

## **IMPLEMENTASI LONG SHORT- TERM MEMORY UNTUK MEMPREDIKSI HARGA SHIBA INU BERBASIS WEBSITE MENGGUNAKAN PLATFORM PYTHON**

**Sahat Monang Barasa<sup>1</sup>, Elmanani Simamora<sup>2</sup>, Arnita<sup>3</sup>, Mansur<sup>4</sup>, Kana Saputra<sup>5</sup>**

Ilmu Komputer, Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Medan

Jl. Willem Iskandar / Pasar V, Medan, Sumatera Utara

E-mail: \*[sahatmonangbarasa28@gmail.com](mailto:sahatmonangbarasa28@gmail.com)<sup>1</sup>, [elmanani\\_simamora@unimed.ac.id](mailto:elmanani_simamora@unimed.ac.id)<sup>2</sup>, [arnita@unimed.ac.id](mailto:arnita@unimed.ac.id)<sup>3</sup>,  
[asmansur@unimed.ac.id](mailto:asmansur@unimed.ac.id)<sup>4</sup>, [kanasaputras@unimed.ac.id](mailto:kanasaputras@unimed.ac.id)<sup>5</sup>

**Abstrak** - Revolusi Industri 4.0 telah menghadirkan transformasi besar dalam berbagai sektor, termasuk keuangan digital melalui perkembangan mata uang kripto. Salah satu aset kripto yang cukup populer adalah Shiba Inu, yang dikenal memiliki volatilitas harga yang tinggi dan sangat dipengaruhi oleh dinamika global. Untuk membantu investor dalam mengambil keputusan yang lebih tepat, diperlukan model prediksi harga yang andal. Penelitian ini menggunakan metode Long Short-Term Memory (LSTM), yaitu algoritma Recurrent Neural Network (RNN) yang dirancang untuk menangani data deret waktu dan mampu mengingat pola historis secara lebih efektif dibandingkan metode statistik tradisional seperti AR, MA, dan ARIMA. Model dibangun menggunakan bahasa pemrograman Python dan diintegrasikan ke dalam sebuah platform berbasis web guna memberikan akses prediksi secara real-time. Hasil dari penelitian ini menunjukkan bahwa LSTM memiliki performa prediksi yang lebih akurat dalam menangani fluktuasi harga Shiba Inu. Diharapkan, model ini dapat menjadi alat bantu pengambilan keputusan investasi yang lebih cerdas dan responsif terhadap perubahan pasar kripto.

**Kata Kunci:** Shiba Inu, Prediksi Harga, LSTM, Cryptocurrency, RNN, Data Deret Waktu, Python, Web-based Prediction

### **I. PENDAHULUAN**

Cryptocurrency adalah mata uang elektronik yang menggunakan kriptografi dan jaringan terdesentralisasi yang disebut blockchain untuk memungkinkan transaksi yang aman tanpa perlu perantara (Dharma and Gusniati, 2023). Cryptocurrency menawarkan berbagai keuntungan, seperti transaksi yang lebih cepat dan lebih murah, privasi dan keamanan yang lebih baik, dan potensi lindung nilai terhadap inflasi. Namun, mereka juga menimbulkan risiko yang signifikan, seperti volatilitas pasar, ketidakpastian peraturan, dan kerentanan terhadap serangan dunia maya (Chohan, Usman W, 2022). Salah satu karakteristik utama dari cryptocurrency adalah bahwa ia tidak terpusat atau dikendalikan oleh lembaga keuangan atau pemerintah, melainkan dijalankan oleh jaringan peer-to-peer yang dikelola oleh pengguna yang berpartisipasi dalam proses verifikasi transaksi dan pengelolaan jaringan (N.Huda, R. Hambali, 2020).

Shiba Inu mulai diperkenalkan ke dalam pasar aset kripto pada bulan Agustus 2020 dan berjalan di atas jaringan Ethereum. Seiring waktu, aset ini semakin menarik minat investor. Tingginya tingkat volatilitas di dunia cryptocurrency dapat tercermin dari perubahan ekonomi global, seperti melemahnya pasar keuangan internasional, terjadinya krisis finansial pada sejumlah perusahaan, meningkatnya angka pengangguran, serta pergeseran pola konsumsi masyarakat. Seluruh perubahan tersebut memberikan dampak

signifikan terhadap pergerakan aset kripto, yang cenderung menunjukkan fluktuasi yang tidak stabil dan tidak terstruktur jika dibandingkan dengan instrumen investasi seperti saham. Oleh karena itu, pasar cryptocurrency dianggap lebih berisiko dan lebih kompleks untuk diprediksi (Kuncara & Anugrah, 2023). Pasar Shiba Inu saat ini memiliki persediaan koin sebanyak 589 Triliun lebih dengan harga Shiba Inu terakhir yang diketahui adalah 0,00002328 USD dan bisa naik 0,000043 USD selama 24 jam terakhir.

Sementara itu, analisis time series sendiri merupakan teknik dalam pengolahan data kuantitatif yang berfokus pada identifikasi pola berdasarkan urutan waktu (Wijayanti & Pulungan, 2012). Untuk data time series, beberapa model prediksi dapat diterapkan menggunakan teknik statistik dan teknik deep learning. Teknik statistik meliputi model-model, seperti model AR, MA, ARIMA. Model AR hanya mampu menangkap hubungan linear antara data masa lalu dan prediksi masa depan, sedangkan LSTM dapat menangani hubungan non-linear dengan baik, model MA hanya menggunakan kesalahan dari periode sebelumnya untuk membuat prediksi, sehingga tidak memanfaatkan data historis secara mendalam seperti LSTM, model ARIMA memerlukan proses konfigurasi dan pengujian parameter yang signifikan untuk setiap dataset, sementara LSTM dapat dilatih ulang untuk menangkap perubahan dinamis secara langsung tujuan dari penelitian ini adalah untuk menguji sejauh mana algoritma LSTM

efektif dalam meramalkan harga Shiba Inu, serta untuk mengevaluasi performa model LSTM dengan kombinasi parameter yang optimal. Penelitian yang berjudul "Prediksi Harga Cryptocurrency Menggunakan Algoritma LONG SHORT-TERM MEMORY (LSTM)" ini, yang dilakukan oleh Moch Farryz Rizkilloh pada tahun 2022, membahas proses pengembangan model prediksi guna memperkirakan harga pada pasar cryptocurrency. Fokus utama penelitian ini adalah untuk melihat bagaimana LSTM, yang dikenal dengan kemampuannya dalam menangani data runtun waktu, dapat diterapkan secara efektif dalam dunia cryptocurrency yang sangat fluktuatif.

## II. TINJAUAN PUSTAKA

### 2.1. Prediksi

Prediksi kuantitatif merupakan jenis prediksi yang berdasarkan pada data numerik atau kuantitatif yang diperoleh dari kejadian-kejadian yang terjadi di masa lalu. Hasil dari prediksi ini sangat dipengaruhi oleh metode yang digunakan dalam proses peramalan tersebut. Berbagai metode yang diterapkan akan menghasilkan prediksi yang berbeda, sehingga pemilihan metode yang tepat menjadi hal yang sangat penting. Keberhasilan metode ini sangat ditentukan oleh sejauh mana perbedaan atau penyimpangan antara prediksi dan kenyataan yang terjadi. Sebuah metode dapat dianggap baik jika mampu meminimalkan perbedaan atau penyimpangan antara nilai yang diperkirakan dan yang sebenarnya terjadi. Prediksi kuantitatif ini paling efektif digunakan dalam kondisi-kondisi tertentu, yaitu: a. Informasi tersebut dapat dikuantifikasikan ke dalam bentuk data. b. Memiliki informasi tentang keadaan yang lain. c. Bisa diasumsikan bahwa pola metode yang lalu akan dapat berkelanjutan pada masa yang akan datang.

### 2.2. Deep Learning

Dalam konteks Feature Engineering, algoritma yang digunakan bertujuan untuk mengenali pola penting yang mampu membedakan antar kelas. Salah satu pendekatan yang banyak diterapkan oleh para peneliti untuk membangun sistem prediksi adalah melalui teknik data mining. Deep learning sendiri terdiri dari Berbagai algoritma yang fokus pada pembelajaran representasi data secara bertingkat dan nonlinear telah dikembangkan. Salah satunya adalah algoritma Long Short-Term Memory (LSTM), yang merupakan pengembangan dari model Recurrent Neural Network (RNN). LSTM telah terbukti efektif dalam memprediksi data deret waktu (Sianturi, Cholissodin, & Yudistira, 2023).

### 2.3. Neural Network

Neural meniru cara kerja neuron sebagai langkah untuk menciptakan mesin 10 cerdas. Dalam prosesnya, Neural Network tidak secara langsung diprogram untuk menghasilkan keluaran tertentu. Sebaliknya, semua output yang dihasilkan oleh jaringan bergantung pada pengalaman yang diperoleh selama tahap pembelajaran. Pada tahap ini, jaringan diberikan pola-pola input yang kemudian digunakan untuk melatihnya menghasilkan jawaban yang sesuai. Proses pembelajaran dilakukan dengan mengatur bobot pada setiap node dalam jaringan untuk mencapai hasil yang diharapkan (Prasetyo, 2017).

### 2.4. Time Series

Dalam peramalan data time series, sangat penting untuk memahami tipe atau pola data yang ada. Secara umum, terdapat empat jenis pola dalam data time series, yaitu pola horizontal, tren, musiman, dan siklis (Hanke dan Wichren, 2005: 158). Setiap pola ini mempengaruhi cara analisis dan peramalan dilakukan, tergantung pada karakteristik data yang diamati. LSTM dalam Time Series: 1. LSTM merupakan pengembangan dari Recurrent Neural Network (RNN) yang dirancang untuk memproses data berurutan. 2. LSTM memiliki kemampuan untuk mengingat informasi dalam jangka waktu yang lebih lama, sehingga sangat efektif untuk analisis time series. 3. LSTM dapat digunakan untuk berbagai aplikasi, seperti prediksi harga saham, cuaca, dan permintaan produk. Keunggulan LSTM dalam Analisis Time Series: 1. Mengatasi Vanishing Gradient: LSTM dirancang untuk mengatasi masalah vanishing gradient yang sering terjadi pada RNN, memungkinkan model untuk belajar dari data dalam jangka panjang. 2. Fleksibilitas: LSTM dapat menangani data dengan pola yang kompleks dan tidak teratur, membuatnya cocok untuk berbagai jenis time series. 3. Kemampuan Memori: Dengan struktur sel memori, LSTM dapat menyimpan informasi penting dan melupakan informasi yang tidak relevan, meningkatkan akurasi prediksi. Dalam analisis deret waktu, dikenal adanya komponen fluktuasi acak. Fluktuasi ini mencerminkan perubahan yang tidak dapat diprediksi, biasanya muncul akibat kejadian-kejadian tak terduga seperti kondisi cuaca ekstrem, aksi mogok kerja, konflik bersenjata, pemilu, hingga penyebaran isu-isu seperti desas-desus perang, dan sebagainya (Nawangwulan & Angesti, 2016).

### 2.5. Artificial Neural Network

Setelah jaringan mampu menangkap fitur-fitur ini, peneliti dapat menetapkan label pada hasil output, lalu menerapkan metode backpropagation untuk memperbaiki prediksi yang keliru. Dengan pelatihan berulang, sistem akan mampu melakukan

klasifikasi secara mandiri tanpa perlu intervensi manusia secara terusmenerus. Namun, salah satu kelemahan dari Artificial Neural Network (ANN) adalah ketidakmampuannya untuk mempertahankan informasi dari data sebelumnya. Untuk mengatasi keterbatasan ini, digunakan arsitektur Recurrent Neural Network (RNN), yang memiliki kemampuan mempertahankan informasi dari waktu ke waktu melalui loop internal di dalam jaringannya.

#### **2.6. Long Short-Time Memory (LSTM)**

Long-Short Term Memory (LSTM) merupakan salah satu bentuk dari RNN yang sering digunakan untuk menghindari masalah pada penumpukan pada gradien atau ketergantungan jangka panjang dalam memproses ataupun melakukan prediksi terhadap data deret waktu. RNN cenderung memiliki penumpukan pada gradien yang menyebabkan nilai gradien saling bertabrakan sehingga terdapat nilai gradien yang tidak jelas dan dapat menghilangkan nilai akumulasinya sehingga diperlukan LSTM untuk menghindari hal tersebut terjadi (Cholissodin and Soebroto, 2019). Model LSTM terbentuk dari berbagai rangkaian sel memori yang dapat mengantikan sel neuron pada hidden layer dari RNN (Sepp Hochreiter & Jurgen Schmidhuber). Model LSTM dapat menyaring data atau informasi melalui struktur gates untuk dapat mempertahankan informasi yang berhubungan dan mengubah keadaan dari sel memori. Struktur gerbang tersebut mencakup input gate, forget gate, dan output gate (Dhea Larasati & Primandari, 2021).

#### **2.7. Adam Optimizer**

Adam untuk secara efektif mengatasi masalah dalam model yang kompleks dan besar, menjadikannya pilihan populer dalam berbagai jenis aplikasi machine learning (Desi Irfan dkk, 2022). Algoritma ini menggabungkan keuntungan dari dua teknik optimasi lain, yaitu momentum dan adaptive gradient, sehingga dapat meningkatkan konvergensi dengan lebih cepat dan stabil.

#### **2.8. MAE (Mean Absolute Error)**

Metode ini menghitung rata-rata selisih absolut antara nilai yang diprediksi dan nilai aktual. Dengan menggunakan MAE, kita dapat memperoleh nilai yang tidak dipengaruhi oleh tanda negatif, sehingga memudahkan perbandingan antara nilai prediksi dan nilai target yang diinginkan (Hudzaifah dkk, 2019).

#### **2.9. Cryptocurrency**

Cryptocurrency atau mata uang kripto menggunakan algoritma kriptografi untuk menghasilkan dan mengelola transaksi, serta menjaga keamanan sistemnya. Seperti halnya mata uang fisik, cryptocurrency tidak memiliki bentuk

fisik, dan transaksi diatur melalui rangkaian kode yang dikenal sebagai blockchain, yang berfungsi sebagai buku besar digital yang terdistribusi. Pengelolaan dan pengawasan mata uang ini dilakukan langsung oleh komunitas pengguna, bukan oleh lembaga otoritas (Goleman, 2018).

#### **2.10. Shiba Inu**

Shiba Inu, yang juga dikenal dengan nama SHIB, adalah sebuah mata uang kripto yang diluncurkan pada tahun 2020 oleh Ryoshi. Nama mata uang ini diambil dari ras anjing Shiba Inu, yang menjadi simbol terkenal di kalangan komunitas kripto. Shiba Inu termasuk dalam kategori altcoin, yaitu jenis mata uang kripto selain Bitcoin.

#### **2.11. Python**

Python adalah kerangka kerja yang disediakan untuk mempermudah pengembangan aplikasi dengan Python. Framework menyediakan struktur, pustaka, dan alat yang memudahkan pengembang dalam membangun aplikasi tanpa harus menulis kode dari awal. Dalam pengembangan web, framework Python membantu menangani tugas-tugas umum seperti pengelolaan permintaan HTTP, pengelolaan database, dan autentikasi pengguna (Asrul Huda, 2020).

#### **2.12. Penelitian Terdahulu**

Berikut ini adalah rangkuman dari beberapa penelitian serupa yang relevan dan terkait langsung dengan topik yang sedang dibahas dalam penelitian ini.

1. Analisa Prediksi Harga Saham Sektor Perbankan Menggunakan Algoritma LongShortTermMemory (Riyantoko et al., 2020). Metode yang digunakan Long Short Term Memory. Pada penelitian ini didapatkan beberapa percobaan ini mencakup analisis terhadap model optimasi, variasi epoch, waktu komputasi, akurasi, nilai loss, serta RMSE. Semakin besar nilai epoch, semakin lama waktu komputasi yang dibutuhkan untuk menyelesaikan algoritma LSTM, karena peningkatan epoch akan memperpanjang proses perhitungan.
2. Penerapan Algoritma Long Short-Term Memory (LSTM) Berbasis Multifungsi Aktivitas Terbobot Dalam Prediksi harga Ethereum (Sianturi, Cholissodin and Yudistira, 2023). Metode yang digunakan Long Short Term Memory. Penerapan algoritma LongShort Term Memory (LSTM) untuk memprediksi harga Ethereum menghasilkan nilai yang paling optimal dengan proporsi data pelatihan (training) dan data pengujian (testing) sebesar 70:30, serta sequence data sebanyak 14 yang menggambarkan jumlah langkah waktu yang

digunakan dalam model data dalam 2 minggu, nilai hidden unit sebesar 64, jumlah epoch sebesar 150, dan multi fungsi aktivasi yang digunakan adalah sigmoid.

3. Analisis dan Implementasi Long Shortterm Memory Neural Network untuk Prediksi Harga Bitcoin (Aldi, Jondri and Aditsania, 2018). Metode yang digunakan Long Short Term Memory. Pada tugas akhir yang dilakukan oleh Aldi, Jondri, dan Aditsania (2018), model Long Short-Term Memory (LSTM) dikembangkan untuk memprediksi harga Bitcoin dengan menguji beberapa parameter, seperti komposisi data, jumlah pola time series, jumlah neuron tersembunyi, dan jumlah epoch maksimum. Hasil terbaik dari pengujian ini diperoleh dengan menggunakan komposisi data latih sebesar 70% dan 27 data uji 30%, satu pola time series, 25 neuron tersembunyi, serta maksimum epoch sebanyak 100. Akurasi yang tercapai adalah 95,36% pada data latih dan 93,5% pada data uji.

### III. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif, mengingat data yang dikumpulkan terkait dengan persediaan, permintaan, serta pengeluaran atau produksi bersifat kuantitatif. Jenis data yang digunakan dalam studi ini adalah data kuantitatif, yang mengacu pada data yang dapat diukur atau dihitung dalam bentuk angka atau bilangan. Data semacam ini memungkinkan untuk analisis numerik yang dapat menghasilkan kesimpulan yang lebih objektif dan terukur. Tahapan pada penelitian ini adalah:

1. Pengumpulan Data
2. Preprocessing Data
3. Alokasi Data
4. LONG SHORT- TERM MEMORY (LSTM)
5. Training Data
6. Testing Data
7. Evaluasi menggunakan MAE

### IV. HASIL DAN PEMBAHASAN

#### 4.1 Sumber Data

Data yang di ambil dari untuk penelitian ini yaitu dimulai dari bulan Maret tahun 2023 hingga Februari 2025. Pergerakan coin shiba inu selama periode dua tahun tersebut divisualisasikan pada Gambar 4.1 dalam bentuk Box Plot yang mencakup data close. Namun, karena padatnya jumlah data, grafik tersebut tampak menyerupai grafik garis. Selain itu, perbedaan nilai harian antara harga tertinggi (high), terendah (low), pembukaan (open), dan penutupan (close) tidak menunjukkan variasi yang signifikan.

Tabel 1. Contoh Data Crypto SHIBA INU

Tanggal	Open	Low	High	Close	Volume
2023-03-01	0.000012	0.000011	0.000012	0.000012	197
2023-03-02	0.022180	981844	068807	022873	2000
2023-03-03	2717424	1817187	3366181	3067051	

#### 4.2 Preprocessing

Proses preprocessing ini meliputi ekstraksi fitur, analisis statistik, pengurutan, normalisasi, pengelompokan data, dan pembagian dataset. Tujuannya agar data siap digunakan untuk pelatihan model prediksi dengan hasil yang lebih akurat. Berikut adalah penjelasannya:

##### 1. Ekstraksi Fitur

Nilai Rata-rata (Average):

Dihitung dari harga buka (open), tutup (close), tinggi (high), dan rendah (low) menggunakan rumus:

$$\text{Rata-rata} = \frac{\text{buka} + \text{tutup} + \text{tinggi} + \text{rendah}}{4}$$

Contoh perhitungan diberikan untuk beberapa hari.

Relative Strength Index (RSI):

Menggunakan periode 14 jam untuk menghitung perubahan harga.

RSI baru bisa dihitung mulai jam ke-15 karena membutuhkan data 14 jam sebelumnya.

Rumus RSI:

$$RSI = \frac{\text{Rata-rata Keuntungan}}{\text{Rata-rata Kerugian}}, RSI = 100 \frac{100}{1+RS}$$

Hasil perhitungan average dan RSI digabungkan ke dalam dataframe.

##### 2. Analisis Deskriptif

Dilakukan analisis statistik (mean, std, min, max, dll.) untuk memastikan konsistensi data sebelum diproses lebih lanjut.

##### 3. Pengurutan Data (Ascending)

Data diurutkan berdasarkan tanggal karena merupakan data time series.

##### 4. Normalisasi

Normalisasi dilakukan untuk menyamakan skala data ke rentang [0, 1].

Rumus normalisasi:

$$X_{\text{normalized}} = \frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}}$$

Contoh perhitungan diberikan untuk variabel High, Low, Open, dan Close.

##### 5. Segmentasi

Data dikelompokkan dalam rangkaian 30 titik data historis untuk memprediksi nilai target pada titik ke-31.

##### 6. Pembagian Data

Data dibagi menjadi:

Data Latih (Training Data): 14.063 data dari 8 tahun pertama.

Data Uji (Testing Data): 3.423 data dari 2 tahun terakhir.

Pembagian dilakukan berdasarkan tahun karena data time series tidak boleh diacak.

#### 4.3 Konstruksi Model LSTM

Tahap ini memerlukan penentuan model yang akan dibentuk berdasarkan parameter yang dipilih. Parameter-parameter yang dibutuhkan, antara lain:

1. Hidden Layer: 2
2. Neuron Hidden: 50
3. Batch size: 32
4. Epoch maksimum: 20
5. Optimizer: Adam
6. Fungsi aktivasi: ReLU dan Linear

Tabel 2. Model LSTM yang Terbentuk Menggunakan Python

Layer (type)	Output Shape	Param #
lstm_1(LSTM)	(None, 50, 50)	10,600
dropout_1(Dropout)	(None, 50, 50)	0
lstm_2(LSTM)	(None, 50)	20,200
Dropout_2(Dropout)	(None, 50)	0
dense_1(Dense)	(None, 1)	51

Model neural network ini dirancang dengan dua lapisan tersembunyi yang memiliki karakteristik unik. Lapisan pertama menerima input tiga dimensi yang mencakup tiga komponen utama: jumlah sampel data, langkah waktu (time steps), dan berbagai fitur yang digunakan. Pada lapisan kedua, terdapat 50 neuron yang secara kolektif menghasilkan 20.200 parameter melalui proses pembelajaran mesin. Untuk meningkatkan generalisasi model dan mencegah overfitting, diterapkan lapisan dropout yang berfungsi dengan cara menonaktifkan neuron secara acak selama pelatihan, meskipun lapisan ini tidak menambahkan parameter baru ke dalam model. Lapisan output terdiri dari sebuah neuron tunggal yang bertugas menghasilkan prediksi akhir sesuai dengan target yang diinginkan. Secara keseluruhan, arsitektur ini memiliki total 30.851 parameter, termasuk bobot dan bias, yang akan dioptimalkan selama proses training untuk meningkatkan akurasi prediksi model.

#### 4.4 Perhitungan Manual

##### 1. Inisialisasi Bobot dan Bias

Bobot (weights) dan bias pada model LSTM diacak secara otomatis oleh program. Tujuannya agar model bisa belajar menyesuaikan nilai optimal melalui pelatihan.

##### 2. Contoh Perhitungan pada Time Step t = 0

Forget Gate ( $f_t$ ):

Dihitung menggunakan fungsi sigmoid ( $\sigma$ ).

Contoh:

$$f_t = \sigma(-0.2509 \times 0.000012 + 0 + (-0.0688)) = 0.4828$$

Hasil: 0.4828 (menentukan informasi yang akan dilupakan).

Input Gate ( $i_t$ ) dan Kandidat Memori Baru ( $\tilde{c}$ ):

Input Gate:

$$i_t = \sigma(0.9014 \times 0.000012 + (-0.0688)) = 0.4828$$

Kandidat memori baru menggunakan tanh:

$$\tilde{c} = \tanh(0.4639 \times 0.000012 + (-0.0884)) = -0.0881$$

Update Cell State ( $c_t$ ):

$$c_t = (f_t \times c_{t-1}) + (i_t \times \tilde{c}) = (0.4828 \times 0) + (0.4828 \times -0.0881) = -0.0426$$

Output Gate ( $o_t$ ) dan Hidden State ( $h_t$ ):

Output Gate:

$$o_t = \sigma(0.1973 \times 0.000012 + 0.0732) = 0.5172$$

Hidden State:

$$H_t = \tanh(c_t) \times o_t = -0.0425 \times 0.5172 = -0.0220$$

##### 3. Lanjutan Perhitungan pada Time Step t = 1

Menggunakan nilai  $h_t$  dan  $c_t$  dari langkah sebelumnya.

Proses serupa diulang:

Forget Gate: 0.4842

Input Gate: 0.4828

Cell State baru: -0.0268

Output Gate: 0.4828

Hidden State baru: -0.0139

##### 4. Proses Berulang hingga Model Terlatih

Perhitungan dilakukan berulang untuk setiap time step.

Nilai  $h_t$  dan  $c_t$  terus diperbarui dan diwariskan ke langkah berikutnya.

Setelah pelatihan selesai, model siap digunakan untuk prediksi data time series.

#### 4.5 Pengujian Model

Pada tahap ini akan dilakukan proses pengujian dengan mengimplementasikan learned model dari proses training. Model yang paling optimal didapatkan dari parameter berikut:

1. Hidden Layer : 2
2. Neuron Hidden : 50
3. Batch size : 32
4. Epoch maksimum : 50
5. Optimizer : Adam
6. Fungsi aktivasi : ReLu dan Linear

Proses yang dilakukan pada tahap ini mirip dengan proses pelatihan, di mana semua nilai gates dihitung, termasuk forget gate, input gate, cell state, dan output gate, untuk mendapatkan nilai  $ct$  dan  $ht$  pada setiap time step. Nilai-nilai ini akan digunakan sebagai informasi untuk perhitungan gates pada time step berikutnya. Data yang diuji dalam proses ini berjumlah 3462 data, yang akan menghasilkan nilai prediksi sebagai output akhir. Contoh hasil dari proses pengujian dapat dilihat pada tabel 3.

Tabel 3. Hasil Prediksi

Tanggal	Data Uji	Prediksi (y)
2023-03-03 02:00:00+00:00	0.0000112	0.000011667463
2023-03-03 03:00:00+00:00	0.0000112	0.000011399627

Tanggal	Data Uji	Prediksi (y)
2023-03-03 04:00:00+00:00	0.0000113	0.000011211687
2025-02-26 21:00:00+00:00	0.0000143	0.000014012525
2025-02-26 22:00:00+00:00	0.0000144	0.000014107228
2025-02-26 23:00:00+00:00	0.0000144	0.000014208126

Data yang terdapat pada Tabel 4.3 akan dipulihkan ke bentuk aslinya melalui proses denormalisasi. Proses denormalisasi ini dilakukan dengan menggunakan rumus tertentu, di mana nilai  $mi(y)$  dan  $max(y)$  diambil dari informasi yang tercantum dalam tabel deskriptif data. Pada dasarnya, denormalisasi bertujuan untuk mengembalikan data yang telah dinormalisasi ke rentang nilai semula, sehingga data tersebut bisa lebih mudah diinterpretasikan. Dalam perhitungan ini, rumus yang digunakan akan melibatkan nilai minimum dan maksimum yang tercatat dalam data asli, memungkinkan kita untuk memulihkan nilai-nilai yang telah diproses sebelumnya. Dengan menggunakan pendekatan ini, hasil denormalisasi akan memberikan gambaran yang lebih jelas tentang data dalam konteks aslinya, memungkinkan analisis lebih lanjut yang lebih akurat dan relevan.

$$\begin{aligned}
 y_1 &= (\max y - \min y + \min (y) \\
 y_1 &= 0.000011667463(0.00004456 - \\
 &\quad 0.00000598) + 0.00000598 \\
 y_1 &= 0.00000598045 \\
 y_1 &= (\max y - \min y + \min (y) \\
 y_1 &= 0.000011399627(0.00004456 - \\
 &\quad 0.00000598) + 0.00000598 \\
 y_1 &= 0.0000059800 \\
 y_1 &= (\max y - \min y + \min (y) \\
 y_1 &= 0.000011211687(0.00004456 - \\
 &\quad 0.00000598) + 0.00000598 \\
 y_1 &= 0.0000059804325
 \end{aligned}$$

Tabel 4. Nilai Setelah Denormalisasi

Tanggal	Data Uji	Prediksi (y) Denormalisasi
22:00:00+00:00	000	
2025-02-26 23:00:00+00:00	0.000014400000	0.000005980548149501

#### 4.6 Perhitungan Nilai Akurasi

Pada tahap ini mencari nilai error pada hasil peramalan dengan menggunakan Mean Absolute Error (MAE) dan RMSE (Root Mean Squared Error).

$$\sum_{i=0}^n |y_{actual,i} - y_{predicted,i}|$$

Untuk setiap data, banyak data yang diambil pada perhitungan ini adalah 13, selisih absolut antara harga aktual dan harga prediksi dihitung sebagai berikut:

$$\begin{aligned}
 |0.00001123 - 0.00001125| &= 0.00000002 \\
 |0.00001130 - 0.00001128| &= 0.00000002 \\
 |0.00001130 - 0.00001128| &= 0.00000002 \\
 |0.00001130 - 0.00001128| &= 0.00000002 \\
 |0.00001140 - 0.00001142| &= 0.00000002 \\
 |0.00001140 - 0.00001142| &= 0.00000002 \\
 |0.00001140 - 0.00001142| &= 0.00000002 \\
 |0.00001150 - 0.00001148| &= 0.00000002 \\
 |0.00001150 - 0.00001148| &= 0.00000002 \\
 |0.00001150 - 0.00001148| &= 0.00000002 \\
 |0.00001160 - 0.00001162| &= 0.00000002 \\
 |0.00001160 - 0.00001162| &= 0.00000002 \\
 |0.00001160 - 0.00001162| &= 0.00000002
 \end{aligned}$$

Jumlahkan setiap hasil kemudian bagikan dari banyaknya jumlah

$$MAE = \frac{13(0.00000002)}{13}$$

$$MAE = 0.00000002$$

Berdasarkan perhitungan manual, nilai Mean Absolute Error (MAE) adalah 0.00000002 (2e-08). Nilai MAE yang sangat kecil ini menunjukkan bahwa model memiliki performa yang sangat baik dalam memprediksi harga SHIB.

Perhitungan manual nilai RMSE (Root Mean Squared Error).

$$\begin{aligned}
 RMSE &= \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{actual,i} - y_{predicted,i})^2} \\
 0.00001123 - 0.00001125 &= -0.00000002 \\
 0.00001130 - 0.00001128 &= 0.00000002 \\
 0.00001130 - 0.00001128 &= 0.00000002 \\
 0.00001130 - 0.00001128 &= 0.00000002 \\
 0.00001140 - 0.00001142 &= -0.00000002 \\
 0.00001140 - 0.00001142 &= -0.00000002 \\
 0.00001140 - 0.00001142 &= -0.00000002 \\
 0.00001150 - 0.00001148 &= 0.00000002 \\
 0.00001150 - 0.00001148 &= 0.00000002 \\
 0.00001150 - 0.00001148 &= 0.00000002
 \end{aligned}$$

$$\begin{aligned}
 0.00001160 - 0.00001162 &= -0.00000002 \\
 0.00001160 - 0.00001162 &= -0.00000002 \\
 0.00001160 - 0.00001162 &= -0.00000002 \\
 \text{Kemudian dari perhitungan di atas di} \\
 \text{kuadratkan} \\
 (-0.00000002)^2 &= 4 \times 10^{-16} \\
 (0.00000002)^2 &= 4 \times 10^{-16} \\
 \sum (y_{actual,i} - \hat{y}_{actual,i})^2 &= 13x4x10^{-16} \\
 \sum (y_{actual,i} - \hat{y}_{actual,i})^2 &= 52x10^{-16} \\
 \text{Hitung rata-rata error kuadrat} \\
 \frac{52x10^{-16}}{13} &= 4x10^{-16} \\
 \text{RMSE} &= \sqrt{4x10^{-16}} \\
 \text{RMSE} &= 2 \times 10^{-8} \\
 \text{RMSE} &= 0.00000002
 \end{aligned}$$

#### 4.7 Integrasi Model dan Website Menggunakan Flask

Integrasi model dan website menggunakan Flask berarti menghubungkan model machine learning dengan antarmuka web agar dapat digunakan secara interaktif. Flask berfungsi sebagai backend yang menerima input dari pengguna, memprosesnya dengan model, lalu mengirimkan hasil prediksi ke frontend. Website ini memiliki dua halaman utama:

1. Halaman Upload File – Pengguna dapat mengunggah file Shiba Inu Hourly Data dalam format CSV. Flask akan membaca file tersebut, melakukan preprocessing, dan memasukkan data ke dalam model prediksi.
2. Halaman Hasil Prediksi – Setelah file diproses, halaman ini menampilkan hasil prediksi dalam bentuk plot grafik yang membandingkan harga aktual dengan harga prediksi. Dengan pendekatan ini, pengguna dapat dengan mudah melakukan analisis tanpa perlu menjalankan kode secara manual.

### V. KESIMPULAN DAN SARAN

#### Kesimpulan

Berdasarkan uraian yang telah dibahas, beberapa kesimpulan yang dapat ditarik dari penelitian ini antara lain: 1. Desain sistem dari model LSTM menggunakan data harga SHIB dengan interval waktu per jam, yang mencakup satu fitur utama, yaitu Close Price. Data yang digunakan telah melalui proses normalisasi dengan MinMaxScaler untuk meningkatkan kinerja model. Pembagian data dilakukan dengan 80% sebagai data latih dan 20% sebagai data uji. Model yang dibangun terdiri dari dua lapisan LSTM dengan masing-masing 50 neuron, serta dropout layer untuk mengurangi overfitting. Model dilatih dengan batch size sebanyak 32, menggunakan optimizer Adam dan fungsi aktivasi default dari LSTM. 2. Evaluasi model dilakukan dengan menghitung nilai Mean Absolute Error (MAE), yang menunjukkan

rata-rata kesalahan absolut dalam prediksi harga SHIB. Dari hasil pelatihan selama 20 epoch, diperoleh MAE sebesar  $3.9788651374445924e-07$ , yang menandakan bahwa model memiliki tingkat error yang sangat kecil. Selain itu, hasil prediksi dibandingkan dengan harga aktual menggunakan visualisasi plot garis, yang menunjukkan bahwa model mampu mengikuti tren harga dengan baik. Namun, masih terdapat ruang untuk peningkatan, seperti penyesuaian parameter model dan eksplorasi arsitektur LSTM yang lebih kompleks agar hasil prediksi lebih akurat.

#### Saran

Untuk meningkatkan akurasi model prediksi harga SHIB, dapat dilakukan optimasi hyperparameter seperti jumlah neuron dalam LSTM layer, learning rate, dan batch size menggunakan Grid Search atau Bayesian Optimization. Selain itu, menambahkan fitur tambahan seperti Volume, Open, High, Low, atau indikator teknikal seperti RSI dan Moving Average dapat memberikan konteks lebih luas terhadap pergerakan harga. Model juga bisa ditingkatkan dengan eksplorasi arsitektur yang lebih kompleks, seperti penambahan Bi-LSTM atau kombinasi dengan CNN untuk memahami pola dalam data time series secara lebih baik. Evaluasi model juga sebaiknya tidak hanya menggunakan MAE, tetapi juga metrik lain seperti MSE, RMSE, atau MAPE agar performanya dapat dianalisis lebih komprehensif. Model ini juga sebaiknya bisa diimplementasikan model ini di dalam aplikasi mobile.

### DAFTAR PUSTAKA

- Andriani, N. (2021). Perancangan Aplikasi Menentukan Jumlah Produksi Roti Dengan Metode Fuzzy Tsukamoto Pada Pt. Chochointi Sejahtera. *Hexagon Jurnal Teknik Dan Sains*, 2(1), 57–62.  
<https://doi.org/10.36761/hexagon.v2i1.878>.
- Cholissodin, I., Sutrisno, S., Soebroto, A.A., Hasanah, U. and Febiola, Y.I., 2019. AI, Machine Learning & Deep Learning. *Filkom UB*. Available at: <http://www.researchgate.net/publication/348003841>
- Dani, dkk. 2023. Pemrograman Finansial Untuk Memprediksi Volatilitas Nilai Mata Uang Kripto Berbasis Deep Learning Melalui Implementasi Metode LSTM (Studi Kasus: Bitcoin, Ethereum, Tether dan Binance Coin)
- Deng, L. and Yu, D. (2013) ‘Deep learning: Methods and applications’, Foundations and Trends in Signal Processing, 7(3–4), pp. 197–387. Available at: <https://doi.org/10.1561/2000000039>.
- Dhea Larasati, K., & Primandari, A. H. (2021). Forecasting Bitcoin Price Based On

- Blockchain Information Using LongShort Term Method. In *Parameter: Journal of Statistics* (Vol. 1). [www.blockchain.com](http://www.blockchain.com)
- Hanke, J.E., and Wichern, D.W. 2005. Business Forecasting. Prentice Hall, New York.
- Huda, A. 2020. *Dasar-Dasar Pemrograman Berbasis Python*. UNP Press.
- Meliana, C. (2021) ‘Perbandingan Metode Long Short-Term Memory (LSTM) dan Genetic Algorithm-Long Short-Term Memory (GA LSTM) Pada Peramalan Polutan Udara’. Available at: [http://repository.unimus.ac.id/4751/7/BAB\\_II.pdf](http://repository.unimus.ac.id/4751/7/BAB_II.pdf).
- M. S. Rico Nur Ilham, Strategi Investasi Aset Digital Cryptocurrency: Bintang Pustaka Madani, 2021. Mulyadi, Implementasi kebijakan(Jakarta:Balai Pustaka,2015),4520
- Nawangwulan, S. and Angesti, D. (2016) ‘Analisis Time Series Metode Winter Jumlah Penderita Gastroenteritis Rawat Inap Berdasarkan Data Rekam Medis Di Rsud Dr. Soetomo Surabaya’, Jurnal Manajemen Kesehatan Yayasan RS.Dr. Soetomo, 2(1), p. 17. Available at: <https://doi.org/10.29241/jmk.v2i1.48>.
- Nurdin Usman,Konteks Implementasi Berbasis Kurikulum(Jakarta:Grasindo, 2002), 170
- Paquin, F. et al. (2015) ‘Multi-phase semicrystalline microstructures drive exciton dissociation in neat plastic semiconductors’, *J. Mater. Chem. C*, 3, pp. 10715–10722. Available at: <https://doi.org/10.1039/b000000x>.
- Neural Networks. Modeling and Optimization in Science and Technologies.
- Prasetyo, A.S. et al. (2017) ‘Analisis Potensi dan Risiko Investasi Cryptocurrency di Indonesia’, *Jurnal Ilmiah Information Technology d’Computare*, 7(1), pp. 17–22. Available at: <https://doi.org/10.35957/jatisi.v7i2.195>.
- Retta Marga Allen, dkk. Volume 2 No. 2 Hal. 126–135. *Jurnal Inovasi Pendidikan Matematika*
- Ridho, I.I. et al. (2022) ‘Metode Neural Network Untuk Penentuan Akurasi Prediksi Harga Rumah’, *Technologia : Jurnal Ilmiah*, 13(1), p. 56. Available at: <https://doi.org/10.31602/tji.v13i1.6252>.
- Sianturi, T.B., Cholissodin, I. and Yudistira, N. (2023) ‘Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum’, 7(3), pp. 1101–1107.
- T. Goleman, Cryptocurrency: Mining, Investing and Trading in Blockchain for Beginners. How to Buy Cryptocurrencies (Bitcoin, Ethereum, Ripple, Litecoin or Dash) and what wallet to use. Crypto currency investment strategies. Zen Mastery, 2018.
- Wiranda, L. and Sadikin, M. (2019) ‘Penerapan LONG SHORT TERM MEMORY Pada Data Time Series Untuk Memprediksi Penjualan Produk Pt. Metiska Farma’, *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, 8(3), pp. 184–196.
- Zyen A. K. , Kusumodestoni R. H, (2016), Pengembangan Model Prediksi Harga Saham Berbasis Neural Network, Vol1, Disprotek, Jepara.