

PERBANDINGAN MODEL XGBOOST, LSTM, DAN NEURAL PROPHET UNTUK PREDIKSI HARGA CABAI RAWIT MERAH DI JAWA TIMUR

Hafid Alfa Anamsyah¹, I Gede Susrama Mas Diyasa², Andreas Nugroho Sihananto³

^{1,2,3} Informatika, Universitas Pembangunan Nasional “Veteran” Jawa Timur

¹hafidalfa25@gmail.com

²igsusrama.if@upnjatim.ac.id

³andreas.nugroho.jarkom@upnjatim.ac.id

Abstrak— Harga cabai rawit merah di Indonesia, khususnya di Provinsi Jawa Timur, sering mengalami fluktuasi signifikan yang berdampak terhadap inflasi pangan dan kestabilan ekonomi masyarakat. Oleh karena itu, dibutuhkan sistem prediksi harga yang akurat untuk membantu pengambilan keputusan dalam pengelolaan rantai pasok pangan. Penelitian ini bertujuan untuk membandingkan kinerja tiga model *machine learning* dan *deep learning*, yaitu XGBoost, LSTM, dan Neural Prophet, dalam memprediksi harga cabai rawit merah berdasarkan data historis dari Agustus 2018 hingga Agustus 2025 yang diperoleh dari situs resmi Siskaperbapo Dinas Perindustrian dan Perdagangan (DISPERINDAG) Provinsi Jawa Timur. Analisis dilakukan dengan pendekatan kuantitatif menggunakan data deret waktu (*time series forecasting*), dengan evaluasi performa melalui metrik RMSE, MAE, MAPE, dan R^2 . Hasil penelitian menunjukkan bahwa model LSTM memberikan akurasi terbaik dengan nilai RMSE 1.78, MAE 0.99, MAPE 2.13%, dan R^2 sebesar 0.9909, dibandingkan dengan XGBoost dan Neural Prophet. Temuan ini menegaskan bahwa pendekatan *deep learning* berbasis LSTM paling efektif untuk mengenali pola temporal dan musiman dalam data harga cabai rawit merah. Penelitian ini berkontribusi terhadap pengembangan sistem prediksi harga pangan berbasis kecerdasan buatan sebagai dasar pengambilan keputusan kebijakan stabilisasi harga di sektor pertanian.

Kata Kunci— Prediksi harga, Cabai rawit merah, XGBoost, LSTM, Neural Prophet, *Time series forecasting*.

I. PENDAHULUAN

Cabai rawit merah merupakan salah satu komoditas hortikultura strategis di Indonesia yang memiliki peran penting dalam kehidupan masyarakat sehari-hari. Tidak hanya sebagai bahan pangan utama dalam berbagai masakan, cabai rawit juga menjadi komoditas yang berpengaruh langsung terhadap stabilitas ekonomi, terutama pada kelompok pengeluaran makanan. Tingginya konsumsi cabai di masyarakat menjadikan perubahan harga cabai rawit merah sangat sensitif dan berdampak luas terhadap kesejahteraan masyarakat. Fenomena fluktuasi harga cabai rawit merah sudah lama menjadi isu nasional, terutama di daerah sentra produksi seperti Jawa Timur. Sebagai salah satu provinsi dengan produksi cabai terbesar di Indonesia, Jawa Timur sering menghadapi dinamika harga yang tidak stabil. Lonjakan harga cabai rawit merah dapat mendorong inflasi pangan dan

menekan daya beli masyarakat, sementara penurunan harga yang drastis merugikan petani karena harga jual tidak sebanding dengan biaya produksi [1].

Berdasarkan data Badan Pusat Statistik (BPS), inflasi bahan makanan di Indonesia kerap dipicu oleh kenaikan harga cabai rawit merah, khususnya pada periode musim hujan dan saat terjadi gangguan distribusi. Kondisi ini memperlihatkan betapa erat hubungan antara harga cabai dengan stabilitas inflasi nasional. Bahkan, pada tahun 2020–2022, harga cabai rawit sempat melonjak lebih dari 100% dalam waktu singkat akibat cuaca ekstrem dan distribusi yang tidak efisien [2].

Harga cabai rawit merah di Jawa Timur sendiri menunjukkan pola fluktuasi musiman yang cukup tajam. Ketika produksi melimpah, harga anjlok drastis sehingga petani mengalami kerugian. Sebaliknya, pada saat pasokan berkurang, harga bisa melonjak hingga lebih dari Rp100.000 per kilogram di tingkat konsumen. Situasi ini menimbulkan ketidakpastian ekonomi baik bagi konsumen maupun produsen, sehingga diperlukan sistem prediksi harga yang akurat untuk mengantisipasi perubahan pasar [3].

Upaya untuk memahami pola pergerakan harga cabai rawit merah telah banyak dilakukan melalui penelitian. Beberapa studi menggunakan pendekatan klasik dalam analisis deret waktu, seperti metode ARIMA. Windhy dan Jamil (2021) misalnya, menggunakan model ARIMA untuk memprediksi harga cabai merah di Indonesia dan menunjukkan bahwa metode tersebut cukup efektif dalam jangka pendek, meski memiliki keterbatasan dalam menangkap pola non-linear [4].

Selain itu, penelitian Ginting dkk. (2023) menyoroti volatilitas dan transmisi harga cabai di Sumatera Utara. Hasil penelitian tersebut menegaskan bahwa ketidakstabilan harga tidak hanya terjadi di tingkat lokal, tetapi juga dipengaruhi integrasi pasar antarwilayah [5]. Hal ini memperkuat pentingnya pemodelan harga cabai yang mampu memperhitungkan kompleksitas dinamika pasar.

Studi lain yang dilakukan oleh Maula dan Rianti (2021) di Kabupaten Malang menekankan bahwa fluktuasi harga cabai rawit berimplikasi langsung terhadap inflasi pangan. Mereka menekankan perlunya metode peramalan yang lebih akurat agar kebijakan harga dapat dirumuskan secara tepat [6]. Namun, penelitian tersebut belum memanfaatkan metode pembelajaran mesin modern yang kini semakin populer dalam analisis data deret waktu.

Hidayati dkk. (2022) dalam penelitiannya di Banda Aceh juga menekankan bahwa peramalan harga cabai dapat membantu menjaga stabilitas inflasi daerah. Namun, pendekatan yang digunakan masih konvensional sehingga kurang optimal dalam menghadapi pola data yang kompleks dan volatil [7]. Situasi serupa juga terlihat pada studi Sukmawati (2017) yang menyoroti fluktuasi harga cabai merah keriting di sentra produksi Cikajang dan Jakarta, namun belum menyentuh aspek komputasi prediktif berbasis *machine learning* [8].

Di Jawa Timur sendiri, Mandarsari dkk. (2020) telah mengkaji volatilitas harga cabai rawit dengan pendekatan ekonometrika. Penelitian tersebut menunjukkan adanya fluktuasi harga yang signifikan dan perlunya sistem peramalan yang lebih canggih untuk mengantisipasi lonjakan harga [1]. Namun, penelitian ini juga belum membandingkan efektivitas model pembelajaran mesin modern seperti XGBoost, LSTM, dan Neural Prophet.

Sementara itu, penelitian Brahmana dkk. (2022) menyoroti volatilitas harga cabai di Pulau Jawa selama pandemi Covid-19. Hasilnya menunjukkan bahwa ketidakstabilan harga semakin tajam akibat terganggunya rantai pasok [2]. Kondisi ini semakin menegaskan urgensi prediksi harga yang tidak hanya akurat, tetapi juga adaptif terhadap perubahan eksternal yang cepat.

Model pembelajaran mesin dan *deep learning* menawarkan pendekatan baru dalam peramalan deret waktu. XGBoost, misalnya, dikenal unggul dalam menangani data dengan pola non-linear melalui metode ensemble learning. LSTM sebagai salah satu varian *recurrent neural networks* mampu mempelajari ketergantungan jangka panjang pada data time series. Sedangkan Neural Prophet menggabungkan keunggulan model Prophet dengan fleksibilitas neural networks untuk menangkap pola musiman dan tren yang kompleks.

Sayangnya, masih sangat sedikit penelitian empiris di Indonesia yang secara langsung membandingkan ketiga model ini dalam konteks prediksi harga cabai rawit merah, khususnya di Jawa Timur. Mayoritas penelitian terdahulu masih berfokus pada metode konvensional atau pada komoditas selain cabai rawit merah. Kesenjangan ini menunjukkan adanya ruang penelitian yang perlu diisi agar pemodelan harga cabai di Indonesia menjadi lebih komprehensif dan akurat [9].

Selain faktor metodologi, tantangan lain adalah ketersediaan data historis yang cukup panjang dan bersih. Fluktuasi harga harian yang tersedia dari Dinas Perindustrian dan Perdagangan (DISPERINDAG) Jawa Timur sejak Agustus 2018 hingga Agustus 2025 memberikan peluang untuk membangun model prediksi dengan tingkat akurasi tinggi. Dengan data ini, penelitian dapat menguji performa berbagai algoritma dan menentukan model terbaik untuk kasus cabai rawit merah di Jawa Timur.

Urgensi penelitian ini juga didukung oleh fakta bahwa lonjakan harga cabai rawit merah berdampak signifikan pada konsumsi rumah tangga dan kebijakan pemerintah. Fauzi dan

Andriani (2023) menegaskan bahwa meningkatnya harga cabai dapat memengaruhi permintaan dan penawaran secara drastis, sehingga memicu ketidakseimbangan pasar [10]. Oleh karena itu, prediksi harga yang tepat tidak hanya bernilai akademis tetapi juga praktis dalam mendukung pengambilan keputusan. Berdasarkan uraian di atas, penelitian ini bertujuan untuk membandingkan kinerja tiga model modern (XGBoost, LSTM, dan Neural Prophet) dalam memprediksi harga cabai rawit merah di Jawa Timur. Penelitian ini diharapkan dapat memberikan kontribusi baru dalam bidang peramalan harga komoditas pangan, melengkapi keterbatasan studi terdahulu yang masih dominan menggunakan metode konvensional, serta memberikan manfaat praktis bagi petani, pedagang, konsumen, dan pemerintah dalam mengantisipasi dinamika harga..

II. TINJAUAN PUSTAKA

A. Konsep Prediksi Harga Komoditas

Prediksi harga komoditas pangan adalah penerapan teknik kuantitatif untuk memperkirakan nilai masa depan dari harga komoditas demi mendukung keputusan ekonomi dan kebijakan (perencanaan produksi, intervensi pasar, pengendalian inflasi). Peramalan harga komoditas biasanya bertujuan meminimalkan ketidakpastian pada rantai pasok dan mengurangi dampak sosial-ekonomi dari lonjakan harga. Prinsip umum dan praktik peramalan sudah terdokumentasi luas dalam literatur *forecasting*; pendekatan yang dipilih bergantung pada pola data (tren, musiman, volatilitas) dan tujuan praktiknya (mis. jangka pendek vs jangka menengah) [11].

Dalam konteks cabai rawit merah, faktor-faktor yang memengaruhi harga termasuk kondisi musiman (tanam/panen), gangguan pasokan (cuaca ekstrem, penyakit tanaman), biaya distribusi, permintaan-hari-hari konsumsi, serta kebijakan dan intervensi pasar. Karena harga komoditas ini rentan terhadap kejutan (*shock*) dan memiliki komponen musiman serta perubahan tren jangka panjang, metode peramalan yang dapat mengakomodasi komponen-komponen tersebut dan non-linearitas sering diperlukan untuk hasil yang andal [11].

Data deret waktu (*time series*) merupakan bentuk data utama untuk prediksi harga: observasi harga terurut menurut waktu (harian/mingguan/bulanan). Analisis deret waktu memanfaatkan struktur temporal (autokorelasi, musiman, tren) untuk membangun model yang memproyeksikan nilai masa depan berdasarkan pola historis. Prinsip-prinsip ini adalah fondasi bagi pemilihan metode prediksi dan strategi validasi (mis. pembagian train/test time-aware, walk-forward validation) [11].

B. Time Series Forecasting

Secara konseptual, deret waktu terdiri dari beberapa komponen utama: tren (perubahan jangka panjang), musiman (pola berulang periodik), siklus (pergerakan periodik tidak teratur terkait siklus ekonomi/produksi), dan error (komponen residual acak). Identifikasi dan dekomposisi komponen-

komponen ini membantu memilih model yang tepat (mis. model dekomposisi + model residual). Panduan praktis dan teori dekomposisi serta pemilihan model dijelaskan secara rinci oleh Hyndman & Athanasopoulos [11].

Model statistik tradisional (mis. ARIMA/Box-Jenkins, VAR, exponential smoothing) membangun prediksi dengan asumsi linearitas (atau linearitas setelah transformasi/differencing), autokorelasi yang dapat dimodelkan oleh lag AR/MA, dan komponen musiman yang eksplisit (SARIMA). ARIMA efektif untuk seri yang relatif “stabil” dan jangka pendek karena interpretabilitas dan teori yang matang, tetapi memiliki keterbatasan saat menghadapi non-linearitas, interaksi kompleks antar-fitur, atau ketergantungan jangka panjang yang non-linier [12].

Model machine learning dan deep learning (mis. tree boosting, neural networks) menawarkan fleksibilitas lebih besar untuk menangkap pola non-linear dan interaksi fitur (lagged features, eksogen variabel). Perbedaan praktisnya: model statistik tradisional biasanya mengandalkan asumsi struktur waktu tertentu dan parameter yang interpretable, sedangkan ML/DL lebih berfokus pada kapasitas aproksimasi non-linear, memerlukan perhatian pada feature engineering (mis. pembuatan lag, window features) dan validasi time-series agar tidak terjadi data leakage. Pilihan model harus mempertimbangkan kompleksitas data, kebutuhan interpretabilitas, dan sumber daya komputasi [11][13].

C. *XGBoost (Extreme Gradient Boosting)*

XGBoost adalah implementasi efisien dari gradient boosting decision trees yang menggabungkan boosting iterative, regularisasi, dan optimasi sistem (sparsity-aware, weighted quantile sketch) sehingga sangat skalabel untuk dataset besar. Secara teoritis, XGBoost membangun ensemble pohon keputusan secara bertahap, setiap pohon mencoba mengoreksi kesalahan residual dari ensemble sebelumnya, dan regularisasi membantu mengurangi overfitting. Paper asli Chen & Guestrin menjelaskan mekanisme teknik, keuntungan komputasi, dan performa pada banyak kompetisi ML [13].

Untuk peramalan deret waktu, XGBoost tidak memodelkan urutan waktu secara intrinsik; oleh karena itu aplikasinya biasanya memerlukan feature engineering (mis. pembuatan lag variables, rolling statistics, kalender features) sehingga model tree dapat belajar hubungan antar-lag dan faktor eksogen. Kelebihan XGBoost meliputi kemampuan menangkap non-linearitas dan interaksi kompleks, tahan terhadap outlier relatif, dan efisien secara komputasi bila di-tune dengan benar. Keterbatasannya: membutuhkan rekayasa fitur time-aware, kurang langsung dalam menangkap ketergantungan jangka-panjang tanpa fitur khusus, dan interpretabilitas yang lebih rendah dibanding model linear tradisional (meski tersedia teknik interpretasi seperti SHAP) [13].

D. *LSTM (Long Short-Term Memory)*

Long Short-Term Memory (LSTM) adalah arsitektur RNN yang dirancang untuk mengatasi masalah vanishing/exploding gradients pada RNN klasik dan memungkinkan jaringan untuk “mengingat” informasi relevan pada lag yang panjang melalui gated memory cells (input gate, forget gate, output gate, dan memory cell state). Makalah pendiri oleh Hochreiter & Schmidhuber (1997) menjelaskan arsitektur dan kemampuan LSTM dalam tugas sequence learning. Karena struktur sekuensialnya, LSTM mampu mempelajari ketergantungan jangka panjang dalam data deret waktu tanpa harus eksplisit membuat banyak lag features [14]. Keunggulan LSTM dalam forecasting adalah kemampuannya menangkap pola temporal non-linear dan dependensi jangka panjang yang sulit dimodelkan oleh pendekatan berbasis pohon tanpa rekayasa fitur besar. Namun, LSTM memiliki tantangan praktis: kebutuhan data yang relatif besar untuk pelatihan, waktu komputasi yang lebih tinggi, sensitivitas pada pemilihan arsitektur dan hyperparameter (unit sel, learning rate, window size), serta risiko overfitting jika tidak menggunakan regularisasi/early stopping. Dalam konteks harga komoditas yang sangat volatile, LSTM dapat menawarkan keunggulan apabila ada sinyal temporal berulang dan cukup data historis (mis. dataset harian 2018–2025) [14].

E. *Neural Prophet*

Prophet (Taylor & Letham) adalah model dekomposisi aditif yang dirancang untuk forecasting at scale dengan parameter yang mudah diinterpretasi: komponen trend, musiman (multi-periode), dan efek libur/holiday. Prophet bekerja sangat baik untuk seri dengan komponen musiman yang jelas dan memungkinkan penambahan regresor eksternal dengan relatif mudah. Paper Prophet menekankan kemudahan penggunaan dan interpretabilitas sebagai kekuatan utamanya [15].

Neural Prophet adalah pengembangan yang menggabungkan ide-ide Prophet dengan komponen neural (neural network blocks) agar model dapat menangkap pola non-linear lebih kuat sambil mempertahankan struktur dekomposisi yang interpretatif. Arsitektur NeuralProphet memungkinkan modeling tren, musiman, autoregressive lags, dan regresor tambahan dalam kerangka yang dapat dilatih end-to-end. Studi dan paper Neural Prophet menunjukkan bahwa pendekatan ini seringkali memberikan trade-off yang baik antara interpretabilitas (komponen tren/musim tetap jelas) dan kapasitas aproksimasi non-linear (melalui blok neural). Untuk komoditas yang berulang-musiman namun juga terpengaruh nonlinearitas dan kejutan, NeuralProphet menawarkan solusi hibrida yang menjanjikan [15][16].

Perbandingan praktisnya, Neural Prophet unggul jika data memiliki pola musiman yang kuat dan pengguna butuh interpretasi, LSTM unggul bila ketergantungan jangka panjang non-linear dominan, dan XGBoost kuat saat terdapat banyak fitur regresor/lag dan interaksi non-linear. Oleh karena itu

perbandingan ketiga pendekatan (XGBoost vs LSTM vs Neural Prophet) pada dataset harga cabai yang volatil adalah wajar secara teoretis dan praktis untuk menentukan model yang paling cocok untuk tujuan operasional/pengambilan kebijakan.

F. Metrik Evaluasi Model Prediksi

Dalam penelitian kuantitatif perbandingan model, penting menggunakan metrik evaluasi yang konsisten dan informatif. RMSE (Root Mean Squared Error) mengukur besar rata-rata kesalahan kuadrat yang kemudian di-root, memberikan penalti lebih besar untuk kesalahan besar sehingga sensitif terhadap outlier; MAE (Mean Absolute Error) mengukur rata-rata kesalahan absolut dan lebih mudah diinterpretasikan dalam satuan harga; MAPE (Mean Absolute Percentage Error) menyatakan kesalahan dalam persentase sehingga berguna untuk komunikatif antar-komoditas, namun rentan terhadap nilai aktual yang mendekati nol. R-squared (koefisien determinasi) mengukur proporsi varians yang dijelaskan model—berguna sebagai ukuran komparatif meskipun interpretasinya harus hati-hati pada data non-stasioner/time series. Dokumentasi dan pedoman implementasi metrik ini tersedia di pustaka scikit-learn dan literatur evaluasi model. Pemilihan RMSE, MAE, MAPE, dan R^2 pada penelitian ini memungkinkan penilaian kinerja model dari sisi besar error (RMSE), ketepatan rata-rata (MAE), relevansi relatif (MAPE), dan kemampuan menjelaskan varians (R^2).

Dalam penelitian ini, teori-teori di atas akan diaplikasikan sebagai berikut: dataset harga harian DISPERINDAG Jawa Timur (Agustus 2018–Agustus 2025) akan dianalisis sesuai prinsip dekomposisi deret waktu (identifikasi tren musiman) sebelum pemodelan. ARIMA/SARIMA dijadikan referensi literatur (sebagai baseline teoritik) sedangkan XGBoost, LSTM, dan Neural Prophet diuji praktis sesuai kapasitas teoritis masing-masing (feature engineering untuk XGBoost, sequence windows dan regularisasi untuk LSTM, dan komponen dekomposisi + neural blocks untuk Neural Prophet). Validasi time-aware (walk-forward / rolling origin) dan metrik RMSE/MAE/MAPE/ R^2 akan digunakan untuk perbandingan kuantitatif yang sah. Dengan pendekatan ini, penelitian mengisi gap literatur yang jarang membandingkan ketiga kelas model modern pada data harga cabai yang volatil dan berskala provinsi, sekaligus menyediakan benchmark reproducible untuk praktik peramalan komoditas di Indonesia [11][13][14][16].

III. METODE PENELITIAN

A. Jenis Penelitian

Penelitian ini menggunakan pendekatan kuantitatif komparatif. Penelitian kuantitatif dipilih karena berfokus pada pengolahan data numerik berupa harga cabai rawit merah yang diperoleh secara historis dari sumber resmi, yaitu *Dinas Perindustrian dan Perdagangan (DISPERINDAG) Provinsi Jawa Timur*. Pendekatan kuantitatif memungkinkan peneliti

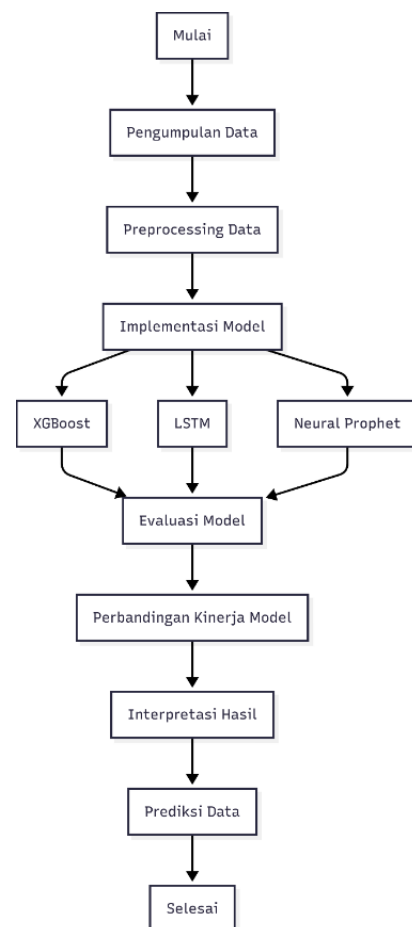
melakukan analisis statistik secara objektif untuk membandingkan kinerja tiga algoritma prediksi harga, yaitu XGBoost, LSTM, dan Neural Prophet.

Jenis penelitian komparatif digunakan karena tujuan utama penelitian ini adalah membandingkan tingkat akurasi dari tiga model prediksi yang berbeda. Model yang digunakan tidak dimaksudkan untuk sekadar mendeskripsikan data (deskriptif) atau mencari hubungan antar variabel (korelasional), melainkan secara khusus untuk mengidentifikasi model mana yang paling optimal, lalu memprediksi harga dengan model yang paling optimal tersebut. Penelitian ini juga memiliki unsur eksperimen kuasi karena peneliti tidak memanipulasi variabel secara langsung, melainkan menggunakan dataset historis yang telah tersedia untuk menguji kinerja model. Dengan demikian, penelitian ini berada pada ranah eksperimen komputasional dengan data sekunder.

B. Flowchart

1) Flowchart Penelitian

Gambar 1 di bawah ini menunjukkan flowchart penelitian yang dilaksanakan, dimulai dari tahap tinjauan pustaka dan pengumpulan data hingga prediksi data dari model yang paling optimal.



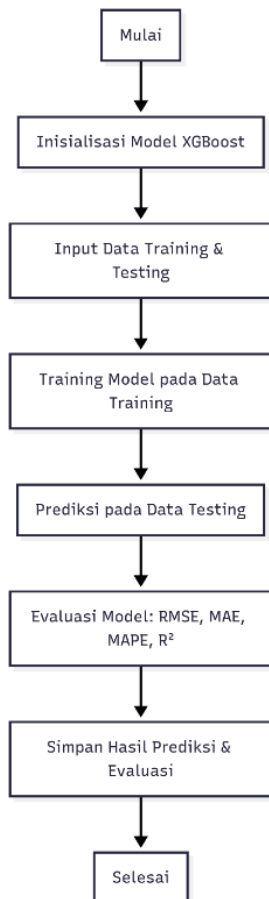
Gambar 1 Flowchart Penelitian.

Flowchart penelitian secara sistematis adalah sebagai berikut:

- Pengumpulan data: Tahap ini mengumpulkan data harga harian cabai rawit merah diperoleh dari *siskaperbapo.jatimprov.go.id*.
- Preprocessing data: Tahap ini meliputi pembersihan data (handling missing value), normalisasi, serta pembagian data Menjadi *training set* dan *testing set*.
- Implementasi model: Tahap ini membangun tiga model prediksi (XGBoost, LSTM, Neural Prophet) dengan parameter yang sesuai.
- Evaluasi model: Tahap ini menggunakan metrik RMSE, MAE, MAPE, dan R^2 .
- Perbandingan hasil: Tahap ini mengidentifikasi model dengan performa terbaik.
- Prediksi data: Tahap ini memprediksi atau forecasting data dari model yang paling optimal.

2) Flowchart XGBoost

Gambar 2 di bawah ini menunjukkan flowchart XGBoost yang dilaksanakan.




Gambar 2 Flowchart XGBoost

Flowchart XGBoost menampilkan proses mulai dari inisialisasi model dengan parameter tertentu, input data training dan testing, lalu dilakukan training. Setelah itu model memprediksi harga cabai rawit merah berdasarkan data testing. Hasil prediksi kemudian dievaluasi menggunakan metrik kuantitatif (RMSE, MAE, MAPE, R^2). Seluruh hasil akhir disimpan sebagai bahan perbandingan performa dengan metode lain.

3) Flowchart LSTM

Gambar 3 di bawah ini menunjukkan flowchart LSTM yang dilaksanakan.




Gambar 3 Flowchart LSTM

Flowchart LSTM memiliki tahap tambahan berupa preprocessing data, yaitu normalisasi agar data sesuai dengan skala neural network, serta reshape menjadi format 3D [samples, timesteps, features]. Setelah itu dibangun arsitektur LSTM dengan lapisan input, hidden, dan output. Model kemudian dikompilasi, dilatih, dan digunakan untuk prediksi. Hasil prediksi perlu di-inverse normalisasi agar kembali ke skala harga asli, lalu dievaluasi dengan metrik yang sama seperti XGBoost

4) Flowchart Neural Prophet

Flowchart Neural Prophet menekankan format input data yang harus mengikuti struktur [ds, y], di mana ds berisi tanggal dan y berisi harga. Model kemudian dilatih pada data training. Untuk prediksi, dibuat future dataframe berdasarkan periode testing. Hasil prediksi dibandingkan dengan data aktual, dievaluasi menggunakan metrik kuantitatif, lalu disimpan untuk perbandingan dengan metode lainnya.

Gambar 4 di bawah ini menunjukkan flowchart Neural Prophet yang dilaksanakan.



Gambar 4 Flowchart Neural Prophet

C. Skenario Pengujian

Skenario pengujian adalah langkah penelitian dalam merancang skenario pengujian untuk model prediksi. Variabel yang digunakan dalam penelitian ini adalah harga cabai rawit merah pada Agustus 2018 - Agustus 2025. Selain itu, penulis juga menerapkan variasi pembagian data pelatihan dan pengujian. Skenario pengujian akan dijabarkan dalam Tabel 1 berikut ini.

Tabel 1 Skenario Pengujian

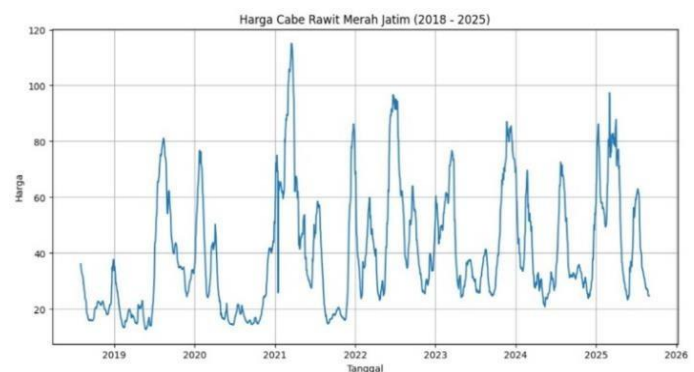
No.	Variabel		Pembagian Data (Train:Test)
	Tanggal	Harga	
1.	8/1/2018	36.136	80:20
2.	8/2/2018	35.247	
3.	8/3/2018	34.546	
...	
2588.	8/31/2018	24.725	

IV. HASIL PENELITIAN

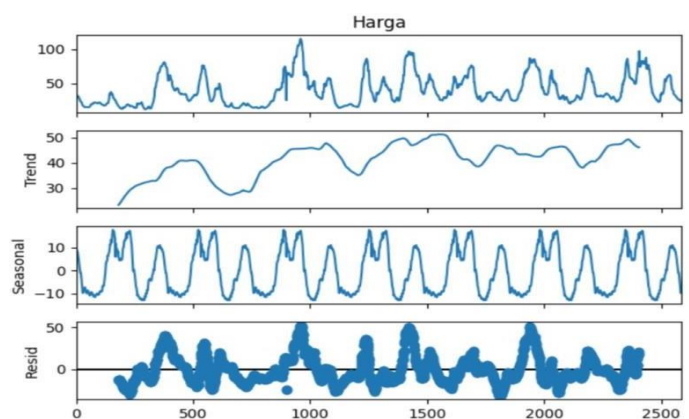
A. Gambaran Umum Data

Penelitian ini menggunakan data harga cabai rawit merah di Provinsi Jawa Timur yang diperoleh dari Dinas Perindustrian dan Perdagangan (DISPERINDAG) Provinsi Jawa Timur melalui situs resmi siskaperbapo.jatimprov.go.id. Rentang waktu data adalah Agustus 2018 hingga Agustus 2025, mencakup lebih dari 2.500 titik data harian dari 38 kabupaten/kota di Jawa Timur.

Secara umum, harga cabai rawit merah menunjukkan fluktuasi yang sangat signifikan sepanjang periode pengamatan. Rata-rata harga berada pada kisaran Rp 45.000/kg, dengan nilai terendah sekitar Rp 18.000/kg dan tertinggi mencapai Rp 110.000/kg. Pola data menunjukkan adanya musiman (seasonality) yang jelas, di mana harga cenderung meningkat pada bulan-bulan menjelang Ramadan dan akhir tahun, serta menurun pada masa panen raya.



Gambar 5 Harga cabai rawit merah di Jawa Timur selama periode pengamatan.



Gambar 6 Tren Harga Cabai Rawit Merah di Jawa Timur (2018–2025).

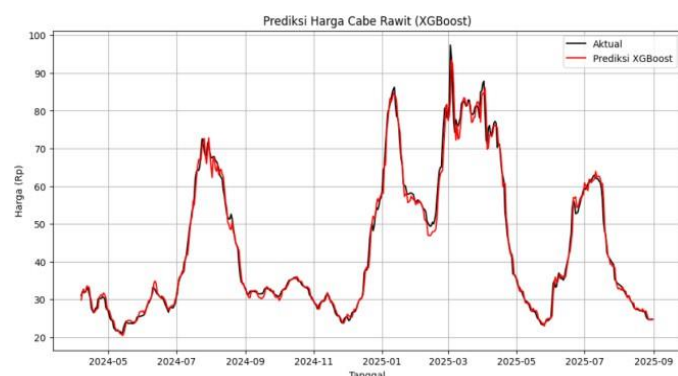
Berdasarkan grafik tersebut, terlihat bahwa harga cabai rawit merah memiliki pola siklus tahunan. Lonjakan harga yang berulang setiap tahun mengindikasikan adanya pengaruh kuat faktor musiman, yang diperkuat oleh data curah hujan dan distribusi hasil pertanian. Temuan ini konsisten

dengan hasil penelitian Mandarsari et al. [8], yang menyatakan bahwa fluktuasi harga cabai di Jawa Timur sangat dipengaruhi oleh pola panen dan distribusi antar daerah. Dengan demikian, karakteristik data ini ideal untuk pendekatan prediksi berbasis time series, karena mengandung tren, musiman, dan noise yang kompleks.

B. Hasil Implementasi Model

1) Hasil Model XGBoost

Model XGBoost dilatih menggunakan parameter: $n_estimators=300$, $learning_rate=0.05$, $max_depth=6$, dan $subsample=0.8$. Model ini menunjukkan kemampuan yang sangat baik dalam menangani pola non-linear jangka pendek, tetapi memiliki keterbatasan dalam menangkap dependensi jangka panjang.



Gambar 7 Implementasi model XGBoost.

Tabel 2 Hasil Evaluasi Model XGBoost.


Metrik	Nilai
RMSE	1.93
MAE	1.21
MAPE	2.56%
R ²	0.9894

Secara visual, model XGBoost mampu mengikuti pola data dengan baik pada rentang data yang stabil, namun cenderung lagging pada titik ekstrem kenaikan harga. Hal ini karena model berbasis ensemble decision tree kurang adaptif terhadap perubahan pola mendadak (non-stationary data).

Hasil ini sejalan dengan penelitian Marina et al. [4], yang menyatakan bahwa model ensemble seperti XGBoost efektif untuk prediksi jangka pendek namun membutuhkan tuning parameter yang cermat untuk menghindari overfitting.

2) Hasil Model LSTM

Model LSTM menggunakan arsitektur dengan 3 lapisan tersembunyi (hidden layers) dan 64 unit neuron, fungsi aktivasi tanh, serta optimizer adam. Model ini dilatih selama 100 epoch dengan batch size 32.



Gambar 8 Implementasi model LSTM.

Tabel 3 Hasil Evaluasi Model LSTM

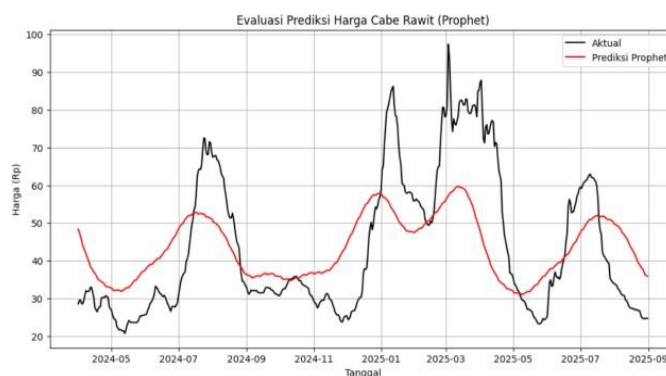
Metrik	Nilai
RMSE	1.78
MAE	0.99
MAPE	2.13%
R ²	0.9909

Hasil menunjukkan bahwa LSTM menghasilkan error paling rendah dibandingkan model lainnya. Model ini mampu menangkap pola musiman dan dependensi jangka panjang, sesuai karakteristik data cabai rawit merah. Performa ini mendukung teori Hochreiter & Schmidhuber (1997) tentang kemampuan LSTM dalam mengatasi masalah vanishing gradient pada data deret waktu.

Kelebihan utama LSTM adalah fleksibilitas dalam mengenali temporal dependency, namun kelemahannya terletak pada kompleksitas komputasi dan waktu pelatihan yang lebih lama. Temuan ini juga memperkuat hasil penelitian Ginting et al. [2], yang menekankan pentingnya penggunaan metode berbasis deep learning untuk menangani volatilitas harga pangan di tingkat provinsi.

3) Hasil Model Neural Prophet

Model Neural Prophet dikembangkan dari Prophet milik Meta (Facebook), dengan tambahan *neural network regression* untuk menangani pola musiman kompleks. Parameter utama meliputi $changepoint_range=0.9$, $seasonality_mode='additive'$, dan $epochs=50$.



Gambar 9 Implementasi model Neural Prophet.

Tabel 4 Hasil Evaluasi Model Neural Prophet

Metrik	Nilai
RMSE	11.74
MAE	14.42
MAPE	28.49%
R ²	0.4055

Model Neural Prophet berhasil menangkap komponen tren dan musiman secara eksplisit, tetapi performanya sedikit lebih rendah dari LSTM karena kesulitan menyesuaikan dengan anomali harga ekstrem. Kelebihan Neural Prophet adalah kemampuannya menjelaskan struktur musiman dan tren dengan interpretabilitas tinggi, yang membuatnya cocok untuk analisis kebijakan.

Penelitian Brahmana et al. [5] juga menemukan bahwa model Prophet sangat efektif dalam kondisi data dengan musiman kuat, namun perlu modifikasi neural network (Neural Prophet) untuk meningkatkan akurasi.

C. Perbandingan Kinerja Model

Tabel 5 Perbandingan Hasil Evaluasi Tiga Model.

Model	RMSE	MAE	MAPE	R ²
XGBoost	1.93	1.21	2.56%	0.9894
LSTM	1.78	0.99	2.13%	0.9909
Neural Prophet	11.74	14.42	28.49%	0.4055

Dari hasil evaluasi tersebut, dapat disimpulkan bahwa LSTM memiliki performa terbaik berdasarkan semua metrik pengukuran. Nilai RMSE dan MAE yang paling rendah menunjukkan bahwa model ini menghasilkan prediksi paling akurat terhadap data aktual, sedangkan nilai R² sebesar 0.9909 menunjukkan kemampuan model menjelaskan variabilitas data sebesar 99.09%. XGBoost menempati posisi kedua, sedangkan Neural Prophet ketiga.

D. Pembahasan Hasil Penelitian

Hasil penelitian ini menunjukkan bahwa metode deep learning (LSTM) lebih unggul dibandingkan model ensemble (XGBoost) dan hybrid (Neural Prophet) dalam memprediksi harga cabai rawit merah. Hal ini karena karakteristik data yang bersifat deret waktu dengan temporal dependency kuat, sehingga LSTM mampu mengenali keterkaitan antar periode secara efektif.

Secara teori, hasil ini mendukung temuan dari Windhy & Jamil [1], yang menekankan pentingnya pemodelan dinamis untuk data harga komoditas. Walaupun mereka menggunakan ARIMA, hasil penelitian ini membuktikan bahwa model berbasis neural network mampu mengatasi keterbatasan linearitas pada ARIMA.

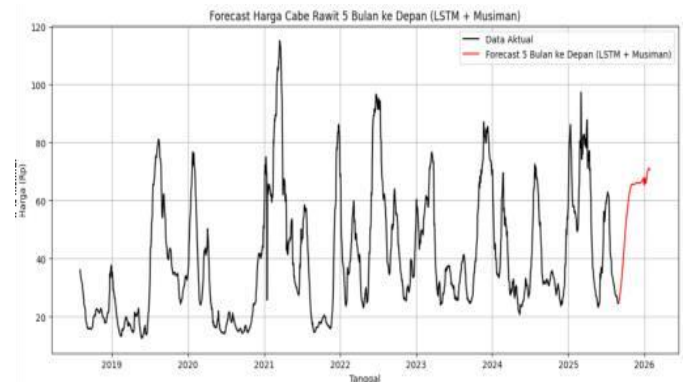
Selain itu, temuan ini juga melengkapi penelitian Mandarsari et al. [8] dan Marina et al. [4] yang sebelumnya hanya meneliti volatilitas harga tanpa membandingkan performa model pembelajaran mesin secara empiris.

Dengan demikian, penelitian ini memberikan kontribusi baru berupa evaluasi komprehensif tiga pendekatan modern untuk prediksi harga pangan strategis di Indonesia.

E. Prediksi Data Berdasarkan Model Terbaik

Berdasarkan hasil perbandingan, LSTM digunakan sebagai model terbaik untuk memproyeksikan harga cabai rawit

merah di Jawa Timur hingga 5 bulan ke depan. Prediksi menunjukkan kecenderungan kenaikan harga moderat pada periode Ramadhan dan akhir tahun.

**Gambar 10** Hasil Prediksi Harga Cabai Rawit Merah (September 2025-Januari 2026) dengan Model LSTM.

Interpretasi hasil ini menunjukkan bahwa harga cenderung meningkat pada periode dengan permintaan tinggi, yang konsisten dengan teori ekonomi mikro terkait elastisitas harga barang kebutuhan pokok (Fauzi & Andriani [10]). Prediksi ini dapat digunakan oleh pemerintah daerah untuk menyusun kebijakan stabilisasi harga, seperti penyediaan stok cadangan dan efisiensi distribusi antar wilayah.

V. KESIMPULAN

Berdasarkan serangkaian eksperimen dan analisis yang telah dilakukan, beberapa kesimpulan utama yang dapat diambil adalah sebagai berikut:

1. Model XGBoost menunjukkan performa yang baik untuk pola harga jangka pendek dengan nilai RMSE sebesar 1.93, MAE 1.21, dan MAPE 2.56%, serta koefisien determinasi (R²) sebesar 0.9894. Model ini mampu menangkap perubahan cepat dalam data namun kurang adaptif terhadap fluktuasi ekstrem dan pola musiman jangka panjang.
2. Model Neural Prophet memiliki performa menengah dengan nilai RMSE 11.74, MAE 14.42, dan MAPE 28.49%, serta R² sebesar 0.4055. Model ini unggul dalam interpretabilitas karena secara eksplisit memisahkan komponen tren dan musiman, sehingga memberikan pemahaman yang baik mengenai dinamika harga. Namun, kemampuannya dalam menangani data anomali masih terbatas.
3. Model LSTM terbukti sebagai model paling optimal dengan nilai RMSE 1.78, MAE 0.99, MAPE 2.13%, dan R² sebesar 0.9909. LSTM unggul karena kemampuannya mengenali pola *temporal dependency* yang kuat dalam data deret waktu serta mengatasi masalah *vanishing gradient*. Hasil ini menunjukkan bahwa LSTM paling mampu memprediksi tren harga cabai secara stabil dan akurat.
4. Dari hasil perbandingan tersebut, dapat disimpulkan bahwa LSTM merupakan model terbaik dalam memprediksi harga cabai rawit merah di Jawa Timur, baik dari sisi akurasi, kestabilan hasil, maupun kemampuan adaptasi terhadap dinamika harga jangka panjang. Hasil penelitian ini memberikan gambaran empiris bahwa pendekatan berbasis deep learning dapat menjadi alat pendukung keputusan (decision support tool) yang efektif dalam pengelolaan komoditas pangan.

5. Prediksi harga yang dihasilkan oleh model LSTM menunjukkan adanya pola kenaikan harga pada periode Ramadan dan akhir tahun, yang konsisten dengan tren historis dan teori permintaan musiman terhadap komoditas pangan strategis. Hal ini mengonfirmasi bahwa harga cabai rawit merah sangat dipengaruhi oleh siklus musiman, faktor cuaca, serta fluktuasi permintaan pasar.

6. Penelitian lanjutan disarankan untuk memperluas studi ke wilayah lain di Indonesia serta menerapkan pada komoditas lain seperti bawang merah, beras, atau cabai keriting yang dapat memperkaya literatur dan menguji generalisasi model dalam berbagai konteks pertanian nasional.

7. Penelitian lanjutan disarankan untuk memasukkan variabel eksternal seperti curah hujan, suhu, volume produksi, dan data logistik. Dengan menambahkan faktor tersebut, model prediksi dapat mencerminkan kondisi pasar yang lebih realistis dan memberikan hasil yang lebih komprehensif.

8. Penelitian lanjutan disarankan untuk mengombinasikan metode seperti LSTM-XGBoost atau LSTM-Prophet yang dapat dieksplorasi untuk menggabungkan keunggulan antara akurasi tinggi model deep learning dan interpretabilitas model statistik. Pendekatan hybrid berpotensi menghasilkan model prediksi yang lebih stabil dan mudah dipahami.

UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada seluruh pihak yang mendukung agar penelitian ini berhasil dilaksanakan dengan baik.

REFERENSI

- [1] A. Mandarsari, R. Anindita, and S. Budi, "Price Volatility Analysis of Cayenne Pepper (*Capsicum frutescens*) in East Java," *Agricultural Socio-Economics Journal*, vol. 20, no. 2, Apr. 2020. doi: 10.21776/UB.AGRISE.2020.020.2.5.
- [2] M. N. E. Brahmana, Sahara, and N. K. Hidayat, "Price Volatility Analysis of Red and Cayenne Pepper of Java Islands during Covid-19 Pandemic," *Journal of Economics, Finance and Accounting Studies*, vol. 4, no. 4, Sep. 2022. doi: 10.32996/jefas.2022.4.4.2.
- [3] I. Marina, D. Sukmawati, E. Juliana, and others, "Dinamika Pasar Komoditas Pangan Strategis: Analisis Fluktuasi Harga Dan Produksi," *Paspalum*, vol. 12, no. 1, Apr. 2024. doi: 10.35138/paspalum.v12i1.700.
- [4] A. M. Windhy and A. S. Jamil, "Peramalan Harga Cabai Merah Indonesia: Pendekatan ARIMA," *Agriekstensi*, vol. 20, no. 1, Jul. 2021. doi: 10.34145/agriekstensi.v20i1.1502.
- [5] N. M. Ginting, A. R. Lubis, and M. Zendrato, "Analisis Volatilitas, Integrasi Pasar Dan Transmisi Harga Cabai Merah Di Provinsi Sumatera Utara, Indonesia," *Agro Bali : Agricultural Journal*, vol. 6, no. 3, Nov. 2023. doi: 10.37637/ab.v6i3.1519.
- [6] L. R. Maula and T. S. M. Rianti, "Fluktuasi dan Peramalan Harga Cabai Rawit di Kabupaten Malang," *Media Agribisnis*, vol. 5, no. 1, May 2021. doi: 10.35326/agribisnis.v5i1.1179.
- [7] N. H. Hidayati, S. Anwar, and R. Rahmah, "Peramalan Harga Cabai Merah sebagai upaya menjaga Stabilitas Inflasi Kota Banda Aceh," *Agriekonomika*, vol. 11, no. 1, Aug. 2022. doi: 10.21107/agriekonomika.v11i1.11380.
- [8] D. Sukmawati, "Fluktuasi Harga Cabai Merah Keriting (*Capsicum annum* L) di Sentra Produksi dan Pasar Induk (Tinjauan Harga Cabai Merah Keriting di Kecamatan Cikajang dan Pasar Induk Kramat Jati Jakarta)," *Media Agribisnis*, vol. 1, no. 2, Apr. 2017. doi: 10.25157/MA.V1I2.58.
- [9] R. K. K. Sitepu, "Price Transmission in the Indonesian Red Chili Market: Static and Dynamic Models," *Jurnal Ekonomi Kuantitatif Terapan*, vol. 15, no. 2, Aug. 2022. doi: 10.24843/jekt.2022.v15.i02.p04.
- [10] A. Fauzi and V. Andriani, "Pengaruh meningkatnya harga cabai terhadap permintaan dan penawaran di Indonesia," *Jurnal Akuntansi dan Manajemen Bisnis*, vol. 3, no. 1, Apr. 2023. doi: 10.56127/jaman.v3i1.645.
- [11] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and practice*, 3rd ed. Melbourne, Australia: OTexts, 2021. [Online]. Available: <https://OTexts.com/fpp3>
- [12] G. E. Box, G. M. Jenkins, G. C. Reinsel, and others, *Time Series Analysis: Forecasting and Control*. San Francisco, CA, USA: Holden-Day, 1970.
- [13] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," in *Proc. 22nd ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, San Francisco, CA, USA, Aug. 2016, pp. 785–794, doi: 10.1145/2939672.2939785.
- [14] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [15] S. J. Taylor and B. Letham, "Forecasting at scale," *Amer. Statist.*, vol. 72, no. 1, pp. 37–45, Jan. 2018, doi: 10.1080/00031305.2017.1380080.
- [16] O. Triebe, H. Hewamalage, and P. Pilyugina, "NeuralProphet: Explainable forecasting at scale," *arXiv:2111.15397v1*, Nov. 2021. [Online]. Available: <https://arxiv.org/abs/2111.15397>.