

Perbandingan Performa Algoritma ARIMA, XGBoost, dan LSTM untuk Prediksi Harga Bitcoin Menggunakan Dataset Publik

Ahsan Firdaus*, Riza Adrianti Supono

Universitas Gunadarma, Indonesia

Email: ahsanfirdaus1@gmail.com*, adrianti@staff.gunadarma.ac.id

Keywords:

Bitcoin; Price Prediction;
ARIMA; XGBoost; LSTM.

Abstract

Bitcoin is a blockchain-based digital asset characterized by high price volatility, complicating investment decision-making and increasing the need for accurate prediction methods. As Bitcoin adoption and crypto asset transactions increase in Indonesia, the ability to predict price movements is becoming increasingly important for investors and industry players. Although various studies have developed cryptocurrency price prediction models, comparative studies comparing statistical, machine learning, and deep learning approaches on the same dataset are still limited. Therefore, this study aims to compare the performance of the Autoregressive Integrated Moving Average (ARIMA), Extreme Gradient Boosting (XGBoost), and Long Short-Term Memory (LSTM) algorithms in predicting Bitcoin's daily price. The dataset used is historical Bitcoin to Rupiah (BTC/IDR) data from January 1, 2020, to May 31, 2025, obtained from public datasets. The research stages include data collection, data preprocessing, data division using the temporal split method with a 70:30 ratio, implementation of the baseline model without hyperparameter optimization, and evaluation using the Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE) metrics. The results show that the LSTM model produces the best performance with an RMSE value of 83,205,260, MAE of 63,429,270, and MAPE of 4.90%, followed by XGBoost with a MAPE value of 20.29%, while ARIMA produces the lowest performance with a MAPE value of 46.44%. These findings indicate that LSTM is more effective in capturing non-linear patterns and temporal dependencies in volatile Bitcoin price data compared to ARIMA and XGBoost. Thus, a deep learning approach using LSTM can be a better alternative.

Kata Kunci:

Bitcoin; Prediksi Harga; ARIMA;
XGBoost; LSTM.

Abstrak

Bitcoin merupakan aset digital berbasis teknologi blockchain yang memiliki karakteristik volatilitas harga tinggi sehingga menyulitkan proses pengambilan keputusan investasi dan meningkatkan kebutuhan akan metode prediksi yang akurat. Seiring meningkatnya adopsi Bitcoin dan transaksi aset kripto di Indonesia, kemampuan memprediksi pergerakan harga menjadi semakin penting bagi investor maupun pelaku industri. Meskipun berbagai penelitian telah mengembangkan model prediksi harga cryptocurrency, kajian komparatif yang membandingkan pendekatan statistik, machine learning, dan deep learning pada dataset yang sama masih terbatas.

Oleh karena itu, penelitian ini bertujuan untuk membandingkan performa algoritma Autoregressive Integrated Moving Average (ARIMA), Extreme Gradient Boosting (XGBoost), dan Long Short-Term Memory (LSTM) dalam memprediksi harga harian Bitcoin. Dataset yang digunakan berupa data historis Bitcoin terhadap Rupiah (BTC/IDR) periode 1 Januari 2020 hingga 31 Mei 2025 yang diperoleh dari dataset publik. Tahapan penelitian meliputi pengumpulan data, prapemrosesan data, pembagian data menggunakan metode temporal split dengan rasio 70:30, implementasi model baseline tanpa optimasi hyperparameter, serta evaluasi menggunakan metrik Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Hasil penelitian menunjukkan bahwa model LSTM menghasilkan performa terbaik dengan nilai RMSE sebesar 83.205.260, MAE sebesar 63.429.270, dan MAPE sebesar 4,90%, diikuti oleh XGBoost dengan nilai MAPE sebesar 20,29%, sedangkan ARIMA menghasilkan performa terendah dengan nilai MAPE sebesar 46,44%. Temuan ini menunjukkan bahwa LSTM lebih efektif dalam menangkap pola non-linear dan dependensi temporal pada data harga Bitcoin yang bersifat volatil dibandingkan ARIMA dan XGBoost. Dengan demikian, pendekatan deep learning menggunakan LSTM dapat menjadi alternatif yang lebih baik.

PENDAHULUAN

Bitcoin merupakan mata uang digital terdesentralisasi pertama di dunia, diperkenalkan pada tahun 2009 oleh individu atau kelompok dengan nama samaran Satoshi Nakamoto (Nakamoto, n.d.). Berbeda dengan mata uang konvensional yang dikendalikan oleh bank sentral, Bitcoin beroperasi tanpa otoritas pusat melalui teknologi blockchain—sebuah buku besar digital yang mencatat semua transaksi secara transparan dan permanen. Transaksi Bitcoin divalidasi oleh jaringan komputer (nodes) melalui proses yang disebut penambangan (mining) yang menggunakan algoritma kriptografi untuk memastikan keamanan dan integritas data (AlMadany et al., 2024).

Seiring dengan pertumbuhan adopsi dan kapitalisasi pasar, Bitcoin telah menjadi subjek perhatian utama dalam dunia keuangan dan teknologi. Namun, salah satu karakteristik utama Bitcoin adalah volatilitas harganya yang tinggi dengan fluktuasi signifikan dalam waktu singkat. Volatilitas ini disebabkan oleh berbagai faktor, termasuk perubahan regulasi, sentimen pasar, adopsi teknologi, dan dinamika ekonomi global. Sebagai contoh, pada tahun 2024, harga Bitcoin mencapai puncaknya sekitar \$93.429 dengan kapitalisasi pasar sekitar \$1,85 triliun, namun juga mengalami penurunan tajam dalam periode tertentu.

Prediksi harga Bitcoin menjadi penting karena investor memerlukan informasi prediktif untuk menentukan waktu yang tepat dalam membeli atau menjual aset. Dengan memahami potensi pergerakan harga, investor dapat mengimplementasikan strategi lindung nilai (hedging) untuk mengurangi risiko kerugian. Perusahaan yang menerima pembayaran dalam Bitcoin atau berinvestasi dalam aset kripto perlu memperkirakan nilai tukar untuk perencanaan keuangan yang efektif. Selain itu, prediksi harga yang akurat dapat mendukung pengembangan aplikasi dan layanan keuangan berbasis blockchain.

Dalam konteks ini, penggunaan model prediktif seperti Autoregressive Integrated Moving Average (ARIMA), Extreme Gradient Boosting (XGBoost), dan Long Short-Term Memory (LSTM) menjadi relevan untuk menganalisis tren harga Bitcoin dan memberikan wawasan yang berguna bagi berbagai pemangku kepentingan. Ketiga algoritma tersebut dipilih karena mewakili pendekatan dari tiga paradigma berbeda: statistik konvensional (ARIMA), machine learning berbasis pohon keputusan (XGBoost), dan deep learning sekuensial (LSTM). Dengan membandingkan performa baseline-nya pada domain yang sama, penelitian ini diharapkan dapat memberikan wawasan mengenai kekuatan relatif dari tiap paradigma dalam konteks prediksi harga aset digital.

Di Indonesia, adopsi aset kripto menunjukkan tren yang meningkat. Hingga November 2024, jumlah investor kripto di Indonesia mencapai 22,11 juta. Selain itu, nilai transaksi aset kripto sepanjang tahun 2024 mencapai Rp650,61 triliun, meningkat hampir empat kali lipat dibandingkan tahun sebelumnya. Pertumbuhan ini mencerminkan minat yang tinggi dari masyarakat terhadap aset digital, sekaligus menekankan pentingnya alat prediksi harga yang andal untuk mendukung pengambilan keputusan investasi.

Meskipun telah banyak penelitian yang membahas model prediksi harga Bitcoin, sebagian besar studi tersebut berfokus pada pengembangan atau penerapan satu jenis model tertentu. Berdasarkan penelitian sebelumnya oleh (Oyedele et al., 2023) (Viéitez et al., 2024), pendekatan deep learning dan boosted trees telah terbukti memiliki potensi signifikan dalam meningkatkan akurasi prediksi harga kripto. Namun, kajian komparatif secara sistematis mengenai performa ARIMA, XGBoost, dan LSTM untuk prediksi harga Bitcoin pada periode 2020–2025 masih terbatas. Oleh karena itu, penelitian ini bertujuan untuk membandingkan performa model ARIMA, XGBoost, dan LSTM dalam memprediksi harga Bitcoin, dengan menggunakan dataset publik periode 2020–2025. Evaluasi performa akan dilakukan berdasarkan metrik Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE).

Kebaruan (novelty) penelitian ini terletak pada beberapa aspek. Pertama, penelitian ini melakukan perbandingan langsung antara tiga paradigma berbeda (ARIMA sebagai representasi statistik klasik, XGBoost sebagai representasi machine learning berbasis boosted tree, dan LSTM sebagai representasi deep learning) pada dataset yang sama dengan periode waktu yang sama. Kedua, penelitian ini menggunakan dataset publik terbaru (2020-2025) yang belum banyak dieksplorasi dalam penelitian sebelumnya. Ketiga, penelitian ini menggunakan pendekatan baseline tanpa optimasi hyperparameter untuk memberikan perbandingan yang adil dan objektif antar model. Keempat, penelitian ini menggunakan metrik evaluasi komprehensif (RMSE, MAE, dan MAPE) untuk menilai performa prediksi dari berbagai perspektif. Kelima, penelitian ini menggunakan data BTC/IDR yang relevan dengan konteks investor dan pasar kripto di Indonesia.


Dengan membandingkan performa baseline dari ketiga pendekatan ini pada dataset publik yang relevan, penelitian ini diharapkan dapat berkontribusi pada pemahaman yang lebih mendalam tentang efektivitas relatif pendekatan statistik, machine learning, dan deep learning dalam konteks prediksi harga aset digital. Hasil dari penelitian ini diharapkan dapat memberikan wawasan mengenai performa relatif dari tiap model dalam memprediksi harga Bitcoin berdasarkan data terkini. Selain itu, temuan ini juga dapat menjadi referensi bagi

investor dan praktisi dalam mengembangkan strategi investasi yang lebih efektif di pasar kripto.

METODE PENELITIAN

Pengumpulan Data

Data yang digunakan adalah data sekunder harian harga Bitcoin terhadap Rupiah (BTC/IDR) dari 1 Januari 2020 hingga 31 Mei 2025, diperoleh dari Investing.com dengan link [Investing.com](https://www.investing.com) melalui unduhan format CSV. Dataset ini terdiri dari 1.971 baris observasi dengan kolom Date (tanggal), Price (harga penutupan), Open, High, Low, Volume, dan Change%. Setelah diunduh, data akan dipra-proses untuk memastikan konsistensi format tanggal dan nilai numerik sebelum langkah selanjutnya.



	A	B	C	D	E	F	G	H
1	Date,"Price","Open","High","Low","Vol","Change %"							
2	06/09/2025,"1,722,226,048","1,728,497,024","1,729,476,992","1,720,000,000","", "-0.28%"							
3	06/08/2025,"1,727,113,984","1,720,999,936","1,739,000,064","1,714,648,960","", "0.36%"							
4	06/07/2025,"1,720,999,936","1,699,998,976","1,720,999,936","1,667,702,016","", "1.24%"							
5	06/06/2025,"1,699,968,000","1,663,469,952","1,719,000,064","1,660,116,992","", "2.19%"							
6	06/05/2025,"1,663,469,952","1,713,096,960","1,720,002,944","1,646,317,952","", "2.90%"							
7	06/04/2025,"1,713,096,960","1,719,987,968","1,727,357,952","1,680,998,016","", "0.32%"							
8	06/03/2025,"1,718,568,960","1,710,000,000","1,738,000,000","1,704,999,936","", "0.50%"							
9	06/02/2025,"1,710,000,000","1,731,606,016","1,731,897,984","1,698,000,000","", "1.26%"							
10	06/01/2025,"1,731,897,984","1,728,919,040","1,732,000,000","1,707,539,968","", "0.19%"							

Gambar 1 Data Historis BTCIDR

Prapemrosesan Data

Tahap prapemrosesan data dilakukan sebelum proses pemodelan untuk memastikan kualitas data yang digunakan berada dalam kondisi baik dan sesuai untuk analisis *time series*. Pada penelitian ini, proses prapemrosesan meliputi *data cleaning*, konversi format data, pemeriksaan *missing value*, penanganan *missing value*, pengecekan data duplikat, visualisasi *rolling mean*, pembersihan data akhir, pembagian data train-test, normalisasi data, serta pembentukan *sequence data* untuk model Long Short-Term Memory (LSTM).

Tahapan prapemrosesan dilakukan menggunakan bahasa pemrograman Python pada *environment* Kaggle. Implementasi preprocessing bertujuan untuk meningkatkan konsistensi data serta mengurangi potensi error selama proses pemodelan menggunakan algoritma ARIMA, XGBoost, dan LSTM.

HASIL DAN PEMBAHASAN

Deskripsi Eksperimen

Penelitian ini bertujuan untuk membandingkan performa tiga algoritma prediksi *time series*, yaitu ARIMA, XGBoost, dan Long Short-Term Memory (LSTM) dalam memprediksi harga harian Bitcoin terhadap Rupiah (BTC/IDR). Dataset yang digunakan merupakan data historis harian Bitcoin periode 1 Januari 2020 hingga 31 Mei 2025 yang diperoleh dari Investing.com dalam format CSV.

```
df = pd.read_csv('/kaggle/input/datasets/ahsanfirdaus/btc-idr-dataset-investingcom/BTC_IDR_Indodax')
df.head()
```

	Date	Price	Open	High	Low	Vol.	Change %
0	06/09/2025	1,722,226,048	1,728,497,024	1,729,476,992	1,720,000,000	NaN	-0.28%
1	06/08/2025	1,727,113,984	1,720,999,936	1,739,000,064	1,714,648,960	NaN	0.36%
2	06/07/2025	1,720,999,936	1,699,998,976	1,720,999,936	1,667,702,016	NaN	1.24%
3	06/06/2025	1,699,968,000	1,663,469,952	1,719,000,064	1,660,116,992	NaN	2.19%
4	06/05/2025	1,663,469,952	1,713,096,960	1,720,002,944	1,646,317,952	NaN	-2.90%

Gambar 2 Dataset Overview

Tahap eksperimen dilakukan menggunakan pendekatan *baseline* tanpa optimasi hyperparameter lanjutan agar perbandingan performa antar model dapat dilakukan secara lebih adil dan objektif. Ketiga model diuji menggunakan dataset yang sama dengan skema pembagian data training dan testing menggunakan metode *temporal split* sebesar 70:30. Pendekatan *temporal split* dipilih karena penelitian ini menggunakan data *time series* sehingga urutan waktu harus dipertahankan dan data tidak boleh diacak.

```
train_size = int(len(df) * 0.7)
train_df = df.iloc[:train_size]
test_df = df.iloc[train_size:]

print("Train Size:", len(train_df))
print("Test Size :", len(test_df))
```

Train Size: 1359
Test Size : 583

Gambar 3 Train Test Split

Sebelum proses pemodelan dilakukan, dataset terlebih dahulu melalui tahap prapemrosesan yang meliputi *data cleaning*, konversi tipe data, penanganan *missing value*, visualisasi *rolling mean*, normalisasi data untuk LSTM, serta pembentukan *sequence data*. Seluruh eksperimen dilakukan menggunakan bahasa pemrograman Python pada *environment* Kaggle dengan library Pandas, NumPy, Statsmodels, XGBoost, TensorFlow, dan Scikit-learn.

Evaluasi performa model dilakukan menggunakan tiga metrik evaluasi utama, yaitu Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Ketiga metrik tersebut digunakan untuk mengukur tingkat kesalahan prediksi model terhadap nilai aktual harga Bitcoin pada data testing.

Evaluasi Model

Pada tahap ini, ketiga model diuji kemampuannya dalam memprediksi harga Bitcoin pada data uji yang memiliki karakteristik volatilitas tinggi, khususnya pasca-fenomena Bitcoin Halving di tahun 2024.

Model ARIMA

Model ARIMA digunakan sebagai representasi pendekatan statistik klasik dalam penelitian ini. Sebelum proses pemodelan dilakukan, data terlebih dahulu diuji menggunakan Augmented Dickey-Fuller (ADF) Test untuk mengetahui apakah data bersifat stasioner atau tidak. Berdasarkan hasil pengujian diperoleh nilai p-value lebih besar dari 0,05 sehingga data dinyatakan *non-stationary*. Oleh karena itu, model ARIMA menggunakan differencing orde satu pada parameter *baseline*:

$$\text{ARIMA}(1,1,1)$$

Pada penelitian ini proses *forecasting* dilakukan menggunakan pendekatan *recursive forecasting*, yaitu hasil prediksi pada satu langkah waktu dimasukkan kembali ke dalam sequence historis untuk menghasilkan prediksi pada langkah berikutnya. Pendekatan ini digunakan untuk mensimulasikan kondisi prediksi dunia nyata tanpa menggunakan data aktual masa depan.

```
adf_result = adfuller(train_df['Price'])


print("ADF Statistic :", adf_result[0])
print("p-value       :", adf_result[1])

if adf_result[1] < 0.05:
    print("Data is stationary")
else:
    print("Data is NOT stationary")
```

ADF Statistic : -1.6649608477258802
p-value : 0.44925006415222757
Data is NOT stationary

Gambar 0 Output ADF Test

Hasil evaluasi model ARIMA pada data testing menunjukkan performa yang relatif rendah dibandingkan model lainnya. Berdasarkan hasil pengujian diperoleh nilai RMSE, MAE, dan MAPE yang cukup tinggi. Secara visual, hasil prediksi ARIMA terlihat cenderung bergerak stagnan dan tidak mampu mengikuti volatilitas harga Bitcoin yang sangat dinamis.



Gambar 5 Hasil Prediksi Model ARIMA terhadap Data Aktual Bitcoin

Kondisi tersebut menunjukkan bahwa pendekatan statistik linear seperti ARIMA memiliki keterbatasan dalam memodelkan karakteristik pasar cryptocurrency yang bersifat non-linear dan *highly volatile*. Selain itu, penggunaan *recursive forecasting* juga menyebabkan terjadinya akumulasi error pada setiap langkah prediksi sehingga performa model semakin menurun pada periode *forecasting* jangka panjang.


Model XGBoost

Model XGBoost digunakan sebagai representasi pendekatan *machine learning* berbasis boosted decision tree. Karena XGBoost bukan model *time series* secara langsung, maka dilakukan *feature engineering* menggunakan *lag features* dari $t-1$ hingga $t-7$ untuk membantu model mempelajari pola historis harga Bitcoin. Berdasarkan *base model* yang telah dibuat, konfigurasi sebagai berikut:

1. Learning Rate: 0.1
2. Max Depth: 3
3. N_Estimators: 100.

Penelitian ini tidak menggunakan *hyperparameter tuning* tambahan agar konsistensi *baseline* antar model tetap terjaga. Setelah proses training selesai dilakukan, model digunakan untuk memprediksi harga Bitcoin pada data testing menggunakan metode `predict()`.

Hasil evaluasi menunjukkan bahwa model XGBoost memiliki performa yang lebih baik dibandingkan ARIMA. Nilai error berhasil diturunkan secara signifikan dan visualisasi prediksi menunjukkan bahwa model mampu mengikuti pola pergerakan harga Bitcoin pada awal periode pengujian.



Gambar 6 Hasil Prediksi Model XGBoost terhadap Data Aktual Bitcoin

Namun, pada periode kenaikan harga Bitcoin yang sangat tinggi, model XGBoost mulai mengalami *saturation* sehingga garis prediksi terlihat cenderung stagnan dan tertinggal dibandingkan data aktual. Kondisi ini menunjukkan bahwa model *tree-based* memiliki keterbatasan dalam melakukan generalisasi terhadap tren jangka panjang pada data *time series* yang sangat volatil.

Meskipun demikian, XGBoost tetap menunjukkan performa yang kompetitif dan lebih stabil dibandingkan pendekatan statistik klasik.

Model LSTM

Model Long Short-Term Memory (LSTM) digunakan sebagai representasi pendekatan *deep learning* dalam penelitian ini. Sebelum proses training dilakukan, data terlebih dahulu

dinormalisasi menggunakan *MinMaxScaler* dan diubah menjadi *sequence data* dengan *window size* sebesar 7 hari.

Arsitektur *baseline* LSTM yang digunakan terdiri dari satu layer LSTM dengan 50 *hidden units* yang diikuti oleh satu *Dense layer* sebagai output. Model dilatih selama 20 *epoch* menggunakan *optimizer* Adam dan *loss function* Mean Squared Error (MSE).

```
lstm_model = Sequential()

lstm_model.add(LSTM(50, input_shape=(X_train.shape[1], 1)))
lstm_model.add(Dense(1))

lstm_model.compile(optimizer='adam', loss='mse')


history = lstm_model.fit(
    X_train,
    y_train,
    epochs=20,
    batch_size=32,
    verbose=1
)
```

```
I0000 00:00:1779018757.774741      844 gpu_device.cc:2019] Created device /job:localhost/
ice:GPU:0 with 15511 MB memory: -> device: 0, name: Tesla P100-PCIE-16GB, pci bus id:
capability: 6.0
Epoch 1/20
I0000 00:00:1779018760.288085      934 cuda_dnn.cc:529] Loaded cuDNN version 91002
43/43 ----- 2s 6ms/step - loss: 0.0775
Epoch 2/20
```

Gambar 7 Training *epoch* output

Hasil evaluasi menunjukkan bahwa model LSTM memberikan performa terbaik dibandingkan seluruh model yang diuji. Nilai RMSE, MAE, dan MAPE yang dihasilkan lebih rendah dibandingkan ARIMA maupun XGBoost. Selain itu, visualisasi prediksi menunjukkan bahwa model LSTM mampu mengikuti pola pergerakan harga Bitcoin secara lebih baik dan stabil.

Kemampuan tersebut menunjukkan bahwa LSTM lebih efektif dalam mempelajari dependensi temporal dan pola non-linear pada data *time series* cryptocurrency. Mekanisme *memory cell* pada LSTM memungkinkan model untuk mempertahankan informasi historis penting sehingga lebih adaptif terhadap perubahan tren dan volatilitas pasar Bitcoin.



Gambar 8 Hasil Prediksi Model LSTM terhadap Data Aktual Bitcoin


Analisis dan Perbandingan Model

Tabel berikut menyajikan perbandingan performa ketiga model terhadap data pengujian:

Tabel 1 Perbandingan Performa Model Prediksi Bitcoin

Model	RMSE	MAE	MAPE
ARIMA	689,532,700	593,561,500	46.44%
XGBoost	407,783,400	290,669,700	20.29%
LSTM	83,205,260	63,429,270	4.90%

Berdasarkan hasil evaluasi pada Tabel 1, model LSTM menghasilkan performa terbaik dibandingkan model ARIMA dan XGBoost. Hal ini ditunjukkan oleh nilai RMSE, MAE, dan MAPE yang paling rendah pada seluruh metrik evaluasi. Model LSTM mampu menghasilkan nilai MAPE sebesar 4,90%, yang menunjukkan tingkat kesalahan prediksi relatif kecil terhadap harga aktual Bitcoin.



Gambar 9 Perbandingan Hasil Prediksi Ketiga Model terhadap Data Aktual Bitcoin

Sementara itu, model ARIMA menghasilkan performa terendah dengan nilai error paling tinggi. Kondisi ini menunjukkan bahwa pendekatan statistik linear memiliki keterbatasan dalam menangani karakteristik data cryptocurrency yang bersifat non-linear dan *highly volatile*.

Model XGBoost menunjukkan performa yang lebih baik dibandingkan ARIMA, namun masih mengalami keterbatasan dalam mengikuti tren kenaikan harga Bitcoin yang ekstrem. Secara keseluruhan, hasil penelitian menunjukkan bahwa pendekatan *deep learning* menggunakan LSTM lebih efektif dalam memodelkan pola temporal dan volatilitas harga Bitcoin dibandingkan pendekatan statistik maupun *machine learning* berbasis boosted tree.

KESIMPULAN

Berdasarkan hasil penelitian mengenai perbandingan model ARIMA, XGBoost, dan Long Short-Term Memory (LSTM) dalam melakukan prediksi harga harian Bitcoin (BTC/IDR) periode 2020–2025, dapat disimpulkan bahwa model LSTM menunjukkan performa prediksi terbaik dibandingkan dengan model lainnya. Berdasarkan hasil evaluasi menggunakan metrik Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan

Mean Absolute Percentage Error (MAPE), model LSTM mampu menghasilkan tingkat kesalahan paling rendah dengan nilai MAPE sebesar 4,90%, sehingga prediksi yang dihasilkan memiliki tingkat kedekatan paling tinggi terhadap data aktual harga Bitcoin. Hal ini menunjukkan bahwa kemampuan LSTM dalam mempelajari pola historis dan hubungan temporal pada data time series memberikan keunggulan dalam menghadapi karakteristik pasar cryptocurrency yang kompleks.

Masing-masing model memiliki karakteristik dan keterbatasan yang berbeda dalam melakukan prediksi harga Bitcoin. Model ARIMA memiliki keunggulan dari sisi kesederhanaan implementasi dan kemudahan interpretasi statistik, tetapi kurang mampu menangkap pola non-linear serta volatilitas tinggi yang terdapat pada pergerakan harga cryptocurrency. Sementara itu, model XGBoost menunjukkan kemampuan yang lebih baik dibandingkan ARIMA dalam mengenali pola lokal dari data historis Bitcoin, namun masih mengalami keterbatasan ketika menghadapi perubahan harga yang ekstrem atau lonjakan tren yang tinggi. Berbeda dengan kedua model tersebut, LSTM memiliki kemampuan yang lebih baik dalam memahami pola non-linear, dependensi jangka panjang, dan perubahan tren dinamis pada data harga Bitcoin, meskipun membutuhkan sumber daya komputasi yang lebih besar dalam proses pelatihannya.

Karakteristik data Bitcoin yang bersifat highly volatile, non-linear, dan memiliki perubahan tren yang cepat menjadi faktor utama yang memengaruhi efektivitas setiap algoritma prediksi. Model berbasis statistik linear seperti ARIMA cenderung mengalami underfitting karena tidak mampu menangkap kompleksitas pola pergerakan harga cryptocurrency, sedangkan model berbasis deep learning seperti LSTM lebih adaptif dalam mempelajari pola perubahan pasar yang dinamis. Dengan kemampuan tersebut, LSTM mampu memberikan hasil prediksi yang lebih akurat dibandingkan metode lainnya dalam konteks prediksi harga Bitcoin.

Selain itu, penggunaan pendekatan baseline tanpa optimasi hyperparameter lanjutan memberikan gambaran perbandingan performa yang objektif antar model karena seluruh algoritma diuji menggunakan dataset, metode pembagian data, serta indikator evaluasi yang sama. Hasil penelitian menunjukkan bahwa meskipun belum dilakukan optimasi lanjutan, model LSTM tetap mampu memberikan performa yang lebih unggul dibandingkan ARIMA dan XGBoost. Dengan demikian, LSTM dapat menjadi pendekatan yang lebih sesuai untuk pengembangan sistem prediksi harga cryptocurrency, khususnya pada aset digital dengan tingkat volatilitas tinggi seperti Bitcoin.

REFERENSI

- AlMadany, N. N., Hujran, O., Al Naymat, G., & Maghyereh, A. (2024). Forecasting cryptocurrency returns using classical statistical and deep learning techniques. *International Journal of Information Management Data Insights*, 4(2), 100251.
- Batsi, A., Biniz, M., & El Ayachi, R. (2025). Forecasting bitcoin price fluctuations: a time series analysis approach for predictive modelling. *Indonesian Journal of Electrical Engineering and Computer Science*, 37(3), 1964. <https://doi.org/10.11591/ijeecs.v37.i3.pp1964-1975>

- Chaudhary, D., & Saroj, S. K. (2023). Cryptocurrency price prediction using supervised machine learning algorithms. *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, 12(1), e31490. <https://doi.org/10.14201/adcaij.31490>
- Dudek, G., Fiszeder, P., Kobus, P., & Orzeszko, W. (2024). Forecasting cryptocurrencies volatility using statistical and machine learning methods: A comparative study. *Applied Soft Computing*, 151. <https://doi.org/10.1016/j.asoc.2023.111132>
- Fawzi, M. I., Ganesha, T., Anugrah, P. R., Zhahran, M., Abimanyu, F. A., & Bimantoro, H. (2025). Forecasting Bitcoin price prediction with Long Short-Term Memory networks: Implementation and applications using Streamlit. *Jurnal Teknik Informatika (JUTIF)*, 6(5), 2940–2961. <https://doi.org/10.52436/1.jutif.2025.6.5.5168>
- Huang, Z.-C., Sangiorgi, I., & Urquhart, A. (2024). Forecasting Bitcoin volatility using machine learning techniques. *Journal of International Financial Markets, Institutions and Money*, 97, 102064. <https://doi.org/10.1016/j.intfin.2024.102064>
- Jaquart, P., Köpke, S., & Weinhardt, C. (2022). Machine learning for cryptocurrency market prediction and trading. *The Journal of Finance and Data Science*, 8, 331–352. <https://doi.org/10.1016/j.jfds.2022.12.001>
- Liu, Y., Li, Z., Nekhili, R., & Sultan, J. (2023). Forecasting cryptocurrency returns with machine learning. *Research in International Business and Finance*, 64, 101905. <https://doi.org/10.1016/j.ribaf.2023.101905>
- Mizdrakovic, V., Kljajic, M., Zivkovic, M., Bacanin, N., Jovanovic, L., Deveci, M., & Pedrycz, W. (2024). Forecasting bitcoin: Decomposition aided long short-term memory based time series modeling and its explanation with Shapley values. *Knowledge-Based Systems*, 299. <https://doi.org/10.1016/j.knosys.2024.112026>
- Nafkha, R., Suchodolska, D. Ž., & Hoser, P. (2024). Machine Learning-Based Volatility Prediction Performance. *Procedia Computer Science*, 246, 2665–2674. <https://doi.org/10.1016/j.procs.2024.09.407>
- Nakamoto, S. (n.d.). Bitcoin: A Peer-to-Peer Electronic Cash System. Retrieved www.bitcoin.org
- Oyedele, A. A., Ajayi, A. O., Oyedele, L. O., Bello, S. A., & Jimoh, K. O. (2023). Performance evaluation of deep learning and boosted trees for cryptocurrency closing price prediction. *Expert Systems with Applications*, 213. <https://doi.org/10.1016/j.eswa.2022.119233>
- Parente, M., Rizzuti, L., & Trerotola, M. (2024). A profitable trading algorithm for cryptocurrencies using a Neural Network model. *Expert Systems with Applications*, 238. <https://doi.org/10.1016/j.eswa.2023.121806>
- Ramadhan, Z. I., & Widiputra, H. (2024). Comparative analysis of recurrent neural network models performance in predicting Bitcoin prices. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 8(3), 377–388. <https://doi.org/10.29207/resti.v8i3.5810>
- Ren, Y.-S., Ma, C.-Q., Kong, X.-L., Baltas, K., & Zureigat, Q. (2022). Past, present, and future of the application of machine learning in cryptocurrency research. *Research in International Business and Finance*, 63, 101799. <https://doi.org/10.1016/j.ribaf.2022.101799>
- Rizkilloh, M. F., & Widiyanesti, S. (2022). Prediksi harga cryptocurrency menggunakan algoritma Long Short Term Memory (LSTM). *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(1), 25–31. <https://doi.org/10.29207/resti.v6i1.3630>

- Singh, S., Pise, A., & Yoon, B. (2024). Prediction of Bitcoin stock price using feature subset optimization. *Heliyon*, 10(7), e28415. <https://doi.org/10.1016/j.heliyon.2024.e28415>
- Uçkan, T. (2024). Integrating PCA with deep learning models for stock market Forecasting: An analysis of Turkish stocks markets. *Journal of King Saud University - Computer and Information Sciences*, 36(8). <https://doi.org/10.1016/j.jksuci.2024.102162>
- Viéitez, A., Santos, M., & Naranjo, R. (2024). Machine learning Ethereum cryptocurrency prediction and knowledge-based investment strategies. *Knowledge-Based Systems*, 299. <https://doi.org/10.1016/j.knosys.2024.112088>
- Yae, J., & Tian, G. Z. (2022). Out-of-sample forecasting of cryptocurrency returns: A comprehensive comparison of predictors and algorithms. *Physica A: Statistical Mechanics and Its Applications*, 598, 127379. <https://doi.org/10.1016/j.physa.2022.127379>