

PREDIKSI HARGA CRYPTOCURRENCY BITCOIN DENGAN PENDEKATAN DEEP LEARNING MENGGUNAKAN GATED RECURRENT UNIT (GRU)

Umar Faruq Manek, Siti Nur'Afiah, Sumiarni Moka

Teknik Informatika, Universitas Halu Oleo

Kampus Hijau Bumi Tridharma, Anduonohu, Kec. Kambu, Kota Kendari, Kota Kendari 93232

Umarfm18@gmail.com

ABSTRAK

Cryptocurrency, khususnya Bitcoin, dikenal memiliki volatilitas harga yang tinggi, sehingga prediksi harga menjadi penting bagi investor dan pengambil keputusan. Namun, kompleksitas pasar yang dipengaruhi oleh berbagai faktor eksternal membuat prediksi menjadi menantang. Penelitian ini bertujuan untuk mengembangkan model prediksi harga penutupan Bitcoin menggunakan pendekatan deep learning berbasis Gated Recurrent Unit (GRU) untuk menangkap pola temporal dalam data historis. Metode yang digunakan meliputi pengumpulan data dari Yahoo Finance selama periode 2014–2024, pra-pemrosesan data dengan normalisasi dan pembentukan sequences, serta pelatihan model GRU dengan beberapa konfigurasi epoch dan batch size. Evaluasi model dilakukan menggunakan metrik MAE, RMSE, dan MAPE, sedangkan pengujian dilakukan pada 25 tanggal acak untuk membandingkan prediksi dengan harga aktual. Hasil menunjukkan bahwa model GRU dengan konfigurasi 150 epoch dan batch size 62 memberikan performa terbaik dengan MAE 664.49, RMSE 1129.88, dan MAPE 1.84%. Meskipun ada deviasi pada beberapa kasus akibat volatilitas pasar, model ini secara umum mampu memberikan prediksi yang akurat dan dapat digunakan sebagai alat bantu pengambilan keputusan investasi di pasar *cryptocurrency*.

Kata kunci : *Cryptocurrency, Bitcoin, Prediksi, Gated Recurrent Unit (GRU), Deep Learning, Time Series Forecasting*

1. PENDAHULUAN

Dalam beberapa tahun terakhir, *cryptocurrency* telah menjadi salah satu fenomena paling menarik dalam dunia keuangan dan teknologi. Bitcoin adalah sistem mata uang digital terdesentralisasi berbasis teknologi blockchain yang memungkinkan transaksi *peer-to-peer* tanpa melibatkan otoritas pusat seperti bank. Bitcoin menggunakan mekanisme konsensus *Proof-of-Work* (PoW) untuk memastikan keamanan, transparansi, serta integritas data transaksi. Sebagai *cryptocurrency* pertama dan paling populer, telah merevolusi cara pandang masyarakat terhadap sistem keuangan tradisional. Dengan karakteristik desentralisasi, transparansi, dan keamanan yang tinggi, Bitcoin menawarkan alternatif investasi yang menarik bagi berbagai kalangan, mulai dari investor individu hingga institusi keuangan besar. Namun, volatilitas harga Bitcoin yang sangat tinggi menjadi tantangan utama bagi para investor dan trader dalam mengambil keputusan investasi yang tepat. Fluktuasi harga yang tajam dan tidak terduga sering kali menyebabkan risiko kerugian yang signifikan, sehingga prediksi harga Bitcoin menjadi topik yang sangat penting dan relevan untuk dikaji secara mendalam [1].

Prediksi harga aset keuangan, khususnya *cryptocurrency*, merupakan area penelitian yang kompleks dan menantang. Hal ini disebabkan oleh sifat pasar *cryptocurrency* yang sangat dinamis, dipengaruhi oleh berbagai faktor eksternal seperti sentimen pasar, regulasi pemerintah, adopsi teknologi, hingga berita global yang dapat memicu perubahan harga secara drastis dalam waktu singkat. Oleh karena

itu, metode prediksi yang mampu menangkap pola dan tren harga secara akurat sangat dibutuhkan untuk membantu investor dalam mengambil keputusan yang lebih terinformasi dan mengurangi risiko kerugian [2].

Seiring dengan kemajuan teknologi kecerdasan buatan (*Artificial Intelligence*), khususnya dalam bidang pembelajaran mesin (*Machine Learning*) dan pembelajaran mendalam (*Deep Learning*), berbagai model prediksi harga mulai dikembangkan untuk mengatasi kompleksitas data deret waktu pada pasar keuangan. *Deep Learning*, sebagai cabang dari *Machine Learning* yang menggunakan jaringan saraf tiruan dengan banyak lapisan (*deep neural networks*), memiliki kemampuan yang luar biasa dalam mengenali pola dan hubungan *non-linear* yang sulit dideteksi oleh metode statistik konvensional. Salah satu arsitektur *deep learning* yang banyak digunakan untuk analisis data deret waktu adalah *Recurrent Neural Network* (RNN) dan beberapa variannya [3].

Namun, RNN konvensional memiliki keterbatasan dalam mengatasi masalah *vanishing gradient* yang menyebabkan kesulitan dalam menangkap ketergantungan jangka panjang pada data deret waktu. Untuk mengatasi hal ini, dikembangkan varian RNN seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). GRU merupakan model yang relatif lebih sederhana dibandingkan LSTM, namun tetap efektif dalam mengelola informasi penting dari data historis dengan menggunakan dua gerbang utama, yaitu reset gate dan update gate. Struktur ini memungkinkan GRU untuk menyimpan dan melupakan informasi secara selektif, sehingga model dapat fokus pada pola yang relevan

dalam data deret waktu dan meningkatkan akurasi prediksi [4].

Berbagai penelitian sebelumnya telah menunjukkan bahwa model GRU mampu memberikan hasil prediksi yang kompetitif [5], bahkan dalam beberapa kasus lebih baik dibandingkan LSTM, terutama dalam konteks prediksi harga saham dan *cryptocurrency*. Keunggulan GRU dalam hal efisiensi komputasi dan kemampuan generalisasi menjadikannya pilihan yang menarik untuk diterapkan dalam prediksi harga Bitcoin. Dengan menggunakan data historis harga Bitcoin yang mencakup berbagai fitur seperti harga pembukaan, penutupan, harga tertinggi, harga terendah dan tanggal, model GRU dapat dilatih untuk mengenali pola-pola tersembunyi yang mempengaruhi pergerakan harga di masa depan [6].

Penelitian ini bertujuan mengembangkan dan menguji model prediksi harga Bitcoin menggunakan deep learning berbasis GRU, dengan fokus pada evaluasi akurasi dan perbandingan konfigurasi model terbaik. Data historis yang digunakan meliputi harga pembukaan, penutupan, tertinggi, terendah, dan tanggal untuk mengenali pola harga di masa depan.

Penelitian ini penting secara akademis dan praktis, memperkaya metode prediksi harga *cryptocurrency* dengan GRU yang efektif serta membantu investor dan pengembang aplikasi dalam pengambilan keputusan dan pengelolaan risiko. Namun, karena harga Bitcoin dipengaruhi faktor eksternal seperti regulasi, geopolitik, dan sentimen pasar yang sulit diprediksi [7], hasil prediksi sebaiknya digunakan sebagai alat bantu yang melengkapi analisis fundamental dan manajemen risiko.

2. TINJAUAN PUSTAKA

2.1. Cryptocurrency

Cryptocurrency merupakan mata uang elektronik atau digital yang secara inheren tidak bergantung pada bank komersial tradisional, bank sentral, maupun pihak ketiga sebagai otoritas verifikasi transaksi dan penciptaan unit mata uang baru. Sistem ini beroperasi secara desentralisasi dan *peer-to-peer*, memungkinkan transaksi dilakukan secara langsung tanpa memerlukan pengawasan atau regulasi dari lembaga pemerintah seperti departemen perdagangan atau kantor pengawas keuangan semacam Otoritas Jasa Keuangan (OJK). Dengan demikian, *cryptocurrency* memungkinkan transaksi lintas negara yang tidak terikat oleh kontrol institusional konvensional [8].

2.2. Bitcoin

Bitcoin merupakan mata uang digital yang bersifat *peer-to-peer* dan *open source*, yang beroperasi berdasarkan prinsip-prinsip kriptografi untuk memvalidasi setiap transaksi serta mengendalikan proses penciptaannya. Tidak seperti mata uang konvensional yang diterbitkan oleh lembaga resmi, Bitcoin dihasilkan secara otomatis oleh perangkat lunak dalam sistem Bitcoin itu sendiri dan hanya dapat

diakses melalui jaringan tersebut. Selain itu, nilai tukar Bitcoin tidak bergantung pada mata uang dunia nyata, melainkan ditentukan oleh mekanisme penawaran dan permintaan di pasar [9].

2.3. Deep Learning

Deep learning adalah cabang kecerdasan buatan dan *machine learning* yang menggunakan jaringan saraf berlapis ganda untuk meningkatkan akurasi dalam tugas seperti deteksi objek, pengenalan suara, dan terjemahan bahasa. Algoritma ini belajar pada berbagai tingkat abstraksi dengan memanfaatkan konsep-konsep yang saling terkait antara level rendah dan tinggi. Pelatihan jaringan dilakukan dengan metode penurunan *gradien*, namun penambahan lapisan yang terlalu banyak dapat mengurangi efektivitas gradien dan mempengaruhi hasil output [10].

2.4. Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) adalah salah satu jenis arsitektur jaringan saraf rekuren (*Recurrent Neural Network*, RNN) yang diperkenalkan oleh Cho et al. pada tahun 2014. GRU dikembangkan untuk mengatasi masalah *vanishing gradient* yang sering terjadi pada RNN tradisional ketika memproses data deret waktu yang panjang [4].

GRU memiliki dua komponen utama yang disebut gate, yaitu reset gate dan update gate. Kedua gate ini berfungsi mengatur aliran informasi dalam jaringan sehingga model dapat memutuskan informasi mana yang perlu disimpan dan mana yang harus dilupakan dari data sebelumnya. *Reset gate* (r) berfungsi untuk menentukan seberapa banyak informasi masa lalu yang harus dilupakan saat memproses input baru. Dengan kata lain, reset gate membantu jaringan mengabaikan informasi yang tidak relevan dari keadaan tersembunyi sebelumnya. *Update gate* (z) berfungsi untuk mengontrol seberapa banyak informasi dari keadaan tersembunyi sebelumnya yang perlu dipertahankan dan seberapa banyak informasi baru yang harus ditambahkan. Update gate ini memungkinkan GRU untuk menangkap dependensi jangka panjang tanpa kehilangan informasi penting dari masa lalu [11].


2.5. Penelitian Terdahulu

Penelitian yang dilakukan oleh Tanudy, Handhayani, dan Hendryli (2023) [12] menggunakan metode *Gated Recurrent Unit* (GRU) untuk memprediksi harga emas di Indonesia selama periode 7 hari ke depan. Model GRU dilatih dengan data historis harga emas, harga saham PT. Aneka Tambang, dan nilai tukar dolar dari tahun 2018 hingga 2023 yang diperoleh dari Yahoo Finance. Hasilnya menunjukkan tingkat akurasi yang sangat baik dengan nilai R -Squared sebesar 0,97, MAE 300,17, dan RMSE 17,33, menandakan kemampuan *Gated Recurrent Unit* (GRU) dalam menangkap pola jangka panjang dan fluktuasi harga aset time series secara efektif.

Penelitian ini membuktikan bahwa metode *Gated Recurrent Unit* (GRU) tidak hanya cocok untuk prediksi harga emas, tetapi juga berpotensi diaplikasikan pada aset lain seperti saham dan *cryptocurrency* dengan hasil prediksi yang andal. Dengan demikian, penelitian ini bisa menjadi salah satu bukti empiris yang kuat bahwa metode GRU merupakan pilihan yang tepat dan efektif dalam prediksi harga aset berbasis data time series

3. METODE PENELITIAN

Penelitian ini akan menerapkan metode *Gated Recurrent Unit* (GRU) dalam prediksi harga aset kripto Bitcoin. Metode ini meliputi tahapan pengumpulan data, pra-pemrosesan data, pembagian data untuk pelatihan dan pengujian, serta implementasi model GRU untuk memodelkan perilaku harga Bitcoin. Selain itu, penelitian mencakup proses pelatihan model, evaluasi kinerja, dan analisis hasil untuk memvalidasi keefektifan prediksi yang dihasilkan. Tahapan pengujian dilakukan untuk menguji keakuratan dan keandalan model GRU dalam konteks prediksi harga Bitcoin.



Gambar 1. Flowchart Metode Penelitian

3.1. Pengumpulan Data

Data historis harga *Bitcoin* yang digunakan dalam penelitian ini diambil dari *Yahoo Finance*, sebuah platform terkemuka yang menyediakan akses *real-time* ke informasi finansial dan pasar global. *Yahoo Finance* menjadi sumber yang sangat berharga bagi para peneliti dan investor karena menyediakan data yang terstruktur dan komprehensif untuk analisis mendalam. Rentang waktu data mencakup 9 tahun terakhir, mulai dari September 2014 hingga Mei 2024, mencakup parameter penting seperti harga pembukaan, penutupan, tertinggi, terendah, dan volume perdagangan harian. Pengunduhan data dilakukan dalam format *xlsx* yang memungkinkan analisis statistik dan model prediktif, seperti penggunaan metode *Gated Recurrent Unit* (GRU) dalam penelitian ini, untuk memprediksi pergerakan harga *Bitcoin*. *Yahoo Finance* tidak hanya menyediakan data harga historis, tetapi juga menyediakan berita finansial, laporan keuangan, dan analisis pasar yang mendalam, memungkinkan para pengguna untuk memahami dinamika pasar secara lebih baik. Dengan menggunakan data yang akurat dan terpercaya dari *Yahoo Finance*, peneliti dapat mengembangkan strategi investasi yang lebih informasional dan menghasilkan prediksi yang lebih tepat dalam lingkungan pasar yang dinamis seperti *cryptocurrency*.

Tabel 1 Contoh data dari yahoo finance

Date	Open	High	Low	Close
17/09/2014	466	466	466	466
18/09/2014	457	457	413	424
19/09/2014	424	428	385	395
20/09/2014	395	423	390	409
21/09/2014	408	412	393	399

3.2. Pra Pemrosesan Data

Pra-pemrosesan data adalah langkah penting dalam penelitian ini untuk memastikan data yang digunakan berkualitas dan siap untuk dianalisis dengan model GRU. Proses ini mencakup konversi dan transformasi data agar sesuai dengan kebutuhan analisis berbasis waktu, serta pemilihan fitur dan normalisasi data untuk mengoptimalkan performa model. Berikut adalah langkah-langkah detail dalam pra-pemrosesan data :

- Konversi kolom 'Date' ke format *datetime* dan pengaturan sebagai indeks. Langkah ini penting untuk memudahkan pengelompokan dan analisis data berbasis waktu. Dengan mengatur kolom 'Date' sebagai indeks, Anda memastikan bahwa data dapat diakses dan diurutkan berdasarkan urutan waktu secara langsung, yang diperlukan untuk model GRU dalam memprediksi tren harga.
- Pemilihan fitur 'Open', 'High', dan 'Low' sebagai variabel input, serta 'Close' sebagai target prediksi: Memilih fitur-fitur ini sebagai variabel input memungkinkan model GRU untuk memahami variasi harga selama periode waktu tertentu. 'Close'

dipilih sebagai target prediksi karena ini adalah harga penutupan yang ingin diprediksi oleh model. Data dinormalisasi menggunakan *MinMaxScaler* untuk mengoptimalkan konvergensi model.

- c. Data dinormalisasi menggunakan *MinMaxScaler* untuk mengoptimalkan konvergensi model: Normalisasi data adalah langkah krusial dalam pra-pemrosesan data untuk model *GRU*. Dengan menggunakan *MinMaxScaler*, rentang nilai dari setiap fitur (seperti harga) disesuaikan ke rentang antara 0 dan 1, memungkinkan model untuk belajar dengan lebih baik tanpa terpengaruh oleh perbedaan skala antar fitur.
- d. Pembentukan Sequences dengan panjang 60 hari: Pembentukan sequences adalah proses di mana data yang telah dinormalisasi dibagi menjadi segmen-segmen berurutan. Dalam konteks ini, setiap sequence terdiri dari 60 hari data historis sebagai input, dengan harga penutupan pada hari ke-61 sebagai target prediksi. Ini membantu model *GRU* untuk memahami pola dan tren dalam data historis sebelumnya untuk membuat prediksi yang lebih akurat.

3.3. Pembagian Data

Setelah tahap pra-pemrosesan data selesai, langkah selanjutnya adalah pembagian *dataset* menjadi set pelatihan dan set pengujian, yang dikenal sebagai *split data*. Langkah ini penting untuk mengevaluasi performa model secara objektif. Data yang telah dinormalisasi dan dibentuk menjadi *sequences* dibagi menjadi dua bagian, di mana 80% data digunakan untuk melatih model (*train set*) dan 20% sisanya digunakan untuk menguji performa model (*test set*). Pembagian ini memastikan bahwa model memiliki cukup data untuk belajar pola historis sementara tetap menyisakan sebagian data yang tidak pernah dilihat model selama pelatihan untuk validasi.

3.4. Model GRU

Dalam penelitian ini, model prediksi harga Bitcoin dibangun menggunakan arsitektur *Gated Recurrent Unit* (GRU), salah satu varian dari *Recurrent Neural Network* (RNN) yang dirancang untuk menangani data berurutan seperti deret waktu. GRU memiliki struktur yang mirip dengan *Long Short-Term Memory* (LSTM), namun dengan jumlah gate yang lebih sedikit, sehingga komputasi menjadi lebih efisien tanpa mengorbankan kemampuan dalam menangkap pola jangka panjang.

Arsitektur model GRU yang digunakan dalam penelitian ini terdiri dari dua lapisan GRU. Lapisan pertama terdiri dari 50 unit GRU dengan parameter *return_sequences=True*, karena lapisan ini harus memberikan keluaran berupa urutan lengkap agar dapat dihubungkan dengan lapisan GRU berikutnya. Dimensi input didefinisikan melalui argumen *input_shape=(X_train.shape[1], X_train.shape[2])* yang sesuai dengan ukuran *dataset* pelatihan.

Lapisan kedua juga terdiri dari 50 unit GRU, namun dengan parameter *return_sequences=False*, karena hanya nilai terakhir dari urutan yang diperlukan sebagai masukan untuk lapisan output. Setelah itu, sebuah lapisan *Dense* dengan satu *neuron* digunakan untuk menghasilkan prediksi numerik tunggal, yaitu harga Bitcoin pada waktu berikutnya.

Sebagai fungsi optimisasi, model menggunakan algoritma *Adam optimizer*, yang secara umum baik dalam hal kecepatan konvergensi dan performa untuk data sekuensial. Sementara itu, fungsi kerugian (*loss function*) yang digunakan adalah *Mean Squared Error* (MSE), yang cocok untuk tugas regresi seperti prediksi harga. Secara keseluruhan, model GRU yang dibangun dirancang untuk mempelajari pola temporal dari data historis harga Bitcoin dan memberikan prediksi harga berdasarkan informasi masa lalu yang tersedia.

3.5. Pelatihan Model

Dalam melakukan pelatihan model *GRU*, data yang telah dipisahkan ke dalam *training set* dan *test set* digunakan. Proses pelatihan dilakukan dengan menyesuaikan model menggunakan data *training* (*X_train*, *y_train*) dengan berbagai konfigurasi hyperparameter. Tujuannya adalah untuk menemukan metode pelatihan yang paling efektif dengan performa terbaik. Masing-masing model dilatih menggunakan dua *batch size*, yaitu 32 dan 62, dengan jumlah *epochs* sebesar 150, 250, 350, dan 500 pada masing-masing *batch size*, cara ingin digunakan untuk mencari setingan mana yang terbaik dan menghasilkan prediksi yang baik.

3.6. Evaluasi dan Analisis

Analisis dan evaluasi model menggunakan *MAE* (*Mean Absolute Error*), *RMSE* (*Root Mean Squared Error*), dan *MAPE* (*Mean Absolute Percentage Error*) memberikan pemahaman tentang akurasi prediksi. *MAE* menghitung rata-rata kesalahan absolut, *RMSE* mengukur deviasi standar dari kesalahan, dan *MAPE* memberikan kesalahan relatif dalam bentuk persentase. Semakin rendah nilai ketiga metrik ini, semakin baik kualitas prediksi modelnya. Berikut Penjelasannya :

- a. *Mean Absolute Error* (MAE) adalah ukuran rata-rata kesalahan absolut antara nilai aktual dan nilai prediksi dalam model prediksi. Rumus nya dapat dilihat pada persamaan (1)

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

Keterangan :

- *n* : Jumlah total observasi.
- *y_i* : Nilai aktual dari observasi ke-i.
- *ŷ_i* : Nilai yang diprediksi dari observasi ke-i.
- *y_i - ŷ_i* : Nilai absolut dari selisih antara nilai aktual dan prediksi.

- b. *Root Mean Square Error* (RMSE) adalah ukuran yang digunakan untuk menilai akurasi model prediksi. Ini mengukur seberapa jauh nilai yang

diprediksi dari nilai aktual. Rumus nya dapat di lihat pada persamaan (2).

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

Keterangan :

- n : Jumlah total observasi.
- y_i : Nilai aktual dari observasi ke-i.
- $\hat{y}_i$: Nilai yang diprediksi dari observasi ke-i.
- $(y_i - \hat{y}_i)^2$: Kuadrat dari selisih antara nilai aktual dan nilai prediksi.

- c. *Mean Absolute Percentage Error* (MAPE) adalah ukuran statistik yang digunakan untuk menilai akurasi model prediksi. MAPE mengukur rata-rata kesalahan absolut sebagai persentase dari nilai actual. Rumus nya dapat di lihat pada persamaan (3).

$$MAPE = \left(\frac{100\%}{n} \right) \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (3)$$

Keterangan :

- n : Jumlah total observasi atau data yang diprediksi.
- y_i : Nilai aktual dari observasi ke-i.
- $\hat{y}_i$: Nilai yang diprediksi dari observasi ke-i.

3.7. Pengujian Model

Eksperimen Pengujian Prediksi Berbasis Tanggal dirancang untuk mengevaluasi akurasi model prediksi harga penutupan Bitcoin dengan menggunakan 25 tanggal acak sebagai sampel. Dalam eksperimen ini, prediksi harga Bitcoin dari model dibandingkan dengan data harga aktual untuk menghitung deviasi persentase. Hasil evaluasi ini memberikan pemahaman mendalam tentang kinerja model dalam meramalkan pergerakan harga, yang krusial untuk analisis pasar finansial. Informasi ini tidak hanya memvalidasi ketepatan prediksi model tetapi juga menginformasikan keputusan investasi yang lebih cerdas dan efektif dalam konteks volatilitas pasar cryptocurrency yang tinggi

4. HASIL DAN PEMBAHASAN

4.1. Evaluasi Hasil

Dalam penelitian ini, dilakukan evaluasi terhadap berbagai kombinasi pengaturan model *GRU*, termasuk variasi jumlah *epochs* (100, 150, 250,350,500) dan *batch size* (32, 62). Masing-masing pengaturan dinilai menggunakan metrik seperti *mean absolute error* (MAE) dan *root mean square error* (RMSE) untuk menentukan keakuratan prediksi harga *Bitcoin*. Hasil evaluasi menunjukkan perbedaan performa model pada setiap konfigurasi, yang memberikan wawasan tentang pengaturan optimal yang paling sesuai untuk memprediksi pergerakan harga *Bitcoin* secara akurat. Setting terbaik kemudian dipilih berdasarkan metrik evaluasi ini. Berikut hasil pelatihan data yang ada pada Tabel 2.

Tabel 2 Tabel Evaluasi

Epoch	Batch size	MAE	RMSE	MAPE
100	32	712,49	1200,47	1,94%
150	32	847,27	1396,12	2,23%
250	32	840,55	1348,84	2,29%
350	32	728,48	1245,40	1,96%
500	32	1561,07	2196,52	4,75%
100	62	705,84	1077,94	2,10%
150	62	664,49	1129,88	1,84%
250	62	715,28	1216,82	1,92%
350	62	812,97	1478,21	2,10%
500	62	1520,27	2239,48	4,52%

Setelah melakukan pengujian pada berbagai kombinasi pengaturan model *GRU*, hasil evaluasi menunjukkan performa yang berbeda-beda berdasarkan metrik *MAE*, *RMSE*, dan *MAPE*. Dari semua pengaturan yang diuji, konfigurasi terbaik ditemukan pada kombinasi 150 *epochs* dan *batch size* 62. Pada pengaturan ini, model mencapai nilai *MAE* sebesar 664.49, *RMSE* sebesar 1129.88, dan *MAPE* sebesar 1.84%. Angka-angka ini menunjukkan bahwa model memiliki kemampuan prediksi yang sangat baik, dengan tingkat kesalahan yang rendah dalam memproyeksikan harga penutupan *Bitcoin*.

Konfigurasi ini tidak hanya memberikan akurasi yang tinggi, tetapi juga menunjukkan stabilitas dan konsistensi model dalam menangani volatilitas data harga *Bitcoin*. Dengan hasil ini, pengaturan tersebut dipilih sebagai yang paling optimal untuk analisis lanjutan dalam prediksi pasar *cryptocurrency* yang dikenal sangat dinamis. Evaluasi ini menegaskan bahwa penggunaan *GRU* dengan kombinasi tertentu dapat memberikan hasil prediksi yang memuaskan, memberikan landasan kuat untuk aplikasi praktis dalam mengantisipasi pergerakan harga aset digital.

4.2. Pengujian Model Secara Langsung

Pengujian model dilakukan dengan memilih secara acak 25 tanggal dari dataset yang tersedia. Setiap tanggal diinputkan ke dalam model *GRU* untuk memprediksi harga penutupan Bitcoin. Prediksi yang dihasilkan kemudian dibandingkan dengan harga aktual pada tanggal yang sama untuk mengevaluasi akurasi model. Analisis ini penting untuk memvalidasi kemampuan model dalam memproyeksikan harga Bitcoin di kondisi pasar yang sebenarnya. Deviasi antara prediksi dan data aktual digunakan sebagai ukuran evaluasi, memberikan gambaran yang jelas tentang efektivitas model dalam aplikasi nyata. Hasil pengujian ini juga membantu dalam melakukan penyesuaian lebih lanjut jika diperlukan, sehingga meningkatkan performa prediksi di masa mendatang. Tabel 3 menyajikan detail hasil pengujian untuk memberikan informasi yang lebih komprehensif kepada pengguna dan peneliti yang tertarik.

Tabel 3 Pengujian Model Secara Langsung

Date	Prediksi	Aktual	Perbedaan
12/11/2017	5934,51	5950,06	0,26%
05/07/2022	20044,72	20190,11	0,72%
15/04/2018	8120,80	8329,11	2,50%
28/06/2017	2405,73	2574,79	6,57%
17/02/2016	277,00	416,32	33,46%
13/10/2021	56795,02	57401,09	1,06%
18/09/2018	6215,23	6371,29	2,45%
30/04/2023	29272,20	29268,80	0,01%
07/05/2024	61659,07	62334,81	1,08%
04/12/2015	225,40	363,18	37,94%
25/01/2020	8226,08	8367,84	1,69%
08/08/2016	452,65	591,05	23,41%
10/03/2022	39413,65	39437,4	0,06%
14/06/2019	8458,74	8693,83	2,70%
19/04/2017	1068,68	1210,29	11,70%
02/11/2020	13443,90	13550,48	0,79%
16/05/2023	26994,01	27036,65	0,16%
27/12/2018	3564,25	3654,83	2,48%
05/09/2021	51490,80	51753,41	0,51%
20/07/2016	528,51	665,68	20,61%
11/04/2019	4982,95	5064,48	1,61%
23/08/2017	3968,90	4151,52	4,40%
06/01/2024	43602,58	43989,19	0,88%
17/10/2015	132,05	270,64	51,21%
29/03/2018	7215,06	7165,70	0,69%

Pada Tabel 3 di atas menunjukkan hasil pengujian model GRU terhadap 25 tanggal acak. Setiap tanggal dibandingkan antara prediksi harga penutupan Bitcoin dan harga aktualnya. Secara umum, model menunjukkan kinerja yang baik dengan sebagian besar prediksi mendekati harga aktual, dengan persentase perbedaan yang bervariasi. Meskipun terdapat beberapa kasus di mana prediksi memiliki deviasi yang cukup besar, hal ini wajar mengingat sifat volatil pasar cryptocurrency. Berdasarkan hasil pengujian tersebut, model GRU memiliki tingkat akurasi sekitar 91%, yang diperoleh dari rata-rata perbedaan prediksi terhadap harga aktual sebesar 8,36%.

Faktor-faktor eksternal seperti pengumuman berita penting, perubahan regulasi, atau aktivitas besar investor dapat mempengaruhi fluktuasi harga yang signifikan. Namun, penting untuk dicatat bahwa meskipun ada deviasi, prediksi tidak pernah melebihi harga aktual secara signifikan. Model ini dapat dijadikan acuan dalam mengambil keputusan investasi, tetapi penting untuk tetap mempertimbangkan kondisi pasar secara keseluruhan dan faktor-faktor lain seperti sentimen pasar dan analisis fundamental agar keputusan investasi dapat lebih optimal dan berimbang.

5. KESIMPULAN DAN SARAN

Penelitian ini membuktikan bahwa metode *Gated Recurrent Unit* (GRU) sangat efektif dalam memprediksi harga penutupan Bitcoin dengan akurasi tinggi dan kesalahan prediksi rendah. Dengan analisis data historis dan indikator teknis, GRU mampu menangkap pola kompleks pada pasar cryptocurrency

yang volatil, menghasilkan nilai MAE, RMSE, dan MAPE yang konsisten dan dapat diandalkan pada konfigurasi optimal 150 epochs dan batch size 62. Namun, karena harga cryptocurrency juga dipengaruhi oleh faktor eksternal seperti regulasi, teknologi blockchain, dan sentimen pasar global, keputusan investasi sebaiknya tidak hanya mengandalkan model ini, melainkan juga mempertimbangkan analisis fundamental dan teknikal secara menyeluruh. Dengan demikian, integrasi model GRU dan analisis pasar yang komprehensif dapat membantu investor mengidentifikasi peluang dan risiko secara lebih baik dalam menghadapi dinamika pasar *cryptocurrency*.

DAFTAR PUSTAKA

- [1] U. K. and A. P. Maria Teresa Chimienti, "Understanding the crypto-asset phenomenon, its risks and measurement issues," ECB Economic Bulletin. Accessed: Jun. 06, 2025. [Online]. Available: https://www.ecb.europa.eu/press/economic-bulletin/articles/2019/html/ecb.ebart201905_03~c83aeaa44c.en.html
- [2] D. Ariatmanto, R. Sari, and Y. R. Mahdika, "SLR Metode Paling Populer Prediksi Harga Cryptocurrency dengan Machine Learning dan Deep Learning," *Semin. Nas. Corisindo*, pp. 543–548, 2022, [Online]. Available: <https://corisindo.stikom-bali.ac.id/penelitian/index.php/semnas/article/view/114%0Ahttps://corisindo.stikom-bali.ac.id/penelitian/index.php/semnas/article/download/114/85>
- [3] A. Baradja, "Pemanfaatan Recurrent Neural Network (RNN) Untuk Meningkatkan Akurasi Prediksi Mata Uang Pada Forex Trading," *J. Softw. Eng. Ampera*, vol. 4, no. 2, pp. 2775–2488, 2023, [Online]. Available: <https://journal-computing.org/index.php/journal-sea/index>
- [4] R. Kaur *et al.*, "Development of a cryptocurrency price prediction model: leveraging GRU and LSTM for Bitcoin, Litecoin and Ethereum," *PeerJ Comput. Sci.*, vol. 11, pp. 1–30, 2025, doi: 10.7717/peerj-cs.2675.
- [5] Khalis Sofi, Aswan Supriyadi Sunge, Sasmitoh Rahmad Riady, and Antika Zahrotul Kamalia, "Perbandingan Algoritma Linear Regression, Lstm, Dan Gru Dalam Memprediksi Harga Saham Dengan Model Time Series," *Seminastika*, vol. 3, no. 1, pp. 39–46, 2021, doi: 10.47002/seminastika.v3i1.275.
- [6] A. Suwandi, "Prediksi Harga Emas Menggunakan Metode Single Moving Average," *JiTEKH*, vol. 8, no. 1, pp. 32–36, 2020, doi: 10.35447/jitekh.v8i1.194.
- [7] Anonim, "Bitcoin tumbles 4% as Trump tariff spree triggers market jitters," *The Economic Times*. Accessed: Jun. 06, 2025. [Online]. Available: <https://economictimes.indiatimes.com/markets/c>

- ryptocurrency/crypto-news/bitcoin-tumbles-4-as-trump-tariff-spree-triggers-market-jitters/articleshow/119927094.cms?from=mdr
- [8] B. Zohuri, H. T. Nguyen, and M. Moghaddam, "What is the Cryptocurrency? Is it a Threat to Our National Security, Domestically and Globally?," *Int. J. Theor. Comput. Phys.*, vol. 3, no. 1, pp. 1–14, 2022, doi: 10.47485/2767-3901.1020.
- [9] Annisa Fitria, "Bitcoin dalam Sistem Hukum Indonesia," *Lex Jurnalica*, vol. Volume 18, no. Nomor 2, 2021, [Online]. Available: https://digilib.esaunggul.ac.id/public/UEU-Journal-22472-11_2038.pdf
- [10] A. Raup, W. Ridwan, Y. Khoeriyah, S. Supiana, and Q. Y. Zaqiah, "Deep Learning dan Penerapannya dalam Pembelajaran," *JIIIP - J. Ilm. Ilmu Pendidik.*, vol. 5, no. 9, pp. 3258–3267, 2022, doi: 10.54371/jiip.v5i9.805.
- [11] D. S. Aryo Pradipta Gema, "Recurrent Neural Network (RNN) dan Gated Recurrent Unit (GRU)," Binus University. Accessed: Jun. 06, 2025. [Online]. Available: <https://socs.binus.ac.id/2017/02/13/rnn-dan-gru/>
- [12] T. Handhayani, C. Tanudy, and J. Hendryli, "Prediksi Harga Emas di Indonesia Menggunakan Gated Recurrent Unit," *J. Fasilkom*, vol. 13, no. 3, pp. 480–488, 2023, doi: 10.37859/jf.v13i3.6185.