

Analisis Komparatif Model ARIMA, LSTM, dan GRU dalam *Forecasting* Harga Bitcoin Berbasis *Streamlit*

Ridwana Septian Nurardian¹, Albert Riyandi²

^{1,2}Informatika, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika

¹15220780@bsi.ac.id*, ²albert.abe@bsi.ac.id

Abstract

Bitcoin is a cryptocurrency asset characterized by high volatility and non-linear movement patterns that trigger sudden market risks. Considering that the majority of previous studies have solely focused on mathematical metric evaluations without providing practical solutions, this study aims to compare the performance of the conventional statistical model Autoregressive Integrated Moving Average (ARIMA) with Deep Learning architectures, namely Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU), and to implement the best-performing model into an interactive dashboard using Streamlit. The dataset used encompasses daily Bitcoin closing prices for the 2020–2026 period. The methodology includes data preprocessing, MinMaxScaler normalization, sequential data generation using a 30-day sliding window technique, chronological data splitting (80:20), and evaluation using MAE, RMSE, MAPE, Accuracy, and R² Score. Experimental results prove that ARIMA fails to adapt to non-stationary data, whereas GRU outperforms LSTM in terms of architectural efficiency and precision. The GRU model achieved the best performance with an MAE of IDR 34,773,098.88, an RMSE of IDR 46,684,832.94, a MAPE of 2.26%, an Accuracy of 97.74%, and an R² Score of 0.9661. The GRU model was then successfully implemented into a Streamlit web dashboard that facilitates the real-time visualization of historical and predicted prices. In conclusion, the GRU architecture is the most effective and efficient approach for Bitcoin price forecasting, successfully bridging the gap between theoretical analysis and the availability of practical applications.

Keywords: ARIMA, LSTM, GRU, forecasting price bitcoin, streamlit

Abstrak

Bitcoin merupakan aset kripto dengan karakteristik volatilitas tinggi dan pola pergerakan non-linear yang memicu risiko pasar secara tiba-tiba. Mengingat mayoritas studi terdahulu hanya berfokus pada evaluasi metrik matematis tanpa memberikan solusi praktis, penelitian ini bertujuan membandingkan kinerja model statistik konvensional *Autoregressive Integrated Moving Average* (ARIMA) dengan arsitektur *Deep Learning* yakni *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU), serta mengimplementasikan model terbaik ke dalam *dashboard* interaktif berbasis Streamlit. Dataset yang digunakan mencakup harga penutupan harian Bitcoin periode 2020–2026. Metodologi meliputi *preprocessing* data, normalisasi *MinMaxScaler*, pembentukan data sekuensial dengan teknik *sliding window* 30 hari, pembagian data secara kronologis (80:20), hingga evaluasi menggunakan MAE, RMSE, MAPE, Akurasi, dan R² Score. Hasil eksperimen membuktikan bahwa ARIMA gagal beradaptasi terhadap data non-stasioner, sedangkan GRU mengungguli LSTM dari sisi efisiensi arsitektur dan presisi. Model GRU memperoleh performa terbaik dengan MAE Rp34,773,098.88, RMSE Rp46,684,832.94, MAPE 2.26%, Akurasi 97,74%, dan R² Score 0,9661. Model GRU kemudian berhasil diimplementasikan ke dalam *web dashboard* Streamlit yang memfasilitasi visualisasi perbandingan harga historis dan prediksi secara *real-time*. Kesimpulannya, arsitektur GRU merupakan pendekatan paling efektif dan efisien untuk peramalan harga Bitcoin, sekaligus berhasil menjembatani kesenjangan antara analisis teoritis dan ketersediaan aplikasi praktis.

Kata kunci: ARIMA, LSTM, GRU, forecasting harga bitcoin, streamlit

©This work is licensed under a Creative Commons Attribution -ShareAlike 4.0 International License

1. Pendahuluan

Transformasi digital telah mendorong lahirnya instrumen investasi inovatif, salah satunya aset kripto seperti Bitcoin yang didukung oleh teknologi blockchain dan sistem transaksi terdesentralisasi [1], [2]. Bitcoin kini tidak hanya dipandang sebagai alat pembayaran, tetapi juga sebagai komoditas investasi yang berpengaruh terhadap pasar aset digital global [3], [4].

Namun, Bitcoin memiliki tingkat volatilitas yang sangat tinggi, sehingga fluktuasi harga dapat terjadi dalam waktu singkat dan menimbulkan risiko besar bagi investor [5]. Kondisi ini terlihat pada kontraksi nilai transaksi kripto di Indonesia dari Rp650,61 triliun pada 2024 menjadi Rp482,23 triliun pada 2025 akibat

volatilitas pasar [6]. Selain itu, penurunan harga Bitcoin ke level \$81.000 memicu likuidasi massal senilai \$1,7 miliar dan berdampak pada lebih dari 240.000 *trader* dalam satu hari [7]. Tingginya volatilitas pasar kripto dipicu oleh sentimen *risk-off global* dan fenomena likuidasi massal yang kerap terjadi secara mendadak [8]. Penelitian oleh Rodrigues & Machado (2025) mengonfirmasi bahwa fluktuasi harga dalam frekuensi tinggi (*high-frequency data*) menyebabkan metode estimasi tradisional kehilangan keandalan prediksinya akibat fenomena *noise* pasar yang dominan [9]. Fenomena tersebut menunjukkan bahwa pengambilan keputusan investasi tidak dapat hanya mengandalkan intuisi, melainkan memerlukan pendekatan komputasional berbasis data historis untuk menghasilkan peramalan harga yang lebih akurat [10],

[11], [12]. Lebih lanjut, pergerakan harga Bitcoin yang kaotis menuntut penggunaan sistem berbasis kecerdasan buatan dibandingkan metode prediktif konvensional untuk memitigasi risiko *trading* secara optimal [13].


Dalam bidang Informatika, peramalan data deret waktu (*time series*) telah banyak dieksplorasi menggunakan model statistik maupun *Deep Learning* [14]. Keterbatasan model statistik konvensional seperti ARIMA terletak pada asumsi stasioneritas dan hubungan linear dasar, sehingga model ini gagal mengantisipasi tren non-linear ekstrem yang tidak memiliki pola musiman berulang pada pasar kripto [15], [16]. Beberapa penelitian terdahulu telah membandingkan performa ARIMA dengan LSTM [17] serta mengevaluasi varian arsitektur *Recurrent Neural Network* (RNN), seperti LSTM dan GRU [18]. Penelitian lain juga menunjukkan bahwa meskipun ARIMA cukup stabil untuk prediksi jangka pendek pada data stasioner, arsitektur RNN, khususnya GRU, lebih adaptif dalam menangkap volatilitas harga Bitcoin secara *real-time* [19], [20]. Namun, terdapat kelemahan (*research gap*) pada studi-studi terdahulu. Mayoritas penelitian berfokus pada komparasi model yang sejenis atau dievaluasi secara terpisah, serta hanya berhenti pada penyajian metrik evaluasi matematis (seperti RMSE atau MAE) tanpa memberikan solusi aplikatif bagi pengguna akhir [21]. Hasil prediksi dari model yang kompleks tersebut menjadi sulit diinterpretasikan dan diakses secara langsung oleh investor awam.

Untuk menjembatani kesenjangan tersebut, kebaruan (*novelty*) dari penelitian ini terletak pada kombinasi dua aspek utama. Pertama, melakukan komparasi komprehensif secara silang antara model statistik konvensional (ARIMA) yang unggul pada data linear, berhadapan langsung dengan dua model *Deep Learning* (LSTM dan GRU) yang adaptif terhadap data kronologis non-linear, menggunakan dataset Bitcoin periode terbaru yang sangat fluktuatif. Kedua, mengimplementasikan model dengan performa prediksi terbaik secara langsung ke dalam sebuah *web dashboard* interaktif berbasis Streamlit [22], [23]. Melalui pendekatan ini, visualisasi hasil prediksi harga Bitcoin tidak hanya sekadar menyajikan pembuktian akademis terkait tingkat akurasi algoritma, melainkan juga menyediakan *tools* yang interaktif dan mudah dipahami oleh pengguna secara *real-time* untuk meminimalisir risiko investasi.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk membandingkan performa model ARIMA, *Long Short-Term Memory* (LSTM), dan *Gated Recurrent Unit* (GRU) dalam memprediksi harga Bitcoin. Tahapan penelitian mengacu pada proses *Knowledge Discovery in Database* (KDD), yang meliputi pengumpulan data, pemahaman data, *preprocessing*, transformasi data,

pemodelan, evaluasi, dan implementasi sistem [24]. Pendekatan ini digunakan karena penelitian berfokus pada pengukuran performa model secara objektif menggunakan metrik evaluasi numerik.



Gambar 1. Alur Penelitian

Berdasarkan Gambar 1, penelitian dimulai dari tahap pengumpulan data historis Bitcoin, kemudian dilanjutkan dengan *data understanding* untuk memahami struktur dan karakteristik dataset. Setelah itu dilakukan *preprocessing* data, normalisasi, pembentukan data sekuensial menggunakan metode *sliding window*, pembagian data *training* dan *testing*, pemodelan menggunakan ARIMA, LSTM, dan GRU, evaluasi model, serta implementasi hasil prediksi ke dalam *dashboard* interaktif berbasis *Streamlit*.

Data yang digunakan merupakan data sekunder berbentuk deret waktu atau *time series* harga Bitcoin (BTC/USD) yang diperoleh dari *CoinMarketCap*. Dataset ini mencakup periode historis mulai dari 1 Januari 2020 hingga 8 Mei 2026 dengan granularitas harian (*daily*), yang secara keseluruhan menghasilkan total observasi sebanyak 2.320 baris data. Dataset terdiri dari beberapa fitur utama, yaitu tanggal, harga pembukaan, harga tertinggi, harga terendah, harga penutupan, volume, dan kapitalisasi pasar. Data historis Bitcoin digunakan karena memiliki karakteristik volatil, non-linear, dan berurutan berdasarkan waktu, sehingga sesuai untuk penelitian peramalan harga aset kripto [17] [18]. Dalam penelitian ini, fitur Buka, Tinggi, dan Rendah digunakan sebagai variabel *input*,

sedangkan fitur Tutup digunakan sebagai target prediksi.

Tahap *preprocessing* dilakukan untuk memastikan data siap digunakan dalam proses pemodelan. Proses ini meliputi pembersihan data, konversi tipe data, pengurutan data berdasarkan tanggal, pengecekan *missing value*, serta penghapusan data duplikat. Kolom harga yang masih berbentuk teks dibersihkan dari simbol mata uang, tanda koma, dan spasi, kemudian dikonversi menjadi tipe data numerik. Karena harga Bitcoin memiliki rentang nilai yang besar, normalisasi dilakukan menggunakan MinMaxScaler agar nilai data berada pada rentang 0 sampai 1. Normalisasi ini menjadi krusial karena rentang nilai fluktuasi harga Bitcoin yang sangat lebar dapat menyebabkan masalah *exploding/vanishing gradient* saat proses *backpropagation* [25]. Normalisasi diperlukan untuk membantu proses pelatihan model *deep learning* agar lebih stabil dan tidak dipengaruhi oleh perbedaan skala antarfitur [26].

Setelah proses *preprocessing*, data *time series* diubah menjadi bentuk *supervised learning* menggunakan metode *sliding window*. Pada penelitian ini, *window size* yang digunakan adalah 30 hari, sehingga data historis selama 30 hari digunakan sebagai *input* untuk memprediksi harga penutupan pada hari berikutnya. Sejalan dengan temuan Maulana et al. (2026) dan Alfarizi & Lestarini (2025), pembentukan data sekuensial dengan teknik *sliding window* 30 hari secara efektif mentransformasi data mentah menjadi struktur tiga dimensi (*batch size*, *time steps*, *features*) yang dibutuhkan oleh arsitektur LSTM dan GRU untuk mengekstrak dependensi temporal [27] [28]. Teknik *sliding window* digunakan agar model dapat mempelajari pola temporal dari data historis dan menghasilkan struktur *input* tiga dimensi yang sesuai untuk model LSTM dan GRU [29].

Pemodelan dilakukan menggunakan tiga algoritma, yaitu ARIMA, LSTM, dan GRU. Sebagai model statistik dan *baseline*, ARIMA dikonfigurasi dengan orde parameter (1, 1, 1). Pemilihan orde ini mencakup komponen *autoregressive* ($p=1$), tingkat *differencing* untuk membentuk stasioneritas data ($d=1$), dan rata-rata bergerak atau *moving average* ($q=1$) yang optimal untuk pemodelan deret waktu dasar [30]. Sementara itu, model *Deep Learning* dibangun dengan penyesuaian *hyperparameter* secara spesifik. Model LSTM dibangun menggunakan arsitektur dua lapisan tersembunyi (*hidden layer*) yang masing-masing terdiri dari 50 *neuron*. Guna mencegah *overfitting*, diterapkan lapisan *Dropout* dengan nilai 0.2, yang diakhiri dengan satu *Dense layer* (1 *neuron*) sebagai *output* prediksi. Konfigurasi serupa juga diterapkan pada arsitektur GRU, yakni dua *layer* GRU dengan masing-masing 50 *neuron* serta lapisan *Dropout* 0.2. Kedua model *Deep Learning* ini dilatih menggunakan fungsi kerugian *Mean Squared Error* (MSE), algoritma *optimizer* Adam dengan tingkat pembelajaran (*learning rate*) sebesar 0,001, ukuran *batch* (*batch size*) 32, dan

dijalankan selama 50 *epoch*. Penentuan *hyperparameter* ini dirancang untuk mencapai keseimbangan antara akurasi dan efisiensi komputasi, di mana *optimizer* Adam dengan *learning rate* 0,001 dipilih karena kemampuannya menyesuaikan tingkat pembelajaran secara adaptif untuk setiap parameter, sedangkan penerapan *Dropout layer* 0,2 terbukti efektif mencegah *overfitting* pada pelatihan sekuensial. Pemilihan konfigurasi ini didasarkan pada tinjauan literatur terdahulu yang membuktikan stabilitas parameter tersebut pada volatilitas kripto [4] [5].

Dataset dibagi menjadi data latih dan data uji dengan rasio 80:20 secara kronologis. Pembagian dilakukan tanpa pengacakan karena data yang digunakan merupakan data *time series*, sehingga urutan waktu harus tetap dipertahankan untuk menghindari *look-ahead bias*. Pembagian dataset dengan rasio 80:20 secara ketat berdasarkan urutan waktu (*chronological train-test split*) tanpa pengacakan dilakukan untuk menjamin tidak terjadinya *look-ahead bias*, sehingga evaluasi performa model mencerminkan kondisi pengujian pasar yang sesungguhnya [31]. Data *training* digunakan untuk melatih model dalam mempelajari pola historis harga Bitcoin, sedangkan data *testing* digunakan untuk menguji kemampuan model dalam memprediksi data baru yang belum pernah dipelajari sebelumnya. Model ARIMA dilatih menggunakan data harga penutupan, sedangkan model LSTM dan GRU dilatih menggunakan data sekuensial multivariat hasil transformasi *sliding window*.

Evaluasi model dilakukan dengan membandingkan nilai prediksi terhadap data aktual pada data uji. Metrik evaluasi yang digunakan meliputi *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), akurasi, dan R^2 *Score*. Metrik tersebut digunakan untuk mengukur tingkat kesalahan prediksi dan kemampuan model dalam menjelaskan variasi data aktual [32] [33]. Model dengan nilai MAE, RMSE, dan MAPE paling rendah serta nilai R^2 *Score* paling tinggi dipilih sebagai model dengan performa terbaik.

Tahap akhir penelitian adalah implementasi hasil prediksi ke dalam *dashboard* interaktif berbasis Streamlit. Model hasil pelatihan disimpan dalam format .keras atau .pkl, kemudian dimuat kembali pada aplikasi untuk menghasilkan prediksi. Streamlit digunakan karena mampu menyajikan hasil analisis data dan model *machine learning* dalam bentuk antarmuka web yang interaktif, sehingga memudahkan pengguna dalam memahami hasil prediksi tanpa harus berinteraksi langsung dengan kode program [22] [34].

3. Hasil dan Pembahasan

Tanggal	Buka	Tinggi	Rendah	Tutup	Volume	Kapitalisasi pasar
0 - 2026-05-08	Rp 1.387.879.210,06	Rp 1.395.502.588,88	Rp 1.376.183.521,61	Rp 1.383.433.741,86	Rp 586.123.711.347,164	Rp 27.855.386.245.238,412
1 - 2026-05-07	Rp 1.410.160.443,63	Rp 1.415.452.076,37	Rp 1.378.107.805,19	Rp 1.387.885.601,61	Rp 639.563.323.674,871	Rp 27.749.847.370.731,600
2 - 2026-05-06	Rp 1.408.158.425,00	Rp 1.435.970.982,59	Rp 1.405.031.476,41	Rp 1.410.137.587,67	Rp 726.458.007.830,070	Rp 28.372.906.150.572,896
3 - 2026-05-05	Rp 1.387.906.354,43	Rp 1.422.438.452,33	Rp 1.387.275.239,92	Rp 1.408.094.281,58	Rp 690.270.084.236,308	Rp 28.178.551.630.942,140
4 - 2026-05-04	Rp 1.351.444.882,07	Rp 1.405.807.748,38	Rp 1.360.555.359,39	Rp 1.387.976.484,38	Rp 941.690.042.213,930	Rp 27.706.325.047.308,958


Gambar 2. Dataset Awal

Tahap awal penelitian ini melibatkan pengumpulan dan pemuatan data historis harga Bitcoin dari *CoinMarketCap* yang mencakup berbagai kondisi pasar fluktuatif. Gambar 2 menampilkan dataset awal yang terdiri dari fitur tanggal, harga pembukaan, harga tertinggi, harga terendah, harga penutupan, volume, dan kapitalisasi pasar, dengan harga penutupan digunakan sebagai target prediksi utama.




Gambar 3. Grafik Tren Harga Bitcoin

Analisis eksplorasi data (*Exploratory Data Analysis*) pada Gambar 3 memperlihatkan adanya tren fluktuasi harga yang cukup besar dan dinamis, baik pada fase kenaikan maupun penurunan, yang menunjukkan bahwa harga Bitcoin memiliki karakteristik volatilitas historis yang sangat ekstrem.



Gambar 4. Heatmap Korelasi


Lebih lanjut, analisis korelasi pada Gambar 4 membuktikan bahwa fitur harga pembukaan, tertinggi, dan terendah memiliki korelasi linier yang sangat kuat terhadap harga penutupan dengan nilai mendekati 1,00, sehingga ketiga fitur tersebut ditetapkan sebagai variabel masukan multivariat pada pemodelan *Deep Learning*.



Gambar 5. Visualisasi Split Data *Training* dan *Testing*

Setelah melalui tahap pra-pemrosesan data, pembersihan, dan normalisasi menggunakan *MinMaxScaler*, data ditransformasi menggunakan metode *sliding window* 30 hari. Visualisasi pada

Gambar 5 menunjukkan pembagian dataset secara kronologis dengan rasio 80:20 menjadi data latih dan data uji untuk menjamin tidak terjadinya *look-ahead bias* atau kebocoran informasi masa depan ke masa lalu.



Gambar 6. Grafik Prediksi GRU

Hasil pengujian dan evaluasi performa yang divisualisasikan pada Gambar 6 membuktikan bahwa prediksi model *Gated Recurrent Unit* (GRU) sangat adaptif dan hampir menempel pada garis harga aktual di sepanjang periode pengujian. Model ini berhasil mencatatkan kinerja terbaik dengan tingkat kesalahan terendah, yaitu *Mean Absolute Percentage Error* (MAPE) sebesar 2,26% dan *Mean Absolute Error* (MAE) sebesar Rp34,773,098.88, serta mampu menjelaskan variasi data tertinggi dengan nilai R^2 Score mencapai 0,9661.



Gambar 7. Grafik Prediksi LSTM

Sebagai perbandingan, Gambar 7 memperlihatkan bahwa model *Long Short-Term Memory* (LSTM) yang juga dilatih dengan *hyperparameter* serupa mampu mengikuti pola pergerakan harga aktual dengan deviasi kesalahan yang relatif kecil, mencatatkan MAPE sebesar 2,86%.



Gambar 8. Grafik Prediksi ARIMA

Sebaliknya, model statistik klasik *Autoregressive Integrated Moving Average* (ARIMA) pada Gambar 8 menunjukkan grafik prediksi yang cenderung

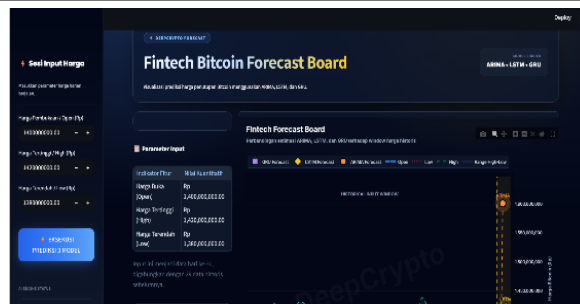
menghasilkan proyeksi lebih datar jika dibandingkan dengan harga aktual yang bergerak fluktuatif. Hal ini mengindikasikan keterbatasan inheren model ARIMA dalam mengikuti perubahan harga yang dinamis akibat karakteristiknya yang hanya sesuai untuk data berpola linear, sehingga menghasilkan tingkat kesalahan tertinggi dengan MAPE mencapai 14,93% dan nilai R -Squared negatif sebesar -0,0136.

REKAPITULASI TABEL METRIK EVALUASI MODEL					
Model	MAE (Rp)	RMSE (Rp)	MAPE (%)	Akurasi (%)	R2 Score
ARIMA	218,905,777.62	255,243,172.49	14.93%	85.07%	-0.0136
LSTM	43,074,581.68	57,568,703.76	2.86%	97.14%	0.9484
GRU	34,773,098.88	46,684,832.94	2.26%	97.74%	0.9661

Gambar 9. Perbandingan Model

Ringkasan perbandingan metrik evaluasi dari ketiga model tersebut pada Gambar 9 secara jelas mempertegas dominasi arsitektur jaringan saraf tiruan berpagar. Keunggulan telak model GRU jika dikomparasikan dengan LSTM dan ARIMA bersumber dari efisiensi arsitektur matematis dan mekanisme pengolahan informasinya. Meskipun LSTM dan GRU sama-sama dirancang untuk mengatasi masalah *vanishing gradient* pada deret waktu kronologis, GRU memiliki arsitektur yang lebih ringkas dengan menyatukan *cell state* dan *hidden state* serta hanya menggunakan dua gerbang utama, yakni *Update Gate* dan *Reset Gate*. Konfigurasi ini membuat GRU memiliki jumlah parameter yang lebih sedikit, yang terbukti sangat tangguh dalam menghindari *overfitting* terhadap *noise* fluktuasi harian pada data aset kripto yang luar biasa volatil. Tingginya nilai kesalahan pada ARIMA membuktikan bahwa asumsi stasioneritas linier dan ketergantungan masa lalu gagal beradaptasi dengan pola kaotis serta non-linear ekstrem dari pergerakan harga Bitcoin yang tidak memiliki siklus musiman berulang.

Temuan dalam penelitian ini secara empiris menguatkan berbagai penelitian terdahulu yang menyatakan bahwa varian *Recurrent Neural Network* (RNN) secara konsisten mengungguli model statistik linier dalam peramalan harga kripto. Hasil penelitian juga menunjukkan bahwa pemodelan varian RNN berpagar (*gated RNN*) sangat adaptif dalam mengekstraksi karakteristik pergerakan ekstrem harga Bitcoin [35]. Selain itu, efisiensi parameter GRU yang lebih unggul dibandingkan LSTM dalam menangani prediksi volatilitas harian Bitcoin sejalan dengan berbagai hasil penelitian komparatif pada model *Deep Learning* modern. Berbeda dengan mayoritas penelitian sebelumnya yang hanya berfokus pada evaluasi metrik matematis di lingkungan simulasi luring, penelitian ini berhasil menjembatani kesenjangan implementasi praktis dengan menghadirkan solusi yang lebih aplikatif bagi pengguna.



Gambar 10. Halaman Dashboard

Untuk merealisasikan implementasi praktis, model GRU terbaik disimpan dalam format bobot terkompresi dan diimplementasikan secara langsung ke dalam *web dashboard* interaktif berbasis Streamlit seperti yang ditampilkan pada Gambar 10.



Gambar 11. Halaman Visualisasi Grafik

Dari sudut pandang pengguna akhir, aplikasi ini berfungsi sebagai sistem pendukung keputusan investasi yang mentransformasi metrik statistik rumit menjadi visualisasi grafik tren yang intuitif sebagaimana ditunjukkan pada Gambar 11.

Gambar 12. Halaman Input Prediksi

Melalui panel pada Gambar 12, pengguna dapat melakukan modifikasi parameter *input* harga historis secara dinamis melalui bilah kontrol di sisi antarmuka, yang kemudian memicu sistem untuk menghitung estimasi secara *real-time* tanpa mengharuskan investor awam memiliki pemahaman pemrograman.



Gambar 13. Tampilan Hasil Prediksi

Dari sisi performa komputasi, ukuran berkas bobot GRU yang kecil dikombinasikan dengan arsitektur *Streamlit* menghasilkan efisiensi memori *server* yang signifikan. Hasil akhir berupa estimasi nilai prediksi dalam bentuk nominal angka yang presisi pada Gambar 13 berhasil dieksekusi dengan latensi sangat rendah, menjamin kinerja sistem pendukung keputusan yang sangat responsif di tengah kebutuhan pemantauan fluktuasi pasar yang bergerak cepat untuk memitigasi risiko investasi.

4. Kesimpulan

Penelitian ini menyimpulkan bahwa arsitektur *Deep Learning* (LSTM dan GRU) secara signifikan mengungguli metode statistik konvensional (ARIMA) dalam memprediksi harga Bitcoin yang memiliki karakteristik non-linear dan volatil. Berdasarkan hasil pengujian kuantitatif, GRU terbukti sebagai model peramalan yang paling optimal. Model ini berhasil mencatatkan tingkat kesalahan terendah dengan *Mean Absolute Error* (MAE) sebesar Rp34,773,098.88 *Root Mean Squared Error* (RMSE) 46,684,832.94, dan *Mean Absolute Percentage Error* (MAPE) 2.26%, serta tingkat akurasi penjelasan variasi data tertinggi dengan nilai *R-Squared* (R^2 Score) mencapai 0.9661 dan akurasi 97,74%.

Fakta komputasional ini membuktikan bahwa model GRU mampu menawarkan efisiensi struktur algoritma yang lebih ringkas dibandingkan LSTM, tanpa mengorbankan tingkat presisi prediksinya. Sebagai luaran teknis dari penelitian ini, model peramalan GRU terbaik telah berhasil diimplementasikan ke dalam antarmuka *web dashboard* interaktif berbasis *Streamlit*, yang memfasilitasi visualisasi perbandingan data harga historis dan hasil peramalan secara *real-time*.

Untuk pengembangan lebih lanjut, penelitian selanjutnya disarankan untuk beralih pada pendekatan multivariat dengan menambahkan variabel eksternal seperti sentimen publik, indikator teknikal, serta faktor makroekonomi (misalnya suku bunga). Integrasi metode *Natural Language Processing* (NLP) pada arsitektur GRU juga direkomendasikan untuk menangkap kausalitas fundamental dari pasar. Selain itu, disarankan untuk melakukan pengujian evaluasi pengguna (*user evaluation*) pada tahap implementasi *dashboard* guna memvalidasi secara empiris efektivitas

dan kegunaan sistem tersebut sebagai alat bantu bagi pengguna.

Daftar Rujukan

- [1] J. Chen, "Analysis of Bitcoin Price Prediction Using Machine Learning," *Journal of Risk and Financial Management*, vol. 16, no. 1, Jan. 2023, doi: 10.3390/jrfm16010051.
- [2] N. P. Patel *et al.*, "Fusion in Cryptocurrency Price Prediction: A Decade Survey on Recent Advancements, Architecture, and Potential Future Directions," *IEEE Access*, vol. 10, pp. 34511–34538, 2022, doi: 10.1109/ACCESS.2022.3163023.
- [3] M. J. Hamayel and A. Y. Owda, "A Novel Cryptocurrency Price Prediction Model Using GRU, LSTM and Bi-LSTM Machine Learning Algorithms," *AI (Switzerland)*, vol. 2, no. 4, pp. 477–496, Dec. 2021, doi: 10.3390/ai2040030.
- [4] Ramadhan F and Nathasia N, "Prediksi Harga Dan Kinerja Aset Bitcoin Menggunakan Algoritma Long Short-Term Memory," *Jurnal Fasilkom*, vol. 15, no. 1, pp. 68–76, Apr. 2025, doi: <https://doi.org/10.37859/jf.v15i1.8902>.
- [5] P. Jaquart, D. Dann, and C. Weinhardt, "Short-term bitcoin market prediction via machine learning," *Journal of Finance and Data Science*, vol. 7, pp. 45–66, Mar. 2021, doi: 10.1016/j.jfds.2021.03.001.
- [6] Otoritas Jasa Keuangan, "Pembukaan Bulan Literasi Kripto (BLK) 2026," Apr. 2026. Accessed: Apr. 26, 2026. [Online]. Available: [https://ojk.go.id/id/berita-dan-kegiatan/siaran-pers/Pages/Pembukaan-Bulan-Literasi-Kripto-\(BLK\)-2026.aspx](https://ojk.go.id/id/berita-dan-kegiatan/siaran-pers/Pages/Pembukaan-Bulan-Literasi-Kripto-(BLK)-2026.aspx)
- [7] IUWASH Tangguh, "Bitcoin Anjlok di Bawah USD 90.000 Dampak Perang Dagang Eropa-AS dan Strategi Investor 2026," 2026. Accessed: Apr. 26, 2026. [Online]. Available: <https://iuwashtangguh.or.id/berita-investasi/4623092629/bitcoin-anjlok-di-bawah-usd-90-000-dampak-perang-dagang-eropa-as-dan-strategi-investor-2026/>
- [8] Reku, "BTC Anjlok Tajam, Risk-Off Global & Likuidasi Massal Jadi Bias Kerok," 2026. Accessed: Apr. 26, 2026. [Online]. Available: <https://reku.id/analysis/btc-anjlok-tajam-risk-off-global-likuidasi-massal-jadi-bias-kerok>
- [9] F. Rodrigues and M. Machado, "High-Frequency Cryptocurrency Price Forecasting Using Machine Learning Models: A Comparative Study," *Information (Switzerland)*, vol. 16, no. 4, Apr. 2025, doi: 10.3390/info16040300.
- [10] M. Ahmed, S. A. Suha, F. H. Mahi, and F. U. Ahmed, "EVALUATING THE PERFORMANCE OF BITCOIN PRICE FORECASTING USING MACHINE LEARNING TECHNIQUES ON HISTORICAL DATA," *Informatyka, Automatyka, Pomiary w Gospodarce i Ochronie Srodowiska*, vol. 14, no. 2, pp. 101–108, 2024, doi: 10.35784/iapgos.5657.
- [11] N. Nafisah, Y. Yamasari, and E. Yohannes, "A Performance Comparison of LSTM and GRU Architectures for Forecasting Daily Bitcoin Price Volatility," *JIEET (Journal of Information Engineering and Educational Technology)*, vol. 9, no. 2, pp. 156–167, 2025, doi: 10.26740/jieet.v9n.
- [12] I. P. B. Priadinata, I. G. I. Sudipa, N. P. S. Meinami, I. M. L. Radhitya, and I. K. D. G. Supartha, "Comparative Analysis of LSTM, GRU, and Bi-LSTM Deep Learning Models for Time Series Cryptocurrency Price Forecasting," *sinkron*, vol. 9, no. 3, pp. 1024–1035, Jul. 2025, doi: 10.33395/sinkron.v9i3.14795.
- [13] C. D. Rahmadewi, R. Parlika, and H. Maulana, "Perbandingan Fuzzy Mamdani dan Sugeno dalam Optimasi Trading Bitcoin Berbasis Indikator Teknikal," *JURNAL FASILKOM*, Apr. 2026, doi: <https://doi.org/10.37859/jf.v16i1.11235>.
- [14] Z. I. Ramadhan and H. Widiputra, "Comparative Analysis of Recurrent Neural Network Models Performance in Predicting Bitcoin Prices," *Jurnal RESTI*, vol. 8, no. 3, pp. 377–388, Jun. 2024, doi: <https://doi.org/10.29207/resti.v8i3.5810>.
- [15] A. Bouteska, M. Z. Abedin, P. Hajek, and K. Yuan, "Cryptocurrency price forecasting – A comparative analysis of ensemble learning and deep learning methods," *International Review of Financial Analysis*, vol. 92, Mar. 2024, doi: 10.1016/j.irfa.2023.103055.
- [16] N. Tripathy, S. K. Nayak, and S. Prusty, "A comparative analysis of Silverkite and inter-dependent deep learning models

- for bitcoin price prediction,” *Frontiers in Blockchain*, vol. 7, 2024, doi: 10.3389/fbloc.2024.1346410.
- [17] N. Latif, J. D. Selvam, M. Kapse, V. Sharma, and V. Mahajan, “Comparative Performance of LSTM and ARIMA for the Short-Term Prediction of Bitcoin Prices,” 2023.
- [18] P. L. Seabe, C. R. B. Moutsinga, and E. Pindza, “Forecasting Cryptocurrency Prices Using LSTM, GRU, and Bi-Directional LSTM: A Deep Learning Approach,” *Fractal and Fractional*, vol. 7, no. 2, Feb. 2023, doi: 10.3390/fractalfract7020203.
- [19] I. W. R. Pinastawa, M. G. Pradana, D. S. Setiawan, and A. Izzety, “Comparison of ARIMA and GRU Methods in Predicting Cryptocurrency Price Movements,” *sinkron*, vol. 9, no. 1, pp. 96–105, Jan. 2025, doi: 10.33395/sinkron.v9i1.14235.
- [20] S. Yu, “Comparative analysis of machine learning techniques for cryptocurrency price prediction,” *Applied and Computational Engineering*, vol. 32, no. 1, pp. 1–12, Jan. 2023, doi: 10.54254/2755-2721/32/20230175.
- [21] M. I. Fawzi, T. Ganesha, P. R. Anugrah, M. Zhahran, F. A. Abimanyu, and H. Bimantoro, “Forecasting Bitcoin Price Prediction with Long Short-Term Memory Networks: Implementation and Applications Using Streamlit,” *Jurnal Teknik Informatika (JUTIF)*, vol. 6, no. 5, pp. 2940–2961, Oct. 2025, doi: 10.52436/1.jutif.2025.6.5.5168.
- [22] O. Bhattarai, R. Chaudhary, and G. Gupta, “Time-Series Real-Time Bitcoin Price Prediction using LSTM,” 2023. [Online]. Available: <https://www.coindesk.com/>.
- [23] C. J. C. Jerlin, A. Deepha, and M. M. M. Krishnan, “Bitcoin Price Prediction,” *International Journal of Scientific Research and Engineering Development*, vol. 8, Apr. 2025, [Online]. Available: www.ijrsred.com
- [24] A. Muis *et al.*, *DATA MINING: Konsep, Metode, dan Aplikasi*. PT. FAASLIB SERAMBI MEDIA., 2025. [Online]. Available: <https://faaslibsmmedia.com/>
- [25] W. Mega and Y. I. Sumbadri, “Analysis Of Lstm-Adamax Performance In Bitcoin Price Prediction Using RSI & MACD Indicators,” *IJCSR: The Indonesian Journal of Computer Science Research E*, 2026, doi: 10.37905.
- [26] B. Auffarth, “Machine Learning for Time-Series with Python,” 2021, Accessed: May 06, 2026. [Online]. Available: <https://books.google.co.id/books?id=a7tLEAAQBAJ>
- [27] F. R. M. Muhammad, R. Permatasari, and E. A. R. Najaf, “Bitcoin Price Prediction Using a Deep Learning Approach with an LSTM Algorithm,” *bit-Tech*, vol. 8, no. 3, pp. 3577–3586, Apr. 2026, doi: 10.32877/bt.v8i3.3613.
- [28] M. Alfarizi and D. Lestarini, “Predicting Cryptocurrency Prices Using Machine Learning: A Case Study on Bitcoin,” 2025. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [29] J. Brownlee, “Deep Learning for Time Series Forecasting,” 2018.
- [30] R. J. Hyndman and G. Athanasopoulos, *Forecasting Principles and Practice*. 2018. Accessed: May 06, 2026. [Online]. Available: <https://books.google.co.id/books?id=bBhDwAAQBAJ>
- [31] M. Elamine and A. Ben Abdallah, “Predicting Cryptocurrency Prices with a Hybrid ARIMA and LSTM Model,” *Journal of Telecommunications and the Digital Economy*, vol. 13, no. 1, pp. 98–117, Mar. 2025, doi: 10.18080/jtde.v13n1.1052.
- [32] M. Aswadi and U. Ependi, “Predicting Bitcoin and Ethereum Prices Using the Long Short-Term Memory (LSTM) Model,” *Journal of Information Systems and Informatics*, vol. 7, no. 3, pp. 3046–3061, Sep. 2025, doi: 10.51519/journalisi.v7i3.1228.
- [33] K. Prayoga, S. Alam, and I. Kurniawan, “IMPLEMENTASI LONG SHORT-TERM MEMORY (LSTM) UNTUK FORECASTING HARGA CRYPTOCURRENCY,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 5, Oct. 2025, doi: <https://doi.org/10.36040/jati.v9i5.15048>.
- [34] F. N. Abdullah, R. S. Nurardian, Amelliya, A. S. Saputra, A. W. Saputra, and W. Bismi, “Pengembangan Aplikasi Prediksi Harga Emas Berbasis Web Menggunakan Model Time Series,” *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 10, no. 4, pp. 1127–1136, Sep. 2025, doi: 10.30591/jpit.v10i4.9165.
- [35] G. R. Malik, R. Parlika, and Kartini, “Pemodelan Dataset On-chain pada BiLSTM untuk Prediksi Harga Bitcoin,” *JURNAL FASILKOM*, vol. 16 No 1, Apr. 2026, doi: <https://doi.org/10.37859/jf.v16i1.11275>.