

**PENERAPAN LONG SHORT-TERM MEMORY UNTUK
PREDIKSI HARGA PADA CRYPTOCURRENCY DI
MARKET FUTURES**

TUGAS AKHIR

Diajukan sebagai syarat menyelesaikan jenjang strata Satu (S-1)
di Program Studi Teknik Informatika, Jurusan Teknologi,
Produksi dan Industri, Institut Teknologi Sumatera

Oleh:

KIAGUS M ROIHAN ANANTA

122140073



**PROGRAM STUDI TEKNIK INFORMATIKA
JURUSAN TEKNOLOGI, PRODUKSI DAN INDUSTRI
INSTITUT TEKNOLOGI SUMATERA
LAMPUNG SELATAN
2024**

DAFTAR ISI

DAFTAR ISI	2
DAFTAR TABEL	4
DAFTAR GAMBAR	5
BAB I	
PENDAHULUAN	6
1.1 Latar Belakang Masalah	6
1.2 Rumusan Masalah	6
1.3 Tujuan Penelitian	7
1.4 Batasan Masalah	7
1.5 Manfaat Penelitian	8
1.5.1 Manfaat Akademik	8
1.5.2 Manfaat Praktis	8
1.6 Sistematika Penulisan	8
1.6.1 Bab I	8
1.6.2 Bab II	8
1.6.3 Bab III	9
1.6.4 Bab IV	9
1.6.5 Bab V	9
BAB II	
TINJAUAN PUSTAKA	10
2.1 Tinjauan Pustaka	10
2.1.1 Pembahasan Tinjauan Pustaka	11
2.2 Dasar Teori	12
2.2.1 Objek Penelitian: Cryptocurrency	12
2.2.2 Metode: Long Short-Term Memory (LSTM)	12
2.2.3 Preprocessors	12
2.2.4 Fitur	12
2.2.5 Klasifikasi dan Evaluasi	13
BAB III	
METODE PENELITIAN	14
3.1 Alur Penelitian	14
3.2 Penjabaran Langkah Penelitian	14
3.2.1 Data Collection	15
3.2.2 Preprocessing	16
3.2.3 Feature Selection	17
3.2.4 Model Development	18
3.2.5 Model Training	18
3.2.5.1 Inisialisasi Model	18
3.2.5.2 Input Data ke Model	18
3.2.5.3 Proses Pelatihan (Forward Pass)	19
3.2.5.4 Evaluasi dan Backpropagation	19

3.2.5.5 Pengulangan (Epochs)	20
3.2.5.6 Output	20
3.2.6 Model Validation	21
3.2.7 Performance Evaluation	22
3.2.7.1 Evaluasi Kinerja Model	22
3.2.7.2 Validasi Model	22
3.2.7.3 Visualisasi Hasil Prediksi	22
DAFTAR PUSTAKA	25

DAFTAR TABEL

Tabel 2.1 Tabel Tinjauan Pustaka

DAFTAR GAMBAR

Gambar 3.1 Diagram Alur Penelitian	14
Gambar 3.2.1.1 Contoh Informasi Orderbook BTCUSDT dari Binance	15
Gambar 3.2.1.2 Contoh Chart BTCUSDT di Timeframe 15 Menit	15
Gambar 3.2.1.3 Contoh Data Harga Transaksi yang Berlangsung	16
Gambar 3.2.3 Contoh Visual Grafik Candlestick Berdasarkan Data OHLC.	17
Gambar 3.2.5.6 Contoh Evaluasi dan Prediksi	21

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Perkembangan teknologi informasi dan keuangan telah mendorong pertumbuhan pasar cryptocurrency yang sangat cepat dalam dekade terakhir. Cryptocurrency seperti Bitcoin, Ethereum, dan ribuan koin digital lainnya telah menjadi bagian dari ekosistem keuangan global. Salah satu daya tarik utama cryptocurrency adalah sifatnya yang bebas, tidak di kontrol siapapun dan dapat diakses oleh siapa saja yang memiliki koneksi internet, serta volatilitas yang tinggi, yang memberikan peluang bagi para trader untuk mendapatkan keuntungan dalam waktu singkat. Namun dibalik peluang ini terdapat tantangan yang besar, yaitu dikarenakan volatilitas yang tinggi membuat pasar yang ekstrem dan sangat sulit diprediksi untuk orang awam..

Pasar cryptocurrency di market futures, dipengaruhi oleh berbagai faktor seperti sentimen pasar, berita global, perkembangan teknologi blockchain. Sifat pasar yang sangat dinamis dapat menyebabkan prediksi harga menjadi salah satu aspek yang paling kompleks dan beresiko. Trader biasanya mengandalkan analisis teknikal dan fundamental untuk keputusan trading, namun pendekatan konvensional ini saja tidak cukup dalam menangani perubahan harga yang tiba-tiba dan pola yang tidak mudah diprediksi.

Pendekatan tradisional seperti analisis teknikal dan fundamental sering kali tidak mampu mengantisipasi perubahan harga yang tiba-tiba, terutama di market futures. Oleh karena itu, penggunaan teknologi canggih seperti Long Short-Term Memory (LSTM) diperlukan untuk menangkap pola data historis dan memberikan prediksi harga yang lebih akurat.

LSTM, sebagai metode deep learning yang dirancang untuk data urutan, memiliki kemampuan unik dalam menangani data time-series seperti harga cryptocurrency. Dengan memanfaatkan teknik ini, diharapkan model prediksi dapat membantu trader dan investor dalam mengambil keputusan yang lebih baik, meminimalkan risiko, dan meningkatkan keuntungan di pasar futures yang dinamis.

Dengan latar belakang ini, penelitian ini bertujuan untuk menerapkan berbagai algoritma machine learning dalam memprediksi harga cryptocurrency di market futures trading. Penelitian ini akan membandingkan kinerja beberapa model machine learning, mengukur akurasi prediksi, serta mengevaluasi keefektifan model dalam menghadapi volatilitas pasar yang tinggi. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan strategi trading yang lebih canggih dan efisien di ekosistem cryptocurrency.

1.2 Rumusan Masalah

1. Bagaimana penerapan Long Short-Term Memory (LSTM) untuk memprediksi harga cryptocurrency di market futures?
2. Apa saja parameter utama yang berkontribusi terhadap akurasi prediksi harga cryptocurrency di market futures?
3. Bagaimana performa model LSTM dibandingkan dengan pendekatan prediksi tradisional?
4. Apa langkah-langkah yang dapat dilakukan untuk meningkatkan akurasi prediksi menggunakan LSTM?

1.3 Tujuan Penelitian

1. Mengembangkan model prediksi harga cryptocurrency menggunakan Long Short-Term Memory (LSTM) di market futures.
2. Mengevaluasi performa model prediksi berdasarkan metrik evaluasi yang relevan.
3. Menentukan faktor utama yang mempengaruhi akurasi prediksi harga di market futures.
4. Memberikan solusi untuk meningkatkan akurasi prediksi di masa depan.

1.4 Batasan Masalah

Agar penelitian ini lebih terfokus dan efektif, beberapa batasan masalah yang ditetapkan adalah sebagai berikut:

1. Penelitian ini dibatasi pada penggunaan data historis harga cryptocurrency dari market futures saja, tanpa melibatkan data dari market spot.
2. Algoritma yang digunakan adalah Long Short-Term Memory (LSTM) sebagai metode utama, tanpa membandingkan dengan algoritma lain seperti Random Forest atau SVM.
3. Data yang digunakan dalam penelitian adalah harga cryptocurrency (Open, High, Low, Close) dan volume perdagangan, tanpa memasukkan data eksternal seperti sentimen pasar atau berita.

4. Fokus penelitian adalah pada prediksi jangka pendek (harian) dan menengah (mingguan), tanpa mengeksplorasi prediksi jangka panjang.
5. Evaluasi model dilakukan menggunakan metrik MAE, RMSE, dan R-Squared, tanpa membahas pengaruh parameter hyperparameter tuning secara mendalam.

1.5 Manfaat Penelitian

1.5.1 Manfaat Akademik

- **Pengembangan Ilmu Pengetahuan:** Penelitian ini dapat menjadi referensi bagi pengembangan kajian tentang penerapan algoritma machine learning dalam memprediksi harga aset keuangan, khususnya cryptocurrency, serta memperkaya literatur di bidang teknologi keuangan (fintech) dan kecerdasan buatan (AI).
- **Referensi untuk Penelitian Selanjutnya:** Hasil penelitian ini dapat menjadi dasar atau acuan bagi penelitian-penelitian lanjutan yang tertarik untuk mengembangkan metode atau algoritma machine learning yang lebih akurat dan efisien dalam trading cryptocurrency.

1.5.2 Manfaat Praktis

- **Optimalisasi Strategi Trading:** Model prediksi berbasis LSTM dapat membantu trader dan investor mengoptimalkan strategi mereka dengan memberikan prediksi harga yang lebih akurat di market futures.
- **Alat Bantu Pengambilan Keputusan:** Hasil prediksi dapat menjadi dasar untuk menentukan waktu terbaik untuk membeli atau menjual aset, sehingga dapat meminimalkan risiko kerugian.
- **Efisiensi Pasar:** Implementasi model ini dapat mendukung efisiensi pasar dengan membantu mengurangi ketidakpastian dan volatilitas harga.
- **Peningkatan Kepercayaan Industri:** Model yang andal dapat meningkatkan kepercayaan pelaku industri keuangan terhadap penggunaan teknologi kecerdasan buatan dalam pengambilan keputusan.

1.6 Sistematika Penulisan

1.6.1 Bab I

Bab ini berisikan latar belakang masalah, rumusan masalah, tujuan penelitian, manfaat penelitian, batasan masalah, dan terakhir sistematika penulisan

1.6.2 Bab II

Pada Bab ini terdapat kajian teoritis, penelitian terdahulu, kerangka pemikiran, dan hipotesis (jika diperlukan).

1.6.3 Bab III

Bab ini menjelaskan metode yang digunakan pada penelitian, jenis penelitian, sumber dan jenis data, metode pengumpulan data, algoritma machine learning, metode pengujian, dan prosedur analisis data.

1.6.4 Bab IV

Pada bab ini disajikan deskripsi data yang telah dikumpulkan, implementasi model, analisis prediksi, dan pembahasan hasil penelitian lebih mendalam.

1.6.5 Bab V

Pada bab terakhir berisikan kesimpulan dari penelitian yang dilakukan dan saran untuk penelitian lebih lanjut.

BAB II

TINJAUAN PUSTAKA

2.1 Tinjauan Pustaka

Tabel 2.1 Tabel Tinjauan Pustaka

No.	Penulis [Judul] [Tahun]	Masalah	Hasil Penelitian
1.	Rajab et al. [An Automatic Lip Reading for Short Sentences Using Deep Learning Nets] [2023]	Mengembangkan sistem membaca bibir otomatis menggunakan deep learning sebagai alternatif bagi individu dengan gangguan pendengaran	Meningkatkan akurasi pengenalan kalimat pendek dengan metode hybrid CNN dan LSTM, meskipun performa menurun pada pembicara yang tidak dikenal.
2.	Talaei Khoei et al. [Deep Learning: Systematic Review, Models, Challenges, and Research Directions] [2023]	Eksplorasi perkembangan deep learning, klasifikasi model, tantangan, dan arah penelitian masa depan	Memberikan tinjauan lengkap tentang model deep learning, membahas teknik-teknik terbaru seperti federated learning dan transfer learning, namun tidak mencakup implementasi praktis.
3.	Ahmad Ma'ruf [Komparasi Algoritma K-NN, Naive Bayes dan SVM untuk Prediksi Kelulusan Mahasiswa Tingkat Akhir] [2023]	Membandingkan kinerja algoritma K-NN, Naive Bayes, dan SVM untuk prediksi kelulusan mahasiswa	Menemukan algoritma yang paling efektif dalam memprediksi kelulusan berdasarkan data akademik, tetapi tidak mempertimbangkan faktor non-akademik yang relevan.
4.	Ramadhani & Akbar [Implementasi Algoritma Decision Tree dan SVM untuk Klasifikasi Penyakit Kanker Paru] [2023]	Klasifikasi penyakit kanker paru menggunakan Decision Tree dan SVM	Memberikan analisis komparatif yang menunjukkan efektivitas model dalam klasifikasi penyakit, tetapi tidak mempertimbangkan data genetik.
5.	Yulianti et al. [Analisis	Menganalisis	Memberikan wawasan

2.1.1 Pembahasan Tinjauan Pustaka

1. Masalah Utama

Penelitian terdahulu menunjukkan volatilitas tinggi pada cryptocurrency yang menyebabkan kesulitan prediksi. Masalah utama yang diangkat adalah bagaimana menerapkan machine learning, khususnya LSTM, untuk menangkap pola data harga cryptocurrency.

2. Metode yang Digunakan

Metode yang sering digunakan adalah:

- Deep Learning seperti LSTM untuk memodelkan data time-series.
- Evaluasi Performa dengan metrik seperti MAE dan RMSE untuk menilai efektivitas model.

3. Kontribusi Penelitian

Penelitian sebelumnya menunjukkan bahwa metode berbasis LSTM lebih unggul dibandingkan model tradisional dalam menangani data volatil dan kompleks. Kontribusi utama adalah pengembangan model prediksi yang lebih adaptif.

4. Keunggulan dan Keterbatasan

- **Keunggulan:** Penelitian terdahulu menunjukkan bahwa pendekatan berbasis LSTM sangat efektif dalam menangani data time-series yang kompleks. LSTM mampu menangkap pola temporal dengan baik, bahkan dalam kondisi volatilitas tinggi, memberikan akurasi prediksi yang lebih tinggi dibandingkan metode tradisional.
- **Keterbatasan:** Sebagian besar penelitian tidak memasukkan data eksternal seperti sentimen pasar atau berita yang dapat memengaruhi

harga. Selain itu, generalisasi model masih menjadi tantangan ketika dihadapkan pada data baru.

2.2 Dasar Teori

Berikut ini adalah teori dan konsep yang berkaitan dengan penelitian prediksi harga cryptocurrency:

2.2.1 Objek Penelitian: Cryptocurrency

Cryptocurrency adalah aset digital yang menggunakan teknologi blockchain untuk mengamankan transaksi. Contoh populer termasuk Bitcoin (BTC) dan Ethereum (ETH). Pasar cryptocurrency memiliki volatilitas tinggi, yang membuat prediksi harga menjadi sangat kompleks.

2.2.2 Metode: Long Short-Term Memory (LSTM)

LSTM adalah jenis jaringan saraf dalam (Deep Neural Network) yang dirancang untuk data urutan atau time-series. LSTM sangat cocok untuk menangkap pola temporal dalam data harga cryptocurrency, yang memiliki sifat fluktuasi yang dinamis.

2.2.3 Preprocessors

Proses pra-pengolahan data meliputi:

- **Normalisasi:** Data harga (Open, High, Low, Close) dan volume diproses menjadi nilai antara 0 dan 1 menggunakan teknik Min-Max Scaling untuk mempercepat konvergensi model.
- **Pemisahan Dataset:** Data dibagi menjadi set pelatihan, validasi, dan pengujian dengan perbandingan 70:20:10.

2.2.4 Fitur

Elemen-elemen data yang digunakan dalam penelitian prediksi harga cryptocurrency adalah sebagai berikut:

1. Open: Harga pembukaan aset cryptocurrency pada suatu periode tertentu, biasanya awal hari perdagangan.
2. High: Harga tertinggi yang dicapai oleh aset selama periode tertentu.
3. Low: Harga terendah yang dicapai oleh aset selama periode tertentu
4. Close: Harga penutupan aset pada akhir periode tertentu.
5. Volume: Total volume perdagangan aset dalam periode tersebut, menunjukkan jumlah aset yang diperdagangkan.

Data ini merupakan atribut utama yang digunakan sebagai input dalam model Long Short-Term Memory (LSTM) untuk mendekripsi pola dan memprediksi pergerakan harga di masa depan. Atribut-atribut ini dipilih karena relevansi mereka terhadap analisis teknis dalam pasar keuangan.

2.2.5 Klasifikasi dan Evaluasi

Evaluasi kinerja model dilakukan menggunakan:

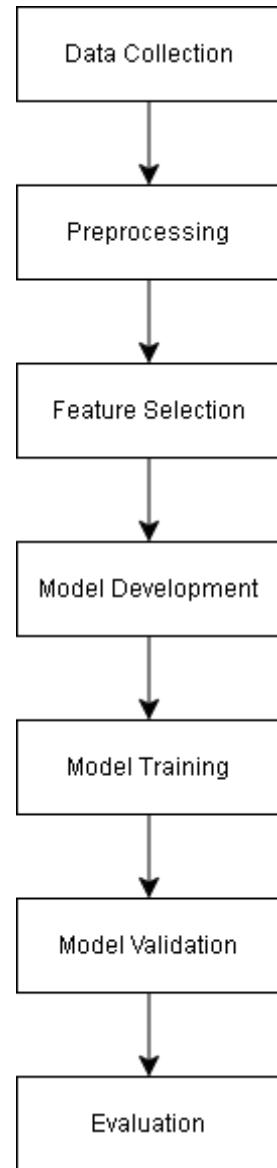
- Mean Absolute Error (MAE): Mengukur rata-rata kesalahan absolut antara prediksi dan nilai aktual.
- Root Mean Squared Error (RMSE): Mengukur akar rata-rata kesalahan kuadrat untuk menunjukkan seberapa besar prediksi menyimpang.
- R-Squared: Mengukur seberapa baik model memprediksi data dibandingkan rata-rata.

BAB III

METODE PENELITIAN

3.1 Alur Penelitian

Berikut adalah diagram alur penelitian untuk prediksi cryptocurrency berbasis LSTM.



Gambar 3.1 Diagram Alur Penelitian

3.2 Penjabaran Langkah Penelitian

Berikut adalah penjelasan detail dari langkah-langkah yang ada pada diagram alur penelitian:

3.2.1 Data Collection

Mengumpulkan data harga cryptocurrency dari platform charting seperti TradingView atau Blockchain.com yang mana terdapat platform-platform trading seperti Binance. Data mencakup informasi historis seperti harga pembukaan (Open), harga penutupan (Close), harga tertinggi (High), harga terendah (Low), dan volume perdagangan.

Order Book			
Price(USDT)	Size(BTC)	Sum(BTC)	
94681.4	0.475	5.185	
94681.3	0.023	4.710	
94681.2	0.042	4.687	
94680.8	0.160	4.645	
94680.6	0.002	4.485	
94680.5	4.483	4.483	
94680.4 ↓ 94684.7			
94680.4	1.599	1.599	
94680.3	0.389	1.988	
94680.0	0.202	2.190	
94679.9	0.237	2.427	
94679.8	0.408	2.835	
94679.0	0.184	3.019	
B 36.75%		63.25% S	

Gambar 3.2.1.1 Contoh Informasi Orderbook BTCUSDT dari Binance



Gambar 3.2.1.2 Contoh Chart BTCUSDT di Timeframe 15 Menit

Trades		
Price(USDT)	Amount(USDT)	Time
94,660.1	189.4	12:33:22
94,660.0	284.0	12:33:20
94,660.0	568.0	12:33:20
94,660.0	378.7	12:33:19
94,660.1	2839.9	12:33:18
94,660.0	27167.5	12:33:17
94,660.0	473.3	12:33:16
94,660.0	7572.8	12:33:16
94,660.0	8046.1	12:33:15
94,660.1	662.7	12:33:14
94,660.1	83774.2	12:33:14

Gambar 3.2.1.3 Contoh Data Harga Transaksi yang Berlangsung

3.2.2 Preprocessing

Melakukan normalisasi data untuk memastikan bahwa semua fitur memiliki nilai yang seragam. Tanpa normalisasi, fitur dengan skala besar dapat mendominasi model, yang menyebabkan bias pada proses pelatihan. Setelah melakukan normalisasi data, selanjutnya menggunakan metode seperti Min-Max Scaling untuk menstandarkan rentang nilai, sehingga model dapat bekerja lebih optimal menggunakan formula berikut:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}}$$

dimana:

x : Nilai asli dari dataset.

x_{min} : Nilai minimum pada kolom data tersebut.

x_{max} : Nilai maksimum pada kolom data tersebut.

x' : Nilai yang telah dinormalisasi, yang berada di rentang [0, 1].

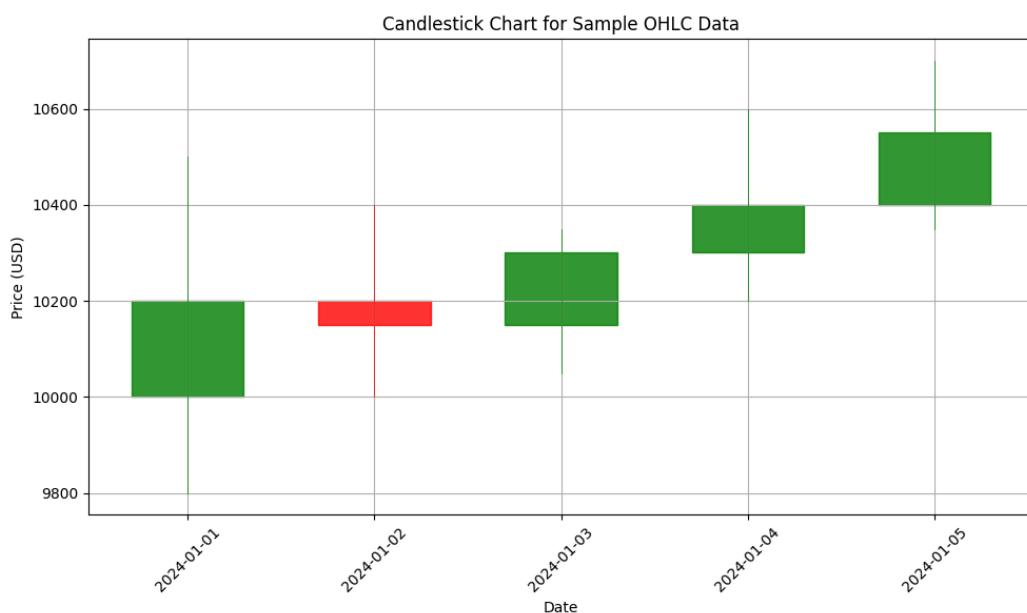
Dataset dibagi untuk memastikan model dapat diuji pada data yang belum pernah dilihat selama pelatihan. Hal ini membantu mengevaluasi performa model dengan lebih akurat. Dengan komposisi dataset:

1. pelatihan (70%): Digunakan untuk melatih model dan menemukan pola dalam data.
2. validasi (20%): Digunakan untuk memantau kinerja model selama pelatihan, terutama untuk menghindari overfitting.
3. pengujian (10%): Digunakan untuk menguji performa akhir model pada data baru yang belum pernah digunakan dalam pelatihan atau validasi.

Proses ini memastikan model yang dihasilkan lebih generalis dan mampu menangani data baru dengan baik.

3.2.3 Feature Selection

Memilih fitur yang relevan seperti harga Open, High, Low, Close (OHLC) dan volume perdagangan, yang memiliki dampak signifikan pada pola harga cryptocurrency. OHLC digunakan untuk membangun grafik candlestick, yang dapat menunjukkan pola seperti *bullish* (naik) atau *bearish* (turun). Kombinasi OHLC dan volume perdagangan membantu dalam memahami tren pasar. Contohnya: Tren naik dengan volume tinggi menandakan momentum pasar yang kuat atau Tren naik dengan volume rendah menandakan pergerakan harga sementara. Dalam machine learning, fitur ini membantu model seperti LSTM dalam mendeteksi pola waktu dan hubungan antarvariabel untuk prediksi harga yang lebih akurat.



Gambar 3.2.3 Contoh Visual Grafik Candlestick Berdasarkan Data OHLC.

3.2.4 Model Development

Menggunakan framework seperti TensorFlow atau PyTorch untuk membangun arsitektur model Long Short-Term Memory (LSTM) yang dirancang khusus untuk data time-series.

3.2.5 Model Training

Melatih model dengan set pelatihan, menggunakan data yang telah diproses untuk menemukan pola dalam dataset. Proses training model dalam konteks Long Short-Term Memory (LSTM) dijelaskan melalui beberapa langkah inti sebagai berikut:

3.2.5.1 Inisialisasi Model

1. LSTM adalah jenis jaringan saraf yang memiliki lapisan berulang (recurrent layers), sehingga cocok untuk data time-series.
2. Model LSTM biasanya terdiri dari beberapa lapisan seperti:
 - Input Layer: Menerima data seperti harga OHLC dan volume perdagangan.
 - Hidden Layers: Lapisan LSTM untuk menangkap pola urutan waktu.
 - Dense Layer: Menghasilkan output berupa prediksi harga.

3.2.5.2 Input Data ke Model

1. Bentuk Data Time-Series:

Model LSTM memerlukan input data dalam bentuk time-series, yaitu data yang memiliki urutan waktu. Setiap titik data digunakan untuk memprediksi nilai di masa depan berdasarkan nilai sebelumnya.

Struktur Input Data: Format data yang dimasukkan ke LSTM harus berbentuk 3D array dengan struktur:

- Samples: Jumlah keseluruhan contoh data dalam dataset.
- Timesteps: Jumlah langkah waktu yang digunakan untuk memprediksi nilai berikutnya.

- Features: Jumlah fitur yang tersedia di setiap titik waktu (contohnya: Open, High, Low, Close, Volume).
2. Bentuk Data Time-Series:
- Data yang telah disiapkan perlu dipisahkan menjadi input (X) dan target (y):
- Input (X): Berisi nilai fitur pada beberapa langkah waktu sebelumnya.
 - Target (y): Berisi nilai yang ingin diprediksi (misalnya harga Close pada langkah waktu berikutnya).
3. Normalisasi Data LSTM sensitif terhadap skala data. Untuk memastikan pelatihan optimal, semua nilai perlu dinormalisasi ke dalam rentang tertentu, biasanya [0, 1].
4. Format Final untuk Model Setelah menyiapkan X dan y , data perlu diformat ke bentuk 3D array untuk dimasukkan ke dalam model LSTM

3.2.5.3 Proses Pelatihan (Forward Pass)

Pada proses pelatihan yang akan terjadi adalah data input akan dimasukkan ke jaringan LSTM. Setelah itu, setiap neuron akan memproses data menggunakan fungsi aktivasi seperti ReLU untuk menemukan hubungan antara waktu dan nilai harga. Terakhir pada lapisan terakhir akan menghasilkan prediksi untuk darta input.

3.2.5.4 Evaluasi dan Backpropagation

1. Evaluasi Error:

Prediksi akan dibandingkan dengan nilai aktual menggunakan fungsi loss seperti Mean Squared Error (MSE)

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{pred} - y_{actual})^2$$

2. Backpropagation:

- a. Model mengubah bobot dan bias di setiap neuron untuk meminimalkan error.
- b. Algoritma optimisasi seperti *Adaptive Moment Estimation* (Adam) digunakan untuk mempercepat konvergensi. Adam digunakan sebagai optimizer dalam framework deep learning seperti TensorFlow atau PyTorch. Adam digunakan karena cocok digunakan untuk dataset besar dan kompleks, efektif untuk masalah yang memerlukan penyesuaian learning rate otomatis, dan direkomendasikan untuk pelatihan model neural network, termasuk LSTM.

3.2.5.5 Pengulangan (Epochs)

Proses pelatihan dilakukan dalam beberapa iterasi (*epochs*), di mana data diulang dalam batch kecil untuk memperbarui bobot secara bertahap.

1. Forward Pass:

Data batch melewati model dari input hingga output untuk menghasilkan prediksi.

2. Backward Pass (Backpropagation):

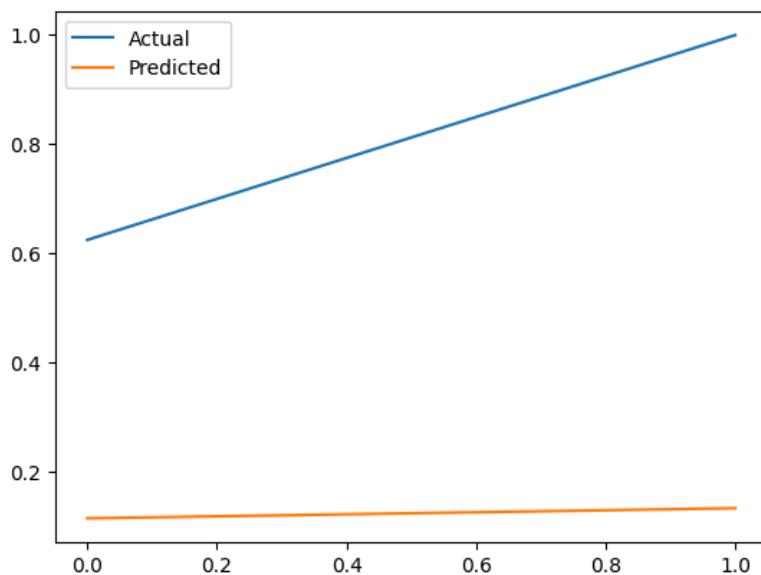
- a. Model menghitung kesalahan (error) antara prediksi dan nilai aktual.
- b. Gradien dihitung dan digunakan untuk memperbarui bobot model.

3. Pembaruan Bobot:

Algoritma optimisasi seperti Adam atau SGD digunakan untuk memperbarui bobot model agar error diminimalkan.

3.2.5.6 Output

Model menghasilkan bobot akhir yang dapat digunakan untuk memprediksi harga di data baru (ujji). Hasil pelatihan dievaluasi pada data validasi untuk memantau kinerja



Gambar 3.2.5.6 Contoh Evaluasi dan Prediksi

3.2.6 Model Validation

Memantau kinerja model selama pelatihan menggunakan set validasi untuk menghindari overfitting dan memastikan model bekerja dengan baik pada data baru. Berikut cara kerja pemantauan kinerja

1. Pembagian Dataset:

Dataset dibagi menjadi tiga bagian, yaitu:

- Training Set: Untuk melatih model
- Validation Set: Untuk mengevaluasi model selama pelatihan
- Test Set: Untuk menguji model setelah pelatihan selesai.

2. Evaluasi pada Setiap Epoch:

- Pada akhir setiap epoch, model dievaluasi pada data validasi menggunakan metrik seperti loss atau accuracy.
- Hasil evaluasi membantu menentukan apakah pelatihan perlu dilanjutkan atau dihentikan.

3. Pemantauan Tren:

- Jika loss validasi terus menurun, model belajar dengan baik.
- Jika loss validasi mulai meningkat sementara loss pelatihan terus menurun, model mulai overfitting.

3.2.7 Performance Evaluation

3.2.7.1 Evaluasi Kinerja Model

Evaluasi kinerja dilakukan menggunakan metrik berikut:

- a. Mean Absolute Error (MAE): Mengukur rata-rata kesalahan absolut antara nilai aktual dan prediksi.
- b. Root Mean Squared Error (RMSE): Menghitung akar rata-rata dari semua kesalahan kuadrat, memberikan penalti lebih besar untuk kesalahan besar.
- c. R-Squared (R^2): Mengukur seberapa baik model menjelaskan variasi dalam data dibandingkan rata-rata nilai.

3.2.7.2 Validasi Model

Pemantauan dilakukan berdasarkan loss validasi:

- a. Jika loss validasi terus menurun, model belajar dengan baik.
- b. Jika loss validasi mulai meningkat sementara loss pelatihan terus menurun, ini menandakan overfitting.

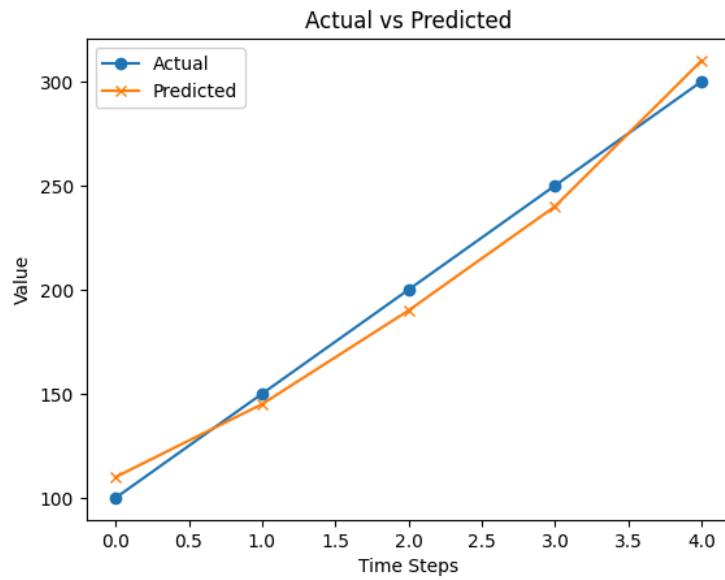
3.2.7.3 Visualisasi Hasil Prediksi

Visualisasi hasil prediksi dilakukan untuk melihat bagaimana nilai prediksi mendekati nilai aktual dan memahami pola kesalahan dan area yang perlu diperbaiki.

Visualisasi dibagi menjadi dua, yaitu :

1. Visualisasi Garis:

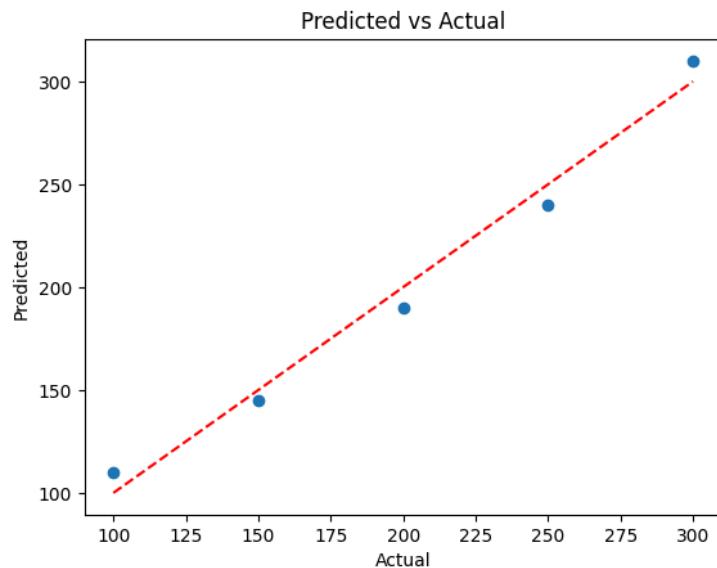
Prediksi dan nilai aktual diplot pada sumbu waktu untuk membandingkan pola.



Gambar 3.2.7.3.1 Contoh Visualisasi Garis Antara Nilai Aktual dan Prediksi

2. Scatter Plot:

Membandingkan nilai prediksi dengan nilai aktual dalam bentuk titik.



Gambar 3.2.7.3.2 Contoh Visualisasi *Scatter Plot* Antara Nilai Aktual dan Prediksi

Menggunakan metrik seperti Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan R-Squared untuk mengevaluasi seberapa akurat prediksi model dibandingkan data aktual. Menampilkan hasil prediksi dalam bentuk visual untuk menunjukkan pola dan akurasi prediksi.

DAFTAR PUSTAKA

- [1] M. Rajab, et al., "An Automatic Lip Reading for Short Sentences Using Deep Learning Nets," *International Journal of Advances in Intelligent Informatics*, vol. 9, no. 1, pp. 15-26, 2023.
- [2] T. T. Khoei, H. O. Slimane, and N. Kaabouch, "Deep Learning: Systematic Review, Models, Challenges, and Research Directions," *Neural Computing and Applications*, vol. 35, pp. 1-20, 2023.
- [3] A. Ma'ruf, "Komparasi Algoritma K-NN, Naive Bayes dan SVM untuk Prediksi Kelulusan Mahasiswa Tingkat Akhir," *MALCOM: Journal of Informatics and Computer Science*, vol. 4, no. 2, pp. 289-299, 2023.
- [4] F. Ramadhani and M. A. Akbar, "Implementasi Algoritma Decision Tree dan Support Vector Machine untuk Klasifikasi Penyakit Kanker Paru," *MALCOM: Journal of Informatics and Computer Science*, vol. 4, no. 2, pp. 287-297, 2023..
- [5] D. R. Yulianti, D. Aprilia, and A. Ma'ruf, "Analisis Sentimen Terhadap Bantuan Langsung Tunai (BLT) Bahan Bakar Minyak (BBM) Menggunakan Support Vector Machine," *MALCOM: Journal of Informatics and Computer Science*, vol. 4, no. 2, pp. 290-300, 2023.10.
- [6] A. Roihan, P. A. Sunarya, and A. S. Rafika, "Pemanfaatan Machine Learning dalam Berbagai Bidang: Review Paper," *Computer and Information Technology*, vol. 5, no. 1, pp. 75-82, 2019.
- [7] "Perbedaan Analisis Fundamental dan Analisis Teknikal dalam Trading Crypto," *BeinCrypto Indonesia*, Jan. 5, 2024. [Online]. Available: <https://id.beincrypto.com/belajar/perbedaan-analisis-fundamental-teknikal>. [Accessed: Sep. 24, 2024].
- [8] M. R. Syahronny and T. Dewayanto, "Penerapan Teknologi Artificial Intelligence dan Blockchain dalam Mendeteksi Fraud pada Proses Audit: Systematic Literature Review," *Accounting*, vol. 13, no. 3, pp. 1-14, 2004.

- [9] O. L. D. Warsito, "Analisis Volatilitas Cryptocurrency, Emas, Dollar, dan Indeks Harga Saham Gabungan (IHSG)," *Social Science and Business*, vol. 4, no. 1, pp. 40-46, 2020.
- [10] Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.
<https://doi.org/10.1162/neco.1997.9.8.1735>
- [11] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <https://www.deeplearningbook.org/>
- [12] Brownlee, J. (2017). *Deep Learning for Time Series Forecasting*. Machine Learning Mastery.
- [13] Kingma, D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. arXiv preprint arXiv:1412.6980.
- [14] Binance API Documentation. (2023). Retrieved from <https://binance-docs.github.io/apidocs/spot/en/>
- [15] Chollet, F. (2018). *Deep Learning with Python*. Manning Publications.
- [16] TensorFlow Documentation. (2023). Retrieved from <https://www.tensorflow.org/>
- [17] Scikit-learn: Machine Learning in Python. (2023). Retrieved from <https://scikit-learn.org/>
- [18] Pandas Documentation. (2023). Retrieved from <https://pandas.pydata.org/>
- [19] McKinney, W. (2017). *Python for Data Analysis*. O'Reilly Media.