

IMPLEMENTASI LONG SHORT-TERM MEMORY (LSTM) UNTUK FORECASTING HARGA CRYPTOCURRENCY

Kresna Prayoga, Syariful Alam, Imay Kurniawan

Teknik Informatika, STT Wastukancana

Jl.Cikopak No.53, Kec Purwakarta, Purwakarta, Jawa Barat, Indonesia-41151

kresnaprayoga71@wastukancana.ac.id

ABSTRAK

Penelitian ini bertujuan mengimplementasikan model Long Short-Term Memory (LSTM) untuk memprediksi harga Bitcoin dengan memanfaatkan data historis dari Yahoo Finance. Metode yang digunakan meliputi pra-pemrosesan data (normalisasi Min-Max, pembagian dataset 95:5), pelatihan model LSTM (2 lapis LSTM dengan 128 dan 64 neuron, optimizer Nadam, 10 epoch), dan evaluasi menggunakan metrik MAE, RMSE, dan MAPE. Hasil menunjukkan model mencapai akurasi tinggi dengan MAE 1403.3701, RMSE 1983.4696, dan MAPE 1.5192%. Model ini diimplementasikan dalam aplikasi web berbasis Streamlit untuk prediksi interaktif 1 - 7 hari ke depan. Temuan ini membuktikan efektivitas LSTM dalam menangani volatilitas harga cryptocurrency dan memberikan manfaat praktis bagi investor.

Kata kunci: Long Short-Term Memory, cryptocurrency, prediksi harga, Bitcoin, Streamlit

1. PENDAHULUAN

Fluktuasi harga Bitcoin dalam beberapa bulan terakhir tidak terlepas dari dinamika kebijakan ekonomi global, terutama kebijakan proteksionis Amerika Serikat di bawah kepemimpinan Donald Trump [1]. Pada April 2025, penerapan tarif impor AS sebesar 145% terhadap barang-barang dari China memicu penurunan 35% volume perdagangan China-AS dalam seminggu [2], sekaligus meningkatkan volatilitas pasar keuangan dunia. Di tengah ketidakpastian ini, Bitcoin semakin dipandang sebagai digital gold—aset alternatif yang diharapkan dapat melindungi nilai (store of value) saat pasar tradisional mengalami gejolak[3].

Di Indonesia, sebagai salah satu pasar kripto terbesar di Asia Tenggara[4], fluktuasi harga Bitcoin ini menimbulkan dampak signifikan. Badan Pengawas Perdagangan Berjangka Komoditi (Bappebti) memang telah melegalkan perdagangan aset kripto sebagai komoditas, namun Bank Indonesia (BI) tetap melarang penggunaannya sebagai alat pembayaran [5]. Dualisme regulasi ini menciptakan ketidakpastian bagi investor lokal, terutama ketika harga Bitcoin mengalami penurunan tajam di bawah \$82.000 pada awal April 2025, sebelum akhirnya rebound 8,9% dalam seminggu [6].

Bagi investor retail di Indonesia, volatilitas harga Bitcoin yang dipicu kebijakan global seperti tarif Trump membawa konsekuensi nyata [7]. Pertama, fluktuasi harga yang tajam meningkatkan risiko likuiditas dan menyulitkan strategi buy-and-hold. Kedua, ketergantungan pada pasar global membuat investor Indonesia sering terlambat merespons perubahan harga karena ketiadaan market maker besar di dalam negeri. Ketiga, minimnya literasi risiko menyebabkan banyak investor pemula terjebak FOMO (Fear of Missing Out) tanpa memahami dampak kebijakan luar negeri terhadap portofolio mereka [8].

Penelitian ini bertujuan untuk mengevaluasi kinerja model Long Short-Term Memory (LSTM) dalam peramalan harga cryptocurrency dengan menggunakan metrik evaluasi seperti Mean Absolute Error (MAE) dan Root Mean Squared Error (RMSE). Dengan mengembangkan model prediksi yang akurat, diharapkan investor dapat membuat keputusan yang lebih tepat dalam menghadapi volatilitas pasar yang dipengaruhi oleh berbagai faktor eksternal, termasuk kebijakan perdagangan global. Hasil penelitian ini diharapkan dapat menjadi acuan dalam pengembangan strategi investasi yang lebih resilien di tengah ketidakpastian pasar kripto global.

2. TINJAUAN PUSTAKA.

2.1. Implementasi

Menurut Kamus Besar Bahasa Indonesia, implementasi adalah pelaksanaan dan penerapan, dimana kedua hal ini bermaksud untuk mencari bentuk tentang hal yang disepakati terlebih dahulu [9].

2.2. Long Short Term Memory (LSTM)

LONG SHORT-TERM MEMORY (LSTM) yang merupakan bentuk pengembangan dari recurrent neural network (RNN). LSTM memiliki kelebihan untuk dapat mengatasi masalah ketergantungan jangka panjang. Diusulkan oleh Sepp Hochreiter dan Jurgen Schmidhuber pada tahun 1997, model LSTM terdiri dari serangkaian sel memori unik yang menggantikan neuronlapisan tersembunyi dari RNN. RNN merupakan bentuk pengembangan dari artificial neural network (ANN). Pengembangan tersebut dilakukan karena ANN tidak mampu melakukan proses pelatihan secara cepat pada data yang banyak. Recurrent neural network (RNN) dirancang untuk memproses data bersambung atau berurutan, serta biasa digunakan untuk menyelesaikan masalah dengan data time series. Tapi RNN tidak mampu mengingat data historis yang terlalu lama [10].

LSTM memprediksi secara akurat terhadap suatu variabel. Peramalan didasarkan pada tingkat kesalahan prediksi, tingkat kesalahan yang semakin kecil akan semakin tepat dalam memprediksi [11].

2.3. Forecasting

Forecasting adalah sebuah perkiraan dan prediksi dalam melihat potensi tentang kejadian dimasa yang akan datang. Peramalan dilakukan sebagai bahan keputusan dalam melakukan prediksi dengan waktu yang lama. Peramalan merupakan langkah awal yang dilakukan untuk menentukan sebuah keputusan dimasa yang akan datang[12]

2.4. Cryptocurrency

Cryptocurrency adalah nama yang diberikan untuk sebuah sistem yang menggunakan kriptografi. Kata “*Cryptocurrency*” berasal dari gabungan 2 kata, yaitu “*cryptography*” yang memiliki arti kode rahasia, dan “*currency*” yang berarti mata uang. Menurut Syamsiah *Cryptocurrency* adalah system mata uang virtual yang berfungsi seperti mata uang standar yang memungkinkan penggunaanya untuk melakukan pembayaran secara virtual atas transaksi bisnis yang terjadi tanpa biaya jasa namun tetap memiliki otoritas kepercayaan yang terpusat [13].


2.5. Bitcoin

Bitcoin adalah salah satu jenis *Cryptocurrency* yang terdistribusi dan terdesentralisasi. Pengguna *Bitcoin* disebut sebagai klien dan masing-masing dari mereka dapat mengatur akun yang dikenal sebagai Alamat [14]. Seorang klien dapat mengirim *Bitcoin* ke klien lain dengan melakukan transaksi dan memasukkannya ke dalam log global dalam bentuk sebuah pembukuan yang besar yang disebut Blockchain. Blockchain dikelola oleh penambang *Bitcoin* yang akan diberi imbalan atas upaya mereka dalam sistem *Bitcoin*. Transaksi *Bitcoin* dilindungi oleh teknik *Cryptography* yang membuat hanya si pemilik sah Alamat [15].

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan menerapkan metodologi *CRISP-DM* (*Cross-Industry Standard Process for Data Mining*) untuk membangun model prediksi harga *Bitcoin* berbasis *Long Short-Term Memory* (*LSTM*). Tahapan penelitian diawali dengan pemahaman

kebutuhan bisnis (*business understanding*), di mana volatilitas harga *Bitcoin* dan kebutuhan investor akan alat prediksi akurat menjadi fokus utama [16]. Data historis harga *Bitcoin* diperoleh dari *Yahoo Finance* (periode Januari 2021-Juni 2025), yang mencakup harga harian (*Open, High, Low, Close*) dan volume perdagangan.



Gambar 1. Metode Penelitian

Tabel 1. Dataset Bitcoin

Price	Close	High	Low	Open	Volume
Ticker	BTC-USD	BTC-USD	BTC-USD	BTC-USD	BTC-USD
Date					
2021-01-01	29374.152	29600.626	28803.585	28994.009	40730301359
2021-01-02	32127.267	33155.117	29091.181	29376.455	67865420765
2021-01-03	32782.023	34608.558	32052.316	32129.408	78665235202
2021-01-04	31971.914	33440.218	28722.755	32810.949	81163475344
2021-01-05	33992.429	34437.589	30221.187	31977.041	67547324782

Proses data preparation melibatkan transformasi data melalui normalisasi *MinMaxScaler* (rentang 0-1) untuk memastikan konsistensi skala, kemudian dibagi menjadi data latih (95%) dan data uji (5%). Pembagian dataset mengikuti praktik standar dalam prediksi deret waktu dalam pemodelan machine learning untuk validasi kinerja model [17]. Data kemudian diubah menjadi sequence dengan window 60 timesteps sebagai input model *LSTM*, teknik yang telah terbukti efektif menangkap pola temporal dalam penelitian terbaru [18].

Arsitektur model *LSTM* yang dikembangkan terdiri dari dua lapisan dengan 128 dan 64 neuron, dilengkapi *dropout layer* ($rate=0.2$) untuk mencegah *overfitting*. Pemilihan *optimizer Nadam* dengan 10 epoch didasarkan pada hasil uji komparatif yang menunjukkan keunggulannya dalam mencapai konvergensi lebih cepat dibandingkan *optimizer* lain (Polat & Koy, 2024). Evaluasi model dilakukan menggunakan tiga metrik utama: *MAE* (*Mean Absolute Error*), *RMSE* (*Root Mean Squared Error*), dan *MAPE* (*Mean Absolute Percentage Error*), dengan kriteria keberhasilan *MAPE* $<10\%$ yang termasuk kategori "sangat baik" (Setiawan & Ramdhani, 2024).

Implementasi akhir berupa aplikasi web interaktif berbasis *Streamlit* yang memungkinkan prediksi real-time dan visualisasi data. Pengembangan aplikasi mengadopsi best practice dari penelitian terbaru tentang integrasi model prediksi dengan antarmuka pengguna [20]. Seluruh proses penelitian dirancang mengikuti prinsip *reproducible research* dengan dokumentasi kode dan parameter yang lengkap.

4. HASIL DAN PEMBAHASAN

4.1. Business Understanding

Tujuan dari penelitian ini adalah, untuk mengembangkan sistem yang dapat memprediksi harga Bitcoin. Selain itu, project ini diharapkan dapat memberikan kontribusi terhadap bidang keilmuan tentang forecasting dan

4.2. Data Understanding

Pada tahap ini, digunakan proses pengumpulan data yang menggunakan metode crawling data. Data yang diambil adalah data *Bitcoin (BTC-USD)* dari *website yahoo finance* menggunakan modul *yfinance* dalam bahasa pemrograman *Python* untuk mengambil data historis *Bitcoin* dari tahun 2021 sampai dengan saat ini. Dibawah ini adalah script untuk mengambil dari *yahoo finance*:

```
# download the data
df = yf.download('BTC-USD', start='2021-01-01', end=datetime.now())
```

Gambar 2. Crawling Data Bitcoin

Data yang di ambil berjumlah 1609 baris data. Data yang diambil meliputi informasi, Harga penutupan (*Close*), Harga tertinggi (*High*), Harga terendah (*Low*), Harga pembukaan (*Open*), dan Volume perdagangan (*Volume*). Berikut adalah script untuk mendeskripsikan isi data beserta outputnya:

```
df.describe()
```

Gambar 3. Describe Data

Tabel 2. Hasil Describe Data

Price	Close	High	Low	Open	Volume
Ticker	BTC-USD	BTC-USD	BTC-USD	BTC-USD	BTC-USD
count	1609	1609	1609	1609	1.609000e+03
mean	47347.330064	48310.356055	46241.326210	47300.288110	3.412961e+10
std	23410.180795	23815.662086	22916.331549	23364.833594	2.128916e+10
min	15787.284180	16253.047852	15599.046875	15782.300781	5.331173e+09
25%	28175.816406	28618.751953	27588.501953	28169.726562	2.012795e+10
50%	42412.433594	43243.167969	41676.488281	42406.781250	2.986748e+10
75%	61649.679688	63174.304688	60361.351562	61612.804688	4.146998e+10
max	111673.281250	111970.171875	109285.070312	111679.359375	3.509679e+11

4.3. Data Preparation

Dataset yang sudah diperoleh langsung dipersiapkan dan di lakukan spliting dengan *ratio* 95% *train* dan 5% *test*. Berikut kode yang saya gunakan:

```
# Create a new dataframe with only the 'Close column
data = df[['Close', 'BTC-USD']]

data = data.to_frame()
# Convert the dataframe to a numpy array
dataset = data.values
# Get the number of rows to train the model on
training_data_len = int(np.ceil( len(dataset) * .95 ))

training_data_len
```

Gambar 4. Train dan Test Dataset

Tabel 3. Hasil Train dan Test Dataset

Data	Train	Test
Jumlah	1529	80
Persentase	95%	5%

Setelah dilakukan *splitting* data selanjutnya datanya di normalisasi dan *scaling* menggunakan *MinMaxScaler* dengan fitur *range* 0 hingga. Dapat di lihat pada gambar berikut:

```
# Scale the data
from sklearn.preprocessing import MinMaxScaler

scaler = MinMaxScaler(feature_range=(0,1))
scaled_data = scaler.fit_transform(dataset)

scaled_data
```

Gambar 5. Normalisasi Dataset

Setelah semua data di *scaling* menggunakan *MinMaxScaler*. Selanjutnya masuk ketahapan pembuatan data training yang di ambil dari data yang sudah di scale

```
# Create the scaled training data set
train_data = scaled_data[0:int(training_data_len), :]
```

Gambar 6. Create Data Training

Selanjutnya membuat *sequence* untuk model *LSTM*nya. yang dimana *x_train* akan berisi *sequence*(urutan) data sepanjang 60 *time_steps* dan *y_train* akan berisi nilai target (nilai berikutnya setelah 60) dan *looping* akan dimulai dari *i=60* karena *sequence* pertama kita butuh 60 data sebelumnya untuk skrip kodenya ada pada gambar berikut :

```
# Split the data into x_train and y_train data sets
x_train = []
y_train = []

for i in range(60, len(train_data)):
    x_train.append(train_data[i-60:i, 0])
    y_train.append(train_data[i, 0])
    if i <= 61:
        print(x_train)
        print(y_train)
        print()
```

Gambar 7. Split Dataset

Lalu data perlu diubah menjadi *numpy array* agar bisa memenuhi kompatibilitas dengan model *LSTM* dan data perlu di *reshape* menjadi *3D* karena model *LSTM* memerlukan data *3D* (*samples*, *train_steps*, dan *features*). Untuk implementasi kodenya ada pada gambar berikut:

```
# Convert the x_train and y_train to numpy arrays
x_train, y_train = np.array(x_train), np.array(y_train)

# Reshape the data
x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))
# x_train.shape
```

Gambar 8. Reshape 2D ke 3D

Untuk *x_train_shape[0]* adalah jumlah *sample/sequence* sedangkan *x_train_shape[1]* adalah panjang *sequencenya* (yaitu 60 *timesteps*), Dan untuk jumlah fiturnya ada 1

4.4. Modeling

Pada tahapan modeling ini ada dua sub tahapan yang terjadi pertama pemilihan parameter dan yang kedua adalah konstruksi model

Pada tahap pemilihan parameter untuk menentukan parameternya sebagai berikut:

- Hidden layer* : 2 layer *LSTM*
- Dense layer* : 1 layer
- Neuron* : *Layer LSTM* (128,64) *Layer Dense* (32)
- Batch Size* : 1
- Epoch* : 10
- Optimizer* : *Nadam*

Untuk penentuan pemilihan parameter didasari dengan hasil komparasi yang dilakukan untuk pengetesan beberapa *optimizer* dengan *epoch* yang berbeda terhadap prediksi harga *bitcoin* ini yang menghasilkan tabel sebagai berikut:

Tabel 4. Hasil Perbandingan *Optimizer*, *Epoch*, dan Evaluasi

<i>Optimizer</i>	<i>Epochs</i>	<i>RMSE</i>	<i>MAE</i>	<i>MAPE%</i>	<i>Training Time (s)</i>
<i>Adam</i>	1	2710.7118	2158.0784	2.3431%	31.5130
<i>Adam</i>	10	4533.8646	4094.2688	4.3307%	278.2623
<i>Adam</i>	50	5336.9013	4913.6415	5.1855%	1398.2946
<i>Adam</i>	100	2263.9015	1794.3874	1.9950%	3003.4220
<i>RMSprop</i>	1	14439.3020	14044.1527	14.9958%	43.7736
<i>RMSprop</i>	10	2570.0578	2113.2990	2.3541%	415.8964
<i>RMSprop</i>	50	2402.7361	1863.6198	2.0000%	1122.7788
<i>RMSprop</i>	100	2264.5597	1783.7953	1.9623%	2192.5604
<i>SGD</i>	1	20725.9948	19895.7706	20.8877%	21.1459
<i>SGD</i>	10	5467.1070	4462.3383	4.6282%	182.6176
<i>SGD</i>	50	4847.3691	3934.9678	4.1126%	908.5176
<i>SGD</i>	100	3876.5480	3152.4900	3.3461%	2247.8784
<i>Nadam</i>	1	7014.2657	6454.5559	6.7866%	24.8411
<i>Nadam</i>	10	2021.6570	1427.2104	1.5699%	216.9420
<i>Nadam</i>	50	2115.5573	1540.8954	1.6712%	1295.6229
<i>Nadam</i>	100	2761.4182	2223.4599	2.3537%	2625.0380

Dilihat dari tabel di atas hasil dari *optimizer nadam* dengan *epoch* 10 merupakan parameter yang paling optimal dibandingkan dengan 15 kombinasi parameter lainnya. Yang dimana kombinasi *optimizer*

nadam dengan *epoch* 10 mampu memberikan hasil *RSME* dengan nilai 2021.6570 , *MAE* dengan nilai 1427.2104 dan *MAPE* dengan nilai 1.5699%

Selanjutnya, Setelah parameter ditentukan maka model sudah bisa *diconstruct* seperti pada gambar dibawah ini:

```
from keras.models import Sequential
from keras.layers import Dense, LSTM

# Build the LSTM model
model = Sequential()
model.add(LSTM(128, return_sequences=True, input_shape= (x_train.shape[1], 1)))
model.add(LSTM(64, return_sequences=False))
model.add(Dense(32))
model.add(Dense(1))

# Compile the model
model.compile(optimizer='Nadam', loss='mean_squared_error')

# Train the model
model.fit(x_train, y_train, batch_size=1, epochs=10)
```

Gambar 9. Model LSTM

4.5. Evaluation

Selanjutnya, kinerja model dievaluasi menggunakan metrik seperti Root Mean Squared Error (RMSE), Mean Absolute Errors (MAE), dan Mean Absolute Percentage Errors (MAPE). Berikut bentuk kode pengevaluasiannya ada pada gambar berikut:

```
# Calculate error metrics
rmse = np.sqrt(np.mean(((predictions - y_test) ** 2)))
mae = mean_absolute_error(y_test, predictions)
mape = np.mean(np.abs((y_test - predictions) / y_test)) * 100

print('Root Mean Squared Error (RMSE):', rmse)
print('Mean Absolute Error (MAE):', mae)
print('Mean Absolute Percentage Error (MAPE):', mape, '%')
```


Gambar 10. Model Evaluasi

Dan setelah dievaluasi mendapatkan hasil seperti yang ditampilkan di tabel di bawah:

Tabel 5. Hasil Evaluasi

Metrik	Hasil
RMSE	1983.4696
MAE	1403.3701
MAPE	1.5192

Setelah itu saya memvisualisasikan hasil prediksi dengan data val menggunakan grafik dengan hasil seperti pada gambar berikut:



Gambar 11. Visualisasi Aktual vs Prediksi

Dan untuk hasil prediksi, diuraikan pada tabel berikut:

Tabel 6. Hasil Aktual vs Prediksi


Date	Aktual	Predictions
2025-06-04	104731.984375	105286.546875
2025-06-05	101575.953125	104665.687500
2025-06-06	104390.343750	101890.648438
2025-06-07	105615.625000	104115.664062
2025-06-09	105730.156250	105275.492188

4.6. Deployment

Setelah menyelesaikan tahapan tahapan di atas, langkah selanjutnya adalah mengimplementasikan antarmukanya menggunakan *platfrom machine learning* yaitu *streamlit*, implementasi ini bertujuan agar dapat membantu pengguna lebih memahami dan menggunakan aplikasi lebih mudah. Untuk memberikan akses yang lebih mudah maka aplikasi dibuat menjadi beberapa halaman:

4.7. Halaman Home

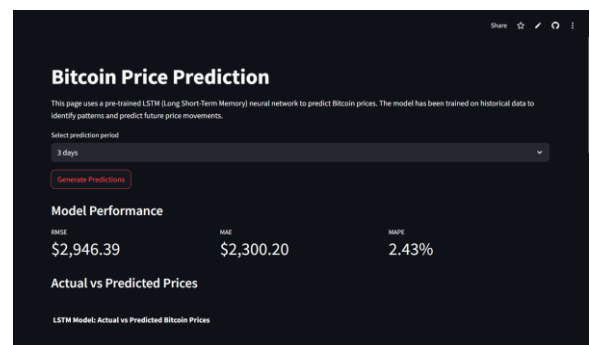
Halaman *home* ini berfungsi sebagai dasbor utama yang memberikan informasi data *bitcoin* secara *realtime* yang dimana data tersebut diambil otomatis dari *yahoofinance*. Berikut tampilan halaman *home* ada pada gambar berikut:



Gambar 12. Tampilan Halaman Home

4.8. Halaman Prediksi

Pada halaman ini akan memprediksi harga *bitcoin* dari mulai 1, 3, hingga 7 hari selanjutnya dan pada halaman ini ditampilkan data prediksi

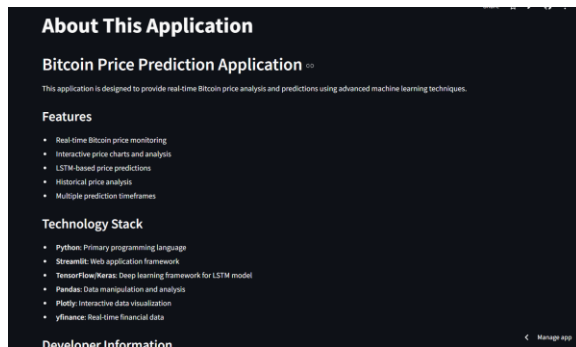


Gambar 13. Tampilan Halaman Prediksi

Jika tombol *generate prediction* akan menampilkan tampilan seperti pada gambar di atas. tampilan akan muncul hasil prediksi grafik prediksi beberapa hari kebelakang dan juga tabel prediksi dalam kurun waktu yang ditentukan.

4.9. Halaman About

Halaman terakhir ini berisikan halaman tentang penjelasan fitur, kegunaan aplikasi, pembuat aplikasi dan lain lain. Berikut tampilan halaman *about* seperti pada gambar berikut:



Gambar 14. Tampilan Halaman About

4.10. Tautan Aplikasi

Pada gambar berikut adalah tautan aplikasi melalui QR Code:



Gambar 15. Qr Code

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengimplementasikan model *Long Short-Term Memory (LSTM)* untuk memprediksi harga *Bitcoin* dengan akurasi tinggi, dibuktikan melalui nilai *MAPE* 1,5192% (kategori "sangat baik"), *MAE* 1403,3701, dan *RMSE* 1983,4696. Hasil ini memenuhi tujuan penelitian untuk mengevaluasi kinerja *LSTM* dalam forecasting *cryptocurrency* menggunakan metrik evaluasi standar. Model menunjukkan kemampuan optimal dalam menangkap pola temporal data berkat arsitektur dua lapis (128 dan 64 neuron) serta penggunaan *optimizer Nadam* dengan 10 epoch. Implementasi aplikasi web berbasis *Streamlit* memperkuat kontribusi praktis penelitian dengan menyediakan alat prediksi yang interaktif dan mudah diakses.

Rekomendasi dikelompokkan menjadi tiga aspek:

Tindakan Praktis, Investor dapat memanfaatkan model ini sebagai alat pendukung keputusan, namun perlu mempertimbangkan faktor eksternal (seperti kebijakan regulasi atau sentimen pasar) yang belum terintegrasi dalam sistem. Pengembangan fitur notifikasi real-time dan analisis risiko akan meningkatkan utilitas aplikasi.

Pengembangan Teori, Perlu eksplorasi *hybrid* model (contoh: *LSTM + Attention Mechanism* atau *cryptocurrency*) untuk meningkatkan akurasi prediksi jangka panjang. Integrasi *variabel* makroekonomi dan data sosial media sebagai fitur tambahan juga dapat menjadi inovasi teoretis. Penelitian Lanjutan, Uji coba model pada aset kripto lain (contoh: *Ethereum*) dengan karakteristik volatilitas berbeda diperlukan untuk menguji generalisasi. Studi komparatif dengan metode

terbaru seperti *N-BEATS* atau *Temporal Fusion Transformer* juga direkomendasikan.

Dengan demikian, penelitian ini tidak hanya berkontribusi pada pengembangan model prediksi finansial, tetapi juga membuka peluang riset lanjutan di bidang analisis *time series* dan *machine learning*.

DAFTAR PUSTAKA

- [1] CNBC, "Trump's Protectionist Policies Shake Global Markets," <https://www.cnbc.com>.
- [2] Bloomberg, "AS-China Trade War Intensifies as New Tariffs Take Effect," <https://www.bloomberg.com>. Accessed: Jun. 17, 2025. [Online]. Available: <https://www.bloomberg.com>
- [3] Cointelegraph, "Bitcoin as Digital Gold: Safe Haven in Turbulent Times," <https://www.cointelegraph.com>.
- [4] Kompas, "Pasar Kripto Indonesia Terbesar di ASEAN," <https://www.kompas.com>. Accessed: Jun. 17, 2025. [Online]. Available: <https://www.kompas.com>
- [5] Kontan, "Dualisme Regulasi Kripto Masih Jadi Tantangan," <https://www.kontan.co.id>.
- [6] CoinDesk, "Bitcoin Price Rebounds After Sharp Decline," <https://www.coindesk.com>.
- [7] DetikFinance, "Dampak Volatilitas Bitcoin bagi Investor RI," <https://finance.detik.com>. Accessed: Jun. 17, 2025. [Online]. Available: <https://finance.detik.com>
- [8] Investor Daily, "Fenomena FOMO di Kalangan Investor Kripto Pemula," <https://investor.id>.
- [9] R. Fauzi, "IMPLEMENTASI ALGORITMA KRIPTOGRAFI ELGAMAL UNTUK PESAN RAHASIA BERBASIS WEB DI MARKAS PMI KOTA TANGERANG," 50 | *Jurnal Ilmu Komputer JIK*, vol. VI, no. 03, 2023.
- [10] R. Akbar, R. Santoso, and B. Warsito, "PREDIKSI TINGKAT TEMPERATUR KOTA SEMARANG MENGGUNAKAN METODE LONG SHORT-TERM MEMORY (LSTM)," *Jurnal Gaussian*, vol. 11, no. 4, pp. 572–579, Feb. 2023, doi: 10.14710/j.gauss.11.4.572-579.
- [11] M. Owen, V. Vincent, R. Br Ambarita, and E. Indra, "IMPLEMENTASI METODE LONG SHORT TERM MEMORY UNTUK MEMPREDIKSI PERGERAKAN NILAI HARGA EMAS," *Jurnal Teknik Informasi dan Komputer (Tekinkom)*, vol. 5, no. 1, p. 96, Jun. 2022, doi: 10.37600/tekinkom.v5i1.507.
- [12] D. Reskianto and M. Agung Barata, "Forecasting Metode Single Exponential Smoothing Dalam Meramalkan Penjualan Barang," *JIP (Jurnal Informatika Polinema)*, vol. 9, no. 4, pp. 435–444, Aug. 2023.
- [13] F. Ramdhani and K. Setiawan, "Penerapan Data Mining untuk Prediksi Pelanggan di PT. XYZ Menggunakan Algoritma Linear Regression," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 2, pp.

- 490–497, Feb. 2024, doi: 10.57152/malcom.v4i2.1217.
- [14] H. K. Sugandi, N. S. Harahap, E. P. Cynthia, F. Yanto, and S. Sanjaya, “RANCANG BANGUN APLIKASI SIMULASI MINING PADA JARINGAN BLOCKCHAIN BITCOIN,” *Sebatik*, vol. 26, no. 1, pp. 332–339, Jun. 2022, doi: 10.46984/sebatik.v26i1.1875.
- [15] I. Dwi Kurniawan, S. Sasono, I. Septiningsih, B. Santoso, and M. Rustamaji, “HUKUM (LEGAL PROTECTION) KONSUMEN DI INDONESIA,” Online, 2021. [Online]. Available: <https://jurnal.unsur.ac.id/jmj>
- [16] N. Latif, J. Durai Selvam, M. Kapse, V. Sharma, and V. Mahajan, “Comparative Performance of LSTM and ARIMA for the Short-Term Prediction of Bitcoin Prices,” *AABFJ*, vol. 17, no. 1, 2023.
- [17] M. F. Rizkilloh and S. Widiyanesti, “Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM),” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 25–31, Feb. 2022, doi: 10.29207/resti.v6i1.3630.
- [18] M. Istaltofa, Sarwido, and A. Sucipto, “Comparison of Linear Regression and LSTM (Long Short-Term Memory) in Cryptocurrency Prediction,” *Journal of Dinda Data Science, Information Technology, and Data Analytics*, vol. 4, no. 2, pp. 141–148, 2024, [Online]. Available: <http://journal.ittelkom-pwt.ac.id/index.php/dinda>
- [19] K. Setiawan and F. Ramdhani, “Penerapan Data Mining untuk Prediksi Pelanggan di PT. XYZ Menggunakan Algoritma Linear Regression,” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 2, pp. 490–497, Feb. 2024, doi: 10.57152/malcom.v4i2.1217.
- [20] M. B. Julyano, S. A. Wibowo, and K. Usman, “Desain dan Implementasi Website Harvest Lens Prediksi Harga Beras Menggunakan Framework Streamlit,” vol. 11, 2024.