

# Perbandingan Kinerja Model Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) Untuk Prediksi Harga Cryptocurrency

Hanif Alhakim<sup>1,\*</sup>, Aditia Yudhistira<sup>2</sup>

<sup>1</sup> Fakultas Teknik dan Ilmu Komputer, Program Studi Informatika, Universitas Teknokrat Indonesia, Bandar Lampung, Indonesia

<sup>2</sup> Fakultas Teknik dan Ilmu Komputer, Magister Ilmu Komputer, Universitas Teknokrat Indonesia, Bandar Lampung, Indonesia

Email: <sup>1,\*</sup>hanif\_alhakim@teknokrat.ac.id, <sup>2</sup>aditiayudhistira@teknokrat.ac.id

Email Penulis Korespondensi: hanif\_alhakim@teknokrat.ac.id

Submitted: 25/05/2026; Accepted: 22/06/2026; Published: 23/06/2026

**Abstrak**—Volatilitas ekstrem di pasar aset kripto menimbulkan risiko finansial substansial yang menuntut sistem peramalan presisi. Keterbatasan model statistik konvensional dalam memodelkan dinamika *non-linear* memicu adopsi pendekatan *deep learning*. Studi ini mengevaluasi komparasi kinerja arsitektur *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dalam memprediksi harga penutupan Bitcoin (BTC), Ethereum (ETH), dan Solana (SOL). Eksperimen menggunakan data historis dari Januari 2023 hingga April 2026, yang didistribusikan dengan rasio latih-uji 80:20 melalui sekuens *sliding window* 60 hari. Regularisasi berbasis *Dropout* dan *Early Stopping* diterapkan guna mencegah *overfitting*. Sebagai kontribusi empiris, penelitian ini menguji secara univariat *trade-off* antara kompleksitas sel memori (LSTM) dan efisiensi arsitektural (GRU) pada data bervolatilitas tinggi. Hasil pengujian menunjukkan bahwa GRU secara konsisten mengungguli LSTM di seluruh instrumen dengan menekan tingkat kesalahan *Mean Absolute Percentage Error* (MAPE) hingga rentang 2,93%–4,89%. Dari aspek efisiensi komputasi, arsitektur GRU mampu memangkas durasi pelatihan sebesar 13,33% hingga 36,92% dibandingkan LSTM. Secara praktis, temuan ini merekomendasikan GRU sebagai fondasi algoritma yang Efektif dan efisien untuk sistem *algorithmic trading* serta pengelolaan risiko portofolio digital.

**Kata Kunci:** Aset Kripto; LSTM; GRU; Deep Learning; Peramalan Rekursif

**Abstract**—Extreme volatility in the cryptocurrency market poses substantial financial risks, necessitating precision forecasting systems. The limitations of conventional statistical models in capturing non-linear dynamics have prompted the adoption of deep learning approaches. This study evaluates the comparative performance of Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) architectures in predicting the closing prices of Bitcoin (BTC), Ethereum (ETH), and Solana (SOL). Experiments utilized historical data from January 2023 to April 2026, partitioned with an 80:20 train-test ratio using a 60-day sliding window sequence. Dropout-based regularization and Early Stopping were implemented to prevent overfitting. As an empirical contribution, this research univariately examines the trade-off between memory cell complexity (LSTM) and architectural efficiency (GRU) on high-volatility data. The results demonstrate that GRU consistently outperforms LSTM across all instruments, reducing the Mean Absolute Percentage Error (MAPE) to a range of 2.93%–4.89%. Regarding computational efficiency, the GRU architecture reduced training duration by 13.33% to 36.92% compared to LSTM. Practically, these findings recommend GRU as an effective and efficient algorithmic foundation for algorithmic trading systems and digital portfolio risk management.

**Keywords:** Crypto Asset; LSTM; GRU; Deep Learning; Recursive Forecasting

## 1. PENDAHULUAN

Dalam beberapa tahun terakhir, pasar mata uang kripto telah mengalami pertumbuhan eksponensial baik dari sisi kapitalisasi pasar maupun adopsi global. Bitcoin (BTC), Ethereum (ETH), dan Solana (SOL) menduduki posisi sentral sebagai aset digital utama yang tidak hanya mendominasi volume perdagangan, tetapi juga menjadi barometer volatilitas dan inovasi teknologi di sektor keuangan digital [1]. Karakteristik utama dari pasar kripto adalah volatilitas harga yang sangat tinggi, sifat non-stasioner, serta dinamika *non-linear* yang kompleks. Fenomena ini dipengaruhi oleh berbagai faktor seperti sentimen pasar, regulasi, perkembangan teknologi *blockchain*, serta interaksi antar aset digital [2]. Bitcoin sebagai pionir kripto menunjukkan dominasi pasar yang kuat dengan likuiditas tinggi dan pengaruh sistemik terhadap *altcoin* lainnya [3]. Sementara itu, Ethereum menawarkan ekosistem kontrak pintar yang memperluas utilitas *blockchain* di luar sekadar alat tukar, sedangkan Solana dikenal dengan *throughput* transaksi tinggi dan biaya rendah sehingga menarik minat pengembang aplikasi terdesentralisasi [2]. Namun demikian, aset ketiga ini sama-sama menahan tantangan prediksi harga akibat fluktuasi ekstrem dan pola pergerakan harga yang sulit dipetakan secara deterministik [4].

Keterbatasan model statistik tradisional seperti ARIMA dalam menangani data kripto telah banyak disediakan dalam literatur terdahulu. Model-model tersebut umumnya mengasumsikan stasioneritas dan linearitas data dua asumsi yang jarang terpenuhi pada deret waktu deretharga kripto [5],[6]. Studi empiris menunjukkan bahwa ARIMA dan turunannya cenderung gagal menangkap pola jangka panjang serta dinamika *non-linear* yang melekat pada pasar kripto [7]. Sebagai respons atas keterbatasan ini, terjadi perubahan paradigma menuju pemanfaatan *machine learning* dan *deep learning* untuk meramalkan waktu finansial [8]. Di antara berbagai pendekatan *deep learning*, *Recurrent Neural Networks* (RNN) dan variannya khususnya *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) menjadi pilihan utama karena kemampuannya dalam memodelkan dependensi temporal jangka panjang serta mengatasi masalah *vanishing gradient* yang sering muncul pada RNN konvensional [9]. LSTM dirancang dengan mekanisme sel memori kompleks untuk mempertahankan informasi historis penting dalam urutan data Panjang [9],

sementara GRU menawarkan arsitektur lebih sederhana dengan efisiensi komputasi lebih baik tanpa mengorbankan kinerja prediksi secara signifikan [10].

Perbandingan teoritis antara LSTM dan GRU telah menjadi fokus kajian akademik dalam beberapa tahun terakhir. LSTM memiliki tiga gerbang utama *input*, *forget*, dan *output gate* yang memungkinkan kontrol granular terhadap aliran dalam informasi jaringan. Kompleksitas ini memberikan keunggulan dalam menangkap pola jangka panjang namun berdampak pada kebutuhan komputasi yang lebih besar [9]. Sebaliknya, GRU membuat arsitektur hanya dengan memakai dua gerbang yaitu *update* dan *reset gate* sehingga mempercepat proses pelatihan serta mengurangi risiko *overfitting* pada *dataset* terbatas atau berisik [10]. Beberapa penelitian yang dilakukan oleh Aljadani [4], Kaur et al. [1], Rodrigues et al. [6] menilai GRU lebih unggul karena strukturnya yang lebih sederhana mampu memangkas waktu pelatihan dan memperkecil nilai galat (MAPE dan RMSE) pada data berfrekuensi tinggi. Berbanding terbalik dengan studi lain yang dilakukan Syed et al. [5], Koszewski et al. [7], Lloyd Seabe [9] menemukan bahwa LSTM dan *Bidirectional LSTM* (Bi-LSTM) justru lebih kuat dalam menangkap pola data yang rumit, terutama pada fluktuasi jangka sangat pendek dan model yang digabungkan dengan analisis sentimen berbasis RoBERTa. Perbedaan hasil ini memperlihatkan bahwa akurasi kedua arsitektur sangat bergantung pada jenis data, frekuensi, dan fitur yang digunakan, sehingga penelitian lebih lanjut pada skenario univariat menjadi penting untuk dilakukan.


Meskipun literatur tentang penerapan LSTM dan GRU untuk prediksi harga cryptocurrency semakin berkembang pesat, terdapat sejumlah ruang penelitian yang masih terbuka luas. Pertama, mayoritas studi terdahulu cenderung bias pada pernyataan variabel multivariat [3], seperti analisis sentimen dan indikator eksternal [7],[9], sehingga evaluasi berbasis data tunggal (univariat) untuk menguji keandalan asli model tanpa gangguan data eksternal masih sangat terbatas. Kedua, meskipun beberapa eksplorasi terkini mulai melibatkan *altcoin* dalam instrumen pengujiannya [4],[1], komparasi kinerja tersebut mayoritas dieksekusi pada horizon waktu yang terlampau sempit, seperti skenario peramalan berfrekuensi tinggi atau sepersekian detik (*split second*) [6],[5]. Konfigurasi jangka pendek tersebut berisiko gagal merekam dinamika tren pasar kripto jangka panjang. Keterbatasan inilah yang menjadi landasan urgensi penelitian ini untuk menguji dan membandingkan batas kemampuan empiris antara model LSTM dan GRU melalui pendekatan univariat.

Penelitian ini bertujuan untuk mengisi kesenjangan literatur melalui evaluasi komprehensif terhadap kinerja arsitektur Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) dengan mengisolasi pendekatan pemodelan univariat [1]. Menggunakan data deret waktu historis harian dari tiga aset kripto berkapitalisasi besar (Bitcoin, Ethereum, dan Solana) pada periode Januari 2023 hingga April 2026, studi ini menyajikan tiga kontribusi utama [5]. Kontribusi diawali dengan menguji batas kemampuan arsitektural murni dari kedua model dalam mempelajari dependensi temporal *non-linear* tanpa pengaruh variabel perancu (*confounding effects*) dari faktor multivariat eksternal [3],[10]. Selanjutnya, studi ini menginvestigasi kompromi (*trade-off*) empiris antara kompleksitas sel memori pada LSTM dan keringkasannya arsitektur pada GRU terhadap profil volatilitas yang berbeda dari ketiga aset tersebut [2]. Investigasi tersebut kemudian diakumulasikan untuk menetapkan tolok ukur (*baseline*) kelayakan implementasi praktis dengan mengevaluasi metrik akurasi (RMSE, MAE, MAPE) yang dikomparasikan langsung dengan efisiensi waktu pelatihan (*training time*) [3]. Hasil evaluasi ini diharapkan dapat menjadi fondasi empiris dalam pengembangan sistem peramalan harga kripto yang menyeimbangkan tingkat presisi tinggi dengan efisiensi sumber daya komputasi [7].

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Tahapan penelitian ini disusun secara sistematis untuk menggambarkan proses prediksi harga aset kripto (Bitcoin, Ethereum, dan Solana) menggunakan algoritma LSTM dan GRU. Alur kerja tersebut diilustrasikan pada Gambar 1:



Gambar 1. Tahapan Penelitian

Gambar 1 menyajikan diagram alur penelitian yang menguraikan tahapan pemodelan harga aset kripto menggunakan arsitektur LSTM dan GRU. Proses penelitian diawali dengan pengumpulan data historis harga penutupan (*close price*) harian dari BTC, ETH, SOL yang bersumber dari Investing.com. Selanjutnya, dilakukan rekayasa data melalui tahap pra-pemrosesan yang meliputi pembersihan data (*data cleaning*), normalisasi skala menggunakan *Min-Max Scaler*, serta pembentukan struktur sliding window dengan *time steps* 60 hari.

*Dataset* yang telah diproses kemudian dibagi secara sekuensial menjadi data latih (*training data*) sebesar 80% dan data uji (*testing data*) sebesar 20%. Pada tahap pemodelan, arsitektur LSTM dan GRU dikonfigurasi secara setara

untuk memastikan perbandingan yang objektif. Kedua model mengimplementasikan lapisan *Bidirectional*, pengoptimasi (*optimizer*) Adam, serta dibatasi hingga maksimal 100 *epoch*.

Setelah proses pelatihan selesai, kinerja dari masing-masing model dievaluasi berdasarkan metrik *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Hasil evaluasi tersebut kemudian dikomparasikan untuk menentukan arsitektur model dengan tingkat akurasi tertinggi. Pada tahap akhir, model terbaik digunakan untuk melakukan peramalan bergerak (*recursive forecasting*) untuk 90 hari ke depan. Seluruh output prediksi beserta zona probabilitas volatilitasnya divisualisasikan dalam bentuk grafik untuk analisis lebih mendalam.

## 2.2 Pengumpulan Data

Penelitian ini menggunakan data sekunder berupa pergerakan harga harian dari tiga cryptocurrency dengan kapitalisasi pasar terbesar dan volatilitas tinggi, yaitu Bitcoin (BTC), Ethereum (ETH), dan Solana (SOL). Ketiga aset ini dipilih karena dinilai representatif untuk menguji ketahanan dan akurasi model *deep learning* dalam menangani data deret waktu (*time-series*) finansial yang bersifat *non-linear* serta fluktuatif. *Dataset* diperoleh secara publik melalui platform Investing.com. Untuk menjaga konsistensi perbandingan antar model, rentang waktu pengambilan data disamakan untuk seluruh aset, yaitu dari 01 Januari 2023 hingga 04 April 2026. Periode waktu ini dipilih karena mampu merekam dinamika pasar kripto secara komprehensif, termasuk fase kenaikan (*bullish*) dan penurunan (*bearish*).

## 2.3 Pra-pemrosesan Data

Pada penelitian ini, tahapan pra-pemrosesan data dibagi menjadi beberapa fase logis yang meliputi pembersihan data, normalisasi nilai fitur, pembagian himpunan data secara kronologis, hingga restrukturisasi dimensi data menggunakan metode jendela bergeser (*sliding window*).

### a. Pembersihan Data dan Seleksi Fitur

Data mentah yang diperoleh dari platform Investing.com dievaluasi terlebih dahulu untuk mendeteksi keberadaan data yang hilang (*missing values*) maupun pencatatan ganda (*duplicate data*). Penelitian hanya mempertahankan harga penutupan (*Close price*) sebagai variabel tunggal yang akan dipelajari polanya oleh model.

### b. Normalisasi Min-Max Scaling

Aset kripto yang diuji memiliki rentang nilai nominal yang sangat timpang dan berbeda secara signifikan. Berdasarkan data historis yang digunakan, Bitcoin berada pada level puluhan ribu USD, Ethereum pada level ribuan USD, sedangkan Solana berada pada tingkat puluhan hingga ratusan USD. Jika data ini diproses dalam skala aslinya, pembaharuan bobot (*weight updates*) selama proses *backpropagation* akan menjadi tidak stabil dan rentan mengalami *gradient exploding*. Oleh karena itu, harga penutupan ditransformasikan ke dalam skala seragam (0, 1) menggunakan metode *Min-Max Scaler* melalui Persamaan:

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

Dalam rumus ini,  $X_{norm}$  merupakan nilai data setelah dinormalisasikan, sedangkan  $X$  merepresentasikan nilai data asli. Batas bawah dan batas atas dari keseluruhan *dataset* masing-masing ditentukan oleh  $X_{min}$  sebagai nilai minimum dan  $X_{max}$  sebagai nilai maksimum.

### c. Pembagian Data Latih dan Data Uji

Kumpulan data yang telah dinormalisasi kemudian dipisahkan menjadi data latih (*training set*) dan data uji (*testing set*) dengan proporsi 80% berbanding 20%. Mengingat sifat data yang bersifat deret waktu, pemisahan dilakukan secara sekuensial berdasarkan urutan kronologis tanggal. Prosedur pengacakan (*random shuffle*) dihindari untuk mencegah terjadinya kebocoran data (*data leakage*), di mana model tidak boleh mempelajari informasi masa depan untuk memprediksi masa lalu. Data latih (80% awal) digunakan untuk mengoptimalkan parameter internal model, sementara data uji (20% akhir) dialokasikan murni untuk mengukur kemampuan model terhadap data baru.

### d. Pembentukan Sekuens Temporal (*Sliding Window*)

Model berbasis *recurrent neural network* seperti LSTM dan GRU memerlukan format masukan data tiga dimensi, yaitu:

$$Input\ Shape = (Samples, Time\ Steps, Features) \quad (2)$$

Untuk memenuhi kebutuhan struktur tersebut, data satu dimensi dikonversi menggunakan teknik *sliding window* dengan menetapkan nilai *time steps* sebesar 60 hari. Melalui skema ini, model akan menganalisis secara runtunan harga dari hari ke- $t$  ( $y_t$ ), model akan dipasok dengan skuens pergerakan harga dari 60 hari sebelumnya ( $X = \{x_{t-60}, x_{t-59}, \dots, x_{t-1}\}$ ) Setelah pasangan input-output terbentuk, jendela bergeser maju sebanyak satu langkah ( $t + 1$ ) untuk membentuk pasangan data berikutnya.

## 2.4 Pembangunan Arsitektur Model

Eksperimen komparatif ini berfokus pada pengujian performa dua arsitektur *recurrent neural network* tingkat lanjut, yaitu *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Untuk menjamin perbandingan yang

objektif (*apple to apple comparison*), kedua model dirancang secara simetris dengan spesifikasi kedalaman, jumlah neuron, dan hiperparameter yang identik dalam memproses sekuens data historis pada Bitcoin, Ethereum, dan Solana. Pendekatan *bidirectional* dipilih karena kemampuannya mengekstrak informasi temporal dari dua arah sekaligus (*forward dan backward*), sehingga lebih unggul dalam merangkum konteks tren pergerakan harga kripto yang volatil.

Secara struktural, LSTM maupun GRU dibangun dalam konfigurasi tumpukan dalam (*deep architecture*) yang terdiri dari tiga lapisan *recurrent* utama. Lapisan pertama dan kedua masing-masing memiliki 50 *hidden units* dengan pengaturan (*return\_sequences=True*) untuk mempertahankan dimensi sekuens temporal. Pada lapisan ketiga, kapasitas unit disusutkan menjadi 25 unit dengan kondisi (*return\_sequences=False*) mengompresi fitur menjadi vektor konteks tunggal. Supaya mengantisipasi *overfitting*, lapisan *Dropout* dengan rasio 10% (0.1) disisipkan setelah setiap lapisan *bidirectional*. Fitur yang terekstrak kemudian disalurkan ke *hidden dense layer* berisi 25 neuron dengan aktivasi *Rectified Linear Unit (ReLU)*, sebelum bergerak pada satu neuron *output linear* untuk memproduksi prediksi harga penutupan. Konfigurasi *baseline* model menggunakan 50 *hidden units* dan dropout 0.1 ditentukan berdasarkan heuristik empiris untuk menjamin stabilitas awal.

Proses optimasi bobot jaringan dikendalikan oleh algoritma *Adaptive Moment Estimation* (Adam) dengan *learning rate* awal sebesar 0.0003. Untuk menjaga stabilitas pelatihan dari fluktuasi harga yang ekstrem, mekanisme *Gradient Clipping* diterapkan dengan ambang batas (*clipnorm=1.0*) guna mencegah fenomena *gradient exploding*. Sepanjang fase pelatihan, model dituntut untuk meminimalkan fungsi kerugian *Mean Squared Error* (MSE) sebagai acuan pembaruan parameter internalnya[11].

Efisiensi komputasi dan pencegahan pemborosan waktu pelatihan dikendalikan secara otomatis melalui integrasi dua fungsi *callbacks*:

- Early Stopping: Diatur dengan *patience* sebesar 30 *epoch* untuk memantau *validation loss*. Fungsi ini diprogram agar baru aktif setelah *epoch* ke-15 (*start\_from\_epoch=15*) untuk memberi ruang adaptasi pada model di awal pelatihan, serta mengembalikan bobot terbaik (*restore best weights*) saat dipicu[12].
- ReduceLRonPlateau*: Jika *validation loss* stagnan selama 10 *epoch* berturut-turut, *learning rate* akan dipangkas otomatis sebesar 50% (faktor 0.5) untuk membantu model menemukan kombinasi bobot yang paling optimal dengan tingkat error terkecil, dengan batas minimum absolut ditentukan sebesar  $1 \times 10^{-7}$ [12].

## 2.5 Evaluasi Kinerja model

Mengukur efektivitas dan efisiensi model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU)[13]. Membandingkan kinerja model pada tiga aset kripto dengan skala nominal harga yang berbeda signifikan (Bitcoin, Ethereum, dan Solana), evaluasi dilakukan secara menyeluruh yang mencakup akurasi prediksi serta efisiensi waktu komputasi. Akurasi model diuji secara terukur menggunakan tiga metrik statistik standar:

- Root Mean Squared Error* (RMSE): Menghitung akar kuadrat dari rata-rata selisih kuadrat antara nilai prediksi dan nilai actual [11]. Karena memberikan dampak lebih besar pada kesalahan ekstrem akibat proses pengkuadratan, RMSE digunakan untuk mendeteksi sensitivitas model terhadap volatilitas dan lonjakan harga yang tajam.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

- Mean Absolute Error* (MAE): *Mean Absolute Error* (MAE): Mengukur rata-rata nilai absolut selisih prediksi secara linier tanpa pembobotan tambahan pada penyimpangan yang besar. Metrik ini menyajikan representasi yang lebih stabil mengenai rata-rata penyimpangan absolut prediksi dari nilai aslinya[14].

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

- Mean Absolute Percentage Error* (MAPE): *Mean Absolute Percentage Error* (MAPE): Menyajikan rata-rata penyimpangan dalam bentuk persentase. Metrik ini krusial untuk menormalisasi perbedaan skala harga antar aset, sehingga akurasi prediksi pada Bitcoin puluhan ribu dolar, Ethereum ribuan dolar, dan Solana puluhan dolar dapat diperbandingkan secara setara [15].

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4)$$

Keterangan matematis dari ketiga persamaan di atas menetapkan bahwa  $n$  merupakan total jumlah observasi pada himpunan data uji,  $y_i$  merepresentasikan nilai harga penutupan aktual pada observasi ke- $i$ , dan  $\hat{y}_i$  adalah nilai prediksi harga yang dihasilkan oleh jaringan saraf pada observasi ke- $i$ .

Efisiensi model diukur berdasarkan Waktu Pelatihan (*Training Time*), yaitu total durasi pemrosesan (dalam detik) yang diperlukan oleh masing-masing arsitektur dari awal proses pelatihan (*epoch*) hingga model mencapai pembelajaran selesai. Pengujian ini bertujuan untuk menganalisis (*trade-off*) desain arsitektur sekaligus menguji dugaan awal terkait efisiensi model, guna melihat apakah kompleksitas struktural LSTM yang memiliki tiga gerbang memori mampu memberikan akurasi yang lebih tinggi, atau model GRU yang lebih ringkas dapat menghasilkan akurasi setara dengan efisiensi waktu yang lebih optimal[16].

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Karakteristik Data Uji

Penelitian ini menggunakan data historis harga penutupan (*close price*) dari tiga aset *cryptocurrency* utama, yaitu Bitcoin (BTC), Ethereum (ETH), dan Solana (SOL). Data yang dikumpulkan memiliki rentang waktu mulai dari 1 Januari 2023 hingga 16 April 2026. Masing-masing aset memiliki total 1.202 baris data harian yang telah dipastikan bersih dari data yang hilang (*missing values*). Untuk kebutuhan pelatihan dan evaluasi model *machine learning*, data tersebut dibagi menggunakan rasio 80:20, yang menghasilkan 961 data latih (*training data*) dan 241 data uji (*testing data*). Karakteristik pergerakan harga dari ketiga aset kripto ini menunjukkan tingkat volatilitas yang sangat bervariasi. Berikut adalah rincian karakteristik masing-masing koin berdasarkan data yang digunakan:

##### 3.1.1 Karakteristik Bitcoin (BTC)

Bitcoin, sebagai aset kripto dengan kapitalisasi pasar terbesar, menunjukkan rentang pergerakan harga yang sangat masif selama periode penelitian. Berdasarkan pengolahan data, nilai minimum harga penutupan BTC berada di angka \$16.618,40, sedangkan titik tertingginya melonjak tajam hingga mencapai \$124.725,10. Rata-rata (mean) harga penutupan selama rentang waktu tersebut adalah \$66.387,10. Tingginya ketidakpastian dan fluktuasi harga pada BTC tergambar jelas dari nilai standar deviasi yang sangat besar, yakni 30.663,75. Lonjakan dan penurunan harga yang ekstrem ini divisualisasikan pada grafik pergerakan historis BTC, yang menunjukkan pola tren *non-linear* yang sangat dinamis, hal ini ditunjukkan pada Gambar 2.



Gambar 2. Harga Penutupan Bitcoin

##### 3.1.2 Karakteristik Ethereum (ETH)

Sebagai aset kripto terbesar kedua, Ethereum memiliki karakteristik volatilitas yang juga signifikan, meskipun dengan rentang harga dasar yang lebih rendah dibandingkan Bitcoin[17]. Harga terendah ETH selama periode pengamatan tercatat pada \$1.200,51, sementara harga tertingginya mampu menembus \$4.831,18. Nilai rata-rata pergerakan harga penutupan ETH berada di kisaran \$2.612,65. Dengan standar deviasi sebesar 818,33, ETH menunjukkan pola pergerakan sekunder yang sering kali mengekor sentimen pasar secara umum, namun tetap memiliki fluktuasi mandiri yang tajam, sebagaimana yang dapat dilihat pada visualisasi grafik historis pergerakan ETH dapat dilihat lebih jelas pada Gambar 3.



Gambar 3. Harga Penutupan Ethereum

##### 3.1.3 Karakteristik Solana (SOL)

Solana mewakili aset kripto alternatif (*altcoin*) dengan nominal harga per koin yang jauh lebih kecil dibandingkan BTC dan ETH, namun memiliki persentase volatilitas dan tingkat pertumbuhan yang sangat signifikan[18]. Harga

minimum SOL selama periode ini sempat menyentuh titik terendah di \$10,00, lalu mengalami lonjakan eksponensial hingga mencapai nilai maksimum \$261,86. Rata-rata harga penutupan SOL tercatat pada angka \$116,56. Nilai standar deviasi sebesar 67,98 mengindikasikan bahwa relatif terhadap harganya, SOL mengalami pergerakan (persentase perubahan) yang paling fluktuatif. Pola pergerakan agresif ini terlihat jelas pada grafik historis SOL yang disajikan pada Gambar 4.



Gambar 4. Harga penutupan Solana

Untuk memberikan visualisasi data yang lebih efisien serta mempermudah pemahaman mengenai karakteristik dari masing-masing aset kripto, ringkasan hasil statistik deskriptif yang mencakup nilai minimum, maksimum, rata-rata, hingga standar deviasi dari ketiga aset kripto tersebut dipaparkan secara runtut pada Tabel 1.

Tabel 1. Statistik Deskriptif Harga Penutupan Kripto (Januari 2023 - April 2026)

Aset Kripto	Jumlah data (Count)	Minimum (USD)	Maksimum (USD)	Rata-rata MEAN (USD)	Standar Deviasi
Bitcoin (BTC)	1202	16.618,40	124.725,10	66.387,10	30.663,74
Ethereum (ETH)	1202	1.200,51	4.831,18	2.612,65	818,33
Solana (SOL)	1202	10	261,86	166,56	67,98

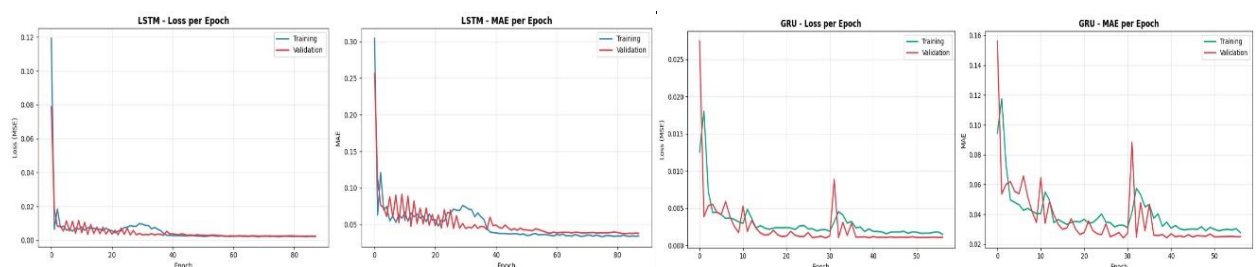
Selisih yang besar antara nilai minimum dan maksimum, serta tingginya nilai standar deviasi pada ketiga aset kripto tersebut, menunjukkan adanya volatilitas tinggi dan pola *non-linear* pada data. Karakteristik data ini menegaskan pentingnya penggunaan model *Deep Learning*, seperti *Long Short-Term Memory (LSTM)* dan *Gated Recurrent Unit (GRU)*. Kedua algoritma ini memiliki kemampuan untuk menangkap dependensi jangka panjang pada data deret waktu yang kompleks, yang sulit ditangani oleh model statistik tradisional.

### 3.2 Pelatihan Data Model

Proses pelatihan model *Deep Learning* dipantau melalui pergerakan nilai *loss (Mean Squared Error)* dan metrik *Mean Absolute Error (MAE)* pada setiap *epoch* [19]. Karakteristik data kripto mempunyai banyak *noise* dan volatilitas ekstrem menyebabkan pelatihan konvergensi model cenderung fluktuatif. Oleh karena itu, penerapan mekanisme *ReduceLRonPlateau* dan *Early Stopping* menjadi krusial untuk memitigasi risiko *overfitting* dan *underfitting* selama pelatihan. Berikut adalah visualisasi dan analisis pelatihan data untuk masing-masing aset:

#### 3.2.1 Pelatihan Data Bitcoin (BTC)


Pada data BTC model LSTM atau GRU menunjukkan tren penurunan *loss* yang signifikan di awal *epoch*. Adaptasi model sempat terhambat adanya volatilitas data. Kurva validasi LSTM mengalami lonjakan tajam pada rentang *epoch* 20 sampai 40 sebelum akhirnya stabil. Sementara pada GRU, lonjakan kurva serupa terjadi saat fase awal pelatihan akibat ketidakstabilan data latih. Penyesuaian bobot otomatis terbantu oleh *optimizer* hasil akhirnya berhasil mengarahkan kedua model menuju titik penyatuan yang konsisten di akhir *epoch*, seperti yang dilustrasikan pada Gambar 5.



Gambar 5. Kurva Loss dan MAE Model Bitcoin

a. Pelatihan Data Ethereum (ETH)

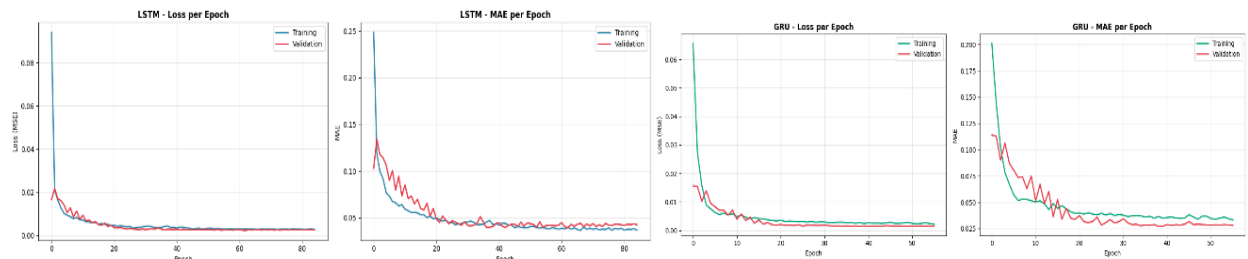
*Dataset* ETH memberikan tingkat kesulitan generalisasi yang lebih tinggi bagi model. Kurva validasi pada model LSTM dan GRU menampilkan osilasi ekstrem di hampir sepanjang proses pelatihan, yang mengindikasikan kuatnya pola *noise* pada pergerakan harga ETH. Meskipun kurva *training* menurun secara konsisten, kurva validasi terus merespons dengan lonjakan fluktuatif. Dalam kondisi ini, fitur *Early Stopping* berperan vital untuk menghentikan perulangan dan mengembalikan bobot terbaik (*best weights*) sebelum model mengalami *overfitting*, dapat dicermati lebih jelas pada Gambar 6.



Gambar 6. Kurva Loss dan MAE Model Ethereum

b. Pelatihan Data Solana (SOL)

Sebagai *altcoin* dengan volatilitas paling agresif, Solana memicu lonjakan kurva validasi yang paling masif. Pada fase tertentu, *loss* validasi meningkat tajam secara tiba-tiba sebelum kembali menurun, menunjukkan kesulitan model dalam mengenali pola *outlier*. Namun, seiring bertambahnya iterasi, aktivasi callback *ReduceLROnPlateau* yang memperkecil *learning rate* berhasil memaksa pergerakan grafik LSTM dan GRU melandai serta konvergen mendekati kurva *training* di akhir *epoch* diperlihatkan dalam gambar 7.



Gambar 7. Kurva Loss dan MAE Model Solana

Analisis *learning curve* mengonfirmasi bahwa arsitektur model sangat sensitif terhadap *noise* pasar kripto. Kendati kurva validasi sempat bergejolak, kombinasi regulasi *hyperparameter* dan strategi *callbacks* terbukti efektif memaksa model mencapai kondisi generalisasi yang optimal dan terhindar dari *overfitting* sebelum memasuki tahap pengujian.

3.3 Komparasi Kinerja Prediksi dan Efisiensi

Evaluasi kinerja arsitektur model pada data uji (*testing data*) merupakan tahapan paling kritis untuk menguji hipotesis awal mengenai dinamika *trade-off* antara akurasi prediksi dan efisiensi komputasi[20]. Parameter akurasi dinilai berdasarkan metrik *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Sementara itu, efisiensi komputasi diukur melalui total waktu pelatihan (*training time*). Ringkasan komparasi metrik performa antara model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) pada ketiga aset kripto disajikan secara terperinci pada Tabel 2.

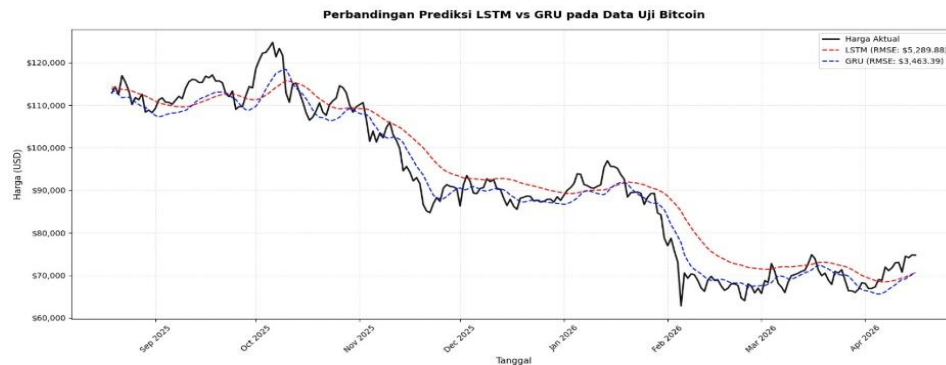
Tabel 2. Komparasi Kinerja Model LSTM dan GRU

Aset Kripto	Model	RMSE (USD)	MAE (USD)	MAPE (%)	Waktu Latih (s)
Bitcoin (BTC)	LSTM	5289.87	4106.99	4.82	56,49
	GRU	3463.39	2659.79	2.93	36,16
Ethereum (ETH)	LSTM	205.33	153.80	5.09	43,21
	GRU	160.06	177.43	3.83	37,45
Solana (SOL)	LSTM	12.43	9.97	7.46	54,74
	GRU	9.83	7.12	4.89	34,53

Berdasarkan Tabel 2, hasil analisis komparatif menunjukkan secara konsisten bahwa arsitektur GRU mendominasi dan mengungguli LSTM pada seluruh skenario pengujian, baik dari segi minimasi error maupun efisiensi waktu. Berikut adalah penjabaran analisis untuk masing-masing aset:

a. Evaluasi Prediksi pada Bitcoin (BTC)

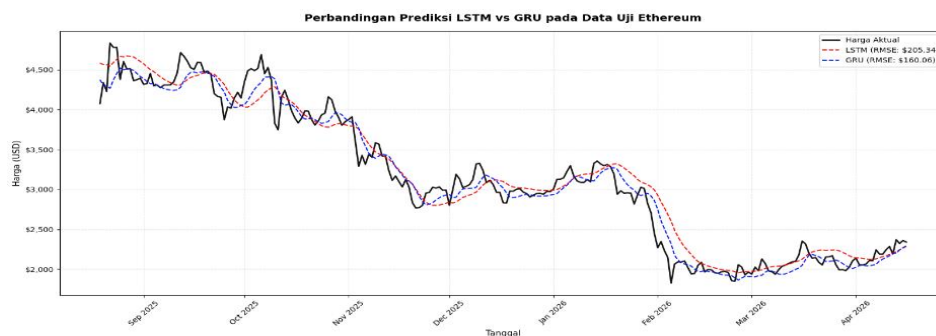
Pada pengujian komparatif menggunakan *dataset* Bitcoin, model GRU menunjukkan dominasi akurasi yang mencolok atas LSTM. Optimasi ini tercermin dari reduksi nilai *Root Mean Squared Error* (RMSE) sebesar \$1.826,49, yang setara dengan peningkatan presisi sebesar 34,53%. Indeks *Mean Absolute Percentage Error* (MAPE) GRU mampu ditekan hingga 2,93%, sedangkan LSTM tertahan di angka 4,82%. Fleksibilitas komputasi juga menjadi poin unggulan GRU, fase pelatihan berjalan 20 detik lebih responsif dibandingkan kompetitornya. Kedekatan proyeksi tren model GRU terhadap fluktuasi riil BTC secara visual tersaji pada Gambar 8.



Gambar 8. Hasil Prediksi vs Harga Aktual BTC

b. Evaluasi Kinerja pada Ethereum (ETH)


Data Ethereum memiliki tingkat *noise* dan fluktuasi sekunder yang tinggi dapat diakomodasi secara optimal oleh model GRU. Hasil evaluasi metrik menunjukkan bahwa GRU mampu menurunkan nilai RMSE sebesar \$45,27 (lebih baik 22,05% dibandingkan LSTM). Tingkat kesalahan persentase (MAPE) pada GRU berhasil ditekan hingga 3,84%, sedangkan LSTM berada pada angka 5,10%. Selain itu, GRU unggul dalam efisiensi waktu dengan durasi pelatihan selama 37,45 detik. Responsivitas arsitektur model dalam mengikuti fluktuasi harga ETH divisualisasikan pada Gambar 9.



Gambar 9. Hasil Prediksi vs Harga Aktual ETH

c. Evaluasi Kinerja pada Solana (SOL)

Solana, sebagai *altcoin* dengan volatilitas harian ekstrem dan intensitas *outlier* yang tinggi, menjadi indikator pengujian krusial dalam penelitian ini. Model GRU kembali menunjukkan konsistensi performa dengan nilai MAPE sebesar 4,90%, mengungguli LSTM yang menghasilkan tingkat kesalahan sebesar 7,47% (menunjukkan keunggulan akurasi GRU sebesar 20,89%). Durasi pelatihan GRU sebesar 34,54 detik terbukti memangkas beban komputasi secara signifikan dibandingkan LSTM yang memerlukan waktu 54,74 detik. Kemampuan adaptasi garis prediksi terhadap lonjakan harga (*sudden spikes*) aktual SOL disajikan pada Gambar 10.



Gambar 10. Hasil Prediksi vs Harga Aktual SOL


Secara menyeluruh, hasil penelitian ini memberikan temuan empiris yang solid bahwa pada *dataset* deret waktu *cryptocurrency* yang penuh volatilitas dan *noise*, peningkatan kompleksitas model tidak selalu berbanding lurus dengan peningkatan performa. Arsitektur LSTM dengan tiga gerbang memorinya ternyata lebih lambat belajar dan lebih rentan terjebak pada *noise* data bising. Sebaliknya, GRU dengan arsitektur dua gerbangnya *update* dan *reset gate* terbukti sebagai model yang jauh lebih kokoh (*robust*). Dalam studi kasus ini, GRU menjadi arsitektur pilihan terbaik karena mampu memberikan akurasi prediksi yang jauh lebih presisi dengan penggunaan waktu komputasi yang jauh lebih hemat di ketiga aset kripto utama[21].

### 3.4 Proyeksi Harga Masa depan

Implementasi model *Deep Learning* dalam penelitian ini diakhiri dengan proyeksi harga aset kripto untuk 90 hari (3 bulan) ke depan menggunakan metode *recursive forecasting*. Strategi ini beroperasi secara sekuensial, di mana nilai estimasi pada hari ke-*t* diintegrasikan kembali sebagai input sliding window untuk memprediksi periode  $t+1$ [16]. Mengingat arsitektur *Gated Recurrent Unit* (GRU) secara konsisten menunjukkan performa unggul pada uji metrik, keluarannya menjadi fokus analisis utama. Sebagai pembandingan, model *Long Short-Term Memory* (LSTM) disertakan guna mengevaluasi linearitas tren jangka panjang. Visualisasi dan analisis mendalam mengenai hasil proyeksi untuk masing-masing aset kripto:

#### a. Estimasi Harga Bitcoin (BTC)

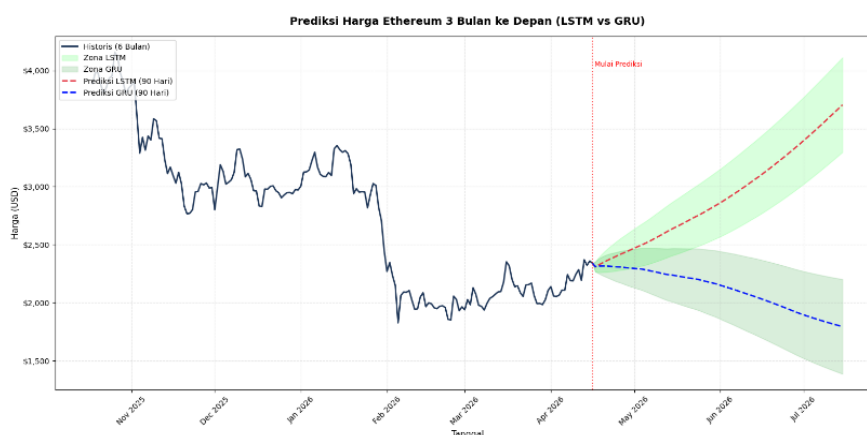
Proyeksi masa depan untuk Bitcoin mengindikasikan pergerakan yang konvergen namun tetap mempertahankan bias tren makro aset utama. Berdasarkan simulasi, GRU memproyeksikan harga penutupan BTC akan stabil dan berkonsolidasi di area atas setelah melewati volatilitas fase pengujian terakhir. Sebaliknya, varian LSTM menghasilkan kurva yang lebih landai. Fenomena ini menunjukkan sensitivitas struktur tiga gerbang memorinya dalam meredam fluktuasi jangka pendek saat dihadapkan pada skema input rekursif. Visualisasi detail disajikan pada Gambar 11.



Gambar 11. Prediksi Harga BTC 3 bulan kedepan

#### b. Estimasi Harga Ethereum (ETH)


Pada komoditas Ethereum, skema peramalan rekursif menangkap sinyal pemulihan tren secara gradual. Model GRU, melalui fleksibilitas parameternya, memproyeksikan ETH akan membentuk struktur akumulasi bervolatilitas rendah yang bergerak menjauhi area kritis pasca fase pengujian. Disisi lain, LSTM mengindikasikan tren yang cenderung *linear flat*. Hal ini mencerminkan kekakuan strukturalnya ketika menghadapi estimasi jangka panjang tanpa pembaruan data aktual harian. Dinamika komparatif ini tertera pada Gambar 12.



Gambar 12. Prediksi Harga ETH 3 bulan kedepan

### c. Estimasi Harga Solana (SOL)

Sebagai *altcoin* dengan historis volatilitas harian paling agresif, Solana memicu divergensi tren yang kontras di antara kedua arsitektur. GRU mampu menangkap residu momentum fluktuatif, sehingga grafiknya bergerak dinamis dengan rentang probabilitas lebar sebelum akhirnya melandai[21]. Sebaliknya, model LSTM menghasilkan kurva yang mengalami penyusutan varians (*decaying*) lebih cepat, menyebabkan garis estimasinya kehilangan sensitivitas terhadap riak harga historis SOL. Perbandingan visual ini dapat dicermati pada Gambar 13.



**Gambar 13.** Prediksi Harga SOL 3 bulan kedepan

Secara teoritis dan empiris, hasil prediksi mengonfirmasi batas kelemahan dasar dari *recursive forecasting*. Semakin jauh pandangan prediksi mendekati hari ke-90, kurva dari kedua model secara bertahap kehilangan fluktuasi mikro harian dan bergerak menuju garis tren makro yang mendatar.

### 3.5 Pembahasan

Evaluasi empiris terhadap data historis Bitcoin (BTC), Ethereum (ETH), dan Solana (SOL) menunjukkan bahwa arsitektur *Gated Recurrent Unit* (GRU) secara konsisten mengungguli *Long Short-Term Memory* (LSTM). Keunggulan tersebut tercermin dari dua indikator utama, akurasi prediksi yang lebih tinggi melalui minimalisasi margin kesalahan (*error rate*), serta efisiensi waktu komputasi yang lebih optimal. Temuan ini menawarkan pendekatan alternatif dalam memitigasi karakteristik pasar kripto yang fluktuatif dan sarat distorsi (*noise*). Perbedaan performa kedua algoritma tersebut berakar pada konfigurasi struktural masing-masing arsitektur.

Meskipun arsitektur *Long Short-Term Memory* (LSTM) sangat andal dalam mempertahankan konteks linier jangka panjang melalui pemisahan eksplisit antara *cell state* dan *hidden state*, konfigurasi tiga gerbang kendalinya yang padat parameter memicu kendala tersendiri saat dihadapkan pada volatilitas aset kripto[22]. Kompleksitas komputasi internal ini sering kali memperlambat responsivitas model terhadap anomali tren yang masif dan mendadak. Fenomena tersebut divalidasi oleh tingginya osilasi pada kurva validasi, di mana gejala hiper-parameterisasi menyebabkan model cenderung mengidentifikasi fluktuasi acak (*noise*) sebagai pola tren utama, yang pada akhirnya mendegradasi akurasi generalisasi.

Sebaliknya, efisiensi mekanis yang ditawarkan oleh *Gated Recurrent Unit* (GRU) mampu memitigasi keterbatasan struktural tersebut dengan meleburkan fungsi kondisi sel langsung ke dalam kondisi tersembunyi. Melalui eliminasi gerbang output, sistem kendali disederhanakan menjadi gerbang pembaruan (*update*) dan gerbang reset saja. Reduksi arsitektural ini tidak hanya memangkas tahapan komputasi dan mempercepat pembaruan bobot selama fase pelatihan, tetapi juga berfungsi sebagai regulasi internal yang secara alami menyaring fluktuasi acak pada data. GRU menunjukkan adaptabilitas dan fleksibilitas yang jauh lebih tinggi dalam merespons pergerakan harga agresif pada instrumen dengan volatilitas ekstrem seperti Solana, sekaligus mengoptimalkan kualitas prediksi dengan durasi komputasi yang jauh lebih efisien.

## 4. KESIMPULAN

studi komparatif ini menunjukkan bahwa arsitektur *Gated Recurrent Unit* (GRU) mengungguli *Long Short-Term Memory* (LSTM) dalam memprediksi pergerakan harga historis Bitcoin (BTC), Ethereum (ETH), dan Solana (SOL). Riset ini memberikan kontribusi empiris penting bahwa pada deret waktu finansial yang derau (*noise*), peningkatan kompleksitas arsitektur model tidak selalu berbanding lurus dengan peningkatan akurasi prediksi. Keberadaan tiga gerbang kendali pada LSTM memicu beban komputasi berlebih dan membuatnya lebih rentan terhadap osilasi acak data kripto. Sebaliknya, arsitektur GRU yang mengeliminasi output gate mampu memfilter derau secara lebih efektif. Keunggulan ini divalidasi oleh kemampuan GRU dalam menekan nilai Mean Absolute Percentage Error (MAPE) pada rentang 2,93%-4,89%, dengan waktu komputasi yang jauh lebih efisien dibandingkan LSTM. Melalui simulasi *recursive forecasting* 90 hari, GRU juga terbukti lebih adaptif dalam mempertahankan momentum volatilitas untuk memproyeksikan tren makro, sementara prediksi LSTM cenderung mengalami penyusutan varians (*decaying*) secara

prematur. Sebagai implikasi praktis, riset ini merekomendasikan arsitektur GRU sebagai solusi prediktif berpresisi tinggi dan hemat sumber daya untuk sistem algorithmic trading berfrekuensi tinggi. Keterbatasan utama riset ini terletak pada penerapan pendekatan univariat yang rentan terhadap akumulasi galat (*compounding error*) pada proyeksi jangka panjang. Untuk penelitian mendatang, disarankan menerapkan teknik *hyperparameter tuning* dan uji validasi statistik guna memperkuat generalisasi model. Selain itu, integrasi variabel prediktor multivariat (seperti volume transaksi, indikator makroekonomi, dan analisis sentimen) serta eksplorasi algoritma berbasis Transformer atau *hybrid attention mechanism* sangat direkomendasikan untuk mengatasi pelemahan varians pada peramalan horizon panjang.

## REFERENCES

- [1] R. Kaur, M. Uppal, D. Gupta, and S. Juneja, "Development of a cryptocurrency price prediction model : leveraging GRU and LSTM for Bitcoin , Litecoin and Ethereum," *PeerJ Comput. Sci.*, vol. 11, no. e2675, pp. 1–30, 2025, doi: 10.7717/peerj-cs.2675.
- [2] A. GIRSANG and STANLEY, "Cryptocurrency Price Prediction Based Social Network Sentiment Analysis Using LSTM-GRU and FinBERT," *IEEE Access*, vol. 11, pp. 120530–120540, 2023, doi: 10.1109/ACCESS.2023.3324535.
- [3] S. Hansun, A. Wicaksana, and A. Q. M. Khaliq, "Multivariate cryptocurrency prediction : comparative analysis of three recurrent neural networks approaches," *J. Big Data*, vol. 9, no. 1, p. 15, 2022, doi: 10.1186/s40537-022-00601-7.
- [4] A. Aljadani, "DLCP 2 F : a DL - based cryptocurrency price prediction framework," *Discov. Artif. Intell.*, vol. 2, no. 1, p. 20, 2022, doi: 10.1007/s44163-022-00036-2.
- [5] S. Syed, A. I. Member, W. Mehmood, and Z. Syed, "Split-Second Cryptocurrency Forecast Using Prognostic Deep Learning Algorithms: Data Curation by DeePhaven," *IEEE Access*, vol. 11, pp. 128644–128654, 2023, doi: 10.1109/ACCESS.2023.3331652.
- [6] F. Rodrigues, "High-Frequency Cryptocurrency Price Forecasting Using Machine Learning Models : A Comparative Study," *MDPI*, vol. 16, no. 4, pp. 1–21, 2025, doi: 10.3390/info16040300.
- [7] K. Koszewski, S. Mazumdar, and A. S. Kumar, "Understanding rate of return dynamics of cryptocurrencies : an experimental campaign," *Artif. Intell. Rev.*, vol. 57, no. 1, p. 29, 2024, doi: 10.1007/s10462-023-10629-7.
- [8] D. Perera, J. Lim, S. Gunraku, and W. H. Lim, "Cryptocurrency Analysis : Price Prediction of Cryptocurrency Using User Sentiments and Quantitative Data," *MONASH Univ.*, vol. 3, pp. 210–217, 2024, doi: 10.5220/0012315100003636.
- [9] P. L. Seabe, C. R. B. Moutsinga, and E. Pindza, "Sentiment-driven cryptocurrency forecasting: analyzing LSTM, GRU, Bi-LSTM, and temporal attention model (TAM)," *Soc. Netw. Anal. Min.*, vol. 15, no. 1, p. 27, May 2025, doi: 10.1007/s13278-025-01463-6.
- [10] M. Zubair *et al.*, "An Improved Machine Learning-Driven Framework for Cryptocurrencies Price Prediction With Sentimental Cautioning," *IEEE Access*, vol. 12, pp. 51395–51418, 2024, doi: 10.1109/ACCESS.2024.3367129.
- [11] H. Nuha, "Mean Squared Error (MSE) dan Penggunaannya," *JAPATUM*, vol. 3, no. 4, pp. 24–26, 2025, doi: 10.59328/JAPATUM.2024.3.4.107.
- [12] T. R. Mahesh *et al.*, "Transformative Breast Cancer Diagnosis using CNNs with Optimized ReduceLRonPlateau and Early Stopping Enhancements," *Int. J. Comput. Intell. Syst.*, vol. 17, no. 1, p. 14, 2024, doi: 10.1007/s44196-023-00397-1.
- [13] D. I. Puteri, "Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah," *Euler J. Ilm. Mat. Sains dan Teknol.*, vol. 11, no. 1, pp. 35–43, 2023, doi: 10.34312/euler.v11i1.19791.
- [14] A. A. Suryanto and A. Muqtadir, "Penerapan Metode Mean Absolute Error (MAE) dalam Algoritme Regresi Linier untuk Prediksi Produksi Padi," *SAINTEKBU J. Sains dan Teknol.*, vol. 11, no. 1, p. 78, 2019, doi: 10.32764/saintekbu.v11i1.298.
- [15] H. H. Nuha, "Mean Absolute Percentage Error (Mape) dan Penggunaannya," *JAPATUM*, vol. 3, no. 4, pp. 26–29, 2025, doi: 10.59328/JAPATUM.2024.3.4.108.
- [16] N. Yudistira *et al.*, *Prediksi Deret Waktu Menggunakan Deep Learning*. Malang: Universitas Brawijaya Press, 2023. [Online]. Available: <https://books.google.co.id/books?id=pOLXEEAAQBAJ>
- [17] T. Kuncara and K. P. Anugrah, "Analisis Volatilitas Cryptocurrency Pada Sebelum Pandemi Dan Pada Saat Pandemi Covid 19 Dengan Metode Return Pada Bitcoin Dan Ethereum," *Keunis*, vol. 11, no. 1, pp. 86–94, 2023, doi: 10.32497/keunis.v11i1.3981.
- [18] D. M. U. Atmaja and A. R. Hakim, "Peramalan Harga Mata Uang Kripto Solana Menggunakan Metode Support Vector Regression (Svr)," *J. Media Elektro*, vol. 10, no. 2, pp. 97–104, 2022, doi: 10.35508/jme.v0i0.8117.
- [19] N. Saptadi, H. Kristiawan, A. Nugroho, N. Rahayu, Suwarmiyati, and B. Waseso, *DEEP LEARNING Teori, Algoritma, dan Aplikasi*. BANTEN: Sada Kurnia Pustaka, 2025. [Online]. Available: <https://books.google.co.id/books?id=JQBLEQAAQBAJ>
- [20] D. Lusiyanti, S. Musdalifah, A. Sahari, and I. Al Fajri, "Evaluasi Kinerja Algoritma Machine learning pada Dataset Skala Besar," *MathVision J. Mat.*, vol. 7, no. 1, pp. 84–92, 2025, doi: 10.55719/mv.v7i1.1661.
- [21] Y. Perdana, N. R. Hanum, A. Rabiula, and Y. Anzari, "Analisis Perbandingan Model Gru Dan Lstm Untuk," *J. Akad.*, vol. 17, no. 2, pp. 54–60, 2025, doi: 10.53564/akademika.v17i2.1692.
- [22] P. B. Wintoro, H. Hermawan, M. A. Muda, and Y. Mulyani, "Implementasi Long Short-Term Memory pada Chatbot Informasi Akademik Teknik Informatika Unila," *Expert J. Manaj. Sist. Inf. dan Teknol.*, vol. 12, no. 1, p. 68, 2022, doi: 10.36448/expert.v12i1.2593.