryptocurrency price,” *Bulletin of Electrical Engineering and Informatics*, vol. 14, no. 1, pp. 513–523, Feb. 2025, doi: 10.11591/eei.v14i1.7377.
- [14] P. S. Pravin, J. Z. M. Tan, K. S. Yap, and Z. Wu, “Hyperparameter optimization strategies for machine learning-based stochastic energy efficient scheduling in cyber-physical production systems,” *Digital Chemical Engineering*, vol. 4, Sep. 2022, doi: 10.1016/j.dche.2022.100047.
- [15] K. Nam and J. Kim, “Determination and application of hyperparameters for landslide susceptibility assessment using Optuna: the Eunsan shallow landslides occurred on August 14, 2022, in Buyeo City, Chungcheong Province, Korea,” *Geosciences Journal*, vol. 29, no. 6, pp. 978–994, Dec. 2025, doi: 10.1007/s12303-025-00054-z.
- [16] Y. Yamasari, N. Nafisah, and E. Yohannes, “Hybrid Autoencoder Architectures with LSTM and GRU Layers for Bitcoin Price Prediction,” vol. 7, no. 4, pp. 687–700, 2025, doi: 10.35882/ijeemi.v7i4.132.
- [17] D. Miller and J. M. Kim, “Univariate and Multivariate Machine Learning Forecasting Models on the Price Returns of Cryptocurrencies,” *Journal of Risk and Financial Management*, vol. 14, no. 10, Oct. 2021, doi: 10.3390/jrfm14100486.
- [18] Y. Yu, J. Peeperkorn, J. De Smedt, and J. De Weerd, “A benchmarking study on process model forecasting: univariate vs. multivariate approaches,” *Process Science*, vol. 2, no. 1, Nov. 2025, doi: 10.1007/s44311-025-00031-7.