

Prediksi Harga Cabai Merah Berbasis *Long Short-Term Memory* dan Komparasi ARIMA pada Data Runtun Waktu

Alisa Apriliani, Ade Ima Afifa Himayati, dan Findasari



Volume 14, Issue 2, Pages 467–483, August 2026

Diterima 30 Mei 2026, Direvisi 27 Juli 2026, Disetujui 1 Agustus 2026, Diterbitkan 5 Agustus 2026

To Cite this Article : A. Apriliani, A. I. A. Himayati, F. Findasari, “Prediksi Harga Cabai Merah Berbasis *Long Short-Term Memory* dan Komparasi ARIMA pada Data Runtun Waktu”, *Euler J. Ilm. Mat. Sains dan Teknol.*, vol. 14, no. 2, pp. 467–483, 2026, <https://doi.org/10.37905/euler.v14i2.39298>

© 2026 by author(s)

JOURNAL INFO • EULER : JURNAL ILMIAH MATEMATIKA, SAINS DAN TEKNOLOGI




	Homepage	:	http://ejurnal.ung.ac.id/index.php/euler/index
	Journal Abbreviation	:	Euler J. Ilm. Mat. Sains dan Teknol.
	Frequency	:	Three times a year
	Publication Language	:	English (preferable), Indonesia
	DOI	:	https://doi.org/10.37905/euler
	Online ISSN	:	2776-3706
	License	:	Creative Commons Attribution-NonCommercial 4.0 International License
	Publisher	:	Department of Mathematics, Universitas Negeri Gorontalo
	Country	:	Indonesia
	OAI Address	:	http://ejurnal.ung.ac.id/index.php/euler/oai
	Google Scholar ID	:	QF_r-gAAAAJ
	Email	:	euler@ung.ac.id


JAMBURA JOURNAL • FIND OUR OTHER JOURNALS




Jambura Journal of
Biomathematics



Jambura Journal of
Mathematics



Jambura Journal of
Mathematics Education



Jambura Journal of
Probability and Statistics

Prediksi Harga Cabai Merah Berbasis *Long Short-Term Memory* dan Komparasi ARIMA pada Data Runtun Waktu

Alisa Apriliani^{1,*}, Ade Ima Afifa Himayati¹, Findasari¹

¹Program Studi Matematika, Universitas Muhammadiyah Kudus, Kudus, 59316, Indonesia

ARTICLE HISTORY

Diterima 30 Mei 2026
Direvisi 27 Juli 2026
Disetujui 1 Agustus 2026
Diterbitkan 5 Agustus 2026

KATA KUNCI

Data Runtun Waktu
Forecasting
Prediksi Harga Cabai
Long Short-Term Memory

KEYWORDS

Time Series Data
Forecasting
Chili Price Prediction
Long Short-Term Memory

ABSTRAK. Harga cabai merah di Kabupaten Jepara, Jawa Tengah, menunjukkan fluktuasi yang tinggi dan bersifat nonlinier akibat faktor musiman, cuaca, dan dinamika pasokan. Ketidakstabilan ini berdampak pada inflasi pangan serta pendapatan petani dan pedagang. Penelitian ini bertujuan membangun model prediksi harga cabai merah di Kabupaten Jepara menggunakan metode Long Short-Term Memory (LSTM) serta membandingkan performanya dengan metode Autoregressive Integrated Moving Average (ARIMA). Data yang digunakan adalah harga mingguan cabai merah periode Januari 2020 hingga Desember 2025 yang diperoleh dari laman resmi hargajateng.org. Tahapan penelitian meliputi data preprocessing, normalisasi menggunakan Min-Max Scaling, pembentukan data time series dengan sliding window, pelatihan model LSTM menggunakan optimizer Adam, fungsi loss Mean Squared Error (MSE), maksimum 200 epoch, batch size 8, serta penerapan EarlyStopping untuk memperoleh model terbaik. Evaluasi performa dilakukan menggunakan Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Hasil penelitian menunjukkan bahwa model LSTM mampu mengikuti pola perubahan harga cabai dengan baik dan menghasilkan nilai RMSE sebesar 16.707,02, MAE sebesar 12.348,54, dan MAPE sebesar 19,31% pada data pengujian. Selain itu, hasil forecasting selama 16 minggu memberikan gambaran kecenderungan perubahan harga pada periode mendatang. Dibandingkan dengan model ARIMA yang menghasilkan RMSE sebesar 20.992,15, MAE sebesar 13.867,26, dan MAPE sebesar 22,70%, model LSTM menunjukkan performa prediksi yang lebih baik dengan tingkat kesalahan yang lebih rendah. Hasil penelitian menunjukkan bahwa metode LSTM lebih efektif dalam memodelkan pola nonlinier pada data harga cabai merah dibandingkan metode ARIMA.

ABSTRACT. The price of red chili in Jepara Regency, Central Java, shows high and nonlinear fluctuations due to seasonal factors, weather, and supply dynamics. This instability affects food inflation as well as the income of farmers and traders. This study aims to build a prediction model for red chili prices in Jepara Regency using the Long Short-Term Memory (LSTM) method and compare its performance with the Autoregressive Integrated Moving Average (ARIMA) method. The data used are weekly red chili prices from January 2020 to December 2025, obtained from the official hargajateng.org website. The research steps include data preprocessing, normalization using Min-Max Scaling, forming time series data with a sliding window, training the LSTM model using the Adam optimizer, Mean Squared Error (MSE) as the loss function, a maximum of 200 epochs, batch size of 8, and applying EarlyStopping to get the best model. Performance evaluation was done using Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE). The study results show that the LSTM model can follow chili price change patterns well, producing an RMSE of 16,707.02, an MAE of 12,348.54, and a MAPE of 19.31% on the testing data. Additionally, the 16-week forecasting results give an idea of the price trend in the upcoming period. Compared to the ARIMA model, which produced an RMSE of 20,992.15, an MAE of 13,867.26, and a MAPE of 22.70%, the LSTM model shows better prediction performance with lower error rates. The study indicates that the LSTM method is more effective in modeling nonlinear patterns in red chili price data compared to the ARIMA method.



This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International License. **Editorial of EULER:** Department of Mathematics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B. J. Habibie, Bone Bolango 96554, Indonesia.

*Penulis Korespondensi.

1. Pendahuluan

Bahan pokok merupakan komoditas penting yang secara rutin dibutuhkan untuk memenuhi kebutuhan dasar pangan masyarakat sehari-hari. Di Indonesia, komoditas seperti beras, jagung, minyak goreng, gula, serta sayuran seperti bawang merah dan cabai rawit menjadi bagian integral dari kebutuhan pokok masyarakat [1]. Ketersediaan, harga, dan kemudahan akses terhadap bahan pokok sangat berpengaruh terhadap kesejahteraan masyarakat serta stabilitas perekonomian lokal dan nasional [2]. Salah satu komoditas yang sangat penting adalah cabai merah, terutama di Kabupaten Jepara, Provinsi Jawa Tengah. Permintaan terhadap cabai merah tinggi dan konsisten, namun harganya di pasar regional dikenal sangat berfluktuasi dan tidak selalu stabil, yang berdampak pada kestabilan pasar serta kesejahteraan petani dan konsumen [3]. Secara spesifik, Kabupaten Jepara dipilih sebagai lokasi penelitian karena perannya sebagai salah satu pusat distribusi pangan strategis di Provinsi Jawa Tengah. Berdasarkan data historis pangan yang tidak terkontrol akibat dampak cuaca, kenaikan biaya transportasi, serta dinamika rantai pasok regional. Ketidakstabilan harga di Jepara, sebagaimana dilaporkan melalui Sistem Informasi Harga dan Produk Komoditi (SiHaTi), seringkali menunjukkan volatilitas yang signifikan dibandingkan wilayah sekitarnya yang berdampak langsung pada daya beli masyarakat dan tingkat inflasi daerah.

Meskipun prediksi harga komoditas pangan telah banyak dieksplorasi, sebagian besar penelitian terdahulu di wilayah Jawa Tengah masih mengandalkan model statistik linier seperti *Autoregressive Integrated Moving Average* (ARIMA). Model ARIMA, yang berbasis pada asumsi linearitas dan stasioneritas, memiliki keterbatasan inheren dalam menangani data yang bersifat non-linier dan volatilitas ekstrem yang kerap terjadi pada harga cabai [4]. Selain itu, penelitian sebelumnya telah membandingkan model ARIMA dan *Long Short-Term Memory* (LSTM) dalam pemodelan data runtun waktu. Mani *et al.* [5] melakukan perbandingan ARIMA dan LSTM untuk peramalan tingkat polusi udara dan menunjukkan bahwa LSTM menghasilkan performa yang lebih baik dibandingkan ARIMA berdasarkan nilai MAE dan RMSE. Hasil tersebut menunjukkan bahwa penggunaan model berbasis *deep learning* seperti LSTM dapat menjadi alternatif dalam pemodelan dan peramalan data runtun waktu yang memiliki pola kompleks.

Ketidakmampuan model linier dalam menangkap pola tersebut berakar pada sifat harga cabai yang sangat volatil dan dipengaruhi oleh faktor-faktor eksogen yang kompleks. Secara empiris, ketidakstabilan harga cabai tersebut dipicu oleh berbagai faktor kompleks, mulai dari pola panen musiman hingga kondisi iklim yang tidak menentu. Pola distribusi yang belum merata di Provinsi Jawa Tengah semakin memperparah kondisi ini, yang secara tidak langsung berdampak pada risiko kerugian ekonomi bagi petani, kesulitan pengelolaan stok bagi pedagang, hingga kontribusi terhadap inflasi pangan regional yang menggerus daya beli masyarakat. Mengingat perubahan harga cenderung meningkat tajam pada periode tertentu, misalnya saat permintaan masyarakat melonjak sementara pasokan menurun. Pasar menjadi sulit diprediksi, yang pada akhirnya meningkatkan ketidakpastian harga bagi seluruh pelaku ekonomi.

Oleh karena itu, pemahaman mendalam terhadap dinamika harga melalui pemodelan *deep learning* yang mampu mengakomodasi kompleksitas data nonlinier tersebut sangat penting. Hal ini diperlukan untuk memperoleh informasi mengenai kecenderungan perubahan harga serta mendukung analisis stabilisasi harga pangan di tingkat daerah. Sebagai salah satu pendekatan, Jaringan Saraf Tiruan (JST) berbasis data runtun waktu dapat digunakan untuk memodelkan pola harga berdasarkan data historis. Salah satu arsitektur yang sesuai untuk data runtun waktu adalah *Long Short-Term Memory* (LSTM) karena memiliki mekanisme memori yang memungkinkan model mempertahankan informasi dari periode sebelumnya [6].

Penelitian mengenai prediksi harga cabai telah dilakukan dengan berbagai metode. Fikri dan Nurochman [7] menerapkan metode *Long Short-Term Memory* (LSTM) untuk memprediksi harga cabai rawit merah serta mengevaluasi konfigurasi arsitektur dan *hyperparameter* yang sesuai. Sementara itu, Gunawan dan Andriani [8] menggunakan model *Long Short-Term Memory* (LSTM) untuk memprediksi harga cabai musiman di Jawa Tengah. Selain itu, Adam *et al.* [9] membandingkan performa ARIMA dan LSTM pada prediksi data runtun waktu dan menunjukkan bahwa kedua metode memiliki karakteristik yang berbeda dalam menangani pola data [10].

Meskipun berbagai penelitian telah menerapkan metode statistik maupun kecerdasan buatan untuk memprediksi harga komoditas pangan, terdapat beberapa keterbatasan utama (*research gap*) yang perlu diselesaikan. Penerapan algoritma *Long Short-Term Memory* (LSTM) dalam memprediksi harga cabai merah telah terbukti efektif pada cakupan wilayah tertentu, seperti di Yogyakarta [11]. Di sisi lain, tren pemodelan komoditas pertanian terkini mulai berkembang ke arah arsitektur hibrida yang kompleks, seperti integrasi VMD-LSTM [12] maupun kombinasi ARIMA-LSTM untuk memprediksi data cabai dan iklim nasional [13]. Namun demikian, sebagian besar penelitian terdahulu masih berfokus pada agregasi data berfrekuensi harian atau bulanan, sehingga kurang mampu menangkap dinamika serta laju fluktuasi harga mingguan secara presisi. Selain itu, kajian empiris yang secara spesifik mengeksplorasi volatilitas harga cabai merah di tingkat kabupaten, khususnya Kabupaten Jepara sebagai simpul distribusi pangan strategis, masih sangat terbatas. Evaluasi kinerja berdiri sendiri (*standalone*) antara model *deep learning* dan statistik linier klasik secara langsung (*head-to-head*) pada *dataset* serta rentang waktu pengujian mingguan yang identik juga masih memerlukan pembuktian empiris lebih lanjut.

Kebaruan (*novelty*) dari penelitian ini terletak pada pemodelan prediksi harga cabai merah berbasis data runtun waktu mingguan di tingkat kabupaten menggunakan arsitektur *Long Short-Term Memory* (LSTM), yang dikombinasikan dengan evaluasi komparatif komprehensif terhadap model *Autoregressive Integrated Moving Average* (ARIMA) sebagai pembanding statistik linier [14]. Penelitian ini tidak hanya menguji performa model pada data historis, tetapi juga memberikan kontribusi praktis melalui simulasi *autoregressive point forecast* selama 16 minggu ke depan guna menyediakan gambaran tren pergerakan harga jangka pendek bagi pengambil kebijakan stabilitas pangan daerah.

Berdasarkan uraian *gap* dan *novelty* tersebut, penelitian ini bertujuan untuk:

1. Membangun dan melatih model *Long Short-Term Memory* (LSTM) berbasis data runtun waktu mingguan untuk memprediksi dinamika harga cabai merah di Kabupaten Jepara.
2. Mengevaluasi kinerja prediksi model LSTM serta membandingkan performanya secara komparatif terhadap model ARIMA berdasarkan metrik *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE) pada data pengujian yang sama.
3. Memproyeksikan kecenderungan pergerakan harga cabai merah melalui *forecasting* selama 16 minggu ke depan sebagai landasan analisis stabilitas pasokan pangan.

2. Metode

2.1. Jenis Penelitian


Penelitian ini merupakan penelitian kuantitatif terapan yang menggunakan pendekatan *forecasting* berbasis data runtun waktu (*time series*). Penelitian bertujuan membangun, melatih, dan mengevaluasi model *Long Short-Term Memory* (LSTM) untuk memprediksi harga cabai merah di Kabupaten Jepara.

2.2. Data dan Sumber Data

Data yang digunakan adalah data harga cabai merah mingguan di Kabupaten Jepara, Provinsi Jawa Tengah, periode Januari 2020 hingga Desember 2025. Data bersumber dari sistem informasi harga pangan Pemerintah Provinsi Jawa Tengah yang dapat diakses melalui laman hargajateng.org, yaitu portal Sistem Informasi Harga dan Produk Komoditi (SiHaTi). Seluruh data harga cabai mingguan pada periode tersebut digunakan sebagai sampel (*total sampling*). Data awal terdiri atas 312 observasi mingguan. Dalam proses *data cleaning*, *missing value* yang masih memungkinkan untuk diestimasi diperbaiki menggunakan interpolasi linear, sedangkan observasi yang tidak dapat dipertahankan dieliminasi. Hasil proses tersebut menghasilkan 226 observasi valid yang digunakan dalam pemodelan.

2.3. Tahapan Penelitian

Analisis data dalam penelitian ini menggunakan pendekatan kuantitatif dengan model *Deep Learning* jenis *Long Short-Term Memory* (LSTM). Tahapan analisis ini dilakukan secara berurutan untuk memastikan prediksi harga cabai merah di Kabupaten Jepara. Penelitian dilaksanakan melalui tahapan sistematis sebagaimana disajikan pada **Gambar 1**.



Gambar 1. Tahapan penelitian.

Selanjutnya dilakukan *data cleaning* untuk menangani *missing value*, kemudian data dibagi secara kronologis menjadi data *training*, *validation*, dan *testing*. Setelah itu dilakukan normalisasi menggunakan metode *Min-Max Scaling* dengan parameter yang dihitung hanya dari data *training* untuk menghindari *data leakage*. Tahap berikutnya adalah pembentukan *sequence* menggunakan teknik *sliding window*, pembangunan dan pelatihan model LSTM, prediksi pada data *testing*, evaluasi model menggunakan RMSE, MAE, dan MAPE, dilanjutkan dengan *forecasting* selama 16 minggu serta perbandingan hasil dengan model ARIMA.

2.4. Preprocessing (Normalisasi)

Tahap *preprocessing* meliputi tiga kegiatan utama. Pada tahap awal, dilakukan pembersihan data (*data cleaning*) terhadap total 312 observasi mentah. Data awal terdiri atas 312 observasi mingguan. Sebagian kecil data mengandung *missing value*. *Missing value* yang masih berada di antara dua observasi diestimasi menggunakan interpolasi linear, sedangkan obse-

rvasi yang tidak memungkinkan untuk dipertahankan setelah proses pembersihan data dieliminasi sehingga diperoleh 226 observasi valid.

Kedua, pembagian data dalam rasio 80:20 dilakukan secara kronologis dengan total 226 observasi. Sebanyak 180 observasi digunakan sebagai *training set*. Dari data *training* tersebut, sebanyak 162 observasi digunakan sebagai data pelatihan dan 18 observasi sebagai data validasi. Selanjutnya, sebanyak 46 observasi terakhir digunakan sebagai data *testing*.

Ketiga, normalisasi data ke dalam rentang $[0, 1]$ menggunakan metode *Min-Max Scaling* dilakukan dengan ketentuan: parameter $x_{\min}$ dan $x_{\max}$. Nilai tersebut kemudian digunakan untuk mentransformasi data *testing* guna mencegah terjadinya *data leakage*. Proses ini dipastikan tidak melibatkan informasi dari data *testing* selama tahap *fitting* model. Normalisasi dilakukan dengan persamaan:

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}},$$

di mana:

x_{norm} = data hasil normalisasi,

x = data asli,

$x_{\min}$ = nilai minimum yang dihitung dari *training set*,

$x_{\max}$ = nilai maksimum yang dihitung dari *training set*.

2.5. Arsitektur Model LSTM

Arsitektur model yang digunakan berupa jaringan *sequential* dengan satu lapisan LSTM yang terdiri atas 32 unit neuron. Panjang urutan *input* ditetapkan sebanyak 12 *timestep*. *Look-back window* 12 dipilih sebagai representasi satu siklus tiga bulan pada data mingguan. Pemilihan ini digunakan sebagai konfigurasi penelitian, bukan sebagai hasil optimasi *hyperparameter* model LSTM.

Dengan panjang *sequence* (*look-back*) sebanyak 12 *timestep*, data masukan dibentuk dalam format 3D (*samples, timesteps, features*) (214, 12, 1). Setelah proses pembentukan *sequence* dari 226 data observasi, model memproses 214 sampel efektif ($226 - 12 = 214$) sebelum dilakukan pembagian menjadi data pelatihan, validasi, dan pengujian. *Output* model berupa satu nilai prediksi harga pada *time step* berikutnya. Proses pelatihan dilakukan dengan maksimum 200 *epoch* dengan *batch size* 8 menggunakan *optimizer* Adam dan fungsi *loss* Mean Squared Error (MSE). Selama proses pelatihan diterapkan mekanisme *EarlyStopping* sehingga proses pelatihan dapat berhenti lebih awal apabila nilai *validation loss* tidak lagi mengalami perbaikan.

Penerapan arsitektur lapisan tunggal dipilih untuk menjaga kompleksitas model agar tetap efisien dalam memproses *dataset* mingguan dengan total 226 observasi yang valid serta mereduksi risiko *overfitting*.

2.6. Mekanisme LSTM

Arsitektur LSTM dirancang untuk mengatasi masalah *vanishing gradient* pada *Recurrent Neural Network* (RNN) standar dengan menggunakan mekanisme *gating* yang memungkinkan model untuk mengontrol aliran informasi yang masuk, tersimpan, dan keluar dari *cell state*. Proses ini dilakukan melalui tiga gerbang utama dan satu pembaruan status sel. Berikut adalah persamaan matematis yang merepresentasikan mekanisme kerja LSTM pada setiap *timestep*:

1. *Forget gate* (f_t) pada pers. (1) menentukan informasi masa lalu yang akan dibuang.

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

2. *Input gate* (i_t) pada pers. (2) memilih informasi baru yang akan disimpan.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i). \quad (2)$$

3. Kandidat memori ($\tilde{C}_t$) pada pers. (3) menghasilkan nilai baru potensial.

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c). \quad (3)$$

4. *Cell state* (C_t) pada pers. (4) memperbarui memori jangka panjang.

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t. \quad (4)$$

5. *Output gate* (o_t) pada pers. (5) menentukan bagian mana dari *cell state* yang akan dikeluarkan sebagai *hidden state* h_t .

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o). \quad (5)$$

6. *Hidden State* (h_t) pada pers. (6) merupakan hasil akhir dari unit LSTM pada *timestep* t yang dikirim ke lapisan berikutnya atau digunakan sebagai *output*.

$$h_t = o_t \odot \tanh(C_t), \quad (6)$$

di mana:

- x_t = Vektor input pada *timestep* t ,
- h_{t-1} = Nilai output sebelum *timestep* t ,
- f_t = *Forget gate*,
- i_t = *Input gate*,
- o_t = *Output gate*,
- C_t = *Cell state* saat ini,
- C_{t-1} = *Cell state* sebelum *timestep* t ,
- $\tilde{C}_t$ = Kandidat *cell state* (kandidat *memory*),
- h_t = Nilai output *timestep* t ,
- σ = Fungsi aktivasi *sigmoid*,
- $\tanh$ = Fungsi aktivasi *hyperbolic tangent*,
- W = Nilai *weight* (bobot) masing-masing *gate* dan *cell state*,
- b = Nilai *bias* masing-masing *gate* dan *cell state*,
- $\odot$ = Perkalian Hadamard,
- e = Konstanta bilangan Euler.

2.7. Pelatihan Model

Model dilatih menggunakan *optimizer* Adam dengan fungsi *loss* *Mean Squared Error* (MSE). Selama proses pelatihan diterapkan *callback* *EarlyStopping* dengan parameter `restore_best_weights=True` untuk menghentikan pelatihan secara otomatis ketika nilai *validation loss* tidak lagi mengalami perbaikan, sehingga risiko *overfitting* dapat diminimalkan. Selain itu, *ModelCheckpoint* digunakan untuk menyimpan bobot model terbaik berdasarkan nilai *validation loss*.

2.8. Prediksi dan Denormalisasi

Setelah model menghasilkan nilai prediksi dalam bentuk data yang telah dinormalisasi, hasil prediksi dikembalikan ke skala aslinya menggunakan proses denormalisasi (*inverse transformation*) dengan fungsi `inverse_transform()` pada *Min-Max Scaler*. Tahap ini bertujuan

agar hasil prediksi kembali dalam satuan asli (Rupiah/kg), sehingga dapat dibandingkan secara langsung dengan data aktual. Denormalisasi dilakukan dengan persamaan pada pers. (7).

$$x = x_{\text{norm}} \times (x_{\text{max}} - x_{\text{min}}) + x_{\text{min}}, \quad (7)$$

di mana:

x = nilai hasil denormalisasi (harga prediksi pada skala asli)

x_{norm} = nilai hasil normalisasi

x_{max} = nilai maksimum pada data asli

x_{min} = nilai minimum pada data asli

2.9. Evaluasi Model

Kinerja model dievaluasi menggunakan *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). RMSE digunakan untuk mengukur besarnya kesalahan prediksi dengan memberikan penalti lebih besar terhadap kesalahan yang tinggi, MAE digunakan untuk mengukur rata-rata selisih absolut antara nilai aktual dan nilai prediksi, sedangkan MAPE digunakan untuk mengukur rata-rata persentase kesalahan prediksi terhadap data aktual.

2.10. Perangkat Lunak

Seluruh proses komputasi, mulai dari *preprocessing*, pelatihan model, prediksi, hingga evaluasi, dilakukan menggunakan bahasa pemrograman Python dengan *library* seperti *pandas*, *scikit-learn*, dan *TensorFlow/Keras*.

3. Hasil dan Pembahasan

3.1. Analisis Deskriptif Data dan Pra-pemrosesan Data (Preprocessing)

Penelitian ini menggunakan data harga cabai di Kabupaten Jepara pada periode Januari tahun 2020 hingga bulan Desember 2025 yang diperoleh dari situs hargajateng.org. Data tersebut merupakan data runtun waktu (*time series*), yang mana data tersusun berdasarkan urutan waktu sehingga dapat menunjukkan perubahan harga dari bulan ke bulan.



Gambar 2. Data harga cabai.

Berdasarkan hasil analisis, data harga cabai di Kabupaten Jepara selama periode 2020 hingga 2025 menunjukkan pola yang berfluktuasi dari waktu ke waktu. Fluktuasi ini terjadi secara mingguan, yang mengindikasikan bahwa data memiliki karakteristik volatilitas tinggi.

Secara matematis, data harga cabai tidak hanya bergantung pada nilai sebelumnya, tetapi juga mengandung pola non-linear yang kompleks. Oleh karena itu, diperlukan metode yang mampu menangkap hubungan antar waktu secara dinamis. Dalam penelitian ini, digunakan metode *Long Short-Term Memory* (LSTM) yang memiliki kemampuan dalam memodelkan dependensi jangka pendek maupun jangka panjang melalui mekanisme memori (*cell state*), sehingga diharapkan mampu menangkap pola fluktuasi harga cabai secara lebih akurat.


Tahap *preprocessing* meliputi penanganan *missing value* menggunakan interpolasi linear, normalisasi data ke rentang $[0, 1]$ dengan metode *Min-Max Scaling*, serta pembagian data menjadi 80% data latih (*training*) dan 20% data uji (*testing*). Normalisasi bertujuan meningkatkan stabilitas proses pelatihan model LSTM karena perbedaan skala data yang terlalu besar dapat menghambat proses pembelajaran. Dengan data yang telah dinormalisasi, model dapat lebih mudah dalam mengenali pola yang terdapat pada data.

Pembagian data dilakukan dengan rasio 80% *training* (180 observasi: Januari 2020 – Desember 2024) dan 20% *testing* (46 observasi: Januari – Desember 2025). Hal ini bertujuan untuk mempertahankan urutan waktu pada data, sehingga model dapat mempelajari pola berdasarkan kondisi sebenarnya. Dengan demikian, tahap pra-pemrosesan yang dilakukan telah sesuai dengan kebutuhan pemodelan berbasis LSTM.

3.2. Proses Pelatihan Model (Training)

Proses pelatihan model LSTM menunjukkan penurunan nilai *loss* secara bertahap hingga mencapai konvergensi. Model yang digunakan dalam penelitian ini adalah arsitektur *single layer* LSTM dengan 32 unit. Pemilihan arsitektur ini disesuaikan dengan jumlah data yang relatif terbatas, sehingga diharapkan dapat mengurangi risiko *overfitting* dan menjaga kestabilan model selama proses pelatihan.

Proses pelatihan dilakukan dengan maksimum 200 *epoch* menggunakan *batch size* 8, *optimizer* Adam, dan fungsi *loss* Mean Squared Error (MSE). Selama proses pelatihan diterapkan *callback* *EarlyStopping* dengan parameter `restore_best_weights=True` sehingga proses pelatihan berhenti secara otomatis ketika nilai *validation loss* tidak lagi mengalami perbaikan.



Gambar 3. Validation Loss.


Gambar 3 menunjukkan bahwa nilai *training loss* dan *validation loss* mengalami penurunan yang konsisten pada awal proses pelatihan. Setelah sekitar *epoch* ke-100, kedua kurva mulai

mendekati kondisi konvergen dan tidak menunjukkan perubahan yang signifikan. *EarlyStopping* menghentikan proses pelatihan pada sekitar *epoch* ke-107 karena nilai *validation loss* tidak lagi mengalami perbaikan. Kondisi ini menunjukkan bahwa model telah mencapai konvergensi tanpa indikasi *overfitting* yang berarti, sehingga bobot terbaik digunakan sebagai model akhir dalam proses prediksi.

3.3. Hasil dan Prediksi Harga Cabai

Setelah proses pelatihan model selesai, langkah selanjutnya dilakukan prediksi harga cabai menggunakan model LSTM dengan *input* berupa data *time series* yang telah dinormalisasi. Hasil prediksi pada data *testing* menunjukkan bahwa model LSTM mampu mengikuti pola perubahan harga cabai merah dengan cukup baik. Garis prediksi memiliki kecenderungan yang searah dengan data aktual, baik pada saat harga mengalami kenaikan maupun penurunan. Walaupun demikian, pada beberapa periode dengan perubahan harga yang sangat tajam masih terlihat adanya deviasi antara nilai prediksi dan nilai aktual. Kondisi tersebut menunjukkan bahwa model mampu menangkap pola temporal utama, namun masih mengalami kesulitan dalam merepresentasikan fluktuasi ekstrem yang dipengaruhi oleh faktor-faktor eksternal di luar informasi historis harga.

Setelah proses *training* selesai, model menghasilkan *output* berupa nilai prediksi pada data *testing*. Hasil prediksi tersebut masih dalam bentuk normalisasi, sehingga dilakukan proses denormalisasi agar nilainya kembali ke skala harga asli. Hasil prediksi yang telah diperoleh selanjutnya dibandingkan dengan data aktual untuk melihat kemampuan model dalam mengikuti pola pergerakan harga, yang ditunjukkan pada **Gambar 4**.




Gambar 4. Prediksi vs Aktual.

Pada **Gambar 4**, terlihat bahwa kemampuan model LSTM dalam mengikuti pola perubahan harga didukung oleh mekanisme memori internal (*cell state*) yang secara teoritis memungkinkan model mempertahankan informasi historis dalam rentang waktu yang lebih panjang. Karakteristik tersebut menjadikan LSTM lebih adaptif dibandingkan pendekatan statistik linier ketika digunakan pada data harga cabai yang bersifat nonlinier dan volatil.

Hasil *forecasting* kemudian ditampilkan dalam bentuk grafik bersama data aktual dan hasil prediksi sebelumnya untuk melihat perbandingan secara keseluruhan, seperti pada **Gambar 5**.

Pada **Gambar 5** diperlihatkan perbandingan antara data aktual harga cabai, hasil prediksi model LSTM dan ARIMA pada data *testing*, serta hasil *forecasting* LSTM untuk periode berikutnya. Garis biru menunjukkan data aktual, garis oranye putus-putus menunjukkan hasil prediksi



Gambar 5. Hasil prediksi, data aktual, dan forecasting.

LSTM pada data *testing*, sedangkan garis hijau menunjukkan hasil prediksi ARIMA pada data *testing*. Garis merah muda putus-putus menunjukkan hasil *forecasting* LSTM untuk periode berikutnya. Selain itu, garis merah putus-putus menunjukkan batas antara data *training* dan *testing*, sedangkan garis ungu putus-putus menunjukkan titik awal prediksi LSTM.

Pada grafik terlihat bahwa hasil prediksi model LSTM sudah cukup mampu mengikuti pola pergerakan data aktual. Pola kenaikan dan penurunan harga dapat diikuti oleh model meskipun pada beberapa titik masih terdapat perbedaan antara nilai prediksi dengan data sebenarnya. Selisih tersebut lebih terlihat ketika terjadi perubahan harga yang cukup tinggi, sehingga menunjukkan bahwa model belum sepenuhnya mampu menangkap fluktuasi harga yang ekstrem.

Sementara itu, hasil *forecasting* LSTM yang ditampilkan pada garis merah muda menunjukkan pola yang cenderung lebih stabil dibandingkan data aktual sebelumnya. Hal ini menunjukkan bahwa kemampuan model dalam melakukan prediksi mulai menurun ketika digunakan untuk prediksi jangka yang lebih panjang. Kondisi tersebut dapat terjadi karena harga cabai merupakan data yang fluktuatif dan dipengaruhi oleh berbagai faktor, sehingga model mengalami kesulitan dalam mempertahankan tingkat akurasi pada periode selanjutnya.

3.4. Prediksi Harga Cabai 16 Minggu ke Depan

Berdasarkan model *Long Short-Term Memory* (LSTM) yang telah dilatih, selanjutnya dilakukan prediksi untuk 16 minggu ke depan (Januari–April 2026) dengan pendekatan *autoregressive forecasting*, di mana *output* prediksi periode sebelumnya menjadi *input* untuk periode berikutnya. Dengan cara ini, model LSTM memanfaatkan pola data yang sudah dipelajari untuk memperkirakan nilai pada waktu selanjutnya. Hasil prediksi harga cabai 16 minggu ke depan disajikan pada **Tabel 1**.

Berdasarkan hasil prediksi menggunakan metode LSTM pada **Tabel 1**, harga cabai pada minggu pertama diperkirakan sebesar Rp45.813. Harga tersebut kemudian mengalami penurunan bertahap hingga mencapai titik terendah pada minggu ke-5 sebesar Rp37.267. Setelah itu, harga diproyeksikan kembali meningkat secara konsisten hingga mencapai Rp46.344 pada minggu ke-16. Pola ini menunjukkan adanya kecenderungan fluktuasi harga yang dinamis, di mana model mampu menangkap perubahan tren penurunan di awal periode serta kenaikan bertahap hingga akhir periode prediksi.

Tabel 1. Prediksi harga cabai 16 minggu.

Periode Minggu	Harga (Rp)
Ke-1	45.813
Ke-2	41.777
Ke-3	39.131
Ke-4	37.694
Ke-5	37.267
Ke-6	37.481
Ke-7	38.243
Ke-8	39.382
Ke-9	40.772
Ke-10	42.329
Ke-11	43.763
Ke-12	44.588
Ke-13	45.453
Ke-14	45.990
Ke-15	46.274
Ke-16	46.344

Hasil tersebut memperlihatkan bahwa model LSTM mampu menangkap pola data yang bervariasi karena nilai prediksi yang dihasilkan tidak cenderung datar (stagnan). Namun, ketika digunakan untuk prediksi jangka yang lebih panjang, model masih memiliki keterbatasan dalam menjaga tingkat akurasi, terutama saat terjadi perubahan harga yang ekstrem. Hal ini disebabkan oleh akumulasi kesalahan (*accumulation of errors*) dari hasil prediksi *autoregressive* periode sebelumnya, sehingga performa model pada *forecasting* jangka panjang menjadi kurang optimal.

Meskipun demikian, model ini tetap memiliki potensi besar untuk dikembangkan lebih lanjut. Pengembangan dapat dilakukan dengan menambahkan variabel eksternal seperti kondisi cuaca, tingkat produksi, jalur distribusi, dan tingkat permintaan pasar, serta mengeksplorasi arsitektur pemodelan yang lebih kompleks. Dengan demikian, diharapkan model yang dihasilkan di masa mendatang mampu meningkatkan akurasi prediksi dan memberikan hasil yang lebih representatif terhadap kondisi riil di lapangan.

3.5. Evaluasi Kinerja Model (RMSE, MAE, MAPE)

Pada tahap ini dilakukan evaluasi terhadap hasil prediksi model menggunakan metrik *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Perhitungan ini dilakukan untuk mengetahui tingkat kesalahan antara nilai prediksi dengan nilai aktual.


Berdasarkan perhitungan, diperoleh nilai RMSE sebesar 16.707,02, nilai MAE sebesar 12.348,54, dan MAPE sebesar 19,31%. Nilai RMSE sebesar 16.707,02 menunjukkan besarnya deviasi prediksi terhadap data aktual dengan memberikan penalti yang lebih besar pada kesalahan yang ekstrem. Nilai MAE sebesar 12.348,54 menunjukkan rata-rata selisih absolut antara hasil prediksi dan data aktual. Sementara itu, nilai MAPE sebesar 19,31% menunjukkan bahwa rata-rata kesalahan relatif model berada pada kisaran kurang dari 20%. Berdasarkan nilai MAPE tersebut, performa model dapat dikatakan cukup baik untuk data harga cabai yang memiliki tingkat volatilitas tinggi. Meskipun demikian, interpretasi kualitas model tidak hanya didasarkan pada nilai MAPE, tetapi juga mempertimbangkan RMSE, MAE, serta karakteristik fluktuasi data harga cabai.

Secara keseluruhan, nilai RMSE, MAE, dan MAPE menunjukkan bahwa model LSTM memiliki performa yang cukup baik dalam memprediksi harga cabai, terutama pada data yang

memiliki pola perubahan naik dan turun. Namun, model masih belum sepenuhnya optimal dalam memprediksi perubahan harga yang sangat tinggi atau terlalu rendah pada periode tertentu.

3.6. Grafik Plot Residual dan Histogram


Residual merupakan selisih antara nilai harga cabai aktual dengan nilai hasil prediksi model. Plot *residual* menunjukkan bahwa sebagian besar *error* berada di sekitar garis nol, namun terdapat beberapa lonjakan *error* yang cukup besar pada titik tertentu. Hal ini mengindikasikan bahwa model masih mengalami kesulitan dalam menangkap perubahan data yang bersifat ekstrem. Hasil plot *residual* disajikan pada Gambar 6.



Gambar 6. Grafik plot (*residual*) hasil prediksi model LSTM.

Plot *residual* memperlihatkan bahwa sebagian besar *residual* tersebar di sekitar garis nol tanpa membentuk pola sistematis yang jelas. Hal tersebut menunjukkan bahwa model telah mampu menangkap sebagian besar pola utama pada data. Namun demikian, masih terdapat beberapa *residual* dengan nilai cukup besar yang muncul pada periode ketika terjadi lonjakan harga secara tiba-tiba. Kondisi ini mengindikasikan bahwa model masih memiliki keterbatasan dalam memprediksi perubahan harga yang ekstrem.

Histogram *residual* pada Gambar 7 menunjukkan bahwa sebagian besar nilai *residual* terkonsentrasi di sekitar nol. Hal ini mengindikasikan bahwa mayoritas hasil prediksi memiliki selisih yang relatif kecil terhadap data aktual. Meskipun demikian, penyebaran *residual* yang masih cukup lebar menunjukkan bahwa pada beberapa periode model menghasilkan kesalahan prediksi yang lebih besar. Kondisi tersebut sejalan dengan hasil plot *residual* yang memperlihatkan adanya beberapa *residual* ekstrem ketika terjadi lonjakan harga. Secara keseluruhan, kedua grafik tersebut menunjukkan bahwa model telah mampu menangkap pola utama data, namun masih memiliki keterbatasan dalam memprediksi perubahan harga yang sangat fluktuatif.



Gambar 7. Histogram *residual* hasil prediksi model LSTM.

3.7. Perbandingan LSTM dan ARIMA

Untuk menunjukkan keunggulan metode LSTM, dilakukan perbandingan dengan metode ARIMA (*Auto-Regressive Integrated Moving Average*) [15]. Metodologi *Autoregressive Integrated Moving Average* (ARIMA), yang dikembangkan secara sistematis oleh Box dan Jenkins (1976), merupakan salah satu kontribusi paling berpengaruh dalam analisis deret waktu. Model ARIMA terdiri dari tiga komponen utama, yaitu *Autoregressive* (AR), *Integrated* (I), dan *Moving Average* (MA) [15]. Komponen AR digunakan untuk melihat pengaruh data masa lalu terhadap data saat ini, komponen I digunakan untuk membuat data menjadi stasioner melalui proses *differencing*, sedangkan komponen MA digunakan untuk melihat pengaruh *error* pada periode sebelumnya. Keunggulan pendekatan ARIMA terletak pada kesederhanaannya dan landasan teoritisnya, menjadikannya titik awal yang wajar untuk analisis deret waktu keuangan [16].

Pada penelitian ini digunakan model ARIMA untuk melakukan prediksi. Identifikasi orde model dilakukan melalui analisis plot ACF dan PACF setelah data dibuat stasioner melalui *differencing* orde satu. Beberapa kandidat model ARIMA diuji, yaitu ARIMA(1,1,0), ARIMA(2,1,0), ARIMA(3,1,0), dan ARIMA(5,1,0). Pemilihan model dilakukan berdasarkan nilai *Akaike Information Criterion* (AIC) pada beberapa kandidat model ARIMA. Nilai *Bayesian Information Criterion* (BIC) juga dilaporkan sebagai informasi tambahan untuk membandingkan kompleksitas model.

Tabel 2. Perbandingan nilai AIC dan BIC pada kandidat model ARIMA.

Order	AIC	BIC
(1,1,0)	3783,41	3789,78
(2,1,0)	3770,12	3779,68
(3,1,0)	3765,12	3777,87
(5,1,0)	3767,76	3786,89

Berdasarkan hasil perbandingan kandidat model pada Tabel 2, ARIMA(3,1,0) menghasilkan nilai AIC terendah sebesar 3765,12 dan BIC terendah sebesar 3777,87. Dengan demikian, ARIMA(3,1,0) dipilih sebagai model ARIMA yang digunakan dalam penelitian.

Tahap selanjutnya dilakukan estimasi parameter dan uji signifikansi terhadap masing-masing *lag* menggunakan nilai *p-value*. Hasil estimasi parameter model ARIMA ditunjukkan pada Tabel 3.

Tabel 3. Hasil estimasi parameter ARIMA.

Parameter	Koefisien	<i>p-value</i>	Keterangan
AR (1)	0,0448	0,455	Tidak signifikan
AR (2)	0,2499	0,000	Signifikan
AR (3)	-0,1740	0,006	Signifikan

Berdasarkan Tabel 3, parameter AR(1) tidak signifikan pada taraf signifikansi 5%, sedangkan parameter AR(2) dan AR(3) signifikan dengan *p-value* masing-masing sebesar 0,000 dan 0,006. Hasil tersebut menunjukkan bahwa *lag* kedua dan ketiga memberikan kontribusi yang signifikan dalam menjelaskan hubungan autoregresif pada data setelah proses *differencing*.

Secara struktural, model ARIMA(3,1,0) memiliki nilai $p = 3$, $d = 1$, dan $q = 0$. Nilai $p = 3$ menunjukkan bahwa model menggunakan tiga *lag* autoregresif, nilai $d = 1$ menunjukkan bahwa data mengalami satu kali *differencing* untuk mencapai kondisi stasioner, sedangkan $q = 0$ menunjukkan bahwa model tidak menggunakan komponen *Moving Average*. Dengan demikian, model ARIMA(3,1,0) memanfaatkan informasi dari tiga periode sebelumnya dalam proses pemodelan setelah data mengalami *differencing* satu kali.

Tabel 4. Error LSTM vs ARIMA.


Model	MAE	RMSE	MAPE
LSTM	12.348,54	16.707,02	19,31%
ARIMA	13.867,26	20.992,15	22,70%

Perbedaan performa kedua model menunjukkan bahwa LSTM lebih efektif dalam memodelkan hubungan temporal nonlinier yang terdapat pada data harga cabai mingguan. Sebaliknya, ARIMA lebih sesuai digunakan pada data yang memenuhi asumsi linearitas dan stasioneritas. Walaupun proses *differencing* telah dilakukan pada model ARIMA, karakteristik harga cabai yang dipengaruhi oleh faktor musiman dan dinamika pasar menyebabkan model statistik tersebut kurang mampu mengikuti perubahan harga yang cepat dibandingkan LSTM.

Berdasarkan hasil evaluasi pada Tabel 4 menggunakan metrik MAE, RMSE, dan MAPE, pendekatan LSTM menunjukkan performa prediksi yang lebih baik dibandingkan ARIMA karena menghasilkan kesalahan prediksi yang lebih kecil terhadap data aktual. Nilai MAE sebesar 12.348,54 menunjukkan bahwa rata-rata selisih prediksi terhadap data aktual pada model LSTM lebih kecil dibandingkan model ARIMA yang memiliki nilai 13.867,26. Selain itu, nilai RMSE model LSTM sebesar 16.707,02 juga lebih rendah dibandingkan ARIMA sebesar 20.992,15. Hasil tersebut menunjukkan bahwa tingkat *error* prediksi pada model LSTM cenderung lebih kecil, sehingga hasil prediksinya lebih mendekati data aktual. Pada nilai MAPE, model LSTM memperoleh persentase sebesar 19,31%, sedangkan model ARIMA sebesar 22,70%. Nilai MAPE model LSTM lebih rendah dibandingkan ARIMA sehingga menunjukkan kesalahan prediksi relatif yang lebih kecil.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa model LSTM lebih baik dalam mengenali pola pergerakan harga cabai, terutama untuk prediksi jangka pendek. Perbedaan hasil ini menunjukkan bahwa masing-masing model memiliki karakteristik berbeda dalam menangkap pola data *time series*, di mana LSTM lebih mampu mengenali pola non-linier dan

perubahan data yang fluktuatif, sedangkan ARIMA lebih fokus pada pola linier berdasarkan data historis sebelumnya.



Gambar 8. Perbandingan hasil prediksi LSTM dan ARIMA terhadap data aktual.

Grafik pada **Gambar 8** memperlihatkan bahwa hasil prediksi LSTM lebih dekat terhadap data aktual dibandingkan model ARIMA. Sebaliknya, prediksi ARIMA cenderung menghasilkan kurva yang lebih halus sehingga kurang responsif terhadap perubahan harga yang terjadi secara tiba-tiba. Temuan ini konsisten dengan nilai RMSE, MAE, dan MAPE yang menunjukkan performa LSTM lebih baik dibandingkan ARIMA.

4. Kesimpulan

Berdasarkan hasil analisis, pemodelan, dan evaluasi empiris yang telah dilakukan, penelitian ini menyimpulkan beberapa hal utama sebagai berikut:

1. Model *Long Short-Term Memory* (LSTM) dengan arsitektur *single layer* (32 unit neuron dan *look-back window 12 timestep*) berhasil dibangun dan diterapkan untuk memprediksi harga cabai merah di Kabupaten Jepara berbasis data runtun waktu mingguan. Mekanisme memori internal (*cell state*) pada LSTM terbukti efektif dalam memodelkan pola temporal jangka pendek maupun jangka panjang dari data historis.
2. Model LSTM menunjukkan performa prediksi yang unggul secara signifikan dibandingkan model statistik linier ARIMA(3,1,0). Pada data pengujian (*testing set*), model LSTM menghasilkan nilai RMSE sebesar 16.707,02, MAE sebesar 12.348,54, dan MAPE sebesar 19,31%. Sebaliknya, model ARIMA menghasilkan nilai RMSE sebesar 20.992,15, MAE sebesar 13.867,26, dan MAPE sebesar 22,70%. Hasil ini membuktikan bahwa pendekatan *deep learning* (LSTM) lebih adaptif dan presisi dalam merespons karakteristik data harga cabai yang bersifat nonlinier serta bervolatilitas tinggi.
3. Hasil *forecasting* selama 16 minggu ke depan (Januari–April 2026) mengindikasikan adanya dinamika fluktuasi harga, diawali dengan tren penurunan hingga mencapai titik terendah pada minggu ke-5 (Rp37.267), kemudian mengalami peningkatan secara bertahap hingga minggu ke-16 (Rp46.344). Hasil proyeksi ini memberikan gambaran tren awal yang dapat dimanfaatkan oleh pemangku kepentingan dalam perencanaan stabilitas pasokan pangan, meskipun terdapat keterbatasan akurasi jangka panjang akibat akumulasi kesalahan (*accumulation of errors*) serta belum diakomodasinya variabel faktor eksternal seperti kondisi iklim dan rantai pasok.

Kontribusi Penulis. Alisa Apriliani: Konseptualisasi, metodologi, perangkat lunak, kurasi data, analisis formal, investigasi, visualisasi, penulisan–penyusunan draf awal, penulisan–peninjauan dan penyuntingan. Ade Ima Afifa Himayati: Penulisan–peninjauan dan penyuntingan. Findasari: Perangkat lunak, analisis formal, visualisasi.

Ucapan Terima Kasih. Penulis mengucapkan terima kasih kepada Universitas Muhammadiyah Kudus atas dukungan akademik selama proses penelitian dan penyusunan manuskrip ini. Penulis juga menyampaikan apresiasi kepada semua pihak yang telah memberikan bantuan, masukan, dan motivasi sehingga penelitian ini dapat diselesaikan dengan baik.

Pembiayaan. Penelitian ini tidak menerima pendanaan eksternal.

Konflik Kepentingan. Para penulis menyatakan bahwa tidak terdapat konflik kepentingan yang berkaitan dengan artikel ini.

Ketersediaan Data. Data yang digunakan dalam penelitian ini berupa data historis harga cabai merah di Kabupaten Jepara periode 2020–2025 yang diperoleh dari situs resmi Sistem Informasi Harga dan Produksi Komoditi Jawa Tengah.

Referensi

- [1] S. D. Silalahi and C. A. P., “The influence of increased prices of satisfactions on economic growth,” *Int. J. Econ. Account. Res.*, vol. 7, no. 1, pp. 1–9, 2023, doi:10.29040/ijebar.v7i1.8406.
- [2] F. Ustadatin, A. Muqtadir, and A. Arifia, “Implementasi metode weighted moving average (wma) pada prediksi harga bahan pokok,” *Komputika J. Sist. Komput.*, vol. 12, no. 2, pp. 203–210, 2023, doi:10.34010/komputika.v12i2.10304.
- [3] R. Wahyuni, S. Wira, A. Utomo, T. B. Muhammad, E. Zhafir, and A. Ghifari, “Artificial neural network prediction model for agricultural commodity production using backpropagation algorithm,” *Int. J. Knowl. Database*, vol. 5, no. 1, pp. 52–68, 2025, doi:10.30983/knownbase.v5i1.9530.
- [4] R. A. Putri *et al.*, “Comparative study of hybrid arima-lstm and cnn-lstm for palm oil price forecasting,” *J. Sains, Mat. dan Terap.*, vol. 10, no. 1, pp. 69–79, 2026, doi:10.30829/zero.v10i1.27631.
- [5] G. Mani and R. Volety, “A comparative analysis of lstm and arima for enhanced real-time air pollutant levels forecasting using sensor fusion with ground station data,” *Cogent Eng.*, vol. 8, no. 1, p. 1936886, 2021, doi:10.1080/23311916.2021.1936886.
- [6] S. Wahyutama, T. Rismawan, and S. Bahri, “Penerapan algoritma long short term memory (lstm) dalam prediksi pergerakan harga cryptocurrency menggunakan data time series,” *Coding: J. Komput. dan Apl.*, vol. 14, no. 1, pp. 128–139, 2026, doi:10.26418/coding.v14i1.98866.
- [7] F. N. Fikri, “Performance evaluation of long short-term memory for chili price prediction,” *JISKA (Jurnal Inform. Sunan Kalijaga)*, vol. 10, no. 1, pp. 33–47, 2025, doi:10.14421/jiska.2025.10.1.33-47.
- [8] N. T. U. G. Gunawan and W. Andriani, “Prediksi harga cabai musiman menggunakan model lstm di jawa tengah,” *J. Inform. Manaj. dan Teknol.*, vol. 27, no. 2, pp. 243–254, 2025, doi:10.23969/infomatek.v27i2.26460.
- [9] A. R. Adam, H. A. Raditiansyah, F. Imani, M. R. Fawwaz, M. F. Julham, and Lubis, “Comparison of arima and lstm models in stock price forecasting: A case study of goto.jk,” *JITE (Journal Informatics Telecommun. Eng.)*, vol. 8, no. 1, pp. 94–105, 2024, doi:10.31289/jite.v8i1.11841.
- [10] C. T. Utari, M. T. Arya, P. Sembiring, M. H. Rizq, and Z. Siregar, “Analisis komparasi algoritma arima dan lstm pada prediksi harga cabai merah keriting harian,” *Building of Informatics, Technology and Science (BITS)*, vol. 7, no. 3, pp. 1932–1942, 2025, doi:10.47065/bits.v7i3.8784.
- [11] A. R. H. Dwika and D. Avianto, “Implementasi algoritma lstm untuk prediksi harga cabai merah keriting di yogyakarta,” *Jurnal Indonesia: Manajemen Informatika dan Komunikasi*, vol. 5, no. 1, pp. 635–648, 2024.
- [12] K. Choudhary, G. K. Jha, R. Jaiswal, and R. R. Kumar, “A genetic algorithm optimized hybrid model for agricultural price forecasting based on vmd and lstm network,” *Scientific Reports*, vol. 15, p. 9932, 2025.
- [13] I. Sembiring, I. Prihandi, S. Wijono, and E. Maria, “A hybrid arima–lstm model optimized with a tree-structured parzen estimator for automatic hyperparameter tuning to forecast indonesia’s chili and climate data,” *Engineering, Technology & Applied Science Research*, vol. 16, no. 3, pp. 35 477–35 490, 2026.

-
- [14] Y. Sunendar and Rianto, "Comparison of arima , lstm , and gru models for forecasting sales of hit aerosol products," *J. Comput. Inf. Syst.*, vol. 21, no. 2, pp. 153–159, 2025, doi:[10.33480/pilar.v21i2.6412](#).
- [15] L. D. Jayanti, R. Lestari, F. Aji, and D. Suparno, "Metode autoregressive integrated moving average (arima) pada aplikasi rstudio," *J. Penelit. Multidisplin*, vol. 3, no. 4, pp. 1275–1289, 2025, doi:[10.60126/maras.v3i4.1253](#).
- [16] N. S. Salimah, A. Satrianto, and U. N. Padang, "Volatility analysis and forecasting of inflation in indonesia. analisis volatilitas dan forecasting inflasi di indonesia." *J. Econ. Bus. Account.*, vol. 8, no. 2, pp. 1252–1262, 2025, doi:[10.31539/costing.v8i2.14947](#).