

Prediksi Harga Bawang Merah di Jawa Timur menggunakan Metode Long Short Term Memory (LSTM)

Siti Sri Wahyuni^{1*}, Budi Nugroho², Chrystya Aji Putra³,

¹Informatika/Ilmu Komputer

Universitas Pembangunan Nasional
Veteran Jawa Timur

^{1*}srwahyuni034@gmail.com

²Informatika/Ilmu Komputer

Universitas Pembangunan Nasional
Veteran Jawa Timur

²budinugroho.if@upnjatim.ac.id

³Informatika/Ilmu Komputer

Universitas Pembangunan Nasional
Veteran Jawa Timur

³ajiputra@upnjatim.ac.id

Abstrak— Bawang merah merupakan salah satu komoditas hortikultura strategis yang memiliki peran penting dalam pemenuhan kebutuhan pangan masyarakat Indonesia. Meskipun produksi bawang merah di Provinsi Jawa Timur cenderung meningkat, harga bawang merah masih mengalami fluktuasi yang cukup tinggi sehingga diperlukan metode prediksi yang mampu memodelkan pola data deret waktu secara akurat. Penelitian ini bertujuan menerapkan metode Long Short-Term Memory (LSTM) untuk memprediksi harga harian bawang merah di Provinsi Jawa Timur menggunakan data historis harga periode Januari 2015 hingga Maret 2026 yang diperoleh dari Sistem Informasi Ketersediaan dan Perkembangan Harga Bahan Pokok (SISKAPERBAPO). Model dibangun menggunakan delapan kombinasi parameter yang terdiri atas *sequence length* (7 dan 30 hari), *hidden units* (32 dan 64), serta *epoch* (50 dan 100) kemudian dievaluasi menggunakan MAE, RMSE, MAPE, dan R^2 . Hasil penelitian menunjukkan bahwa konfigurasi terbaik diperoleh pada *sequence length* 7 hari, *hidden units* 64, dan *epoch* 100 dengan nilai MAE sebesar 227,91, RMSE sebesar 372,55, MAPE sebesar 0,65%, dan R^2 sebesar 0,9973. Selain itu, hasil prediksi selama 30 hari ke depan menunjukkan kecenderungan penurunan harga secara bertahap. Hasil tersebut menunjukkan bahwa metode LSTM mampu memodelkan pola temporal data harga bawang merah dengan tingkat akurasi yang sangat baik sehingga berpotensi mendukung pengambilan keputusan dalam memantau pergerakan harga komoditas.

Kata kunci— Long Short-Term Memory (LSTM), prediksi harga, bawang merah, *time series*, *deep learning*.

Abstract— Shallots are one of Indonesia's strategic horticultural commodities and play an important role in meeting the country's food needs. Although shallot production in East Java Province has shown an increasing trend, shallot prices continue to experience significant fluctuations, making an accurate time series forecasting method necessary. This study aims to apply the Long Short-Term Memory (LSTM) method to predict daily shallot prices in East Java Province using historical data from January 2015 to March 2026 obtained from the Food Commodity Availability and Price Information System (SISKAPERBAPO). The model was developed using eight parameter combinations consisting of *sequence lengths* of 7 and 30 days, *hidden units* of 32 and 64, and *epochs* of 50 and 100, and was evaluated using MAE, RMSE, MAPE, and R^2 . The results indicate that the best model configuration was achieved with a 7-day *sequence length*, 64 *hidden units*, and 100 *epochs*, resulting in an MAE of 227.91, an RMSE of 372.55, a MAPE of 0.65%, and an R^2 of 0.9973. In addition, the 30-day forecasting results indicate a gradual downward trend in shallot prices. These findings demonstrate that the LSTM method is capable of modeling the temporal patterns of shallot price data with excellent predictive accuracy and has the potential to support decision-making in monitoring commodity price movements.

Keywords— Long Short-Term Memory (LSTM), price forecasting, shallots, *time series*, *deep learning*.

I. PENDAHULUAN

Bawang merah merupakan salah satu komoditas hortikultura strategis yang memiliki nilai ekonomi tinggi serta berperan penting dalam menjaga stabilitas pangan di Indonesia [1]. Selain menjadi bumbu utama dalam berbagai masakan, bawang merah juga digunakan sebagai bahan baku industri bawang goreng serta memiliki berbagai manfaat bagi kesehatan. Dengan banyaknya manfaat tersebut dan nilai ekonominya yang tinggi, bawang merah menjadi salah satu komoditas pokok di Indonesia [2]. Konsumsi bawang merah di

Indonesia terus meningkat seiring pertumbuhan jumlah penduduk dan kualitas hidup masyarakat [3]. Berdasarkan data Susenas BPS, konsumsi bawang merah rumah tangga di Indonesia menunjukkan tren yang cenderung meningkat dengan rata-rata pertumbuhan sebesar 1,527% per tahun selama periode 2010–2024 [2]. Sejalan dengan peningkatan konsumsi, produksi bawang merah nasional juga menunjukkan tren yang cenderung meningkat meskipun masih mengalami fluktuasi. Berdasarkan data Badan Pusat Statistik (BPS), produksi bawang merah nasional menunjukkan tren meningkat dari

18.154.453 kuintal pada tahun 2020 menjadi 21.797.349 kuintal pada tahun 2025, meskipun sempat mengalami penurunan pada tahun 2022 menjadi 19.823.602 kuintal [4].

Provinsi Jawa Timur merupakan sentra produksi bawang merah terbesar kedua di Indonesia setelah Provinsi Jawa Tengah dengan kontribusi sebesar 22,86% terhadap total produksi nasional [5]. Meskipun produksi bawang merah cenderung meningkat, harga bawang merah di Jawa Timur masih mengalami fluktuasi yang cukup tinggi. Berdasarkan data harian Sistem Informasi Ketersediaan dan Perkembangan Harga Bahan Pokok (SISKAPERBAPO), harga bawang merah selama periode 2015–2026 menunjukkan pola yang tidak stabil dengan beberapa lonjakan harga yang signifikan [6]. Perubahan harga bawang merah dipengaruhi oleh dinamika permintaan dan penawaran. Dari sisi permintaan, pola konsumsi masyarakat yang bersifat musiman dapat meningkatkan kebutuhan bawang merah sedangkan dari sisi penawaran, kondisi cuaca, serangan hama dan penyakit tanaman dapat mengganggu produksi sehingga memicu fluktuasi harga [7]. Karakteristik fluktuasi tersebut menyebabkan harga bawang merah membentuk data deret waktu (*time series*) yang kompleks karena memiliki pola nonlinier dan ketergantungan temporal. Fluktuasi harga ini tidak hanya berdampak pada pendapatan petani, tetapi juga memengaruhi daya beli masyarakat serta pengendalian inflasi daerah. Oleh karena itu, diperlukan suatu metode yang mampu memprediksi pergerakan harga secara lebih akurat sebagai pendukung pengambilan keputusan.

Berbagai penelitian telah dilakukan untuk memprediksi harga bawang merah menggunakan metode statistik seperti ARIMA maupun regresi linear. Khoirani dkk. (2022) menggunakan metode ARIMA untuk meramalkan harga bawang merah di pasar tradisional Sulawesi Selatan dan memperoleh model terbaik ARIMA (3,1,1) dengan nilai MAPE sebesar 9,43% [8]. Selain itu, Al Farisi et al. (2025) mengembangkan model prediksi harga bawang merah berbasis website

menggunakan metode regresi linear di Kabupaten Ponorogo, Jawa Timur. Hasil penelitian menunjukkan bahwa model tersebut memperoleh nilai MAPE sebesar 21,7% [9]. Meskipun kedua metode tersebut telah memberikan kontribusi dalam prediksi harga bawang merah, keduanya masih memiliki keterbatasan dalam menangkap pola data deret waktu yang bersifat nonlinier dan kompleks sehingga akurasi prediksi yang dihasilkan masih dapat ditingkatkan. Oleh karena itu, diperlukan metode yang mampu mempelajari hubungan temporal yang lebih kompleks agar menghasilkan prediksi yang lebih akurat.

Seiring dengan perkembangan teknologi *deep learning*, metode *Long Short-Term Memory* (LSTM) menjadi salah satu pendekatan yang banyak digunakan dalam peramalan data deret waktu. LSTM pertama kali dikembangkan oleh Hochreiter & Schmidhuber (1997) sebagai pengembangan dari *Recurrent Neural Network* (RNN), dengan mekanisme *gating* berupa *input gate*, *forget gate*, dan *output gate* yang memungkinkan model untuk secara selektif menyimpan maupun melupakan informasi dari data historis. Mekanisme ini membuat LSTM mampu memodelkan ketergantungan jangka panjang serta pola non-linear pada data *time series* secara lebih efektif dibandingkan metode konvensional [10]. Rahman dkk. (2026) menunjukkan bahwa model LSTM yang diterapkan untuk prediksi harga bawang merah di sembilan wilayah di Jawa Timur mampu menghasilkan rata-rata nilai *Mean Absolute Percentage Error* (MAPE) sebesar 3,10%, yang termasuk dalam kategori sangat baik [11]. Hasil tersebut mengindikasikan bahwa LSTM memiliki kemampuan yang stabil dan konsisten dalam menangkap pola fluktuasi harga komoditas pertanian berbasis data deret waktu.


Meskipun demikian, penelitian tersebut menggunakan data harga pada tingkat wilayah (*multi-series*) dengan sumber data dari PIHPS sedangkan penelitian ini menggunakan data deret waktu tunggal berupa harga rata-rata Provinsi Jawa Timur yang bersumber dari SISKAPERBAPO dengan periode yang lebih panjang, yaitu Januari 2015 hingga Maret 2026.

Dengan perbedaan karakteristik data tersebut, penelitian ini diharapkan dapat memberikan gambaran yang lebih komprehensif mengenai kinerja model LSTM pada data agregat tingkat provinsi.

Kinerja model selanjutnya dievaluasi menggunakan Mean Absolute Error (MAE), Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), serta koefisien determinasi (R^2) untuk mengukur tingkat akurasi model secara objektif.

II. METODOLOGI PENELITIAN

Penelitian ini menggunakan metode Long Short-Term Memory (LSTM) untuk memprediksi harga bawang merah di Provinsi Jawa Timur berdasarkan data historis harga harian.



Gambar 1. Flowchart Tahapan Penelitian

Berdasarkan Gambar 1, tahapan penelitian terdiri dari beberapa proses sebagai berikut.

A. Studi Literatur

Tahap awal penelitian dilakukan dengan mengumpulkan dan mempelajari berbagai referensi yang berkaitan dengan prediksi harga komoditas, metode Long Short-Term Memory (LSTM), preprocessing data time series serta penelitian terdahulu yang relevan. Studi literatur digunakan sebagai dasar dalam menentukan metode penelitian dan parameter model.

B. Pengumpulan Data

Data yang digunakan merupakan data harga harian bawang merah di Provinsi Jawa Timur yang diperoleh dari Sistem Informasi Ketersediaan dan Perkembangan Harga Bahan Pokok (SISKAPERBAPO) dengan periode pengamatan Januari 2015 hingga Maret 2026.

Tabel 1 Contoh Data Harga Bawang Merah

Tanggal	Harga (Rp)
2015-01-01	15.993
2015-01-02	16.043
2015-01-03	16.035
2015-01-04	16.017
2015-01-05	16.257
...	...
2026-03-31	36.319

Tabel 1 menunjukkan contoh data harga harian bawang merah di Provinsi Jawa Timur yang digunakan dalam penelitian. Dataset terdiri atas atribut tanggal dan harga harian.

C. Data Preprocessing

Tahap preprocessing dilakukan agar data siap digunakan dalam proses pelatihan model LSTM. Tahapan preprocessing meliputi:

- Data cleaning dilakukan untuk menghapus data duplikat dan menangani nilai yang hilang (*missing value*) agar data memenuhi asumsi pemodelan deret waktu. Tahapan ini bertujuan meningkatkan kualitas data sehingga proses pemodelan dapat menghasilkan prediksi yang lebih akurat dan stabil. [12].

Tabel 2 Contoh Data Cleaning Harga Bawang Merah

ds	y
2015-01-01	15993
2015-01-02	16043
2015-01-03	16035
2015-01-04	16017
2015-01-05	16257
...	...
2026-03-31	36319

Tabel 2 merupakan hasil proses *data cleaning* pada data harga bawang merah harian di Provinsi Jawa Timur. Setelah proses pembersihan data selesai, diperoleh sebanyak 4.108 data yang telah tersusun secara kronologis berdasarkan tanggal dengan nilai harga yang lengkap sehingga


siap digunakan pada tahapan preprocessing berikutnya.

- b. Exploratory Data Analysis (EDA) dilakukan untuk mengetahui karakteristik data melalui visualisasi dan analisis statistik deskriptif sehingga pola fluktuasi harga dapat dipahami sebelum proses pemodelan [13].



Gambar 2 Tren Tahunan Harga Bawang Merah


Berdasarkan hasil *Exploratory Data Analysis* (EDA) yang ditunjukkan di Gambar 2, harga bawang merah di Provinsi Jawa Timur menunjukkan pola fluktuasi yang dinamis selama periode 2015 hingga 2026 dengan kecenderungan mengalami peningkatan dalam jangka panjang. Rata-rata harga tahunan terendah terjadi pada tahun 2015 sebesar Rp19.230,65/kg sedangkan rata-rata tertinggi terjadi pada tahun 2025 sebesar Rp37.527,99/kg.



Gambar 3 Tren Bulanan Harga Bawang Merah

Berdasarkan rata-rata bulanan pada Gambar 3, harga cenderung meningkat pada periode April hingga Juli dengan puncak rata-rata terjadi pada bulan Mei sebesar Rp33.136,57/kg, sementara harga terendah

terjadi pada bulan September sebesar Rp22.264,91/kg.



Gambar 4 Heatmap Harga Bawang Merah

Hasil visualisasi *heatmap* yang ditunjukkan pada Gambar 4 juga memperlihatkan adanya fluktuasi harga yang cukup signifikan antarbulan dan antartahun dengan rata-rata harga tertinggi terjadi pada Juli 2022 sebesar Rp55.227,29/kg dan rata-rata terendah pada Agustus 2015 sebesar Rp13.328,19/kg.

Secara keseluruhan, hasil EDA menunjukkan bahwa data memiliki pola tren meningkat, fluktuasi musiman (*seasonality*) serta karakteristik deret waktu yang bersifat nonlinier sehingga metode Long Short-Term Memory (LSTM) dipilih karena mampu mempelajari hubungan temporal jangka panjang pada data harga bawang merah.

- c. Normalisasi Data menggunakan metode Min-Max Scaling untuk mengubah nilai data ke dalam rentang 0–1 sehingga proses pelatihan model menjadi lebih stabil [14]. Sebelum proses pelatihan model dilakukan, data harga bawang merah dinormalisasi menggunakan metode Min-Max Scaling agar seluruh nilai berada pada rentang 0 hingga 1. Normalisasi bertujuan untuk mengurangi perbedaan skala antar data sehingga proses pelatihan model menjadi lebih stabil dan mempercepat konvergensi selama proses pembelajaran. Pada penelitian ini, nilai minimum data sebesar 11.889 dan nilai maksimum sebesar 65.994.

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Keterangan:

x = nilai asli

x_{min} = nilai minimum

x_{max} = nilai maksimum

Tabel 3 Contoh Hasil Normalisasi Data

ds	y	y'
2015-01-01	15993	0,0000
2015-01-02	16043	0,0711
2015-01-03	16035	0,0597
2015-01-04	16017	0,0341
2015-01-05	16257	0,3755

Tabel 3 menunjukkan contoh hasil normalisasi data harga bawang merah menggunakan metode *Min-Max Scaling*. Proses normalisasi mengubah nilai harga asli (y) menjadi nilai terukur (y') pada rentang 0 hingga 1 dengan tetap mempertahankan pola dan hubungan antar data. Data hasil normalisasi ini kemudian digunakan sebagai masukan (*input*) pada proses pembentukan data sekuens dan pelatihan model LSTM.

- d. Pembentukan data *sequence* yaitu mengubah data time series menjadi pasangan data input dan target menggunakan teknik *sliding window* sehingga data dapat diproses oleh model LSTM [15]. LSTM merupakan model berbasis data berurutan (*sequence*), maka data yang telah dinormalisasi diubah menjadi pasangan data input dan target menggunakan teknik *sliding window*. Pada penelitian ini digunakan *sequence length* sebesar 7 dan 30 hari, sehingga model memanfaatkan harga 7 hari dan 30 hari sebelumnya untuk memprediksi harga pada hari berikutnya.

Tabel 4 Contoh Data Sequence dengan Length 7

Seq ke-	Input X (7 nilai ternormalisasi)	Target y	Tanggal Target
1 (01-07 Jan)	[0,0000; 0,0711; 0,0597; 0,0341; 0,3755; 0,3570; 0,3940]	0,6458	08 Jan 2015
2 (02-08 Jan)	[0,0711; 0,0597; 0,0341; 0,3755; 0,3570; 0,3940; 0,6458]	0,6970	09 Jan 2015

Tabel 4 menunjukkan contoh pembentukan data *sequence* menggunakan *sequence length* 7 hari. Setiap data masukan (*input*) terdiri atas tujuh nilai harga yang telah dinormalisasi dari hari-hari sebelumnya, sedangkan nilai target (*target*) merupakan harga pada hari berikutnya. Pada penelitian ini, proses pembentukan *sequence* dilakukan untuk dua skenario yaitu *sequence length* 7 hari dan 30 hari yang bertujuan untuk membandingkan pengaruh panjang data historis terhadap kinerja model LSTM.

- e. Split Data yaitu membagi data menjadi data pelatihan dan data pengujian menggunakan skenario pembagian data yang telah ditentukan. Data kemudian dibagi menjadi data pelatihan (*training*) dan data pengujian (*testing*). Pada penelitian ini digunakan skenario pembagian data sebesar 80% data *training* dan 20% data *testing*. Pembagian dilakukan secara berurutan (tanpa proses *shuffle*) agar karakteristik data time series tetap terjaga.

D. Pemodelan Long Short-Term Memory

Model Long Short-Term Memory (LSTM) dibangun menggunakan data pelatihan yang telah melalui tahapan *preprocessing* yang meliputi *data cleaning*, normalisasi, dan pembentukan *data sequence*. Pada tahap ini, model dilatih untuk mempelajari pola temporal dari data historis harga bawang merah sehingga mampu memprediksi harga pada periode berikutnya. LSTM merupakan pengembangan dari Recurrent Neural Network (RNN) yang dirancang untuk mengatasi permasalahan *vanishing gradient* melalui mekanisme *memory cell* serta tiga komponen utama, yaitu *forget gate*, *input gate*, dan *output gate* [16]. Mekanisme tersebut memungkinkan model mempertahankan informasi penting dalam jangka panjang sekaligus membuang informasi yang tidak relevan.

Tahapan pertama pada LSTM adalah *forget gate* yang berfungsi menentukan informasi dari *cell state* sebelumnya yang perlu dipertahankan

atau dibuang. Nilai *forget gate* dihitung menggunakan Persamaan (2).

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (2)$$

Keterangan:

f_t = nilai *forget gate* pada waktu ke- t

h_{t-1} = *hidden state* sebelumnya

x_t = data masukan pada waktu ke- t

W_f = bobot *forget gate*

b_f = bias

σ = fungsi aktivasi sigmoid

Selanjutnya, input gate menentukan informasi baru yang akan disimpan ke dalam *cell state*. Proses ini terdiri atas perhitungan nilai *input gate* dan kandidat *cell state* sebagaimana ditunjukkan pada Persamaan (3) dan Persamaan (4).

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (4)$$

Keterangan:

i_t = nilai *input gate*

$\tilde{C}_t$ = kandidat *cell state*

W_i, W_c = bobot

b_i, b_c = bias

$\tanh$ = fungsi aktivasi hiperbolik

Setelah itu, *cell state* diperbarui dengan menggabungkan informasi lama yang dipertahankan dan informasi baru yang diperoleh dari *input gate*. Pembaruan *cell state* dihitung menggunakan Persamaan (5).

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (5)$$

Keterangan:

C_t = *cell state* saat ini

C_{t-1} = *cell state* sebelumnya

$\odot$ = perkalian elemen (*element-wise multiplication*)

Tahap terakhir adalah output gate, yang menentukan informasi yang akan dikeluarkan sebagai *hidden state*. Nilai *output gate* dan *hidden state* dihitung menggunakan Persamaan (6) dan Persamaan (7).

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t \odot \tanh(C_t) \quad (7)$$

Keterangan:

o_t = nilai *output gate*

h_t = *hidden state* pada waktu ke- t

W_o = bobot

b_o = bias

Pada penelitian ini, model LSTM dibangun menggunakan satu lapisan LSTM dan satu lapisan Dense sebagai lapisan keluaran. Proses pelatihan dilakukan menggunakan optimizer Adam dengan fungsi kehilangan Mean Squared Error (MSE). Pengujian dilakukan pada beberapa kombinasi sequence length (7 dan 30 hari), hidden units (32 dan 64), serta epoch (50 dan 100) untuk memperoleh konfigurasi model dengan performa terbaik.

E. Denormalisasi

Hasil prediksi yang dihasilkan oleh model LSTM masih berada dalam bentuk nilai ternormalisasi pada rentang 0 hingga 1 sehingga belum dapat diinterpretasikan sebagai harga bawang merah sebenarnya. Oleh karena itu, dilakukan proses denormalisasi untuk mengembalikan nilai prediksi ke skala harga asli menggunakan nilai minimum dan maksimum yang digunakan pada proses normalisasi. Proses denormalisasi dilakukan menggunakan Persamaan (8).

$$x = x' \times (x_{\max} - x_{\min}) + x_{\min} \quad (8)$$

Keterangan:

x = nilai hasil denormalisasi (harga prediksi dalam skala asli),

x' = nilai prediksi hasil normalisasi,

$x_{\max}$ = nilai maksimum data sebelum normalisasi

$x_{\min}$ = nilai minimum data sebelum normalisasi.

Melalui proses denormalisasi, hasil prediksi model dikembalikan ke satuan harga sebenarnya (rupiah per kilogram) sehingga dapat dibandingkan secara langsung dengan data aktual serta digunakan dalam proses evaluasi model dan analisis hasil prediksi.

F. Evaluasi dan Visualisasi

Tahap evaluasi dilakukan untuk menilai kinerja model LSTM pada setiap skenario pengujian yang menggunakan kombinasi parameter. Kinerja masing-masing model dievaluasi menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE) dan koefisien determinasi (R^2) [17].

Mean Absolute Error (MAE) digunakan untuk mengukur rata-rata selisih absolut antara nilai aktual dan nilai hasil prediksi. Semakin kecil nilai MAE, semakin baik kemampuan model dalam melakukan prediksi. MAE dihitung menggunakan Persamaan (9).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (9)$$

keterangan:

y_i = nilai aktual

$\hat{y}_i$ = nilai hasil prediksi

n = jumlah data pengujian

Root Mean Square Error (RMSE) digunakan untuk mengukur besar kesalahan prediksi dengan memberikan penalti yang lebih besar terhadap kesalahan yang bernilai tinggi karena menggunakan proses kuadrat. Semakin kecil nilai RMSE, semakin baik performa model. RMSE dihitung menggunakan Persamaan (10).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

keterangan:

y_i = nilai aktual

$\hat{y}_i$ = nilai hasil prediksi

n = jumlah data pengujian

Mean Absolute Percentage Error (MAPE) digunakan untuk mengukur rata-rata persentase kesalahan prediksi terhadap nilai aktual sehingga memudahkan interpretasi tingkat akurasi model dalam bentuk persentase. Semakin kecil nilai MAPE, semakin tinggi tingkat akurasi model. MAPE dihitung menggunakan Persamaan (11).

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (11)$$

keterangan:

y_i = nilai aktual

$\hat{y}_i$ = nilai hasil prediksi

n = jumlah data pengujian

Koefisien determinasi (R^2) digunakan untuk mengukur kemampuan model dalam menjelaskan variasi data aktual. Nilai R^2 berada pada rentang 0 hingga 1. Semakin mendekati 1, semakin baik model dalam merepresentasikan pola data. Koefisien determinasi dihitung menggunakan Persamaan (12).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (12)$$

keterangan:

y_i = nilai aktual

$\hat{y}_i$ = nilai hasil prediksi

$\bar{y}$ = rata-rata nilai aktual

n = jumlah data pengujian

Hasil evaluasi kemudian dibandingkan untuk menentukan konfigurasi parameter terbaik berdasarkan nilai MAE, RMSE, dan MAPE yang paling rendah serta nilai R^2 yang paling tinggi. Selanjutnya, model dengan konfigurasi terbaik digunakan untuk melakukan prediksi harga bawang merah selama 30 hari ke depan. Hasil prediksi divisualisasikan dalam bentuk grafik untuk membandingkan data aktual dengan hasil prediksi serta menampilkan tren harga pada periode prediksi.

III. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil implementasi model Long Short-Term Memory (LSTM) untuk prediksi harga bawang merah di Provinsi Jawa Timur serta pembahasannya.

A. Arsitektur LSTM

Model Long Short-Term Memory (LSTM) digunakan karena memiliki kemampuan untuk

mempelajari hubungan temporal pada data deret waktu (*time series*) serta mempertahankan informasi jangka panjang melalui mekanisme *memory cell* dan *gate*. Pada penelitian ini, arsitektur model terdiri atas satu lapisan LSTM (*hidden layer*) yang berfungsi mengekstraksi pola dari data historis harga bawang merah dan satu lapisan Dense sebagai lapisan keluaran untuk menghasilkan nilai prediksi. Model dikompilasi menggunakan optimizer Adam dengan *learning rate* sebesar 0,001.

Tabel 5 Skenario Pengujian Model

Parameter	Nilai Pengujian
Model	LSTM
Hidden Layer	1 layer
Hidden Units	32 dan 64
Epoch	50 dan 100
Batch Size	32
Learning Rate	0,001
Optimizer	Adam
Sequence Length	7 hari dan 30 hari
Split Data	80:20

Tabel 5 menunjukkan skenario pengujian yang digunakan dalam proses pelatihan model LSTM. Pengujian dilakukan menggunakan variasi *sequence length* selama 7 hari dan 30 hari, *hidden units* sebanyak 32 dan 64, serta jumlah *epoch* sebesar 50 dan 100. Kombinasi parameter tersebut digunakan untuk memperoleh konfigurasi model yang menghasilkan kinerja prediksi terbaik.

B. Evaluasi Model

Evaluasi dilakukan menggunakan empat metrik yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE) dan *koefisien determinasi* (R^2).

Tabel 6 Hasil Pengujian

Seq	Unit	Epoch	MAE	RMSE	MAPE	R^2
7	32	50	302,43	462,89	0,86	0,9959
7	32	100	245,22	391,66	0,70	0,9970
7	64	50	283,20	432,01	0,82	0,9964
7	64	100	227,91	372,55	0,65	0,9973
30	32	50	319,71	462,97	0,92	0,9959
30	32	100	290,74	419,93	0,83	0,9966
30	64	50	267,10	416,56	0,76	0,9967

30	64	100	279,79	410,28	0,79	0,9968
----	----	-----	--------	--------	------	--------


Berdasarkan hasil pengujian pada Tabel 6, peningkatan jumlah epoch dari 50 menjadi 100 secara umum menghasilkan nilai MAE, RMSE, dan MAPE yang lebih rendah. Hal ini menunjukkan bahwa proses pelatihan yang lebih lama memberikan kesempatan bagi model untuk melakukan pembaruan bobot (*weight update*) lebih banyak sehingga proses optimasi dapat mencapai titik konvergensi yang lebih baik. Pada data harga bawang merah yang memiliki pola tren dan fluktuasi harian, jumlah epoch yang lebih tinggi memungkinkan model mempelajari hubungan temporal secara lebih optimal tanpa menunjukkan indikasi overfitting yang juga didukung oleh kurva training loss dan validation loss yang relatif berdekatan.

Penggunaan 64 hidden units juga memberikan performa yang lebih baik dibandingkan 32 hidden units. Semakin banyak hidden units, semakin besar kapasitas model dalam merepresentasikan pola nonlinier dan ketergantungan temporal pada data deret waktu. Karakteristik harga bawang merah yang dipengaruhi oleh perubahan tren serta fluktuasi harian memerlukan representasi fitur yang lebih kaya sehingga konfigurasi 64 hidden units mampu menghasilkan prediksi yang lebih akurat. Sebaliknya, penggunaan 32 hidden units memiliki kapasitas representasi yang lebih terbatas sehingga beberapa pola perubahan harga belum dapat dipelajari secara optimal.

Hasil pengujian juga menunjukkan bahwa *sequence length* 7 hari menghasilkan akurasi yang lebih tinggi dibandingkan *sequence length* 30 hari. Kondisi ini mengindikasikan bahwa pergerakan harga bawang merah lebih dipengaruhi oleh informasi historis jangka pendek dibandingkan informasi yang terlalu panjang. Penggunaan *sequence* sepanjang 30 hari menyebabkan model mempelajari informasi historis yang lebih panjang sehingga kompleksitas pembelajaran meningkat. Pada data penelitian ini, penambahan informasi historis tersebut belum memberikan peningkatan akurasi dibandingkan *sequence length* 7 hari.


Nilai MAPE sebesar 0,65% termasuk dalam kategori *highly accurate forecasting* karena

berada di bawah 10% sehingga menunjukkan bahwa model LSTM memiliki tingkat akurasi prediksi yang sangat baik. Nilai MAE dan RMSE yang rendah juga menunjukkan bahwa selisih antara hasil prediksi dan data aktual relatif kecil sedangkan nilai R^2 yang mendekati 1 mengindikasikan bahwa model mampu merepresentasikan pola data dengan sangat baik.



Gambar 5 Grafik Aktual vs Prediksi Harga Bawang Merah

Berdasarkan Gambar 5, hasil prediksi model LSTM pada konfigurasi terbaik yaitu sequence length 7 hari, hidden units 64, dan epoch 100 memiliki pola yang sangat mendekati data aktual. Garis prediksi hampir berimpit dengan garis aktual yang menunjukkan bahwa model mampu menangkap pola temporal harga bawang merah dengan baik. Perbedaan hanya terlihat pada beberapa titik saat terjadi perubahan harga yang cukup tajam, namun secara keseluruhan hasil prediksi tetap menunjukkan tingkat kesesuaian yang tinggi terhadap data aktual.



Gambar 6 Kurva Training Loss dan Validation Loss

Gambar 6 menampilkan kurva training loss dan validation loss pada konfigurasi terbaik yaitu sequence length 7 hari, hidden units 64, dan epoch 100. Kedua kurva mengalami penurunan yang signifikan pada awal proses pelatihan dan kemudian cenderung stabil hingga akhir epoch dengan pola yang relatif berdekatan.

Kondisi ini menunjukkan bahwa model telah mencapai konvergensi serta mampu mempelajari pola data dengan baik tanpa indikasi overfitting.

C. Prediksi

Setelah diperoleh konfigurasi model terbaik berdasarkan hasil evaluasi, model *Long Short-Term Memory* (LSTM) digunakan untuk melakukan prediksi harga bawang merah selama 30 hari ke depan. Prediksi dilakukan menggunakan konfigurasi terbaik yaitu sequence length 7 hari, hidden units 64, dan epoch 100. Hasil prediksi kemudian divisualisasikan dalam bentuk grafik untuk menunjukkan proyeksi pergerakan harga bawang merah pada periode mendatang.



Gambar 7 Prediksi Harga Bawang Merah 30 Hari ke Depan

Berdasarkan Gambar 7, hasil prediksi menunjukkan bahwa harga bawang merah diperkirakan mengalami tren penurunan secara bertahap selama 30 hari ke depan. Harga yang pada awal periode prediksi berada pada kisaran Rp36.000/kg diproyeksikan menurun hingga sekitar Rp34.600/kg pada akhir periode prediksi. Meskipun menunjukkan kecenderungan menurun, perubahan harga berlangsung secara bertahap tanpa fluktuasi yang ekstrem sehingga pola prediksi terlihat relatif stabil.

IV. KESIMPULAN

Penelitian ini berhasil menerapkan metode *Long Short-Term Memory* (LSTM) untuk memprediksi harga bawang merah di Provinsi Jawa Timur berdasarkan data historis harian periode Januari 2015 hingga Maret 2026. Berdasarkan pengujian terhadap delapan kombinasi parameter, konfigurasi terbaik diperoleh pada sequence length 7 hari, hidden units 64, dan epoch 100. Konfigurasi tersebut menghasilkan nilai MAE sebesar 227,91, RMSE

sebesar 372,55, MAPE sebesar 0,65%, dan R^2 sebesar 0,9973 yang menunjukkan bahwa model memiliki tingkat kesalahan prediksi yang rendah serta mampu menjelaskan 99,73% variasi data harga bawang merah. Selain itu, hasil prediksi selama 30 hari ke depan menunjukkan adanya kecenderungan penurunan harga secara bertahap berdasarkan pola historis yang dipelajari model. Dengan demikian, metode LSTM terbukti mampu memodelkan pola temporal pada data harga bawang merah dan menghasilkan prediksi dengan tingkat akurasi yang sangat baik sehingga berpotensi digunakan sebagai pendukung pengambilan keputusan dalam memantau pergerakan harga komoditas. Untuk penelitian selanjutnya, model dapat dikembangkan dengan menambahkan variabel eksternal seperti curah hujan, musim panen, inflasi atau faktor distribusi, sehingga diharapkan mampu meningkatkan akurasi prediksi terutama pada kondisi fluktuasi harga yang dipengaruhi oleh berbagai faktor di luar data historis.

REFERENSI

- [1] J. Irawan, W. Hadiano, I. Syafari, D. Andriani, and M. Kamal, "Penerapan Teknologi Produksi Benih Bawang Merah untuk Mewujudkan Kemandirian Kelompok Wanita Tani Makmue Beurata, Desa Gampong Ladang, Aceh Barat," *Jurnal Masyarakat Mandiri dan Pembangunan (JMPM)*, vol. 7, no. 1, Jun. 2026, doi: 10.35311/jmpm.v7i1.1180.
- [2] Pusat Data dan Sistem Informasi Pertanian, *Analisis Kinerja Perdagangan Komoditas Bawang Merah*, vol. 15, no. 1C. Jakarta: Sekretariat Jenderal Kementerian Pertanian Republik Indonesia, 2025.
- [3] N. Apriyani, E. Andriani, and R. D. Yulihartika, "Analisis Fluktuasi Harga dan Saluran Pemasaran Bawang Merah (Allium Ceva L) di Kota Bengkulu," *AGRITECH: Jurnal Fakultas Pertanian Universitas Muhammadiyah Purwokerto*, vol. 23, no. 2, pp. 167–173, Dec. 2021, doi: 10.30595/agritech.v23i2.12133.
- [4] Badan Pusat Statistik, "Produksi Tanaman Sayuran dan Buah-Buahan Semusim Menurut Provinsi dan Jenis Tanaman, 2025," BPS-Statistics Indonesia. [Online]. [Accessed: Jul. 5, 2026].
- [5] Y. Syaqui Asy-syahid, E. S. Rahayu, and S. M. Handayani, "Analisis Tataniaga dan Disparitas Harga Komoditas Bawang Merah di Provinsi Jawa Tengah," in *Prosiding Seminar Nasional dalam Rangka Dies Natalis ke-47 Universitas Sebelas Maret: Akselerasi Hasil Penelitian dan Optimalisasi Tata Ruang Agraria untuk Mewujudkan Pertanian Berkelanjutan*, Surakarta, Indonesia, 2023, pp. 402–410.
- [6] Dinas Perindustrian dan Perdagangan Provinsi Jawa Timur, "Sistem Informasi Ketersediaan dan Perkembangan Harga Bahan Pokok (SISKAPERBAPO)," [Online]. Available: <https://siskaperbapo.jatimprov.go.id>. [Accessed: Jul. 5, 2026].
- [7] N. R. Sari and Y. Agustina, "Analisis Volatilitas Harga Bawang Merah di Kabupaten Kediri," *Agricore: Jurnal Agribisnis dan Sosial Ekonomi Pertanian Unpad*, vol. 10, no. 2, pp. 515–526, Dec. 2025, doi: 10.24198/agricore.v10i2.65263.
- [8] N. M. Khoirani, R. A. S. Anees, S. F. P. Annisa, and H. A. Rusyda, "Peramalan Harga Bawang Merah di Pasar Tradisional Sulawesi Selatan dengan Metode ARIMA," *Jurnal Agribisnis*, vol. 24, no. 2, pp. 274–287, Dec. 2022, doi: 10.31849/agr.v24i2.8670.
- [9] S. Al Farisi, G. A. Buntoro, and A. Prasetyo, "Prediksi Harga Bawang Merah dengan Regresi Linear Berbasis Website di Ponorogo," *Jurnal Teknik Informatika dan Sistem Informasi (JATISI)*, vol. 12, no. 3, pp. 61–77, Sep. 2025.
- [10] N. Selle, N. Yulistira, dan C. Dewi, "Perbandingan Prediksi Penggunaan Listrik dengan Menggunakan Metode Long Short Term Memory (LSTM) dan Recurrent Neural Network (RNN)," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 9, no. 1, hlm. 155–162, Feb. 2022, doi: 10.25126/jtik.202295585.
- [11] M. L. Rahman, M. Hani'ah, and M. A. Hendrawan, "Hyperparameter Tuning Metode Long Short-Term Memory (LSTM) untuk Prediksi Harga Bawang Merah di Pasar Tradisional Jawa Timur," *Jurnal Teknologi Informasi dan Multimedia*, vol. 8, no. 2, pp. 417–430, 2026, doi: 10.35746/jtim.v8i2.976.
- [12] M. F. A. C. and A. M. Hilda, "Sistem Informasi Prediksi Harga Saham Bank Syariah Menggunakan Metode ARIMA dan SARIMA dengan Antarmuka Visual," *Journal of Information System Research (JOSH)*, vol. 7, no. 2, pp. 301–310, Jan. 2026, doi: 10.47065/josh.v7i2.9026.
- [13] A. H. Wibowo, K. Faisah, and Y. Devianto, "Analisa Dan Visualisasi Data Penjualan Menggunakan Exploratory Data Analysis Pada PT. Telkominfra," *Jurnal Teknik Informatika dan Sistem Informasi (JATISI)*, vol. 9, no. 3, pp. 2292–2304, Sep. 2022.
- [14] R. Septiana, A. R. Putri, W. S. Maharani, G. D. Gultom, E. D. Simanullang, K. D. Tania, A. Meiriza, and A. Rifai, "Prediksi Harga Emas Indonesia Menggunakan Model CNN-LSTM," *INFOMATEK: Jurnal Informatika, Manajemen dan Teknologi*, vol. 27, no. 1, pp. 131–138, Jun. 2025, doi: 10.23969/infomatek.v27i1.24417.
- [15] Y. Ashari and A. Suhendar, "Implementasi Algoritma Long Short-Term Memory (LSTM) untuk Memprediksi Harga Beras di Jawa Tengah Berdasarkan Cuaca," *Djtechno: Jurnal Teknologi Informasi*, vol. 5, no. 3, Dec. 2024.
- [16] L. Wiranda and M. Sadikin, "Penerapan Long Short Term Memory pada Data Time Series untuk Memprediksi Penjualan Produk PT. Metiska Farma," *Jurnal Nasional Pendidikan Teknik Informatika*, vol. 8, no. 3, pp. 184–193, Dec. 2019.
- [17] N. K. Agusmawati, F. Khoiriyah, and A. Tholib, "Prediksi Harga Emas Menggunakan Metode LSTM dan GRU," *Jurnal Informatika dan Teknik Elektro Terapan (JITET)*, vol. 11, no. 3, 2023, doi: 10.23960/jitet.v11i3.3250.