



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 2 (2026) pp: 9639- 9649

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Implementasi Algoritma GRU Untuk Trading Strategy pada Cryptocurrency Berbasis Web

I Gede Bayu Balawa Tangub¹, Neny Sulistianingsih², Tomi Tri Sujaka³

¹Program Studi Ilmu Komputer, Fakultas Teknik, Universitas Bumigora

²Magister Ilmu Komputer, Program Pasca Sarjana, Universitas Bumigora

³Teknik, Ilmu Komputer, Universitas Bumigora

bayubalawa1@gmail.com, neny.sulistianingsih@universitasbumigora.ac.id, tomi.tri@universitasbumigora.ac.id

Abstrak

Perkembangan investasi cryptocurrency, khususnya Ethereum (ETH), terus meningkat seiring dengan bertambahnya jumlah investor aset digital. Namun, tingginya volatilitas harga cryptocurrency menyebabkan proses pengambilan keputusan trading menjadi lebih kompleks dan berisiko. Oleh karena itu, diperlukan metode prediksi yang mampu menghasilkan informasi harga secara akurat untuk mendukung pengambilan keputusan investasi. Penelitian ini bertujuan untuk membandingkan performa algoritma Gated Recurrent Unit (GRU) dan Bidirectional Gated Recurrent Unit (Bi-GRU) dalam memprediksi harga penutupan Ethereum serta mengimplementasikan model terbaik ke dalam sistem trading strategy berbasis web. Metode penelitian menggunakan pendekatan Cross Industry Standard Process for Data Mining (CRISP-DM) yang meliputi tahapan business understanding, data understanding, data preparation, modeling, evaluation, dan deployment. Dataset yang digunakan berupa data historis harian ETH-USD yang diperoleh dari Yahoo Finance pada periode 9 November 2016 hingga 16 Januari 2026. Proses penelitian mencakup prapemrosesan data, pelatihan model, evaluasi performa menggunakan RMSE, MAE, MSE, R^2 , dan Explained Variance, serta implementasi sistem berbasis web. Hasil penelitian menunjukkan bahwa model GRU memberikan performa yang lebih baik dibandingkan Bi-GRU dengan nilai RMSE sebesar 150,99, MAE sebesar 117,70, MSE sebesar 22.798,51, R^2 sebesar 0,96, dan Explained Variance sebesar 0,98. Hasil prediksi kemudian diintegrasikan ke dalam strategi trading berbasis aturan yang menghasilkan sinyal buy, sell, dan hold. Sistem berhasil diimplementasikan menggunakan Vercel dan Hugging Face Spaces. Hasil penelitian menunjukkan bahwa algoritma GRU efektif untuk prediksi harga Ethereum dan berpotensi mendukung pengambilan keputusan trading berbasis data secara lebih objektif.

Kata Kunci: GRU, Trading Strategy, Cryptocurrency, Berbasis Web

1. Latar Belakang

Perkembangan teknologi informasi telah mendorong transformasi signifikan pada sektor keuangan digital, yang ditandai dengan munculnya *cryptocurrency* sebagai instrumen investasi modern yang memanfaatkan teknologi *blockchain* bersifat terdesentralisasi dan transparan [1]. Aset kripto seperti Bitcoin dan Ethereum kini semakin diminati oleh masyarakat luas karena potensi keuntungannya yang menjanjikan dibandingkan mata uang konvensional [2]. Namun, karakteristik utama pasar *cryptocurrency* adalah tingkat volatilitas harga yang sangat ekstrem, di mana fluktuasi yang drastis dapat terjadi dalam waktu singkat, sehingga meningkatkan risiko kerugian bagi investor jika tidak didukung oleh analisis yang akurat [3], [4].

Dalam aktivitas trading, investor dihadapkan pada keputusan kritis untuk melakukan *buy*, *sell*, atau *hold* yang sangat bergantung pada kemampuan memprediksi pergerakan harga [5]. Oleh karena itu, sistem prediksi berbasis data historis (*time series*) menjadi komponen vital dalam penyusunan strategi trading guna meminimalkan risiko objektif investor [6]. Penelitian sebelumnya telah mencoba berbagai metode, seperti *Backpropagation Neural Network* (BPNN), namun metode ini dinilai kurang optimal dalam menangani dependensi jangka panjang pada data deret waktu yang kompleks [2]. Begitu pula dengan metode statistik tradisional seperti ARIMA yang memiliki keterbatasan dalam menangkap pola non-linier pada data harga kripto yang fluktuatif [6].

Pendekatan *Deep Learning*, khususnya arsitektur *Recurrent Neural Network* (RNN), hadir sebagai solusi karena kemampuannya dalam memodelkan data sekuensial [7]. Namun, RNN konvensional sering mengalami kendala *vanishing gradient*. Untuk mengatasi hal ini, dikembangkan model seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) yang mampu menangkap keterkaitan data jangka panjang secara lebih efektif melalui mekanisme *gating* [8], [9]. Di antara keduanya, GRU menawarkan keunggulan berupa struktur

yang lebih sederhana dan efisiensi komputasi yang lebih tinggi dengan parameter yang lebih sedikit, namun tetap mampu menghasilkan akurasi prediksi yang kompetitif, bahkan seringkali mengungguli LSTM pada jenis data tertentu [4], [10].


Berbagai penelitian telah menerapkan metode deep learning untuk memprediksi harga cryptocurrency dan instrumen keuangan lainnya. [4] menunjukkan bahwa model GRU mampu mengungguli LSTM pada prediksi harga Ethereum dengan nilai MAPE sebesar 0,45% dan R^2 sebesar 0,9983, sedangkan LSTM memperoleh MAPE sebesar 0,49% dan R^2 sebesar 0,9980. [11] melaporkan bahwa model Bi-LSTM menghasilkan nilai MAPE terendah pada Bitcoin (0,036%), Litecoin (0,041%), dan Ethereum (0,124%). Sementara itu, [12] menemukan bahwa model Hybrid CNN-LSTM-GRU memberikan performa terbaik dengan RMSE sebesar 0,1089 dan R^2 sebesar 0,9913. Pada penelitian lain, [13] menunjukkan bahwa model GRU memperoleh nilai MAE terendah sebesar 0,0096 dibandingkan LSTM dan Transformer pada prediksi harga Zcash. Selain itu, [14] menemukan bahwa GRU memberikan performa terbaik pada aset Bitcoin, Ethereum, dan Solana dengan nilai R^2 masing-masing sebesar 0,9792, 0,9391, dan 0,9539. Hasil tinjauan sistematis yang dilakukan oleh [15] juga menunjukkan bahwa Bi-GRU unggul pada data indeks saham dan forex, sedangkan Transformer Hybrid memberikan performa terbaik pada data cryptocurrency. Temuan-temuan tersebut menunjukkan bahwa model deep learning memiliki kemampuan yang baik dalam memprediksi harga aset digital, namun performanya masih sangat dipengaruhi oleh karakteristik data dan arsitektur model yang digunakan.

Meskipun model prediksi terus berkembang, sebagian besar studi masih berfokus pada hasil akurasi model di lingkungan eksperimen tanpa mengintegrasikannya ke dalam sebuah sistem yang aplikatif. Kurangnya aksesibilitas instrumen prediksi yang mudah digunakan menjadi hambatan bagi investor retail. Padahal, implementasi dalam bentuk aplikasi berbasis web memiliki keunggulan dalam hal kemudahan akses dan penggunaan secara *real-time* [16]. Dengan memanfaatkan ekosistem pemrograman modern seperti JavaScript yang kini telah bertransformasi menjadi bahasa *full-stack*, pengembangan sistem informasi yang interaktif dan responsif menjadi sangat dimungkinkan [17]. Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk membandingkan performa algoritma *Gated Recurrent Unit* (GRU) dan *Bidirectional Gated Recurrent Unit* (Bi-GRU) dalam memprediksi harga *cryptocurrency* serta mengimplementasikan model terbaik ke dalam *sistem trading strategy* berbasis web. Sistem ini diharapkan tidak hanya mampu memberikan prediksi harga dengan tingkat kesalahan yang rendah, tetapi juga menyediakan sinyal trading yang objektif berdasarkan data historis untuk membantu investor dalam mengambil keputusan yang lebih tepat.

2. Metode Penelitian

2.1 Kerangka Kerja Penelitian

Penelitian ini menerapkan kerangka kerja *Cross-Industry Standard Process for Data Mining* (CRISP-DM) sebagai pendekatan sistematis untuk membangun model prediksi harga Ethereum [18]. Penggunaan metodologi ini memastikan setiap tahapan—mulai dari pemahaman kebutuhan bisnis hingga penyebaran model (*deployment*)—berjalan secara terstruktur guna menghasilkan solusi yang aplikatif bagi investor kripto [19]. Seluruh alur penelitian dirancang untuk memproses data deret waktu (*time series*) menggunakan algoritma *Deep Learning* secara objektif [20]. Tahapan penelitian CRISP-DM yang digunakan dalam penelitian ini dapat dilihat pada Gambar 1.



Gambar 1 Tahapan Penelitian [21]

2.2 Business & Data Understanding

Tahap awal difokuskan pada analisis kebutuhan *trader* terhadap alat bantu pengambilan keputusan di tengah tingginya volatilitas pasar [1]. Data yang digunakan adalah harga penutupan (*Close Price*) Ethereum (ETH-USD) yang diambil dari Yahoo Finance untuk periode 9 November 2017 hingga 17 Januari 2026 menggunakan pustaka Python *yfinance*. Variabel harga penutupan dipilih karena mencerminkan konsensus akhir nilai pasar harian, yang sangat krusial dalam analisis teknikal dan penyusunan strategi trading [6].

2.3 Data Preparation

Proses transformasi data mentah menjadi format yang siap dilatih dilakukan melalui beberapa langkah kunci. Pada tahap data preparation, dilakukan proses pembersihan data dengan menghapus missing values untuk menjaga stabilitas komputasi model [3]. Selanjutnya, dilakukan seleksi fitur dengan memfokuskan penggunaan variabel harga penutupan (*Close Price*) sebagai fitur input tunggal (*univariate*) karena memiliki relevansi yang tinggi terhadap penentuan sinyal *trading* [5]. Dataset kemudian dibagi secara kronologis menjadi 80% data latih dan 20% data uji guna mempertahankan dependensi temporal [5]. Setelah itu, dilakukan normalisasi menggunakan metode *Min-Max Scaler* untuk mengubah rentang nilai menjadi 0 hingga 1. Proses ini terbukti dapat mempercepat konvergensi gradien serta meningkatkan performa algoritma *machine learning* dibandingkan tanpa penskalaan [22], [23]. Selanjutnya, diterapkan teknik *sliding window* sebanyak 60 hari untuk mengubah data menjadi struktur tiga dimensi berupa *samples*, *time steps*, dan *features* sesuai dengan kebutuhan input model GRU [2].

2.4 Modeling (GRU & Bi-GRU)

Penelitian ini membandingkan dua arsitektur Recurrent Neural Network (RNN), yaitu Gated Recurrent Unit (GRU) dan Bidirectional Gated Recurrent Unit (Bi-GRU). Model GRU dipilih karena memiliki efisiensi komputasi yang baik serta kemampuan mengatasi vanishing gradient melalui struktur gate yang lebih sederhana dibandingkan Long Short-Term Memory (LSTM) [8], [9]. Sementara itu, Bi-GRU digunakan karena mampu menangkap informasi temporal dari dua arah, yaitu maju (*forward*) dan mundur (*backward*), sehingga secara teori dapat meningkatkan akurasi prediksi pada data deret waktu yang kompleks [10].

Pada model GRU, proses pembelajaran melibatkan dua mekanisme utama, yaitu *update gate* dan *reset gate*. *Update gate* berfungsi untuk menentukan seberapa besar informasi dari *hidden state* sebelumnya yang dipertahankan, sedangkan *reset gate* mengatur informasi masa lalu yang akan digunakan dalam pembentukan kandidat *hidden state* baru [24]. Secara matematis, proses komputasi pada GRU dapat dinyatakan sebagai berikut pada Persamaan (1)–(4).

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

$$r_t = \sigma(W_r[h_{t-1}, x_t] + b_r) \quad (2)$$

$$\tilde{h}_t = \tau(W_h[r_t \odot h_{t-1}, x_t] + b_h) \quad (3)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (4)$$

dengan z_t merupakan *update gate*, r_t merupakan *reset gate*, \tilde{h}_t adalah kandidat *hidden state*, h_t merupakan *hidden state* pada waktu ke-(t), dan x_t adalah input pada waktu ke-(t).

Berbeda dengan GRU standar, Bi-GRU memproses data dalam dua arah, yaitu dari masa lalu ke masa depan (*forward*) dan dari masa depan ke masa lalu (*backward*). Hasil dari kedua arah tersebut kemudian digabungkan (*concatenation*) untuk menghasilkan representasi yang lebih komprehensif terhadap pola data [24]. Persamaan Bi-GRU dapat dinyatakan sebagai berikut pada Persamaan (5)

$$h_t = \vec{h}_t \oplus \overleftarrow{h}_t \quad (5)$$

di mana \vec{h}_t menyatakan *hidden state* arah maju, \overleftarrow{h}_t menyatakan *hidden state* arah mundur, dan \oplus menunjukkan operasi penggabungan (*concatenation*) kedua *hidden state* tersebut.

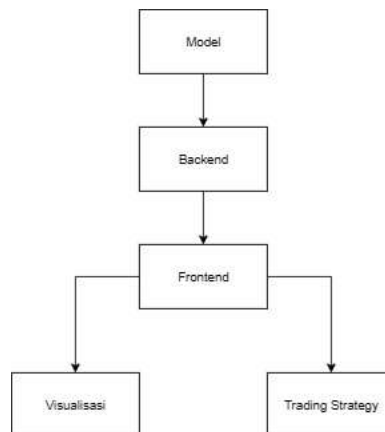
Kedua model dibangun menggunakan arsitektur *Sequential* dengan lapisan *Dropout* sebesar 0,2 untuk meminimalkan risiko *overfitting* selama proses pelatihan [5]. Pada tahap pelatihan, kedua model menggunakan optimizer Adam dengan *learning rate* sebesar 0,001 dan fungsi *loss* Mean Squared Error (MSE). Selain itu, model dilatih selama 100 *epoch* dengan *batch size* 64 serta *validation split* sebesar 10%. Penggunaan konfigurasi parameter yang sama pada kedua model bertujuan untuk memastikan bahwa perbedaan kinerja yang diperoleh berasal dari karakteristik arsitektur GRU dan Bi-GRU, bukan dari perbedaan pengaturan parameter pelatihan.

2.5 Evaluasi Model

Untuk mengukur akurasi prediksi, digunakan beberapa metrik evaluasi regresi, yaitu Mean Squared Error (MSE), Root Mean Square Error (RMSE), Mean Absolute Error (MAE), koefisien determinasi (R^2), dan Explained Variance. MSE, RMSE, dan MAE digunakan untuk mengukur besarnya kesalahan prediksi, di mana nilai yang lebih kecil menunjukkan performa model yang lebih baik. Sementara itu, R^2 dan Explained Variance digunakan untuk mengevaluasi kemampuan model dalam menjelaskan variasi data aktual, dengan nilai yang semakin mendekati 1 mengindikasikan kemampuan prediksi yang semakin baik [4], [5], [15].

2.6 Deployment

Model terbaik yang diperoleh dari tahap pelatihan kemudian diintegrasikan ke dalam ekosistem web modern agar dapat diakses secara praktis oleh pengguna [25]. Model tersebut ditempatkan pada sisi backend yang dibangun menggunakan *framework* FastAPI sebagai web service untuk menangani proses inferensi dan penyediaan data secara real-time. FastAPI dipilih karena memiliki performa tinggi dan mampu menangani permintaan pengguna dengan efisien [19]. Selanjutnya, backend terhubung dengan frontend yang dikembangkan menggunakan React.js dengan pendekatan *Single Page Application* (SPA), sehingga mampu memberikan antarmuka yang interaktif dan responsif [25]. Melalui frontend, hasil prediksi model disajikan dalam bentuk visualisasi grafik harga, indikator teknikal, dan informasi pendukung lainnya. Selain itu, frontend juga menampilkan hasil implementasi trading strategy yang dihasilkan berdasarkan sinyal dari model prediksi. Seluruh proses pengembangan dilakukan menggunakan Visual Studio Code (VSCoDe) sebagai *Integrated Development Environment* (IDE) untuk pengembangan aplikasi berbasis Python dan JavaScript [26]. Alur integrasi sistem yang dikembangkan dapat dilihat pada Gambar 2.



Gambar 2 Alur Integrasi Sistem

3. Hasil dan Diskusi

3.1 Hasil

Berdasarkan hasil pengujian menggunakan beberapa metrik evaluasi, model GRU menunjukkan performa yang lebih baik dibandingkan model Bi-GRU pada dataset yang digunakan. Hal ini terlihat dari nilai RMSE model GRU sebesar 150,99, yang lebih rendah dibandingkan model Bi-GRU sebesar 166,08. Nilai RMSE yang lebih kecil menunjukkan bahwa kesalahan prediksi yang dihasilkan model GRU relatif lebih rendah. Kondisi serupa juga terlihat pada nilai MAE dan MSE, di mana model GRU memperoleh nilai MAE sebesar 117,70 dan MSE

DOI: <https://doi.org/10.31004/riggs.v5i2.10129>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

sebesar 22.798,51, sedangkan model Bi-GRU menghasilkan nilai MAE sebesar 138,52 dan MSE sebesar 27.583,27. Dengan demikian, model GRU memiliki kemampuan yang lebih baik dalam meminimalkan kesalahan prediksi.

Selain itu, kemampuan model dalam menjelaskan variasi data juga ditunjukkan melalui nilai koefisien determinasi (R^2 Score). Model GRU memperoleh nilai R^2 sebesar 0,96, sedikit lebih tinggi dibandingkan model Bi-GRU yang memperoleh nilai 0,95. Hasil ini menunjukkan bahwa kedua model mampu menjelaskan sebagian besar variasi data aktual, dengan model GRU memiliki kemampuan yang sedikit lebih baik. Sementara itu, nilai Explained Variance pada kedua model sama-sama mencapai 0,98, yang mengindikasikan bahwa baik GRU maupun Bi-GRU mampu menangkap pola data dengan sangat baik. Secara keseluruhan, meskipun kedua model menunjukkan kinerja yang baik, model GRU memberikan performa yang lebih unggul dan konsisten dibandingkan model Bi-GRU berdasarkan metrik evaluasi yang digunakan. Rangkuman hasil evaluasi kedua model dapat dilihat pada Tabel 1.

Tabel 1 Hasil Evaluasi Gru & Bi-Gru

Metrik Evaluasi	Gru	Bi-Gru
RMSE	150,99	166,08
MAE	117,70	138,52
MSE	22.798,51	27.583,27
R^2 Score	0,96	0,95
Explained Variance	0,98	0,98

Untuk melihat kemampuan prediksi secara lebih rinci, dilakukan perbandingan antara nilai aktual dengan hasil prediksi yang dihasilkan oleh model GRU dan Bi-GRU pada beberapa data pengujian. Hasil perbandingan menunjukkan bahwa model GRU secara umum menghasilkan prediksi yang lebih mendekati nilai aktual dibandingkan model Bi-GRU. Hal ini dapat dilihat dari nilai selisih prediksi (meleset berapa) maupun persentase kesalahan (meleset %) yang cenderung lebih kecil pada sebagian besar data pengujian.

Sebagai contoh, pada 17 Januari 2026, harga aktual tercatat sebesar \$3.308,86. Model GRU menghasilkan prediksi sebesar \$3.191,39 dengan selisih \$117,47 atau 3,55%, sedangkan model Bi-GRU menghasilkan prediksi sebesar \$3.353,07 dengan selisih \$44,20 atau 1,34%. Hasil ini menunjukkan bahwa pada kondisi tertentu model Bi-GRU dapat memberikan prediksi yang lebih mendekati nilai aktual dibandingkan model GRU.

Namun, secara keseluruhan model GRU menunjukkan performa yang lebih konsisten selama periode pengujian. Hal ini terlihat dari persentase kesalahan yang cenderung lebih rendah pada sebagian besar data, terutama pada rentang 20–26 Januari 2026. Sebagai ilustrasi, pada 20 Januari 2026 model GRU hanya memiliki tingkat kesalahan sebesar 1,03%, sedangkan model Bi-GRU mencapai 19,06%. Temuan tersebut mengindikasikan bahwa meskipun Bi-GRU mampu memberikan prediksi yang lebih baik pada beberapa titik data tertentu, model GRU lebih stabil dan menghasilkan tingkat akurasi yang lebih tinggi secara umum.

Selain itu, berdasarkan kolom status tebakan, model GRU lebih sering berada pada kategori "kekecilan" dengan tingkat penyimpangan yang relatif kecil terhadap nilai aktual, sedangkan model Bi-GRU cenderung menghasilkan prediksi "kemahalan" dengan selisih yang lebih besar. Temuan ini menunjukkan bahwa model Bi-GRU memiliki kecenderungan untuk mengestimasi harga lebih tinggi (overestimate) dibandingkan nilai aktual.

Secara keseluruhan, meskipun kedua model masih mampu merepresentasikan arah atau tren pergerakan harga, model GRU menunjukkan kemampuan prediksi yang lebih akurat dan lebih stabil dibandingkan model Bi-GRU. Hasil ini juga sejalan dengan evaluasi kuantitatif pada Tabel 1, di mana model GRU memperoleh nilai RMSE, MAE, dan MSE yang lebih rendah serta nilai R^2 yang sedikit lebih tinggi dibandingkan model Bi-GRU. Perbandingan nilai aktual dengan hasil prediksi kedua model disajikan pada Tabel 2.

Tabel 2 Hasil Perbandingan Prediksi Harga Gru & Bi-Gru

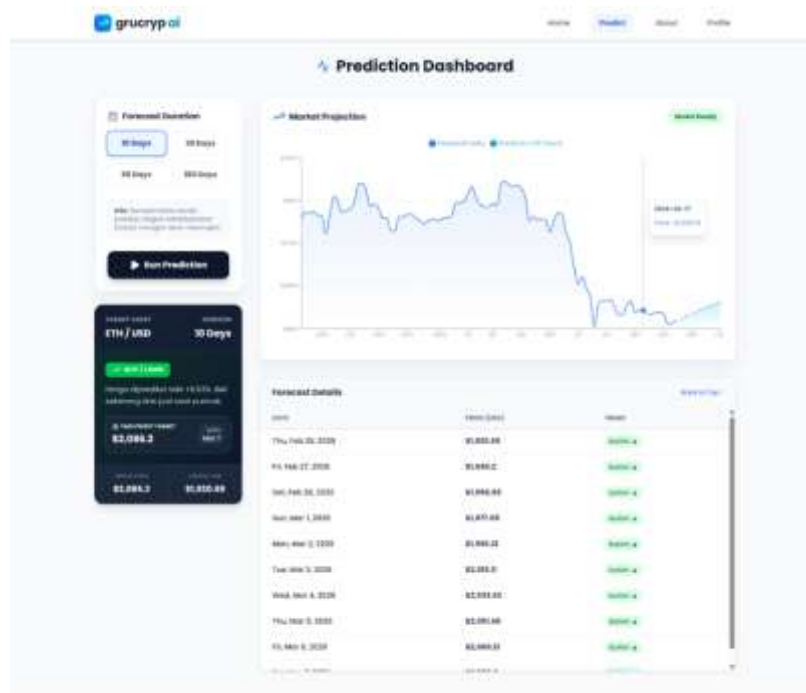
Tanggal	Harga Asli (\$)	Model	Tebakan AI (\$)	Meleset Berapa (\$)	Meleset (%)	Status Tebakan
17-Jan-26	3308.86	Gru	3191,39	117.47	3.55%	Kekecilan
		Bi Gru	3353,07	44.2	1.34%	Kemahalan
18-Jan-26	3281.16	Gru	3107,19	173.96	5.30%	Kekecilan
		Bi Gru	3398,31	117.15	3.57%	Kemahalan
19-Jan-26	3186.62	Gru	3034,66	151.96	4.77%	Kekecilan
		Bi Gru	3445,99	259.37	8.14%	Kemahalan
20-Jan-26	2935.61	Gru	2965,97	30.36	1.03%	Kemahalan

Tanggal	Harga Asli (\$)	Model	Tebakan AI (\$)	Meleset Berapa (\$)	Meleset (%)	Status Tebakan
21-Jan-26	2978.9	Bi Gru	3495,24	559.63	19.06%	Kemahalan
		Gru	2899,61	79.29	2.66%	Kekecilan
22-Jan-26	2949.63	Bi Gru	3545,26	566.36	19.01%	Kemahalan
		Gru	2835,18	114.45	3.88%	Kekecilan
23-Jan-26	2953.26	Bi Gru	3595,49	645.85	21.90%	Kemahalan
		Gru	2772,76	180.49	6.11%	Kekecilan
24-Jan-26	2948.74	Bi Gru	3645,58	692.33	23.44%	Kemahalan
		Gru	2712,43	236.31	8.01%	Kekecilan
25-Jan-26	2815.9	Bi Gru	3695,78	747.04	25.33%	Kemahalan
		Gru	2654,2	161.71	5.74%	Kekecilan
26-Jan-26	2926.46	Bi Gru	3745,94	930.04	33.03%	Kemahalan
		Gru	2598,03	328.42	11.22%	Kekecilan
		Bi Gru	3796,35	869.89	29.73%	Kemahalan

Implementasi dari model terbaik kemudian diwujudkan dalam bentuk sistem berbasis website yang dapat diakses secara online. Website ini dikembangkan untuk mempermudah pengguna dalam mengakses hasil prediksi tanpa perlu menjalankan proses komputasi secara manual. Sistem terdiri dari beberapa halaman utama, yaitu halaman beranda sebagai pengantar, halaman prediksi sebagai fitur inti, halaman informasi model, serta halaman profil pengembang.

Fitur utama sistem terdapat pada halaman prediksi, di mana pengguna dapat menentukan durasi prediksi dan menjalankan proses forecasting. Hasil prediksi kemudian ditampilkan dalam bentuk visualisasi grafik yang menggabungkan data historis dan hasil prediksi, sinyal trading sebagai rekomendasi keputusan, serta tabel detail yang memuat informasi harga dan tren pergerakan. Selain itu, sistem juga menyediakan informasi transparansi model yang mencakup arsitektur, parameter, serta hasil evaluasi performa.

Dengan adanya implementasi ini, hasil penelitian tidak hanya terbatas pada evaluasi model, tetapi juga telah berhasil diterapkan dalam sistem yang interaktif dan aplikatif. Hal ini menunjukkan bahwa model GRU yang diusulkan tidak hanya memiliki performa yang baik secara teoritis, tetapi juga efektif untuk digunakan dalam aplikasi nyata guna mendukung pengambilan keputusan berbasis prediksi. Tampilan awal website yang dikembangkan dapat dilihat pada Gambar 3.



Gambar 3 Tampilan Hasil Prediksi

3.2 Diskusi

Pada bagian ini dibahas hasil penelitian berdasarkan perbandingan performa model GRU dan Bi-GRU dalam memprediksi harga penutupan (close price) Ethereum (ETH-USD). Berdasarkan hasil evaluasi yang diperoleh, model GRU menunjukkan performa yang lebih baik dibandingkan model Bi-GRU. Model GRU menghasilkan nilai RMSE sebesar 117,30, MAE sebesar 83,99, MSE sebesar 13.760,29, R^2 sebesar 0,9751, dan Explained Variance sebesar 0,9763. Sementara itu, model Bi-GRU memperoleh nilai RMSE sebesar 174,08, MAE sebesar 138,53, MSE sebesar 30.304,70, R^2 sebesar 0,9452, dan Explained Variance sebesar 0,9721. Nilai RMSE, MAE, dan MSE yang lebih rendah menunjukkan bahwa model GRU mampu menghasilkan prediksi yang lebih dekat dengan nilai aktual dibandingkan model Bi-GRU. Selain itu, nilai R^2 yang lebih tinggi menunjukkan bahwa model GRU mampu menjelaskan variasi data harga Ethereum dengan lebih baik. Hasil tersebut mengindikasikan bahwa arsitektur GRU lebih sesuai dalam memodelkan karakteristik data harga Ethereum yang bersifat nonlinier dan memiliki volatilitas tinggi.

Temuan penelitian ini sejalan dengan beberapa penelitian terdahulu yang menunjukkan keunggulan model GRU pada prediksi data keuangan dan cryptocurrency. Penelitian pada [14] menunjukkan bahwa GRU mengungguli LSTM pada prediksi harga Ethereum dengan MAPE sebesar 0,45% dan R^2 sebesar 0,9983, sedangkan LSTM memperoleh MAPE sebesar 0,49% dan R^2 sebesar 0,9980. Hasil serupa juga dilaporkan pada [27], di mana GRU menghasilkan nilai MAE terendah sebesar 0,0096 dibandingkan LSTM dan Transformer pada prediksi harga Zcash. Selain itu, penelitian pada [28] menunjukkan bahwa GRU memberikan performa terbaik pada aset BTC, ETH, dan SOL dengan nilai R^2 masing-masing sebesar 0,9792, 0,9391, dan 0,9539.

Hasil penelitian ini juga didukung oleh studi tinjauan sistematis pada [12] yang menunjukkan bahwa keluarga model GRU dan Bi-GRU memiliki performa yang kompetitif pada berbagai instrumen keuangan. Dalam penelitian tersebut, Bi-GRU unggul pada data indeks saham dan forex, sedangkan GRU memberikan hasil terbaik pada data komoditas. Temuan tersebut menunjukkan bahwa performa model sangat dipengaruhi oleh karakteristik data yang digunakan. Pada penelitian ini, data historis Ethereum lebih sesuai dimodelkan menggunakan GRU dibandingkan Bi-GRU, sehingga menghasilkan nilai error yang lebih rendah dan kemampuan prediksi yang lebih baik.

Di sisi lain, beberapa penelitian menunjukkan bahwa model yang lebih kompleks dapat memberikan performa yang lebih unggul pada kondisi tertentu. Penelitian pada [13] menunjukkan bahwa Bi-LSTM memperoleh nilai MAPE terendah pada prediksi BTC, ETH, dan LTC. Penelitian pada [11] menunjukkan bahwa model Hybrid CNN-LSTM-GRU menghasilkan performa terbaik dengan RMSE sebesar 0,1089 dan R^2 sebesar 0,9913. Penelitian pada [29] juga menemukan bahwa Transformer memberikan hasil terbaik pada indeks FTSE

100, S&P 500, dan HSI dibandingkan RNN, LSTM, BiLSTM, dan GRU. Selain itu, studi tinjauan sistematis pada [15] menunjukkan bahwa pendekatan Hybrid dan Deep Reinforcement Learning mampu menghasilkan profit yang lebih tinggi dibandingkan model prediksi konvensional.

Meskipun demikian, penggunaan model yang lebih kompleks tidak selalu menghasilkan peningkatan performa pada seluruh jenis data. Hasil penelitian ini menunjukkan bahwa model GRU yang memiliki arsitektur lebih sederhana mampu memberikan hasil yang lebih baik dibandingkan Bi-GRU pada data harga Ethereum. Temuan ini mengindikasikan bahwa keberhasilan suatu model tidak hanya ditentukan oleh tingkat kompleksitasnya, tetapi juga oleh kesesuaian antara karakteristik data dan arsitektur model yang digunakan.

Dibandingkan dengan penelitian-penelitian sebelumnya, penelitian ini menggunakan rentang data yang lebih panjang, yaitu data harian Ethereum dari 1 Januari 2016 hingga 17 Januari 2026 dengan jumlah lebih dari 3.600 data. Selain menggunakan metrik RMSE, MAE, MSE, dan R² yang umum digunakan pada penelitian terdahulu [4], [5], [14], dan [28], penelitian ini juga menambahkan metrik Explained Variance untuk memberikan gambaran yang lebih komprehensif mengenai kemampuan model dalam menjelaskan variasi data. Hasil yang diperoleh menunjukkan bahwa model GRU mampu mencapai nilai R² sebesar 0,9751 dan Explained Variance sebesar 0,9763, yang mengindikasikan kemampuan yang sangat baik dalam menangkap pola pergerakan harga Ethereum.

Perbandingan hasil penelitian ini dengan penelitian-penelitian terdahulu disajikan pada Tabel 3. Tabel tersebut menunjukkan bahwa model GRU secara konsisten memberikan performa yang kompetitif pada berbagai studi prediksi cryptocurrency. Dalam konteks penelitian ini, model GRU terbukti lebih unggul dibandingkan Bi-GRU berdasarkan nilai RMSE, MAE, MSE, dan R² yang diperoleh. Dengan demikian, posisi penelitian ini memperkuat temuan-temuan sebelumnya bahwa GRU merupakan salah satu metode yang efektif dan andal untuk prediksi harga cryptocurrency, khususnya Ethereum, meskipun berbagai pendekatan yang lebih kompleks seperti Bi-LSTM, Transformer, maupun model hybrid juga menunjukkan potensi yang tinggi pada dataset dan kondisi tertentu.

Tabel 3 Rangkuman penelitian terhadulu dan penelitian saat ini

Peneliti	Data	Metode	Evaluasi	Hasil
[6]	Data historis harian ETH (Yahoo Finance), 1 Jan 2019 – 30 Apr 2022, 1.216 data	ARIMA	Black Box (fungsional) Testing	Prediksi berhasil, tidak dilaporkan evaluasi matriks.
[2]	Data harian ETH (Kaggle), Agustus 2015 – September 2021, 2.240 data	Backpropagation Neural Network (BNN) 3 arsitektur: 3-8-1, 3-9-1, 3-10-1	MAPE	MAPE BNN 3-8-1 = 1.4694%, MAPE BNN 3-9-1 = 1.4839%, MAPE BNN 3-10-1 = 1.4727%.
[30]	Data harian BTC & ETH (investing.com), 1 Jan 2018 – 31 Des 2021, 1.461 data	Gated Recurrent Unit (GRU) dengan variasi window size	MAPE	Window size terbaik = 2. Akurasi ETH: 1 bulan = 90.15%, 6 bulan = 76.88%, 12 bulan = 66.09%.
[4]	Data per jam BTC & ETH (cryptodatadownload.com): BTC 79.042 data (2015–2024), ETH 74.266 data (2016–2024)	LSTM dan GRU (5 layer, dropout 0.2, Adam optimizer, early stopping)	MAPE, RMSE, R ²	ETH – GRU: MAPE=0.45%, RMSE=20.89, R ² =0.9983. ETH – LSTM: MAPE=0.49%, RMSE=22.29, R ² =0.9980.
[5]	Data harian ETH (Yahoo Finance), 1 Jan 2021 – 1 Jul 2025, 1.642 data	GRU (50 neuron, dropout 0.2, Adam, 70 epoch) dan XGBoost (1000 estimator, LR=0.05)	RMSE, R ²	GRU:RMSE=101.37, R ² =0.9718. XGBoost: RMSE=107.83, R ² =0.9656.

Peneliti	Data	Metode	Evaluasi	Hasil
[12]	BTC, ETH, LTC	LSTM, GRU, Bi-LSTM	RMSE, MAPE	BTC – Bi-LSTM: MAPE = 0,036%. LTC – Bi-LSTM: MAPE = 0,041%. ETH – Bi-LSTM: MAPE = 0,124%.
[31]	BTC, ETH	LSTM, GRU	MAPE, RMSE, R^2	ETH – GRU: MAPE = 0,45%, RMSE = 20,89, $R^2 = 0,9983$. ETH – LSTM: MAPE = 0,49%, RMSE = 22,29, $R^2 = 0,9980$.
[11]	Data harga Perak (XAGg/TRY)	CNN, LSTM, GRU, dan Hybrid CNN-LSTM-GRU	RMSE, MAE, MAPE, R^2 , MASE, SMAPE	Hybrid CNN-LSTM-GRU: RMSE = 0,1089, MAE = 1,4789%, $R^2 = 0,9913$.
[29]	Data Shanghai Composite Index	LASSO-LSTM/GRU dan PCA-LSTM/GRU	MSE, RMSE, MAE	LASSO: MSE \approx 733. PCA: MSE > 3000.
[15]	58 studi dalam tinjauan sistematis	GRU, Bi-GRU, dan BERT/Transformer	Median Normalized RMSE dan MAE	Stock Index – Bi-GRU: RMSE = 0,012, MAE = 0,009. Forex – Bi-GRU: RMSE = 0,009, MAE = 0,007. Commodity – GRU: RMSE = 0,015, MAE = 0,012. Cryptocurrency – Transformer Hybrid: RMSE = 0,025, MAE = 0,020.
[27]	Data indeks saham FTSE 100, S&P 500, dan HSI	RNN, LSTM, BiLSTM, GRU, dan Transformer	MAE, MSE, RMSE, Huber Loss, Log-Cosh	TSE100 – Transformer: MAE = 0,0149, RMSE = 0,0197, MSE = 0,038877. FTSE100 – GRU: MAE = 0,0155, RMSE = 0,0200, MSE = 0,040151. S&P500 – Transformer: MAE = 0,0054, RMSE = 0,0077, MSE = 0,005961. S&P500 – GRU: MAE = 0,0062, RMSE = 0,0082, MSE = 0,006669. HSI – Transformer: MAE = 0,0123, RMSE = 0,0165, MSE = 0,027196. HSI – GRU: MAE = 0,0142, RMSE = 0,0178, MSE = 0,031837.
[28]	75 studi dalam tinjauan sistematis	LSTM, GRU, CNN, Transformer, dan Reinforcement Learning	ROI, Profit Rate, RMSE	PPO: Profit = 341,28%. DRL: Profit = 114,4%. Bi-LSTM: RMSE dan MAPE terendah. GRU: Terbaik pada BTC, ETH, dan LTC.
[13]	Data harga (ZEC)	Zcash LSTM (aktivasi linear dan sigmoid), GRU, dan Transformer	MAE	GRU: MAE = 0,0096.

Peneliti	Data	Metode	Evaluasi	Hasil
[14]	Data BTC, ETH, XRP, dan SOL	LSTM, GRU, Hybrid LSTM+GRU, dan SGD Regression	R ² Score, MAE, RMSE	BTC – GRU: R ² = 0,9792, MAE = 0,0144, RMSE = 0,0200. ETH – GRU: R ² = 0,9391, MAE = 0,0200, RMSE = 0,0263. SOL – GRU: R ² = 0,9539, MAE = 0,0207, RMSE = 0,0273. XRP – LSTM-GRU: R ² = 0,9874, MAE = 0,0121, RMSE = 0,0255.
[32]	Data indeks saham DAX, Dow Jones, dan S&P 500	GRU-CNN	MSE, MAE	GRU-CNN: MSE = 0,0023, MAE = 0,0374.
Penelitian ini	Data harian ETH (Yahoo Finance), 1 Jan 2016 – 17 Jan 2026, lebih dari 3.600 data	GRU dan Bi-GRU (Bidirectional GRU)	RMSE, MAE, MSE, R ² , Explained Variance	GRU: RMSE=117.30, MAE=83.99, MSE=13760.29, R ² =0.9751, EV=0.9763. Bi-GRU: RMSE=174.08, MAE=138.53, MSE=30304.70, R ² =0.9452, EV=0.9721.

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, algoritma Gated Recurrent Unit (GRU) berhasil diimplementasikan untuk memprediksi harga penutupan (close price) Ethereum menggunakan data historis periode 9 November 2016 hingga 16 Januari 2026. Hasil evaluasi menunjukkan bahwa model GRU mampu menghasilkan prediksi yang baik dengan nilai R² sebesar 0,96 dan Explained Variance sebesar 0,98, yang mengindikasikan bahwa model dapat menjelaskan sebagian besar variasi harga aktual Ethereum serta mampu menangkap pola pergerakan harga dengan baik. Hasil perbandingan dengan model Bi-GRU menunjukkan bahwa model GRU memberikan performa yang lebih unggul pada dataset yang digunakan dalam penelitian ini. Hal tersebut ditunjukkan oleh nilai RMSE, MAE, dan MSE yang lebih rendah, serta nilai R² yang sedikit lebih tinggi dibandingkan model Bi-GRU. Meskipun pada beberapa titik data Bi-GRU mampu menghasilkan prediksi yang lebih mendekati nilai aktual, secara keseluruhan model GRU menunjukkan tingkat akurasi dan konsistensi yang lebih baik dalam melakukan prediksi harga Ethereum. Selain itu, model prediksi yang dikembangkan telah berhasil diintegrasikan ke dalam aplikasi berbasis web yang dilengkapi dengan rekomendasi sinyal trading berupa buy, sell, dan hold berdasarkan aturan yang telah ditetapkan. Implementasi ini memungkinkan hasil prediksi dapat dimanfaatkan secara lebih praktis melalui antarmuka yang interaktif, responsif, dan mudah diakses oleh pengguna. Dengan demikian, penelitian ini menunjukkan bahwa algoritma GRU memiliki potensi sebagai pendekatan yang efektif dalam mendukung analisis pasar cryptocurrency dan pengambilan keputusan berbasis data. Untuk penelitian selanjutnya, pengembangan dapat dilakukan dengan menambahkan variabel eksternal yang berpotensi memengaruhi pergerakan harga cryptocurrency, memanfaatkan data real-time, serta mengeksplorasi metode hibrida atau kombinasi beberapa model guna meningkatkan akurasi prediksi dan kualitas rekomendasi sinyal trading yang dihasilkan.

Referensi

- [1] J. Akuntansi and B. Rolando, "The Impact of Cryptocurrency on the Traditional Banking System in Indonesia: A Threat or Complement," vol. 5, no. 1, pp. 1–14, 2025.
- [2] U. Kristen, S. Wacana, J. Diponegoro, and K. Sidorejo, "Penerapan Data Mining Untuk Memprediksi Harga Cryptocurrency Ethereum Menggunakan Metode Backpropagation Neural Network 1,2," vol. 10, no. 1, pp. 3–9, 2023.
- [3] M. Alfarizi and D. Lestari, "Predicting Cryptocurrency Prices Using Machine Learning: A Case Study on Bitcoin," vol. 9, no. 6, pp. 3612–3621, 2025.
- [4] R. S. Andromeda, N. Anisa, and S. Winarsih, "Perbandingan Kinerja Metode LSTM dan GRU dalam Prediksi Harga Close Cryptocurrency Performance Comparison of LSTM and GRU Methods in Predicting Cryptocurrency Closing Prices," vol. 14, pp. 366–379, 2025.
- [5] M. F. Reza, T. Informatika, U. Islam, S. Agung, A. Wahid, and A. S. Winarsih, "Implementasi Model Gated Recurrent Unit (Gru) Atau Extreme Gradient Boosting (Xgboost) Untuk Prediksi Harga," vol. 3, no. 1, pp. 209–222, 2025.
- [6] K. S. Zamzami, M. Ayu, D. Widyadara, and A. B. Setiawan, "Aplikasi Prediksi Harga Ethereum Menggunakan Metode ARIMA," pp. 302–307, 2022.

- [7] X. Kong, Z. Chen, W. Liu, K. Ning, L. Zhang, and S. Muhammad, *Deep learning for time series forecasting : a survey*, vol. 16, no. 7. Springer Berlin Heidelberg, 2025. doi: 10.1007/s13042-025-02560-w.
- [8] I. D. Mienye, "A Comprehensive Review of Deep Learning : Architectures , Recent Advances , and Applications," 2024.
- [9] Cho et al., "Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation," 2014.
- [10] Y. Duan, Y. Liu, Y. Wang, S. Ren, and Y. Wang, "Improved BIGRU Model and Its Application in Stock Price Forecasting," pp. 1–19, 2023.
- [11] N. Aulia, "Prediksi Harga Ethereum Berdasarkan Informasi Blockchain Menggunakan Metode Long Short Term Memory," 2020.
- [12] A. Shukla, "Journal of Artificial Intelligence & Cloud Computing Modern JavaScript Frameworks and JavaScript ' s Future as a Full-Stack Programming Language," vol. 2, no. 4, pp. 1–5.
- [13] A. F. Hakim, Y. Irawan, and R. R. Setiawan, "Implementation of the Crisp-Dm Methodology and Naive Bayes Algorithm on A Raw Material Requirement Prediction System to Reduce Food Waste (Case Study : Adamsafee Bakery , Resto , & Cafe)," vol. 18, no. 2, pp. 968–983, 2025.
- [14] U. D. Nuswantoro, "Pengembangan Web Service Menggunakan Framework Fastapi Untuk Meningkatkan Kemudahan Integrasi Sistem Informasi Akademik Multiplatform," vol. 12, no. 2, pp. 149–157, 2024.
- [15] H. Hewamalage, K. Ackermann, and C. Bergmeir, "Forecast evaluation for data scientists : common pitfalls and best practices," *Data Min. Knowl. Discov.*, vol. 37, no. 2, pp. 788–832, 2023, doi: 10.1007/s10618-022-00894-5.
- [16] DataSolut, "CRISP-DM Standard Process for Data Mining."
- [17] R. R. Laska and A. M. Yolanda, "A Comparative Study of Z-Score and Min-Max Normalization for Rainfall Classification in Pekanbaru," vol. 2024, no. April, 2024.
- [18] M. A. A. P. Mahmud, P. K. Saha, K. D. Gupta, and Z. Siddique, "Effect of Data Scaling Methods on Machine Learning Algorithms and Model Performance," pp. 5–9, 2021.
- [19] C. Alkahfi, A. Kurnia, and A. Saefuddin, "Perbandingan Kinerja Model Berbasis RNN pada Peramalan Data Ekonomi dan Keuangan Indonesia," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1235–1243, 2024, doi: 10.57152/malcom.v4i4.1415.
- [20] R. Jonathan and Suprihadi, "Development of Front-End Web Applications Utilizing Single Page Application Framework and React.js Library," *International Journal Software Engineering and Computer Science (IJECS)*, vol. 3, no. 3, pp. 529–536, 2023, doi: 10.35870/ijsecs.v3i3.1943.
- [21] Muhammad Romzi and Budi Kurniawan, "Implementasi Pemrograman Python Menggunakan Visual Studio Code," *Jik*, vol. XI, no. 2, pp. 1–9, 2020. [Online]. Available: www.python.org
- [22] P. L. Seabe and others, "Cryptocurrency Price Prediction Using Deep Learning Models: A Comparative Study of LSTM, GRU, and Bi-LSTM," *SAIEE Research Journal*, vol. 114, no. 2, pp. 45–53, 2023.
- [23] A. Yunizar, T. Rismawan, D. Marisa Midyanti, J. Reayasa Sistem Komputer, and F. H. MIPA Universitas Tanjungpura Jalan Hadari Nawawi Pontianak, "Penerapan Metode Recurrent Neural Network Model Gated Recurrent Unit Untuk Prediksi Harga Cryptocurrency," 2023.
- [24] R. Satria A. and N. A. S. W., "Komparasi Algoritma LSTM dan GRU dalam Memprediksi Harga Aset Kripto Bitcoin dan Ethereum," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 9, no. 1, pp. 112–120, 2025.
- [25] Y. E. Gür, "Precious Metals Price Forecasting Using Hybrid Deep Learning Models: The Case of Silver (XAG/TRY)," *J. Behav. Exp. Finance*, vol. 41, p. 100892, 2024.
- [26] Y. Gao, R. Wang, and E. Zhou, "Stock Index Forecasting Based on Dimension Reduction and Deep Learning: A LASSO-LSTM and LASSO-GRU Approach," *Knowl. Based. Syst.*, vol. 223, p. 107056, 2021.
- [27] Z. Y. Shehu and others, "Deep Learning for Financial Time Series Forecasting: A Systematic Review of GRU, Bi-GRU, and Transformer Models (2020–2025)," *Artif. Intell. Rev.*, vol. 59, no. 3, p. 142, 2026.
- [28] T. O. Kehinde and others, "Evaluating Sequential Deep Learning Models and Transformer Networks for Global Stock Index Prediction," *Expert Syst. Appl.*, vol. 215, p. 119312, 2023.
- [29] S. Ataei and others, "Deep Reinforcement Learning versus Sequence Models in Financial Trading: A Systematic Review of 75 Studies," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 36, no. 4, pp. 2145–2158, 2025.
- [30] J. Lian, "The Impact of Activation Functions on Deep Learning Performance: Forecasting Zcash Price Volatility," *J. Comput. Sci. Technol.*, vol. 39, no. 2, pp. 312–325, 2024.
- [31] A. D. Gbadebo, "Comparative Analysis of Hybrid Deep Learning and Stochastic Gradient Descent Regression in Multi-Cryptocurrency Price Prediction," *Appl. Soft Comput.*, vol. 152, p. 111204, 2025.
- [32] H. Song and H. Choi, "Forecasting Stock Market Indices Using the Recurrent Neural Network Based Hybrid Models: CNN-LSTM, GRU-CNN, and Ensemble Models," *Applied Sciences*, vol. 13, no. 7, 2023, doi: 10.3390/app13074644.