

Perbandingan Kinerja Metode LSTM dan GRU dalam Prediksi Harga *Close Cryptocurrency*

Performance Comparison of LSTM and GRU Methods in Predicting Cryptocurrency Closing Prices

¹Rayhan Satria Andromeda*, ²Nurul Anisa Sri Winarsih

^{1,2}Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro

*e-mail: andromedarayhan@gmail.com

(received: 6 December 2024, revised: 7 January 2025, accepted: 10 January 2025)

Abstrak

Perkembangan teknologi telah meningkatkan minat terhadap investasi *cryptocurrency*, khususnya Bitcoin dan Ethereum, meskipun volatilitas harga yang tinggi tetap menjadi tantangan utama bagi investor. Penelitian ini bertujuan untuk memprediksi fluktuasi harga *cryptocurrency* menggunakan model Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU), yang dikenal unggul dalam analisis data deret waktu. Evaluasi performa model dilakukan dengan menggunakan parameter seperti *learning rate*, *timestamps*, *batch size*, jumlah epoch, dan *callback Early Stopping*. Metrik pengukuran yang digunakan meliputi *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), dan koefisien determinasi (R^2). Hasil penelitian menunjukkan bahwa model GRU lebih unggul dibandingkan LSTM dalam memprediksi harga *cryptocurrency*. Pada data Bitcoin, GRU mencatatkan nilai MAPE sebesar 0,38%, RMSE sebesar 343,02, dan R^2 sebesar 0,9988, yang mengungguli LSTM dengan MAPE 0,41%, RMSE sebesar 356,01, dan R^2 sebesar 0,9987. Pada data Ethereum, GRU mencatatkan nilai MAPE sebesar 0,45%, RMSE sebesar 20,89, dan R^2 sebesar 0,9983, lebih baik dibandingkan LSTM dengan MAPE sebesar 0,49%, RMSE sebesar 22,29, dan R^2 sebesar 0,9980. Temuan ini menunjukkan bahwa GRU lebih akurat dan efisien dalam memodelkan pola harga *cryptocurrency*, sehingga dapat memberikan peluang strategis bagi investor untuk membuat keputusan yang lebih terinformasi dalam menghadapi dinamika pasar *cryptocurrency* yang kompleks.

Kata kunci: *cryptocurrency*, deep learning, LSTM, GRU, prediksi

Abstract

Technological advancements have increased interest in cryptocurrency investments, particularly Bitcoin and Ethereum, despite the high price volatility that remains a major challenge for investors. This study aims to predict cryptocurrency price fluctuations using Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) models, both of which are well-regarded for time series data analysis. Model performance was evaluated using parameters such as learning rate, timestamps, batch size, number of epochs, and Early Stopping callbacks. The evaluation metrics included Mean Absolute Percentage Error (MAPE), Root Mean Square Error (RMSE), and the coefficient of determination (R^2). The results indicate that the GRU model outperforms LSTM in predicting cryptocurrency prices. For Bitcoin data, GRU achieved a MAPE of 0.38%, RMSE of 343.02, and R^2 of 0.9988, surpassing LSTM, which recorded a MAPE of 0.41%, RMSE of 356.01, and R^2 of 0.9987. Similarly, for Ethereum data, GRU achieved a MAPE of 0.45%, RMSE of 20.89, and R^2 of 0.9983, outperforming LSTM with a MAPE of 0.49%, RMSE of 22.29, and R^2 of 0.9980. These findings demonstrate that GRU is more accurate and efficient in modeling cryptocurrency price patterns, offering strategic opportunities for investors to make more informed decisions in navigating the complexities of the cryptocurrency market.

Keywords: *cryptocurrency*, deep learning, LSTM, GRU, prediction

1 Pendahuluan

Investasi merupakan tindakan untuk mengalokasikan sebagian dana yang dimiliki pada aset tertentu dengan harapan mendapatkan keuntungan di masa depan [1], Pesatnya perkembangan

<http://sistemasi.ftik.unisi.ac.id>

teknologi, khususnya internet, telah mendorong transformasi dalam cara masyarakat berinvestasi. Salah satu bentuk investasi yang semakin diminati adalah mata uang kripto (*cryptocurrency*), sebuah aset digital berbasis teknologi blockchain. Mata uang ini memiliki keunggulan, seperti sistem pengelolaan yang terdesentralisasi, tingkat keamanan tinggi yang menjaga kerahasiaan, dan kemudahan dalam proses transaksi [2]. Dengan menggunakan *cryptocurrency*, individu dapat melakukan pertukaran nilai tanpa memerlukan perantara pihak ketiga [3]. Khususnya Bitcoin dan Ethereum menduduki posisi teratas dalam kapitalisasi pasar *cryptocurrency* sebagai instrumen investasi [4]. Bitcoin sering disebut sebagai "emas digital," sedangkan Ethereum dikenal sebagai platform yang mendukung aplikasi terdesentralisasi dan kontrak pintar. Pada November 2024, harga Bitcoin melonjak, didorong oleh berbagai faktor seperti persetujuan ETF Bitcoin di Amerika Serikat serta ekspektasi regulasi yang lebih mendukung industri kripto. Selain Bitcoin, minat terhadap altcoin dan DeFi (Decentralized Finance) juga menunjukkan peningkatan signifikan, mencerminkan tren utama yang tengah berkembang di pasar kripto.

Investasi memiliki potensi terjadinya kerugian yang tidak diinginkan dalam proses pengambilan keputusan [5], dalam perdagangan *cryptocurrency*, investor memiliki peluang untuk meraih keuntungan melalui capital gain dan staking. Namun, fluktuasi harga yang signifikan dalam *cryptocurrency* sering kali disebabkan oleh perubahan dalam permintaan dan penawaran, serta faktor eksternal seperti sentimen pasar, berita ekonomi, kebijakan pemerintah, atau bahkan pernyataan dari tokoh terkenal. Hal ini menunjukkan bahwa volatilitas pasar yang tinggi membawa risiko besar bagi para investor [6]. Sebagai contoh, pasca pemilihan presiden AS pada 2024, harga Bitcoin melonjak seiring ekspektasi regulasi yang mendukung *cryptocurrency*, sementara Ethereum menunjukkan tren pertumbuhan yang kuat. Meskipun menawarkan potensi keuntungan besar, juga membawa risiko yang signifikan. Dalam situasi seperti ini, kemampuan untuk memprediksi harga menjadi aspek krusial. Analisis deret waktu menawarkan solusi melalui identifikasi pola historis untuk memproyeksikan tren masa depan, untuk itu peramalan deret waktu telah menjadi kajian penting di dalam analisis bidang ekonomi dan keuangan [7]. Dengan memanfaatkan pola harga pada interval tertentu, metode ini memungkinkan deteksi tren berulang yang dapat membantu investor mengambil keputusan lebih akurat di tengah dinamika pasar *cryptocurrency* yang berubah dengan cepat.

Analisis deret waktu atau *time series analysis* adalah metode peramalan yang menggunakan data historis untuk mengidentifikasi pola dan tren sebagai dasar dalam menentukan metode prediksi yang sesuai [8]. Metode ini memberikan landasan ilmiah bagi penyusunan strategi investasi yang lebih terukur dan membantu mengurangi ketidakpastian akibat volatilitas pasar. Dengan pemodelan sistematis berbasis data historis, investor dapat menganalisis tren jangka panjang maupun pendek, meningkatkan akurasi prediksi, serta mengelola risiko secara lebih efektif. Selain itu, metode ini memungkinkan investor menentukan momen yang tepat untuk masuk atau keluar dari pasar, memaksimalkan potensi keuntungan, dan meminimalkan kerugian. Manfaat lainnya mencakup perencanaan portofolio yang lebih adaptif terhadap pergerakan pasar, mendukung pengambilan keputusan yang terarah di tengah dinamika harga *cryptocurrency* yang semakin kompleks.

2 Tinjauan Literatur

Memprediksi harga Bitcoin secara akurat merupakan tantangan besar karena volatilitasnya yang tinggi [9]. Namun, prediksi yang akurat seringkali menjadi tantangan karena kompleksitas dan ketidakpastian sistem ekonomi dan keuangan, yang dipengaruhi oleh berbagai faktor eksternal dan kebijakan ekonomi [10]. Prediksi ini melibatkan tiga faktor utama, yaitu teknikal, fundamental, dan sentimen [11]. Ketiga faktor tersebut menghasilkan data sekuensial yang kompleks dan dinamis, sehingga membutuhkan metode analisis canggih untuk meningkatkan akurasi prediksi. Salah satu metode yang banyak digunakan adalah prediksi *time series* berbasis deep learning. Metode ini fleksibel untuk berbagai tujuan seperti *supervised*, *unsupervised*, dan *semi-supervised learning*, serta cocok untuk analisis data teknikal, fundamental, dan sentimen [12]. Model deep learning seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) mengatasi kelemahan RNN tradisional dengan mempertahankan informasi jangka panjang, sehingga ideal untuk pola harga aset yang fluktuatif. Tantangan utama dalam penerapan deep learning adalah menentukan parameter epoch yang optimal guna menghasilkan prediksi akurasi tinggi [13]. Dalam beberapa aplikasi prediksi, LSTM dan GRU mampu mengatasi masalah peluruhan gradien yang biasanya ditemukan pada model

jaringan saraf tradisional[14] .Kombinasi ketiga faktor utama dengan kemampuan LSTM dan GRU memberikan pendekatan holistik yang lebih akurat untuk memprediksi pergerakan harga *cryptocurrency*.

Long Short-Term Memory (LSTM) adalah pengembangan dari arsitektur *Recurrent Neural Network* (RNN) yang pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997. LSTM menggunakan tiga gerbang utama *input*, *forget*, dan *output gate* yang memungkinkan pengelolaan informasi secara rinci dan terkontrol sepanjang sekuens data. LSTM juga dikenal sebagai jaringan saraf dengan arsitektur yang fleksibel dan dapat disesuaikan sesuai aplikasi yang dirancang [15] . Hal ini menjadikan LSTM sangat efektif dalam menangkap pola pergerakan harga yang berulang dalam rentang waktu yang panjang [16]. Di sisi lain, *Gated Recurrent Unit* (GRU) memiliki performa serupa dengan LSTM namun dengan struktur yang lebih sederhana, hanya menggunakan dua gerbang utama, yaitu *reset gate* dan *update gate*. GRU tetap mampu mempertahankan informasi penting dalam jangka panjang dengan efisiensi yang lebih tinggi [17]. Penelitian menunjukkan bahwa parameter seperti jumlah layer, epoch, dan struktur model memiliki pengaruh signifikan terhadap akurasi prediksi. Dengan kemampuan untuk menangkap pola harga yang fluktuatif dan berulang, baik LSTM maupun GRU menjadi alat yang potensial bagi investor dalam memprediksi harga *cryptocurrency* [18]. Kedua model ini membantu investor membuat keputusan yang lebih akurat di tengah dinamika pasar yang terus berubah. Penelitian sebelumnya. Selama beberapa tahun terakhir ini.

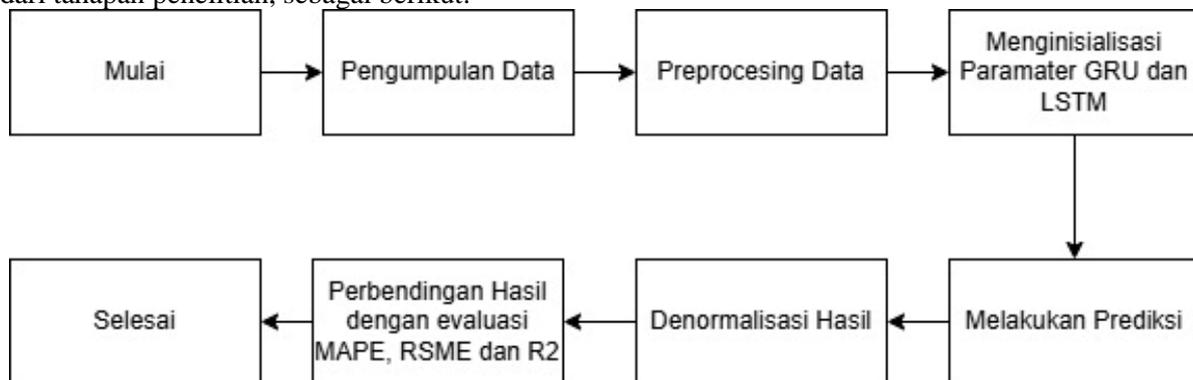
Algoritma *deep learning* telah banyak diterapkan dalam bidang finansial untuk mendukung analisis dan prediksi aset keuangan, seperti *cryptocurrency* dan saham [19]. Metode *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU), yang merupakan varian dari *algoritma Recurrent Neural Network* (RNN), terbukti efektif dalam menangani data deret waktu dengan pola yang kompleks dan ketergantungan jangka panjang. Dalam konteks prediksi harga Bitcoin, penerapan LSTM menghasilkan nilai RMSE sebesar 17.318,40 pada data pelatihan dan 27.921,84 pada data pengujian, dengan nilai MAPE masing-masing 3,24% dan 5,36% [20] . Selain itu, model LSTM-RNN juga digunakan untuk memprediksi harga Bitcoin dalam USD, menghasilkan nilai RMSE sebesar 0,14 dan *loss function* sebesar 0,0101, menunjukkan performa yang unggul dibandingkan model jaringan syaraf tiruan tradisional [21]. Sementara itu, GRU juga menjadi pilihan populer karena memiliki struktur yang lebih sederhana, namun tetap mampu menghasilkan prediksi yang akurat. Penelitian yang membandingkan GRU dan LSTM dalam memprediksi harga saham menunjukkan bahwa GRU memiliki nilai MAPE terendah sebesar 2,14% dan RMSE sebesar 0,01775, sedangkan LSTM mencatatkan nilai MAPE 2,42% dan RMSE sebesar 0,01807 [17] . Studi lain mendukung temuan ini, di mana GRU menunjukkan performa unggul dibandingkan metode seperti *Linear Regression* dan LSTM dalam beberapa kasus prediksi harga saham [22] . Dengan demikian, baik LSTM maupun GRU merupakan algoritma yang efektif untuk prediksi data deret waktu, dan pemilihannya bergantung pada karakteristik data serta kebutuhan spesifik model yang akan digunakan.

Selain itu, literatur [10] menegaskan bahwa faktor-faktor makroekonomi, seperti perubahan regulasi atau peristiwa geopolitik, juga dapat menimbulkan kejutan harga yang besar pada aset kripto. Dalam kondisi pasar yang sensitif, model GRU perlu di *fine tune* secara berkala melalui konsep online learning untuk menjaga keakuratan prediksinya terhadap *shock* pasar. Pendekatan ini membuka peluang penelitian lebih lanjut pada penggunaan ensemble model, di mana GRU digabungkan dengan metode lain (misalnya ARIMA, XGBoost, atau LSTM) agar masing-masing keunggulan model dapat saling melengkapi [18]. Meski dapat meningkatkan akurasi, ensemble model menuntut strategi *bagging* atau *boosting* yang tepat serta sumber daya komputasi yang lebih besar. Beberapa studi [17][19][22] menyoroti bahwa *Gated Recurrent Unit* (GRU) terbukti efektif dalam menganalisis data deret waktu dengan volatilitas tinggi, seperti harga kripto, karena proses pelatihannya yang efisien dan kemampuan untuk menangkap pola data tanpa memerlukan arsitektur yang terlalu kompleks. Keunggulan efisiensi ini menjadi semakin relevan mengingat pasar kripto beroperasi 24 jam sehari, 7 hari seminggu (24/7), yang menghasilkan volume data sangat besar dan terus-menerus. Tantangan utamanya adalah memastikan bahwa model GRU dapat menyesuaikan diri secara real-time terhadap perubahan pasar yang tiba-tiba, terutama apabila diintegrasikan ke dalam strategi *live trading* atau *backtesting*. Meski demikian, GRU menunjukkan potensi signifikan untuk mengelola data *streaming* secara berkelanjutan, karena komputasi yang lebih ringan memungkinkan proses pembaruan model atau *online learning* dilakukan tanpa mengorbankan terlalu banyak sumber daya.

Untuk memastikan akurasi prediksi, penelitian ini menggunakan tiga metrik evaluasi umum, yaitu *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), dan *R-squared* (R^2). MAPE mengukur tingkat akurasi prediksi dengan melihat perbedaan persentase antara nilai prediksi dan aktual, memberikan interpretasi langsung dalam bentuk persentase *error*. RMSE menghitung besar kesalahan prediksi terhadap garis regresi linier, memberikan informasi mengenai deviasi dalam satuan yang sama dengan data asli ini untuk mengetahui seberapa jauh hasil prediksi dari nilai sebenarnya [23]. R^2 , atau koefisien determinasi, mengukur seberapa baik model prediksi menjelaskan variabilitas data aktual, dengan nilai mendekati 1 menunjukkan model yang sangat baik dalam memprediksi data. Ketiga metrik ini mudah diimplementasikan dan sering digunakan dalam evaluasi akurasi prediksi aset keuangan. Dengan membandingkan hasil MAPE, RMSE, dan R^2 , penelitian ini bertujuan untuk menentukan model dengan kesalahan prediksi terkecil dan tingkat kecocokan terbaik, sehingga dapat memberikan wawasan mendalam mengenai metode terbaik untuk prediksi harga *cryptocurrency* yang akurat.

3 Metode Penelitian

Pada penelitian ini, tahapan-tahapan yang akan dilakukan meliputi pengumpulan data, *preprocessing* data, inialisasi parameter model LSTM dan GRU, pelaksanaan prediksi, denormalisasi hasil, evaluasi performa model menggunakan MAPE, RMSE, dan R^2 , serta perbandingan hasil performa. Pada Gambar 1. Tahapan Penelitian dibawah ini merupakan gambaran dari tahapan penelitian, sebagai berikut:



Gambar 1. Tahapan penelitian

3.1 Pengumpulan Data

Dalam tahapan pengumpulan data pada penelitian ini, digunakan data sekunder yang bersumber dari situs web <https://www.cryptodatadownload.com/>. Data yang diambil mencakup informasi terkait mata uang kripto, yaitu Bitcoin (BTC) dan Ethereum (ETH), yang menjadi fokus utama penelitian. Untuk data Bitcoin (BTC), periode pengumpulan dimulai pada tanggal 8 Oktober 2015 pukul 13.00 waktu server hingga tanggal 13 Oktober 2024 pukul 23.00 waktu server, dengan total keseluruhan sebanyak 79.042 data. Sementara itu, data Ethereum (ETH) diperoleh dengan periode pengumpulan yang dimulai pada tanggal 9 Mei 2016 pukul 13.00 waktu server hingga tanggal 28 Oktober 2024 pukul 23.00 waktu server, dengan jumlah data sebanyak 74.266 data. Dataset yang dikumpulkan dalam penelitian ini mencakup berbagai atribut yang relevan dengan kebutuhan analisis, seperti yang dijelaskan secara rinci pada Tabel 1. Atribut-atribut tersebut mencakup informasi penting yang dapat mendukung proses analisis lebih lanjut untuk mencapai tujuan penelitian.

Tabel 1. Atribut dataset

Atribut	Deskripsi
Unix Date	Timestamp dalam format UNIX yang menunjukkan waktu pencatatan Tanggal dan waktu pencatatan data (format: MM/DD/YYYY HH)
Open	Harga pembukaan mata uang cryptocurrency pada periode tertentu
High	Harga tertinggi mata uang cryptocurrency pada periode tertentu
Low	Harga terendah mata uang cryptocurrency pada periode tertentu
Close	Harga penutupan mata uang cryptocurrency pada periode tertentu
Volume BTC/ETH	Volume transaksi dalam mata uang cryptocurrency (BTC atau ETH)

Volume USD	Volume transaksi dalam mata uang USD (Dolar AS)
------------	---

Pengumpulan data ini diawali dengan mencari dataset publik dari sumber terpercaya melalui studi literatur, dengan tujuan mendapatkan data, informasi, dan gambaran lengkap mengenai komparasi metode *Gated Recurrent Unit* (GRU) dan *Long Short-Term Memory* (LSTM) dalam prediksi harga *cryptocurrency*. Dataset dari cryptodatadownload.com dipilih karena dinilai valid untuk tugas prediksi *cryptocurrency*, didukung oleh penelitian sebelumnya, seperti yang dilakukan oleh Puadi (2021) dan Buslim (2021), yang juga menggunakan dataset ini dalam studi mereka.

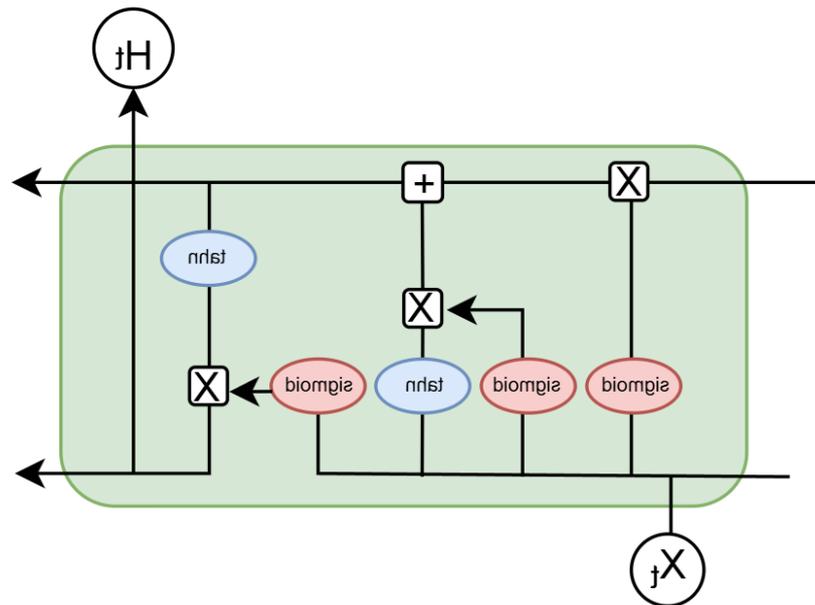
3.2 Preprocessing Data

Pada tahap preprocessing data, data yang digunakan pada penelitian ini dipersiapkan melalui beberapa tahapan penting, yaitu data cleaning, normalisasi data, dan splitting data. Pada tahap data cleaning, dilakukan pembersihan data dengan memastikan tidak ada nilai null atau missing values dalam dataset yang digunakan. Hal ini penting untuk menjaga konsistensi dan kredibilitas data yang akan dianalisis. Setelah itu, dilakukan normalisasi data menggunakan metode *Min-Max Scaling*. Proses normalisasi bertujuan untuk mengubah skala data ke rentang antara 0 dan 1, yang dapat meningkatkan stabilitas dan kinerja model yang digunakan. Dalam hal ini, *MinMaxScaler* dari *library sklearn.preprocessing* digunakan untuk mentransformasi data menjadi skala yang konsisten. Selanjutnya, dilakukan splitting data untuk membagi dataset menjadi tiga bagian: data training, validation, dan testing. Data training digunakan untuk melatih model, data validation digunakan untuk mengevaluasi model selama pelatihan, dan data testing digunakan untuk menguji model setelah pelatihan selesai.

Dalam penelitian ini, data dibagi menjadi 80% untuk training dan 20% untuk testing, di mana 10% terakhir diperuntukkan sebagai data testing dan 10% sebelumnya menjadi validation. Pembagian ini bertujuan untuk memisahkan secara jelas data yang digunakan untuk melatih model, memantau kinerja (validation), serta menguji performa akhir (testing). Hasil pembagian menunjukkan bahwa, untuk dataset ETH, data training memiliki dimensi (59283, 120, 6), sedangkan data validation dan testing masing-masing berdimensi (7297, 120, 6). Sementara itu, untuk dataset BTC, data training berdimensi (63103, 120, 6), sedangkan data validation dan testing masing-masing berdimensi (7775, 120, 6). Format (59283, 120, 6) menandakan bahwa setiap batch data dibangun melalui jendela waktu (timestep) berukuran 120 dengan total 6 fitur (misalnya *Open*, *High*, *Low*, *Close*, *Volume*, dan sebagainya). Dengan demikian, tahapan preprocessing—meliputi pembersihan missing values, normalisasi, dan pembentukan sekuens—membuat dataset siap digunakan untuk analisis selanjutnya, khususnya dalam pemodelan prediksi harga *cryptocurrency* berbasis time series. Pembagian data semacam ini juga membantu memastikan bahwa penilaian performa model lebih objektif, karena data yang dipakai untuk pengujian benar-benar terpisah dari data yang digunakan selama pelatihan.

3.3 Long Short Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah salah satu metode dalam *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi masalah *long-term dependency* dalam pemrosesan data sekuensial. Pada Gambar 2 LSTM mengimplementasikan tiga gerbang utama, yaitu *Forget Gate*, *Input Gate*, dan *Output Gate*, yang memungkinkan model untuk secara selektif menyimpan, memperbarui, atau menghapus informasi. *Forget Gate* bertugas menentukan informasi mana yang harus dilupakan berdasarkan kondisi saat ini, sedangkan *Input Gate* mengatur informasi baru yang akan ditambahkan ke dalam *cell state*. *Output Gate* kemudian menentukan informasi yang akan diteruskan ke langkah berikutnya atau ke layer berikutnya. Dalam mekanisme ini, masukan (X_t) diproses secara paralel melalui ketiga gerbang, dengan *cell state* (C_t) berfungsi sebagai memori utama yang diperbarui setiap waktu. Dengan struktur seperti ini, LSTM dapat menjaga informasi penting dari data sekuensial yang panjang tanpa mengalami masalah *vanishing gradient* yang sering dialami oleh RNN tradisional. Dengan menggunakan struktur ini, LSTM dapat mengatasi masalah *vanishing gradient* yang sering terjadi pada RNN tradisional, terutama pada data sekuensial yang panjang.

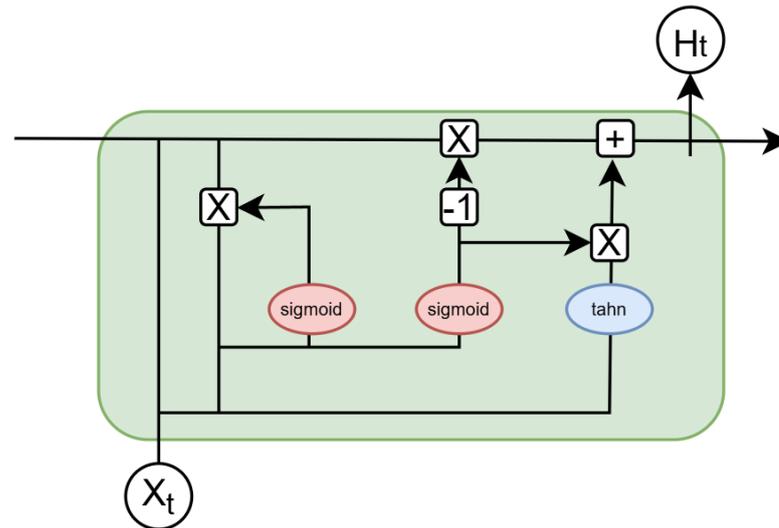


Gambar 2. Diagram LSTM

Dalam penelitian ini, LSTM digunakan untuk mempelajari pola temporal dari data yang telah melalui proses *preprocessing*. Desain model LSTM dalam penelitian ini mencakup lima layer LSTM, lima layer dropout, dan satu layer dense. Setelah setiap layer LSTM, diterapkan layer dropout untuk mencegah *overfitting* dengan mengabaikan beberapa unit secara acak selama pelatihan. Layer dense berfungsi untuk menghasilkan output berdasarkan pola yang telah dipelajari oleh model. Model ini dikonfigurasi dengan parameter seperti *dropout*, *learning rate*, *timestep*, *batch size*, dan *epoch* untuk meningkatkan akurasi dan generalisasi model terhadap data baru.

3.4 Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) adalah model yang diperkenalkan oleh Cho dkk pada tahun 2014 sebagai solusi terhadap permasalahan *vanishing gradient* yang sering terjadi pada *Recurrent Neural Network* (RNN). Fenomena *vanishing gradient* muncul ketika nilai gradien mengecil seiring waktu, sehingga model kesulitan untuk belajar dari data dengan dependensi jangka panjang. Pada Gambar 3 GRU memperbaiki hal ini dengan memperkenalkan dua mekanisme utama, yaitu *Update Gate* dan *Reset Gate*. *Update Gate* mengontrol informasi lama yang tetap relevan untuk langkah waktu selanjutnya, sementara *Reset Gate* menentukan sejauh mana informasi masa lalu harus dilupakan. Dalam mekanisme GRU, masukan (X_t) bersama dengan memori sebelumnya (H_{t-1}) diproses melalui kedua gate ini, di mana *Reset Gate* (fungsi sigmoid) mengontrol informasi lama yang dihapus dan *Update Gate* (fungsi sigmoid) mengatur kombinasi memori lama dan memori baru. Fungsi tanh kemudian digunakan untuk menghasilkan kandidat memori baru berdasarkan kombinasi masukan dan informasi yang telah difilter. Informasi akhir (H_t) dihasilkan melalui kombinasi linier memori lama dan memori baru, yang memberikan GRU kemampuan untuk menangani pola dependensi jangka panjang secara efisien.



Gambar 3. Diagram GRU

Dalam penelitian ini, arsitektur GRU dirancang dengan lima lapisan GRU, lima lapisan dropout, dan satu lapisan dense. Setiap lapisan GRU bertugas mempelajari pola temporal dari data, sedangkan dropout berfungsi untuk mencegah *overfitting* dengan mengabaikan beberapa unit secara acak selama pelatihan. Lapisan dense digunakan sebagai *output layer* yang menghasilkan prediksi akhir. Proses pelatihan melibatkan parameter-parameter seperti *dropout rate*, *learning rate*, *timestep*, *batch size*, dan *epoch* untuk memastikan generalisasi yang baik pada data dan akurasi prediksi yang tinggi

3.5 Konfigurasi

Penelitian ini memfokuskan pada evaluasi performa dua jenis model *Recurrent Neural Network* (RNN), yaitu GRU dan LSTM, dalam memprediksi harga dua aset kripto (BTC dan ETH) yang dikenal memiliki pola time series non-linear dan sangat volatil. Setiap model dibangun dengan dua lapisan utama, di mana lapisan pertama memiliki 150 unit dengan pengaturan *return_sequences=True* sehingga memungkinkan keluaran sekuensial untuk lapisan selanjutnya, sementara lapisan kedua memiliki 75 unit dengan *return_sequences=False* guna menghasilkan representasi akhir sebelum diteruskan ke lapisan Dense sebagai pemetaan ke output prediksi. Untuk mencegah *overfitting*, model diberi Dropout sebesar 0.2 sebelum lapisan Dense. Penelitian ini juga menerapkan empat kombinasi *hyperparameter* utama pada kedua jenis model dua nilai *learning rate* (0.0001 dan 0.001) serta dua nilai *batch size* (64 dan 100). Timestep dipertahankan pada 120, dimaksudkan untuk menangkap pola historis jangka pendek hingga menengah yang relevan dengan fluktuasi harga harian kripto. Secara keseluruhan, setiap kombinasi *hyperparameter* (4 total) dieksplorasi pada dua jenis arsitektur (GRU dan LSTM), sehingga total diperoleh 8 eksperimen per dataset. Dengan mempertimbangkan adanya dua dataset (BTC dan ETH), jumlah keseluruhan eksperimen adalah 16. Pelatihan model dibatasi hingga 100 epoch dan dilengkapi dengan mekanisme *early stopping* (*patience=10*) untuk memutus proses pelatihan apabila loss validasi tidak membaik selama 10 epoch berturut-turut. Selain itu, *ModelCheckpoint* digunakan untuk menyimpan bobot terbaik model berdasarkan metrik evaluasi (*val_loss*), sehingga model terbaik tetap terjaga meskipun pada epoch-epoch selanjutnya terjadi potensi *overfitting*.

Dalam hal optimasi, penggunaan optimizer Adam (Adaptive Moment Estimation) dipilih karena kemampuannya menyesuaikan laju pembelajaran secara adaptif pada tiap parameter dan memanfaatkan momentum untuk mempercepat konvergensi. Secara default, Adam memanfaatkan dua parameter utama, yaitu $\beta_1 = 0.9$ dan $\beta_2 = 0.999$ untuk memperhitungkan momen pertama dan kedua dari gradien. Pada rentang tugas prediksi yang kompleks seperti harga kripto, *learning rate* 0.001 umumnya memberi konvergensi lebih cepat dan stabil, sementara *learning rate* 0.0001 disiapkan untuk meredam potensi *overshooting* ketika menghadapi volatilitas yang lebih ekstrem. Selanjutnya, pemilihan *batch size* juga dilakukan secara hati-hati: nilai 64 memungkinkan pembaruan bobot berlangsung lebih sering, namun fluktuasi gradiennya relatif lebih tinggi; sebaliknya, *batch size* 100 memberikan estimasi gradien yang lebih stabil walaupun pembaruan bobot terjadi lebih jarang.

Dengan menerapkan Dropout 0.2 pada setiap forward pass, model berusaha menghindari ketergantungan berlebihan pada neuron tertentu, sehingga mendorong kemampuan generalisasi yang lebih baik. Proses pelatihan pun dijaga agar tidak berlanjut ketika tidak ada peningkatan performa validasi dalam rentang 10 epoch, berkat penerapan *early stopping* di saat bersamaan, bobot terbaik tetap tersimpan berkat *ModelCheckpoint*. Keseluruhan metode ini disusun untuk memastikan model mampu menyeimbangkan performa dan stabilitas pelatihan, sehingga menghasilkan prediksi yang akurat pada pola harga BTC dan ETH yang sangat dinamis.

3.6 Evaluasi

Pada tahap ini, peneliti bertujuan untuk mengevaluasi kinerja model prediksi harga *cryptocurrency* yang telah dikembangkan dalam penelitian ini. Penilaian dilakukan dengan menggunakan beberapa metrik evaluasi yang umum digunakan dalam analisis data prediktif, yaitu *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *R-squared* (R^2). Ketiga metrik ini dipilih karena mampu memberikan gambaran yang komprehensif mengenai akurasi dan kemampuan model dalam memprediksi harga *cryptocurrency*, khususnya Bitcoin (BTC) dan Ethereum (ETH). Penilaian kinerja model ini difokuskan pada dua jenis model pembelajaran mendalam, yaitu *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Dengan mengevaluasi hasil prediksi menggunakan metrik-metrik tersebut, penelitian ini diharapkan dapat menentukan model mana yang paling efektif dan akurat dalam meramalkan harga *cryptocurrency*.

1. *Root Mean Square Error* (RMSE)

RMSE digunakan untuk mengukur kesalahan dalam prediksi harga kripto antara nilai yang diprediksi oleh model dan nilai aktual harga kripto. RMSE dihitung dengan cara menghitung selisih kuadrat antara harga yang diprediksi dan harga aktual, kemudian mengakarkannya. RMSE memberikan gambaran tentang seberapa besar kesalahan yang dihasilkan oleh model dalam prediksi harga kripto.

Rumus untuk menghitung RMSE dapat dilihat pada Persamaan (1):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{prediksi,i} - y_{aktual,i})^2} \quad (1)$$

Semakin kecil nilai RMSE, semakin akurat model dalam memprediksi harga kripto. RMSE akan digunakan untuk membandingkan seberapa baik model LSTM dan GRU dalam meramalkan harga kripto. Model dengan nilai RMSE lebih kecil menunjukkan bahwa model tersebut lebih akurat dalam memprediksi harga.

2. *Mean Absolute Percentage Error* (MAPE)

MAPE digunakan untuk mengevaluasi model prediksi harga kripto dengan cara menghitung kesalahan relatif antara harga yang diprediksi dan harga aktual, yang dinyatakan dalam persentase. MAPE mengukur seberapa besar kesalahan relatif dalam prediksi terhadap harga aktual dalam bentuk persentase. Rumus menghitung MAPE dapat disajikan pada Persamaan (2):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_{aktual,i} - y_{prediksi,i}|}{y_{aktual,i}} \times 100\% \quad (2)$$

Semakin kecil nilai MAPE, semakin baik performa model. MAPE digunakan untuk membandingkan kemampuan kedua model (LSTM dan GRU) dalam meramalkan harga kripto, di mana nilai MAPE yang lebih rendah menandakan prediksi yang lebih tepat. Meskipun MAPE berguna, perlu diingat bahwa nilai-nilai yang sangat rendah (mendekati nol) dalam harga kripto dapat menyebabkan MAPE menjadi lebih tinggi, sehingga perlu diinterpretasikan dengan hati-hati.

3. *R-squared* (R^2)

R-squared mengukur sejauh mana variasi dalam harga kripto dapat dijelaskan oleh model prediksi, baik LSTM maupun GRU. Nilai R^2 berkisar antara 0 dan 1, dengan nilai yang lebih tinggi menunjukkan bahwa model dapat menjelaskan sebagian besar variasi dalam data harga kripto. R^2 memberikan gambaran tentang seberapa baik model mencocokkan harga kripto aktual dengan harga yang diprediksi. Nilai R^2 dihitung berdasarkan formula yang tercantum dalam Persamaan (3):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{aktual,i} - y_{prediksi,i})^2}{\sum_{i=1}^n (y_{aktual,i} - \bar{y})^2} \quad (3)$$

Semakin tinggi nilai R^2 , semakin baik model dalam menjelaskan variasi harga kripto yang sebenarnya. Nilai R^2 yang tinggi mengindikasikan bahwa model LSTM atau GRU mampu

memprediksi harga kripto dengan akurat, sedangkan nilai yang rendah menunjukkan model yang kurang efektif.

Perbandingan antara LSTM dan GRU

RMSE dan MAPE akan digunakan untuk membandingkan kesalahan prediksi antara kedua model (LSTM dan GRU). Model yang menghasilkan nilai RMSE dan MAPE lebih rendah dianggap lebih akurat dalam memprediksi harga kripto. R^2 akan digunakan untuk mengukur seberapa baik kedua model dapat menjelaskan variasi harga kripto. Model dengan nilai R^2 lebih tinggi akan dianggap lebih mampu menjelaskan data harga kripto. Dengan menggunakan ketiga metrik ini, evaluasi akan memberikan gambaran yang komprehensif mengenai kelebihan dan kekurangan model LSTM dan GRU dalam memprediksi harga kripto, yang pada akhirnya membantu memilih model terbaik untuk prediksi harga kripto.

4 Hasil dan Pembahasan

Pada bagian ini, peneliti memaparkan hasil pengujian model prediksi harga cryptocurrency yang telah dikembangkan. Pengujian dilakukan untuk mengevaluasi performa metode *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dalam memprediksi harga *close* cryptocurrency, khususnya Bitcoin (BTC) dan Ethereum (ETH). Evaluasi dilakukan dengan menggunakan tiga metrik utama, yaitu *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), dan *R-squared* (R^2).

Pengujian dilakukan dengan berbagai kombinasi parameter *learning rate* dan *batch size* untuk mengidentifikasi konfigurasi optimal dari masing-masing metode. Hasil evaluasi ini bertujuan untuk memberikan pemahaman mendalam tentang keunggulan dan kelemahan kedua model dalam memprediksi harga cryptocurrency, baik dari segi akurasi, stabilitas, maupun efisiensi.

4.1 Hasil Pengujian

Berikut adalah hasil pengujian evaluasi menggunakan metrik evaluasi MAPE dan RMSE pada metode LSTM dan GRU dalam memprediksi harga *close* Cryptocurrency

Tabel 2. Hasil pengujian bitcoin

Learning Rate	Batch Size	GRU MAPE (%)	GRU RMSE	GRU R^2	LSTM MAPE (%)	LSTM RMSE	LSTM R^2
0.0001	64	0.51%	304.42	0.9983	0.50%	435.60	0.9981
	100	0.38%	342.91	0.9988	0.82%	688.35	0.9952
0.001	64	0.50%	401.91	0.9984	0.46%	406.5	0.9983
	100	0.72%	558.09	0.9968	0.84%	687.24	0.9952

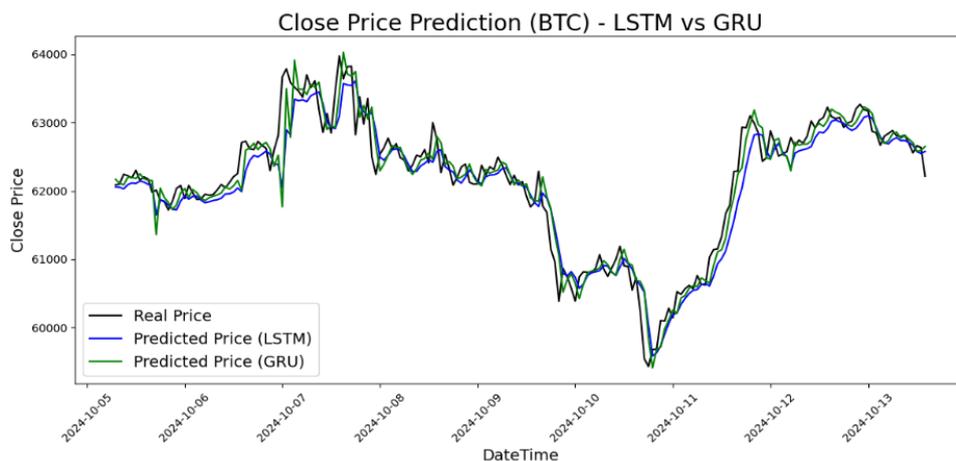
Berdasarkan Tabel 2, hasil pengujian untuk prediksi harga Bitcoin menunjukkan bahwa baik GRU maupun LSTM memiliki performa yang cukup kompetitif. Namun, GRU secara konsisten mencatat nilai MAPE dan RMSE yang lebih rendah pada sebagian besar kombinasi parameter. Sebagai contoh, pada konfigurasi *learning rate* 0.0001 dengan *batch size* 64, GRU memiliki nilai MAPE sebesar 0.51% dan RMSE 304.42, yang menunjukkan akurasi absolut lebih baik dibandingkan LSTM, meskipun nilai MAPE LSTM serupa, yaitu 0.50%. Dengan kombinasi *learning rate* yang sama tetapi *batch size* lebih besar (100), GRU mempertahankan keunggulannya dengan nilai MAPE terendah sebesar 0.38% dibandingkan LSTM yang mencapai 0.82%. Selain itu, nilai RMSE GRU (342.91) juga jauh lebih kecil dibandingkan RMSE LSTM (688.35). Hal ini menegaskan bahwa GRU lebih unggul dalam memprediksi harga Bitcoin pada kondisi *batch size* besar, sementara LSTM cenderung memberikan kesalahan prediksi absolut lebih besar. Namun pada konfigurasi *learning rate* 0.001 dengan *batch size* 64, LSTM menunjukkan performa yang sedikit lebih baik pada nilai MAPE sebesar 0.46%, lebih rendah dibandingkan GRU dengan 0.50%. Namun, GRU tetap menghasilkan nilai RMSE lebih kecil (401.91) dibandingkan LSTM (406.50), yang menunjukkan bahwa GRU memiliki keunggulan dalam meminimalkan kesalahan absolut. Pada konfigurasi *batch size* 100 dengan *learning rate* 0.001, GRU kembali menunjukkan performa yang lebih stabil dengan nilai MAPE 0.72% dan RMSE 558.09, lebih rendah dibandingkan LSTM yang mencatatkan MAPE 0.84% dan RMSE 687.24. Nilai R^2 pada kedua metode tetap tinggi di atas 0.995, menunjukkan kemampuan keduanya dalam menjelaskan variasi data kompleks.

Tabel 3. Hasil pengujian ETH

Learning Rate	Batch Size	GRU MAPE (%)	GRU RMSE	GRU R ²	LSTM MAPE (%)	LSTM RMSE	LSTM R ²
0.0001	64	0.51%	23.25	0.9979	0.89%	40.75	0.9934
	100	0.55%	25.74	0.9974	0.77%	34.52	0.9953
0.001	64	0.50%	22.53	0.998	0.62%	28.77	0.9967
	100	0.44%	20.55	0.9983	1.64%	58.54	0.9865

Pada Tabel 3 yang memuat hasil pengujian untuk harga ETH, memperkuat keunggulan GRU dalam meminimalkan error prediksi dibandingkan LSTM. Pada *learning rate* 0.0001 dengan *batch size* 64, GRU memiliki nilai MAPE sebesar 0.51% dan RMSE 23.25, yang jauh lebih rendah dibandingkan LSTM dengan nilai MAPE 0.89% dan RMSE 40.75. Hal ini menunjukkan bahwa GRU mampu memberikan prediksi yang lebih akurat dengan kesalahan relatif dan absolut yang lebih kecil pada data ETH. Pada konfigurasi batch size 100 dengan learning rate yang sama, GRU tetap unggul dengan nilai MAPE 0.55% dibandingkan LSTM (0.77%), sementara nilai RMSE GRU (25.74) juga lebih kecil dibandingkan RMSE LSTM (34.52).

Menariknya, pada *learning rate* 0.001 dengan batch size 64, GRU menghasilkan nilai MAPE 0.50% dan RMSE 22.53, yang lebih baik dibandingkan LSTM dengan MAPE 0.62% dan RMSE 28.77. Namun, pada batch size 100, performa LSTM terlihat lebih fluktuatif dengan nilai MAPE sebesar 1.64%, jauh lebih tinggi dibandingkan GRU yang memiliki nilai MAPE 0.44%. RMSE LSTM juga jauh lebih besar (58.54) dibandingkan GRU (20.55), yang menunjukkan bahwa GRU mampu memberikan prediksi yang lebih stabil dan akurat pada kondisi batch size besar. Secara umum, hasil pengujian menunjukkan bahwa GRU memiliki nilai MAPE dan RMSE yang lebih konsisten dibandingkan LSTM. Hal ini kemungkinan disebabkan oleh arsitektur GRU yang lebih sederhana, yang memungkinkan model lebih efisien dalam menangkap pola temporal data, terutama pada kombinasi parameter yang tidak terlalu kompleks. Sebaliknya, arsitektur LSTM yang lebih kompleks cenderung lebih sensitif terhadap perubahan parameter, sehingga menghasilkan nilai MAPE dan



RMSE yang lebih fluktuatif.

Gambar 4 Hasil prediksi BTC

Pada Gambar 4, terlihat bahwa hasil prediksi model GRU dan LSTM dibandingkan dengan harga asli Bitcoin menunjukkan bahwa model GRU lebih akurat dalam mengikuti pola harga asli (ditunjukkan oleh garis hitam) dibandingkan model LSTM. Garis prediksi GRU (hijau) cenderung lebih dekat dengan garis harga asli, terutama pada periode-periode dengan fluktuasi harga yang tajam. Sebagai contoh, pada periode 2024-10-07 hingga 2024-10-09, GRU mampu memprediksi pola penurunan dan kenaikan harga dengan lebih baik dibandingkan LSTM, yang menunjukkan deviasi lebih besar. Hal ini juga terlihat pada periode 2024-10-11 hingga 2024-10-12, di mana GRU lebih stabil dalam memprediksi kenaikan harga, sementara LSTM menunjukkan deviasi yang lebih signifikan dari harga asli. Dengan kombinasi parameter terbaik GRU (*learning rate* 0.0001, *batch size* 100) menghasilkan nilai MAPE 0.38% dan RMSE 342.91, lebih unggul dibandingkan LSTM

<http://sistemasi.ftik.unisi.ac.id>

(learning rate 0.001, batch size 64) dengan MAPE 0.46% dan RMSE 406.50. Grafik ini memperkuat bahwa model GRU lebih unggul dalam menangkap pola jangka panjang dan fluktuasi harga Bitcoin yang tinggi.



Gambar 5 Hasil prediksi ETH

Pada Gambar 5, hasil prediksi harga ETH menggunakan model GRU dan LSTM menunjukkan pola yang mirip dengan Bitcoin. Garis prediksi GRU (hijau) lebih mendekati garis harga asli (hitam) dibandingkan garis prediksi LSTM (biru). Pada periode 2024-10-21 hingga 2024-10-23, GRU menunjukkan akurasi prediksi yang lebih tinggi dalam mengikuti pola penurunan harga ETH. Sementara itu, LSTM menunjukkan fluktuasi yang lebih besar dan deviasi yang lebih signifikan dari harga asli pada periode yang sama. Demikian pula, pada periode 2024-10-26 hingga 2024-10-28, prediksi GRU lebih konsisten dalam mengikuti pola kenaikan harga ETH, sedangkan prediksi LSTM terlihat lebih tidak stabil. Dengan parameter GRU (learning rate 0.001, batch size 64) menghasilkan nilai MAPE 0.50% dan RMSE 22.53, lebih baik dibandingkan LSTM (learning rate 0.001, batch size 64) dengan MAPE 0.62% dan RMSE 28.77. Grafik ini menguatkan bahwa GRU lebih efektif dalam menangkap pola perubahan harga ETH yang lebih dinamis.

Selanjutnya ditampilkan hasil prediksi dengan metode LSTM dan GRU selama 10 jam ke depan. Berdasarkan hasil prediksi, dapat dilihat bahwa hasil prediksi menggunakan metode LSTM memberikan nilai prediksi harga yang lebih tinggi dibandingkan dengan hasil prediksi menggunakan metode GRU. Perbandingan hasil prediksi dengan metode LSTM dan GRU dapat dilihat pada Tabel 4 dan Tabel 5.

Tabel 4. Hasil prediksi harga Close BTC metode LSTM dan GRU.

Hour	BTC GRU (\$)	BTC LSTM (\$)
Hour 1	4991.19	5283.24
Hour 2	4910.23	5539.33
Hour 3	4990.5	5341.54
Hour 4	5163.48	5607.95
Hour 5	5082.77	5626.81
Hour 6	5199.27	5352.99
Hour 7	5170.76	5300.27
Hour 8	5138.01	5185.19
Hour 9	5010.82	5083.98
Hour 10	4977.49	4897.99

Tabel 4 menampilkan hasil prediksi untuk harga BTC menggunakan metode LSTM dan GRU. Dari tabel ini, terlihat bahwa metode LSTM memberikan hasil prediksi yang lebih bervariasi

dengan nilai yang cenderung lebih tinggi dibandingkan metode GRU, terutama pada jam ke-2 dan ke-4. Namun, prediksi GRU terlihat lebih stabil dengan perubahan yang lebih teratur pada setiap jam. Hal ini menunjukkan bahwa GRU lebih unggul dalam memberikan prediksi yang konsisten untuk pola-pola yang sederhana.

Tabel 5. Hasil prediksi harga close ETH metode LSTM dan GRU.

Hour	ETH GRU (\$)	ETH LSTM (\$)
Hour 1	5261.18	4919.2
Hour 2	5498.41	4727.4
Hour 3	5453	4665.63
Hour 4	5662.81	4891.36
Hour 5	5592.22	5060.82
Hour 6	5814.08	5293.15
Hour 7	6036.82	5270.48
Hour 8	6213.4	5058.31
Hour 9	6085.44	5180.83
Hour 10	5822.4	5375.13

Tabel 5 menampilkan hasil prediksi untuk harga ETH menggunakan metode LSTM dan GRU. Serupa dengan hasil pada prediksi BTC, metode LSTM menunjukkan sensitivitas yang lebih tinggi terhadap fluktuasi harga, seperti yang terlihat pada jam ke-3 dan ke-4, di mana prediksi harga lebih tinggi dibandingkan metode GRU. Sebaliknya, metode GRU memberikan nilai prediksi yang lebih mendekati pola data historis dengan fluktuasi yang lebih kecil.

Berdasarkan hasil prediksi dari kedua tabel, metode GRU cenderung memberikan nilai prediksi yang lebih stabil dalam rentang waktu yang diamati, menandakan keandalannya dalam memetakan pola sederhana atau perubahan yang relatif teratur pada data. Di sisi lain, LSTM menunjukkan kemampuan untuk mempelajari nuansa yang lebih kompleks, tercermin dari prediksi yang lebih tinggi pada jam-jam tertentu, sehingga dapat dikatakan lebih sensitif terhadap perubahan tren atau pola yang fluktuatif. Dari sudut pandang arsitektur, GRU (Gated Recurrent Unit) sering dianggap unggul dalam beberapa skenario karena hanya menggunakan dua *gate* (update dan reset), menjadikannya lebih ringan, lebih cepat dalam pelatihan, serta efisien secara komputasi—terutama saat diaplikasikan pada data dengan frekuensi pembaruan tinggi seperti harga kripto. Keunggulan ini juga krusial dalam proses *backtesting* pada strategi *trading* real-time, karena kecepatan eksekusi prediksi dapat memengaruhi profitabilitas. Meski demikian, pemilihan GRU atau LSTM pada akhirnya sangat tergantung pada kebutuhan spesifik dan karakteristik data yang dihadapi: GRU unggul untuk stabilitas dan efisiensi, sedangkan LSTM memungkinkan deteksi dinamika harga yang lebih rumit. Dari sisi aplikasi praktis, stabilitas dan efisiensi prediksi kedua model ini dapat diintegrasikan dalam berbagai skenario, mulai dari *Algorithmic Trading* (membuat *trading bot* yang mengeksekusi transaksi otomatis), perencanaan portofolio investasi (penyesuaian alokasi aset yang volatil), hingga analisis risiko (penentuan *stop loss*, *take profit*, serta *entry point* yang optimal). Dengan demikian, baik GRU maupun LSTM dapat dimanfaatkan secara komplementer untuk memaksimalkan peluang

5 Kesimpulan

Hasil penelitian ini menunjukkan bahwa *Gated Recurrent Unit* (GRU) secara konsisten lebih unggul dibandingkan *Long Short-Term Memory* (LSTM) dalam memprediksi harga cryptocurrency Bitcoin (BTC) dan Ethereum (ETH). GRU mencatat nilai *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE) yang lebih rendah pada sebagian besar kombinasi hyperparameter, menandakan prediksi yang lebih akurat dan stabil. Sebagai contoh, pada prediksi BTC, GRU mencapai nilai MAPE terendah sebesar 0.38%, sedangkan nilai terbaik LSTM adalah 0.46%. Untuk ETH, GRU mencatat nilai MAPE serendah 0.44%, jauh lebih baik dibandingkan LSTM yang mencapai 1.64% pada konfigurasi tertentu. GRU juga menunjukkan pola prediksi yang lebih

stabil dan mendekati harga asli dibandingkan LSTM, yang lebih sensitif terhadap perubahan hyperparameter sehingga menghasilkan fluktuasi yang lebih besar dalam prediksi. Namun, LSTM memiliki keunggulan dalam menangkap pola data yang lebih kompleks berkat arsitekturnya yang lebih mendalam, meskipun sering kali diiringi dengan nilai error yang lebih tinggi dibandingkan GRU. Dalam beberapa kasus, LSTM mencatat prediksi harga yang lebih responsif terhadap perubahan tren, namun hal ini menyebabkan deviasi yang lebih signifikan dari data aktual. Secara keseluruhan, GRU lebih direkomendasikan untuk tugas prediksi harga *close cryptocurrency* karena arsitekturnya yang sederhana, stabilitas prediksi yang tinggi, dan performa yang lebih konsisten. Meskipun demikian, LSTM dapat menjadi pilihan untuk data dengan pola yang lebih kompleks.

Referensi

- [1] F. Faidah, "Pengaruh Literasi Keuangan dan Faktor Demografi terhadap Minat Investasi Mahasiswa," *JABE (Journal Appl. Bus. Econ.*, vol. 5, no. 3, p. 251, 2019, doi: 10.30998/jabe.v5i3.3484.
- [2] S. Alonso-Monsalve, A. L. Suárez-Cetrulo, A. Cervantes, and D. Quintana, "Convolution on Neural Networks for High-Frequency Trend Prediction of Cryptocurrency Exchange Rates using Technical Indicators," *Expert Syst. Appl.*, vol. 149, p. 113250, 2020, doi: <https://doi.org/10.1016/j.eswa.2020.113250>.
- [3] M. . R. Rere, Hariyanto, and Rozi, "Studi Prediksi Harga Bitcoin menggunakan *Recurrent Neural Network*," *Semin. Nas. Teknol. Inf. dan Komun. STI&K*, vol. 6, no. 1, pp. 149–155, 2022.
- [4] M. W. P. Aldi, Jondri, and A. Aditsania, "Analisis dan Implementasi *Long Short Term Memory Neural Network* Untuk Prediksi Harga Bitcoin," *E-Proceeding Eng.*, vol. 5, no. 2, pp. 3548–3555, 2018.
- [5] I. Akil and I. Chaidir, "Prediksi Harga Saham Twitter dengan *Long Short-Term Memory Recurrent Neural Network*," *INTI Nusa Mandiri*, vol. 17, no. 1, pp. 1–7, 2022, doi: 10.33480/inti.v17i1.3277.
- [6] R. A. Pangaribuan, N. U. Rahmi, and U. P. Indonesia, "Risk and Return Investment Analysis on Bitcoin, Ethereum, Dogecoin, Litecoin, XRP and LQ45 Share after the Covid-19 Pandemic Analisis Risk dan Return Investasi pada Bitcoin, Ethereum, Dogecoin, Litecoin, XRP dan Saham Saham LQ45 setelah Pandemi Covid-19," *Manag. Stud. Entrep. J.*, vol. 4, no. 3, pp. 2930–2941, 2023, [Online]. Available: <http://journal.yrpiiku.com/index.php/msej>
- [7] J. Homepage, C. Alkahfi, A. Kurnia, and A. Saefuddin, "MALCOM: Indonesian Journal of Machine Learning and Computer Science Performance Comparison of RNN-based Models in Forecasting Indonesian Economic and Financial Data Perbandingan Kinerja Model berbasis RNN pada Peramalan Data Ekonomi dan Keuangan Indonesia," vol. 4, no. October, pp. 1235–1243, 2024.
- [8] K. Kusnawi, M. A. F. Eka Putra, and J. Ipmawati, "Price Prediction of basic Material using ARIMA Forecasting Method Through Open Data Sumedang District," *Sistemasi*, vol. 12, no. 2, p. 293, 2023, doi: 10.32520/stmsi.v12i2.2282.
- [9] K. Ramani, M. Jahnavi, P. Reddy, P. V. Chakravarthi, and P. Meghanath, *Prediction of Bitcoin Price through LSTM, ARIMA, XGBoost, Prophet and Sentiment Analysis on Dynamic Streaming Data*. 2023. doi: 10.1109/ICACCS57279.2023.10113014.
- [10] S. Park and J.-S. Yang, "Interpretable Deep Learning LSTM Model for Intelligent Economic Decision-Making," *Knowledge-based Syst.*, vol. 248, p. 108907, 2022, doi: <https://doi.org/10.1016/j.knosys.2022.108907>.
- [11] M. A. D. Suyudi, E. C. Djamal, and A. Maspupah, "Prediksi Harga Saham menggunakan Metode *Recurrent Neural Network*," *Semin. Nas. Apl. Teknol. Inf.*, pp. 1907–5022, 2019.
- [12] S. Samsudin, A. M. Harahap, and S. Fitrie, "Implementasi Gated Recurrent Unit (Gru) untuk Prediksi Harga Saham Bank Konvensional di Indonesia," *JISTech (Journal Islam. Sci. Technol.*, vol. 6, no. 2, pp. 42–49, 2021, doi: 10.30829/jistech.v6i2.11058.
- [13] W. Hastomo, A. S. B. Karno, N. Kalbuana, E. Nisfiani, and L. ETP, "Optimasi Deep Learning untuk Prediksi Saham di," ... (*Jurnal Edukasi dan ...*, vol. 7, no. 2, pp. 133–140, 2021, [Online]. Available: <https://jurnal.untan.ac.id/index.php/jepin/article/view/47411>
- [14] M.-L. Shen, C.-F. Lee, H.-H. Liu, P.-Y. Chang, and C.-H. Yang, "Effective Multinational

- Trade Forecasting using Lstm Recurrent Neural Network,” Expert Syst. Appl.*, vol. 182, p. 115199, 2021, doi: <https://doi.org/10.1016/j.eswa.2021.115199>.
- [15] V. Riandaru Prasetyo *et al.*, “Prediksi Harga Emas berdasarkan Data gold.org menggunakan Metode Long Short Term Memory Gold Price Prediction based on Gold.org Data using the Long Short Term Memory Method,” vol. 11, no. September, pp. 623–629, 2022, [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [16] J. Cao, Z. Li, and J. Li, “Financial Time Series Forecasting Model Based on CEEMDAN and LSTM,” *Phys. A Stat. Mech. its Appl.*, vol. 519, pp. 127–139, 2019, doi: <https://doi.org/10.1016/j.physa.2018.11.061>.
- [17] K. Sofi, A. S. Sunge, S. R. Riady, and A. Z. 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.
- [18] M. F. Rizkilloh and S. Widiyanesti, “Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM),” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 6, no. 1, pp. 25–31, 2022, doi: 10.29207/resti.v6i1.3630.
- [19] W. Hastomo, Aminudin, and A. S. B. Karno, “Kemampuan Long Short Term Memory Machine Learning dalam Proyeksi Saham Bank BRI Tbk,” *Univ. Gunadarma Jl. Margonda Raya*, vol. 4, no. 1, p. 16424, 2020.
- [20] M. R. Pahlevi, “Prediksi Harga Forex menggunakan Algoritma Long Short-Term Memory,” *Jnanaloka*, pp. 69–76, 2023, doi: 10.36802/jnanaloka.2022.v3-no2-69-76.
- [21] N. G. Ramadhan, N. A. F. Tanjung, and F. D. Adhinata, “Implementation of LSTM-RNN for Bitcoin Prediction,” *Ind. J. Comput.*, vol. 6, no. 3, pp. 17–24, 2021, doi: 10.34818/indojc.2021.6.3.592.
- [22] N. W. Meri Aryati, I. K. A. G. Wiguna, N. W. S. Putri, I. K. K. Widiartha, and N. L. W. S. R. Ginantra, “Komparasi Metode LSTM dan GRU dalam memprediksi Harga Saham,” *J. Media Inform. Budidarma*, vol. 8, no. 2, p. 1131, 2024, doi: 10.30865/mib.v8i2.7342.
- [23] M. Amos, “Perbandingan Algoritma Linear Regression, Neural Network, Deep Learning, dan K-Nearest Neighbor (K-NN) untuk Prediksi Harga Bitcoin,” *JSI J. Sist. Inf.*, vol. 14, no. 1, pp. 2450–2464, 2022, doi: 10.18495/jsi.v14i1.16561.