

Analysis Of Lstm-Adamax Performance In Bitcoin Price Prediction Using RSI & MACD Indicators

Windha Mega PD^{1, a)} Yoga Imam Sumbadri^{2, b)}

^{1,2)} Program Studi Informatika

Fakultas Ilmu Komputer

Universitas Amikom Yogyakarta, Jl. Padjajaran, Ring Road Utara, Yogyakarta 55281, Indonesia

Author Emails

^{a)} Corresponding author: windha@amikom.ac.id

^{b)}yogaimam@students.amikom.ac.id

Abstract. One digital asset that is difficult to predict due to its extreme volatility is Bitcoin. Bitcoin's value has been predicted using various techniques, ranging from technical analysis to artificial intelligence-based models. Long Short-Term Memory (LSTM) is an artificial neural network architecture capable of recognizing patterns in historical data and is often used for time series data prediction. This study explores the application of an optimized LSTM model with the Adamax algorithm combined with the technical indicators RSI (Relative Strength Index) and MACD (Moving Average Convergence Divergence) to predict Bitcoin prices based on historical data. The LSTM-Adamax model demonstrated strong performance, achieving an RMSE of 435.9, MAE of 284.5, and R^2 of 0.99947, indicating high accuracy and robustness in capturing price patterns. A comparative evaluation between the model with and without these indicators revealed a slight performance improvement when the technical indicators were used. The model was successfully implemented as a web application using Streamlit, allowing users to upload Bitcoin price data, configure prediction parameters, and visualize the results in real-time. The application also communicates the predicted price movement direction (up or down) and its magnitude. In conclusion, the integration of LSTM-Adamax with RSI and MACD proved effective in predicting Bitcoin prices based on time-series data, providing reliable predictions and user-friendly implementation through a web interface.

Keywords:

Bitcoin Prediction; Short Term Memory; Adamax; RSI MACD

Abstraksi. Salah satu aset digital yang sulit diprediksi karena volatilitasnya yang ekstrem adalah bitcoin. Nilai bitcoin telah diprediksi menggunakan berbagai teknik, mulai dari analisis teknikal hingga model berbasis kecerdasan buatan. Long Short-Term Memory (LSTM) merupakan arsitektur jaringan saraf tiruan yang mampu mengenali pola dalam data historis, dan sering digunakan untuk prediksi data deret waktu. Penelitian ini mengeksplorasi penerapan model LSTM yang dioptimalkan dengan algoritma Adamax dikombinasikan dengan indikator teknis RSI (Relative Strength Index) dan MACD (Moving Average Convergence Divergence) untuk memprediksi harga Bitcoin berdasarkan data historis. Model LSTM-Adamax menunjukkan kinerja yang kuat, mencapai RMSE sebesar 435,9, MAE sebesar 284,5, dan R^2 sebesar 0,99947, yang menunjukkan akurasi dan ketahanan yang tinggi dalam menangkap pola harga. Evaluasi komparatif antara model dengan dan tanpa indikator ini mengungkapkan sedikit peningkatan kinerja ketika indikator teknis digunakan. Model ini berhasil diimplementasikan sebagai aplikasi web menggunakan Streamlit, memungkinkan pengguna untuk mengunggah data harga Bitcoin, mengkonfigurasi parameter prediksi, dan memvisualisasikan hasilnya secara real-time. Aplikasi ini juga mengkomunikasikan arah pergerakan harga yang diprediksi (naik atau turun) dan besarnya. Kesimpulannya, integrasi LSTM-Adamax dengan RSI dan MACD terbukti efektif dalam memprediksi harga Bitcoin berdasarkan data deret waktu, memberikan prediksi yang andal dan implementasi yang ramah pengguna melalui antarmuka web.

Keyword:

Prediksi Bitcoin; Long Short Term Memory; Adamax; RSI MACD

PENDAHULUAN

Bitcoin adalah aset digital dengan volatilitas tinggi yang sulit diprediksi. Sejak diluncurkan pada tahun 2009, harga Bitcoin telah berfluktuasi secara signifikan karena penawaran dan permintaan pasar, kebijakan pemerintah, dan sentimen investor[1]. Partisipasi investor institusional telah meningkat pesat sejak tahun 2020, menggeser dominasi dari investor ritel, dengan kepemilikan mencapai sekitar 31% dari pasokan Bitcoin pada tahun 2024 ($\pm 6,1$ juta BTC). Perubahan ini menunjukkan pergeseran peran Bitcoin dari aset spekulatif menjadi instrumen investasi yang mapan, sehingga relevan untuk studi ilmiah.

Berbagai teknik telah digunakan untuk memprediksi harga Bitcoin, mulai dari analisis teknis hingga metode berbasis kecerdasan buatan. LSTM telah menjadi model populer karena kemampuannya untuk mengenali pola dalam data historis, menangani urutan panjang, dan mengatasi masalah gradien yang menghilang pada RNN tradisional [2][3][4]. Namun, model ini masih menghadapi tantangan seperti overshoot, stagnasi, dan sensitivitas terhadap hyperparameter. Untuk mengatasi masalah ini, algoritma optimasi adaptif seperti Adamax digunakan karena dapat menyesuaikan laju pembelajaran secara dinamis. Pendekatan ini membantu mengurangi risiko melampaui titik optimal dan mempercepat konvergensi ketika pelatihan melambat, sehingga mendukung pembelajaran yang stabil pada data kompleks seperti harga Bitcoin [5].

Studi ini mengusulkan model LSTM yang dioptimalkan dengan Adamax, dikombinasikan dengan indikator teknis *Moving Average Convergence Divergence* (MACD) dan *Relative Strength Index* (RSI)[1][6]. Tujuannya adalah untuk menghasilkan prediksi harga Bitcoin yang lebih akurat, membantu pelaku pasar dalam pengambilan keputusan, dan mendukung penerapan pembelajaran mesin di sektor keuangan digital [7], [8].

TINJAUAN PUSTAKA

Penelitian terkait prediksi harga bitcoin dengan menggunakan metode deep learning telah banyak dilakukan dalam beberapa tahun terakhir. Salah satu pendekatan yang sering digunakan adalah *Long Short-Term Memory* (LSTM), yang unggul dalam menangani data deret waktu dengan ketergantungan jangka panjang. Sejumlah penelitian Bitcoin berbasis LSTM juga menekankan bahwa pemilihan fitur (misalnya closing price vs multivariat) memengaruhi performa, dan sering kali model tampak sangat “bagus” pada metrik jika terjadi kebocoran data (data leakage) atau skema pemisahan data tidak benar (misalnya shuffling pada data time series). Karena itu, penelitian-penelitian Bitcoin berbasis LSTM umumnya menyarankan pemisahan train/validation/test berbasis waktu, normalisasi yang dilakukan hanya dari data latih, serta pengujian pada periode yang benar-benar “out-of-sample”[8], [9]. LSTM cukup konsisten digunakan pada data finansial/kripto karena mampu memodelkan ketergantungan temporal [9]. Namun terdapat beberapa kekurangan seperti ketergantungan pada fitur harga saja (univariat) yang rentan gagal menangkap momentum, evaluasi yang kadang kurang ketat (risiko leakage), dan fokus pada akurasi tanpa membahas stabilitas model pada rezim pasar berbeda (bull/bear/sideways) [10]

LSTM diperkenalkan untuk mengatasi masalah vanishing/exploding gradients pada RNN, sehingga dapat mempelajari ketergantungan jangka panjang melalui mekanisme gates (input, forget, output) dan cell state [9]. Dalam konteks harga aset (saham/kripto), LSTM populer karena mampu memodelkan pola berurutan dan ketergantungan historis. Namun, sifat pasar yang dinamis membuat performa LSTM sensitif terhadap: panjang lookback window, strategi normalisasi, dan pengaturan hiperparameter (jumlah unit, layer, dropout). Penelitian optimasi hiperparameter LSTM pada data pasar menunjukkan bahwa pencarian hiperparameter dapat meningkatkan performa sekaligus mengurangi bias pemilihan konfigurasi yang terlihat bagus, tetapi sensitif terhadap skala data dan rezim pasar, interpretabilitas lebih rendah dibanding model statistik sederhana [11].

Banyak penelitian menambahkan indikator teknis untuk memperkaya fitur input karena indikator dianggap merepresentasikan momentum dan trend yang tidak selalu tampak jelas dari harga mentah. Secara konsep, RSI membantu menangkap kekuatan relatif pergerakan terbaru, tetapi sebagai indikator teknikal, dapat memberi sinyal terlambat pada kondisi tertentu dan performanya sangat bergantung pada rezim pasar. Ada penelitian yang secara eksplisit menggabungkan RSI dan MACD ke dalam model LSTM untuk prediksi harga (mis. konteks saham), dengan tujuan meningkatkan akurasi melalui fitur momentum dan tren [12]. Pada konteks Bitcoin, riset/tesis yang menguji banyak indikator teknis dengan LSTM menekankan bahwa tidak semua indikator sama kuatnya; beberapa indikator lebih stabil pada periode tertentu, sementara yang lain menambah noise.

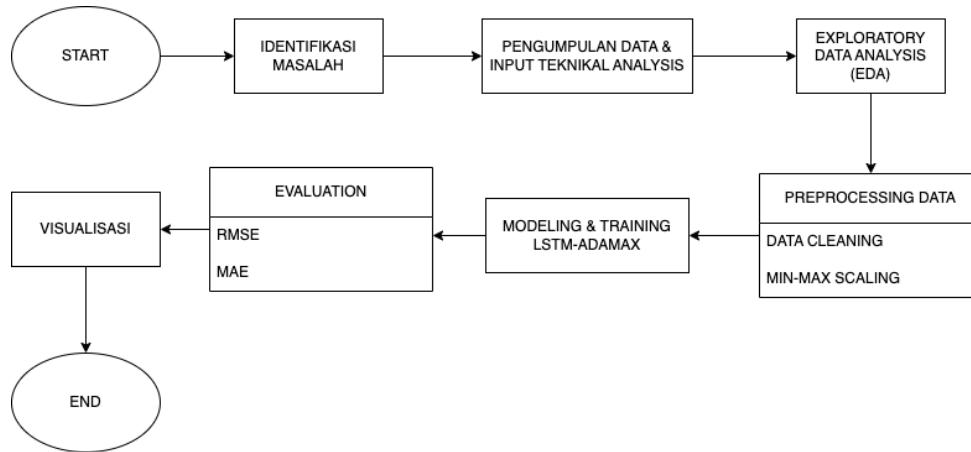
Penelitian komparatif optimizer pada jaringan deret waktu (LSTM/GRU) di domain pasar menunjukkan bahwa pilihan optimizer dapat memengaruhi RMSE dan kecepatan konvergensi, meskipun hasilnya dapat berbeda tergantung data dan arsitektur [13]. Argumen teoritis dan empiris bahwa varian Adam dapat membantu stabilitas update bobot; ini relevan untuk data kripto yang noisy, tetapi tidak ada jaminan Adamax selalu unggul; performa sangat bergantung pada learning rate, batch size, regularisasi, dan desain evaluasi.

Berdasarkan studi literatur di atas, Kombinasi LSTM dengan optimizer Adamax pada prediksi Bitcoin masih relatif lebih jarang dibahas dibanding Adam/SGD secara umum, padahal optimizer berpengaruh pada konvergensi dan stabilitas pelatihan. Peran RSI dan MACD sebagai fitur sering dianggap membantu, tetapi hasilnya bisa kecil/inkonsisten tergantung periode data dan cara evaluasi. Studi-studi indikator teknis pada LSTM menekankan pentingnya menguji indikator mana yang benar-benar robust. Pada penelitian ini, menekankan pada pengembangan evaluasi stabilitas LSTM dengan Adamax pada prediksi bitcoin, dan menguji kontribusi RSI dan MACD melalui perbandingan model with vs without indicator dan memperkuat implementatif melalui website interaktif.

METODE PENELITIAN

Objek penelitian ini adalah data harga Bitcoin historis, yang digunakan untuk mengembangkan model prediksi *Long Short-Term Memory* (LSTM) yang dioptimalkan dengan algoritma Adamax. Data tersebut mencakup harga pembukaan, harga penutupan, harga tertinggi, harga terendah, dan volume perdagangan harian. Selain data harga dasar tersebut, input model diperkaya dengan indikator teknis, yaitu *Moving Average Convergence Divergence* (MACD) dan *Relative Strength Index* (RSI).

Alur penelitian dilakukan melalui beberapa tahapan utama, yang divisualisasikan dalam bagan alur penelitian pada Gambar 1 di bawah ini. Setiap tahapan berfungsi untuk memastikan bahwa data diproses dan dimodelkan secara sistematis untuk menghasilkan prediksi harga Bitcoin yang optimal.



GAMBAR 1. Alur Penelitian

Identifikasi Masalah

Penelitian ini dilatarbelakangi oleh tantangan dalam memprediksi harga Bitcoin, yang memiliki volatilitas tinggi dan fluktuasi ekstrem. Harga bitcoin sangat dipengaruhi oleh faktor pasar, sentimen investor, kebijakan ekonomi, serta faktor teknikal lainnya. Untuk itu, diperlukan model prediksi yang mampu menangkap pola dinamis dari data historis harga bitcoin. Dalam penelitian ini, dibangun model prediksi harga bitcoin menggunakan arsitektur *Long Short-Term Memory* (LSTM) yang dioptimasi dengan algoritma Adamax dan diperkaya dengan fitur indikator teknikal.

Pengumpulan Data dan Input Teknikal Analysis

Data yang digunakan adalah data sekunder berupa harga historis bitcoin yang diperoleh dari website https://www.kaggle.com/datasets/novandraanugrah/bitcoin-historical-datasets-2018-2024?select=btc_1d_data_2018_to_2025.csv, Data mencakup periode tahun 2018 hingga 2025 dan terdiri dari atribut harga pembukaan (*Open*), harga penutupan (*Close*), harga tertinggi (*High*), harga terendah (*Low*), volume transaksi (*Volume*), dll. Selain data harga dasar, penelitian ini juga mengintegrasikan fitur indikator teknikal, yaitu *Moving Average Convergence Divergence* (MACD) dan *Relative Strength Index* (RSI), yang dihitung dengan menggunakan library Python khusus untuk analisis teknikal. Fitur-fitur ini ditambahkan sebagai input tambahan guna meningkatkan performa model prediksi.

Eksploratori Data Analisis

Analisis Data Eksploratif (EDA) adalah metode dalam fase pemahaman data yang bertujuan untuk memeriksa data berkualitas baik dan untuk memastikan data tersebut dapat digunakan secara efektif dalam proses pemodelan selanjutnya. Proses ini membantu memahami struktur awal dataset sebelum praproses dan melibatkan beberapa langkah: analisis statistik deskriptif untuk memeriksa rata-rata, median, deviasi standar, dan rentang data; visualisasi data seperti histogram dan grafik deret waktu untuk mengamati pola distribusi dan pergerakan harga; analisis korelasi antar fitur untuk mengidentifikasi hubungan antar variabel; dan identifikasi nilai yang hilang dan outlier yang dapat memengaruhi kualitas data pada tahap selanjutnya.

Pra pemrosesan

Pra pemrosesan data adalah langkah awal dalam Pembelajaran Mesin yang bertujuan untuk mengubah atau mengkonversi data ke dalam format yang sesuai agar lebih mudah dipahami dan diproses oleh mesin. Proses ini mencakup konversi format waktu dan pengaturan data secara kronologis untuk menjaga kontinuitas [14], penanganan nilai yang hilang dengan menghapus baris kosong menggunakan dropna(), pemilihan fitur penting seperti harga penutupan, volume, RSI, dan MACD, normalisasi data numerik menggunakan *Min-Max Scaler* ke rentang 0–1 [15], pembuatan data deret waktu melalui teknik jendela geser untuk mendeteksi pola berulang [16], dan pemisahan data menggunakan pemisahan berbasis waktu (80% pelatihan dan 20% pengujian) untuk mencegah kebocoran data dan memastikan evaluasi model yang lebih akurat.

Pemodelan LSTM-Adamax

Model prediksi ini dibangun menggunakan arsitektur LSTM yang dioptimalkan dengan Adamax, dipilih karena kemampuannya untuk memproses data deret waktu dan menangkap ketergantungan jangka panjang. Struktur model mencakup lapisan input yang sesuai dengan jumlah fitur yang digunakan, satu atau dua lapisan LSTM dengan dropout untuk mengurangi overfitting, lapisan dense sebagai lapisan output untuk memprediksi harga Bitcoin, optimizer Adamax untuk mempercepat konvergensi, dan aktivasi ReLU di lapisan tersembunyi dengan aktivasi linear di lapisan output untuk menghasilkan prediksi nilai kontinu.

Pelatihan Model dan Prediksi Model

Dalam mengevaluasi kinerja model regresi atau prediksi deret waktu, tiga metrik utama digunakan: *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Coefficient of Determination* (R^2). RMSE menghitung akar kuadrat dari rata-rata selisih kuadrat antara prediksi dan nilai aktual, sehingga lebih sensitif terhadap outlier dan cocok untuk distribusi kesalahan Gaussian. MAE mengukur rata-rata selisih absolut antara prediksi dan nilai aktual, sehingga lebih kuat terhadap outlier dan sesuai untuk distribusi Laplace. R^2 menunjukkan proporsi varians data yang dijelaskan oleh

model, dengan nilai mendekati 1 menunjukkan kinerja yang lebih baik. Kombinasi ketiga metrik ini memberikan penilaian komprehensif terhadap model, meliputi kesalahan rata-rata, kesalahan ekstrem, dan kemampuan model untuk merepresentasikan pola data.

Evaluasi Model

Dalam mengevaluasi kinerja model prediksi regresi atau deret waktu, tiga metrik utama digunakan: *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Coefficient of Determination* (R^2). RMSE menghitung akar kuadrat dari rata-rata selisih kuadrat antara prediksi dan nilai aktual, sehingga lebih sensitif terhadap outlier dan cocok untuk distribusi kesalahan Gaussian.

Hasil Evaluasi

Hasil prediksi dievaluasi menggunakan grafik garis yang membandingkan nilai prediksi dengan harga Bitcoin aktual, sehingga memungkinkan penilaian visual tentang seberapa baik model LSTM-Adamax mengikuti tren pergerakan harga.

HASIL DAN PEMBAHASAN

DESKRIPSI DATASET

Studi ini menggunakan dataset harga Bitcoin historis per jam dari tahun 2018 hingga 2025 yang berisi 64.103 titik data dengan lima atribut utama seperti pada gambar 2 (*Open*, *High*, *Low*, *Close*, *Volume*) dan menggabungkan indikator teknis RSI dan MACD untuk meningkatkan akurasi prediksi harga penutupan.

```
DatetimeIndex: 64103 entries, 2018-01-01 00:00:00 to 2025-04-30 00:00:00
Data columns (total 14 columns):
 #   Column           Non-Null Count  Dtype  
--- 
 0   Open             64103 non-null    float64
 1   High            64103 non-null    float64
 2   Low              64103 non-null    float64
 3   Close            64103 non-null    float64
 4   Volume           64103 non-null    float64
 5   Close time       64103 non-null    object 
 6   Quote asset volume 64103 non-null    float64
 7   Number of trades 64103 non-null    int64  
 8   Taker buy base asset volume 64103 non-null    float64
 9   Taker buy quote asset volume 64103 non-null    float64
 10  Ignore           64103 non-null    int64  
 11  RSI              64890 non-null    float64
 12  MACD             64078 non-null    float64
 13  MACD_signal      64070 non-null    float64
dtypes: float64(11), int64(2), object(1)
```

GAMBAR 2. Deskripsi Dataset

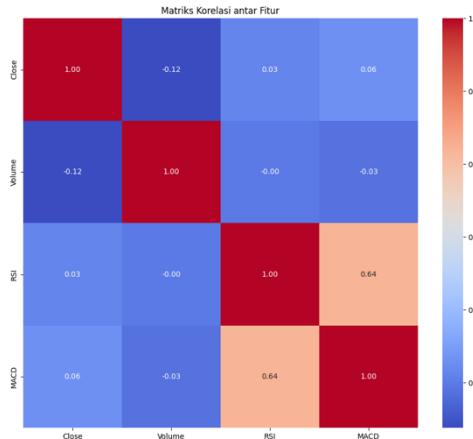
Analisis Data Eksplorasi (EDA)

Eksplorasi data dilakukan untuk mengidentifikasi pola, tren, dan hubungan antar variabel, mengungkapkan fluktuasi tajam pada harga penutupan yang mencerminkan volatilitas pasar kripto dan membantu dalam memilih fitur yang relevan untuk model prediksi. Gambar 3 di bawah ini menunjukkan harga penutupan Bitcoin dari tahun 2018 hingga 2025.



GAMBAR 3. Harga Penutupan Bitcoin

Gambar 4 di bawah ini menyajikan hasil analisis korelasi antara fitur *Close*, *Volume*, RSI, dan MACD untuk memastikan tidak terjadi multikolinearitas. Analisis menunjukkan bahwa RSI dan MACD memiliki korelasi sedang sebesar 0,64, sedangkan *Close* menunjukkan korelasi rendah dengan RSI (0,03) dan MACD (0,06). *Volume* juga menunjukkan korelasi rendah dengan semua fitur lainnya. Temuan ini menunjukkan bahwa setiap fitur memberikan kontribusi yang berbeda pada proses pelatihan model LSTM-Adamax dan mendukung keputusan pemilihan fitur selama tahap pra-pemrosesan.



GAMBAR 4. Matrik Korelasi

Pra-pemrosesan Data

Konversi waktu dan pengurutan data dilakukan dengan mengkonversi kolom Waktu Buka ke format tanggal dan waktu, menyusunnya secara kronologis, dan menetapkannya sebagai indeks utama untuk memastikan pola temporal diinterpretasikan dengan benar oleh model LSTM. Gambar 5 di bawah ini menunjukkan dataset sebelum menghapus nilai yang hilang. Nilai yang hilang dihapus untuk menjaga kualitas data dengan menghapus baris dengan nilai yang tidak lengkap dan hasilnya disajikan pada Gambar 6 di bawah ini.

```
Missing values per kolom:
Open          0
High          0
Low           0
Close          0
Volume         0
Close time     0
Quote asset volume 0
Number of trades 0
Taker buy base asset volume 0
Taker buy quote asset volume 0
Ignore          0
RSI             0
MACD            0
MACD_signal     0
dtype: int64
```

GAMBAR 5. Sebelum Penghapusan Missing Value

```
Missing values per kolom:
Open          0
High          0
Low           0
Close          0
Volume         0
Close time     0
Quote asset volume 0
Number of trades 0
Taker buy base asset volume 0
Taker buy quote asset volume 0
Ignore          0
RSI             13
MACD            25
MACD_signal     33
dtype: int64
```

GAMBAR 6. Setelah Penghapusan Missing Value

Langkah selanjutnya adalah pemilihan fitur, yang dilakukan dengan mempertimbangkan korelasi dan relevansi, menghasilkan pemilihan Close, Volume, RSI, dan MACD sebagai input utama model. Semua data kemudian dinormalisasi menggunakan MinMaxScaler ke rentang 0–1 untuk memastikan pelatihan yang stabil. Data deret waktu distrukturkan dengan ukuran jendela 30, di mana setiap input mencatat 30 jam sebelumnya untuk memprediksi harga berikutnya. Setelah itu, dataset dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian guna memastikan evaluasi model yang akurat.

Arsitektur dan Konfigurasi Model

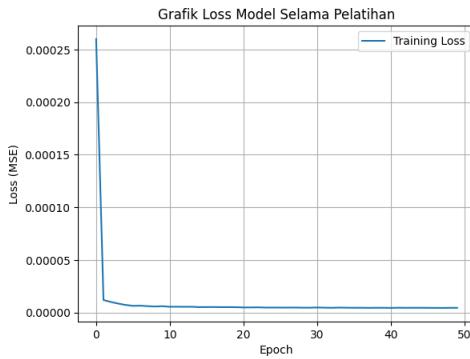
Model yang diimplementasikan menggunakan *Long Short-Term Memory* (LSTM), varian dari *Recurrent Neural Network* (RNN) yang unggul dalam memproses data deret waktu. Struktur model terdiri dari satu lapisan LSTM dengan 50 neuron dan satu lapisan Dense sebagai lapisan keluaran untuk menghasilkan prediksi harga penutupan. Proses pelatihan menggunakan optimizer Adamax, varian dari Adam yang dioptimalkan untuk meningkatkan stabilitas pelatihan, dengan Mean Squared Error (MSE) sebagai fungsi kerugian untuk meminimalkan perbedaan kuadrat antara hasil prediksi dan data aktual.

Pelatihan Model

Model dilatih selama 50 epoch dengan ukuran batch 32 menggunakan data pelatihan yang telah diproses sebelumnya, dan kinerjanya dipantau melalui metrik kerugian (mean_squared_error) pada data pelatihan dan validasi. Pada 10 epoch pertama, penurunan loss yang signifikan diamati, seperti yang ditunjukkan pada Gambar 7 di bawah ini, yang mengindikasikan bahwa model mampu dengan cepat menangkap pola awal dari data historis. Selanjutnya, dari epoch

ke-20 hingga ke-50, nilai loss cenderung konvergen, menandakan bahwa model telah menemukan parameter optimal untuk meminimalkan kesalahan.

Perbedaan antara loss pelatihan dan loss validasi minimal, menunjukkan bahwa model tidak mengalami overfitting dan menunjukkan kemampuan generalisasi yang baik untuk data baru. Secara keseluruhan, grafik loss menunjukkan tren penurunan yang stabil tanpa fluktuasi yang signifikan, menunjukkan bahwa proses pelatihan efektif.



GAMBAR 7. Visualisasi Model Loss Selama Training

Evaluasi Model

Kinerja model dievaluasi menggunakan data pengujian dengan beberapa metrik: *Root Mean Squared Error* (RMSE) sebesar 435,9, *Mean Absolute Error* (MAE) sebesar 284,5, dan Koefisien Determinasi (R^2 Score) sebesar 0,99947. RMSE menunjukkan kesalahan prediksi rata-rata dalam satuan harga Bitcoin, sedangkan MAE mengukur perbedaan absolut rata-rata antara nilai prediksi dan nilai aktual. Nilai R^2 yang mendekati 1 menunjukkan bahwa model dapat menjelaskan pola varians data dengan sangat baik.

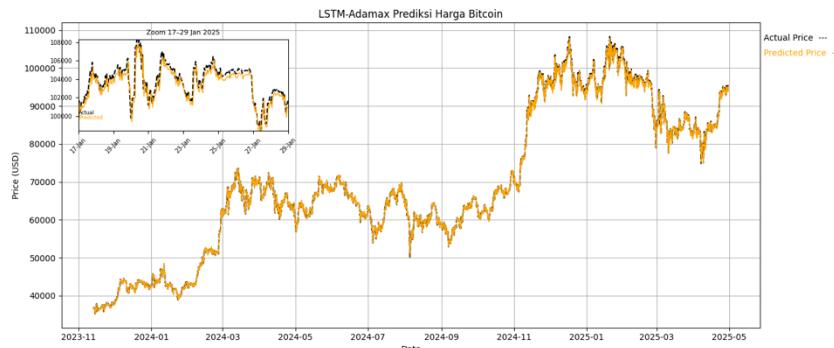
R² Score: 0.9994670851352079
RMSE: 435.91753833595885
MAE: 284.54546393547025

GAMBAR 8. Hasil Evaluasi RMSE dan MAE

Dari Gambar 8, dapat dilihat bahwa model tersebut menunjukkan kinerja prediksi yang sangat baik. RMSE dan MAE yang rendah menunjukkan kesalahan prediksi minimal, sementara Skor R^2 sebesar 0,99947 menunjukkan bahwa model tersebut mampu menjelaskan hampir semua varians dalam data harga Bitcoin. Meskipun terjadi lonjakan harga yang tiba-tiba, yang merupakan karakteristik khas pasar kripto, model tersebut mempertahankan akurasi dan stabilitas yang tinggi. Ini membuktikan bahwa LSTM-Adamax dapat diandalkan untuk memodelkan pola harga Bitcoin di pasar yang dinamis.

Visualisasi Hasil Prediksi

Untuk memahami kinerja model LSTM-Adamax dalam memprediksi harga Bitcoin, dilakukan visualisasi yang membandingkan nilai aktual dan hasil prediksi.



GAMBAR 9. Visualisasi Data Aktual dengan Data Prediksi

Gambar 9 menunjukkan bahwa model tersebut mampu mengikuti pola pergerakan harga dari November 2023 hingga Mei 2025 dengan cukup baik. Garis prediksi mendekati harga aktual, meskipun terdapat sedikit penyimpangan selama lonjakan ekstrem. Hal ini menunjukkan bahwa model tersebut dapat diandalkan untuk menangkap tren jangka pendek di pasar kripto yang volatil.

Perbandingan Model Dengan dan Tanpa Indikator Teknikal (RSI & MACD)

Untuk mengevaluasi kontribusi indikator teknikal, dilakukan perbandingan antara dua model LSTM-Adamax: satu hanya menggunakan fitur Close dan Volume, dan yang lainnya termasuk indikator teknikal RSI dan MACD. Evaluasi dilakukan menggunakan RMSE, MAE, dan R^2 Score, seperti yang ditunjukkan pada Tabel 1.

TABEL 1. Perbandingan Model Dengan dan Tanpa Indikator Teknikal RSI & MACD

No	Model	RMSE	MAE	R^2
1	Tanpa Indikator Teknikal (RSI & MACD)	441,74	288,02	0,99945 (99,945%)
2	Dengan Indikator Teknikal (RSI & MACD)	435,90	284,55	0,99947 (99,947%)

Hasil penelitian menunjukkan bahwa model dengan indikator teknis memiliki RMSE dan MAE yang lebih rendah serta R^2 yang sedikit lebih tinggi dibandingkan dengan model tanpa indikator. Meskipun peningkatan kinerja tidak substansial, indikator RSI dan MACD tetap memberikan kontribusi tambahan dengan membantu model mengenali pola pergerakan harga yang tidak sepenuhnya tercermin hanya oleh harga dan volume saja. Hal ini menegaskan bahwa penggunaan indikator teknis dapat meningkatkan kualitas prediksi dan meningkatkan kemampuan model untuk beradaptasi dengan pasar kripto yang dinamis.

Implementasi Aplikasi Prediksi Harga Bitcoin Berbasis Streamlit

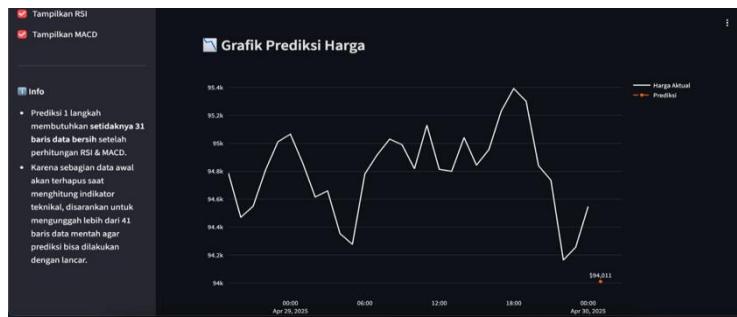
Tahap akhir penelitian ini melibatkan implementasi model LSTM-Adamax untuk prediksi harga Bitcoin ke dalam aplikasi web interaktif berbasis Streamlit. Hal ini memungkinkan pengguna untuk menggunakan model secara langsung melalui antarmuka web tanpa memerlukan pengetahuan teknis.

1. Menjalankan Streamlit dan LocalTunnel

Untuk menjalankan aplikasi secara online, perintah `!streamlit run app.py & npx localtunnel` digunakan. Perintah ini menjalankan aplikasi `app.py` pada port 8501 dan membuka akses publik melalui LocalTunnel, memungkinkan pengguna untuk mengakses aplikasi menggunakan URL yang disediakan, misalnya, <https://tame-peaches-take.localtunnel.me>.

2. Antarmuka Aplikasi

Aplikasi ini menyediakan visualisasi komprehensif, termasuk tabel data, hasil prediksi, arah tren, dan grafik interaktif, dengan desain yang ringkas, modern, dan ramah pengguna.



GAMBAR 10. Aplikasi Streamlit 1

Gambar 10 menunjukkan antarmuka awal, yang memungkinkan pengguna untuk mengunggah data harga Bitcoin historis dalam format CSV. Setelah diunggah, aplikasi menampilkan rentang waktu data, jumlah baris yang tersedia, dan lima entri terakhir sebagai gambaran visual.



Gambar 11. Aplikasi Streamlit 2

Gambar 11 menampilkan hasil prediksi harga sesuai dengan jumlah langkah yang dipilih pengguna, lengkap dengan harga aktual terbaru, indikator metrik, arah pergerakan harga, dan grafik interaktif untuk memudahkan pemahaman tren harga. Aplikasi ini juga mencakup validasi internal untuk memastikan file yang diunggah memenuhi persyaratan jumlah baris minimum (misalnya, 42 baris untuk prediksi satu langkah), memastikan keakuratan perhitungan dan prediksi indikator teknis. Dengan demikian, aplikasi prediksi harga Bitcoin berbasis LSTM-Adamax ini telah berhasil diimplementasikan sebagai antarmuka web interaktif, yang memungkinkan analisis dan visualisasi otomatis dan real-time hanya dengan mengunggah data dan mengatur parameter prediksi.

KESIMPULAN

Studi ini mengevaluasi implementasi model LSTM yang dioptimalkan dengan Adamax dan pemanfaatan indikator teknis RSI dan MACD untuk memprediksi harga Bitcoin dari data historis. Hasil menunjukkan bahwa kombinasi LSTM-Adamax dengan indikator teknis meningkatkan akurasi prediksi, mencapai RMSE sebesar 435,9, MAE sebesar 284,5, dan R^2 sebesar 0,99947 (99,947%). Meskipun korelasi RSI dan MACD dengan harga penutupan relatif rendah, keduanya tetap memberikan informasi tren dan momentum yang memperkuat input model. Perbandingan dengan model tanpa indikator menunjukkan sedikit peningkatan akurasi, dari R^2 0,99945 menjadi 0,99947.

Untuk memperluas cakupan dan menyempurnakan penelitian di masa mendatang, beberapa rekomendasi dapat diajukan, diantaranya Penambahan Indikator Teknikal Lainnya untuk meningkatkan performa model, disarankan menambahkan indikator teknikal lain seperti Bollinger Bands, Stochastic Oscillator, dan Exponential Moving Average (EMA) guna memperkaya input model dengan sinyal tren dan volatilitas tambahan. Optimasi Hyperparameter yang Lebih Mendalam, Penelitian ini menggunakan parameter default pada model LSTM. Disarankan penggunaan teknik hyperparameter tuning seperti Grid Search, Random Search, atau Bayesian Optimization untuk mendapatkan konfigurasi terbaik.

DAFTAR PUSTAKA

- [1] M. K. Salman and A. A. Ibrahim, “Price prediction of different cryptocurrencies using technical trade indicators and machine learning,” in *IOP Conference Series: Materials Science and Engineering*, IOP Publishing Ltd, Nov. 2020. doi: 10.1088/1757-899X/928/3/032007.
- [2] H. K. Andi, “An Accurate Bitcoin Price Prediction using logistic regression with LSTM Machine Learning model,” *Journal of Soft Computing Paradigm*, vol. 3, no. 3, pp. 205–217, Sep. 2021, doi: 10.36548/jscp.2021.3.006.
- [3] A. Sagheer, A. Raza, M. Rizwan, R. Rana, and F. Kiran, “A Hybrid Deep Learning Model for Accurate Bitcoin Price Forecasting,” *LGU Research Journal of Computer Science & Information Technology*, no. 9, doi: 10.54692/lgrjcsit.2025.091663.
- [4] A. Khumaidi, P. Kusmanto, and N. Hikmah, “Optimizing Bitcoin Price Predictions Using Long Short-Term Memory Algorithm: A Deep Learning Approach,” *ILKOM Jurnal Ilmiah*, vol. 16, no. 1, pp. 38–45, Apr. 2024, doi: 10.33096/ilkom.v16i1.1831.38-45.
- [5] Y. Shao *et al.*, “An Improvement of Adam Based on a Cyclic Exponential Decay Learning Rate and Gradient Norm Constraints,” *Electronics (Switzerland)*, vol. 13, no. 9, May 2024, doi: 10.3390/electronics13091778.
- [6] I. Zaznov, A. Badii, J. Kunkel, and A. Dufour, “AdamZ: an enhanced optimisation method for neural network training,” *Neural Comput. Appl.*, vol. 37, no. 32, pp. 26887–26914, Nov. 2025, doi: 10.1007/s00521-025-11649-w.
- [7] D. Chicco, M. J. Warrens, and G. Jurman, “The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation,” *PeerJ Comput. Sci.*, vol. 7, pp. 1–24, 2021, doi: 10.7717/PEERJ-CS.623.
- [8] G. Napolès and B. Nicenboim, “Predicting Bitcoin price using technical indicator data features in Long Short-Term Memory models,” 2021.
- [9] “LSTM”.
- [10] G. Cohen and A. Aiche, “Predicting the Bitcoin’s price using AI,” *Front. Artif. Intell.*, vol. 8, 2025, doi: 10.3389/frai.2025.1519805.
- [11] E. Ismanto and V. Vitriani, “RETRACTED: LSTM Network Hyperparameter Optimization for Stock Price Prediction Using the Optuna Framework,” *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika*, vol. 9, no. 1, pp. 22–35, Jan. 2023, doi: 10.26555/jiteki.v9i1.24944.
- [12] G. Napolès and B. Nicenboim, “Predicting Bitcoin price using technical indicator data features in Long Short-Term Memory models,” 2021.
- [13] A. Makinde, “Optimizing Time Series Forecasting: A Comparative Study of Adam and Nesterov Accelerated Gradient on LSTM and GRU networks Using Stock Market data,” Sep. 2024, [Online]. Available: <http://arxiv.org/abs/2410.01843>
- [14] E. Baumann, H. Buba, T. Cox, and C. Hsu, “An Introductory Approach to Time-Series Data Preparation and Analysis.”
- [15] S. Gurumoorthy, A. K. Kokku, P. Falkowski-Gilski, and P. B. Divakarachari, “Effective Air Quality Prediction Using Reinforced Swarm Optimization and Bi-Directional Gated Recurrent Unit,” *Sustainability (Switzerland)*, vol. 15, no. 14, Jul. 2023, doi: 10.3390/su151411454.
- [16] R. Kaur *et al.*, “Development of a cryptocurrency price prediction model: leveraging GRU and LSTM for Bitcoin, Litecoin and Ethereum,” *PeerJ Comput. Sci.*, vol. 11, 2025, doi: 10.7717/peerj-cs.2675.