

## **Perbandingan Model ARIMA dan Hybrid ARIMA-Random Forest untuk Peramalan Harga Bawang Merah Harian di Provinsi Jawa Timur**

**Khusniatul Mawadah<sup>1</sup>, Affiati Oktaviarina<sup>2</sup>**

<sup>1,2</sup>Universitas Negeri Surabaya

<sup>2</sup>affiatioktaviarina@unesa.ac.id

### **ABSTRAK**

Harga bawang merah merupakan salah satu komoditas hortikultura strategis yang sering mengalami fluktuasi tinggi, khususnya pada data berfrekuensi harian. Volatilitas harga tersebut menimbulkan tantangan dalam perencanaan distribusi, pengendalian inflasi pangan, serta perumusan kebijakan. Penelitian ini bertujuan untuk membandingkan kinerja model Autoregressive Integrated Moving Average (ARIMA) dan model hybrid ARIMA–Random Forest dalam meramalkan harga bawang merah harian di Provinsi Jawa Timur. Data yang digunakan berupa data harga bawang merah harian periode Januari 2018 hingga Desember 2025 yang diperoleh dari Pusat Informasi Harga Pangan Strategis (PIHPS) Bank Indonesia. Data dipra-pemrosesan menggunakan metode Last Observation Carried Forward (LOCF) untuk menangani nilai hilang. Analisis deret waktu meliputi pemeriksaan stasioneritas, identifikasi dan pemodelan ARIMA, serta pengembangan model hybrid berbasis Random Forest pada residual ARIMA. Evaluasi kinerja model dilakukan menggunakan skema walk-forward evaluation pada horizon peramalan 1, 7, dan 14 hari dengan indikator Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Hasil penelitian menunjukkan bahwa model hybrid ARIMA–Random Forest memberikan kinerja yang lebih baik pada peramalan jangka sangat pendek (horizon 1 hari), sedangkan model ARIMA(3,0,1) menunjukkan kinerja yang stabil dan kompetitif pada horizon peramalan 7 dan 14 hari. Selain itu, hasil peramalan multi-langkah menggunakan ARIMA(3,0,1) menunjukkan kecenderungan penurunan harga secara bertahap dengan interval kepercayaan yang semakin melebar seiring bertambahnya horizon. Temuan ini menunjukkan bahwa pemilihan model peramalan perlu disesuaikan dengan panjang horizon dan tujuan analisis.

**Kata Kunci:** harga bawang merah; ARIMA; Random Forest; model hybrid; peramalan deret waktu

### **ABSTRACT**

The price of shallots is one of the strategic horticultural commodities that often experiences high fluctuations, especially in daily data. This price volatility poses challenges in distribution planning, food inflation control, and policy formulation. This study aims to compare the performance of the Autoregressive Integrated Moving Average (ARIMA) model and the ARIMA–Random Forest hybrid model in forecasting daily shallot prices in East Java Province. The data used are daily shallot prices from January 2018 to December 2025 obtained from the Bank Indonesia Strategic Food Price Information Center (PIHPS). The data was pre-processed using the Last Observation Carried Forward (LOCF) method to handle missing values. Time series analysis included stationarity testing, ARIMA identification and modeling, and the development of a Random Forest-based hybrid model on ARIMA residuals. Model performance was evaluated using a walk-forward evaluation scheme on a 1-, 7-, and 14-day forecasting horizon with the Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and Mean Absolute Percentage Error (MAPE) indicators. The results show that the ARIMA–Random Forest hybrid model performs better in very short-term forecasting (1-day horizon), while the ARIMA(3,0,1) model shows stable and competitive performance in 7- and 14-day forecasting horizons. In addition, multi-step forecasting results using ARIMA(3,0,1) show a gradual downward price trend with widening confidence intervals as the horizon increases. These findings indicate that the choice of forecasting model needs to be adjusted to the length of the horizon and the purpose of the analysis.

**Keywords:** shallot price; ARIMA; Random Forest; hybrid model; time series forecasting

## PENDAHULUAN

Komoditas hortikultura memiliki peran strategis dalam perekonomian Indonesia karena kontribusinya terhadap ketahanan pangan dan stabilitas harga pangan nasional (Syahrul, 2021). Salah satu komoditas hortikultura yang memiliki tingkat konsumsi tinggi serta berpengaruh signifikan terhadap inflasi pangan adalah bawang merah (Riyadh, 2023). Sebagai komoditas pangan strategis, harga bawang merah dikenal sering mengalami fluktuasi yang tinggi akibat dinamika pasokan, distribusi, serta pengaruh faktor musiman dan kondisi cuaca, yang berimplikasi langsung terhadap stabilitas inflasi pangan dan efektivitas kebijakan pengendalian harga (Hartono et al., 2023).

Provinsi Jawa Timur merupakan salah satu sentra produksi bawang merah terbesar di Indonesia. Meskipun demikian, stabilitas harga bawang merah di wilayah ini masih menunjukkan volatilitas yang relatif tinggi, khususnya pada data berfrekuensi harian (Nursiyono & Chotimah, 2021). Ketersediaan data harga bawang merah harian yang disediakan oleh Pusat Informasi Harga Pangan Strategis (PIHPS) Bank Indonesia membuka peluang untuk melakukan analisis deret waktu dengan resolusi temporal yang lebih tinggi. Analisis berbasis data harian memungkinkan penangkapan dinamika harga jangka pendek secara lebih komprehensif, termasuk lonjakan harga ekstrem dan fluktuasi harian yang sering luput teridentifikasi pada data mingguan atau bulanan (PIHPS Nasional, 2025).

Dalam kajian peramalan harga komoditas pangan, model Autoregressive Integrated Moving Average (ARIMA) masih banyak digunakan karena kemampuannya dalam menangkap pola linier dan ketergantungan temporal pada data historis (Box et al., 2015). Model ARIMA mampu memberikan hasil peramalan yang cukup akurat pada data harga komoditas hortikultura di Indonesia, khususnya pada horizon peramalan jangka pendek dengan tingkat volatilitas yang relatif moderat (Riyadh, 2023). Namun, kinerja ARIMA cenderung menurun ketika dihadapkan pada fluktuasi harga yang tajam dan perubahan struktural pada data harga bawang merah, yang mengindikasikan keterbatasan asumsi linieritas pada model tersebut (Nursiyono & Chotimah, 2021). Kondisi ini menunjukkan bahwa meskipun relevan sebagai model dasar, ARIMA memiliki keterbatasan dalam mendukung peramalan operasional pada data harga berfrekuensi tinggi yang sangat volatil, seperti untuk perencanaan distribusi harian, respons cepat terhadap lonjakan harga, dan penentuan intervensi pasar jangka pendek.

Untuk mengatasi keterbatasan model linier, pendekatan hybrid yang menggabungkan metode statistik dan pembelajaran mesin semakin banyak dikembangkan dalam beberapa tahun terakhir (Zhang, 2003). Pendekatan hybrid umumnya memanfaatkan model statistik untuk menangkap komponen linier utama deret waktu, sementara pola nonlinier yang tersisa dimodelkan menggunakan algoritma pembelajaran mesin (Khashei, Mehdi; Bijari, 2011).

Random Forest merupakan salah satu algoritma pembelajaran mesin yang banyak digunakan dalam kerangka hybrid karena kemampuannya dalam menangkap hubungan nonlinier yang kompleks, ketahanannya terhadap noise, serta stabilitas prediksi pada data yang berfluktuasi tinggi (Breiman, 2001). Penggabungan model ARIMA dengan metode pembelajaran mesin mampu menghasilkan kinerja peramalan yang lebih baik dibandingkan model ARIMA tunggal, khususnya pada data deret waktu yang mengandung pola nonlinier (Pai & Lin, 2005). Temuan tersebut menegaskan bahwa model statistik murni memiliki keterbatasan dalam menangkap dinamika kompleks pada data harga dan keuangan.

Selanjutnya, melalui studi komparatif pada berbagai model hybrid berbasis pembelajaran mesin menunjukkan bahwa kombinasi ARIMA dan Random Forest secara konsisten mampu meningkatkan akurasi peramalan pada data deret waktu yang bersifat

volatil dan kompleks (Bello-Angulo, 2022). Hasil penelitian tersebut memperkuat bukti empiris bahwa pendekatan hybrid lebih adaptif dibandingkan model linier tunggal dalam menghadapi fluktuasi ekstrem.

Meskipun penelitian mengenai peramalan harga bawang merah di Indonesia telah berkembang, sebagian besar kajian masih berfokus pada data berfrekuensi rendah, seperti data mingguan atau bulanan, serta menggunakan skema evaluasi statis yang kurang merepresentasikan kondisi peramalan operasional yang dinamis (Nursiyono & Chotimah, 2021). Kajian yang secara khusus memanfaatkan data harga bawang merah harian, menerapkan skema evaluasi berbasis *walk-forward*, serta membandingkan kinerja model ARIMA dan model hybrid ARIMA–Random Forest pada berbagai horizon peramalan masih relatif terbatas.

Penelitian ini berbeda dari studi sebelumnya karena secara eksplisit memanfaatkan data harga bawang merah berfrekuensi harian, menerapkan skema *walk-forward evaluation* pada horizon peramalan multi-langkah (1, 7, dan 14 hari), serta menekankan implikasi operasional peramalan, seperti untuk mendukung perencanaan distribusi harian, respons cepat terhadap lonjakan harga, dan penentuan intervensi pasar jangka pendek, bukan semata-mata perbandingan akurasi statistik. Pendekatan ini memungkinkan evaluasi kinerja model yang lebih realistis dan relevan dengan kebutuhan pengambilan keputusan jangka pendek hingga menengah di sektor pangan.

Berdasarkan celah penelitian tersebut, penelitian ini bertujuan untuk membandingkan kinerja model ARIMA dan model hybrid ARIMA–Random Forest dalam meramalkan harga bawang merah harian di Provinsi Jawa Timur menggunakan skema *walk-forward evaluation* pada horizon peramalan 1, 7, dan 14 hari. Hasil penelitian ini diharapkan dapat memberikan kontribusi empiris dalam pemilihan model peramalan yang sesuai dengan karakteristik data berfrekuensi tinggi serta mendukung pengambilan keputusan operasional dan kebijakan stabilisasi harga pangan.

## **METODE PENELITIAN**

### **Data dan Pra-pemrosesan**

Data harga bawang merah harian di Provinsi Jawa Timur diperoleh dari Pusat Informasi Harga Pangan Strategis (PIHPS) Bank Indonesia untuk periode Januari 2018 hingga Desember 2025. Data disusun sebagai deret waktu univariat dan diurutkan secara kronologis berdasarkan tanggal pengamatan. Pemeriksaan awal dilakukan untuk mengidentifikasi keberadaan nilai hilang serta pola kemunculan data hilang berturut-turut.

Nilai harga yang hilang diimputasi menggunakan metode *Last Observation Carried Forward* (LOCF) dengan mekanisme *forward fill*, di mana nilai yang hilang digantikan oleh nilai terakhir yang tersedia sebelumnya. Untuk mencegah terbentuknya nilai artifisial pada awal deret waktu, observasi awal yang belum memiliki nilai historis dihapus sebelum proses imputasi dilakukan. Pendekatan ini memastikan bahwa seluruh nilai imputasi hanya bergantung pada informasi masa lalu dan tidak menimbulkan kebocoran data masa depan (*future data leakage*).

### **Pemeriksaan Stasioneritas**

Pemeriksaan stasioneritas dilakukan secara bertahap sebelum pemodelan ARIMA. Tahap pertama difokuskan pada stasioneritas varians, mengingat data harga harian komoditas cenderung memiliki volatilitas yang berubah dari waktu ke waktu. Stabilitas varians dievaluasi menggunakan *rolling standard deviation* dengan jendela 30 hari untuk mengamati perubahan tingkat fluktuasi harga.

Apabila variasi varians menunjukkan ketidakstabilan yang signifikan, disiapkan opsi transformasi Box–Cox untuk menstabilkan varians. Setelah varians dinilai cukup stabil, stasioneritas mean diuji menggunakan uji Augmented Dickey–Fuller (ADF) dengan pemilihan lag otomatis berbasis kriteria Akaike Information Criterion (AIC). Hasil uji ADF digunakan sebagai dasar penentuan derajat differencing pada model ARIMA.

### Pembagian Data

Pembagian data dilakukan menggunakan pendekatan *time-based split* untuk menjaga urutan temporal. Data latih mencakup periode Januari 2018 hingga Desember 2023, sedangkan data uji mencakup periode Januari 2024 hingga Desember 2025. Skema ini dirancang agar evaluasi model dilakukan pada data yang benar-benar berada di luar periode pelatihan, sehingga merepresentasikan kondisi peramalan yang realistis.

### Pemodelan ARIMA

Pemodelan *Autoregressive Integrated Moving Average* (ARIMA) dilakukan menggunakan data latih yang telah melalui tahap pemeriksaan stasioneritas. Derajat differencing ditentukan berdasarkan hasil uji stasioneritas mean sehingga pemodelan dilakukan pada tingkat data yang sesuai dengan asumsi stasioneritas.

Identifikasi parameter autoregressive ( $p$ ) dan moving average ( $q$ ) dilakukan melalui analisis fungsi autokorelasi (ACF) dan fungsi autokorelasi parsial (PACF). Untuk memperoleh model yang optimal, dilakukan pencarian kombinasi parameter ARIMA ( $p$ ,  $d$ ,  $q$ ) menggunakan *grid search* terbatas dengan rentang  $p = 0$  hingga 3 dan  $q = 0$  hingga 2. Setiap kandidat model diestimasi menggunakan metode *Maximum Likelihood Estimation*.

Pemilihan model ARIMA terbaik didasarkan pada nilai Akaike Information Criterion (AIC) terendah, dengan Bayesian Information Criterion (BIC) digunakan sebagai kriteria pendukung. Kecukupan model kemudian dievaluasi melalui diagnostik residual yang meliputi analisis visual residual, fungsi autokorelasi residual, serta uji Ljung–Box pada beberapa lag untuk memastikan bahwa residual tidak mengandung autokorelasi yang signifikan.

### Pemodelan Random Forest pada Residual ARIMA

Untuk menangkap pola nonlinier yang tidak dapat direpresentasikan secara optimal oleh model ARIMA, residual dari model ARIMA pada data latih digunakan sebagai dasar pembentukan model Random Forest. Residual ARIMA ditransformasikan menjadi dataset *supervised learning* berbasis lag waktu, di mana residual pada waktu ke- $t$  digunakan sebagai variabel target dan residual pada waktu ke- $(t-1)$  hingga ke- $(t-14)$  digunakan sebagai variabel input. Pemilihan lag residual hingga 14 hari didasarkan pada pertimbangan siklus jangka pendek harga komoditas pangan yang umumnya menunjukkan pola fluktuasi mingguan hingga dua mingguan, sehingga mampu merepresentasikan dinamika residu yang relevan secara operasional.

Algoritma *Random Forest Regressor* dilatih dengan jumlah pohon keputusan sebanyak 400 ( $n\_estimators = 400$ ) untuk meningkatkan stabilitas prediksi dan mengurangi variansi model, mengingat residual ARIMA bersifat fluktuatif dan mengandung noise. Parameter  $random\_state = 42$  digunakan untuk memastikan reproduktibilitas hasil pelatihan, sedangkan  $min\_samples\_leaf = 2$  diterapkan untuk mengurangi risiko *overfitting* terhadap noise residual. Proses pelatihan dilakukan tanpa pengacakan urutan data sehingga struktur temporal residual tetap terjaga.

### Pemodelan Hybrid ARIMA-Random Forest

Model hybrid ARIMA–Random Forest dibangun dengan mengombinasikan prediksi linier yang dihasilkan oleh model ARIMA dan prediksi nonlinier residual yang dihasilkan oleh model Random Forest. Pada tahap peramalan, nilai prediksi hybrid diperoleh dengan menjumlahkan prediksi ARIMA dan prediksi residual dari Random Forest pada setiap horizon peramalan.

Untuk horizon peramalan lebih dari satu langkah, prediksi residual dilakukan secara iteratif menggunakan pendekatan *recursive forecasting*, di mana prediksi residual pada satu langkah digunakan kembali sebagai input untuk memprediksi residual pada langkah berikutnya. Pendekatan ini memastikan bahwa proses peramalan hanya memanfaatkan informasi historis yang tersedia pada saat peramalan dilakukan dan konsisten dengan skenario peramalan operasional. Dengan mekanisme ini, model hybrid mampu menghasilkan prediksi pada horizon 1, 7, dan 14 hari secara konsisten.

### Evaluasi Kinerja Model

Evaluasi kinerja model ARIMA dan model hybrid ARIMA–Random Forest dilakukan menggunakan skema *walk-forward evaluation*. Pada setiap langkah evaluasi, model ARIMA dan model Random Forest dilatih ulang menggunakan data historis hingga waktu tertentu, kemudian digunakan untuk menghasilkan prediksi sesuai dengan horizon peramalan yang ditetapkan. Skema ini dirancang untuk merepresentasikan kondisi peramalan yang realistis dan menghindari kebocoran informasi dari data masa depan.

Kinerja model dievaluasi pada horizon peramalan 1 hari, 7 hari, dan 14 hari ke depan menggunakan Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Penggunaan beberapa indikator kesalahan bertujuan untuk memberikan evaluasi yang komprehensif, di mana MAE mengukur kesalahan absolut rata-rata, RMSE memberikan penalti lebih besar terhadap kesalahan ekstrem, dan MAPE merepresentasikan kesalahan relatif terhadap skala harga.

## HASIL DAN PEMBAHASAN

### Deskripsi Data dan Pra-pemrosesan

Data harga bawang merah harian yang digunakan dalam penelitian ini mencakup periode Januari 2018 hingga Desember 2025 dengan total 2.922 observasi kalender. Setelah menghapus observasi awal yang tidak memiliki nilai historis serta melakukan imputasi data hilang menggunakan metode *Last Observation Carried Forward (LOCF)*, diperoleh sebanyak 2.921 observasi data harga yang lengkap dan siap untuk dianalisis. Satu observasi awal dihapus karena tidak memiliki nilai historis yang diperlukan untuk imputasi LOCF, sehingga imputasi hanya memanfaatkan informasi masa lalu.

Statistik deskriptif data harga bawang merah harian setelah proses imputasi LOCF disajikan pada Tabel 1.

Tabel 1. Statistik Deskriptif Harga Bawang Merah Harian

Statistik	Nilai (Rp)
Jumlah observasi	2.921
Rata-rata	30.662
Simpangan baku	8.862
Minimum	14.750
Kuartil 1	24.250
Median	29.550
Kuartil 3	35.450
Maksimum	71.300

Berdasarkan Tabel 1, harga bawang merah harian setelah proses imputasi LOCF memiliki nilai rata-rata sebesar Rp30.662 dengan median Rp29.550. Kedekatan antara nilai rata-rata dan median menunjukkan bahwa secara umum distribusi harga relatif seimbang, meskipun masih dipengaruhi oleh beberapa nilai ekstrem pada periode tertentu. Hal ini mengindikasikan bahwa lonjakan harga yang terjadi bersifat episodik dan tidak mendominasi keseluruhan distribusi data.

Nilai simpangan baku sebesar Rp8.862 tergolong cukup tinggi dibandingkan dengan nilai rata-rata, yang mencerminkan tingkat variasi harga yang besar. Kondisi ini menunjukkan bahwa harga bawang merah bersifat volatil, sejalan dengan karakteristik komoditas pangan strategis yang dipengaruhi oleh faktor musiman, ketidakpastian pasokan, serta dinamika permintaan harian.

Rentang harga yang lebar, dengan nilai minimum Rp14.750 dan maksimum mencapai Rp71.300, mengindikasikan adanya fluktuasi ekstrem dalam periode pengamatan. Perbedaan yang signifikan antara harga terendah dan tertinggi ini menunjukkan bahwa pasar bawang merah rentan terhadap shock jangka pendek, seperti gangguan produksi, distribusi, maupun kebijakan perdagangan.

Selain itu, nilai kuartil pertama (Q1) sebesar Rp24.250 dan kuartil ketiga (Q3) sebesar Rp35.450 menunjukkan bahwa 50% data harga berada dalam rentang yang cukup luas. Hal ini mengonfirmasi bahwa variasi harga tidak hanya disebabkan oleh nilai ekstrem, tetapi juga oleh fluktuasi yang terjadi secara konsisten dalam rentang harga menengah. Dengan demikian, distribusi harga bawang merah mencerminkan dinamika pasar yang kompleks dan tidak stabil.

Karakteristik statistik deskriptif ini memperkuat indikasi bahwa data harga bawang merah memiliki sifat heterogen dan tidak sepenuhnya linier. Oleh karena itu, diperlukan pendekatan pemodelan yang mampu menangkap variasi harga yang tinggi, ketidakstasioneran, serta kemungkinan pola nonlinier dalam deret waktu, sehingga mendukung penggunaan model hybrid pada tahap analisis selanjutnya.

Selanjutnya, untuk mengkaji dinamika harga secara temporal serta mengidentifikasi pola fluktuasi, tren, dan musiman, deret waktu harga bawang merah harian setelah imputasi LOCF ditampilkan pada Gambar 1.



Gambar 1. Deret Waktu Harga Bawang Merah Harian Setelah Imputasi LOCF

Gambar 1 menunjukkan pergerakan harga bawang merah harian setelah dilakukan proses *Last Observation Carried Forward* (LOCF) untuk menangani data hilang. Secara umum, harga bawang merah memperlihatkan fluktuasi yang tinggi dengan pola naik–turun yang tidak stabil sepanjang periode pengamatan 2018–2025. Volatilitas ini mengindikasikan bahwa harga bawang merah sangat sensitif terhadap berbagai faktor eksternal.

Terlihat adanya beberapa lonjakan harga yang ekstrem, khususnya pada sekitar tahun 2020, 2022, dan 2024, di mana harga meningkat tajam dalam waktu relatif singkat sebelum kembali menurun. Lonjakan tersebut dapat dikaitkan dengan gangguan pasokan, faktor musiman seperti periode hari besar keagamaan, kondisi cuaca ekstrem, maupun tekanan

inflasi dan distribusi. Pola ini menunjukkan adanya shock jangka pendek yang tidak dapat dijelaskan hanya oleh tren linier sederhana.

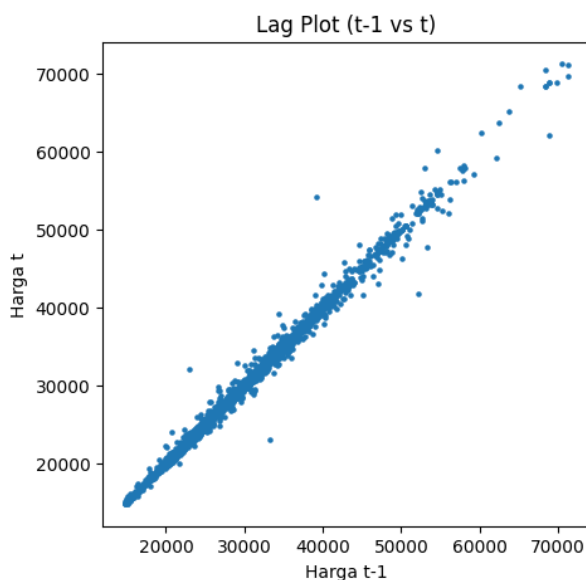
Selain lonjakan ekstrem, grafik juga memperlihatkan pola musiman yang berulang, di mana kenaikan dan penurunan harga cenderung terjadi pada periode tertentu setiap tahunnya. Hal ini mengindikasikan keberadaan komponen musiman (*seasonality*) yang cukup kuat, di samping tren jangka panjang yang cenderung meningkat pada beberapa tahun terakhir.

Karakteristik data yang bersifat nonlinier, tidak stasioner, dan memiliki volatilitas tinggi menunjukkan bahwa pendekatan pemodelan konvensional berbasis linier saja berpotensi kurang optimal. Oleh karena itu, penggunaan pendekatan model hybrid, yang menggabungkan metode statistik dan pembelajaran mesin, menjadi relevan untuk menangkap baik pola linier (tren dan musiman) maupun pola nonlinier yang muncul akibat fluktuasi ekstrem harga bawang merah.

### Hasil Pemeriksaan Stasioneritas

Pemeriksaan stasioneritas dilakukan untuk memastikan pemenuhan asumsi dasar dalam pemodelan deret waktu, yang mencakup stasioneritas varians dan stasioneritas mean.

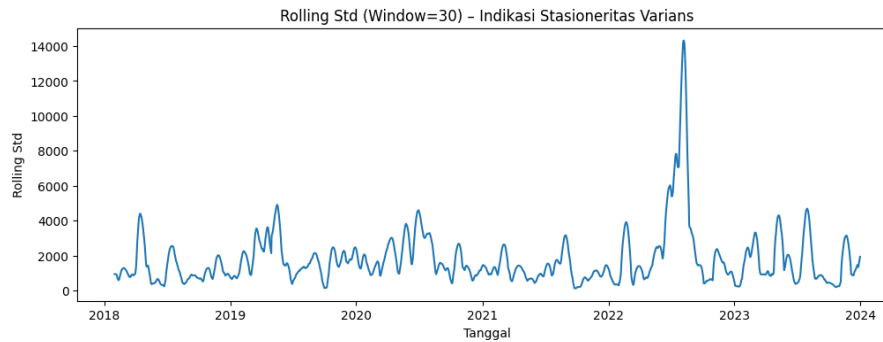
Sebagai langkah awal, ketergantungan temporal antar pengamatan dianalisis menggunakan *lag plot* antara harga pada waktu ke- $t$  dan  $t-1$ , sebagaimana ditampilkan pada Gambar 2.



Gambar 2. Lag Plot Harga Bawang Merah ( $t-1$  terhadap  $t$ )

Gambar 2 menunjukkan hubungan yang kuat dan hampir linier antara harga pada waktu  $t-1$  dan  $t$ . Sebaran titik yang mengikuti pola diagonal mengindikasikan adanya autokorelasi yang tinggi antar pengamatan berurutan. Hal ini menegaskan bahwa harga bawang merah pada suatu periode sangat dipengaruhi oleh harga pada periode sebelumnya, sehingga pendekatan pemodelan berbasis autoregresif relevan untuk digunakan.

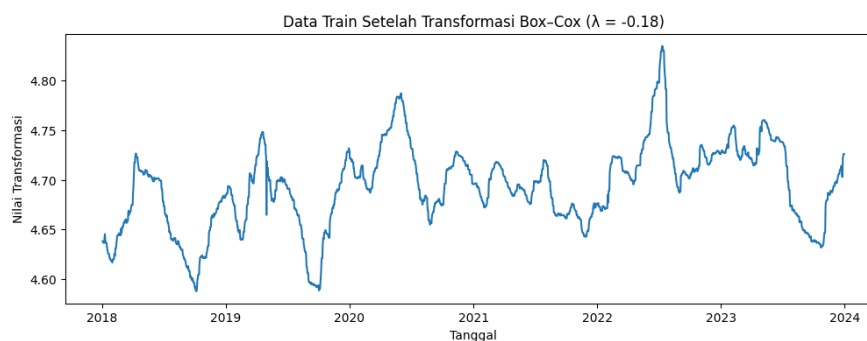
Selanjutnya, pemeriksaan stasioneritas varians dilakukan menggunakan pendekatan *rolling standard deviation* dengan jendela waktu 30 hari, sebagaimana ditunjukkan pada Gambar 3.



Gambar 3. Rolling Standard Deviation (Window = 30 Hari)

Berdasarkan Gambar 3, nilai *rolling standard deviation* mengalami fluktuasi yang signifikan sepanjang periode pengamatan. Terlihat adanya beberapa periode dengan peningkatan volatilitas yang tajam, khususnya pada sekitar tahun 2022. Kondisi ini menunjukkan bahwa varians data tidak bersifat konstan, sehingga data belum memenuhi asumsi stasioneritas varians. Pola tersebut mencerminkan adanya *volatility clustering*, yang umum dijumpai pada data harga komoditas.

Untuk menstabilkan varians data, dilakukan transformasi Box–Cox dengan parameter  $\lambda = -0,18$ . Hasil transformasi Box–Cox terhadap data harga bawang merah ditampilkan pada Gambar 4.



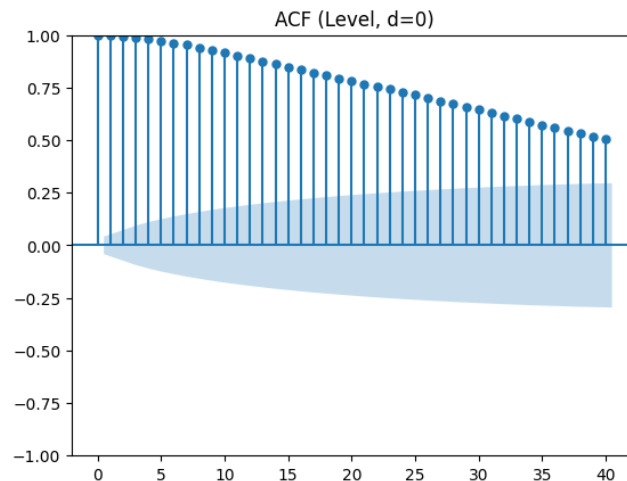
Gambar 4. Data Harga Bawang Merah Setelah Transformasi Box–Cox

Gambar 4 menunjukkan bahwa setelah transformasi Box–Cox, fluktuasi data menjadi lebih homogen dibandingkan dengan data pada level awal. Varians data tampak lebih stabil, sementara pola tren dan musiman tetap terjaga. Hal ini menunjukkan bahwa transformasi Box–Cox efektif dalam menstabilkan varians tanpa menghilangkan karakteristik utama deret waktu.

Selanjutnya, pengujian stasioneritas mean dilakukan menggunakan uji Augmented Dickey–Fuller (ADF) pada data hasil transformasi. Hasil uji ADF menunjukkan nilai statistik sebesar  $-3,7535$  dengan *p-value* sebesar  $0,0034$ . Nilai *p-value* yang lebih kecil dari taraf signifikansi 5% mengindikasikan bahwa data telah stasioner terhadap mean. Dengan demikian, derajat *differencing* ditetapkan sebesar  $d = 0$ , sehingga pemodelan ARIMA dilakukan pada data level hasil transformasi tanpa perlu dilakukan differencing tambahan.

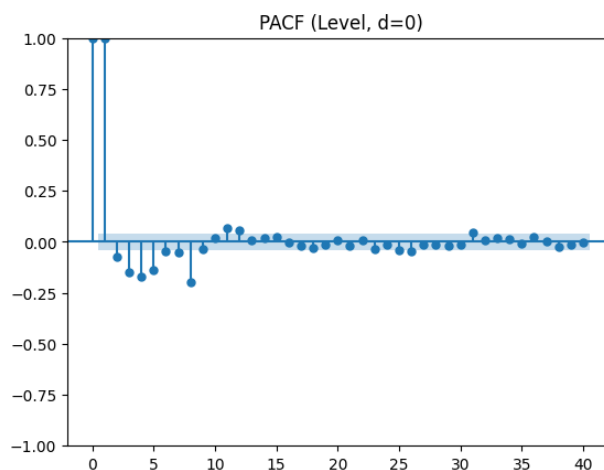
### Hasil Identifikasi dan Pemodelan ARIMA

Identifikasi parameter model ARIMA dilakukan pada data latih yang telah memenuhi asumsi stasioneritas terhadap mean, dengan derajat *differencing* ditetapkan sebesar  $d = 0$  berdasarkan hasil uji Augmented Dickey–Fuller sebelumnya. Penentuan orde autoregresif ( $p$ ) dan moving average ( $q$ ) dilakukan melalui analisis grafik *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF), sebagaimana ditampilkan pada Gambar 5 dan Gambar 6.



Gambar 5. Grafik ACF Data Latih (Level,  $d = 0$ )

Berdasarkan Gambar 5, grafik ACF menunjukkan pola peluruhan (*tailing off*) yang lambat dan bertahap, di mana nilai autokorelasi masih signifikan hingga lag yang cukup panjang. Pola ini mengindikasikan adanya ketergantungan temporal yang kuat dalam data dan menunjukkan bahwa komponen *moving average* berpotensi berperan dalam pembentukan model.



Gambar 6. Grafik PACF Data Latih (Level,  $d = 0$ )

Sementara itu, Gambar 6 memperlihatkan grafik PACF dengan pemotongan (*cut-off*) yang jelas hingga sekitar lag ke-3, di mana lag-lag awal menunjukkan nilai autokorelasi parsial yang signifikan, sedangkan lag selanjutnya berada di sekitar nol dan berada dalam batas kepercayaan. Pola ini mengindikasikan keberadaan komponen autoregresif dengan orde terbatas, khususnya hingga orde tiga.

Berdasarkan kombinasi pola peluruhan pada grafik ACF dan pemotongan pada grafik PACF, dilakukan pencarian kandidat model ARIMA menggunakan pendekatan *grid search* terbatas pada rentang  $p = 0-3$  dan  $q = 0-2$ , dengan derajat *differencing* ditetapkan sebesar  $d = 0$ . Seleksi model dilakukan berdasarkan nilai Akaike Information Criterion (AIC) dan Bayesian Information Criterion (BIC). Hasil evaluasi kandidat model disajikan pada Tabel 2.

Tabel 2. Kandidat Model ARIMA Berdasarkan Nilai AIC dan BIC

Model ARIMA	AIC	BIC
(3,0,1)	34329,86	34364,01
(2,0,2)	34403,16	34437,31
(3,0,0)	34483,05	34511,51
(1,0,2)	34508,14	34536,59
(2,0,0)	34541,58	34564,34


Berdasarkan Tabel 2, model ARIMA(3,0,1) memiliki nilai AIC dan BIC terendah dibandingkan dengan kandidat model lainnya. Hal ini menunjukkan bahwa model tersebut memberikan keseimbangan terbaik antara tingkat kecocokan terhadap data dan kompleksitas model.

Secara struktural, model ARIMA(3,0,1) mampu menangkap ketergantungan jangka pendek melalui tiga komponen autoregresif, serta mengakomodasi fluktuasi acak melalui satu komponen *moving average*. Pemilihan model ini juga konsisten dengan hasil analisis grafik ACF dan PACF, yang mengindikasikan dominasi komponen autoregresif dengan orde terbatas dan adanya efek *moving average* pada lag awal.

Dengan demikian, model ARIMA(3,0,1) ditetapkan sebagai model dasar (baseline) dan selanjutnya digunakan dalam tahap diagnostik residual, evaluasi kinerja peramalan, serta sebagai komponen linier dalam pengembangan model hybrid ARIMA–Random Forest pada tahap analisis berikutnya.

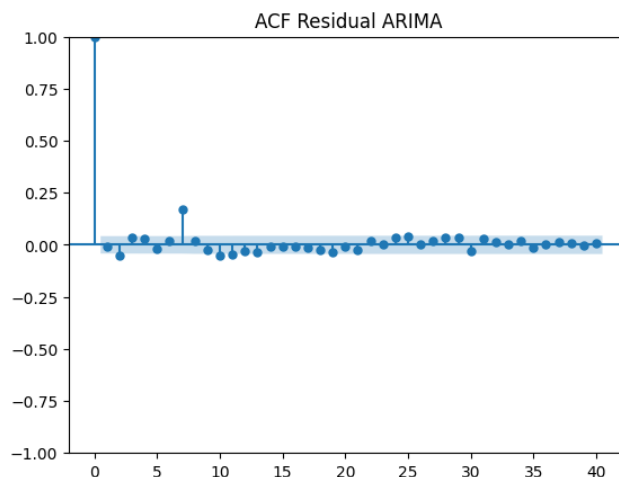
### Diagnostik Residual Model ARIMA

Diagnostik residual dilakukan untuk mengevaluasi kecukupan model ARIMA(3,0,1) dalam menangkap struktur dependensi data harga bawang merah. Evaluasi ini bertujuan untuk memastikan bahwa residual bersifat mendekati *white noise*, yaitu tidak memiliki pola sistematis yang tersisa. Visualisasi residual dan grafik *Autocorrelation Function* (ACF) residual ditampilkan pada Gambar 7 dan Gambar 8.



Gambar 7. Plot Residual Model ARIMA(3,0,1)

Berdasarkan Gambar 7, residual model ARIMA(3,0,1) berfluktuasi di sekitar nilai nol tanpa menunjukkan pola tren yang jelas. Hal ini mengindikasikan bahwa model telah berhasil menangkap komponen linier utama dalam data. Namun demikian, masih terlihat adanya fluktuasi residual dengan amplitudo yang bervariasi, yang mengindikasikan kemungkinan keberadaan pola kompleks yang belum sepenuhnya terakomodasi oleh model linier.



Gambar 8. Grafik ACF Residual Model ARIMA(3,0,1)

Selanjutnya, Gambar 8 menunjukkan bahwa sebagian besar nilai autokorelasi residual berada dalam batas kepercayaan, khususnya pada lag-lag awal. Hal ini mengindikasikan bahwa autokorelasi jangka pendek telah berhasil direduksi oleh model ARIMA. Namun, pada beberapa lag yang lebih panjang masih terlihat nilai autokorelasi yang signifikan, yang mengindikasikan adanya dependensi lemah yang tersisa.

Untuk menguji autokorelasi residual secara formal, dilakukan uji Ljung–Box pada beberapa lag, dengan hasil disajikan pada Tabel 3.

Tabel 3. Hasil Uji Ljung–Box Residual ARIMA(3,0,1)

Lag	Statistik Q	p-value
1	0,179	0,672
10	83,049	< 0,001
20	97,284	< 0,001
30	113,377	< 0,001
40	117,362	< 0,001

Berdasarkan Tabel 3, uji Ljung–Box pada lag 1 menghasilkan nilai *p-value* sebesar 0,672 ( $> 0,05$ ), yang menunjukkan bahwa tidak terdapat autokorelasi residual yang signifikan pada lag pendek. Hal ini mengindikasikan bahwa model ARIMA(3,0,1) telah mampu menangkap dependensi jangka pendek secara memadai.

Namun, pada lag yang lebih panjang (lag 10 hingga 40), nilai *p-value* menunjukkan hasil yang signifikan. Kondisi ini mengindikasikan bahwa masih terdapat dependensi residual pada horizon waktu yang lebih panjang. Fenomena ini umum terjadi pada data deret waktu dengan jumlah observasi besar, di mana uji Ljung–Box menjadi lebih sensitif terhadap autokorelasi kecil yang tersisa.

Secara keseluruhan, hasil diagnostik residual menunjukkan bahwa model ARIMA(3,0,1) telah efektif dalam menangkap struktur linier utama data harga bawang merah, namun masih menyisakan pola residual yang bersifat kompleks dan kemungkinan nonlinier. Oleh karena itu, diperlukan pendekatan lanjutan yang mampu memodelkan pola residual tersebut, sehingga penggunaan pendekatan model hybrid ARIMA–Random Forest menjadi relevan untuk meningkatkan kinerja peramalan.

### Perbandingan Kinerja Model ARIMA dan Hybrid ARIMA–Random Forest

Evaluasi kinerja model ARIMA dan model hybrid ARIMA–Random Forest dilakukan menggunakan skema *walk-forward evaluation* untuk menjaga konsistensi temporal dan menghindari *information leakage*. Pengujian dilakukan pada horizon peramalan 1, 7, dan 14 hari menggunakan data uji periode 2024–2025. Kinerja model dievaluasi menggunakan

Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE), yang masing-masing merepresentasikan kesalahan absolut rata-rata, sensitivitas terhadap kesalahan ekstrem, dan kesalahan relatif terhadap skala harga. Hasil evaluasi kinerja kedua model disajikan pada Tabel 4.

Tabel 4. Perbandingan Kinerja Model ARIMA dan Hybrid ARIMA–Random Forest

Model	Horizon (Hari)	MAE	RMSE	MAPE
ARIMA(3,0,1)	1	421,53	895,58	1,10
Hybrid ARIMA–RF	1	417,82	889,74	1,08
ARIMA(3,0,1)	7	1.888,97	2.860,57	4,69
Hybrid ARIMA–RF	7	1.894,24	2.859,03	4,71
ARIMA(3,0,1)	14	3.459,08	4.985,53	8,51
Hybrid ARIMA–RF	14	3.454,28	4.976,35	8,51

Berdasarkan Tabel 4, kinerja model ARIMA(3,0,1) dan model hybrid ARIMA–Random Forest menunjukkan perbedaan yang bergantung pada horizon peramalan. Pada horizon peramalan satu hari, model hybrid secara konsisten menghasilkan nilai kesalahan yang lebih rendah dibandingkan model ARIMA untuk seluruh indikator evaluasi, yang menunjukkan bahwa penambahan komponen nonlinier melalui Random Forest mampu memberikan koreksi terhadap residual ARIMA yang masih mengandung pola jangka sangat pendek. Sebaliknya, pada horizon peramalan 7 dan 14 hari, perbedaan kinerja antara kedua model relatif kecil dan cenderung setara, yang menunjukkan bahwa keunggulan model hybrid tidak bersifat konsisten pada peramalan multi-langkah.

Ditinjau dari Mean Absolute Error (MAE), model hybrid ARIMA–Random Forest menunjukkan kesalahan absolut rata-rata yang lebih rendah dibandingkan model ARIMA pada horizon peramalan satu hari. Hal ini mengindikasikan bahwa secara rata-rata, prediksi model hybrid lebih dekat ke nilai aktual pada peramalan jangka sangat pendek. Keunggulan tersebut mencerminkan kemampuan Random Forest dalam menangkap variasi residu harian yang tidak sepenuhnya dapat direpresentasikan oleh struktur linier ARIMA. Namun, pada horizon peramalan 7 dan 14 hari, perbedaan nilai MAE antara kedua model menjadi sangat kecil, bahkan pada horizon 7 hari model ARIMA menunjukkan nilai MAE yang sedikit lebih rendah. Temuan ini menunjukkan bahwa efektivitas koreksi nonlinier pada model hybrid menurun seiring bertambahnya horizon peramalan.

Berdasarkan Root Mean Squared Error (RMSE), pola yang serupa juga terlihat. Pada horizon peramalan satu hari, model hybrid menghasilkan nilai RMSE yang lebih rendah dibandingkan model ARIMA, yang mengindikasikan bahwa model hybrid lebih efektif dalam menekan kesalahan prediksi yang bersifat ekstrem (*large errors*) pada peramalan jangka sangat pendek. Kondisi ini menunjukkan bahwa Random Forest mampu mengoreksi fluktuasi residu yang besar ketika prediksi masih sangat dipengaruhi oleh informasi historis terdekat. Sebaliknya, pada horizon peramalan 7 dan 14 hari, perbedaan nilai RMSE antara kedua model menjadi sangat kecil. Fenomena ini dapat dijelaskan melalui mekanisme *error propagation* pada pendekatan *recursive forecasting*, di mana kesalahan prediksi pada satu langkah akan terakumulasi dan mengurangi keunggulan model hybrid pada peramalan multi-langkah.

Ditinjau dari Mean Absolute Percentage Error (MAPE), model hybrid ARIMA–Random Forest juga menunjukkan kinerja yang sedikit lebih baik dibandingkan model ARIMA pada horizon peramalan satu hari. Nilai MAPE yang lebih rendah mengindikasikan bahwa secara relatif terhadap skala harga, kesalahan prediksi model hybrid lebih kecil pada peramalan jangka sangat pendek. Namun, pada horizon peramalan 7 dan 14 hari, nilai MAPE kedua model relatif berdekatan dan bahkan hampir identik pada horizon 14 hari.

Hal ini menunjukkan bahwa secara proporsional terhadap nilai aktual, tingkat akurasi kedua model menjadi semakin serupa pada peramalan jangka menengah, sehingga kontribusi komponen nonlinier dalam model hybrid tidak memberikan peningkatan signifikan terhadap akurasi relatif pada horizon peramalan yang lebih panjang.

Secara keseluruhan, hasil evaluasi berdasarkan MAE, RMSE, dan MAPE menunjukkan bahwa model hybrid ARIMA–Random Forest unggul pada peramalan jangka sangat pendek, sementara model ARIMA tetap kompetitif dan stabil pada peramalan jangka menengah. Keterbatasan keunggulan model hybrid pada horizon peramalan yang lebih panjang berkaitan dengan akumulasi kesalahan pada pendekatan *recursive forecasting*, yang membatasi efektivitas koreksi nonlinier seiring bertambahnya horizon peramalan. Temuan ini sejalan dengan studi Pai dan Lin (2005) serta Bello-Angulo (2022), yang melaporkan bahwa keunggulan model hybrid paling menonjol pada peramalan jangka sangat pendek dan cenderung menurun pada peramalan multi-langkah.

### Hasil Peramalan Harga Bawang Merah Periode Mendatang

Peramalan harga bawang merah harian untuk periode 14 hari ke depan dilakukan menggunakan model ARIMA(3,0,1) yang dilatih pada seluruh data historis hingga 31 Desember 2025. Model ARIMA digunakan pada tahap ini karena kemampuannya dalam menghasilkan peramalan multi-langkah yang relatif stabil serta menyediakan interval kepercayaan, sehingga sesuai untuk analisis peramalan jangka menengah.

Hasil numerik peramalan harga bawang merah harian selama 14 hari ke depan disajikan pada Tabel 5.

Tabel 5. Hasil Peramalan Harga Bawang Merah Harian 14 Hari ke Depan (ARIMA(3,0,1))

Tanggal	Ramalan (Rp)	Batas Bawah 95%	Batas Atas 95%
1 Jan 2026	39.883	38.526	41.240
2 Jan 2026	39.502	37.545	41.460
3 Jan 2026	39.137	36.634	41.640
4 Jan 2026	38.787	35.769	41.805
5 Jan 2026	38.452	34.938	41.966
...	...	...	...
14 Jan 2026	36.011	28.537	43.486

Berdasarkan Tabel 5, nilai ramalan menunjukkan kecenderungan penurunan harga bawang merah secara bertahap sepanjang horizon peramalan. Selain itu, interval kepercayaan 95% terlihat semakin melebar pada horizon yang lebih panjang. Kondisi ini mencerminkan meningkatnya tingkat ketidakpastian prediksi seiring bertambahnya langkah peramalan, yang merupakan karakteristik umum dalam peramalan deret waktu.

Secara visual, hasil peramalan harga bawang merah harian ditampilkan pada Gambar 9, yang memperlihatkan data historis hingga akhir tahun 2025 serta hasil peramalan 14 hari ke depan beserta interval kepercayaan 95%.



Gambar 9. Peramalan Harga Bawang Merah Harian 14 Hari ke Depan (ARIMA(3,0,1))

Berdasarkan Gambar 9, pola peramalan mengikuti dinamika data aktual pada periode akhir pengamatan. Transisi dari data historis ke hasil peramalan berlangsung secara halus tanpa lonjakan yang tidak wajar, yang mengindikasikan bahwa model mampu mempertahankan kontinuitas pola deret waktu. Arah pergerakan hasil peramalan yang cenderung menurun sejalan dengan kecenderungan data aktual pada akhir periode historis, menunjukkan bahwa model berhasil menangkap kecenderungan jangka pendek yang terkandung dalam data.

Selain itu, fluktuasi hasil peramalan terlihat lebih halus dibandingkan dengan data aktual. Hal ini mengindikasikan bahwa komponen variasi acak jangka pendek telah tereduksi dalam proses peramalan, sehingga proyeksi yang dihasilkan lebih stabil dan berfokus pada pola sistematis deret waktu.

### **Peramalan Hybrid Jangka Sangat Pendek**

Sebagai pelengkap analisis, dilakukan peramalan satu hari ke depan menggunakan model hybrid ARIMA–Random Forest. Model hybrid menghasilkan nilai ramalan sebesar Rp40.163 untuk tanggal 1 Januari 2026, yang sedikit lebih tinggi dibandingkan hasil ramalan satu langkah dari model ARIMA.

Perbedaan nilai ramalan tersebut mencerminkan kontribusi komponen nonlinier yang ditangkap oleh algoritma Random Forest pada residual ARIMA. Penyesuaian tambahan ini meningkatkan sensitivitas model terhadap pola jangka sangat pendek yang tidak sepenuhnya tertangkap oleh model linier.

Namun demikian, mengingat potensi akumulasi kesalahan pada peramalan residual secara multi-langkah, penggunaan model hybrid dibatasi pada horizon peramalan sangat pendek. Untuk peramalan jangka menengah dan lebih panjang, model ARIMA tetap digunakan karena stabilitasnya dalam menghasilkan proyeksi multi-langkah serta kemampuannya dalam menyediakan interval kepercayaan.

### **PENUTUP**

Penelitian ini menunjukkan bahwa harga bawang merah harian di Provinsi Jawa Timur memiliki volatilitas yang tinggi dan dinamika jangka pendek yang kompleks, sehingga memerlukan pendekatan peramalan yang mampu menangkap pola linier dan nonlinier secara bersamaan. Hasil evaluasi menunjukkan bahwa model hybrid ARIMA–Random Forest memberikan kinerja yang lebih baik pada peramalan jangka sangat pendek (1 hari), sedangkan pada horizon peramalan yang lebih panjang (7 dan 14 hari), model ARIMA tetap menunjukkan kinerja yang kompetitif dan stabil.

Temuan ini mengindikasikan bahwa tidak terdapat satu model peramalan yang unggul secara universal untuk seluruh horizon peramalan. Model hybrid lebih sesuai untuk mendukung kebutuhan peramalan operasional jangka sangat pendek, seperti respons cepat terhadap lonjakan harga dan perencanaan distribusi harian, sementara model ARIMA lebih tepat digunakan untuk peramalan multi-langkah yang memerlukan kestabilan prediksi dan penyediaan interval kepercayaan.

Penelitian ini memiliki keterbatasan, terutama pada penggunaan metode imputasi Last Observation Carried Forward (LOCF) yang berpotensi mempertahankan nilai konstan pada periode data hilang serta pendekatan pemodelan yang masih bersifat univariat. Oleh karena itu, penelitian selanjutnya disarankan untuk mengevaluasi metode imputasi alternatif yang lebih adaptif terhadap volatilitas, mengembangkan model hybrid dengan algoritma nonlinier lain, serta memasukkan variabel eksogen yang relevan guna meningkatkan akurasi

dan relevansi peramalan dalam mendukung pengambilan keputusan operasional dan kebijakan stabilisasi harga pangan.

### UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih kepada Program Studi S1 Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Surabaya atas dukungan akademik yang diberikan selama pelaksanaan penelitian ini. Penulis juga menyampaikan apresiasi kepada dosen pembimbing yang telah memberikan arahan, masukan, dan diskusi yang konstruktif dalam penyusunan dan penyempurnaan artikel ini. Selain itu, penulis mengucapkan terima kasih kepada Pusat Informasi Harga Pangan Strategis (PIHPS) Bank Indonesia atas ketersediaan data harga pangan yang digunakan dalam penelitian ini.

### REFERENSI

- Bello-Angulo, D. (2022). Hybrid machine learning models for time series forecasting: A comparative study. *Applied Soft Computing*, 115. <https://doi.org/10.1016/j.asoc.2021.108205>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control* (5th ed.). Wiley.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Hartono, R., Rahman, M. S., Retnoningsih, D., & Shaleh, M. I. (2023). Price Volatility of Horticulture Commodity During the Pandemic in East Java, Indonesia. In *Habitat* (Vol. 34, Issue 3, pp. 277–288). <https://doi.org/10.21776/ub.habitat.2023.034.3.25>
- Khashei, Mehdi; Bijari, M. (2011). An artificial neural network (p, d, q) model for time series forecasting. *Expert Systems with Applications*, 38(1), 479–489. <https://doi.org/10.1016/j.eswa.2010.06.044>
- Nursiyono, J. A., & Chotimah, C. (2021). Badan Pusat Statistik Provinsi Jawa Timur. In *Jurnal Ilmiah Teori dan Aplikasi Statistika* (Vol. 14, Issue 1).
- Pai, P. F., & Lin, C. S. (2005). A hybrid ARIMA and support vector machines model in stock price forecasting. *Omega*, 33(6), 497–505. <https://doi.org/10.1016/j.omega.2004.07.024>
- PIHPS Nasional. (2025). Informasi Harga Pangan Antar Daerah : Harga bawang merah. In *PIHPS Nasional*. Bank Indonesia. <https://www.bi.go.id/hargapangan/>
- Riyadh, M. I. (2023). Factors Influencing the Prices of Red Chili and Shallots in Indonesia: Analysis of the Impact on the Global Market. *International Journal of Social Service and Research*, 3(10), 2470–2476. <https://doi.org/10.46799/ijssr.v3i10.560>
- Syahrul. (2021). Rencana Strategis Kementerian Pertanian Tahun 2020-2024. *Salinan Keputusan Menteri Pertanian Republik Indonesia*, 1–161.
- Zhang, P. G. (2003). Time series forecasting using a hybrid ARIMA and neural network model. In *Neurocomputing* (Vol. 50). [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)