

PREDIKSI HARGA CRYPTOCURRENCY XLM MENGGUNAKAN METODE DEEP LEARNING LSTM DAN GRU

Sadam Muhammad Natzir¹, Harumawan Jatiprasetya²

^{1,2}Program Studi Magister Informatika, Universitas Amikom Yogyakarta

Jl. Ring Road Utara, Sleman - Daerah Istimewa Yogyakarta, Indonesia

Email: ¹sadamnatzir@students.amikom.ac.id, ²harumawan@students.amikom.ac.id

ABSTRAK

Volatilitas pasar yang tinggi serta potensi keuntungan besar dari cryptocurrency menjadikan prediksi harga sebagai topik penelitian yang menarik. Penelitian ini bertujuan untuk memprediksi harga cryptocurrency Stellar (XLM) dengan menerapkan metode Deep Learning, yaitu Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU). Data yang digunakan mencakup harga harian XLM selama beberapa tahun terakhir, serta indikator teknikal dan aktivitas perdagangan. Model LSTM dan GRU dievaluasi berdasarkan akurasi dalam memprediksi harga XLM menggunakan metrik MAPE, RMSE, dan MSE. Hasil menunjukkan bahwa meskipun keduanya mampu menangkap pola tren jangka pendek, model GRU memberikan hasil yang lebih unggul. GRU mencatat MAPE sebesar 3.6164%, RMSE sebesar 0.0206, dan MSE sebesar 0.0004. Sementara itu, LSTM mencatat MAPE sebesar 4.5638%, RMSE sebesar 0.0244, dan MSE sebesar 0.0005. Temuan ini menunjukkan bahwa GRU lebih efektif dalam memodelkan kompleksitas dan non-linearitas data harga XLM dibandingkan LSTM. Dengan demikian, GRU dapat dipertimbangkan sebagai metode yang lebih unggul dalam prediksi harga cryptocurrency. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan model prediksi yang lebih akurat serta membantu pengambilan keputusan investasi yang lebih bijak.

Kata kunci: Cryptocurrency, Deep Learning, GRU, LSTM, Prediksi

ABSTRACT

The high market volatility and significant profit potential of cryptocurrencies have made price prediction a compelling area of research. This study aims to predict the price of Stellar (XLM), a widely recognized cryptocurrency, by applying deep learning methods, namely Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU). The dataset includes daily XLM prices over the past few years, along with technical indicators and trading activity data. The LSTM and GRU models are evaluated based on their accuracy in predicting XLM prices using metrics such as MAPE, RMSE, and MSE. The results show that while both models are capable of capturing short-term trends, the GRU model outperforms LSTM. GRU achieved a MAPE of 3.6164%, RMSE of 0.0206, and MSE of 0.0004, whereas LSTM recorded a MAPE of 4.5638%, RMSE of 0.0244, and MSE of 0.0005. These findings indicate that GRU is more effective in modeling the complexity and non-linearity of XLM price data compared to LSTM. Therefore, GRU can be considered a superior approach for cryptocurrency price prediction. This study is expected to contribute to the development of more accurate forecasting models and to support better investment decision-making.

Keywords: Cryptocurrency, Deep Learning, GRU, LSTM, Predicting

1. PENDAHULUAN

Mata uang digital merupakan bentuk aset yang dikembangkan berbasis teknologi blockchain. Inovasi ini pertama kali muncul pada tahun 2009 melalui peluncuran Bitcoin sebagai mata uang kripto perdana [1]. Seiring berkembangnya era ekonomi digital serta pemanfaatan teknologi blockchain yang semakin meluas, kehadiran mata uang kripto dapat dipandang sebagai salah satu fondasi penting dalam kemajuan inovasi teknologi finansial (FinTech) di masa mendatang [2]. Dalam beberapa tahun terakhir, mata uang kripto telah menjadi salah satu kemajuan terbesar dalam teknologi digital dan keuangan [3]. Jumlah mata uang kripto telah meningkat secara signifikan dalam beberapa tahun terakhir, sehingga memahami dan memprediksi perubahan tren menjadi sangat penting, karena perubahan tersebut dapat menghasilkan keuntungan atau kerugian bagi setiap mata uang kripto [4].

Struktur jaringan berbasis volatilitas mencerminkan emosi investor, seperti ketakutan dan keserakahan, sehingga dapat digunakan untuk mengidentifikasi perubahan yang berdampak pada pasar mata uang kripto [5]. Meskipun pergerakan kripto terjadi secara sering dan berpotensi memengaruhi pasar mata uang kripto, beberapa tantangan empiris menyebabkan dampak kausalnya terhadap pasar masih belum diketahui [6]. Prediksi



menjadi hal yang krusial untuk investasi di masa depan. Dalam beberapa studi, model hibrida seperti LSTM-GRU telah digunakan dan berhasil memprediksi pergerakan harga Ethereum dan Solana serta melampaui semua model acuan [7]. Namun, dalam penelitian ini dipilih pendekatan dasar menggunakan model Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) secara terpisah. Pemilihan ini didasarkan pada dua pertimbangan utama. Pertama, untuk menganalisis dan membandingkan kinerja masing-masing model dalam konteks prediksi harga Stellar Lumens (XLM). Kedua, untuk menjaga kesederhanaan model dalam tahap awal penelitian guna memahami karakteristik data dan kontribusi masing-masing arsitektur secara independen, sebelum mempertimbangkan model hibrid yang lebih kompleks.

Oleh karena itu, prediksi harga mata uang kripto, termasuk Stellar, menjadi topik yang sangat menarik bagi investor, peneliti, dan pengembang [8]. Penelitian sebelumnya tentang Stellar telah mencakup karakteristik teknis, keamanan, pembayaran mikro, dan penilaian risiko. Namun, hanya sedikit studi yang berfokus pada peramalan harga Stellar XLM secara khusus. Maka dari itu, penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan mengembangkan dan mengevaluasi model peramalan seperti LSTM dan GRU untuk Stellar XLM.

Volatilitas yang tinggi pada mata uang kripto, termasuk Bitcoin, telah mendorong minat terhadap prediksi harga. Metode *machine learning*, khususnya Recurrent Neural Networks (RNN) seperti Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU), sering kali menunjukkan kinerja yang lebih baik dibandingkan model peramalan tradisional seperti ARIMA [7]. Meskipun ARIMA disebutkan dalam literatur, penelitian ini tidak menggunakannya secara eksplisit karena fokus utama diarahkan pada perbandingan dua model Deep Learning (LSTM dan GRU) yang telah terbukti unggul dalam menangani data deret waktu yang kompleks.

Faktor-faktor yang memengaruhi harga mata uang kripto mencakup tren pasar, biaya transaksi, dan sentimen di media sosial. Sebagai contoh, cuitan Elon Musk telah berdampak signifikan terhadap harga Dogecoin. Studi ini juga akan menelaah model prediksi harga untuk Ethereum, yang dikenal dengan kapabilitas *smart contract* yang kuat, dan Solana, yang terkenal karena kecepatan transaksinya yang tinggi.

Model *machine learning* merupakan salah satu pendekatan yang menjanjikan untuk memprediksi harga mata uang kripto. Model ini terutama mencakup Recurrent Neural Networks (RNN) dan versi yang lebih canggih dari RNN, yaitu Gated Recurrent Unit (GRU) [9]. GRU adalah jenis RNN yang dirancang untuk mengatasi masalah vanishing gradient yang sering terjadi pada RNN tradisional. Dengan mekanisme gerbang (*gating mechanism*) yang dimilikinya, jaringan ini mampu mempertahankan informasi penting dari input sebelumnya dalam jangka waktu yang lebih lama [10]. Oleh karena itu, GRU sangat cocok digunakan untuk tugas-tugas yang memerlukan prediksi deret waktu (time series), seperti prediksi harga mata uang kripto.

LSTM adalah jenis Artificial Neural Network (ANN) yang banyak digunakan di bidang *machine learning* dan kecerdasan buatan. LSTM sangat sesuai untuk data deret waktu karena kemampuannya dalam menyimpan informasi dalam jangka waktu yang lama [11]. Untuk memprediksi harga Stellar Lumens, penggunaan GRU menawarkan beberapa keunggulan [12]. Pertama, model ini mampu mengenali pola dan tren harga yang non-linear dan dinamis karena kemampuan GRU dalam menangani data deret waktu yang kompleks. Kedua, GRU memiliki efisiensi komputasi yang lebih baik dibandingkan dengan Long Short-Term Memory (LSTM), yang merupakan varian lain dari RNN. Oleh karena itu, GRU lebih cocok digunakan pada *dataset* yang besar dengan waktu pelatihan yang lebih singkat [13].

Koin Stellar adalah sebuah *platform* pembayaran berbasis blockchain yang membantu investor mentransfer aset antar mata uang kripto secara cepat dan efisien [14]. Namun demikian, koin Stellar Lumens (XLM), yang merupakan koin asli dari jaringan ini, jarang diprediksi harganya secara spesifik dalam publikasi ilmiah, meskipun koin Stellar telah mengalami perubahan harga yang signifikan, yang menunjukkan tingkat volatilitas yang tinggi di pasar mata uang kripto [14].

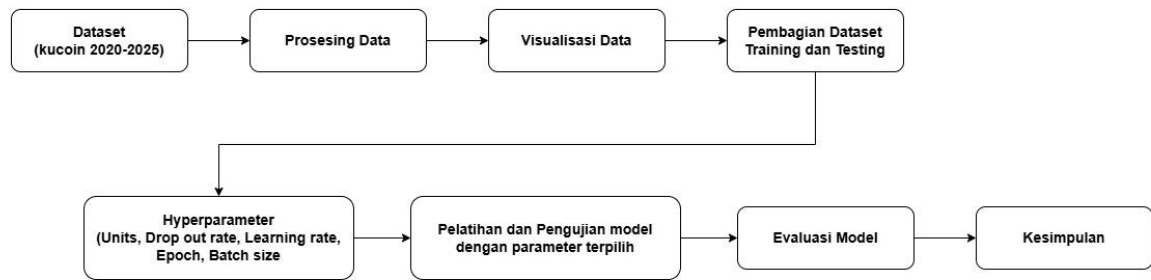
Penelitian ini bertujuan untuk memberikan kontribusi pada literatur yang berkembang mengenai mata uang kripto dengan menerapkan metode *machine learning* untuk prediksi harga, khususnya dengan fokus pada Stellar Lumens (XLM). Dengan mengembangkan model prediktif yang akurat menggunakan data harga historis dan fitur relevan lainnya, studi ini bermaksud menawarkan alat praktis yang dapat membantu investor dan pelaku pasar dalam membuat keputusan investasi yang lebih tepat dan strategis. Pada akhirnya, tujuan utama dari penelitian ini adalah menyediakan opsi yang mudah diakses dan efektif bagi investor untuk memprediksi harga koin Stellar sesuai dengan kebutuhan masing-masing.

Informasi berikut menjelaskan struktur bagian-bagian selanjutnya dari penelitian ini: Pendekatan penelitian disajikan pada Bagian 2 bersamaan dengan bagian data. Pada Bagian 3, digunakan metode LSTM dan GRU untuk memprediksi harga koin Stellar serta dilakukan evaluasi terhadap hasilnya. Kesimpulan dari penelitian ini disajikan pada Bagian 4.

2. METODE PENELITIAN

Untuk mencapai tujuan penelitian ini, peneliti memilih untuk fokus pada dua metode Deep Learning, yaitu LSTM (Long Short-Term Memory) dan GRU (Gated Recurrent Unit), dengan menggunakan data historis harga mata uang kripto XLM (Stellar) sebagai objek utama penelitian. Metodologi penelitian ini diterapkan dalam beberapa tahapan, meliputi pengumpulan data harga historis XLM, visualisasi pola historis untuk setiap mata uang, pembagian *dataset* menjadi data pelatihan dan pengujian, hyper-tuning model Deep Learning untuk menemukan parameter terbaik, pelatihan dan pengujian kedua model Deep Learning, serta perhitungan dan perbandingan

kinerja masing-masing metode berdasarkan metrik yang dipilih. Kerangka metodologi penelitian ini ditampilkan dalam Gambar 1.



Gambar 1. Metodologi pengolahan data dan pemilihan model

Deskripsi dan Praproses Data

Data yang digunakan untuk mata uang digital diambil dari Kucoin. Dataset harian untuk XLM mencakup periode dari 1 Januari 2020 hingga 23 Mei 2025, dengan total 1.971 observasi. Data ini mencakup informasi seperti tanggal, harga pembukaan, harga tertinggi, harga terendah, harga penutupan, dan volume transaksi harian. Dalam penelitian ini, peneliti menggunakan harga penutupan sebagai data deret waktu. Sebelum melakukan analisis lebih lanjut, data perlu diproses agar sesuai untuk dianalisis menggunakan alat deep learning. Pertama, dilakukan pengecekan untuk memastikan tidak ada nilai yang hilang dalam dataset. Selanjutnya, dilakukan normalisasi data untuk membantu algoritma Deep Learning (DL) agar konvergen lebih cepat [15]. Normalisasi menggunakan min-max scaler untuk mengubah nilai ke dalam rentang 0 hingga 1.

Setelah *scaling*, data disusun agar siap untuk pembelajaran terawasi (*supervised learning*). Data diubah ke dalam format yang memungkinkan untuk memprediksi harga mata uang kripto berdasarkan dua hari sebelumnya. Dengan kata lain, langkah waktu yang digunakan dalam penelitian ini adalah dua untuk memprediksi nilai berikutnya. Dengan konversi ini, data siap untuk peramalan deret waktu.

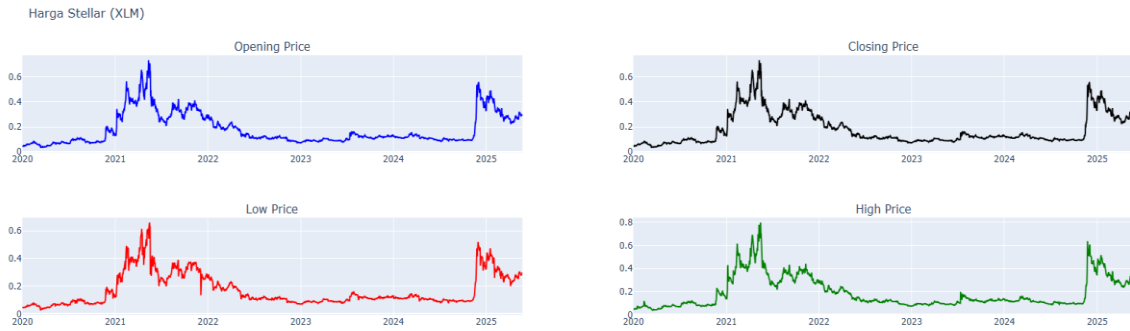
Deskripsi dan Praproses Data

Sebelum melakukan analisis data, disarankan untuk memahami perilaku data dengan mengamati polanya. Gambar 2 menampilkan nilai XLM seiring waktu dan menggambarkan distribusi nilai mata uang digital antara 1 Januari 2020 hingga 23 Mei 2025.



Gambar 2. Harga XLM untuk hari-hari yang dipilih

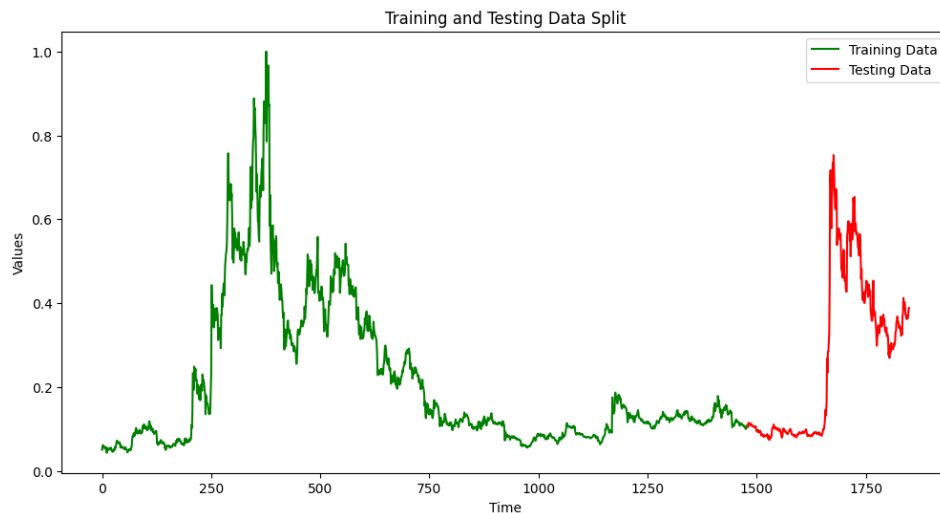
Gambar 2 menunjukkan bahwa antara awal tahun 2022 hingga pertengahan 2024, harga koin XLM berada dalam kondisi relatif stabil tanpa adanya tren naik atau turun yang signifikan, serta tidak terlihat adanya lonjakan harga yang mencolok seperti pada tahun-tahun sebelumnya.



Gambar 3. XLM stock price for the selected days

Set Pelatihan dan Pengujian

Untuk membagi *dataset* menjadi data pelatihan dan pengujian, digunakan rasio 80:20. 80 persen pertama dari data dipilih sebagai data pelatihan, sementara 20 persen sisanya dipilih sebagai data pengujian. Data pelatihan terdiri dari 1.577 hari pertama, sementara data pengujian terdiri dari 394 hari terakhir dari *dataset*. Grafik distribusi dapat dilihat pada Gambar 4.

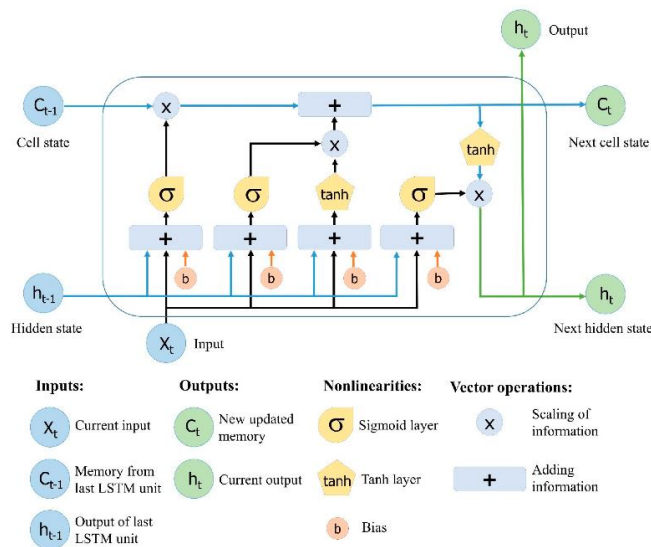


Gambar 4. Grafik Pembagian Data Pelatihan dan Data Pengujian

Long-Short Term Memory (LSTM)

LSTM (Long Short-Term Memory) adalah jenis jaringan saraf buatan yang termasuk dalam kategori Recurrent Neural Networks (RNN). Dalam konteks ini, jaringan LSTM terbukti mampu menangani ketergantungan temporal jangka panjang dalam data berurutan. Keunggulan utamanya adalah kemampuannya untuk mengatasi tantangan tersebut tanpa menghadapi kesulitan yang sering dialami oleh jaringan saraf berulang tradisional (RNN) selama proses optimasi [10].

Menurut [16], Long Short-Term Memory (LSTM) memiliki tiga gerbang yang memainkan peran penting dalam pengelolaan informasi: gerbang input, gerbang *output*, dan gerbang lupa. Selain itu, LSTM memiliki status sel yang berfungsi sebagai wadah untuk menyimpan dan mengendalikan informasi temporal. Gerbang lupa mengatur seberapa banyak informasi yang harus dibuang dari status sel, sementara gerbang input mengontrol seberapa banyak informasi baru yang harus disimpan dalam status sel. Gerbang output bertanggung jawab untuk menentukan informasi mana yang harus dikeluarkan dari status sel [17]. Gambar 5 menggambarkan arsitektur algoritma LSTM.



Gambar 5. Arsitektur LSTM

Proses pelatihan maju (*forward training*) dari LSTM dapat diformulasikan dengan persamaan berikut:

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

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

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * C_t \quad (4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

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


Dalam jaringan Long Short-Term Memory (LSTM), x_t merupakan input yang diterima pada waktu ke- t , sedangkan h_{t-1} dan C_{t-1} masing-masing merepresentasikan keluaran tersembunyi (*hidden state*) dan status sel (*cell state*) dari waktu sebelumnya [18]. Proses pengolahan informasi dalam LSTM melibatkan parameter bobot (W) dan bias (b) yang digunakan untuk menghitung tiga gerbang utama, yaitu *forget gate* (f_t), *input gate* (i_t), dan *output gate* (o_t) [19]. *Forget gate* berfungsi untuk menentukan informasi dari *cell state* sebelumnya (C_t) yang perlu dilupakan, sementara *input gate* mengontrol informasi baru yang akan ditambahkan ke memori jangka panjang. Kandidat memori baru yang akan ditambahkan ke *cell state* dihitung menggunakan fungsi aktivasi tangen hiperbolik (\tanh) dan dilambungkan sebagai C_t [20]. Status sel saat ini (C_t) diperoleh melalui kombinasi antara informasi yang dipertahankan oleh *forget gate* dan informasi baru yang ditentukan oleh input gate.

Output gate (o_t) selanjutnya mengatur bagian dari cell state yang akan diteruskan sebagai output jaringan pada waktu t , yang dinyatakan sebagai hidden state h_t . Ketiga gerbang ini f_t , i_t , dan o_t dikendalikan oleh fungsi aktivasi sigmoid (σ) yang mengatur skala informasi dalam rentang nilai antara 0 dan 1. Hidden state h_t merupakan hasil dari perkalian antara output gate dan cell state yang telah dinormalisasi melalui fungsi \tanh , dan berperan penting dalam penyimpanan informasi jangka pendek serta sebagai input untuk langkah waktu berikutnya dalam pemrosesan sekuensial [21].

Gated Recurrent Unit (GRU)

GRU pertama kali diperkenalkan oleh Kyunghyun Cho pada tahun 2014 [22]. Gated Recurrent Unit (GRU) adalah algoritma yang dikembangkan dari Recurrent Neural Network (RNN) dan memiliki kemiripan dengan varian RNN lainnya, yaitu Long Short Term Memory (LSTM) [23]. Sel GRU memiliki dua gerbang, tidak seperti sel LSTM. Gerbang pertama adalah update gate dan gerbang kedua adalah reset gate. Selain itu, bobot dari gerbang-gerbang ini diperbarui secara adaptif selama proses pembelajaran algoritma [10].

GRU telah menunjukkan kinerja yang mengesankan dalam berbagai tugas, termasuk pengenalan citra dan analisis data berurutan. Keunggulan GRU terletak pada strukturnya yang lebih sederhana dibandingkan dengan LSTM, karena hanya memiliki dua gerbang [24]. GRU dapat dianggap sebagai varian dari LSTM dengan tujuan yang sama, yaitu meningkatkan kinerja dari jaringan saraf berulang (RNN) dalam memprediksi data berurutan. GRU bahkan dapat lebih efisien dan cepat dibandingkan LSTM pada data berurutan berdimensi rendah karena memiliki jumlah gerbang dan parameter yang lebih sedikit [25]. Struktur GRU ditunjukkan pada Gambar 6.



Gambar 6. Arsitektur GRU

Proses pelatihan maju (forward training process) pada GRU dapat dirumuskan dengan persamaan-persamaan berikut:

$$z_t = \sigma(Wz[ht - 1, xt] + bz) \quad (7)$$

$$r_t = \sigma(Wr[ht - 1, xt] + br) \quad (8)$$

$$ht = (1 - z_t) * ht - 1 + z_t * \tanh(Wh[r_t * ht - 1, xt] + bh) \quad (9)$$

Dalam arsitektur Gated Recurrent Unit (GRU), terdapat dua komponen utama, yaitu update gate (z_t) dan reset gate (r_t). Gerbang *update* berfungsi untuk mengatur seberapa besar informasi dari *hidden state* sebelumnya (h_{t-1}) yang perlu dipertahankan, sementara gerbang reset mengatur seberapa besar informasi sebelumnya yang perlu dilupakan sebelum digabungkan dengan input saat ini (x_t). Fungsi aktivasi sigmoid (σ) digunakan dalam kedua gerbang ini untuk menghasilkan nilai antara 0 dan 1 sebagai faktor pengatur [26]. Setelah proses penggabungan melalui gerbang reset, dihasilkan kandidat memori baru yang dihitung menggunakan fungsi aktivasi tangen hiperbolik (\tanh). *Hidden state* saat ini (h_t) kemudian dihitung sebagai gabungan linier antara *hidden state* sebelumnya dan kandidat memori baru, yang dikontrol oleh gerbang *update*. Arsitektur GRU memungkinkan pembelajaran urutan data dengan efisiensi tinggi, dengan struktur yang lebih sederhana daripada Long Short-Term Memory (LSTM) namun tetap efektif dalam menangkap ketergantungan jangka panjang.

Metrik Kinerja

Untuk mengevaluasi kinerja metode Deep Learning yang diusulkan, studi ini menggunakan nilai RMSE (Root Mean Square Error) dan MAPE (Mean Absolute Percentage Error). RMSE dan MAPE dihitung berdasarkan persamaan berikut [27]:

$$MSE = \frac{1}{n} \sum_{i=1}^n (A_i - F_i)^2 \quad (10)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (A_i - F_i)^2} \quad (11)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \quad (12)$$

Dalam persamaan di atas, n adalah jumlah observasi, A_i merupakan nilai aktual dari observasi ke- i , sedangkan F_i adalah nilai prediksi atau peramalan yang dihasilkan dari eksekusi model.

Penyetelan Hiperparameter

Penyetelan hiperparameter merupakan aspek krusial yang sangat memengaruhi kinerja algoritma pembelajaran mesin. Dengan pemilihan hiperparameter yang optimal, kinerja algoritma dapat meningkat secara signifikan sehingga memungkinkan prediksi yang lebih akurat. Ketika model dijalankan dengan parameter yang telah dioptimalkan, algoritma dapat belajar dengan lebih efisien dibandingkan dengan model yang tidak disetel dengan baik [28]. Oleh karena itu, sebelum menerapkan algoritma Deep Learning secara final, penting untuk menentukan nilai terbaik dari hiperparameter tersebut. Dalam penelitian ini, penyetelan hiperparameter dilakukan secara manual berdasarkan eksperimen dan pengamatan kinerja model pada beberapa nilai yang telah dipilih secara cermat. Pendekatan ini dilakukan dengan mencoba beberapa kombinasi nilai untuk parameter seperti *units*, *dropout rate*, *learning rate*, *epoch size*, dan *batch size*, kemudian memilih konfigurasi yang memberikan hasil terbaik pada data validasi. Metode manual ini dipilih karena keterbatasan sumber daya dan waktu, serta untuk memfokuskan pada nilai-nilai yang dianggap relevan berdasarkan pemahaman terhadap karakteristik dataset dan model yang digunakan.

Parameter yang disetel meliputi *units*, *dropout rate*, *learning rate*, *epoch size*, dan *batch size*. *Units* mengacu pada jumlah neuron dalam lapisan tersembunyi jaringan saraf yang berfungsi menentukan kompleksitas model, di mana jumlah neuron yang terlalu sedikit dapat menyebabkan underfitting dan jumlah yang terlalu banyak berisiko menyebabkan *overfitting* serta meningkatkan beban komputasi. *Dropout rate* adalah proporsi neuron yang

diabaikan secara acak selama pelatihan guna mencegah *overfitting*, sehingga nilai dropout yang tepat penting untuk menjaga keseimbangan antara regularisasi dan kemampuan model belajar. Learning rate mengatur besar kecilnya penyesuaian bobot pada setiap iterasi pelatihan; learning rate yang terlalu besar dapat menyebabkan model gagal konvergen, sementara *learning rate* yang terlalu kecil dapat membuat pelatihan berjalan lambat dan terjebak pada minimum lokal. *Epoch size* merujuk pada jumlah siklus lengkap pelatihan dengan seluruh *dataset*, yang disetel untuk memastikan model cukup belajar tanpa mengalami *overfitting*. *Batch size* adalah jumlah sampel data yang diproses dalam satu iterasi, yang berpengaruh pada kestabilan pembelajaran dan efisiensi komputasi. Tabel 1 menunjukkan nilai alternatif dari parameter-parameter tersebut yang diuji dalam eksperimen.

Tabel 1. Nilai Alternatif untuk Parameter yang Dipilih

Parameter	Nilai
Unit	[50, 100, 150]
Dropout Rate	0.2, 0.5
Learning Rate	0.001, 0,1
Epoch	[50, 100, 150]
Batch Size	[32, 64, 128]

Dataset

Data yang dianalisis berasal dari Kucoin, *platform* bursa mata uang kripto global. *Dataset* ini terdiri dari satu file .csv yang mencatat harga harian cryptocurrency Stellar (XLM) dari 1 Januari 2020 hingga 23 Mei 2025. Tabel 2 memberikan spesifikasi *dataset* terkait cryptocurrency tersebut, sementara contoh *dataset* ditampilkan pada Gambar 7.

Tabel 2. Spesifikasi *Dataset*

Nama Variabel	Deskripsi Variabel	Tipe Data
Timestamp	Date	Date
Open	Opening Price	Number
Hight	Highest Price	Number
Low	Lowest Price	Number
Close	Closing Price	Number

	open	high	low	close	volume
timestamp					
2020-01-01	0.044869	0.045540	0.044821	0.045290	1.080201e+05
2020-01-02	0.045306	0.045467	0.043522	0.043635	3.820867e+05
2020-01-03	0.043556	0.045600	0.043326	0.045600	5.565984e+05
2020-01-04	0.045606	0.045741	0.045135	0.045635	4.574369e+05
2020-01-05	0.045592	0.046355	0.045353	0.045544	2.283819e+05
...
2025-05-19	0.292800	0.294000	0.277000	0.286900	7.183810e+06
2025-05-20	0.286600	0.289600	0.280100	0.287600	6.678892e+06
2025-05-21	0.287300	0.298100	0.284100	0.293200	7.661185e+06
2025-05-22	0.293300	0.304500	0.293000	0.304300	6.533034e+06
2025-05-23	0.304200	0.312400	0.299800	0.305100	3.593570e+06

Gambar 7. Contoh *Dataset*

3. HASIL DAN PEMBAHASAN

Untuk mengimplementasikan model deep learning yang diusulkan, digunakan pustaka Python seperti Scikit-learn, Keras, dan TensorFlow. Algoritma model ini ditulis menggunakan Python versi 3.8 dan dijalankan pada platform Google Colab. Hasil performa berdasarkan model Deep Learning ditampilkan pada Tabel 3. Model yang menunjukkan nilai Mean Squared Error (MSE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE) terendah diidentifikasi sebagai model terbaik.

Tabel 3. Hasil Kinerja dari Model yang Diusulkan

Model	Units	Epoch	Batch Size	Drop Rate	Learning Rate	MAPE	RMSE	MSE
LSTM	50	50	32	0.2	0.001	5.7108	0.0306	0.0009
					0.01	5.4352	0.0275	0.0007
				0.001	5.9696	0.0327	0.0010	
	100	100	64	0.5	0.01	6.3735	0.0325	0.0010
					0.001	8.5627	0.0539	0.0029
				0.01	4.5638	0.0244	0.0005	



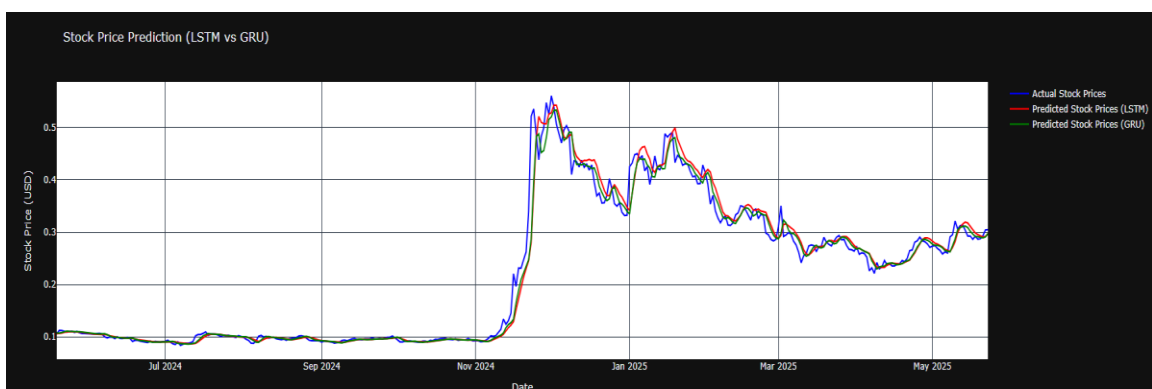
Model	Units	Epoch	Batch Size	Drop Rate	Learning Rate	MAPE	RMSE	MSE
GRU	150	150	128	0.5	0.001	5.9341	0.0323	0.0010
					0.01	7.3542	0.0439	0.0019
				0.2	0.001	5.8984	0.0325	0.0010
					0.01	6.7818	0.0382	0.0014
				0.5	0.001	8.5111	0.0520	0.0027
					0.01	6.6226	0.0357	0.0012
	50	50	32	0.2	0.001	4.8074	0.0273	0.0007
					0.01	6.2423	0.0291	0.0008
				0.5	0.001	5.0456	0.0301	0.0009
					0.01	4.1188	0.0231	0.0005
				0.2	0.001	4.6802	0.0268	0.0007
					0.01	3.6164	0.0206	0.0004
	100	100	64	0.5	0.001	4.2558	0.0258	0.0006
					0.01	4.0632	0.0238	0.0007
				0.2	0.001	4.0994	0.0229	0.0005
					0.01	4.4686	0.0267	0.0007
				0.5	0.001	4.1047	0.0237	0.0005
					0.01	4.8605	0.0282	0.0007

Metrik kinerja ditunjukkan pada Tabel 3, yang mengindikasikan bahwa model GRU dengan konfigurasi 100 Unit, 100 Epoch, Batch Size 64, Drop Rate 0.2, dan Learning Rate 0.01 secara signifikan mengungguli model LSTM terbaik yang diuji. Model GRU mencapai Mean Absolute Percentage Error (MAPE) sebesar 3.6164%, Root Mean Squared Error (RMSE) sebesar 0.0206, dan Mean Squared Error (MSE) sebesar 0.0004, sedangkan model LSTM dengan performa terbaik, yaitu konfigurasi 50 Unit, 50 Epoch, Batch Size 32, Drop Rate 0.2, dan Learning Rate 0.01, hanya mampu mencapai MAPE sebesar 4.5638%, RMSE sebesar 0.0244, dan MSE sebesar 0.0005.

Hasil ini menunjukkan bahwa GRU secara konsisten lebih unggul dalam mengurangi kesalahan prediksi, khususnya dalam metrik RMSE dan MSE, yang menandakan kemampuannya dalam menghasilkan prediksi yang lebih akurat terhadap nilai aktual. Di sisi lain, meskipun model LSTM tetap memberikan hasil yang cukup baik, terutama pada konfigurasi tertentu, model GRU menunjukkan kestabilan dan performa yang lebih optimal dalam keseluruhan pengujian, menjadikannya pilihan yang lebih efektif untuk permasalahan prediksi pada *dataset* ini.

Secara keseluruhan, GRU menjadi pilihan yang lebih efisien dan optimal dalam skenario ini, tidak hanya karena kemampuannya dalam menghasilkan prediksi yang lebih akurat, tetapi juga karena kompleksitas model yang lebih rendah dibandingkan LSTM, sehingga lebih cepat dilatih dan berpotensi lebih hemat sumber daya komputasi.

Gambar 8 menunjukkan perbandingan antara harga aktual XLM dan prediksi menggunakan dua metode Deep Learning yang diusulkan, yaitu LSTM dan GRU. Grafik tersebut menunjukkan bahwa garis prediksi dari kedua model hampir seluruhnya tumpang tindih dengan garis harga aktual sepanjang interval pengujian, yang mengindikasikan kinerja yang sangat baik dari keduanya. Hasil ini menyiratkan bahwa baik LSTM maupun GRU mampu memprediksi harga XLM dengan akurasi tinggi, meskipun terdapat perbedaan kecil dalam metrik kinerja mereka.



Gambar 8. Nilai Aktual vs Nilai Prediksi

4. SIMPULAN

Temuan penelitian menunjukkan bahwa model GRU mengungguli LSTM dalam memprediksi harga XLM, dengan nilai MSE, RMSE, dan MAPE yang lebih rendah. Hal ini menunjukkan bahwa GRU lebih efektif dalam memodelkan kompleksitas dan non-linearitas data harga XLM. Studi ini menyarankan bahwa algoritma GRU dapat dianggap sebagai pendekatan yang lebih unggul untuk memprediksi harga kripto, khususnya XLM,

dibandingkan dengan LSTM. Penelitian selanjutnya dapat mengeksplorasi keandalan metode GRU pada jenis mata uang kripto lainnya dan membandingkannya dengan teknik prediksi alternatif.

DAFTAR PUSTAKA

- [1] J. Mere, “Pembuatan Dan Pengujian Token Crypto Pada Jaringan Mainnet Menggunakan Smart Contract Binance Smart Chain (Bsc) Dan Remix.Ethereum,” *HOAQ (High Education of Organization Archive Quality): Jurnal Teknologi Informasi*, vol. 14, no. 2, pp. 82–89, Dec. 2023, doi: 10.52972/hoaq.vol14no2.p82-89.
- [2] W. Yin, M. Zhang, Z. Zhu, and E. Zhang, “A novel approach based on similarity measure for the multiple attribute group decision-making problem in selecting a sustainable cryptocurrency,” *Heliyon*, vol. 9, no. 5, 2023, doi: 10.1016/j.heliyon.2023.e16051.
- [3] T. Bakhtiar, X. Luo, and I. Adelopo, “The impact of fundamental factors and sentiments on the valuation of cryptocurrencies,” *Blockchain: Research and Applications*, vol. 4, no. 4, Dec. 2023, doi: 10.1016/j.bcr.2023.100154.
- [4] D. O. Oyewola, E. G. Dada, and J. N. Ndunagu, “A novel hybrid walk-forward ensemble optimization for time series cryptocurrency prediction,” *Heliyon*, vol. 8, no. 11, Nov. 2022, doi: 10.1016/j.heliyon.2022.e11862.
- [5] A. P. N. Nguyen, T. T. Mai, M. Bezbradica, and M. Crane, “Volatility and returns connectedness in cryptocurrency markets: Insights from graph-based methods,” *Physica A: Statistical Mechanics and its Applications*, vol. 632, Dec. 2023, doi: 10.1016/j.physa.2023.129349.
- [6] H. Lee and D. Wie, “Gone with the fire: Market reaction to cryptocurrency exchange shutdown,” *Heliyon*, vol. 9, no. 7, Jul. 2023, doi: 10.1016/j.heliyon.2023.e18231.
- [7] A. S. Girsang and Stanley, “Hybrid LSTM and GRU for Cryptocurrency Price Forecasting Based on Social Network Sentiment Analysis Using FinBERT,” *IEEE Access*, vol. 11, pp. 120530–120540, 2023, doi: 10.1109/ACCESS.2023.3324535.
- [8] S. Syed, A. Iqbal, W. Mehmood, Z. Syed, M. Khan, and G. Pau, “Split-Second Cryptocurrency Forecast Using Prognostic Deep Learning Algorithms: Data Curation by Deephaven,” *IEEE Access*, vol. 11, 2023, doi: 10.1109/ACCESS.2023.3331652.
- [9] M. Sajjad *et al.*, “A Novel CNN-GRU-Based Hybrid Approach for Short-Term Residential Load Forecasting,” *IEEE Access*, vol. 8, pp. 143759–143768, 2020, doi: 10.1109/ACCESS.2020.3009537.
- [10] S. O. Birim and Ş. Öztürk Birim, “An Analysis For Cryptocurrency Price Prediction Using Lstm, Gru, And The Bi-Directional Implications,” 2022. [Online]. Available: <https://www.researchgate.net/publication/359504764>
- [11] N. Fauzi, A. Giffary, and F. Sulianta, “Prediction Of Cryptocurrency Prices Using Lstm, Svm And Polynomial Regression,” 2023. [Online]. Available: <https://ajesh.ph/index.php/gp>
- [12] X. Ruan, L. Wang, C. Thongprayoon, W. Cheungpasitporn, and H. Liu, “GRU-D-Weibull: A novel real-time individualized endpoint prediction,” *Artif Intell Med*, vol. 146, Dec. 2023, doi: 10.1016/j.artmed.2023.102696.
- [13] D. Xu, “Price Prediction of Cryptocurrency based on LSTM Model: Evidence from Ethereum,” *Highlights in Science, Engineering and Technology*, vol. 39, 2023, doi: 10.54097/hset.v39i.6639.
- [14] A. Kumar, N. Sharma, K. K. Gurma, A. Anand, J. C. Patni, and L. Pinjarkar, “Forecasting Stellar XLM Prices: Insights from ARIMA Analysis,” *International Journal of Religion*, vol. 5, no. 6, pp. 273–288, Apr. 2024, doi: 10.61707/7074ja52.
- [15] Singh Ashish, Kumar Abhinav, and Akhtar Zahid, “Bitcoin Price Prediction: A Deep Learning Approach,” *IEEE Access*, Oct. 20221.
- [16] F. Shahid, A. Zameer, and M. Muneeb, “Predictions for COVID-19 with deep learning models of LSTM, GRU and Bi-LSTM,” *Chaos Solitons Fractals*, vol. 140, Nov. 2020, doi: 10.1016/j.chaos.2020.110212.
- [17] N. Ayoobi *et al.*, “Time series forecasting of new cases and new deaths rate for COVID-19 using deep learning methods,” *Results Phys*, vol. 27, Aug. 2021, doi: 10.1016/j.rinp.2021.104495.
- [18] S. Gegenleithner, M. Pirker, C. Dorfmann, R. Kern, and J. Schneider, “Long short-term memory networks for enhancing real-time flood forecasts: a case study for an underperforming hydrologic model,” *Hydrol Earth Syst Sci*, vol. 29, no. 7, pp. 1939–1962, Apr. 2025, doi: 10.5194/hess-29-1939-2025.
- [19] Q. Guo, Z. He, and Z. Wang, “Assessing the effectiveness of long short-term memory and artificial neural network in predicting daily ozone concentrations in Liaocheng City,” *Sci Rep*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-91329-w.
- [20] M. Gauch, F. Kratzert, D. Klotz, G. Nearing, J. Lin, and S. Hochreiter, “Rainfall-runoff prediction at multiple timescales with a single Long Short-Term Memory network,” *Hydrol Earth Syst Sci*, vol. 25, no. 4, 2021, doi: 10.5194/hess-25-2045-2021.
- [21] F. Landi, L. Baraldi, M. Cornia, and R. Cucchiara, “Working Memory Connections for LSTM,” *Neural Networks*, vol. 144, 2021, doi: 10.1016/j.neunet.2021.08.030.

- [22] X. Luo, D. Ma, S. Zhang, and D. Wang, "GRU neural network-based method for box girder crack damage detection," *Chinese Journal of Ship Research*, vol. 17, no. 4, pp. 194–203, Aug. 2022, doi: 10.19693/j.issn.1673-3185.02415.
- [23] N. W. Saputra, F. Insani, S. Agustian, and S. Sanjaya, "Penerapan Deep Learning Menggunakan Gated Recurrent Unit Untuk Memprediksi Harga Minyak Mentah Dunia," *Building of Informatics, Technology and Science (BITS)*, vol. 5, no. 1, Jun. 2023, doi: 10.47065/bits.v5i1.3552.
- [24] Yang Nian, Shi Dongxin, and Hua Yan, "Bidirectional Gated Recurrent Unit Neural Networks for Relation Extraction of Chinese Enterprises," *IEEE Access*, 2020.
- [25] Lai Shanyan, Ye Chunyang, and Zhou Jiang Hui Hongyu, "Chinese stock trend prediction based on multi-feature learning and model fusion," *IEEE Access*, 2021.
- [26] Z. S. Lin, "Enhanced GRU-based regression analysis via a diverse strategies whale optimization algorithm," *Sci Rep*, vol. 14, no. 1, p. 25629, Dec. 2024, doi: 10.1038/s41598-024-77517-0.
- [27] M. Rasyid, E. A. Muharyanto, and E. S. Wagola, "Perbandingan Metode Peramalan Pada Penjualan Barang Dagang Cv Andika Di Pulau Buru," 2023.
- [28] Amirabadi A.M., Kahaei H.M., and Nezamalhoseini A.S., "Novel suboptimal approaches for hyperparameter tuning of deep neural network [under the shelf of optical communication]," *Physical Communication*, 2020.