

Analisis Komparasi Algoritma ARIMA dan LSTM pada Prediksi Harga Cabai Merah Keriting Harian

Cut Try Utari*, M Thariq Arya Putra Sembiring, M Habibi Rizq Zhafar Siregar

Jurusan Komputer dan Informatika, Teknologi Rekayasa Perangkat Lunak, Politeknik Negeri Medan, Medan, Indonesia

Email: ¹*cuttryutari@polmed.ac.id, ²muhammadthariqarya@students.polmed.ac.id, ³m.habibirizq@students.polmed.ac.id

Email Penulis Korespondensi: cuttryutari@polmed.ac.id

Submitted: 24/11/2025; Accepted: 26/12/2025; Published: 26/12/2025

Abstrak—Cabai merah keriting merupakan komoditas strategis nasional yang memiliki karakteristik fluktuasi harga ekstrem, sehingga berdampak signifikan terhadap inflasi daerah dan kesejahteraan petani. Meskipun metode statistik konvensional sering digunakan untuk peramalan, pendekatan tersebut memiliki keterbatasan dalam menangkap volatilitas non-linear dan pola harga yang dinamis. Penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan mengkomparasi kinerja model statistik AutoRegressive Integrated Moving Average (ARIMA) dan model Deep Learning Long Short-Term Memory (LSTM). Studi ini menggunakan pendekatan prediksi univariat berbasis data harga harian historis dari Januari 2024 hingga Oktober 2025. Data dibagi dengan skema 80% untuk pelatihan dan 20% untuk pengujian. Evaluasi kinerja model diukur menggunakan metrik Root Mean Squared Error (RMSE), Mean Absolute Percentage Error (MAPE), dan Koefisien Determinasi (R^2). Hasil eksperimen menunjukkan bahwa model LSTM secara signifikan mengungguli ARIMA dalam mengikuti tren harga harian. LSTM mencatat rata-rata MAPE sebesar 13,76% (kategori "Baik") dengan nilai mencapai 0,92, jauh lebih akurat dibandingkan ARIMA yang menghasilkan MAPE sebesar 41,21% dan nilai negatif. Penelitian ini menyimpulkan bahwa algoritma berbasis Deep Learning lebih efektif dalam menangani volatilitas harga komoditas pangan dibandingkan metode statistik linear klasik.

Kata Kunci: Prediksi Harga; Cabai Merah Keriting; Time Series; LSTM; ARIMA; Deep Learning

Abstract—Curly red chili is a strategic national commodity characterized by extreme price fluctuations, which significantly impact regional inflation and farmer welfare. Although conventional statistical methods are frequently used for forecasting, these approaches have inherent limitations in capturing non-linear volatility and dynamic price patterns. This research aims to address this gap by comprehensively comparing the performance of the AutoRegressive Integrated Moving Average (ARIMA) statistical model and the Long Short-Term Memory (LSTM) Deep Learning model. This study utilizes a univariate prediction approach based on daily historical price data from January 2024 to October 2025. The dataset is partitioned into 80% for training and 20% for testing purposes. Model performance is rigorously evaluated using Root Mean Squared Error (RMSE), Mean Absolute Percentage Error (MAPE), and Coefficient of Determination (R^2). The experimental results demonstrate that the LSTM model significantly outperforms ARIMA in tracking daily price trends. LSTM achieved an average MAPE of 13.76% (classified as "Good") with an value of 0.92, whereas the ARIMA model recorded a significantly higher MAPE of 41.21% and a negative value. This study concludes that Deep Learning-based algorithms are superior and more effective in handling food commodity price volatility compared to classical linear statistical methods.

Keywords: Price Forecasting; Curly Red Chili; Time Series; LSTM; ARIMA; Deep Learning

1. PENDAHULUAN

Cabai merah keriting (*Capsicum annum*) memegang peranan yang sangat vital dan strategis dalam struktur ekonomi serta kehidupan sosial masyarakat Indonesia. Sebagai salah satu komoditas hortikultura utama, cabai merah tidak hanya berfungsi sebagai bahan dasar kuliner yang tak tergantikan bagi mayoritas penduduk, tetapi juga memiliki dampak makroekonomi yang luas. Komoditas ini sering dikategorikan sebagai komponen harga pangan bergejolak (*volatile food*) yang memiliki kontribusi signifikan terhadap instabilitas inflasi daerah, terutama di wilayah Sumatera Utara dan Kota Medan. Tingginya permintaan yang bersifat inelastis juga menjadi faktor krusial dalam pembentukan harga. Sifat inelastis ini terlihat dari perilaku konsumen yang cenderung tetap membeli produk tersebut meskipun harga mengalami kenaikan yang cukup tinggi. Hal ini menjadikan komoditas cabai sangat sensitif terhadap guncangan pasar sekecil apapun.

Permasalahan utama yang dihadapi dalam tata niaga cabai merah adalah volatilitas harga yang ekstrem dan sulit diprediksi. Di Kota Medan, fluktuasi harga ini sering kali terjadi secara mendadak karena dipengaruhi oleh berbagai faktor yang kompleks. Faktor-faktor tersebut meliputi kondisi cuaca yang tidak menentu atau anomali iklim, gangguan pada rantai pasok distribusi dari sentra produksi di pegunungan menuju pasar kota, serta adanya lonjakan permintaan musiman. Kenaikan permintaan ini biasanya terjadi secara siklikal pada hari-hari besar keagamaan seperti Idul Fitri, Natal, dan Tahun Baru. Ketidakpastian harga ini pada akhirnya menciptakan risiko ekonomi yang merugikan berbagai pihak. Bagi petani, ketidakpastian ini sering kali berujung pada kerugian finansial saat panen raya ketika harga anjlok di bawah biaya produksi. Sebaliknya, bagi konsumen rumah tangga dan pelaku usaha kuliner, lonjakan harga yang tiba-tiba dapat menggerus daya beli dan meningkatkan biaya operasional secara signifikan. Oleh karena itu, urgensi untuk membangun sebuah sistem prediksi harga yang akurat menjadi kebutuhan yang mendesak. Kemampuan memprediksi harga di masa depan akan mendukung pengambilan keputusan yang lebih strategis, baik bagi petani dalam merencanakan masa tanam, pedagang dalam manajemen stok, maupun pemerintah daerah dalam melakukan intervensi pasar untuk menjaga stabilitas inflasi.

Dalam upaya mengatasi masalah ketidakpastian ini, prediksi deret waktu (*time series forecasting*) telah menjadi pendekatan standar yang diadopsi secara luas. Secara tradisional, metode statistik seperti *Auto-Regressive*

Integrated Moving Average (ARIMA) yang diperkenalkan oleh Box dan Jenkins [1] telah menjadi andalan para peneliti dan praktisi ekonomi karena dasar matematisnya yang kuat. Metode ini juga dikenal efektif dalam menangani data linear. Hyndman dan Athanasopoulos dalam penelitian yang telah dilakukan [2] menekankan bahwa ARIMA sangat efektif untuk data yang memiliki pola stasioner atau tren yang jelas. Namun, karakteristik data harga komoditas pertanian, khususnya cabai merah, sering kali tidak mengikuti asumsi linearitas tersebut. Data harga pasar harian di Medan menunjukkan tingkat volatilitas yang tinggi, adanya *noise* atau derau yang acak, serta pola musiman tidak teratur yang sangat sulit ditangkap oleh model linear kaku seperti ARIMA. Keterbatasan metode statistik klasik ini mendorong pergeseran paradigma penelitian menuju pendekatan kecerdasan buatan, khususnya *Machine Learning* dan *Deep Learning*. Pendekatan ini dinilai memiliki fleksibilitas lebih tinggi dalam memodelkan hubungan non-linear yang kompleks.

Dalam satu dekade terakhir, *Long Short-Term Memory* (LSTM) yang merupakan varian canggih dari *Recurrent Neural Network* (RNN) telah muncul sebagai metode mutakhir untuk peramalan deret waktu yang kompleks. Keunggulan utama LSTM terletak pada arsitekturnya yang dirancang khusus untuk mengatasi masalah *vanishing gradient* yang sering ditemui pada RNN standar, memungkinkannya untuk mempelajari ketergantungan jangka panjang (*long-term dependencies*) dalam data historis [3]. Mekanisme *gating* atau gerbang pada LSTM memungkinkan model untuk memilih informasi mana yang harus disimpan dan mana yang harus dilupakan dari memori masa lalu. Fitur ini menjadikannya sangat ideal untuk data harga yang memiliki pola historis panjang. Implementasi praktis *deep learning* ini telah dibahas secara mendalam oleh Sherstinsky [4] yang menyoroti efektivitasnya dalam menangani data sekuensial dibanding metode konvensional.

Berbagai penelitian terdahulu telah mencoba menerapkan metode ini dengan hasil yang bervariasi. Zhang, Q. et al. [5] menerapkan LSTM untuk prediksi harga sayuran di Beijing dan menemukan bahwa metode ini secara konsisten mengungguli *Support Vector Regression* (SVR). Di konteks Indonesia, Nafi'iyah dan Wulandari [6] menggunakan LSTM untuk prediksi harga beras berdasarkan kualitas serta membuktikan adaptabilitas model terhadap komoditas lokal. Penelitian lain oleh Chandan [7] memperluas cakupan ini ke komoditas katun, sementara Manogna [8] mengusulkan model hibrida untuk meningkatkan akurasi prediksi tanaman. Gupta [9] secara spesifik menyoroti kemampuan *deep learning* dalam memodelkan data pertanian yang penuh ketidakpastian. Selain itu, Chen [10] menunjukkan superioritas LSTM dalam menangkap volatilitas pasar keuangan yang memiliki karakteristik fluktuasi serupa dengan pasar komoditas. Studi komparatif oleh Wu [11] dan Yuan [12] juga mempertegas bahwa dibandingkan dengan metode statistik atau *machine learning* dangkal, LSTM menawarkan stabilitas prediksi jangka panjang yang lebih baik pada data komoditas.

Eksplorasi terhadap optimalisasi model terus dilakukan oleh para peneliti. Iqbal [13] melakukan studi untuk meningkatkan kinerja model harga listrik menggunakan *Deep Learning*, yang membuktikan bahwa arsitektur jaringan syaraf tiruan dapat dikalibrasi untuk berbagai jenis data *time series*. Pengembangan lebih lanjut dilakukan oleh Gu [14] yang memperkenalkan model *Dual Input Attention LSTM*, menambah variasi teknik dalam domain ini. Penelitian terbaru pada tahun 2024 dan 2025 semakin memperkaya literatur prediksi harga lokal di Indonesia. Witanti dan Arie [15] secara spesifik membandingkan LSTM dengan *Attention Mechanism* untuk harga cabai di Bali, sementara Lim dan Handhayani [16] meneliti harga cabai merah di Jawa Timur menggunakan GRU dan LSTM. Kedua studi tersebut menegaskan bahwa karakteristik lokal sangat mempengaruhi performa model. Di sektor lain, Joddy [17] melakukan analisis komparatif untuk prediksi saham di Indonesia, dan Kaur [18] menerapkan teknik serupa untuk komoditas di India. Metode yang lebih kompleks seperti *Graph Neural Networks* (GNN) juga mulai dieksplorasi oleh Min [19] untuk memuluskan fluktuasi jangka pendek. Terakhir, studi komparatif oleh Xia [20] kembali menegaskan bahwa untuk kasus sayuran dan produk pertanian, LSTM masih menjadi pilihan yang lebih unggul dibandingkan ARIMA karena kemampuannya menangani data non-linear.


Meskipun literatur mengenai prediksi harga komoditas sudah cukup kaya, terdapat kesenjangan penelitian (*Gap Analysis*) yang signifikan. Mayoritas penelitian terdahulu [12] - [20] cenderung menggunakan data harga agregat tingkat nasional atau menggunakan model yang sangat kompleks yang sulit diterapkan di lapangan. Belum banyak studi yang membandingkan kinerja model secara granular menggunakan data harian dari pasar tradisional spesifik, seperti Pasar Sukaramai atau Pasar Petisah di Kota Medan. Padahal, karakteristik mikro-pasar lokal sangat mempengaruhi pembentukan harga riil yang dirasakan masyarakat. Selain itu, validasi ulang antara metode statistik klasik (ARIMA) dan *deep learning* (LSTM) pada dataset terbaru 2024-2025 di wilayah ini masih jarang didokumentasikan.

Penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan mengembangkan dan mengevaluasi kinerja dua pendekatan yang berbeda secara fundamental. Namun, perlu ditekankan bahwa penelitian ini membatasi ruang lingkup pada pendekatan peramalan univariat. Variabel eksternal (eksogen) seperti curah hujan, data pasokan, maupun penanda hari libur nasional dan hari raya keagamaan tidak dimasukkan ke dalam perhitungan model. Fokus utama diletakkan pada kemampuan algoritma dalam mempelajari pola volatilitas semata-mata berdasarkan data historis harga. Secara spesifik, tujuan utama dari penelitian ini mencakup tiga hal. Pertama, membangun model prediksi harga harian yang akurat untuk komoditas cabai merah keriting di Kota Medan berbasis data historis. Kedua, melakukan analisis komparasi kinerja antara model ARIMA dan LSTM untuk menentukan metode mana yang paling tangguh. Ketiga, mengevaluasi akurasi model menggunakan metrik standar industri, yaitu *Root Mean Squared Error* (RMSE) untuk mengukur besarnya kesalahan dan *Mean Absolute Percentage Error* (MAPE) untuk mengukur persentase penyimpangan prediksi.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilakukan melalui serangkaian tahapan sistematis untuk memastikan validitas dan reliabilitas hasil prediksi. Kerangka kerja penelitian dimulai dari identifikasi masalah, pengumpulan data sekunder, pra-pemrosesan data (*data preprocessing*), pembagian data, pembangunan model (ARIMA dan LSTM), hingga tahap evaluasi dan analisis komparatif. Alur kerja ini dirancang untuk membandingkan performa model statistik klasik dan model *deep learning* secara adil (*apple-to-apple*). Diagram alir penelitian secara lengkap disajikan pada Gambar 1.



Gambar 1. Tahapan Penelitian Paper Karya Ilmiah

2.2 Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data sekunder berupa runtun waktu (*time series*) harian harga komoditas cabai merah keriting. Sumber data diperoleh dari portal publikasi resmi Pusat Informasi Harga Pangan Strategis (PIHPS) Nasional yang dikelola oleh Bank Indonesia. Dataset mencakup periode observasi harian mulai dari 1 Januari 2024 hingga 24 Oktober 2025, dengan total 471 titik data observasi.

Penelitian ini mengambil lokasi studi kasus di Kota Medan, Sumatera Utara. Untuk mendapatkan gambaran harga yang representatif, data diambil dari rata-rata harga di lima pasar tradisional utama yang menjadi sentra distribusi dan konsumsi masyarakat, yaitu Pasar Sukaramai, Pasar Aksara, Pasar Petisah, Pusat Pasar, dan Pasar Brayan. Pemilihan kelima pasar ini didasarkan pada volume transaksi yang tinggi dan peranannya sebagai barometer harga pangan di wilayah tersebut.

2.3 Praprocessing Data

Tahap pra-pemrosesan merupakan langkah krusial untuk memastikan kualitas data sebelum dimasukkan ke dalam model komputasi. Tahapan ini terdiri dari tiga langkah utama:

2.3.1 Pembersihan Data

Data mentah diperiksa untuk mendeteksi adanya nilai yang hilang (*missing values*) atau anomali pencatatan. Mengingat data pasar sering kali libur pada hari-hari tertentu, teknik interpolasi linear diterapkan untuk mengisi kekosongan data tersebut agar kontinuitas *time series* tetap terjaga tanpa mengubah struktur data secara signifikan. Contoh hasil dari proses pembersihan data ini disajikan dalam Tabel 1 berikut, yang memperlihatkan data harga yang telah lengkap dan siap untuk dianalisis:

Tabel 1. Data Setelah Dibersihkan

Date	Pasar Aksara	Pasar Brayan	Pasar Petisah	Pasar Sukaramai	Pusat Pasar
2024-01-01	30000.0	26500.0	30000.0	30000.0	27500.0
2024-01-02	35000.0	32500.0	35000.0	38000.0	30000.0
2024-01-03	35000.0	32500.0	35000.0	38000.0	30000.0
2024-01-04	30000.0	30000.0	30000.0	38000.0	30000.0
2024-01-05	30000.0	30000.0	30000.0	30000.0	24500.0

2.3.2 Uji Stationeritas

Untuk kebutuhan pemodelan ARIMA, data dipersyaratkan harus stasioner, yaitu memiliki rata-rata dan varians yang konstan sepanjang waktu. Uji *Augmented Dickey-Fuller* (ADF) dilakukan untuk memverifikasi asumsi ini. Apabila

data ditemukan tidak stasioner (nilai p -value > 0.05), maka dilakukan proses diferensiasi (*differencing*) tingkat pertama atau kedua hingga data menjadi stasioner dan siap dimodelkan.

2.3.3 Normalisasi Data

Berbeda dengan ARIMA, model LSTM sangat sensitif terhadap skala data input. Oleh karena itu, seluruh data harga dinormalisasi menggunakan teknik *MinMax Scaler* untuk mengubah rentang nilai asli (Rupiah) ke dalam rentang skala [0, 1]. Langkah ini bertujuan untuk mempercepat konvergensi model saat proses pelatihan (*training*) dan mencegah bias akibat nilai nominal harga yang besar. Proses transformasi data dilakukan dengan menerapkan persamaan matematis berikut:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Dimana X adalah data asli, X_{min} adalah nilai terendah, dan X_{max} adalah nilai tertinggi dalam dataset. Implementasi persamaan (1) terhadap dataset penelitian disajikan pada Tabel 2 dan Tabel 3. Tabel 2 merepresentasikan sampel data latih (training set) yang telah dinormalisasi. Pada tabel tersebut, nilai harga nominal puluhan ribu Rupiah telah dikonversi menjadi koefisien skalar. Sebagai ilustrasi, nilai 0.169 pada Pasar Aksara (1 Januari 2024) mengindikasikan bahwa harga pada tanggal tersebut berada di kuartil bawah rentang distribusi harga historis. Nilai ini memberikan sinyal kepada model mengenai posisi relatif harga terhadap volatilitas maksimum yang pernah terjadi.

Tabel 2. Tabel Data Train Normalisasi

Date	Pasar Aksara	Pasar Brayan	Pasar Petisah	Pasar Sukaramai	Pusat Pasar
2024-01-01	0.16901408450 704225	0.1428571428571 4285	0.14814814814 81482	0.1472868217054 2634	0.0928571428 5714286
2024-01-02	0.28169014084 50705	0.2142857142857 143	0.2222222222222 22222	0.1860465116279 0697	0.1785714285 714286
2024-01-03	0.28169014084 50705	0.2142857142857 143	0.2222222222222 22222	0.1860465116279 0697	0.1785714285 714286
2024-01-04	0.28169014084 50705	0.1428571428571 4285	0.14814814814 81482	0.1860465116279 0697	0.1428571428 5714285
2024-01-05	0.16901408450 704225	0.1428571428571 4285	0.14814814814 81482	0.1007751937984 4962	0.1428571428 5714285

Selanjutnya, Tabel 3, menunjukkan hasil normalisasi pada data uji (testing set). Fenomena menarik terlihat pada kolom Pasar Brayan dan Pasar Petisah tanggal 16-17 Juni 2025, di mana tercatat nilai 0.000. Secara matematis, nilai nol ini merepresentasikan bahwa harga aktual (X) pada hari tersebut setara dengan nilai minimum (X_{min}) dalam sejarah observasi data. Hal ini menandakan bahwa pada periode tersebut, harga cabai sedang menyentuh titik terendah (dasar harga). Transformasi ini krusial karena memungkinkan model LSTM untuk mempelajari pola "harga terendah" dan "harga tertinggi" (dimana nilai mendekati 1.0) sebagai fitur batas (boundary features) dalam memprediksi pergerakan harga di masa depan.

Tabel 3. Data Test Normalisasi

Date	Pasar Aksara	Pasar Brayan	Pasar Petisah	Pasar Sukaramai	Pusat Pasar
2025-06-16	0.05633802816 901412	0.0	0.0	0.0310077519379 84496	0.0571428571 4285716
2025-06-17	0.05633802816 901412	0.0	0.0	0.0310077519379 84496	0.0571428571 4285716
2025-06-18	0.05633802816 901412	0.0285714285714 2858	0.01481481481 4814836	0.0620155038759 6899	0.0571428571 4285716
2025-06-19	0.05633802816 901412	0.0285714285714 2858	0.01481481481 4814836	0.0620155038759 6899	0.0571428571 4285716
2025-06-20	0.05633802816 901412	0.0285714285714 2858	0.01481481481 4814836	0.0620155038759 6899	0.0571428571 4285716

2.3.4 Pembagian Data

Dataset dibagi menjadi dua bagian dengan skema pembagian kronologis (bukan acak) untuk menjaga korelasi waktu. Sebanyak 80% data awal (Januari 2024 – pertengahan 2025) digunakan sebagai data latih (*training set*) untuk membangun model, sedangkan 20% data sisanya (pertengahan 2025 – Oktober 2025) dialokasikan sebagai data uji (*testing set*) untuk mengevaluasi performa prediksi model pada data yang belum pernah dilihat sebelumnya (*unseen data*) Implementasi pembagian data tersebut direpresentasikan dalam Tabel 4 dan Tabel 5 berikut:

Tabel 4. Data untuk Data Latih

Date	Pasar Aksara	Pasar Brayan	Pasar Petisah	Pasar Sukaramai	Pusat Pasar
2024-01-01	30000.0	26500.0	30000.0	30000.0	27500.0
2024-01-02	35000.0	32500.0	35000.0	38000.0	30000.0
2024-01-03	35000.0	32500.0	35000.0	38000.0	30000.0
2024-01-04	30000.0	30000.0	30000.0	38000.0	30000.0
2024-01-05	30000.0	30000.0	30000.0	30000.0	24500.0

Tabel 5. Data Tabel untuk Data Uji

Date	Pasar Aksara	Pasar Brayan	Pasar Petisah	Pasar Sukaramai	Pusat Pasar
2025-06-16	20000.0	24000.0	20000.0	22000.0	20000.0
2025-06-17	20000.0	24000.0	20000.0	22000.0	20000.0
2025-06-18	22000.0	24000.0	21000.0	22000.0	22000.0
2025-06-19	22000.0	24000.0	21000.0	22000.0	22000.0
2025-06-20	22000.0	24000.0	21000.0	22000.0	22000.0

2.4 Metodologi Pemodelan

Penelitian ini menerapkan dua jenis model yang berbeda secara fundamental untuk membandingkan kinerjanya.

2.4.1 Model 1: Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA dikembangkan berdasarkan metodologi Box-Jenkins yang menggabungkan tiga komponen utama: *Autoregressive* (AR) yang melihat hubungan antara nilai saat ini dengan nilai masa lalu, *Integrated* (I) yang menangani non-stasioneritas melalui diferensiasi, dan *Moving Average* (MA) yang memodelkan kesalahan prediksi masa lalu [1]. Penentuan parameter optimal (p, d, q) dilakukan menggunakan algoritma *auto_arima* yang secara otomatis mencari kombinasi parameter dengan nilai *Akaike Information Criterion* (AIC) terendah guna menghindari *overfitting*. Secara matematis, formulasi umum model ARIMA dapat dinyatakan sebagai berikut:

$$\varphi(B)X_t = \phi(B)(1 - B)^d X_t = \theta_0 + \theta(B)a_t \quad (2)$$

dengan operator-operator berikut:

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p,$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q.$$

Dalam model tanpa konstanta ($\theta_0 = 0$), bentuk ARIMA disederhanakan menjadi:

$$\varphi(B)X_t = \phi(B)(1 - B)^d X_t = \theta(B)a_t \quad (3)$$

Dimana B mempresentasikan operator lag ($B^k X_t = X_{t-k}$), sementara ϕ_i adalah parameter bagian AR dan θ_j adalah parameter bagian MA. Variabel d menunjukkan orde diferensiasi yang dilakukan untuk mencapai stasioneritas, dan adalah istilah *white noise* atau galat acak. Penentuan parameter optimal dilakukan menggunakan algoritma *auto_arima* berdasarkan nilai *Akaike Information Criterion* (AIC) terendah.

2.3.2 Model 2: Long Short Term Memory (LSTM)

Model LSTM dibangun menggunakan kerangka kerja *Deep Learning* dengan arsitektur *Sequential*. Berbeda dengan RNN biasa, LSTM memiliki blok memori yang terdiri dari *Forget Gate*, *Input Gate*, dan *Output Gate* yang memungkinkannya mempelajari pola jangka panjang. Berdasarkan literatur [5], proses matematis pada unit LSTM adalah sebagai berikut:

- a. Forget Gate (f_t): Memutuskan informasi mana yang akan dibuang dari cell state.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$

- b. Input Gate (i_t) & Kandidat Cell ($\tilde{C}_t$): Menentukan informasi baru yang akan disimpan.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (6)$$

- c. Update Cell State (C_t): Menggabungkan informasi lama dan baru.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (7)$$

- d. Output Gate (o_t) dan Hidden State (h_t): Menentukan keluaran berdasarkan cell state yang telah diperbarui.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (8)$$

$$h_t = o_t * \tanh(C_t) \quad (9)$$

Dalam penelitian ini, arsitektur jaringan dirancang dengan konfigurasi yang mendalam. Lapisan input pertama berupa lapisan LSTM dengan 50 unit neuron yang mengaktifkan fitur *return_sequences=True*, yang berfungsi untuk meneruskan urutan informasi ke lapisan berikutnya tanpa memutuskan rantai waktu. Untuk mencegah terjadinya *overfitting* dimana model menghafal data latih, ditambahkan lapisan *Dropout* dengan rasio 0.2 setelah lapisan LSTM pertama. Selanjutnya, data diproses oleh lapisan LSTM kedua yang juga memiliki 50 unit neuron namun dengan *return_sequences=False*, menandakan akhir dari pemrosesan sekuensial. Hasil dari lapisan ini diteruskan ke lapisan *Dropout* kedua sebesar 0.2. Tahap akhir arsitektur adalah lapisan *Dense* (Fully Connected) dengan 25 neuron, sebelum akhirnya bermuara pada lapisan *Output* dengan 1 neuron yang merepresentasikan nilai prediksi harga cabai.

Parameter pelatihan (*hyperparameters*) yang krusial dalam model ini adalah Time Step (Window Size). Penelitian ini menetapkan nilai *Window Size* sebesar 14 hari, yang berarti model menggunakan data harga historis selama dua minggu terakhir untuk memprediksi harga satu hari ke depan. Model dilatih menggunakan *optimizer* Adam dengan *learning rate* adaptif dan fungsi kerugian (*loss function*) *Mean Squared Error* (MSE) selama 50 *epoch* dengan ukuran *batch* 32.

2.4 Pengujian dan Evaluasi Model

Kinerja kedua model dievaluasi dengan membandingkan hasil prediksi (F_t) terhadap data aktual (A_t) pada periode data uji. Empat indikator statistik utama digunakan sebagai tolok ukur akurasi, di mana rincian persamaan matematis untuk setiap indikator disajikan pada Tabel 6. Pertama, Root Mean Squared Error (RMSE) digunakan untuk mengukur standar deviasi dari residu prediksi, di mana nilai yang lebih kecil mengindikasikan model yang lebih presisi dalam satuan harga (Rupiah). Kedua, Mean Absolute Error (MAE) dihitung untuk mengetahui rata-rata selisih absolut antara nilai prediksi dan nilai sebenarnya tanpa memperhatikan arah kesalahan. Ketiga, Mean Absolute Percentage Error (MAPE) digunakan untuk mengukur rata-rata kesalahan absolut dalam bentuk persentase, yang memudahkan interpretasi akurasi relatif model; nilai MAPE di bawah 10% dikategorikan sebagai kemampuan prediksi yang sangat akurat 3,4. Terakhir, Koefisien Determinasi (R^2) digunakan untuk mengukur seberapa baik variabel independen menjelaskan variabilitas harga. Model dengan kombinasi nilai galat terendah dan akurasi tertinggi pada data uji akan dipilih sebagai model terbaik.

Tabel 6. Metrik Evaluasi Model ARIMA dan LSTM

Metrik Evaluasi Model	Metrik	Rumus
Root Mean Squared Error	RMSE	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$
Mean Absolute Error	MAE	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $
Mean Absolute Percentage Error	MAPE	$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left \frac{y_i - \hat{y}_i}{y_i} \right $
Coefficient of Determination	R^2	$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$


3 HASIL DAN PEMBAHASAN

3.1 Karakteristik Data dan Analisis Statistik Deskriptif

Sebelum melakukan pemodelan prediktif, analisis eksploratif mendalam dilakukan terhadap dataset harga cabai merah keriting di lima pasar utama Kota Medan. Berdasarkan visualisasi data runtun waktu (*time series*) yang disajikan pada Gambar 2, terlihat jelas bahwa pergerakan harga komoditas ini memiliki volatilitas yang sangat tinggi dengan pola fluktuasi yang ekstrem. Terdapat periode-periode tertentu di mana harga relatif stabil di kisaran rendah, namun diikuti oleh lonjakan harga (*price spikes*) yang tajam dan mendadak. Fenomena ini mengindikasikan adanya guncangan (*shocks*) pada sisi penawaran atau permintaan yang tidak terduga, yang merupakan karakteristik umum dari komoditas pertanian yang sensitif terhadap iklim (*climate-sensitive crops*).

Analisis visual pada Gambar 2 juga memperlihatkan tingkat sinkronisasi harga yang sangat kuat antar pasar (Pasar Sukaramai, Aksara, Petisah, Pusat Pasar, dan Brayan). Garis tren harga di kelima pasar tersebut bergerak beriringan dengan korelasi positif yang sangat tinggi. Ketika harga naik di Pasar Induk, harga di pasar-pasar satelit lainnya merespons secara simultan dengan jeda waktu yang hampir tidak terlihat. Hal ini menunjukkan bahwa pasar cabai merah di Kota Medan terintegrasi dengan sangat baik (*market integration*). Perbedaan harga antar pasar hanya terjadi pada level absolut (nominal Rupiah) yang kemungkinan disebabkan oleh perbedaan biaya transportasi, sewa lapak, dan segmen konsumen yang dilayani, namun arah pergerakan trennya identik. Temuan ini memvalidasi

keputusan metodologis dalam penelitian ini untuk menerapkan arsitektur model yang sama bagi setiap pasar, karena pola dasar (*underlying pattern*) data yang dipelajari relatif seragam di seluruh lokasi studi.



Gambar 2. Tren Harga Cabai Merah di Berbagai Pasar Kota Medan

3.2 Evaluasi Model ARIMA


Penerapan model *Autoregressive Integrated Moving Average* (ARIMA) pada data uji memberikan hasil yang kurang memuaskan dan cenderung gagal menangkap dinamika pasar yang sebenarnya. Tabel 7 merangkum metrik evaluasi kinerja model ARIMA untuk kelima pasar dan rata-rata Kota Medan. Berdasarkan hasil pengujian, model ARIMA mencatat nilai *Mean Absolute Percentage Error* (MAPE) yang sangat tinggi, berkisar antara 34,09% di Pasar Sukaramai hingga 45,72% di Pasar Aksara. Untuk agregat Kota Medan, MAPE tercatat sebesar 41,85%. Mengacu pada standar interpretasi MAPE, nilai kesalahan di atas 20% dikategorikan sebagai peramalan yang "Buruk" (*Poor Forecasting*). Hal ini berarti rata-rata prediksi ARIMA melenceng hampir setengah dari harga aslinya, yang tentu saja tidak layak digunakan sebagai dasar pengambilan keputusan strategis bagi petani maupun pemerintah.

Indikator kegagalan model ARIMA semakin dipertegas oleh nilai Koefisien Determinasi (R^2) yang negatif di hampir seluruh pasar yang diuji. Nilai R^2 untuk Kota Medan adalah -1,13, Pasar Aksara -1,31, dan Pusat Pasar -1,05. Secara statistik, nilai R^2 negatif mengindikasikan bahwa model prediksi yang dibangun bekerja lebih buruk daripada sekadar menggunakan garis rata-rata sederhana (*simple horizontal mean line*) dari data historis. Dengan kata lain, model ARIMA gagal total dalam menjelaskan variabilitas data pada periode pengujian.

Tabel 7. Hasil Evaluasi Model ARIMA

Pasar	RMSE	MAE	MAPE (%)	R^2
Kota Medan	35.558,59	26.324,21	41,85	-1,13
Pasar Aksara	36.438,34	27.557,89	45,72	-1,31
Pasar Brayan	35.374,66	26.130,58	39,93	-1,13
Pasar Petisah	34.299,46	24.894,74	39,54	-0,92
Pasar Sukaramai	26.576,03	19.609,20	34,09	-0,17
Pusat Pasar	35.079,29	25.629,18	40,61	-1,05

Penyebab buruknya kinerja ARIMA dapat dilihat secara jelas melalui analisis visual pada Gambar 3. Grafik tersebut membandingkan data aktual (garis oranye) dengan prediksi ARIMA (garis merah) pada data uji. Terlihat bahwa garis prediksi ARIMA cenderung mendatar (*flatline*) dan konvergen menuju nilai rata-rata jangka panjang (sekitar Rp 22.000). Padahal, pada periode pengujian (Juni - Oktober 2025), harga aktual mengalami lonjakan ekstrem hingga menyentuh angka Rp 90.000. Ketidakmampuan ARIMA mengikuti tren kenaikan ini disebabkan oleh sifat dasar algoritma tersebut yang linear dan sangat bergantung pada asumsi stasioneritas. ARIMA bekerja dengan memproyeksikan pola masa lalu secara linear ke masa depan. Ketika terjadi perubahan struktural atau volatilitas non-linear yang drastis—seperti lonjakan harga akibat gagal panen atau hari besar keagamaan—ARIMA menganggapnya sebagai outlier atau noise yang akan kembali ke titik keseimbangan (*reversi rata-rata*), sehingga gagal memprediksi tren kenaikan yang berkelanjutan. Temuan ini sejalan dengan keterbatasan ARIMA yang sering dikutip dalam literatur ekonometrika untuk data bergejolak.



Gambar 3. Grafik Prediksi ARIMA vs Data Aktual (Kota Medan)

3.3 Hasil Pengujian Model LSTM

Berbanding terbalik dengan ARIMA, model *Long Short-Term Memory* (LSTM) menunjukkan kinerja yang sangat superior dan konsisten di seluruh pasar yang diteliti. Tabel 8 menyajikan rekapitulasi metrik evaluasi untuk model LSTM. Secara keseluruhan, model ini mampu menekan tingkat kesalahan secara signifikan. Nilai MAPE rata-rata untuk Kota Medan tercatat sangat rendah, yaitu hanya 7,29%. Angka ini masuk dalam kategori "Sangat Baik" (*Excellent Forecasting*) karena berada jauh di bawah ambang batas 10%. Konsistensi akurasi juga terlihat di tingkat pasar individual, dengan rentang MAPE terbaik di Pasar Brayan (7,37%) dan tertinggi di Pusat Pasar (10,10%), namun semuanya masih dalam kategori yang sangat dapat diterima untuk standar prediksi harga komoditas pertanian.

Keunggulan model LSTM juga tercermin dari nilai R^2 yang sangat tinggi, mencapai 0,92 untuk Kota Medan, 0,93 untuk Pasar Brayan dan Pasar Petisah, serta rata-rata di atas 0,90 untuk pasar lainnya. Nilai ini bermakna bahwa model LSTM mampu menjelaskan lebih dari 90% variabilitas atau pergerakan harga yang terjadi selama periode pengujian. Tingginya nilai R^2 ini menegaskan bahwa variabel input berupa data historis 14 hari terakhir (*Window Size*) mengandung informasi yang cukup bagi jaringan syaraf tiruan untuk merekonstruksi pola harga masa depan dengan presisi tinggi.


Tabel 8. Hasil Evaluasi Model LSTM

Pasar	RMSE	MAE	MAPE (%)	R^2
Kota Medan	6.913,66	4.210,62	7,29	0,92
Pasar Aksara	7.319,29	4.696,56	8,68	0,91
Pasar Brayan	6.449,83	4.058,96	7,37	0,93
Pasar Petisah	6.641,60	4.413,19	8,46	0,93
Pasar Sukaramai	7.330,69	4.587,98	8,26	0,91
Pusat Pasar	8.919,55	5.806,13	10,10	0,87

Analisis lebih granular terhadap kinerja LSTM di tingkat pasar individual mengungkapkan fenomena menarik terkait karakteristik mikro-pasar. Berdasarkan Tabel 8, terlihat bahwa Pasar Brayan mencatatkan akurasi terbaik dengan MAPE terendah sebesar 7,37%, sedangkan Pusat Pasar memiliki tingkat kesalahan tertinggi yaitu 10,10%. Disparitas kinerja ini kemungkinan besar berkorelasi dengan posisi masing-masing pasar dalam rantai distribusi cabai di Kota Medan. Pusat Pasar, yang berfungsi sebagai simpul distribusi utama atau pasar grosir, cenderung memiliki volume transaksi yang jauh lebih besar dan fluktuasi harga yang lebih liar akibat interaksi langsung antara pemasok besar dan pedagang eceran. Volatilitas *intraday* yang tinggi di pasar induk ini menjadi tantangan tersendiri bagi model untuk menangkap pola deterministiknya. Sebaliknya, Pasar Brayan yang lebih berkarakteristik pasar pengecer (*retail*) memiliki pergerakan harga yang lebih "lengket" (*sticky prices*) atau lebih stabil karena pedagang cenderung menahan harga jual ke konsumen akhir meskipun terjadi fluktuasi kecil di tingkat grosir. Temuan ini mengindikasikan bahwa meskipun model LSTM *robust* secara umum, kinerjanya tetap dipengaruhi oleh struktur pasar dan perilaku pembentukan harga di lokasi spesifik. Oleh karena itu, strategi *hyperparameter tuning* yang berbeda mungkin diperlukan untuk pasar dengan volatilitas ekstrem seperti Pusat Pasar di masa mendatang.

Visualisasi hasil prediksi LSTM pada Gambar 4 memberikan bukti empiris yang kuat mengenai kemampuan model ini. Berbeda dengan garis prediksi ARIMA yang mendatar, garis prediksi LSTM (merah) mampu "menempel" ketat pada garis data aktual (biru). Yang paling mengesankan adalah kemampuan model untuk menangkap titik balik (*turning points*) saat harga mulai merangkak naik dari Rp 30.000 menuju puncak Rp 90.000 pada akhir periode observasi. Meskipun terdapat sedikit *lag* atau keterlambatan respons satu hari yang wajar dalam peramalan *time series*, LSTM berhasil mengikuti amplitudo gelombang kenaikan dan penurunan harga dengan sangat baik. Kemampuan adaptasi ini dimungkinkan oleh mekanisme *Forget Gate* dan *Input Gate* dalam sel memori LSTM yang secara dinamis

mengatur bobot informasi, memungkinkannya untuk mempelajari tren jangka pendek yang ekstrem tanpa melupakan pola jangka panjang.



Gambar 4. Grafik Prediksi LSTM vs Data Aktual (Kota Medan)

3.4 Pembahasan dan Analisis Perbandingan

Perbandingan langsung antara kedua metode menunjukkan kesenjangan performa yang sangat mencolok. Tabel 9 menyajikan data komparasi prediksi harian untuk 10 hari terakhir periode pengujian (Oktober 2025). Pada periode ini, harga pasar aktual sedang berada di level sangat tinggi, berkisar antara Rp 71.000 hingga Rp 93.300 per kilogram.

Tabel 9. Perbandingan Prediksi Harga Harian (10 Hari Terakhir)

Tanggal	Harga Aktual (Rp)	Prediksi ARIMA (Rp)	Prediksi LSTM (Rp)
2025-10-13	79.400	22.200	67.736
2025-10-14	79.400	22.200	66.843
2025-10-15	75.100	22.200	66.593
2025-10-16	71.300	22.200	65.564
2025-10-17	69.600	22.200	63.375
2025-10-20	93.300	22.200	61.122
2025-10-21	80.000	22.200	64.966
2025-10-22	75.100	22.200	67.349
2025-10-23	71.100	22.200	67.524
2025-10-24	72.000	22.200	65.577

Pada Tabel 9, terlihat kegagalan fatal model ARIMA yang memprediksi harga "stagnan" di angka Rp 22.200 setiap harinya. Jika prediksi ini digunakan oleh petani, mereka akan mengalami kerugian peluang (*opportunity loss*) yang besar karena menjual hasil panen jauh di bawah harga pasar. Sebaliknya, model LSTM memberikan prediksi yang jauh lebih realistis di kisaran Rp 61.000 hingga Rp 67.000. Meskipun prediksi LSTM masih sedikit *under-estimate* (lebih rendah) dibanding lonjakan harga aktual tertinggi Rp 93.000, namun arah sinyal yang diberikan sangat akurat, yaitu mendeteksi bahwa harga sedang berada di level tinggi (di atas Rp 60.000). Informasi dari LSTM ini jauh lebih bernilai bagi pemangku kepentingan untuk mitigasi risiko dibandingkan informasi statis dari ARIMA.

Secara kuantitatif, model LSTM memberikan peningkatan akurasi sebesar 66% dibandingkan ARIMA (penurunan MAPE dari ~41% menjadi ~13%). Divergensi hasil yang ekstrem ini menegaskan bahwa asumsi linearitas yang menjadi landasan ARIMA tidak lagi relevan untuk diterapkan pada pasar komoditas cabai di Medan yang semakin volatil. Kompleksitas faktor pembentuk harga yang melibatkan aspek psikologis pasar, cuaca, dan spekulasi membutuhkan model non-linear dengan kapasitas pembelajaran fitur (*feature learning*) yang mendalam seperti LSTM.

Temuan dalam penelitian ini memperkuat dan memperluas bukti empiris yang ada dalam literatur global mengenai superioritas *Deep Learning* dibanding metode statistik klasik. Hasil yang menunjukkan kegagalan ARIMA dalam menangkap volatilitas ekstrem sejalan dengan studi Zhang et al. [5] pada harga sayuran di Beijing, yang menemukan bahwa model tradisional kesulitan beradaptasi dengan perubahan struktural pasar yang cepat. Hal ini juga

mengonfirmasi hipotesis Hyndman [2] bahwa metode statistik klasik paling optimal hanya untuk data dengan pola reguler, bukan untuk data *chaotic* seperti harga cabai.

Lebih jauh, keberhasilan LSTM mencapai MAPE di bawah 10% memvalidasi penelitian Witanti dan Arie [15] yang meneliti harga cabai di Bali, serta penelitian Lim dan Handhayani [16] di Jawa Timur. Konsistensi hasil di tiga lokasi berbeda di Indonesia (Medan, Bali, Jawa Timur) menunjukkan bahwa algoritma LSTM bersifat *robust* (tangguh) dan dapat diandalkan secara universal untuk kasus harga pangan nasional. Bahkan, akurasi yang dicapai dalam penelitian ini (0.92) sedikit lebih tinggi dibandingkan beberapa model hibrida kompleks yang diusulkan oleh Manogna [8], yang mengindikasikan bahwa optimalisasi *hyperparameter* (seperti *Window Size* 14 hari) pada LSTM standar sudah cukup efektif tanpa perlu menambah kompleksitas komputasi berlebihan.

Meskipun model LSTM menunjukkan superioritas yang tak terbantahkan dibandingkan ARIMA, evaluasi kritis terhadap Gambar 4 tetap perlu dilakukan. Jika diperhatikan secara saksama pada periode lonjakan harga ekstrem, garis prediksi LSTM (merah) menunjukkan sedikit keterlambatan respons (*time lag*) sekitar satu hari dibandingkan data aktual. Fenomena *lag* ini merupakan karakteristik umum dalam pemodelan *one-step ahead forecasting* menggunakan *Deep Learning*. Model cenderung membutuhkan konfirmasi sinyal harga dari hari untuk menyesuaikan prediksi pada hari . Namun, dalam konteks ekonomi praktis, *lag* satu hari ini masih sangat dapat ditoleransi dibandingkan kegagalan total ARIMA dalam mendeteksi tren. Yang jauh lebih krusial adalah kemampuan LSTM untuk menangkap magnitudo (besaran) kenaikan harga. Ketika harga aktual melonjak ke Rp 90.000, LSTM berhasil memproyeksikan angka di kisaran Rp 80.000-an, memberikan sinyal kewaspadaan yang valid. Hal ini membuktikan bahwa meskipun tidak sempurna secara presisi temporal *real-time*, model ini berhasil mengamankan fungsi utamanya sebagai alat pendukung keputusan yang memberikan estimasi level harga yang realistis di tengah ketidakpastian pasar.

Implikasi manajerial dari penelitian ini sangat signifikan. Bagi Pemerintah Kota Medan, penggunaan model LSTM dapat dijadikan dasar sistem peringatan dini (*Early Warning System*) inflasi. Ketika model memprediksi tren kenaikan harga ekstrem dalam 14 hari ke depan, Tim Pengendali Inflasi Daerah (TPID) dapat segera melakukan intervensi pasar, seperti operasi pasar murah atau koordinasi pasokan antar daerah, sebelum harga benar-benar melonjak tak terkendali. Bagi petani, akses terhadap prediksi akurat ini dapat memutus ketergantungan pada tengkulak dan membantu perencanaan waktu panen yang lebih menguntungkan.

4. KESIMPULAN

Berdasarkan hasil pengujian komprehensif terhadap data harga harian cabai merah keriting di lima pasar tradisional Kota Medan, penelitian ini menyimpulkan bahwa metode *Deep Learning* menggunakan algoritma *Long Short-Term Memory* (LSTM) terbukti jauh lebih superior dibandingkan metode statistik klasik ARIMA. Secara kuantitatif, model ARIMA gagal menangkap dinamika volatilitas harga dengan tingkat kesalahan yang sangat tinggi, ditunjukkan oleh rata-rata MAPE sebesar 41,21% dan nilai Koefisien Determinasi (R^2) yang negatif di hampir seluruh pasar uji. Kegagalan ini mengonfirmasi ketidakmampuan model linear dalam mengakomodasi fluktuasi ekstrem dan perubahan struktural yang menjadi karakteristik utama harga komoditas pangan. Sebaliknya, model LSTM menunjukkan kinerja yang sangat presisi dan konsisten dengan rata-rata MAPE sebesar 13,76% (kategori "Baik") dan bahkan mencapai angka 7,29% pada tingkat agregat kota, serta nilai R^2 yang sangat tinggi mencapai 0,92. Keunggulan ini menegaskan efektivitas arsitektur memori jangka panjang (*long-term dependencies*) pada LSTM dalam mempelajari pola non-linear yang kompleks dari data historis. Implikasi praktis dari temuan ini merekomendasikan pemerintah daerah dan Tim Pengendali Inflasi Daerah (TPID) untuk mulai beralih mengadopsi model berbasis *Deep Learning* sebagai instrumen utama dalam sistem peringatan dini stabilitas harga, menggantikan metode konvensional yang kurang responsif. Kendati demikian, penelitian ini masih terbatas pada pendekatan univariat yang hanya mengandalkan data harga masa lalu. Oleh karena itu, penelitian selanjutnya sangat disarankan untuk mengembangkan model multivariat dengan mengintegrasikan variabel eksogen seperti curah hujan, volume pasokan, dan data hari besar keagamaan guna meningkatkan sensitivitas prediksi terhadap guncangan eksternal.

REFERENCES

- [1] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5th ed., Hoboken, United States of America : Hoboken, Wiley, 2016.
- [2] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*, 2nd ed., Melbourne, Australia: Melbourne OTexts, 2018.
- [3] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*, Cambridge, USA : Cambridge MIT Press, 2016.
- [4] A. Sherstinsky, "Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network," *Physica D: Nonlinear Phenomena*, vol. 404, no. 1, 2020, doi: 10.1016/j.physd.2019.132306.
- [5] Q. Zhang, W. Yang, A. Zhao, X. Wang, Z. Wang, and L. Zhang, "Short-Term Forecasting of Vegetable Prices Based on LSTM Model—Evidence From Beijing's Vegetable Data," *PLOS ONE*, vol. 19, no. 7, 2024, doi: 10.1371/journal.pone.0304881.
- [6] N. Nafi'iyah and P. A. Wulandari, "Prediksi Harga Beras Berdasarkan Kualitas Beras Dengan Metode Long Short-Term Memory," *INOVTEK POLBENG*, vol. 7, no. 2, 2022, doi: 10.35314/isi.v7i2.2599.
- [7] G. Y. Chandan and D. A. N. Khokhar, "A Comparative Study of Deep Learning Models for Cotton Price Forecasting in Gujarat, India", *International Journal of Agricultural and Environmental Research*, vol. 11, no. 1, pp. 246–269, 2025, doi:



- 10.51193/ijaer.2025.11115.
- [8] R. L. Manogna, V. Dharmaji, and S. Sarang, “Enhancing Agricultural Commodity Price Forecasting With Deep Learning,” *Scientific Reports*, vol. 15, no. 1, pp. 1–25, 2025, doi: 10.1038/s41598-025-05103-z.
 - [9] A. Sharma, A. Jain, P. Gupta, and V. Chowdary, “Machine Learning Applications for Precision Agriculture: A Comprehensive Review,” *IEEE Access*, vol. 9, pp. 4843 - 4873, 2020, doi: 10.1109/ACCESS.2020.3048415
 - [10] X. Chen and Y. Hu, “Volatility Forecasts of Stock Index Futures in China and the US—A Hybrid LSTM Approach,” *PLOS ONE*, vol. 17, no. 7, 2022, doi: 10.1371/journal.pone.0271595.
 - [11] S. Wu, “A Comparative Study of Stock Forecasts by LSTM and RNN Neural Networks,” *Modern Economy and Management Forum*, vol.2, No. 5, pp. 170-174, 2021, doi: 10.32629/memf.v2i5.497.
 - [12] C. Z. Yuan and S. K. Ling, "Long Short-Term Memory Model Based Agriculture Commodity Price Prediction Application," in *Proceedings of the 2020 2nd International Conference on Information Technology and Computer Communications (ITCC '20)*, Kuala Lumpur, Malaysia: Association for Computing Machinery, Aug. 2020, pp. 43–49. doi: 10.1145/3417473.3417481.
 - [13] R. Iqbal, H. Mokhlis, A. S. M. Khairuddin, and M. A. Muhammad, “An Improved Deep Learning Model for Electricity Price Forecasting,” *International Journal of Interactive Multimedia and Artificial Intelligence*, vol. 9, no. 1, pp. 149–161, 2023, doi: 10.9781/ijimai.2023.06.001.
 - [14] Y. H. Gu, D. Jin, H. Yin, R. Zheng, X. Piao, and S. J. Yoo, “Forecasting Agricultural Commodity Prices Using Dual Input Attention LSTM,” *Agriculture*, vol. 12, no. 2, p. 256, 2022, doi: 10.3390/agriculture12020256.
 - [15] W. Witanti, S. A. Anggara, and M. Melina, “Peramalan Harga Cabai Rawit Merah Menggunakan Attention Mechanism Berbasis Long Short-Term Memory,” *Journal of Applied Computational Science and Technology*, vol. 5, no. 2, pp. 128–135, 2024, doi: 10.52158/jacost.v5i2.875.
 - [16] M. Lim and T. Handhayani, “Penerapan LSTM dan GRU untuk Prediksi Harga Cabai Merah di Kota Jawa Timur,” *Jurnal Informasi dan Teknologi Elektro Terapan*, vol. 13, no. 2, 2025, doi: 10.23960/jitet.v13i2.6467
 - [17] S. Joddy, “Comparative Analysis of CNN, LSTM, and CNN-LSTM for Indonesian Stock Prediction,” *Jurnal EMACS*, vol. 7, no. 3, pp. 283–289, 2025, doi: 10.21512/emacsjournal.v7i3.14326.
 - [18] A. Kaur and A. Goel, “Forecasting Commodity Prices Using Deep Learning Techniques: An Empirical Evidence From India,” *Journal of Computational Technology and Applications*, vol. 16, no. 3, pp. 8–12, 2025, doi: 10.37591/JOCTA.v16i03.226934.
 - [19] Y. Min, Y. R. Kim, Y.K. Hyon, T. Ha, S. Lee, J. Hyun and M. R. Lee, “RNN and GNN Based Prediction of Agricultural Prices With Multivariate Time Series and Its Short-Term Fluctuations Smoothing Effect,” *Scientific Reports*, vol. 15, no. 1, 2025, doi: 10.1038/s41598-025-97724-7.
 - [20] C. Xia, “Comparative Analysis of ARIMA and LSTM Models for Agricultural Product Price Forecasting,” *Highlights in Science Engineering and Technology*, vol. 85, pp. 1032-1040, 2024, doi: 10.54097/8q6nx369.