

## Forecasting The Price of Red Bird's Eye Chili in Southeast Sulawesi Province Containing Outlier Data Using ARIMA Method with Iterative Procedure

### Peramalan Harga Cabai Rawit Merah di Provinsi Sulawesi Tenggara yang Mengandung Data *Outlier* Menggunakan Metode ARIMA dengan Prosedur Iteratif

Astrid Widyaningsih<sup>1</sup>, Makkulau<sup>2</sup>, dan Lilis Laome<sup>3\*</sup>

<sup>1,2,3</sup> Department of Statistics, Halu Oleo University, Kendari, Indonesia

Email: <sup>1</sup>[astridwidyaningsih003@gmail.com](mailto:astridwidyaningsih003@gmail.com), <sup>2</sup>[kulau.statistika@gmail.com](mailto:kulau.statistika@gmail.com),

<sup>3</sup>[lilis.la\\_ome@uho.ac.id](mailto:lilis.la_ome@uho.ac.id)

\*Corresponding author

#### Abstract

The price of red bird's eye chili in Southeast Sulawesi Province often experiences fluctuations that are detrimental to farmers. This study aims to forecast the price of red bird's eye chili using the ARIMA model and to correct outliers that affect the model's accuracy. The ARIMA(2,1,1) model was selected as the best-fitting model after detecting and correcting four innovational outliers (IO). The correction process resulted in a decrease in the Mean Squared Error (MSE) from 50,602,363 to 38,245,864. The 20-week-ahead forecast indicates a downward trend in prices, with increasingly stable prediction intervals. This method proves effective in improving model accuracy and providing more reliable information for decision-making.

**Keywords:** ARIMA, Forecasting, Red Bird's Eye Chili, Outlier, Innovational Outlier, MSE

#### Abstrak

Harga cabai rawit merah di Provinsi Sulawesi Tenggara sering mengalami fluktuasi yang merugikan petani. Penelitian ini bertujuan untuk meramalkan harga cabai rawit merah menggunakan model ARIMA serta mengoreksi outlier yang memengaruhi akurasi model. Model ARIMA(2,1,1) dipilih sebagai model terbaik setelah dilakukan deteksi dan koreksi terhadap empat innovational outlier (IO). Hasil koreksi menunjukkan penurunan nilai Mean Squared Error (MSE) dari 50.602.363 menjadi 38.245.864. Peramalan untuk 20 minggu ke depan menunjukkan kecenderungan penurunan harga di masa mendatang, dengan rentang prediksi yang semakin stabil. Metode ini terbukti efektif meningkatkan akurasi model dan memberikan informasi yang lebih andal bagi pengambilan keputusan.

**Kata Kunci:** ARIMA, Peramalan, Cabai Rawit Merah, Outlier, Innovational Outlier, MSE



## **1. PENDAHULUAN**

Komoditas pertanian memiliki peran penting, tetapi fluktuasi harganya kerap membebani konsumen dan menimbulkan ketidakpastian pendapatan bagi petani. Ketidakstabilan iklim juga memperparah volatilitas harga, sehingga menyulitkan pemerintah menjaga keseimbangan pasokan dan permintaan [7]. Cabai merupakan komoditas hortikultura bernilai ekonomi tinggi di Indonesia, namun harganya sangat berfluktuasi dan berkontribusi pada inflasi. Kenaikan harga umumnya terjadi pada musim hujan, bulan Ramadan, dan menjelang hari-hari besar keagamaan [12]. Secara global, peramalan harga menjadi penting karena berkaitan dengan ketahanan pangan. Dengan meningkatnya populasi, prediksi harga yang akurat membantu berbagai pihak memastikan ketersediaan pangan dan mendukung pembangunan ekonomi [16].

Data dari PIHPS menunjukkan bahwa harga cabai rawit merah secara nasional melonjak dari Rp55.600/kg (10 Oktober 2023) menjadi Rp99.500/kg (11 Desember 2023), sementara di Sulawesi Tenggara mencapai Rp135.650/kg [2]. Fluktuasi ini menimbulkan risiko kerugian bagi petani, sehingga diperlukan metode peramalan yang dapat memprediksi harga secara akurat.

Salah satu solusi untuk mendukung para pengambil keputusan terkait stabilisasi harga adalah dengan melakukan prediksi harga. Model Autoregressive Integral Moving Average (ARIMA), yang merupakan salah satu metode peramalan deret waktu yang paling umum dan banyak digunakan, karena dapat secara simultan memperhitungkan ketergantungan hukum perubahan variabel target pada deret waktu serta interferensi fluktuasi acak terhadap dampak deret waktu dalam proses pencocokan deret waktu, dan telah menunjukkan tingkat akurasi dan reliabilitas yang sangat baik dalam peramalan tren [17]. Namun, keberadaan pencilan (outlier), khususnya innovational outlier (IO), dapat mengganggu akurasi model ARIMA secara signifikan. Oleh karena itu, diperlukan pendekatan seperti prosedur iteratif untuk mendeteksi dan mengoreksi IO secara efektif.

## **2. Tinjauan Pustaka**

### **2.1 Peramalan**

Peramalan adalah menebak atau memperkirakan suatu situasi di masa depan berdasarkan kondisi masa lalu dan saat ini yang diperlukan untuk menentukan kapan suatu peristiwa akan terjadi, sehingga tindakan yang tepat dapat diambil [11]. Peramalan Deret Waktu merupakan alat penting untuk membuat prediksi berdasarkan data historis yang dikumpulkan dari waktu ke waktu. Dengan memanfaatkan berbagai model statistik dan pembelajaran mesin, bisnis dan peneliti dapat memprediksi peristiwa, tren, dan perilaku di masa mendatang, mulai dari keuangan hingga prakiraan cuaca [6].

## 2.2 Analisis Deret Waktu

Deret waktu adalah rangkaian data yang diamati dari waktu ke waktu, di mana nilai pada periode berikutnya dipengaruhi oleh nilai sebelumnya. Dengan membangun model matematika, peneliti dapat memahami perilaku deret waktu dan membuat prediksi untuk periode mendatang [9].

Analisis deret waktu adalah salah satu prosedur statistik yang diterapkan untuk memprediksi struktur probabilitas dari kondisi di masa depan dalam kerangka pengambilan keputusan. Pemodelan deret waktu sering dikaitkan dengan proses peramalan nilai karakteristik tertentu pada periode yang akan datang [11]. Peramalan deret waktu memanfaatkan data historis untuk memprediksi nilai di masa depan dan banyak digunakan dalam bidang energi, keuangan, hingga meteorologi untuk mengantisipasi perubahan dan tren [10].

## 2.3 Outlier

Outlier adalah titik data yang menyimpang jauh dari pola umum karena mekanisme atau proses yang berbeda. Kehadirannya perlu diperhatikan karena dapat menimbulkan bias dalam analisis statistik dan pemodelan, sehingga deteksi outlier menjadi tahap prapemrosesan yang penting dalam statistika dan ilmu data [4]. Deteksi outlier diperlukan untuk memastikan keandalan analisis, menemukan kejadian tidak biasa, memvalidasi model, dan menjaga kualitas data. Salah satu metode sederhana adalah aturan 3-sigma, yaitu mengidentifikasi data sebagai outlier jika jaraknya dari rerata melebihi tiga kali deviasi standar [8].

## 2.4 Metode ARIMA

Autoregressive Integrated Moving Average (ARIMA) adalah teknik analisis deret waktu yang sering digunakan untuk memprediksi data masa depan. Model ARIMA sepenuhnya mengabaikan variabel independen saat membuat prakiraan. Untuk prediksi jangka pendek yang presisi, ARIMA menggunakan nilai historis dan terkini dari variabel dependen. ARIMA tepat ketika observasi dari deret waktu tersebut terkait secara statistik [12].

Model ARIMA digunakan berdasarkan asumsi bahwa data time series yang digunakan harus stasioner yang artinya rata-rata dan variansi dari data tersebut adalah konstan [13].

Model ARIMA  $(p,d,q)$  yang dimana orde  $p$  menyatakan operator AR, orde  $d$  menyatakan hasil dari *differencing* dan orde  $q$  menyatakan operator dari MA [1]. Bentuk umum model ARIMA adalah sebagai berikut:

$$\phi_p(B)(1-B)^d Y_t = \theta_q(B)\alpha_t$$

$$\left( (1 - \phi_1 B) - (1 - \phi_p B^p) \right) (1 - B)^d Y_t = \left( (1 - \theta_1 B) - (1 - \theta_p B^p) \right) \alpha_t \quad (2.1)$$

keterangan:

$Y_t$  : Nilai deret waktu pada waktu ke- $t$

- $\phi_p$  : Koefisien *autoregressive*  
 $\theta_p$  : Koefisien *moving average*  
 $\alpha_t$  : Sisaan pada saat ke- $t$   
 $p$  : Derajat *autoregressive*  
 $q$  : Derajat *moving average*  
 $d$  : *differencing*  
 $B$  : Operator *backshift*

## 2.5 ARIMA dengan Deteksi Outlier

Tipe *outlier* pada data time series, yaitu *Additive Outlier* (AO) dan *Innovational Outlier* (IO). IO tidak hanya memengaruhi observasi pada saat guncangan terjadi, tetapi juga memengaruhi observasi selanjutnya melalui struktur dinamis deret waktu. Sebaliknya, AO menghilangkan observasi ekstrem tanpa bergantung pada dinamika deret. Sementara itu, IO mungkin lebih cocok dalam kasus-kasus seperti krisis keuangan, perang, atau bencana alam, di mana perekonomian mungkin membutuhkan waktu yang cukup lama untuk pulih [3].

## 2.6 Prosedur Iteratif

Keberadaan outlier sering membuat nilai perkiraan jauh dari data asli atau memiliki nilai residual yang sangat besar, oleh karena itu diperlukan prosedur untuk mendeteksi dan mengurangi pengaruh outlier [18]. Sadik, dkk. [15] mengutip dari Chang, dkk. [5] yang memperkenalkan Prosedur iteratif sebagai suatu prosedur mendeteksi terjadinya pencilan AO maupun IO. Prosedur ini dirancang untuk mendeteksi keberadaan pencilan serta mengidentifikasi jenis atau tipe pencilan secara simultan.

Berikut adalah langkah-langkah prosedur iteratif:

1. Model deret waktu ( $Y_t$ ) diasumsikan bebas pencilan, kemudian hitung residual ( $\hat{\epsilon}_t$ ) dari model dugaan :

$$\hat{\epsilon}_t = \hat{\pi}(B)Y_t = \frac{\hat{\phi}(B)}{\hat{\theta}(B)}Y_t \quad \text{dan} \quad \sigma_a^2 = \frac{1}{n} \sum_{t=1}^n \hat{\epsilon}_t^2 \quad (2.2)$$

Hitung  $\hat{\lambda}_{1,t}$  dan  $\hat{\lambda}_{2,t}$  untuk  $t = 1, 2, \dots, n$  menggunakan model dugaan, kemudian tentukan:

$$\hat{\lambda}_T = \max_t \max_i \{|\hat{\lambda}_{i,t}|\} \quad (2.3)$$

dimana T adalah waktu ketika nilai maksimum terjadi. Pencilan tipe AO terjadi jika  $\hat{\lambda}_T = |\hat{\lambda}_{1,t}| > C$ , dimana  $C$  merupakan nilai kritis yang besarnya sama dengan tiga ( $C = 3$ ).

Kemudian data  $Y_t$  dimodifikasi menggunakan:

$$\tilde{Y}_t = Y_t - \hat{\omega}_{AT} I_t^{(T)} \quad (2.4)$$

dimana:

- $\tilde{Y}_t$  : Data yang telah dikoreksi setelah menghilangkan efek pencilan  
 $Y_t$  : Data asli pada waktu  $t, j$

$\hat{\omega}_{AT}$  : Estimasi besar dampak pencilan dalam model

$I_t^{(T)}$  : Variabel indikator pencilan pada waktu  $T$

Kemudian hitung residual yang baru menggunakan:

$$\tilde{e}_t = \hat{e}_t - \hat{\omega}_{AT} \hat{\pi}(B) I_t^{(T)} \quad (2.5)$$

dengan:

$\tilde{e}_t$  : Residual yang telah dikoreksi setelah menghilangkan efek pencilan

$e_t$  : Residual dari model ARIMA sebelum koreksi pencilan

$\hat{\omega}_{AT}$  : Estimasi besar dampak pencilan terhadap residual

$\hat{\pi}B$  : Operator polinomial dalam *backward shift* operator  $B$ , yang digunakan untuk merepresentasikan struktur dependensi dalam residual

$I_t^{(T)}$  : Variabel indikator pencilan pada waktu  $T$

2. Hitung kembali nilai  $\hat{\lambda}_{1,t}$  dan  $\hat{\lambda}_{2,t}$  dari nilai residual yang telah dimodifikasi dan  $\tilde{\sigma}_\alpha^2$ , kemudian ulangi langkah 2 sampai semua pencilan terdeteksi. Untuk inisial penduga bagi  $(B)$  tidak diubah. Jika setelah iterasi tertentu tidak ditemukan lagi pencilan (*outlier*) dalam data residual, maka iterasi dihentikan secara otomatis.

## 2.7 Cabai Rawit

Cabai merupakan bahan penting dalam berbagai makanan dan merupakan komoditas pangan utama. Sebagai komoditas pertanian, harga cabai memiliki volatilitas yang tinggi akibat faktor musiman, keterbatasan pasokan, dan fluktuasi permintaan. Cabai juga memiliki masa simpan yang terbatas dan rentan terhadap penurunan kualitas. Kerentanan cabai menyebabkan petani berusaha menjual cabai secepat mungkin agar kualitasnya tidak menurun. Kesibukan petani dalam menjual cabai menyebabkan harga anjlok tajam ketika panen sedang melimpah [14].

## 3. METODE PENELITIAN

### 3.1 Data Penelitian

Penelitian ini menggunakan data sekunder berupa harga mingguan cabai rawit merah di Provinsi Sulawesi Tenggara, yang diperoleh dari situs resmi Bank Indonesia. Periode data yang dianalisis mencakup Januari 2023 hingga Maret 2025. Data disusun dalam bentuk deret waktu dengan frekuensi mingguan.

### 3.2 Langkah-langkah Analisis

Tahapan analisis yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. Analisis deskriptif data untuk mengidentifikasi karakteristik distribusi harga dan kemungkinan pencilan.
2. Uji stasioneritas dengan Augmented Dickey-Fuller (ADF) dan *differencing* jika diperlukan.
3. Identifikasi ordo model ARIMA berdasarkan pola ACF dan PACF.

4. Estimasi parameter ARIMA menggunakan metode Maximum Likelihood Estimation (MLE).
5. Diagnostik residual meliputi uji Ljung-Box dan uji normalitas Kolmogorov-Smirnov.
6. Deteksi dan koreksi IO menggunakan prosedur iteratif
7. Evaluasi kinerja model sebelum dan sesudah koreksi IO menggunakan MSE dan MAPE.
8. Peramalan harga selama 20 minggu ke depan.

## 4. HASIL DAN PEMBAHASAN

### 4.1 Analisis Deskriptif

Deskriptif variabel penelitian dilakukan untuk memberikan gambaran umum terkait variabel penelitian yang digunakan. Penelitian ini menggunakan data sekunder yang diperoleh yang bersumber dari Pusat Informasi Harga Pangan Strategis (PIHPS) Nasional oleh Bank Indonesia yaitu data harga cabai rawit merah di Provinsi Sulawesi Tenggara dari bulan Januari 2023 sampai Maret 2025, yang terdiri dari 117 data.


**Tabel 4.1.** Statistik Deskriptif Harga Cabai Rawit Merah

Variabel	Minimum	Maksimum	Rata-Rata	Standar Deviasi
Harga Cabai Rawit Merah	26.250	138.150	61.608,5	24.928,7

Tabel 4.1 menunjukkan plot data harga cabai rawit merah di Provinsi Sulawesi Tenggara periode Januari 2023 sampai Maret 2025. Secara umum, data menunjukkan fluktuasi yang cukup signifikan dengan adanya beberapa lonjakan tajam pada titik-titik tertentu.

### 4.2 Pendeteksian *Outlier*

Untuk melihat apakah data harga cabai rawit di Provinsi Sulawesi Tenggara mengandung *outlier* atau tidak, maka perlu dilakukan pendeteksian *outlier* dengan cara melihat hasil *boxplot* sebagai berikut:



**Gambar 4.1.** *Boxplot* Data Harga Cabai Rawit Merah

Gambar 4.1 menunjukkan sebaran data deret waktu dengan sebagian besar nilai berada antara 45.000 hingga 75.000 dan median sekitar 60.000. Namun, tampak beberapa titik ekstrim di atas 120.000 hingga 140.000 yang teridentifikasi sebagai *outlier*. Nilai-nilai pencilan ini dapat memengaruhi akurasi analisis dan peramalan.

### 4.3 Metode ARIMA

#### Uji Stasioneritas

Sebelum memodelkan data menggunakan metode ARIMA, terlebih dahulu perlu dilakukan pengujian apakah data bersifat stasioner. Hal ini penting karena tanpa kestasioneran, model deret waktu seperti ARIMA dapat memberikan hasil yang tidak valid dan kurang akurat. Uji kestasioneran data dilakukan dengan menggunakan metode *Augmented Dickey-Fuller* (ADF).

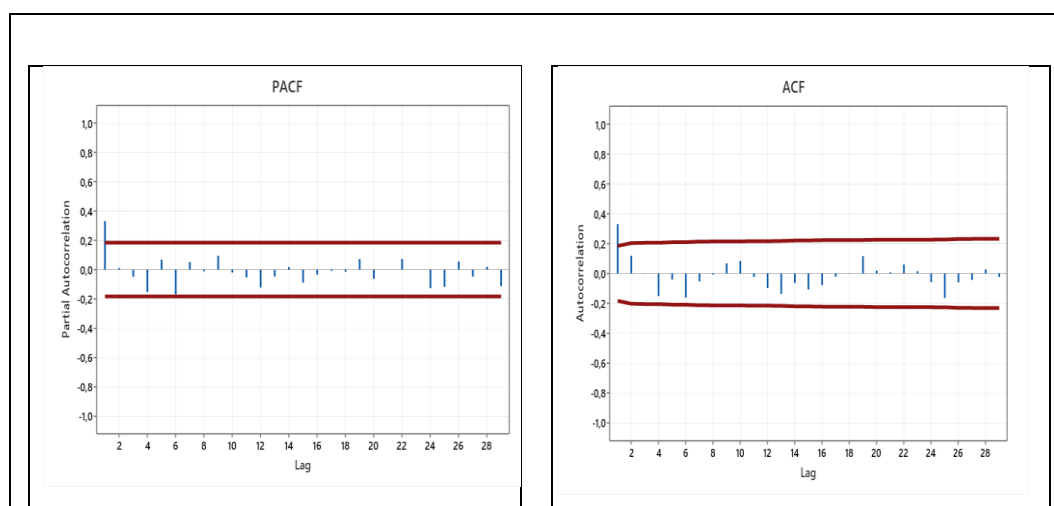
**Tabel 4.2.** Hasil Uji ADF

Tahap	ADF	<i>p-value</i>	Keterangan
Sebelum Differencing	-2.01	0.133	Tidak stasioner
Setelah Differencing	-7.42	0.000	Stasioner

Hasil menunjukkan bahwa data telah memenuhi syarat stasioner setelah dilakukan *differencing*.

#### Identifikasi Model

Setelah data dinyatakan stasioner, dilakukan identifikasi model dengan mengamati pola pada plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Pola ACF yang memotong pada lag ke-1 dan PACF yang meluruh perlahan mengindikasikan bahwa model ARIMA(2,1,1) merupakan kandidat yang sesuai.



**Gambar 4.2.** Plot ACF dan PACF

#### Estimasi Parameter dan Pemeriksaan Diagnostik

Estimasi parameter dilakukan menggunakan metode Maximum Likelihood Estimation (MLE). Hasil estimasi menunjukkan bahwa seluruh parameter dalam model ARIMA(2,1,1) signifikan secara statistik ( $p\text{-value} < 0,05$ ).

Tabel 4.3. Hasil Estimasi Parameter ARIMA(2,1,1)

Parameter	Estimasi	Std. Error	<i>z-value</i>	<i>p-value</i>
AR(1)	0,843	0,072	11,71	< 0,001
AR(2)	-0,431	0,084	-5,13	< 0,001
MA(1)	-0,981	0,067	-14,63	< 0,001

Setelah parameter diestimasi, dilakukan uji diagnostik terhadap residual model untuk memastikan bahwa asumsi *white noise* terpenuhi.

1. Uji Autokorelasi (Ljung-Box Test)

Hasil uji Ljung-Box menunjukkan bahwa tidak terdapat autokorelasi yang signifikan dalam residual ( $p\text{-value} > 0,05$ ), yang berarti residual bersifat acak.

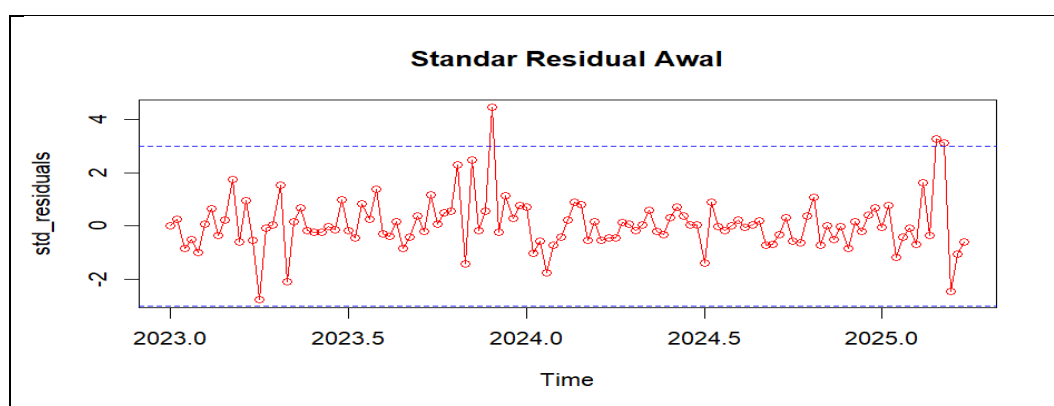
2. Uji Normalitas Residual

Uji *Kolmogorov Smirnov* memberikan  $p\text{-value} > 0,05$ , sehingga residual dianggap berdistribusi normal.

Berdasarkan hasil estimasi dan uji diagnostik, model ARIMA(2,1,1) dinyatakan layak dan dapat digunakan untuk analisis lebih lanjut, termasuk proses deteksi dan koreksi *outlier*.

#### 4.4 Metode ARIMA dengan Prosedur Iteratif

Prosedur iteratif digunakan untuk mendeteksi dan mengoreksi outlier bertipe *innovational outlier* (IO). Residual terstandarisasi digunakan untuk mengidentifikasi titik dengan deviasi lebih dari  $\pm 3\sigma$ .



Gambar 4.3. Plot Standardized Residual ARIMA (2,1,1)

Gambar 4.3 menunjukkan plot *standardized residual* pada model ARIMA (2,1,1) dapat dilihat bahwa terdapat *outlier* pada waktu ke-48, waktu ke-113 dan waktu ke-114. Setelah mendeteksi adanya *outlier* selanjutnya adalah melakukan modifikasi pada data *outlier* tersebut. Berikut adalah tabel iterasi dari beberapa *outlier* yang terdeteksi.



Tabel 4.4. Deteksi dan Koreksi IO

Iterasi	Minggu ke	Tipe Outlier	Keterangan
1	48	IO	Deteksi awal
1	113	IO	Deteksi awal
1	114	IO	Deteksi awal
2	14	IO	Tambahan

Total ada empat IO berhasil dikoreksi melalui dua kali iterasi. Model kemudian diperbarui menjadi ARIMA(2,1,1) + 4 IO. Dengan demikian, model akhir yang diperoleh dapat dituliskan secara matematis sebagai model ARIMA(2,1,1) dengan tambahan komponen IO pada titik waktu tertentu. Secara formal, model tersebut adalah:

$$Y_t = 2,302Y_{t-1} - 1,665Y_{t-2} + 0,363Y_{t-3} + \alpha_t + 0,999\alpha_{t-1} + 3,000.I_t^{(14)} + 3,322.I_t^{(48)} + 3,269.I_t^{(113)} + 3,496.I_t^{(114)}$$

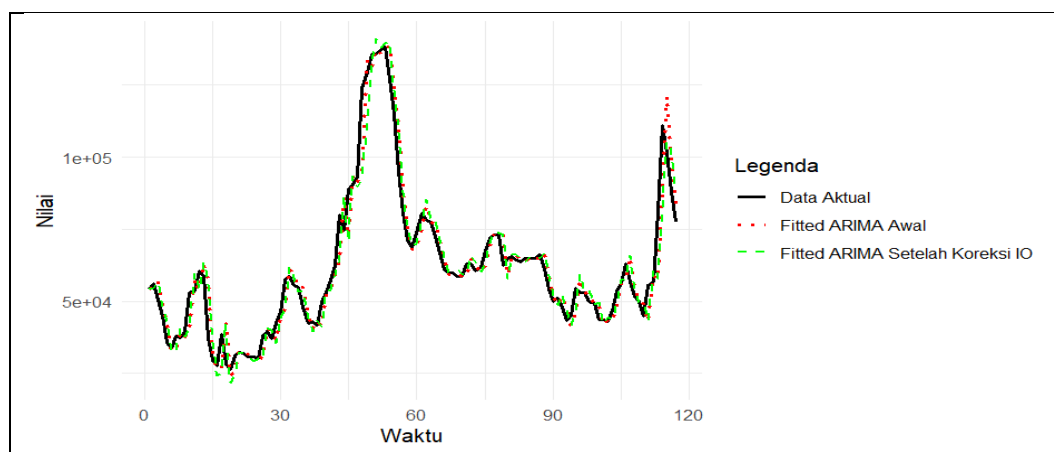
#### 4.5 Perbandingan Model

Perbandingan akurasi model sebelum dan sesudah koreksi IO dilakukan menggunakan *Mean Squared Error* (MSE).

Tabel 4.5. Perbandingan Model Sebelum dan Sesudah Koreksi Outlier

Model	MSE
ARIMA(2,1,1)	50.602.363
ARIMA(2,1,1) + 4 IO	38.245.864

Penurunan nilai MSE sebesar 24,4% menunjukkan bahwa koreksi IO memberikan dampak positif terhadap akurasi model.



Gambar 4.4. Plot Perbandingan

#### 4.6 Akurasi Peramalan

Untuk mengukur tingkat akurasi model dalam meramalkan harga, digunakan indikator Mean Absolute Percentage Error (MAPE). MAPE menghitung rata-rata dari persentase kesalahan antara nilai aktual dan nilai hasil peramalan. Dalam penelitian ini, data aktual harga cabai rawit merah pada bulan April dan Mei 2025 digunakan sebagai pembanding untuk menghitung nilai MAPE.

Penghitungan dilakukan untuk dua model, yaitu model ARIMA sebelum dan sesudah dilakukan koreksi *outlier*. Hasilnya disajikan sebagai berikut:

**JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI**  
Astrid Widyaningsih, Makkulau, Lilis Laome

**Tabel 4.6.** Perbandingan Nilai MAPE

Model	MAPE (%)	Kategori Akurasi
ARIMA(2,1,1) (tanpa koreksi)	13,407	Baik
ARIMA(2,1,1) + 4 IO (terkoreksi)	8,354	Sangat Baik

Hasil menunjukkan bahwa nilai MAPE pada model sebelum dilakukan koreksi adalah sebesar 13,407%, yang termasuk dalam kategori baik. Setelah dilakukan koreksi *outlier*, nilai MAPE menurun menjadi 8,354%, yang tergolong sangat baik. Penurunan nilai MAPE ini menunjukkan bahwa proses deteksi dan koreksi *innovational outlier* berhasil meningkatkan akurasi model. Model ARIMA(2,1,1) yang telah dikoreksi memiliki tingkat kesalahan prediksi yang lebih rendah, sehingga menghasilkan hasil ramalan yang lebih mendekati data aktual. Dengan demikian, model yang telah melalui proses koreksi lebih tepat digunakan dalam peramalan harga cabai rawit merah di Provinsi Sulawesi Tenggara.


#### 4.7 Peramalan

Model akhir digunakan untuk memprediksi harga cabai selama 12 minggu ke depan. Hasil peramalan menunjukkan tren penurunan harga dengan interval prediksi yang cenderung menyempit.

**Tabel 4.7.** Hasil Peramalan Harga Cabai Rawit Merah

Minggu ke	Prediksi Harga	Lo 80	Hi 80	Lo 95	Hi 95
118	79.275	71.275	87.275	67.275	91.275
119	75.887	67.887	83.887	63.887	87.887
120	73.601	65.601	81.601	61.601	85.601
...	...	...	...	...	...

Berikut adalah gambar hasil ramalan harga cabai rawit merah di Provinsi Sulawesi Tenggara 20 minggu kedepan



**Gambar 4.5.** Plot Hasil Ramalan

**5. KESIMPULAN**

Berdasarkan hasil dan pembahasan yang telah dilakukan maka dapat disimpulkan bahwa:

1. Tingkat akurasi peramalan mengalami peningkatan setelah dilakukan koreksi *outlier*, yang tercermin dari penurunan nilai MAPE dari 13,407% menjadi 8,354%. Penurunan ini mengindikasikan bahwa proses deteksi dan koreksi *outlier* berhasil meningkatkan kinerja model ARIMA, sehingga menghasilkan peramalan yang lebih mendekati nilai aktual dan lebih andal untuk menganalisis harga cabai rawit merah di Provinsi Sulawesi Tenggara.
2. Hasil peramalan harga cabai rawit merah menunjukkan adanya penurunan harga dari minggu ke minggu. Prediksi harga terus menurun, dan rentang perkiraan harga (interval kepercayaan) tetap stabil. Hal ini menunjukkan bahwa harga cabai rawit merah diperkirakan akan terus turun dalam beberapa minggu ke depan.

**DAFTAR PUSTAKA**

- [1] Aminnudin, Y. F., 2018. *Penerapan Filter Kalman Dalam Perbaikan Hasil Prediksi Return Harga Minyak Mentah Dunia Dengan Model ARIMA*. Institut Teknologi Sepuluh Nopember. Surabaya.
- [2] Bank Indonesia. 2024. *Perkembangan Harga Pangan Eceran*. Diakses 12 Oktober 2024, dari <https://www.bi.go.id/hargapangan>.
- [3] Boug , P., Hungnes, H. & Kurita, T., Getting Back on Track: Forecasting After Extreme Obeservations. *International Journal of Forecasting*, In Press
- [4] Cebeci, Z., Cebeci, C., Tahtali, Y. & Bayyurt, L., 2022. Two novel outlier detection approaches based on unsupervised possibilistic and fuzzy clustering. *PeerJ Comput. Sci.*, Vol. 8, e1060.
- [5] Chang, I., Tiao, G. C. & Chen, C., 1988. Estimation of time series parameters in the presence of outliers. *Technometrics*, Vol. 3, 193-204
- [6] Chen, J., Chen, T., Wang, Y. & Wang, L., 2024. A Survey of Time Series Data Forecasting Methods Based on Deep Learning. *JOBARI (Journal of Basic Applied Research International)*, Vol. 30, No. 6, 140-157.
- [7] Gu, Y.H., Jin, D., Yin, H., Zheng, R., Piao, X. & Yoo, S.J., 2022. Forecasting Agricultural Commodity Prices Using Dual Input Attention LSTM. *Agriculture*, Vol. 12, No.256.
- [8] Irazabal, J., Salazar, F., Silva-Cancino, N. & Vicente, D.J., 2025. Detection of Outliers in Dam Monitoring Time Series with Autoencoders. *Journal of Civil Structural Health Monitoring*, Vol. 15, 1771-1792
- [9] Kmytiuk, T., Majore, G. & Bilyk, T., 2024. Time Series Forecasting of Price of The Agricultural Products using Data Science. *Agricultural and Resource Economics: International Scientific E-Journal*, Vol. 10, No. 3.
- [10] Kong, X., Chen, Z., Liu, W., Ning, K., Zhang, L., Marier, S.M., Liu, Y., Chen. Y. & Xia, Feng., 2025. Deep Learning for Time Series Forecasting: A Survey. *International Journal of Machine Learning and Cybernetics*, Vol. 16, 5079-5112.
- [11] Laome, L., Wibawa, G.N., Raya, R., Makkulau & Asbahuna, A.R., 2021. Forecasting Time Series Data Containing Outliers with the ARIMA Additive Outlier Method. *Journal of Physics: Conference Series*, Vol. 1889, No. 012106
- [12] Prasetyo, K., Putri, D.D., Wijayanti, I.K.E. & Zulkifli, L., 2023. Forecasting of Red Chili Prices in Banyumas Regency: The ARIMA Approach. *E3S Web of Conferences*, Vol.444, No.02017.
- [13] Qadrini, L., Asrirawan, Mahmudah, N., Fahmuddin, M. & Amri, I. F., 2020. Peramalan *Inflow* dan *Outflow* Uang Kartal Bank Indonesia dengan Pendekatan ARIMA, *Time Series*

- Regression (TSR), ARIMAX, dan NN di Lampung. Jurnal Matematika, Statistika Dan Komputasi. Vol. 17, No.2.*
- [14] Ramadhan, A.U., Siregar, M.U., Nafisah, S., Gunawan, E.H. & Mulyawan, R., 2023. Price Forecasting of Chili Variant Commodities Using Radial Basis Function Neural Network. IJID (International Journal on Informatics for Development), Vol.12, No. 1, 1-14
- [15] Sadik, K., Erfiani, & WP, N., 2008. Pendeteksian Pencilan Aditif dan Inovatif dalam Data Deret Waktu Melalui Metode Iteratif. *Forum Statistika dan Komputasi. Vol.13, No.2.*
- [16] Sun, F., Meng, X., Zhang, Y., Wang, Y., Jiang, H. & Liu, P., 2023. Agricultural Product Price Forecasting Methods: A Review. *Agriculture, Vol. 13, No. 1671.*
- [17] Wang, L., 2025. ARIMA model analyzes the tendency and challenges of intelligent marketing in the era of digitalization. *Applied Mathematics and Nonlinear Sciences, Vol.10, No.1.*
- [18] Wei. 2006. *Time Series Analysis, Univariate and Multivariate Methods.* United States of America: Pearson Education Inc.