

Predicting Cryptocurrency Prices Using Machine Learning: A Case Study on Bitcoin

M. Alfarizi¹, Dinda Lestarini^{2*}

* Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Sriwijaya
09031182227016@student.unsri.ac.id¹, dinda@unsri.ac.id²

Article Info

Article history:

Received 2025-09-16

Revised 2025-11-07

Accepted 2025-11-12

Keyword:

*Bitcoin Price Prediction,
Cryptocurrency,
Machine Learning,
LSTM,
GRU.*

ABSTRACT

The rapid growth of cryptocurrencies, particularly Bitcoin, has drawn significant attention from investors and researchers due to its extreme price volatility. However, predicting the price of Bitcoin against the Indonesian Rupiah (BTC/IDR) remains a major challenge, especially in emerging markets such as Indonesia. This study aims to conduct an empirical comparison among three deep learning models Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), and one-dimensional Convolutional Neural Network (CNN-1D) in forecasting Bitcoin prices based on historical data obtained from the Indodax platform for the period 2018–2025. The dataset consists of five main variables: opening price, highest price, lowest price, closing price, and trading volume. Prior to model training, preprocessing steps were conducted, including handling missing values using the forward fill method, normalization with MinMaxScaler, and constructing time series data with a 60-day look-back window. The models were trained using an 80% training and 20% testing data split, the Adam optimizer, Mean Squared Error (MSE) as the loss function, for 50 epochs with a batch size of 32. Evaluation was performed using five quantitative metrics: MSE, RMSE, MAE, MAPE, and R², along with validation techniques to prevent data leakage. The results indicate that the GRU model achieved the best performance, with a MAPE of 1.77% and an R² of 0.9916, outperforming LSTM (MAPE 3.90%) and CNN-1D (MAPE 6.17%). These findings suggest that GRU is computationally more efficient and better adapted to nonlinear temporal dependencies in highly volatile markets. This research contributes to the academic discourse on the application of deep learning for digital asset price forecasting and provides practical implications for investors and developers of financial predictive systems in Indonesia. Future studies are expected to explore hybrid models or multi-step forecasting approaches to enhance real-time predictive performance.



This is an open access article under the [CC-BY-SA](#) license.

I. PENDAHULUAN

Perkembangan teknologi digital telah mengubah secara fundamental cara manusia berinteraksi dengan sistem keuangan global. Salah satu inovasi paling revolusioner di era ini adalah kemunculan mata uang kripto (*cryptocurrency*), yang beroperasi tanpa otoritas terpusat dan memanfaatkan teknologi *blockchain* sebagai basis keamanannya. Bitcoin merupakan mata uang digital yang menggunakan kode kriptografi dan dapat disimpan pada perangkat komputer[1]. Bitcoin, sebagai mata uang kripto pertama yang

diperkenalkan pada tahun 2009 oleh Satoshi Nakamoto, telah menjadi simbol dari transformasi ekonomi digital modern. Nilainya yang fluktuatif menjadikannya instrumen investasi berisiko tinggi namun menarik bagi investor di seluruh dunia, termasuk di Indonesia. Karena karakteristiknya yang terdistribusi, elastis, jelas, cepat, dan mempunyai biaya transaksi yang rendah, Bitcoin telah mendapatkan perhatian yang besar di dunia teknologi keuangan[2].

Meskipun popularitasnya terus meningkat, harga Bitcoin memiliki karakteristik volatilitas yang sangat tinggi. Perubahan harga yang ekstrem, berupa lonjakan tajam

maupun penurunan drastis dalam waktu singkat, menimbulkan risiko besar bagi investor dan menjadikan prediksi harga Bitcoin sebagai tantangan yang kompleks. Kesesuaian penggunaan transaksi aset kripto dalam perspektif hukum Islam dianggap haram karena terdapat elemen gharar. Unsur ini meliputi ketidakadaan bentuk fisik serta tingkat volatilitas yang sangat tinggi, di mana harga dapat berfluktuasi secara drastis dari waktu ke waktu. Oleh karena itu, keadaan ini menimbulkan ketidakpastian yang mirip dengan khimar (perjudian)[3]. Di Indonesia, urgensi penelitian mengenai prediksi harga kripto semakin kuat seiring meningkatnya jumlah investor aset digital. Semangat untuk melakukan investasi dalam aset kripto sangat mencolok, walaupun mereka memahami bahwa aset kripto membawa risiko tinggi karena perubahan harga yang tajam [4].

Fenomena ini semakin diperkuat dengan meningkatnya jumlah investor aset digital di Indonesia. Berdasarkan data Badan Pengawas Perdagangan Berjangka Komoditi (Bappebti, 2025), tercatat lebih dari 20 juta pengguna kripto aktif di Indonesia, menandakan bahwa aset digital telah menjadi bagian penting dalam ekosistem investasi nasional. Namun, tingginya volatilitas harga Bitcoin terhadap Rupiah (BTC/IDR) menyebabkan prediksi harga menjadi sulit dilakukan secara akurat, terutama dalam konteks pasar domestik yang masih berkembang. Fakta ini mempertegas kebutuhan akan model prediksi harga yang akurat dan adaptif untuk mendukung pengambilan keputusan investasi serta mitigasi risiko. Dengan menggunakan algoritma Pembelajaran Mesin dan memperhatikan faktor-faktor yang memengaruhinya, investor dapat lebih terampil dalam mengambil keputusan yang didasarkan pada informasi terkait strategi investasi mereka [5].

Fluktuasi harga Bitcoin dipengaruhi oleh berbagai faktor, baik internal maupun eksternal, seperti volume perdagangan, tingkat permintaan pasar, peristiwa ekonomi global, hingga sentimen publik di media sosial. Kondisi tersebut menciptakan tantangan tersendiri bagi pelaku pasar yang membutuhkan sistem prediksi harga yang handal dan berbasis data. Selama ini, sejumlah penelitian telah mencoba menerapkan berbagai pendekatan untuk memprediksi harga Bitcoin. Metode tradisional seperti Autoregressive Integrated Moving Average (ARIMA) dan regresi linier memang efektif dalam mengidentifikasi pola umum, namun keduanya sering kali kurang mampu menangkap dinamika nonlinier serta perubahan tiba-tiba yang menjadi karakteristik khas pasar kripto [6]. Dengan kemajuan teknologi, pendekatan berbasis machine learning dan deep learning semakin banyak diterapkan karena kemampuannya dalam mengekstraksi pola kompleks dari data historis serta memberikan tingkat akurasi prediksi yang lebih tinggi dibandingkan metode statistik konvensional [7].

Beberapa penelitian sebelumnya berfokus pada pasangan BTC/USD yang cenderung memiliki volume dan likuiditas tinggi. Namun, belum banyak kajian yang meneliti pasangan BTC/IDR, padahal kondisi ekonomi dan perilaku pasar

Indonesia memiliki karakteristik berbeda dari pasar global. Hal ini menjadikan penelitian berbasis konteks lokal penting untuk dilakukan, agar hasil yang diperoleh lebih relevan dan aplikatif bagi investor dalam negeri. Rasio yang dihasilkan antara data sebenarnya dan estimasi memiliki perbedaan sebesar 0,0026786069402187% dari data yang faktual[8].

Selain itu, mayoritas penelitian terdahulu hanya menyoroti performa model tunggal, tanpa melakukan perbandingan komprehensif antaralgoritma deep learning. Oleh karena itu, penelitian ini mencoba menjembatani kesenjangan tersebut dengan membandingkan tiga model populer, yaitu Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), dan Convolutional Neural Network satu dimensi (CNN-1D). Ketiga model ini memiliki keunggulan masing-masing, di mana LSTM dan GRU unggul dalam memahami ketergantungan jangka panjang pada data deret waktu (time series), sedangkan CNN-1D lebih baik dalam mengenali pola lokal atau tren jangka pendek. Melalui perbandingan ketiga model tersebut dalam konteks pasar kripto Indonesia, penelitian ini diharapkan dapat mengidentifikasi model yang paling tepat untuk diterapkan pada data dengan tingkat volatilitas tinggi, seperti pada aset Bitcoin [9]. Berdasarkan penelitian yang tersedia, LSTM sering diterapkan dalam metode prediksi yang menunjukkan tingkat akurasi sangat tinggi[10].

Hasil penelitian sebelumnya menunjukkan bahwa LSTM unggul dalam memprediksi tren jangka panjang, LSTM memiliki kemampuan yang sangat baik dalam menganalisis rincian perubahan harga, menangkap nuansa yang halus serta pola-pola kecil yang berpengaruh terhadap perubahan harga [11]. GRU menawarkan efisiensi komputasi dengan performa yang setara bahkan lebih baik dalam beberapa kasus, sedangkan CNN-1D relatif cepat dilatih namun cenderung lebih sesuai untuk prediksi jangka pendek. Gap penelitian yang muncul adalah belum adanya perbandingan komprehensif di konteks pasar Indonesia, khususnya dengan data historis Bitcoin dari Indodax.

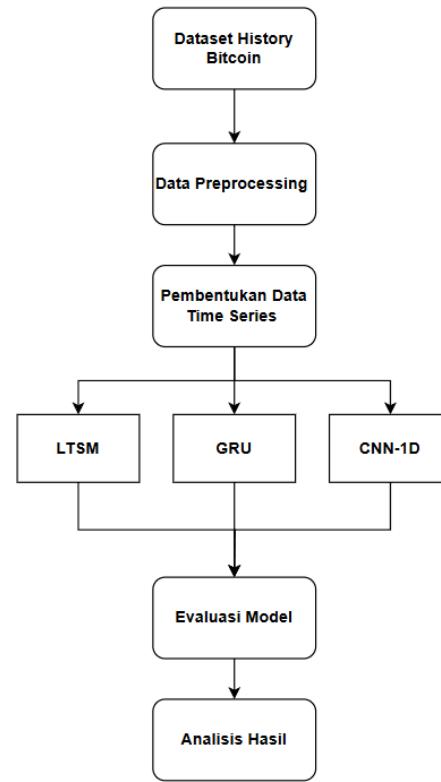
Dari sisi ilmiah, penelitian ini memberikan kontribusi dengan menjelaskan bagaimana perbedaan arsitektur model *deep learning* memengaruhi hasil prediksi harga Bitcoin terhadap Rupiah. Dari sisi praktis, penelitian ini diharapkan dapat menjadi acuan bagi pengembangan sistem *forecasting dashboard* atau *decision support system* yang membantu investor dan pelaku pasar dalam mengambil keputusan berbasis data. Secara khusus, tujuan penelitian ini adalah untuk, Membandingkan performa tiga model *deep learning* (LSTM, GRU, CNN-1D) dalam memprediksi harga Bitcoin terhadap Rupiah (BTC/IDR), Menentukan model dengan akurasi tertinggi berdasarkan metrik evaluasi MSE, RMSE, MAE, MAPE, dan R², Memberikan analisis ilmiah terhadap keunggulan dan keterbatasan masing-masing model, dan menyediakan landasan bagi pengembangan sistem prediksi harga kripto berbasis AI yang dapat diimplementasikan di lingkungan pasar Indonesia [12]. Model *Markowitz*, atau yang dikenal sebagai Model Rata-Rata Varians, adalah salah satu metode untuk menyusun portofolio yang paling efisien [13].

Kebaruan (novelty) penelitian ini terletak pada penerapan dataset BTC/IDR dengan periode data yang panjang (January 2018–Agustus 2025) dari platform Indodax, serta penggunaan kombinasi tiga model *deep learning* untuk mengukur efektivitas prediksi harga aset digital pada konteks lokal. Selain itu, penelitian ini menekankan pentingnya tahapan *preprocessing*, seperti normalisasi dan pembagian data yang sistematis, guna menghindari *data leakage* dan meningkatkan stabilitas hasil pelatihan model. Dengan demikian, penelitian ini tidak hanya berkontribusi terhadap pengembangan keilmuan di bidang *financial technology* dan *artificial intelligence*, tetapi juga memiliki implikasi praktis yang kuat dalam pengambilan keputusan keuangan di era digital yang semakin dinamis.

II. METODE

Penelitian ini dirancang secara sistematis untuk memperoleh hasil yang valid, terukur, dan dapat direplikasi dalam konteks prediksi harga aset kripto berbasis *deep learning*. Metodologi yang digunakan bertujuan untuk menjelaskan secara rinci tahapan penelitian mulai dari pengumpulan data, pengolahan, pembangunan model, hingga evaluasi performa. Dengan perancangan metode yang terstruktur, penelitian ini diharapkan mampu menghasilkan model prediksi yang tidak hanya akurat, tetapi juga memiliki dasar ilmiah yang kuat serta relevan untuk diterapkan pada kondisi pasar kripto di Indonesia. Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan tujuan membandingkan performa tiga model *deep learning* yang terdiri dari *Long Short-Term Memory* (LSTM), *Gated Recurrent Unit* (GRU), dan *Convolutional Neural Network* satu dimensi (CNN-1D) dalam memprediksi harga Bitcoin terhadap Rupiah (BTC/IDR).

Pendekatan ini dipilih karena mampu menghasilkan analisis numerik yang terukur dan objektif, serta memungkinkan evaluasi kuantitatif terhadap performa masing-masing model. Seluruh proses penelitian dilakukan secara sistematis melalui tahapan pengumpulan data, pembersihan dan normalisasi data (*preprocessing*), pembangunan model, pelatihan, serta evaluasi hasil prediksi. Hasil prediksi dari ketiga model dievaluasi menggunakan metrik statistik seperti MSE, RMSE, MAE, MAPE, dan R^2 untuk mengukur tingkat akurasi. Tahap akhir berupa perbandingan dan analisis dilakukan guna menilai performa terbaik di antara model yang digunakan serta memberikan gambaran komprehensif mengenai kelebihan dan keterbatasannya.



Gambar 1. Alur Penelitian

A. Dataset

Penelitian ini menggunakan data historis harga Bitcoin (BTC/IDR) yang diperoleh dari Indodax, salah satu platform perdagangan aset kripto terbesar di Indonesia[14]. Dataset mencakup periode Januari 2018 hingga Agustus 2025 dengan frekuensi data harian. Rentang waktu yang panjang ini dipilih untuk menangkap dinamika pasar kripto dalam jangka panjang dan memastikan variasi data mencerminkan volatilitas harga Bitcoin di pasar Indonesia. Data yang digunakan meliputi lima fitur utama, yaitu harga pembukaan, harga tertinggi, harga terendah, harga penutupan, dan volume transaksi. Pemilihan fitur tersebut didasarkan pada fakta bahwa kelima variabel ini merupakan indikator teknikal utama dalam analisis harga aset keuangan. Data pada tahun 2025 adalah data aktual hingga bulan Agustus, bukan hasil proyeksi. Semua data dikumpulkan dalam format CSV dan diolah menggunakan bahasa pemrograman Python dengan bantuan beberapa pustaka seperti *Pandas*, *NumPy*, dan *Matplotlib*.

Tanggal	Terakhir	Pembukaan	Tertinggi	Terendah	Vol	Perubahan%
14/08/2025	1.930.259,968	1.979.042,048	1.990.000,000	1.915.000,960		-2,46%
12/08/2025	1.959.406,976	1.945.010,944	1.961.897,984	1.930.334,976		0,74%
11/08/2025	1.945.010,944	1.936.585,984	1.979.000,064	1.935.664,000		0,44%
10/08/2025	1.936.585,984	1.898.320,000	1.937.396,992	1.898.001,024		2,02%
09/08/2025	1.898.321,024	1.898.025,984	1.910.000,000	1.891.027,968		0,02%
19/01/2018	163.484,992	160.604,992	166.000,000	152.707.008,076K		1,79%
18/01/2018	160.604,992	154.000,000	178.576,000	148.256.992,137K		4,29%
17/01/2018	154.000,000	146.371,008	158.666,000	125.003.000,181K		5,44%
16/01/2018	146.052,000	203.398,000	203.399,008	134.000,096,167K		-28,19%
15/01/2018	203.399,008	195.599,008	208.000,000	193.000.000,064K		3,99%

Gambar 2. Dataset Bitcoin

Sebagai contoh, pada tanggal 14 Agustus 2025, harga penutupan Bitcoin tercatat sebesar Rp1.930.259.968 dengan harga pembukaan Rp1.979.042.048, harga tertinggi Rp1.990.000.000, dan harga terendah Rp1.915.000.960, serta mengalami penurunan sebesar -2,46%. Sementara itu, data pada periode awal, misalnya 15 Januari 2018, menunjukkan harga penutupan sebesar Rp203.399.008 dengan persentase perubahan positif sebesar 3,99%. Rentang waktu yang cukup panjang ini memperlihatkan perbedaan ekstrem harga Bitcoin, dari ratusan juta rupiah di tahun 2018 hingga menembus lebih dari Rp1,9 miliar pada tahun 2025. Karakteristik data tersebut mencerminkan volatilitas tinggi yang menjadi ciri khas aset kripto. Oleh karena itu, dataset ini relevan digunakan sebagai basis pengujian model prediksi berbasis *Machine Learning*, karena mampu memberikan tantangan nyata dalam mengidentifikasi pola fluktuasi jangka pendek maupun tren jangka panjang.

B. Pre-processing

Sebelum digunakan dalam proses pelatihan, seluruh data melalui tahapan *preprocessing* untuk memastikan kualitas dan konsistensinya. Tahapan ini dimulai dengan pembersihan data untuk menghapus nilai duplikat dan anomali yang berpotensi memengaruhi hasil. Nilai yang hilang diisi menggunakan metode *forward fill*, di mana nilai kosong digantikan dengan data valid terakhir untuk menjaga kesinambungan urutan waktu. Selanjutnya dilakukan normalisasi dengan metode *MinMaxScaler* agar seluruh nilai berada dalam rentang [0,1]. Proses ini penting untuk mempercepat konvergensi model serta menjaga kestabilan pelatihan. Setelah itu, data disusun menjadi deret waktu dengan jendela pengamatan selama 60 hari, sehingga model dapat mempelajari pola harga selama 60 hari sebelumnya untuk memprediksi harga pada hari berikutnya. Pembagian data dilakukan secara kronologis dengan rasio 80% untuk pelatihan dan 20% untuk pengujian. Pembagian dilakukan tanpa acak (*non-random split*) untuk mencegah terjadinya *data leakage* antarperiode yang dapat menurunkan validitas hasil. Walaupun demikian, menjadikan data *stasioner* kadang dapat meningkatkan kinerja mereka dengan menyederhanakan struktur yang harus dipahami oleh model[15].

C. Pembentukan Data Time Series

Setelah melalui tahap *preprocessing*, data historis harga Bitcoin diubah ke dalam format deret waktu (*time series*) agar dapat dipelajari oleh model berbasis *deep learning*. Proses ini dilakukan dengan menggunakan pendekatan *look-back window* sepanjang 60 hari, yaitu setiap 60 data harga terakhir dijadikan sebagai masukan (*input sequence*) untuk memprediksi harga pada hari ke-61. Pembentukan pasangan data input-output ini dilakukan melalui fungsi `create_dataset()`, di mana variabel X merepresentasikan urutan harga pada 60 hari sebelumnya, sedangkan variabel y

merepresentasikan harga pada hari berikutnya yang menjadi target prediksi. Selanjutnya, data dibagi menjadi dua subset, yaitu 80% data latih dan 20% data uji, sehingga model dapat mempelajari pola harga dari data latih sekaligus dievaluasi pada data uji. Data input kemudian di-*reshape* ke dalam format tiga dimensi [*samples,timesteps,features*] agar sesuai dengan kebutuhan arsitektur LSTM dan GRU dalam menangkap pola temporal, serta mendukung CNN-1D dalam mengekstraksi pola spasial pada data deret waktu.

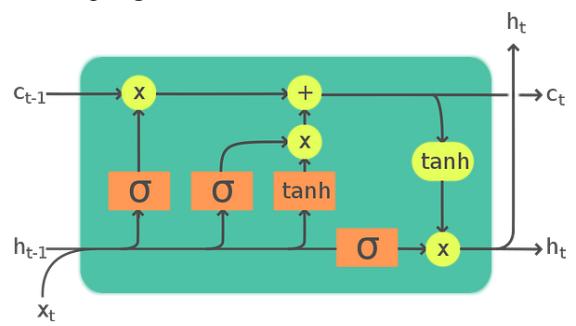
D. Arsitektur Model Machine Learning

Tiga model *deep learning* yang digunakan dalam penelitian ini dibangun menggunakan pustaka *TensorFlow* dan Keras. Model LSTM dirancang karena kemampuannya dalam mengenali hubungan jangka panjang pada data deret waktu, sementara GRU digunakan karena memiliki struktur yang lebih sederhana dan efisien dalam hal waktu pelatihan. CNN-1D digunakan untuk menguji sejauh mana arsitektur konvolusional dapat mendekripsi pola lokal pada data harga kripto. Ketiga model tersebut dilatih menggunakan *optimizer Adam* dengan fungsi kerugian *Mean Squared Error (MSE)*, jumlah neuron sebanyak 50, *batch size* sebesar 32, dan pelatihan selama 50 *epoch*. Untuk CNN-1D, digunakan 64 filter dengan ukuran kernel 2 dan fungsi aktivasi *ReLU*.

Proses pelatihan dilakukan dengan penerapan teknik *early stopping* untuk mencegah *overfitting*, di mana pelatihan dihentikan secara otomatis ketika nilai kesalahan pada data validasi tidak lagi menurun. Setiap model kemudian disimpan dalam format digital menggunakan perintah *model.save()* agar dapat digunakan kembali untuk keperluan analisis hasil atau replikasi penelitian.

1) Long Short-Term Memory

Metode LSTM (*Long Short-Term Memory*) merupakan jenis model *Recurrent Neural Network (RNN)* yang banyak digunakan untuk meramalkan harga Bitcoin dan aset keuangan lainnya[16]. Arsitektur LSTM memiliki kemampuan untuk menyimpan informasi penting dalam jangka panjang melalui mekanisme memory cell yang dilengkapi dengan tiga gerbang utama, yaitu *forget gate*, *input gate*, dan *output gate*.



Gambar 3. Arsitektur LSTM

Gambar 3 menunjukkan arsitektur internal sebuah unit LSTM. Input berupa x_t dan *hidden state* sebelumnya h_{t-1} diproses melalui ketiga gerbang untuk menghasilkan *cell state* baru (C_t) dan *hidden state* baru (h_t). Mekanisme ini

memungkinkan LSTM menyimpan informasi jangka panjang yang relevan sekaligus melupakan informasi yang tidak diperlukan. Secara matematis, mekanisme kerja LSTM dapat dijelaskan dengan persamaan berikut:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3)$$

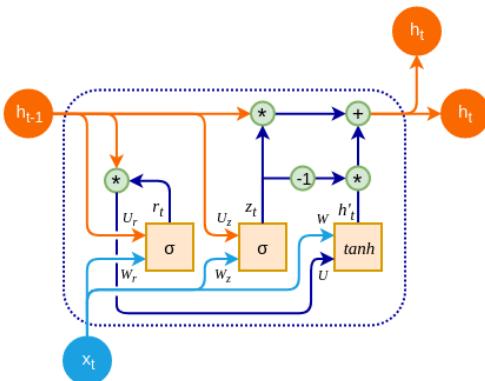
$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (4)$$

$$O_t = \sigma(W_O \cdot [h_{t-1}, x_t] + b_O) \quad (5)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (6)$$

2) Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) merupakan varian dari *Recurrent Neural Network* (RNN) yang dikembangkan sebagai penyederhanaan dari arsitektur LSTM. Metode ini mampu menyimpan data dari masa lalu melalui pengulangan dalam strukturnya, sehingga informasi masa lalu tetap terjaga dalam memori yang memfasilitasi pengenalan pola data dengan baik, kemudian memanfaatkan pola tersebut untuk menghasilkan prediksi[17]. GRU hanya menggunakan dua gerbang utama, yaitu *reset gate* dan *update gate*, yang mengontrol aliran informasi dari waktu ke waktu. Dengan jumlah parameter yang lebih sedikit dibandingkan LSTM, GRU lebih efisien secara komputasi, namun tetap mampu menangkap ketergantungan jangka panjang pada data deret waktu.



Gambar 4. Arsitektur GRU

Gambar 4 menunjukkan arsitektur internal unit GRU. Input pada waktu $t(x_t)$ bersama dengan *hidden state* sebelumnya (h_{t-1}) diproses melalui dua gerbang untuk menghasilkan *hidden state* baru (h_t). Sifat ini membuat GRU lebih ringan dibandingkan LSTM, namun tetap efektif dalam mengolah data deret waktu dengan pola fluktuatif.

Secara matematis, mekanisme GRU dapat dijelaskan dengan persamaan berikut:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (7)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (8)$$

$$\tilde{h}_t = \tanh(W \cdot [r_t \cdot h_{t-1}, x_t] + b) \quad (9)$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad (10)$$

3) Convolutional Neural Network 1-Dimensi (CNN-1D)

CNN-1D umumnya digunakan untuk data sekuensial, termasuk deret waktu, dengan tujuan mengekstraksi pola lokal menggunakan filter konvolusi. CNN-1D bekerja dengan menerapkan kernel konvolusi sepanjang sumbu waktu. Keunggulan CNN terletak pada kemampuannya untuk membedakan informasi dari data yang terbatas serta variasi sinyal yang tinggi yang berasal dari sumber yang berbeda [18].

Persamaan matematis CNN-1D dapat dituliskan sebagai berikut:

$$y(t) = (x * \omega) = \sum_{i=0}^{k-1} x(t+i) \cdot \omega(i) \quad (11)$$

Keterangan:

- x = input sequence
- ω = filter atau kernel konvolusi
- k = ukuran kernel
- $y(t)$ = output hasil konvolusi

Arsitektur CNN-1D umumnya terdiri dari lapisan konvolusi, diikuti dengan pooling layer untuk mereduksi dimensi, kemudian *fully connected layer* sebagai penghubung menuju lapisan output.

E. Proses Pelatihan dan Validasi

Model dilatih menggunakan 80% data sebagai *training set* dan 20% sebagai *testing set*, dengan tambahan 10% dari data latih digunakan sebagai *validation set* untuk mengurangi risiko *overfitting*. Proses pelatihan dijalankan selama 50 *epoch* dengan *batch size* 32, menggunakan *optimizer* Adam serta fungsi kerugian MSE. Untuk meningkatkan reliabilitas, dilakukan eksplorasi awal terhadap beberapa kombinasi *hyperparameter*. Eksperimen mencakup variasi jumlah *neuron* (50, 100, 150), ukuran *batch* (16, 32, 64), dan panjang *look-back window* (30, 60, 90 hari). Hasil pengujian menunjukkan bahwa konfigurasi dengan 50 *neuron*, *batch size* 32, dan *look-back window* 60 hari menghasilkan keseimbangan terbaik antara akurasi prediksi dan efisiensi komputasi. Oleh karena itu, konfigurasi ini ditetapkan sebagai pengaturan akhir pada seluruh model yang diuji.

F. Model Evaluasi

Evaluasi performa model dilakukan dengan menggunakan lima metrik utama yang umum dipakai dalam penelitian peramalan deret waktu, yaitu *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi (R^2). Kelima metrik tersebut digunakan untuk memberikan gambaran menyeluruh tentang akurasi, reliabilitas, dan ketstabilan prediksi. MSE dan RMSE menilai besar kesalahan absolut antara nilai aktual dan prediksi, MAE

menunjukkan rata-rata deviasi, sedangkan MAPE menilai tingkat kesalahan relatif terhadap nilai sebenarnya. R^2 digunakan untuk menunjukkan proporsi variasi data aktual yang mampu dijelaskan oleh model. Fungsi MSE adalah untuk menilai seberapa efektif sebuah model dalam menghubungkan nilai prediksi dengan nilai yang sebenarnya, menggunakan kuadrat kesalahan yang sekecil mungkin sebagai dasar perhitungan[19].

MSE mengukur rata-rata kuadrat selisih antara nilai aktual dan nilai prediksi, yang dirumuskan sebagai:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (12)$$

RMSE merupakan akar dari MSE sehingga hasil evaluasi berada pada skala yang sama dengan data asli:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (13)$$

MAE digunakan untuk menghitung rata-rata selisih absolut antara nilai aktual dan prediksi tanpa memperhatikan arah kesalahan:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (14)$$

MAPE menyatakan kesalahan dalam bentuk persentase relatif terhadap nilai aktual, sehingga memudahkan perbandingan antar model:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (15)$$

Adapun koefisien determinasi (R^2) digunakan untuk menilai seberapa besar variasi data aktual yang dapat dijelaskan oleh model, dengan rumus:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

Nilai R^2 mendekati 1 menunjukkan model memiliki kemampuan prediksi yang baik, sedangkan nilai mendekati 0 menunjukkan sebaliknya. Dengan menggunakan kombinasi kelima metrik ini, penelitian memperoleh gambaran menyeluruh terkait tingkat akurasi, stabilitas, dan reliabilitas dari masing-masing model (LSTM, GRU, dan CNN-1D) dalam meramalkan harga aset kripto.

III. HASIL DAN PEMBAHASAN

A. Pre Processing

Tahap *preprocessing* dilakukan untuk memastikan data yang diperoleh dari Indodax siap digunakan dalam proses pelatihan model *deep learning*. Data mentah yang terdiri dari kolom harga pembukaan, harga tertinggi, harga terendah,

harga penutupan, dan volume transaksi terlebih dahulu diubah ke dalam format numerik yang seragam. Proses ini mencakup konversi kolom tanggal ke format *datetime*, penghapusan simbol pemisah ribuan, penggantian tanda desimal, serta pembersihan karakter non-numerik seperti tanda persen. Selanjutnya, seluruh data diurutkan secara kronologis agar urutan waktu tetap konsisten. Proses ini penting karena model LSTM, GRU, dan CNN-1D sangat bergantung pada urutan temporal data dalam memahami pola harga. Setelah itu, dilakukan normalisasi menggunakan metode *MinMaxScaler* agar semua nilai berada pada rentang [0,1]. Normalisasi ini berfungsi untuk mempercepat proses konvergensi model dan menghindari dominasi fitur dengan skala nilai besar. Gambar 5 menunjukkan hasil pra-pemrosesan data, di mana seluruh variabel numerik telah berhasil dikonversi dan siap digunakan untuk tahap normalisasi serta pembentukan *look-back window* sebelum dimasukkan ke dalam model.

```
df["Tanggal"] = pd.to_datetime(df["Tanggal"], dayfirst=True)

for col in ["Terakhir", "Pembukaan", "Tertinggi", "Terendah", "Vol", "Perubahan%"]:
    df[col] = df[col].astype(str).replace(".", "", regex=False)
    df[col] = df[col].str.replace(",", ".", regex=False)
    df[col] = df[col].str.replace("%", "", regex=False)
    df[col] = pd.to_numeric(df[col], errors="coerce")

df = df.sort_values("Tanggal").reset_index(drop=True)

print(df.info())
print(df.head())

<class 'pandas.core.frame.DataFrame'>
RangeIndex: 2752 entries, 0 to 2751
Data columns (total 7 columns):
 #   Column      Non-Null Count  Dtype  
 --- 
 0   Tanggal     2752 non-null   datetime64[ns]
 1   Terakhir    2752 non-null   int64  
 2   Pembukaan   2752 non-null   int64  
 3   Tertinggi   2752 non-null   int64  
 4   Terendah    2752 non-null   int64  
 5   Vol          0 non-null    float64
 6   Perubahan%  2752 non-null   float64
dtypes: datetime64[ns](1), float64(2), int64(4)
memory usage: 150.6 KB
None
   Tanggal  Terakhir  Pembukaan  Tertinggi  Terendah  Vol  Perubahan%
0  2018-01-15  203399008  195599008  208000000  193000000  NaN  3.99
1  2018-01-16  146052000  203398000  203399008  134000096  NaN  -28.19
2  2018-01-17  154000000  146371008  158666000  125003000  NaN  5.44
3  2018-01-18  160604992  154000000  178576000  148256992  NaN  4.29
```

Gambar 5. Hasil proses pre-processing

Pembentukan deret waktu dilakukan dengan pendekatan *look-back window* sepanjang 60 hari. Setiap 60 data harga terakhir digunakan sebagai input untuk memprediksi harga pada hari ke-61. Proses ini menghasilkan pasangan data (X, y), di mana X merupakan deret harga historis dan y merupakan harga target. Dataset kemudian dibagi secara kronologis menjadi data latih (80%) dan data uji (20%) tanpa acak, untuk menghindari *data leakage* antarperiode. Setelah pembagian, data di-*reshape* menjadi format tiga dimensi [samples, timesteps, features] agar sesuai dengan arsitektur model *deep learning*. Hasil visualisasi menunjukkan bahwa proses *preprocessing* berhasil mengonversi seluruh variabel numerik ke dalam format yang bersih dan siap digunakan. Selain itu, normalisasi dan penyusunan *time window* membantu model memahami hubungan jangka panjang

antara pergerakan harga historis dan harga masa depan secara efektif.

```
def create_dataset(dataset, look_back=60):
    X, y = [], []
    for i in range(look_back, len(dataset)):
        X.append(dataset[i-look_back:i, 0])
        y.append(dataset[i, 0])
    return np.array(X), np.array(y)

look_back = 60
X_train, y_train = create_dataset(train_data, look_back)
X_test, y_test = create_dataset(test_data, look_back)

# Reshape untuk LSTM [samples, timesteps, features]
X_train = np.reshape(X_train, (X_train.shape[0], X_train.shape[1], 1))
X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 1))
```

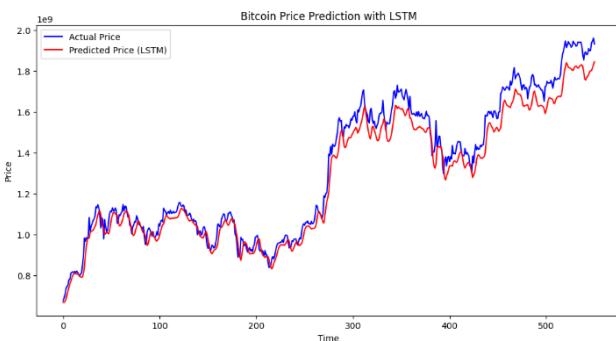
Gambar 6. Pembentukan Data Time Series

B. Hasil Prediksi Model

Hasil eksperimen menampilkan performa tiga model utama, yaitu LSTM, GRU, dan CNN-1D, dalam memprediksi harga Bitcoin terhadap Rupiah (BTC/IDR). Setiap model diuji menggunakan dataset yang sama agar perbandingan hasil bersifat objektif dan adil. Hasil prediksi kemudian dibandingkan dengan nilai aktual untuk menilai sejauh mana akurasi dan kemampuan model dalam mengikuti pola harga.

1) Long Short-Term Memory

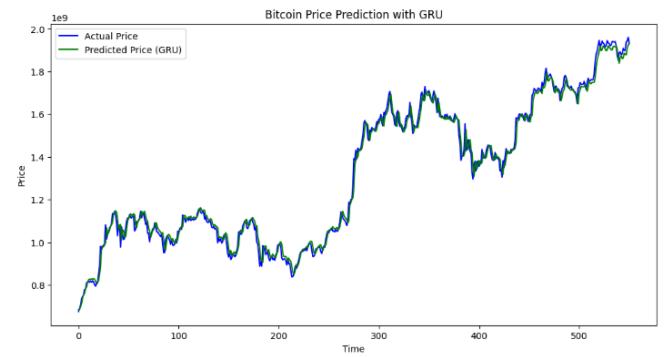
Model LSTM dibangun menggunakan parameter look-back window 60 hari, 50 neuron per layer, batch size 32, dan 50 epochs. Proses pelatihan menggunakan optimizer Adam dengan fungsi kerugian MSE, serta metrik evaluasi MAE, RMSE, MAPE, dan R^2 . Hasilnya menunjukkan bahwa LSTM mampu mengikuti tren harga dengan cukup baik, baik pada periode kenaikan maupun penurunan harga. Nilai evaluasi LSTM adalah MSE sebesar $4,52 \times 10^{15}$, RMSE sebesar $6,72 \times 10^7$, MAE sebesar $5,47 \times 10^7$, MAPE sebesar 3,90%, dan R^2 sebesar 0,959. Meskipun hasilnya cukup baik, LSTM cenderung menghasilkan deviasi yang lebih besar pada fase volatilitas tinggi. Hal ini disebabkan karena kompleksitas arsitektur empat gerbang yang membuatnya memerlukan waktu pelatihan lebih lama untuk mencapai bobot optimal. Hasil visualisasi harga aktual vs prediksi ada pada gambar 7.



Gambar 7. Visualisasi hasil prediksi harga Bitcoin menggunakan LSTM

2) GRU

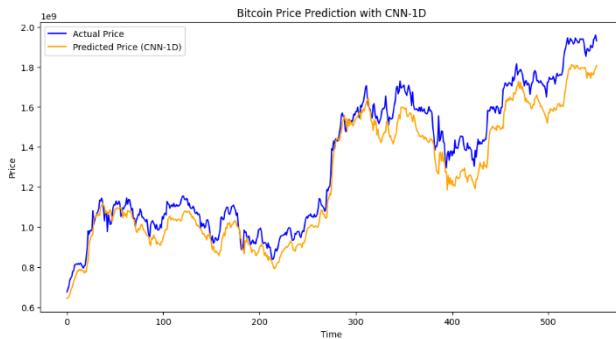
Model GRU menggunakan konfigurasi serupa dengan LSTM, yakni look-back 60, batch size 32, dan epochs 50. Model ini dikompilasi dengan optimizer Adam dan fungsi kerugian mean squared error. Hasil pengujian menunjukkan bahwa GRU memberikan performa terbaik dengan nilai MSE sebesar $9,44 \times 10^{14}$, RMSE sebesar $3,07 \times 10^7$, MAE sebesar $2,25 \times 10^7$, MAPE sebesar 1,77%, dan R^2 sebesar 0,9916. Nilai ini menunjukkan bahwa lebih dari 99% variasi harga aktual dapat dijelaskan oleh model GRU. Secara visual, hasil prediksi GRU hampir menempel pada garis harga aktual sepanjang periode pengujian. Hal ini menunjukkan kemampuan GRU dalam mengenali pola jangka panjang sekaligus menyesuaikan diri terhadap fluktuasi harga yang ekstrem. Selain itu, arsitektur GRU yang hanya memiliki dua gerbang membuat pelatihannya lebih efisien dibandingkan LSTM, tanpa mengorbankan performa akurasi. Hasil visualisasi harga aktual vs prediksi ada pada gambar 8.



Gambar 8. Visualisasi hasil prediksi harga Bitcoin menggunakan GRU

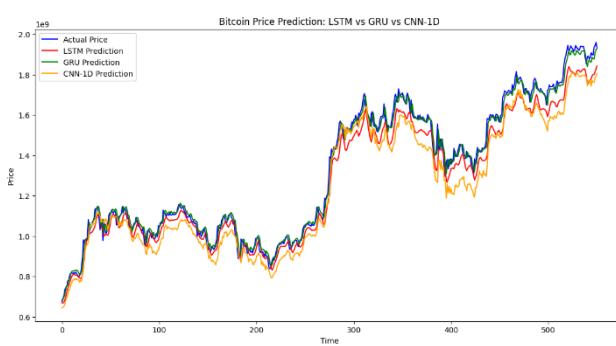
3) CNN-1D

Model CNN-1D diuji dengan parameter look-back window 60, batch size 32, dan epochs 50. Hasil prediksi menunjukkan performa yang relatif lebih rendah dibandingkan LSTM dan GRU. CNN-1D menghasilkan MSE sebesar $9,33 \times 10^{15}$, RMSE sebesar $9,66 \times 10^7$, MAE sebesar $8,29 \times 10^7$, MAPE sebesar 6,17%, dan R^2 sebesar 0,917. Performa yang kurang optimal disebabkan karena CNN-1D hanya mampu mengekstraksi fitur lokal dan tidak memiliki mekanisme memori jangka panjang seperti model recurrent. Meskipun demikian, CNN-1D masih dapat memberikan prediksi yang cukup akurat pada fase pasar yang stabil, serta unggul dalam hal efisiensi komputasi dan kecepatan pelatihan. Hasil visualisasi harga aktual vs prediksi ada pada gambar 9.



Gambar 9. Visualisasi hasil prediksi harga Bitcoin menggunakan CNN-1D

4) Perbandingan Model



Gambar 10. Visualisasi perbandingan hasil prediksi LSTM, GRU, dan CNN-1D terhadap harga aktual

Gambar 10 memperlihatkan perbandingan hasil prediksi harga Bitcoin menggunakan tiga model utama, yaitu *Long Short-Term Memory* (LSTM), *Gated Recurrent Unit* (GRU), dan *Convolutional Neural Network* satu dimensi (CNN-1D). Garis biru menggambarkan harga aktual, sedangkan garis merah, hijau, dan oranye masing-masing merepresentasikan hasil prediksi LSTM, GRU, dan CNN-1D.

Berdasarkan visualisasi tersebut, ketiga model mampu menangkap pola pergerakan harga Bitcoin secara umum, baik pada fase kenaikan maupun penurunan harga. Namun demikian, tingkat akurasi yang dicapai setiap model berbeda. GRU memperlihatkan performa terbaik karena garis prediksi hampir menempel pada garis harga aktual sepanjang periode pengujian, dengan deviasi yang relatif kecil. LSTM menunjukkan hasil prediksi yang cukup konsisten, meskipun sedikit tertinggal dibandingkan GRU pada fase tren yang curam. Sementara itu, CNN-1D menunjukkan deviasi yang lebih besar, khususnya pada periode volatilitas tinggi, sehingga performanya relatif kurang dibandingkan dua model berbasis RNN.

Secara keseluruhan, hasil perbandingan ini menunjukkan bahwa GRU adalah model dengan kinerja terbaik dalam penelitian ini, diikuti oleh LSTM yang masih kompetitif.

CNN-1D, meskipun memiliki akurasi lebih rendah, tetap unggul dari sisi efisiensi komputasi dan kecepatan pelatihan. Dengan demikian, pemilihan model prediksi harga Bitcoin sebaiknya mempertimbangkan *trade-off* antara akurasi dan efisiensi, tergantung kebutuhan implementasi sistem.

C. Evaluasi Model

Tabel I berikut menyajikan hasil evaluasi performa ketiga model (LSTM, GRU, CNN-1D) berdasarkan lima metrik utama, yaitu *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi (R^2).

TABEL I
EVALUASI KETIGA MODEL

Model	MSE	RMSE	MAE	MAPE (%)	R^2
LSTM	4.526	6.727	5.474	3.903	0.959
GRU	9.442	3.072	2.254	1.775	0.991
CNN-1D	9.337	9.663	8.291	6.174	0.916

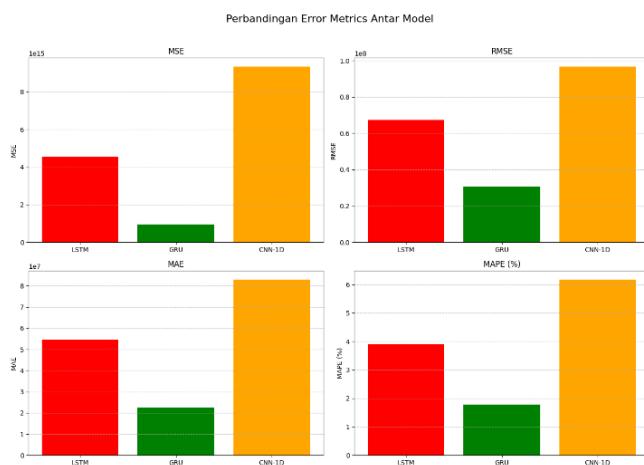
Evaluasi model dilakukan untuk menilai performa prediksi tiga arsitektur deep learning LSTM, GRU, dan CNN-1D terhadap data harga Bitcoin terhadap Rupiah (BTC/IDR). Pengukuran kinerja dilakukan menggunakan lima metrik utama, yaitu *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi (R^2). Berdasarkan hasil evaluasi kuantitatif, model GRU menunjukkan performa terbaik di antara ketiga model. GRU memperoleh nilai MSE sebesar 9.44×10^{14} , RMSE sebesar 3.07×10^7 , MAE sebesar 2.25×10^7 , MAPE sebesar 1.77%, dan R^2 sebesar 0.9916. Nilai R^2 yang tinggi menunjukkan bahwa model ini mampu menjelaskan lebih dari 99% variasi harga aktual Bitcoin terhadap Rupiah.

Untuk menghindari kemungkinan *overfitting*, penelitian ini menggunakan strategi *early stopping* selama pelatihan. Proses pelatihan dihentikan secara otomatis ketika nilai kesalahan validasi tidak lagi menurun selama beberapa *epoch* berturut-turut. Selain itu, pembagian data latih dan data uji dilakukan secara kronologis (80:20) untuk mencegah terjadinya data leakage antarperiode, sehingga hasil pengujian benar-benar mencerminkan kemampuan generalisasi model terhadap data baru. Model LSTM juga menunjukkan performa yang cukup baik dengan nilai MSE sebesar 4.52×10^{15} , RMSE sebesar 6.72×10^7 , MAE sebesar 5.47×10^7 , MAPE sebesar 3.90%, dan R^2 sebesar 0.959. Meskipun akurasi LSTM relatif tinggi, model ini memerlukan waktu pelatihan lebih lama dibandingkan GRU karena struktur arsitektur empat gerbang yang lebih kompleks.

Sementara itu, model CNN-1D menghasilkan performa terendah dengan MSE sebesar 9.33×10^{15} , RMSE sebesar

9.66×10^7 , MAE sebesar 8.29×10^7 , MAPE sebesar 6.17%, dan R^2 sebesar 0.917. Hal ini menunjukkan bahwa CNN-1D kurang efektif dalam menangkap pola jangka panjang yang sangat penting pada data deret waktu seperti harga Bitcoin. Secara keseluruhan, hasil evaluasi kuantitatif memperlihatkan bahwa GRU merupakan model yang paling optimal dalam memprediksi harga Bitcoin terhadap Rupiah. LSTM tetap dapat dijadikan alternatif yang kompetitif, sedangkan CNN-1D lebih unggul dari sisi efisiensi komputasi namun kurang akurat dalam kondisi volatilitas tinggi.

D. Perbandingan Error Metrics



Gambar 11. Perbandingan error metrics

Gambar 11 memperlihatkan perbandingan nilai error metrics dari ketiga model utama, yakni *Long Short-Term Memory* (LSTM), *Gated Recurrent Unit* (GRU), dan *Convolutional Neural Network* satu dimensi (CNN-1D). Perbandingan nilai error metrics dilakukan untuk memperkuat hasil evaluasi yang telah diperoleh. Keempat metrik utama MSE, RMSE, MAE, dan MAPE digunakan untuk melihat konsistensi performa antar model. Hasil perbandingan menunjukkan bahwa model GRU memiliki nilai kesalahan paling kecil pada semua metrik evaluasi, diikuti oleh LSTM, sedangkan CNN-1D menunjukkan error tertinggi. Nilai MAE pada GRU tercatat sebesar 2.25×10^7 dan MAPE sebesar 1.77%, menegaskan bahwa model ini mampu meminimalkan deviasi prediksi terhadap harga aktual.

LSTM berada pada posisi menengah dengan MAPE sebesar 3.90%, yang menunjukkan bahwa meskipun kurang akurat dibandingkan GRU, model ini masih mampu memberikan prediksi yang stabil. Sebaliknya, CNN-1D memiliki nilai error terbesar dengan MAPE sebesar 6.17%, menunjukkan ketidaktepatan model ini dalam menghadapi fluktuasi ekstrem. Visualisasi hasil perbandingan memperlihatkan bahwa kurva error GRU lebih landai dan konsisten dibandingkan dua model lainnya. Hal ini menunjukkan stabilitas dan kemampuan model dalam

beradaptasi terhadap dinamika harga pasar yang cepat berubah.

E. Analisis

Analisis hasil penelitian memperlihatkan bahwa perbedaan kinerja antar model dipengaruhi oleh struktur internal masing-masing arsitektur. GRU menunjukkan performa terbaik karena memiliki dua gerbang utama, *update gate* dan *reset gate*, yang memungkinkan model mempertahankan informasi penting sekaligus mempercepat proses pelatihan tanpa mengalami gradient vanishing. LSTM juga memiliki kemampuan menangkap ketergantungan jangka panjang, tetapi kompleksitas empat gerbang membuat waktu komputasi menjadi lebih tinggi dan berpotensi menghambat efisiensi pelatihan. CNN-1D di sisi lain hanya mengekstraksi fitur lokal melalui operasi konvolusi, sehingga kurang optimal dalam mempelajari konteks jangka panjang pada data harga Bitcoin yang bersifat sangat dinamis.

Evaluasi kuantitatif melalui metrik MSE, RMSE, MAE, dan R^2 semakin memperkuat temuan tersebut. Model GRU menunjukkan performa paling unggul dengan nilai error terendah ($MSE = 9.44 \times 10^{14}$, $RMSE = 3.07 \times 10^7$, $MAE = 2.25 \times 10^7$, $MAPE = 1.77\%$, dan $R^2 = 0.9916$). Capaian ini mengindikasikan bahwa GRU mampu memprediksi harga Bitcoin dengan tingkat ketepatan yang tinggi sekaligus menjaga konsistensi hasil. LSTM berada pada posisi menengah dengan error yang relatif lebih tinggi ($MAPE = 3.90\%$), tetapi masih menunjukkan kemampuan prediksi yang cukup baik. Sebaliknya, CNN-1D mencatat error terbesar ($MAPE = 6.17\%$) dengan nilai R^2 yang relatif rendah (0.9165), yang menandakan keterbatasannya dalam mengatasi volatilitas tinggi pada data kripto.

Dari hasil perbandingan, dapat disimpulkan bahwa GRU adalah model yang paling sesuai untuk kasus prediksi harga Bitcoin terhadap Rupiah. Selain karena efisiensinya, struktur GRU juga mampu menyeimbangkan antara kompleksitas dan akurasi. LSTM tetap relevan sebagai model alternatif dengan performa yang mendekati GRU, sedangkan CNN-1D lebih cocok diterapkan pada sistem prediksi cepat dengan keterbatasan sumber daya komputasi. Temuan ini memiliki implikasi praktis yang signifikan. Model GRU dapat diimplementasikan dalam bentuk *forecasting dashboard* atau *AI-based decision support system* yang membantu investor dan platform perdagangan kripto dalam mengambil keputusan berbasis data. Dengan akurasi tinggi dan stabilitas prediksi yang konsisten, model ini berpotensi menjadi bagian dari sistem peringatan dini terhadap volatilitas pasar.

Namun demikian, penelitian ini masih memiliki keterbatasan. Model yang digunakan hanya memanfaatkan data harga historis tanpa mempertimbangkan faktor eksternal seperti berita, sentimen pasar, maupun indikator makroekonomi. Oleh karena itu, penelitian lanjutan disarankan untuk menerapkan pendekatan hybrid dengan memasukkan fitur tambahan seperti indeks volatilitas, trading volume anomaly, atau social media *sentiment analysis* untuk

meningkatkan kemampuan prediksi jangka panjang dan real-time forecasting. LSTM.

IV. KESIMPULAN

Penelitian ini bertujuan untuk membandingkan performa tiga model deep learning Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), dan Convolutional Neural Network satu dimensi (CNN-1D) dalam memprediksi harga Bitcoin terhadap Rupiah (BTC/IDR). Hasil menunjukkan bahwa setiap model memiliki karakteristik dan tingkat akurasi berbeda sesuai kompleksitas arsitektur serta kemampuannya dalam mengenali pola deret waktu. Model GRU memberikan performa terbaik dengan nilai MAPE 1,77% dan R^2 sebesar 0,9916, menandakan kemampuannya menjelaskan lebih dari 99% variasi harga aktual Bitcoin. Keunggulan ini berasal dari efisiensi arsitektur GRU yang mampu mempertahankan informasi jangka panjang secara stabil. LSTM tetap menunjukkan performa kompetitif, sedangkan CNN-1D memiliki akurasi lebih rendah karena hanya mengekstraksi pola lokal tanpa memperhatikan konteks temporal yang lebih luas.

Secara keseluruhan, model berbasis recurrent neural network, khususnya GRU, terbukti lebih efektif untuk prediksi harga aset kripto dibandingkan pendekatan konvolisional. Proses preprocessing yang tepat seperti normalisasi dan pembagian data yang sistematis juga terbukti penting dalam menjaga stabilitas pelatihan serta mencegah data leakage. Penelitian ini berpotensi menjadi dasar pengembangan sistem prediksi harga berbasis kecerdasan buatan yang dapat membantu investor dan analis pasar dalam pengambilan keputusan. Ke depan, penelitian dapat dikembangkan dengan menambahkan variabel eksternal seperti volume perdagangan, sentimen pasar, dan indikator makroekonomi untuk menghasilkan prediksi yang lebih komprehensif dan realistik.

DAFTAR PUSTAKA

- [1] Budi Dharma, Putri Gusniati, and Tria Wardani, “Analisis Pemanfaatan Cryptocurrency Bitcoin Sebagai Alat Alternatif Investasi,” *J. Publ. Sist. Inf. dan Manaj. Bisnis*, vol. 2, no. 1, pp. 175–182, 2023, doi: 10.55606/jupsim.v2i1.858.
- [2] D. Molitor, W. Raghupathi, V. Raghupathi, and A. Saharia, “Understanding Cryptocurrency,” *Int. J. Blockchain Appl. Secur. Comput.*, vol. 1, no. 1, pp. 1–25, 2023, doi: 10.4018/ijbasc.331079.
- [3] C. A. Apriliani, A. I. Hamzani, and M. Wildan, “Legalitas Transaksi Aset Kripto Menurut Perspektif Hukum Islam,” *J. Ilm. Mhs. Perbank. Syariah*, vol. 3, no. 1, pp. 113–124, 2023, doi: 10.36908/jimpa.v3i1.161.
- [4] S. Hartono and R. Budiarrah, “Potensi Keseksian Penerapan Pajak Penghasilan Terhadap Transaksi Aset Kripto Di Indonesia,” *J. Pajak dan Keuang. Negara*, vol. 4, no. 1, pp. 132–146, 2022, doi: 10.31092/jpkn.v4i1.1740.
- [5] C. Herdian, “Prediksi Harian Harga Penutupan Dogecoin: Analisis Faktor Pengaruh dan Algoritmanya,” *Techno Xplore J. Ilmu Komput. dan Teknol. Inf.*, vol. 8, no. 1, pp. 17–27, 2023, doi: 10.36805/technoxplore.v8i1.4423.
- [6] J. Chen, “Analysis of Bitcoin Price Prediction Using Machine Learning,” 2023.
- [7] & J. Urooj, Asif, “Bitcoin Price Forecasting : A Comparative Study of Machine Learning , Statistical and Deep Learning Models,” vol. 6, no. 2, pp. 396–412, 2024.
- [8] E. Liunokas, K. I. Kobesi, and C. N. Salsinha, “Prediksi Harga Bitcoin Menggunakan Metode LINEAR REGRESION,” *J. Math. Theory Appl.*, vol. 2, no. 2, pp. 43–52, 2024, doi: 10.32938/jmath.v2i2.7699.
- [9] A. Mahmoud and A. Mohammed, “Multivariate Time Series Forecasting,” *Neural Process. Lett.*, vol. 56, no. 5, pp. 1–25, 2024, doi: 10.1007/s11063-024-11656-3.
- [10] R. S. Dwi Harjo, R. Anugrah, and J. Dharmawan, “Prediksi Coin Kripto Dengan Menggunakan Metode LSTM (Long Short-Term Memory),” *J. Adv. Res. Informatics*, vol. 3, no. 2, pp. 112–119, 2025, doi: 10.24929/jars.v3i2.4240.
- [11] J. Alvi, K. Nizam, S. M. Jafri, M. Rehan, and M. M. Ali, “Cryptocurrency Predictive Analytics: A Comparative Study of LSTM, CNN, and GRU Models,” *Pakistan Bus. Rev.*, vol. 26, no. 3, pp. 255–287, 2025, doi: 10.22555/pbr.v26i3.1236.
- [12] S. Hassan, M. Khan, F. Lee, “Cryptocurrency Price Prediction with Convolutional Neural Network and Stacked Gated Recurrent Unit,” 2022.
- [13] S. Nur Fadila and S. U. Zuliana, “Optimasi Portofolio Saham Menggunakan Model Markowitz Berdasarkan Prediksi Harga Saham,” *Kaunia Integr. Interconnect. Islam Sci. J.*, vol. 18, no. 1, pp. 35–40, 2023, doi: 10.14421/kaunia.3948.
- [14] R. Parlika, R. R. Isnanto, and B. Rahmat, “Prediction of ROI Achievements and Potential Maximum Profit on Spot Bitcoin Rupiah Trading Using K-means Clustering and Patterned Dataset Model,” *Int. J. Informatics Vis.*, vol. 8, no. 3–2, pp. 1987–2001, 2024, doi: 10.62527/ijov.8.3-2.3120.
- [15] S. Rani, R. Kaur, and C. Desai, “Enhancing Time Series Forecasting Accuracy With Deep Learning Models: a Comparative Study,” *Int. J. Adv. Res.*, vol. 12, no. 08, pp. 315–324, 2024, doi: 10.21474/ijar01/19257.
- [16] H. Utama, “Pendekatan Deep Learning Menggunakan Metode Lstm Untuk Prediksi Harga Bitcoin,” *Indones. J. Comput. Sci. Res.*, vol. 2, no. 2, pp. 43–50, 2023, doi: 10.59095/ijcsr.v2i2.77.
- [17] W. Jeanne Clarisa Wetik, “Penerapan Metode Recurrent Neural Network (RNN) Model Gated Recurrent Unit (GRU) untuk Prediksi Harga Cryptocurrency,” *Kinabalu*, vol. 11, no. 2, pp. 50–57, 2023.
- [18] M. A. Pramudito, Y. N. Fu’adah, R. Magdalena, A. Rizal, And F. F. Taliningsih, “Identifikasi Sinyal Congestive Heart Failure dengan Metode Convolutional Neural Network 1D,” *MIND.J.*, vol. 7, no. 1, pp. 11–20, 2022, doi: 10.26760/mindjournal.v7i1.11-20.
- [19] N. O. Idris and F. Pontoioyo, “Evaluasi Model Machine Learning untuk Prediksi Harga Mobil dengan Perbandingan Ensemble dan Regresi Linear,” *J. Ilmu Komput. dan Sist. Inf.*, vol. 4, no. 1, pp. 129–143, 2025, doi: 10.70340/jirs.v4i1.181.