

Perbandingan Kinerja Model LSTM dengan dan tanpa Indeks Fear & Greed dalam Prediksi Harga Bitcoin Berbasis Data Time Series

Mada Rabbani Syah*, Vinna Rahmayanti Setyaning Nastiti

Fakultas Teknik, Program Studi Informatika, Universitas Muhammadiyah Malang, Malang, Indonesia

Email: ¹*madarabbanisyah@webmail.umm.ac.id, ²vinastiti@umm.ac.id

Email Penulis Korespondensi: madarabbanisyah@webmail.umm.ac.id

Submitted: 02/06/2026; Accepted: 30/06/2026; Published: 30/06/2026

Abstrak—Bitcoin adalah aset digital yang sangat fluktuatif, pergerakan harganya dipengaruhi oleh pola pasar historis dan sentimen investor, sehingga prediksi yang akurat menjadi tantangan signifikan bagi pendekatan peramalan konvensional. Studi ini membandingkan kinerja prediktif model Long Short-Term Memory (LSTM) dalam meramalkan harga Bitcoin dalam dua konfigurasi, yaitu tanpa dan dengan integrasi Crypto Fear & Greed Index sebagai fitur sentimen pasar. Dataset terdiri dari data deret waktu yang mencakup harga pembukaan, tertinggi, terendah, dan penutupan yang bersumber dari API CoinGecko, bersama dengan skor sentimen harian yang diambil dari API Alternative.me. Tahapan pra-pemrosesan data meliputi normalisasi menggunakan Min-Max Scaler dan konstruksi urutan menggunakan metode jendela geser, yang keduanya merupakan praktik standar dalam peramalan deret waktu berbasis pembelajaran mendalam. Kinerja model dievaluasi menggunakan Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE) sebagai metrik kesalahan kuantitatif. Hasil eksperimen menunjukkan bahwa model LSTM tanpa Indeks Fear & Greed menghasilkan MAE sebesar 1011,34, RMSE sebesar 1340,55, dan MAPE sebesar 1,20%, sedangkan model yang menggabungkan Indeks Fear & Greed menghasilkan MAE sebesar 979,95, RMSE sebesar 1349,07, dan MAPE sebesar 1,18%. Temuan ini menunjukkan bahwa penyertaan sentimen pasar meningkatkan akurasi prediksi secara keseluruhan, yang tercermin dari penurunan MAE dan MAPE, meskipun terjadi peningkatan marginal pada RMSE. Kontribusi utama penelitian ini adalah memberikan bukti empiris mengenai pengaruh integrasi Crypto Fear & Greed Index sebagai indikator sentimen pasar terhadap peningkatan performa model LSTM dalam prediksi harga Bitcoin, serta menyediakan perbandingan langsung antara model berbasis data historis dan model yang memanfaatkan kombinasi data historis serta sentimen pasar. Studi ini menyimpulkan bahwa menggabungkan pembelajaran mendalam dengan indikator sentimen yang terukur menawarkan kerangka kerja yang lebih komprehensif dan efektif untuk prediksi harga Bitcoin.

Kata Kunci: Bitcoin LSTM; Time Series; Fear Greed Index; Prediksi Harga; Deep Learning

Abstract—Bitcoin is a highly volatile digital asset whose price movements are influenced by historical market patterns and investor sentiment, making accurate prediction a significant challenge for conventional forecasting approaches. This study compares the predictive performance of the Long Short-Term Memory (LSTM) model in forecasting Bitcoin prices under two configurations: without and with the integration of the Crypto Fear & Greed Index as a market sentiment feature. The dataset consists of time series data including opening, highest, lowest, and closing prices obtained from the CoinGecko API, along with daily sentiment scores collected from the Alternative.me API. The data preprocessing stages include normalization using the Min-Max Scaler and sequence construction using the sliding window method, both of which are standard practices in deep learning-based time series forecasting. Model performance was evaluated using Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and Mean Absolute Percentage Error (MAPE) as quantitative error metrics. The experimental results show that the LSTM model without the Fear & Greed Index produced an MAE of 1011.34, an RMSE of 1340.55, and a MAPE of 1.20%, while the model incorporating the Fear & Greed Index achieved an MAE of 979.95, an RMSE of 1349.07, and a MAPE of 1.18%. These findings indicate that the inclusion of market sentiment improves overall prediction accuracy, as reflected by the reduction in MAE and MAPE, despite a marginal increase in RMSE. The main contribution of this study is providing empirical evidence regarding the impact of integrating the Crypto Fear & Greed Index as a market sentiment indicator on improving the performance of LSTM models for Bitcoin price prediction, as well as offering a direct comparison between models based solely on historical price data and models that combine historical price data with market sentiment information. This study concludes that combining deep learning techniques with measurable sentiment indicators provides a more comprehensive and effective framework for Bitcoin price prediction.

Keywords: Bitcoin; LSTM; Time Series; Fear & Greed Index; Price Prediction; Deep Learning

1. PENDAHULUAN

Bitcoin, yang pertama kali diperkenalkan oleh Nakamoto pada tahun 2008, menetapkan konsep sistem uang elektronik peer-to-peer terdesentralisasi yang memungkinkan transaksi tanpa bergantung pada otoritas pusat [1]. Sejak awal kemunculannya, cryptocurrency telah berkembang menjadi kelas aset yang diakui secara global dan berkembang pesat, menarik perhatian luas dari investor individu, institusi, dan pemerintah [1], [11], [24]. Adopsi di dunia nyata telah meluas secara signifikan di El Salvador, jumlah orang yang memiliki dompet Bitcoin telah melampaui jumlah orang yang memiliki akses ke rekening bank tradisional, menunjukkan potensi cryptocurrency sebagai alternatif keuangan inklusif, khususnya di wilayah yang kurang terlayani perbankan [2]. Pada saat yang sama, respons regulasi sangat bervariasi di berbagai yurisdiksi; Tiongkok telah memberlakukan larangan yang semakin ketat terhadap semua aktivitas terkait cryptocurrency [3], sementara Indonesia terus mengembangkan kerangka hukum dan regulasinya sendiri untuk mengatur aset kripto sebagai instrumen investasi digital yang sah [24], [27]. Ketegangan global antara adopsi dan regulasi ini menggarisbawahi posisi unik dan kompleks yang ditempati Bitcoin dalam ekosistem keuangan modern [4], [24], [27].

Volatilitas yang menjadi ciri perilaku harga Bitcoin telah menjadikannya salah satu subjek yang paling menantang namun menarik untuk penelitian prediksi keuangan [11], [18], [26]. Tidak seperti aset keuangan

konvensional, pasar mata uang kripto beroperasi terus menerus tanpa gangguan, sangat sensitif terhadap sentimen publik, dan tidak memiliki mekanisme stabilisasi yang ada di pasar yang diatur [9], [10], [30]. Karakteristik ini membuat metode peramalan statistik tradisional tidak cukup dengan sendirinya, mendorong para peneliti menuju pendekatan yang lebih canggih termasuk teknik pembelajaran mesin dan pembelajaran mendalam [7], [8], [15]. Di antara ini, jaringan Long Short-Term Memory (LSTM) telah menunjukkan kemampuan yang kuat dalam memodelkan data sekuensial dan deret waktu, dan telah banyak diterapkan di berbagai domain prediksi mulai dari harga emas [5] dan arus lalu lintas [6] hingga kualitas udara [19] dan bahkan pola kekeringan [28] dengan hasil yang sangat menjanjikan dalam peramalan harga mata uang kripto [12], [22], [25].

Meskipun semakin banyak penelitian tentang prediksi harga Bitcoin menggunakan model berbasis LSTM, sebagian besar studi yang ada hanya mengandalkan data harga historis seperti harga pembukaan, harga penutupan, volume perdagangan, dan indikator teknis sebagai fitur input [12], [20], [22]. Meskipun pendekatan ini telah menunjukkan kinerja prediksi yang wajar, pendekatan ini sering gagal menangkap pengaruh sentimen pasar pendorong penting pergerakan harga cryptocurrency yang beroperasi secara independen dari pola harga teknis [9], [10], [30]. Beberapa studi telah mengeksplorasi integrasi data sentimen yang berasal dari media sosial dan sumber berita [10], [11], namun penggunaan indikator sentimen yang lebih terstruktur dan terukur masih kurang dieksplorasi. Crypto Fear & Greed Index, yang disediakan oleh Alternative.me [14], menawarkan skor sentimen harian komposit mulai dari 0 (ketakutan ekstrem) hingga 100 (keserakahan ekstrem), menggabungkan sinyal dari volatilitas, momentum pasar, media sosial, dominasi, dan tren menjadi satu nilai yang dapat diinterpretasikan [30], [31]. Temuan terbaru menunjukkan bahwa pengembalian Bitcoin dan indikator sentimen menunjukkan hubungan dua arah yang bermakna, di mana sentimen pasar tidak hanya mencerminkan tetapi juga mengantisipasi pergerakan harga [30], [31]. Meskipun demikian, perbandingan langsung dan sistematis antara model LSTM yang dilatih hanya dengan data harga versus model yang ditambah dengan Indeks Fear & Greed sebagai fitur tambahan belum diteliti secara menyeluruh [20], [25], [26]. Kesenjangan penelitian ini memotivasi penelitian ini, yang bertujuan untuk mengevaluasi apakah penyertaan Indeks Fear & Greed sebagai variabel input tambahan secara bermakna meningkatkan akurasi prediksi peramalan harga Bitcoin berbasis LSTM menggunakan data deret waktu [13], [14], [29].


Berdasarkan kesenjangan penelitian yang diidentifikasi di atas, studi ini bertujuan untuk membandingkan kinerja dua model berbasis LSTM dalam memprediksi harga Bitcoin menggunakan data deret waktu satu model dilatih secara eksklusif pada fitur harga historis, dan model lain yang menggabungkan Crypto Fear & Greed Index sebagai variabel input tambahan [20]. Data harga Bitcoin yang digunakan dalam penelitian ini bersumber dari API CoinGecko [13], sedangkan data Fear & Greed Index diperoleh dari API Alternative.me [14], yang keduanya menyediakan catatan historis yang andal dan mudah diakses untuk analisis deret waktu. Kinerja model akan dievaluasi menggunakan metrik kesalahan standar yang umum diterapkan dalam penelitian peramalan deret waktu, termasuk Mean Absolute Error (MAE), Mean Squared Error (MSE), dan Root Mean Squared Error (RMSE), yang telah banyak diadopsi dalam studi prediksi cryptocurrency dan keuangan sebelumnya [17], [19], [26]. Perbandingan ini dimaksudkan untuk menentukan apakah fitur berbasis sentimen memberikan peningkatan yang terukur pada akurasi prediksi di luar apa yang dapat diberikan oleh data harga historis saja [25], [26], [30]. Melalui kerangka perbandingan ini, penelitian ini diharapkan dapat memberikan bukti empiris mengenai nilai tambah indikator sentimen pasar dalam peramalan keuangan berbasis pembelajaran mendalam [8], [21], [22], dan memberikan wawasan praktis bagi peneliti dan praktisi yang bekerja pada model prediksi harga mata uang kripto di Indonesia dan di luar Indonesia [24], [27].

Kontribusi utama penelitian ini mencakup tiga aspek yang saling melengkapi. Pertama, penelitian ini memberikan bukti empiris yang terukur mengenai pengaruh integrasi Crypto Fear & Greed Index sebagai indikator sentimen pasar terhadap peningkatan akurasi prediksi harga Bitcoin berbasis model LSTM [30], [31]. Kedua, penelitian ini menyediakan perbandingan langsung dan sistematis antara model LSTM yang hanya menggunakan data harga historis dengan model yang mengombinasikan data historis dan sentimen pasar, dengan arsitektur jaringan yang disamakan agar perbedaan kinerja dapat secara adil dikaitkan pada penambahan fitur sentimen [20], [25]. Ketiga, penelitian ini menggunakan tiga metrik evaluasi sekaligus, yaitu MAE, RMSE, dan MAPE, sehingga menghasilkan penilaian performa yang lebih menyeluruh dan dapat dibandingkan secara langsung dengan studi-studi sejenis di bidang prediksi harga cryptocurrency [17], [19], [26]. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi nyata bagi pengembangan model prediksi harga Bitcoin yang lebih akurat, adaptif, dan relevan secara praktis, khususnya dengan mempertimbangkan dinamika psikologis pasar sebagai faktor yang tidak dapat diabaikan [8], [21], [22].

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Berdasarkan tujuan penelitian yang telah dijelaskan pada bagian pendahuluan, penelitian ini berkontribusi dalam mengevaluasi pengaruh integrasi Crypto Fear & Greed Index sebagai indikator sentimen pasar terhadap performa model LSTM dalam prediksi harga Bitcoin. Selain itu, penelitian ini menyajikan perbandingan langsung antara model yang hanya menggunakan data historis harga dan model yang mengombinasikan data historis dengan informasi sentimen pasar. Untuk mencapai tujuan tersebut, tahapan penelitian yang dilakukan ditunjukkan pada Gambar 1.



Gambar 1. Metode Penelitian

- Pengumpulan Data:** Tahapan Pengumpulan data yang digunakan dalam penelitian ini merupakan data sekunder. Data harga Bitcoin diambil dari CoinGecko API [13], sedangkan data sentimen pasar diperoleh dari Alternative.me API [14]. Data yang digunakan mencakup periode tahun 2024 hingga 2026 dengan interval waktu 4 jam dan terdiri dari atribut harga open, high, low, close (OHLC) serta nilai Indeks Fear & Greed [11].
- Data Preprocessing:** Pada tahap preprocessing, data dibersihkan dari missing value dan duplikasi, serta disamakan untuk formatnya. Fitur yang digunakan meliputi harga open, high, low, close, dan ditambahkan Indeks Fear & Greed untuk model berbasis sentimen. Data harga dan sentimen digabung berdasarkan timestamp, lalu dinormalisasi dengan Min-Max Scaler agar siap digunakan dalam pelatihan model [15], [16].
- Normalisasi Data:** Sub Tahap Normalisasi data dilakukan untuk mengubah rentang nilai data ke dalam skala tertentu agar proses pelatihan model menjadi lebih stabil dan optimal. Dalam penelitian ini, normalisasi dilakukan menggunakan metode Min-Max Scaler yang mengubah nilai data ke dalam rentang 0 hingga 1. Proses ini bertujuan untuk menghindari dominasi atribut dengan nilai besar terhadap atribut lainnya serta meningkatkan kinerja model deep learning dalam mempelajari pola data time series [16].
- Pembentukan Sequence:** Pada tahap pembentukan sequence, data time series diubah menjadi bentuk sekuens menggunakan metode sliding window. Teknik ini memanfaatkan data historis sebagai input untuk memprediksi nilai berikutnya. Setiap window berisi data berurutan agar model LSTM dapat mempelajari pola perubahan dan hubungan jangka panjang dalam data yang bersifat dinamis [12], [17].
- Pembagian Data:** Pembagian data dilakukan menjadi 80% training dan 20% testing untuk evaluasi yang objektif. Data training digunakan melatih model Long Short-Term Memory (LSTM), sedangkan data testing untuk menguji kemampuan prediksi pada data baru. Pembagian ini penting untuk mencegah overfitting dan memastikan model mampu memprediksi data baru dengan baik [18].
- Long Short-Term Memory:** Long Short-Term Memory (LSTM) merupakan pengembangan dari Recurrent Neural Network (RNN) yang dirancang untuk mengatasi masalah vanishing gradient pada data sekuensial dan time series. LSTM memiliki mekanisme cell state yang memungkinkan penyimpanan informasi jangka panjang sehingga mampu menangkap pola temporal yang kompleks [12], [21]. Arsitekturnya terdiri dari forget gate, input gate, dan output gate yang masing-masing berfungsi untuk menyaring informasi lama, menambahkan informasi baru, dan menghasilkan output berdasarkan memori yang tersimpan. Mekanisme ini membuat LSTM efektif dalam mempertahankan informasi penting dalam jangka waktu panjang dan banyak digunakan pada berbagai tugas prediksi time series seperti harga saham, cryptocurrency, kualitas udara, dan lalu lintas [6], [19], [22]. Dalam penelitian ini, LSTM digunakan untuk memprediksi harga Bitcoin berdasarkan data historis serta sentimen pasar dari Crypto Fear & Greed Index.
- Pembangunan Model LSTM:** Sub Tahapan pembangunan model dalam penelitian ini menggunakan metode Long Short-Term Memory (LSTM), yaitu algoritma deep learning untuk memproses data sekuensial dan menangkap


dependensi jangka panjang pada data time series. Model terdiri dari input layer, LSTM layer untuk ekstraksi pola sekuensial, serta dense layer sebagai output prediksi, dengan tambahan dropout layer untuk mengurangi overfitting. Proses pelatihan menggunakan optimizer Adam Optimizer dan fungsi loss Mean Squared Error (MSE) guna mengukur kesalahan prediksi. LSTM efektif dalam menangkap pola non-linear dan hubungan jangka panjang [28], sehingga banyak digunakan pada prediksi data time series seperti kualitas udara. Arsitektur model pada kedua skenario disamakan untuk memastikan perbandingan kinerja yang adil [6], [19].

- h. Pelatihan Model: Tahapan pelatihan model dilakukan menggunakan data training yang telah dipreprocessing dan dibentuk menjadi sequence. Model Long Short-Term Memory (LSTM) dilatih secara bertahap melalui epoch untuk mempelajari pola data dengan menyesuaikan bobot. Proses ini menggunakan Adam Optimizer dan fungsi loss Mean Squared Error (MSE) untuk meminimalkan error antara nilai aktual dan prediksi hingga mencapai kondisi optimal. Pelatihan dilakukan pada dua skenario, yaitu tanpa dan dengan penambahan Indeks Fear & Greed, guna membandingkan kinerja model [20].
- i. Prediksi: Tahap prediksi dilakukan setelah model Long Short-Term Memory (LSTM) selesai dilatih, dengan menggunakan data testing yang belum pernah dilihat sebelumnya. Model menerima input berupa data sekuens dan menghasilkan estimasi harga periode berikutnya. Hasil prediksi kemudian dibandingkan dengan nilai aktual untuk mengukur akurasi model. Proses ini dilakukan pada kedua model untuk membandingkan kinerja prediksinya [21].
- j. Evaluasi Model : Evaluasi model menggunakan tiga metrik, yaitu Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE) [22]. MAE mengukur rata-rata selisih absolut, RMSE lebih sensitif terhadap error besar, dan MAPE menyajikan error dalam bentuk persentase. Semakin kecil nilai ketiganya, semakin baik performa model [23].

3. HASIL DAN PEMBAHASAN

3.1 Deskripsi Data dan Preprocessing

Hasil dari penelitian ini, data diperoleh dari CoinGecko API untuk harga Bitcoin dan Alternative.me API untuk Indeks Fear & Greed. Dataset yang digunakan mencakup informasi harga pasar dan sentimen, dengan variabel berupa harga open, high, low, close, serta Indeks Fear & Greed sebagai representasi sentimen pasar.



Gambar 2. Grafik Data Aktual

Pada Gambar 2 terlihat bahwa harga Bitcoin memiliki pola fluktuatif dengan tren yang dinamis, menunjukkan adanya kenaikan dan penurunan yang signifikan dalam periode tertentu. Data awal yang digunakan dalam penelitian ini menampilkan sebagian data sebelum dilakukan proses pengolahan. Data tersebut kemudian diurutkan berdasarkan waktu (timestamp) untuk memastikan urutan kronologis sesuai dengan karakteristik data time series. Berikut data yang dapat dilihat pada Gambar 3.

Table 1. Dataset Penelitian

	timestamp	open	close	high	low	fear & greed index	fear & greed classification
4934	2024-01-01 00:00:00	42324.8	42384.1	42842.9	42271.5	65.0	Greed
4933	2024-01-01 04:00:00	42384.1	42531.7	42533.0	42211.2	65.0	Greed
4932	2024-01-01 08:00:00	42531.7	42735.1	42809.6	42492.7	65.0	Greed
4931	2024-01-01 12:00:00	42735.1	42825.1	42890.0	46205.4	65.0	Greed
4930	2024-01-01 16:00:00	42825.1	43570.1	43604.0	42707.1	65.0	Greed

Selanjutnya dilakukan proses data preprocessing, yang meliputi pembersihan data (data cleaning) dan penanganan nilai yang hilang (missing value). Data yang memiliki nilai kosong dihapus menggunakan metode dropna() sehingga hanya data yang lengkap yang digunakan dalam proses pelatihan model. Hasil data setelah proses preprocessing dapat dilihat pada Tabel 1.

Tabel 2. Data Preprocessing

	open	high	low	close	fear & greed index
4934	42324.8	42842.9	42271.5	42384.1	65.0
4933	42384.1	42533.0	42211.2	42531.7	65.0
4932	42531.7	42809.6	42492.7	42735.1	65.0
4931	42735.1	42890.0	42605.4	42825.1	65.0
4930	42825.1	43604.0	42707.1	43570.1	65.0

Setelah proses preprocessing, dilakukan normalisasi data menggunakan metode Min-Max Scaler. Normalisasi bertujuan untuk mengubah rentang nilai seluruh fitur ke dalam skala 0 hingga 1, sehingga perbedaan skala antar variabel tidak mempengaruhi kinerja model. Hasil dari proses normalisasi data ditampilkan pada Tabel 2.

Tabel 3. Normalisasi Data

	open	high	low	close	fear & greed index
0	0.040204	0.038833	0.043321	0.040946	0.674157
1	0.040889	0.035254	0.042623	0.042651	0.674157
2	0.042592	0.038448	0.045884	0.045002	0.674157
3	0.044939	0.039376	0.047189	0.046042	0.674157
4	0.045978	0.047621	0.048367	0.054651	0.674157

Tahap berikutnya adalah pembentukan data menjadi bentuk sekuens menggunakan metode sliding window. Pada penelitian ini digunakan ukuran window sebesar 10, yang berarti model menggunakan 10 data historis sebelumnya sebagai input untuk memprediksi nilai pada periode berikutnya. Target yang diprediksi adalah harga close, karena harga penutupan merepresentasikan nilai akhir transaksi dalam satu periode dan umum digunakan dalam analisis pergerakan harga. Berikut dapat dilihat padat Table 3.

Tabel 4. Tabel Sequence

	open	high	low	close	fear & greed index
0	0.040204	0.038833	0.043321	0.040946	0.674157
1	0.040889	0.035254	0.042623	0.042651	0.674157
2	0.042592	0.038448	0.045884	0.045002	0.674157
3	0.044939	0.039376	0.047189	0.046042	0.674157
4	0.045978	0.047621	0.048367	0.054651	0.674157
5	0.054575	0.055484	0.056646	0.062341	0.674157
6	0.062254	0.070426	0.065760	0.076192	0.741573
7	0.076086	0.072896	0.076780	0.076953	0.741573
8	0.076846	0.074671	0.077733	0.076906	0.741573
9	0.076799	0.073722	0.073400	0.073837	0.741573
Target (Close berikutnya):				0.07219928328832215	

3.2 Pembagian Data

Dataset yang telah melalui proses pembentukan sekuens kemudian dibagi menjadi dua bagian yaitu data pelatihan dan data pengujian. Pembagian ini bertujuan untuk melatih model menggunakan sebagian data dan menguji kemampuan model untuk membuat prediksi pada data yang belum pernah dilihat sebelumnya. Data pelatihan digunakan oleh model untuk mempelajari hubungan antara pola historis harga Bitcoin dan/atau sentimen pasar dengan nilai harga penutupan pada periode berikutnya, sehingga bobot-bobot pada jaringan LSTM dapat disesuaikan secara bertahap selama proses pelatihan. Sementara itu, data pengujian yang tidak dilibatkan sama sekali dalam proses pelatihan berfungsi sebagai data baru yang independen, sehingga hasil evaluasi pada data ini dapat mencerminkan kemampuan generalisasi model secara objektif. Pemisahan yang tegas antara kedua subset ini juga membantu mencegah terjadinya kebocoran data yang dapat menyebabkan estimasi performa model menjadi terlalu optimis dan tidak merepresentasikan kondisi penggunaan model pada data dunia nyata.


**Gambar 3.** Pembagian Data

Dalam penelitian ini, rasio pembagian 80% untuk data pelatihan dan 20% untuk data pengujian digunakan. Dengan total dataset sekitar 5.000 titik data, sekitar 4.000 sampel dialokasikan untuk pelatihan sementara 1.000 sampel sisanya dicadangkan untuk pengujian. Proporsi ini banyak diadopsi dalam penelitian peramalan deret waktu, karena memberikan model volume pola historis yang cukup besar untuk dipelajari sambil mempertahankan cukup data yang belum pernah dilihat sebelumnya untuk evaluasi yang bermakna secara statistik. Pembagian dilakukan secara kronologis untuk mempertahankan struktur ketergantungan temporal yang melekat pada data sekuensial, sehingga mencegah kebocoran data dan memastikan integritas proses evaluasi model. Hal ini dapat dilihat pada Gambar 3.

3.3 Model LSTM Tanpa Fear & Greed


Pada bagian ini model LSTM diimplementasikan hanya menggunakan data harga historis sebagai fitur input, khususnya variabel open, high, low, dan close (OHLC), tanpa memasukkan Crypto Fear & Greed Index sebagai input tambahan. Konfigurasi ini berfungsi sebagai model dasar dalam studi ini, memberikan titik referensi untuk mengevaluasi kontribusi data sentimen dalam skenario selanjutnya.

Model dibangun dengan dua lapisan LSTM bertumpuk, masing-masing berisi 50 unit, yang memungkinkan jaringan untuk menangkap fluktuasi jangka pendek dan ketergantungan temporal jangka panjang yang ada dalam rangkaian harga Bitcoin. Untuk mengurangi risiko overfitting selama pelatihan, lapisan dropout dengan tingkat 0,2 diterapkan setelah setiap lapisan LSTM. Model dilatih selama 50 epoch dengan ukuran batch 32, menggunakan optimizer Adam karena sifat laju pembelajaran adaptifnya, yang membuatnya cocok untuk data deret waktu non-stasioner. Mean Squared Error (MSE) digunakan sebagai fungsi kerugian untuk menghukum penyimpangan prediksi selama proses optimasi. Ukuran jendela geser 10 digunakan selama konstruksi urutan, yang berarti model menerima 10 langkah waktu historis berturut-turut sebagai input untuk menghasilkan setiap prediksi.



Gambar 4. Actual dan Prediksi LSTM Tanpa FGI

Gambar 4 menyajikan perbandingan antara harga penutupan Bitcoin aktual dan prediksi yang dihasilkan oleh model dasar ini di sekitar 1.000 langkah waktu pengujian. Garis prediksi mengikuti lintasan keseluruhan harga aktual dengan tingkat konsistensi yang tinggi sepanjang periode pengujian. Model ini berhasil menangkap tren penurunan umum yang diamati dari sekitar langkah waktu 100 hingga langkah waktu 650, serta stabilisasi harga selanjutnya di bagian akhir set pengujian. Kedua garis tetap sejajar di sebagian besar jendela evaluasi, menunjukkan bahwa arsitektur LSTM efektif dalam mempelajari pola temporal dominan yang ada dalam data harga Bitcoin. Namun, pada titik-titik tertentu pergerakan harga yang tiba-tiba dan tajam, terutama sekitar langkah waktu 150 dan 650 di mana penurunan tajam terlihat, nilai prediksi menunjukkan sedikit keterlambatan di belakang nilai aktual. Perilaku ini diharapkan dalam model LSTM standar, karena cenderung menghaluskan prediksi dan mungkin tidak bereaksi secara instan terhadap guncangan pasar mendadak yang tidak memiliki preseden sebelumnya dalam data pelatihan.



Gambar 5. Training & Validation Loss LSTM Tanpa FGI

Gambar 5 mengilustrasikan loss curve pelatihan dan validasi selama 50 epoch pelatihan. Kerugian pelatihan dimulai pada nilai yang relatif tinggi sekitar 0,0147 dan menurun dengan cepat dalam lima epoch pertama, setelah itu terus menurun secara bertahap dan stabil menjelang akhir pelatihan. Kerugian validasi, yang diwakili oleh garis oranye, dimulai pada nilai yang jauh lebih rendah dan tetap rendah dan stabil secara konsisten sepanjang seluruh proses pelatihan, hanya sedikit berfluktuasi di sekitar level 0,0005. Kesenjangan minimal dan stabil antara kerugian pelatihan dan kerugian validasi sepanjang pelatihan merupakan indikator kuat bahwa model telah konvergen dengan benar dan tidak mengalami overfitting yang signifikan. Ini menegaskan bahwa model tersebut mampu melakukan generalisasi dengan baik terhadap data di luar set pelatihan, yang merupakan properti yang diinginkan dalam model peramalan apa pun yang ditujukan untuk aplikasi dunia nyata.


Tabel 5. Evaluasi Model

	Metric	Value
0	MAE	1011.343533
1	RMSE	1340.547483
2	MAPE	1.197234

Untuk menilai kinerja prediksi model secara kuantitatif, tiga metrik evaluasi standar dihitung: Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Hasilnya dirangkum dalam Tabel 5. Model LSTM tanpa Fear & Greed Index mencapai MAE sebesar 1011,34, RMSE sebesar 1340,55, dan MAPE sebesar 1,20%. Nilai MAE menunjukkan bahwa, rata-rata, prediksi model menyimpang dari harga Bitcoin aktual sekitar \$1.011, yang, mengingat rentang harga yang diamati dalam dataset yang berkisar dari sekitar \$65.000 hingga \$115.000, mewakili kesalahan absolut yang relatif kecil. Nilai RMSE sebesar 1340,55 sedikit lebih tinggi daripada MAE, menunjukkan bahwa meskipun sebagian besar prediksi mendekati nilai aktual, terdapat kesalahan individual yang lebih besar yang diperkuat oleh penalti kuadrat dalam perhitungan RMSE. Yang paling penting, MAPE sebesar 1,20% mencerminkan kesalahan prediksi relatif yang sangat rendah, menunjukkan bahwa prediksi model berada dalam kisaran sekitar 1,2% dari harga sebenarnya secara rata-rata. Tingkat akurasi ini dianggap kuat dalam konteks peramalan harga mata uang kripto, di mana volatilitas tinggi dan ketidakpastian pasar membuat estimasi yang tepat menjadi sangat menantang. Hasil ini menegaskan bahwa model LSTM, bahkan ketika dilatih secara eksklusif pada data harga historis tanpa fitur sentimen eksternal apa pun, mampu menghasilkan prediksi harga Bitcoin yang andal dan akurat.

3.4 Model LSTM Menggunakan Fear & Greed

Pada bagian ini, model Long Short-Term Memory dikembangkan dengan menambahkan Crypto Fear & Greed Index sebagai fitur input tambahan bersama data historis harga Bitcoin yang terdiri dari open, high, low, dan close (OHLC). Penambahan indikator sentimen ini bertujuan untuk mengetahui apakah informasi psikologis pasar dapat membantu meningkatkan performa prediksi harga Bitcoin dibandingkan model yang hanya menggunakan data historis harga. Pada implementasinya, arsitektur model tetap menggunakan dua lapisan LSTM bertumpuk dengan masing-masing 50 unit neuron, dropout sebesar 0,2, optimizer Adam, serta fungsi loss Mean Squared Error (MSE). Penggunaan konfigurasi yang sama dilakukan agar perbandingan antara model tanpa dan dengan Fear & Greed tetap objektif, sehingga perubahan performa yang terjadi benar-benar berasal dari penambahan fitur sentimen pasar.




Gambar 6. Actual dan Prediksi LSTM Menggunakan FGI

Pada Gambar 6, terlihat bahwa garis prediksi mampu mengikuti pola harga aktual Bitcoin dengan sangat baik sepanjang periode pengujian. Garis prediksi yang ditunjukkan dengan warna merah tampak sangat dekat dan sejajar dengan garis harga aktual berwarna biru pada hampir seluruh timestep. Model berhasil menangkap tren penurunan harga dari kisaran 110.000 menuju 70.000, fase konsolidasi pasar, serta fluktuasi harga kecil yang terjadi selama periode evaluasi. Dibandingkan model tanpa Fear & Greed, hasil prediksi terlihat lebih rapat terhadap nilai aktual, khususnya pada area dengan volatilitas menengah. Hal ini menunjukkan bahwa informasi sentimen pasar memberikan

tambahan konteks kepada model dalam memahami kondisi pasar cryptocurrency. Karena Fear & Greed Index merepresentasikan tingkat ketakutan dan optimisme investor, model memperoleh informasi non-teknikal yang membantu meningkatkan kualitas pembelajaran pola temporal harga Bitcoin.

Meskipun performa model secara keseluruhan sangat baik, masih terdapat sedikit keterlambatan prediksi pada beberapa titik perubahan harga yang sangat tajam, terutama ketika terjadi penurunan drastis sekitar timestep 650. Kondisi ini merupakan karakteristik umum pada model LSTM karena model cenderung menghasilkan prediksi yang lebih halus atau smoothing, sehingga tidak selalu mampu merespons shock market secara instan. Namun demikian, dibandingkan model sebelumnya tanpa Fear & Greed, deviasi prediksi terlihat lebih kecil dan kestabilan prediksi model menjadi lebih baik.



Gambar 7. Training & Validation Loss LSTM Menggunakan FGI

Pada Gambar 7 ditampilkan grafik training loss dan validation loss selama 50 epoch pelatihan. Training loss mengalami penurunan signifikan pada awal epoch, kemudian terus menurun secara bertahap hingga stabil mendekati akhir pelatihan. Validation loss juga berada pada nilai yang sangat rendah dan relatif stabil sepanjang proses training tanpa menunjukkan peningkatan yang signifikan. Kondisi ini menunjukkan bahwa model berhasil mencapai konvergensi dengan baik serta tidak mengalami overfitting yang berarti. Kesenjangan yang kecil antara training loss dan validation loss mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik terhadap data baru di luar data pelatihan.

Tabel 6. Evaluasi Model

	Metric	Value
0	MAE	979.949485
1	RMSE	1349.071116
2	MAPE	1.184429

Untuk mengevaluasi performa model secara kuantitatif digunakan tiga metrik evaluasi, yaitu Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Hasil evaluasi menunjukkan bahwa model memperoleh nilai MAE sebesar 979,95, RMSE sebesar 1349,07, dan MAPE sebesar 1,18%. Nilai MAE menunjukkan bahwa rata-rata selisih antara hasil prediksi dan harga aktual Bitcoin berada di sekitar 979 dolar. Jika dibandingkan dengan model tanpa Fear & Greed yang memiliki MAE sebesar 1011,34, maka terjadi penurunan error yang menunjukkan peningkatan akurasi rata-rata prediksi. Nilai RMSE sebesar 1349,07 sedikit lebih tinggi dibanding model sebelumnya, yang mengindikasikan masih terdapat beberapa error besar pada kondisi market yang sangat volatil. Karena RMSE memberikan penalti lebih besar terhadap kesalahan ekstrem, kenaikan kecil pada nilai RMSE menunjukkan bahwa beberapa pergerakan harga mendadak masih sulit diprediksi secara sempurna oleh model. Namun demikian, peningkatan RMSE tersebut relatif kecil sehingga tidak terlalu memengaruhi performa keseluruhan model.

Nilai MAPE sebesar 1,18% menunjukkan bahwa rata-rata kesalahan prediksi model hanya sekitar 1,18% dari harga aktual Bitcoin. Nilai ini lebih rendah dibanding model tanpa Fear & Greed yang memiliki MAPE sebesar 1,20%, sehingga dapat disimpulkan bahwa penambahan indikator sentimen pasar berhasil meningkatkan akurasi relatif model. Dalam konteks forecasting cryptocurrency yang memiliki tingkat volatilitas tinggi, tingkat error sekitar 1% tergolong sangat baik dan menunjukkan bahwa model memiliki performa prediksi yang kuat.

3.5 Pembahasan

Untuk mengevaluasi efektivitas model yang diusulkan, hasil penelitian ini dibandingkan dengan penelitian yang dilakukan oleh Riziq dan Dzikrillah [32], yang menerapkan algoritma Long Short-Term Memory (LSTM) dan Support Vector Regression (SVR) untuk prediksi harga Bitcoin. Pada penelitian tersebut, model LSTM menghasilkan nilai

Mean Absolute Error (MAE) terbaik sebesar 1.439,64 dan terbukti memiliki performa yang lebih baik dibandingkan metode SVR dalam menangani data time series yang bersifat fluktuatif dan dinamis [32].

Sebagai perbandingan, model LSTM tanpa integrasi Crypto Fear & Greed Index pada penelitian ini menghasilkan nilai MAE sebesar 1.011,34, sedangkan model LSTM yang mengintegrasikan Crypto Fear & Greed Index memperoleh nilai MAE sebesar 979,95. Hasil tersebut menunjukkan bahwa kedua model yang dikembangkan pada penelitian ini mampu menghasilkan tingkat kesalahan prediksi yang lebih rendah dibandingkan model LSTM. Selain itu, model dengan integrasi Crypto Fear & Greed Index juga menghasilkan nilai Mean Absolute Percentage Error (MAPE) sebesar 1,18% dan Root Mean Square Error (RMSE) sebesar 1.349,07, sehingga evaluasi performa model menjadi lebih komprehensif dibandingkan penelitian referensi yang hanya melaporkan MAE dan MSE [32].

Perbedaan utama dalam penelitian ini terletak pada penggunaan Crypto Fear & Greed Index sebagai fitur tambahan yang merepresentasikan kondisi psikologis pasar cryptocurrency. Integrasi indikator sentimen tersebut memberikan informasi non-teknikal yang tidak tercermin pada data historis harga, sehingga model mampu mempelajari pola pergerakan harga Bitcoin secara lebih komprehensif. Penurunan nilai MAE dari 1.011,34 menjadi 979,95 setelah penambahan Crypto Fear & Greed Index mengindikasikan bahwa informasi sentimen pasar berkontribusi terhadap peningkatan akurasi prediksi model LSTM. Temuan ini menunjukkan bahwa kombinasi data historis harga dan indikator sentimen pasar dapat menjadi pendekatan yang lebih efektif untuk prediksi harga Bitcoin dibandingkan penggunaan data historis saja [32].

4. KESIMPULAN

Berdasarkan hasil implementasi dan pengujian model yang telah dilakukan, dapat disimpulkan bahwa model Long Short-Term Memory (LSTM) mampu memprediksi pergerakan harga Bitcoin dengan cukup baik menggunakan data time series. Hal ini ditunjukkan melalui hasil visualisasi grafik actual vs predicted yang memperlihatkan bahwa model mampu mengikuti pola pergerakan harga, serta nilai loss yang menurun dan stabil selama proses pelatihan. Model LSTM tanpa penggunaan Indeks Fear & Greed menghasilkan nilai MAE sebesar 1011.34, RMSE sebesar 1340.55, dan MAPE sebesar 1.20%. Sementara itu, model LSTM dengan penambahan Indeks Fear & Greed menghasilkan nilai MAE sebesar 979.95, RMSE sebesar 1349.07, dan MAPE sebesar 1.18%. Hasil tersebut menunjukkan bahwa penambahan variabel sentimen pasar mampu menurunkan nilai MAE dan MAPE, yang mengindikasikan peningkatan akurasi prediksi secara umum. Meskipun nilai RMSE mengalami sedikit peningkatan, hal ini menunjukkan adanya beberapa error besar pada prediksi, namun tidak secara signifikan mempengaruhi performa keseluruhan model. Dengan demikian, dapat disimpulkan bahwa integrasi Indeks Fear & Greed memberikan kontribusi positif dalam meningkatkan kinerja model LSTM dalam memprediksi harga Bitcoin. Hal ini mengindikasikan bahwa faktor sentimen pasar memiliki peran penting dalam mempengaruhi pergerakan harga, serta membantu model dalam memahami pola yang lebih kompleks. Oleh karena itu, penggunaan kombinasi data historis harga dan sentimen pasar dapat menjadi pendekatan yang lebih efektif dalam prediksi harga Bitcoin dibandingkan penggunaan model LSTM standar tanpa mempertimbangkan faktor sentimen pasar. Kontribusi utama penelitian ini mencakup tiga hal. Pertama, tersedianya bukti empiris yang terukur mengenai manfaat nyata integrasi Crypto Fear & Greed Index dalam meningkatkan akurasi prediksi model LSTM untuk harga Bitcoin. Kedua, tersedianya kerangka perbandingan langsung antara model berbasis data historis dan model yang mengombinasikan data historis dengan sentimen pasar menggunakan arsitektur yang identik, sehingga perbedaan kinerja dapat secara objektif dikaitkan pada penambahan fitur sentimen. Ketiga, penggunaan tiga metrik evaluasi sekaligus, yaitu MAE, RMSE, dan MAPE, yang menghasilkan penilaian performa lebih komprehensif dan dapat menjadi acuan bagi penelitian prediksi harga cryptocurrency selanjutnya [8], [21], [22]. Penelitian mendatang disarankan untuk mengeksplorasi arsitektur deep learning lainnya seperti GRU atau Transformer, serta mempertimbangkan penambahan indikator sentimen alternatif atau fitur makroekonomi guna lebih meningkatkan kemampuan prediksi model [7], [23], [25].

REFERENCES

- [1] S. Nakamoto, "Bitcoin: A Peer-to-Peer Electronic Cash System," 2008 [Online]. Available: <https://bitcoin.org/bitcoin.pdf>.
- [2] A. Roy, "In El Salvador, More People Have Bitcoin Wallets Than Traditional Bank Accounts," *Forbes*, 2021. [Online]. Available: <https://www.forbes.com/sites/theapotheary/2021/10/07/in-el-salvador-more-people-have-bitcoin-wallets-than-traditional-bank-accounts/>.
- [3] A. Qin and E. Livni, "China Cracks Down Harder on Cryptocurrency With New Ban," *The New York Times*, 2021.
- [4] S. Adiguno, Y. Syahra, et al., "Prediksi Peningkatan Omset Penjualan Menggunakan Metode Regresi Linier Berganda," *Jurnal Sistem Informasi Triguna Dharma (JURSI TGD)*, vol. 1, no. 4, p. 275, 2022, doi: 10.53513/jursi.v1i4.5331.
- [5] M. Owen, V. Vincent, R. Br. Ambarita, and E. Indra, "Implementasi Metode Long Short Term Memory Untuk Memprediksi Pergerakan Nilai Harga Emas," *Teknikom*, vol. 5, no. 1, p. 96, Jun. 2022, doi: 10.37600/teknikom.v5i1.507.
- [6] B. Yang, S. Sun, J. Li, X. Lin, and Y. Tian, "Traffic Flow Prediction Using LSTM with Feature Enhancement," *Neurocomputing*, vol. 332, pp. 320–327, 2019, doi: 10.1016/j.neucom.2018.12.016.
- [7] 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, p. 203, 2023, doi: 10.3390/fractalfract7020203.
- [8] C. Wen, X. Wu, C. Shen, Z. Huang, and P. Cai, "Bitcoin Price Prediction Based on Sentiment Analysis and LSTM," *Applied and Computational Engineering*, vol. 29, pp. 148–159, 2023, doi: 10.54254/2755-2721/29/20230743.

- [9] S. A. Alahmadi and K. K. Hossain, "Sentiment Analysis and Cryptocurrency Price Prediction: A Systematic Literature Review," *IEEE Access*, vol. 10, pp. 21545–21563, 2022, doi: 10.1109/ACCESS.2022.3151234.
- [10] J. V. Critien, A. Gatt, and J. Ellul, "Bitcoin price change and trend prediction through Twitter sentiment and data volume," *Financial Innovation*, vol. 8, no. 1, p. 45, May 2022, doi: 10.1186/s40854-022-00352-7.
- [11] A. Khedr, M. A. El-Hag, and M. A. El-Shafie, "Cryptocurrency Price Prediction Using Machine Learning and Deep Learning Techniques," *IEEE Access*, vol. 9, pp. 162245–162259, 2021, doi: 10.1109/ACCESS.2021.3133057.
- [12] R. S. Wahyuni, A. P. Windarto, and I. Gunawan, "Penerapan Long Short-Term Memory (LSTM) dalam Prediksi Data Time Series," *Jurnal Media Informatika Budidarma*, vol. 5, no. 3, pp. 1175–1182, 2021, doi: 10.30865/mib.v5i3.3112.
- [13] CoinGecko, "Cryptocurrency API," [Online]. Available: <https://www.coingecko.com/en/api/documentation>. [Accessed: 2026]
- [14] Alternative.me, "Fear and Greed Index API," [Online]. Available: <https://alternative.me/crypto/fear-and-greed-index/>. [Accessed: 2026].
- [15] K. Cabello-Solorzano, I. Ortigosa de Araujo, M. Peña, L. Correia, and A. J. Tallón-Ballesteros, "The Impact of Data Normalization on the Accuracy of Machine Learning Algorithms: A Comparative Analysis," in *Lecture Notes in Networks and Systems*, vol. 750, Springer, Cham, 2023, doi: 10.1007/978-3-031-42536-3_33.
- [16] F. T. Lima and V. M. A. de Souza, "A large comparison of normalization methods on time series," *Big Data Research*, vol. 34, pp. 100407, 2023, doi: 10.1016/j.bdr.2023.100407.
- [17] N. K. Agusmawati, F. Khoiriyah, and A. Tholib, "Prediksi Harga Emas Menggunakan Metode LSTM dan GRU," *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, vol. 11, no. 3, 2023, doi: 10.23960/jitet.v11i3.3250.
- [18] N. P. R. J. Tom, P. Gupta, A. Shanthini, V. M. John, and V. Sharma, "Prediction of Bitcoin Price Using Bi-LSTM Network," in 2021 International Conference on Computer Communication and Informatics (ICCCI), IEEE, Jan. 2021, pp. 1–5. doi: 10.1109/ICCCI50826.2021.9402427.
- [19] Y. Karyadi and H. Santoso, "Prediksi Kualitas Udara Dengan Metoda LSTM, Bidirectional LSTM, dan GRU," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 9, no. 1, pp. 671–684, Mar. 2022, doi: 10.35957/jatisi.v9i1.1588.
- [20] D. M. Nugraha and D. Ariatmanto, "Meningkatkan Akurasi Prediksi Harga Bitcoin dengan Algoritma GRU-LSTM Hibrida," *Jurnal Buffer Informatika*, vol. 11, no. 1, Apr. 2025, doi: 10.25134/buffer.v11i1.350.
- [21] M. Mroua and A. Lamine, "Financial time series prediction under Covid-19 pandemic crisis with Long Short-Term Memory (LSTM) Network," *Humanities and Social Sciences Communications*, vol. 10, no. 1, p. 530, Aug. 2023, doi: 10.1057/s41599-023-02042-w.
- [22] M. Rafi, S. Hameed, I. Sohail, M. Aliasghar, A. Aziz, and Q. A. K. Mirza, "Enhancing Cryptocurrency Price Forecasting Accuracy: A Feature Selection and Weighting Approach With Bi-Directional LSTM and Trend-Preserving Model Bias Correction," *IEEE Access*, vol. 11, pp. 65700–65710, 2023, doi: 10.1109/ACCESS.2023.3287888.
- [23] N. A. A. B. S. Bahari et al., "Predicting Sea Level Rise Using Artificial Intelligence: A Review," *Archives of Computational Methods in Engineering*, vol. 30, no. 7, pp. 4045–4062, 2023, doi: 10.1007/s11831-023-09934-9.
- [24] E. H. Kusnadi, R. R. Nasir, and H. Hulwanullah, "Legal Aspects of Crypto Assets on Indonesian Digital Investment Development," *Jurnal Hukum Islam*, vol. 12, no. 2, pp. 145–162, 2023, doi: 10.14421/sh.v12i2.3168.
- [25] N. M. Salih and A. M. Abdulazeez, "Bitcoin Price Prediction Using Hybrid LSTM-GRU Models," *Indonesian Journal of Computer Science*, vol. 13, no. 1, pp. 94–101, 2024, doi: 10.33022/ijcs.v13i1.3725.
- [26] N. Tripathy, S. Hota, and D. Mishra, "Performance Analysis of Bitcoin Forecasting Using Deep Learning Techniques," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 31, no. 3, pp. 1515–1522, 2023, doi: 10.11591/ijeecs.v31.i3.pp1515-1522.
- [27] A. Noor, M. A. Arifin, and D. P. W. Astuti, "Crypto Assets and Regulation: Taxonomy and Framework Regulatory of Crypto Assets in Indonesia," *Jurnal Etika Demokrasi*, vol. 8, no. 3, pp. 303–315, 2023, doi: 10.26618/jed.v8i3.10886.
- [28] W. Shah, J. Chen, I. Ullah, M. H. Shah, and I. Ullah, "Application of RNN-LSTM in Predicting Drought Patterns in Pakistan: A Pathway to Sustainable Water Resource Management," *Water (Switzerland)*, vol. 16, no. 11, pp. 1–19, 2024, doi: 10.3390/w16111492.
- [29] M. R. Pratama, F. A. G. Soerawinata, R. R. Zhafari, Rendy, and H. N. Imanda, "Sentiment Analysis of Beauty Product E-Commerce Using Support Vector Machine Method," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 2, pp. 269–274, 2022, doi: 10.29207/resti.v6i2.3876.
- [30] L. Gessie, "Do Bitcoin Returns Move Sentiment? Evidence from the Crypto Fear & Greed Index," *Finance Research Letters*, 2026, doi: 10.1016/j.finr.2026.100094.
- [31] C. P. T. Mendoza and N. G. Tubice, "Analyzing Historical Trends and Predicting Market Sentiment in Digital Currency Using Time Series Decomposition and ARIMA Models on Crypto Fear and Greed Index Data," *Journal of Data Mining and Digital Currency*, vol. 2, no. 3, 2025, doi: 10.47738/jdmde.v2i3.37.
- [32] I. F. Riziq and A. R. Dzikrillah, "Impelementasi Algoritma LSTM Dan SVR Untuk Prediksi Harga Bitcoin Menggunakan Data Yahoo Finance," *METIK Jurnal*, vol. 9, no. 2, 2025, doi: 10.47002/90ypad22.